



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

ERIKA CARLOS MEDEIROS

**FreshnessScope:** Uma Solução Automatizada para Classificar o  
Frescor da Carne de Peixes com Base em Visão Computacional e  
*Machine learning*

Recife

2021

ERIKA CARLOS MEDEIROS

**FreshnessScope:** Uma Solução Automatizada para Classificar o Frescor da Carne de Peixes com Base em Visão Computacional e *Machine learning*

Tese de Doutorado apresentada à Universidade Federal de Pernambuco como requisito parcial para a obtenção do título de Doutor em Ciência da Computação.

Área de concentração: Inteligência Computacional

**Orientador:** Prof. Dr. Leandro Maciel Almeida

**Coorientador:** Prof. Dr. José Gilson de Almeida Teixeira Filho

Recife

2021

Catálogo na fonte  
Bibliotecária Nataly Soares Leite Moro, CRB4-1722

M488f    Medeiros, Erika Carlos  
            FreshnessScope uma solução automatizada para classificar o frescor da carne de peixes com base em visão computacional e machine learning / Erika Carlos Medeiros. – 2021.  
            290 f.: il., fig., tab., gráf.

            Orientador: Leandro Maciel Almeida.  
            Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2021.  
            Inclui referências e apêndices.

            1. Inteligência computacional. 2. Frescor da carne de peixes. 3. Frescor da carne de atum. 4. Frescor da carne de salmão. 5. Sistemas de visão computacional. I. Almeida, Leandro Maciel (orientador). II. Título

            006.31                      CDD (23. ed.)                      UFPE - CCEN 2022 – 33

**Erika Carlos Medeiros**

**FreshnessScope: Uma Solução Automatizada para Classificar o Frescor da Carne de Peixes com Base em Visão Computacional e *Machine learning*.**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Ciência da Computação. Área de Concentração: Inteligência Computacional.

Aprovado em: 14/12/2021.

---

**Orientador: Prof. Dr. Leandro Maciel Almeida**

**BANCA EXAMINADORA**

---

Prof. Dr. Cleber Zanchettin  
Centro de Informática / UFPE

---

Prof. Dr. Fernando Maciano de Paula Neto  
Centro de Informática / UFPE

---

Prof. Dr. Frederico Duarte de Menezes  
Instituto Federal de Pernambuco - Campus Recife

---

Prof. Dr. André Câmara Alves do Nascimento  
Departamento de Computação / UFRPE

---

Prof. Dr. João Fausto Lorenzato de Oliveira  
Departamento de Ciência da Computação / UDESC

À Tia Dilva, sempre.

## **AGRADECIMENTOS**

Ao meu pai, a minha mãe.

Aos meus irmãos.

Aos meus orientadores.

## RESUMO

Na indústria alimentícia, a inspeção manual sempre foi parte integrante do monitoramento e controle de qualidade. Além de tedioso e lento, esse processo tem alto custo associado a longos tempos treinamentos para formar especialistas e consequentemente tem baixa escalabilidade. Há uma necessidade evidente da adoção de sistemas de inspeção que possam fornecer informações confiáveis em todo processo de produção e que possam auxiliar o especialista humano. A motivação deste estudo centra-se na segurança alimentar, nomeadamente no consumo de peixes, e objetiva a classificação automatizada do nível de frescor da carne de peixe, através da análise de parâmetros colorimétricos, análise muito utilizada na indústria de pescados, haja vista a mudança de coloração da carne de peixes em função de sua deterioração. Tendo tal motivação em vista, usando visão computacional e aprendizagem de máquina, é construída uma solução de fácil e rápida instrumentalização de amostras para classificação automatizada do frescor da carne de peixes, que apresentem mudanças em sua coloração em função de mudanças no nível do frescor, de modo a diminuir a dependência de especialistas nesta tarefa. A solução usa níveis discretos de frescor de peixes e para sua construção foram capturadas 95 amostras de carne de atum e 105 amostras de carne de salmão, que estão disponíveis em conjuntos de dados de imagens inéditos. A solução, chamada de FreshnessScope, inclui *hardware* e protocolo para captura de imagens das amostras da carne dos peixes, protocolo para o pré-processamento das imagens digitais capturadas, além da extração de características de cores a partir destas. As características foram usadas como recursos em modelos de classificação baseados em AM. Os classificadores otimizados, presentes na solução, são baseados em aprendizagem supervisionada, e quando usados para a tarefa de classificação do frescor de amostras de carne de atum e salmão apresentaram alto desempenho. A solução FreshnessScope mostrou-se robusta, confiável e de fácil adaptabilidade, podendo ser operada por pessoas interessadas em classificação de peixes cujo frescor pode ser determinado por observação de padrões de cores. O maior custo da solução está associado ao uso de uma câmera fotográfica de 12 MP.

**Palavras-chave:** frescor da carne de peixes; frescor da carne do atum; frescor da carne do salmão; sistemas de visão computacional; aprendizagem de máquina.

## ABSTRACT

Manual inspection has always been an integral part of quality monitoring and control in the food industry. In addition to being tedious and slow, this process has a high cost associated with long training times to train specialists and, consequently, low scalability. There is a clear need to adopt inspection systems that can provide reliable information throughout the production process and that can help the human specialist. The motivation of this study is centred on food safety, namely in fish consumption. It aims at the automated classification of the freshness level of fish meat through the analysis of colorimetric parameters, an analysis widely used in the fish industry, given the change coloration of fish meat as a function of deterioration. With this motivation, using computer vision and machine learning, a solution for easy and quick instrumentation of samples for automated classification of fish meat freshness is built, which presents changes in their color due to changes in the level of freshness, to reduce the dependence of specialists in this task. The solution uses discrete levels of fish freshness, and to build it, 95 tuna meat samples and 105 salmon meat samples were captured, which are available in unprecedented image datasets. The solution, called FreshnessScope, includes *hardware* and a protocol for capturing images of fish meat samples, pre-processing the captured digital images, and extracting color characteristics from them. Characteristics were used as resources in AM-based classification models. The optimized classifiers present in the solution are based on supervised learning. When used to classify the freshness of tuna and salmon meat samples, they presented high performance. The FreshnessScope solution proved to be robust, reliable and easily adaptable and can be operated by people interested in grading fish whose freshness can be determined by observing color patterns. The highest cost of the solution is associated with using a 12 MP camera.

**Keywords:** fish meat freshness; tuna meat freshness; salmon meat freshness; computer Vision Systems; machine learning.

## LISTA DE FIGURAS

|             |                                                                                                                                                                                                   |     |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 1 -  | Passos abstratos para a construção de uma solução de classificação do frescor de carnes de peixe                                                                                                  | 37  |
| Figura 2 -  | Etapas de um sistema de visão computacional típico                                                                                                                                                | 42  |
| Figura 3 -  | Diferença de imagens (a) multiespectrais e (b) hiperespectrais                                                                                                                                    | 45  |
| Figura 4 -  | Sistema de coordenadas tridimensional formado pelos componentes do espaço cores RGB                                                                                                               | 49  |
| Figura 5 -  | Representação gráfica dos componentes do espaço de cores HSV                                                                                                                                      | 50  |
| Figura 6 -  | Representação gráfica dos componentes do espaço de cores HSI                                                                                                                                      | 51  |
| Figura 7 -  | Processo de Classificação                                                                                                                                                                         | 54  |
| Figura 8 -  | Framework Auto-Sklearn para realização de aprendizagem de máquina automatizada                                                                                                                    | 60  |
| Figura 9 -  | Representação da descida do gradiente para minimização da função de custo $J(w, b)$                                                                                                               | 71  |
| Figura 10 - | Rede Neural MLP                                                                                                                                                                                   | 76  |
| Figura 11 - | Gráficos dos comportamentos das funções de ativação implementadas                                                                                                                                 | 78  |
| Figura 12 - | Fases da metodologia para o desenvolvimento da solução para classificação do frescor da carne de peixes                                                                                           | 83  |
| Figura 13 - | Especialista extraíndo amostra da carne do atum, recém pescado e retirado de caminhões frigoríficos, através de sashibo                                                                           | 116 |
| Figura 14 - | Sashibo, instrumento cortante para puncionar o dorso do atum                                                                                                                                      | 116 |
| Figura 15 - | Amostras de carne de atum retiradas do sashibo diretamente em cartões de captura, feitos de papel, com formato quadrado e dimensões 23 x 23 cm, para serem levados ao SVC para serem fotografadas | 118 |
| Figura 16 - | Amostras de atum representantes das classes (a) 2+, (b) 2, (c) 2- e (d) 3                                                                                                                         | 118 |
| Figura 17 - | Amostras de salmão representantes das classes (a) “muito fresco”, (b) “fresco” e (c) “consumo imediato”                                                                                           | 119 |

|             |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                         |     |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 18 - | Salmões congelados em caixa de isopor, sendo inspecionados sensorialmente por especialista e cortados em pedaços para serem servidos ou para serem congelados                                                                                                                                                                                                                                                                                                                                           | 120 |
| Figura 19 - | (a) Amostra de atum e (b) amostra de salmão extraídas do corpo dos peixes para serem fotografadas                                                                                                                                                                                                                                                                                                                                                                                                       | 121 |
| Figura 20 - | Imagens de amostras de carne de atum extraídas com sashibo e fotografadas sobre a bancada sobre fundo branco e sobre o corpo do peixe, sem uso de padronização de captura                                                                                                                                                                                                                                                                                                                               | 122 |
| Figura 21 - | Desenho do estúdio fotográfico usado no SVC (a) montado e (b) desmontado                                                                                                                                                                                                                                                                                                                                                                                                                                | 123 |
| Figura 22 - | Configuração adotada do SVC para captura de imagens de amostras de atum e salmão, constando de estúdio fotográfico com luzes de LED circulares e abertura no topo                                                                                                                                                                                                                                                                                                                                       | 124 |
| Figura 23 - | Imagens de amostras de carne de atum extraídas com sashibo e postas em folha de isopor branco com áreas de classificação demarcadas, para serem retiradas da área de descarga da indústria de pescados e então fotografadas                                                                                                                                                                                                                                                                             | 127 |
| Figura 24 - | Imagem de amostra de carne de atum extraída com sashibo e fotografadas no estúdio sobre fundo preto                                                                                                                                                                                                                                                                                                                                                                                                     | 127 |
| Figura 25 - | Configuração alternativa de iluminação por trás das amostras de atum                                                                                                                                                                                                                                                                                                                                                                                                                                    | 128 |
| Figura 26 - | Amostra (a) de atum e (b) de salmão colocadas sob fundo branco para serem fotografadas                                                                                                                                                                                                                                                                                                                                                                                                                  | 128 |
| Figura 27 - | Etapas de pré-processamento de imagens para amostras de atum. Legenda: Passo 1: redimensionar a imagem original para 600 x 400 pixels; Passo 2: criar imagem em tons de cinza, a partir da máscara que usa um limite para variações de vermelho; Passo 3: criar imagem em tons de cinza, a partir de filtro gaussiano; Passo 4: criar imagem binária, a partir de uma função de limiarização; Passo 5: definir contornos; Passo 6: fazer corte da área contornada para determinar a região de interesse | 133 |

|             |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |     |
|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 28 - | Etapas de pré-processamento de imagens para amostras de salmão. Legenda: Passo 1: redimensionar a imagem original para 600 x 400 pixels; Passo 2: criar imagem em tons de cinza, a partir da máscara que usa um limite para variações de laranja; Passo 3: criar imagem em tons de cinza, a partir de filtro gaussiano; Passo 4: criar imagem binária, a partir de uma função de limiarização; Passo 5: definir contornos; Passo 6: fazer corte da área contornada para determinar a região de interesse | 134 |
| Figura 29 - | Matriz de correlação das características colorimétricas extraídas de amostras de atum                                                                                                                                                                                                                                                                                                                                                                                                                    | 136 |
| Figura 30 - | Matriz de correlação das características colorimétricas extraídas de amostras de salmão                                                                                                                                                                                                                                                                                                                                                                                                                  | 137 |
| Figura 31 - | Número de classes ou níveis de frescor existentes nos conjuntos de dados de (a) atum e (b) salmão                                                                                                                                                                                                                                                                                                                                                                                                        | 138 |
| Figura 32 - | Agrupamentos por níveis de frescor (a) do atum e (b) do salmão gerados pela técnica de redução de dimensionalidade UMAP                                                                                                                                                                                                                                                                                                                                                                                  | 139 |
| Figura 33 - | Fluxograma para construção dos modelos de classificação através do AM automatizada                                                                                                                                                                                                                                                                                                                                                                                                                       | 142 |
| Figura 34 - | PipelineProfiler gerado pelo Auto-Sklearn com modelos para classificação do frescor de amostras de atum                                                                                                                                                                                                                                                                                                                                                                                                  | 143 |
| Figura 35 - | Matriz de confusão de uma previsão do frescor da carne do atum feita pelo AutoML_Ensemble                                                                                                                                                                                                                                                                                                                                                                                                                | 146 |
| Figura 36 - | PipelineProfiler gerado pelo sistema Auto-Sklearn com modelos para classificação do frescor de amostras de salmão                                                                                                                                                                                                                                                                                                                                                                                        | 146 |
| Figura 37 - | Matriz de confusão de uma previsão do frescor da carne do salmão feita pelo AutoML_Ensemble                                                                                                                                                                                                                                                                                                                                                                                                              | 149 |
| Figura 38 - | Fluxograma para construção dos modelos de classificação, com trinta repetições                                                                                                                                                                                                                                                                                                                                                                                                                           | 151 |
| Figura 39 - | Arquitetura do Autoencoder com base em MLP, composta de duas camadas ocultas no Codificador e duas camadas ocultas no Decodificador                                                                                                                                                                                                                                                                                                                                                                      | 152 |

|             |                                                                                                                                                                                                                            |     |
|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 40 - | Curvas de aprendizagem de treinamento do Autoencoder construído com (a) o conjunto de dados de amostras de atum e com (b) o conjunto de dados de amostras de salmão, mostrando a reconstrução das entradas sem sobreajuste | 152 |
| Figura 41 - | Diferenças estatísticas entre os modelos de classificação do frescor da carne de atum para DC = 10,761, calculada pelo teste de Nemenyi                                                                                    | 167 |
| Figura 42 - | Diferenças estatísticas entre os modelos de classificação do frescor de salmão para DC = 10,761, calculada pelo teste de Nemenyi                                                                                           | 174 |
| Figura 43 - | Diagrama das etapas da solução FreshnessScope                                                                                                                                                                              | 177 |
| Figura 44 - | Gráfico de agrupamento das classes de frescor de amostras de atum gerado pela técnica UMAP e destaque para possíveis confusões na classificação realizada pelos modelos                                                    | 218 |
| Figura 45 - | Matriz de confusão da previsão feita pelo melhor modelo Ensemble_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                    | 221 |
| Figura 46 - | Matriz de confusão da previsão feita pelo melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                                     | 222 |
| Figura 47 - | Matriz de confusão da previsão feita pelo melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                                      | 225 |
| Figura 48 - | Matriz de confusão da previsão feita pelo melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                                      | 227 |
| Figura 49 - | Matriz de confusão da previsão feita pelo melhor modelo ExtraTrees_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                     | 229 |
| Figura 50 - | Matriz de confusão da previsão feita pelo melhor modelo PA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                             | 231 |

|             |                                                                                                                                                                          |     |
|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 51 - | Matriz de confusão da previsão feita pelo melhor modelo MLP_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                          | 233 |
| Figura 52 - | Matriz de confusão da previsão feita pelo melhor modelo SGD_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                          | 236 |
| Figura 53 - | Matriz de confusão da previsão feita pelo melhor modelo LR_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                           | 238 |
| Figura 54 - | Matriz de confusão da previsão feita pelo melhor modelo DT_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                           | 240 |
| Figura 55 - | Matriz de confusão da previsão feita pelo melhor modelo QDA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                          | 242 |
| Figura 56 - | Matriz de confusão da previsão feita pelo melhor modelo NC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                           | 245 |
| Figura 57 - | Matriz de confusão da previsão feita pelo melhor modelo RC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                           | 247 |
| Figura 58 - | Matriz de confusão da previsão feita pelo melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                   | 248 |
| Figura 59 - | Matriz de confusão da previsão feita pelo melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                   | 251 |
| Figura 60 - | Gráfico de agrupamento das classes de frescor de amostra de salmão gerado pela técnica UMAP e destaque para possíveis confusões na classificação realizada pelos modelos | 253 |
| Figura 61 - | Matriz de confusão da previsão feita pelo melhor modelo NC_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                         | 255 |

|             |                                                                                                                                                        |     |
|-------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 62 - | Matriz de confusão da previsão feita pelo melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 257 |
| Figura 63 - | Matriz de confusão da previsão feita pelo melhor modelo LDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 258 |
| Figura 64 - | Matriz de confusão da previsão feita pelo melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 261 |
| Figura 65 - | Matriz de confusão da previsão feita pelo melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 263 |
| Figura 66 - | Matriz de confusão da previsão feita pelo melhor modelo SVM_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 265 |
| Figura 67 - | Matriz de confusão da previsão feita pelo melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 267 |
| Figura 68 - | Matriz de confusão da previsão feita pelo melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 269 |
| Figura 69 - | Matriz de confusão da previsão feita pelo melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 271 |
| Figura 70 - | Matriz de confusão da previsão feita pelo melhor modelo AdaBoost_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 273 |
| Figura 71 - | Matriz de confusão da previsão feita pelo melhor modelo QDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 275 |
| Figura 72 - | Matriz de confusão da previsão feita pelo melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 278 |

|             |                                                                                                                                                    |     |
|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Figura 73 - | Matriz de confusão da previsão feita pelo melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições            | 280 |
| Figura 74 - | Matriz de confusão da previsão feita pelo melhor Ensemble_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 282 |
| Figura 75 - | Matriz de confusão da previsão feita pelo melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições           | 284 |
| Figura 76 - | Matriz de confusão da previsão feita pelo melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições            | 286 |
| Figura 77 - | Matriz de confusão da previsão feita pelo melhor modelo RF_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições   | 289 |

## LISTA DE GRÁFICOS

|              |                                                                                                                                                                                                                      |     |
|--------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 1 -  | Distribuição dos artigos do MSL por ano de publicação                                                                                                                                                                | 87  |
| Gráfico 2 -  | Tipo de carnes estudadas nos artigos do MSL para determinação de seu frescor                                                                                                                                         | 88  |
| Gráfico 3 -  | Distribuição dos artigos do MSL por método de análise sensorial                                                                                                                                                      | 88  |
| Gráfico 4 -  | Curva ROC do AutoML_Ensemble para a classificação do frescor de amostras de atum                                                                                                                                     | 144 |
| Gráfico 5 -  | Importância das características para o AutoML_Ensemble ao classificar o frescor da carne do atum                                                                                                                     | 145 |
| Gráfico 6 -  | Curva ROC do AutoML_Ensemble para a classificação do frescor de amostras de salmão                                                                                                                                   | 147 |
| Gráfico 7 -  | Importância das características para o AutoML_Ensemble ao classificar o frescor da carne do salmão                                                                                                                   | 148 |
| Gráfico 8 -  | Médias das acurácias de treinamento ordenadas da maior para a menor, médias das acurácias de teste e tempos médios de treinamento dos 37 (trinta e sete) modelos para classificação do frescor de amostras de atum   | 162 |
| Gráfico 9 -  | Tempos médios de treinamento dos modelos escolhidos para a classificação do frescor da carne do atum                                                                                                                 | 168 |
| Gráfico 10 - | Médias das acurácias de treinamento ordenadas da maior para a menor, médias das acurácias de teste e tempos médios de treinamento dos 37 (trinta e sete) modelos para classificação do frescor de amostras de salmão | 171 |
| Gráfico 11 - | Tempos médios de treinamento dos modelos escolhidos para a classificação do frescor da carne do salmão                                                                                                               | 176 |
| Gráfico 12 - | Importância das características para o melhor modelo Ensemble_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                 | 222 |
| Gráfico 13 - | Curva ROC do melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                                                                                            | 223 |

|              |                                                                                                                                                     |     |
|--------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 14 - | Importância das características para o melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições                 | 224 |
| Gráfico 15 - | Curva ROC do melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                            | 226 |
| Gráfico 16 - | Importância das características para o melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições                  | 226 |
| Gráfico 17 - | Curva ROC do melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                            | 228 |
| Gráfico 18 - | Importância das características para o melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições                  | 228 |
| Gráfico 19 - | Curva ROC do melhor modelo ExtraTrees_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                           | 230 |
| Gráfico 20 - | Importância das características para o melhor modelo ExtraTrees_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições | 230 |
| Gráfico 21 - | Importância das características para o melhor modelo PA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 232 |
| Gráfico 22 - | Curva ROC do melhor modelo MLP_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                  | 234 |
| Gráfico 23 - | Importância das características para o melhor modelo MLP_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições        | 235 |
| Gráfico 24 - | Importância das características para o melhor modelo SGD_Ensemble para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 237 |
| Gráfico 25 - | Curva ROC do melhor modelo LR_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                   | 239 |

|              |                                                                                                                                               |     |
|--------------|-----------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 26 - | Importância das características para o melhor modelo LR_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições   | 239 |
| Gráfico 27 - | Curva ROC do melhor modelo DT_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                             | 241 |
| Gráfico 28 - | Importância das características para o melhor modelo DT_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições   | 242 |
| Gráfico 29 - | Curva ROC do melhor modelo QDA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições                            | 243 |
| Gráfico 30 - | Importância das características para o melhor modelo QDA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições  | 244 |
| Gráfico 31 - | Importância das características para o melhor modelo NC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições   | 246 |
| Gráfico 32 - | Importância das características para o melhor modelo RC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições   | 248 |
| Gráfico 33 - | Curva ROC do melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                     | 249 |
| Gráfico 34 - | Importância das características para o melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições           | 250 |
| Gráfico 35 - | Curva ROC do melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições                                     | 251 |
| Gráfico 36 - | Importância das características para o melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições           | 252 |
| Gráfico 37 - | Importância das características para o melhor modelo NC_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 256 |

|              |                                                                                                                                                |     |
|--------------|------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 38 - | Importância das características para o melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições           | 258 |
| Gráfico 39 - | Curva ROC do melhor modelo LDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                           | 260 |
| Gráfico 40 - | Importância das características para o melhor modelo LDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 260 |
| Gráfico 41 - | Curva ROC do melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                    | 262 |
| Gráfico 42 - | Importância das características para o melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 262 |
| Gráfico 43 - | Importância das características para o melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 264 |
| Gráfico 44 - | Importância das características para o melhor modelo SVM_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 266 |
| Gráfico 45 - | Curva ROC do melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                    | 268 |
| Gráfico 46 - | Importância das características para o melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 268 |
| Gráfico 47 - | Curva ROC do melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                     | 270 |
| Gráfico 48 - | Importância das características para o melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições           | 270 |
| Gráfico 49 - | Curva ROC do melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                     | 272 |

|              |                                                                                                                                                        |     |
|--------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 50 - | Importância das características para o melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                   | 272 |
| Gráfico 51 - | Curva ROC do melhor modelo AdaBoost_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                              | 274 |
| Gráfico 52 - | Importância das características para o melhor modelo AdaBoost_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições    | 275 |
| Gráfico 53 - | Curva ROC do melhor modelo QDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                   | 276 |
| Gráfico 54 - | Importância das características para o melhor modelo QDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições         | 277 |
| Gráfico 55 - | Curva ROC do melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                       | 279 |
| Gráfico 56 - | Importância das características para o melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições             | 279 |
| Gráfico 57 - | Curva ROC do melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                             | 281 |
| Gráfico 58 - | Importância das características para o melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                   | 281 |
| Gráfico 59 - | Importância das características para o melhor modelo Ensemble_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 283 |
| Gráfico 60 - | Curva ROC do melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                            | 285 |
| Gráfico 61 - | Importância das características para o melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                  | 286 |

|              |                                                                                                                                               |     |
|--------------|-----------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Gráfico 62 - | Curva ROC do melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                                    | 288 |
| Gráfico 63 - | Importância das características para o melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 288 |
| Gráfico 64 - | Curva ROC do melhor modelo RF_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                           | 290 |
| Gráfico 65 - | Importância das características para o melhor modelo RF_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 290 |

## LISTA DE QUADROS

|            |                                                                                                                                                                                                                                                                                                                      |     |
|------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Quadro 1 - | Hiper parâmetros que controlam a construção do ensemble no Auto-Sklearn                                                                                                                                                                                                                                              | 61  |
| Quadro 2 - | Diferenças entre os classificadores DT, RF e ExtraTrees                                                                                                                                                                                                                                                              | 67  |
| Quadro 3 - | Etapas do processo do mapeamento sistemático da literatura                                                                                                                                                                                                                                                           | 85  |
| Quadro 4 - | Construção do SVC segundo a metodologia DSR                                                                                                                                                                                                                                                                          | 129 |
| Quadro 5 - | Hiper parâmetros e valores utilizados na otimização dos modelos para classificação do frescor da carne de peixes                                                                                                                                                                                                     | 156 |
| Quadro 6 - | Modelos, hiper parâmetros não otimizados e respectivos valores utilizados                                                                                                                                                                                                                                            | 159 |
| Quadro 7 - | Modelos para classificação do frescor da carne do atum que apresentaram as maiores acurácias de treinamento entre as 30 (trinta) repetições, seus valores de hiper parâmetros otimizados (para o Ensemble_Hibrido, que classificadores são utilizados) e primitiva de pré-processamento de característica aplicada   | 164 |
| Quadro 8 - | Modelos para classificação do frescor da carne do salmão que apresentaram as maiores acurácias de treinamento entre as 30 (trinta) repetições, seus valores de hiper parâmetros otimizados (para o Ensemble_Hibrido, que classificadores são utilizados) e primitiva de pré-processamento de característica aplicada | 172 |

## LISTA DE TABELAS

|             |                                                                                                                                                                      |     |
|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1 -  | Quantidade de artigos resultantes após as etapas do mapeamento sistemático da literatura                                                                             | 87  |
| Tabela 2 -  | Estudos resultantes do mapeamento sistemático da literatura                                                                                                          | 91  |
| Tabela 3 -  | Métricas do AutoML_Ensemble para a classificação do frescor de amostras de atum                                                                                      | 144 |
| Tabela 4 -  | Métricas do AutoML_Ensemble para a classificação do frescor de amostras de salmão                                                                                    | 147 |
| Tabela 5 -  | Médias das acurácias de treinamento, médias das acurácias de teste e médias dos tempos de treinamento dos modelos para classificação do frescor da carne do atum     | 161 |
| Tabela 6 -  | Acurácias de treinamento e de teste dos 15 (quinze) modelos igualmente eficientes e elencados para a classificação do frescor da carne do atum                       | 168 |
| Tabela 7 -  | Médias das acurácias de treinamento, médias das acurácias de teste e tempos médios de treinamento dos modelos para classificação do frescor da carne do salmão       | 170 |
| Tabela 8 -  | Acurácias de treinamento e de teste dos 17 (dezesete) modelos igualmente eficientes e elencados para a classificação do frescor da carne do salmão                   | 175 |
| Tabela 9 -  | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo Ensemble_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições | 221 |
| Tabela 10 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições                  | 223 |
| Tabela 11 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições                   | 225 |
| Tabela 12 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições                   | 227 |

|             |                                                                                                                                                                     |     |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 13 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo ExtraTrees_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições | 229 |
| Tabela 14 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo PA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 232 |
| Tabela 15 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo MLP_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições        | 234 |
| Tabela 16 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo SGD_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições        | 236 |
| Tabela 17 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo LR_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 238 |
| Tabela 18 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo DT_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 241 |
| Tabela 19 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo QDA_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições        | 243 |
| Tabela 20 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo NC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 245 |
| Tabela 21 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo RC_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições         | 247 |
| Tabela 22 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições                 | 249 |
| Tabela 23 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições                 | 251 |

|             |                                                                                                                                                                     |     |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 24 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo NC_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições       | 255 |
| Tabela 25 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 257 |
| Tabela 26 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo LDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 259 |
| Tabela 27 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 261 |
| Tabela 28 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 263 |
| Tabela 29 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo SVM_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 265 |
| Tabela 30 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições               | 267 |
| Tabela 31 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 269 |
| Tabela 32 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                | 272 |
| Tabela 33 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo AdaBoost_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 274 |
| Tabela 34 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo QDA_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições      | 276 |

|             |                                                                                                                                                                        |     |
|-------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 35 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições             | 278 |
| Tabela 36 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                   | 280 |
| Tabela 37 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo Ensemble_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições | 283 |
| Tabela 38 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                  | 285 |
| Tabela 39 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições                   | 287 |
| Tabela 40 - | Precisão, recall, F1-Score e acurácia das previsões do melhor modelo RF_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições          | 289 |

## LISTA DE ABREVIATURAS E SIGLAS

|                  |                                                                |
|------------------|----------------------------------------------------------------|
| AdaBoost         | <i>Adaptive Boosting</i>                                       |
| ADASYN           | <i>Adaptive Synthetic Sampling</i>                             |
| AM               | <i>Aprendizagem de Máquina</i>                                 |
| ABC-ANN          | <i>Artificial Bee Colony-Artificial Neural Network</i>         |
| AUC              | <i>Area Under the Curve (Área sob a Curva)</i>                 |
| BNB              | <i>Bernoulli Naive Bayes</i>                                   |
| CE               | <i>Critérios de Exclusão</i>                                   |
| CEI              | <i>Commission Internationale de l'Éclairage</i>                |
| CEILAB           | <i>L*a*b*</i>                                                  |
| CI               | <i>Critérios de Inclusão</i>                                   |
| CM               | <i>Classificação Média</i>                                     |
| CO               | <i>Monóxido de Carbono</i>                                     |
| DA               | <i>Discriminant Analysis</i>                                   |
| DA-PLS           | <i>Discriminant Analysis Partial Least Squares</i>             |
| DAM              | <i>Desvio Absoluto da Mediana</i>                              |
| DC               | <i>Distância Crítica</i>                                       |
| DL               | <i>DeepLearning</i>                                            |
| DSR              | <i>Design Science Research</i>                                 |
| DT               | <i>Decision Tree</i>                                           |
| ELM              | <i>Extreme Learning Machine</i>                                |
| e-Nose           | <i>Electronic Nose (Nariz Eletrônico)</i>                      |
| e-Tongue         | <i>Electronic Tongue (Língua Eletrônica)</i>                   |
| elish            | <i>Exponential Linear Squashing</i>                            |
| elu              | <i>Exponential linear</i>                                      |
| ExtraTrees       | <i>Extremely Randomized Trees</i>                              |
| FA               | <i>Função de Ativação</i>                                      |
| FAO              | <i>Food and Agriculture Organization of the United Nations</i> |
| FN               | <i>Falso Negativo</i>                                          |
| FP               | <i>Falso Positivo</i>                                          |
| GB               | <i>Gradient Boosting</i>                                       |
| GNB              | <i>Gaussian Naive Bayes</i>                                    |
| GQM              | <i>Goal, Question, Metric</i>                                  |
| hardlim          | <i>Hard Limiting Function</i>                                  |
| hardtanh         | <i>Hard Hiperbolic Function</i>                                |
| HSI              | <i>Hue, Saturation, Intensity</i>                              |
| HSV              | <i>Hue, Saturation, Value</i>                                  |
| IA               | <i>Inteligência Artificial</i>                                 |
| inv_multiquadric | <i>Inverse Multiquadric Radial Basis Function</i>              |
| inv_tribas       | <i>Inverse Triangular Basis Transfer Function</i>              |
| KNN              | <i>K-Nearest Neighbors</i>                                     |
| LDA              | <i>Linear Discriminant Analysis</i>                            |
| LLE              | <i>Locally Linear Embedding</i>                                |
| LR               | <i>Logistic Regression</i>                                     |
| lrelu            | <i>Leaky ReLU</i>                                              |
| LS-SVM           | <i>Least-Squares Support Vector Machines</i>                   |
| MC               | <i>Matriz de Confusão</i>                                      |
| MLP              | <i>Multilayer Perceptron</i>                                   |
| MNB              | <i>Multinomial Naive Bayes</i>                                 |

|                   |                                                                                        |
|-------------------|----------------------------------------------------------------------------------------|
| multiquadric      | <i>Multiquadric Radial Basis Function</i>                                              |
| NB                | <i>Naive Bayes</i>                                                                     |
| NC                | <i>Nearest Centroid</i>                                                                |
| NIASM             | <i>Institute of Abiotic Stress Management</i>                                          |
| NIR               | <i>Near Infrared</i>                                                                   |
| P/B               | <i>Preto e branco</i>                                                                  |
| PA                | <i>Passive Aggressive</i>                                                              |
| PCA               | <i>Principal Component Analysis</i>                                                    |
| PLSR              | <i>Partial Least-Square Regression</i>                                                 |
| QDA               | <i>Quadratic Discriminat Analysis</i>                                                  |
| RandomOverSampler | <i>Random Over-Sampling</i>                                                            |
| RBF               | <i>Radial Basis Function</i>                                                           |
| RC                | <i>Ridge Classifier</i>                                                                |
| RDI               | <i>Região de Interesse</i>                                                             |
| relu              | <i>Rectified Linear Unit</i>                                                           |
| RF                | <i>Random Forest</i>                                                                   |
| RGB               | <i>Red, Green, Blue</i>                                                                |
| RNA               | <i>Redes Neurais Artificiais</i>                                                       |
| RNC               | <i>Rede Neural Convolucional</i>                                                       |
| ROC               | <i>Receiver Operational Characteristics (Características Operacionais do Receptor)</i> |
| SGD               | <i>Stochastic Gradient Descent</i>                                                     |
| sine              | <i>Sinusoidal Function</i>                                                             |
| SMOTE             | <i>Synthetic Minority Oversampling Technique</i>                                       |
| softlim           | <i>Soft Limiting Function</i>                                                          |
| SVC               | <i>Sistema de Visão Computacional</i>                                                  |
| SVM               | <i>Support Vector Machine</i>                                                          |
| tanh              | <i>Hyperbolic Tangent Function</i>                                                     |
| tanhre            | <i>Combinação das funções relu e tanh</i>                                              |
| TBA               | <i>Thiobarbituric Acid</i>                                                             |
| tribas            | <i>Triangular Basis Transfer Function</i>                                              |
| TVB-N             | <i>Total Volatile Basic Nitrogen</i>                                                   |
| TVC               | <i>Total Viable Counts</i>                                                             |
| UE                | <i>Unidade Experimental</i>                                                            |
| UMAP              | <i>Manifold Approximation and Projection</i>                                           |
| VarianceThreshold | <i>Variance Thresholding</i>                                                           |
| VC                | <i>Visão Computacional</i>                                                             |
| VN                | <i>Verdadeiro Negativo</i>                                                             |
| VP                | <i>Verdadeiro Positivo</i>                                                             |

## SUMÁRIO

|          |                                                                          |           |
|----------|--------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO.....</b>                                                   | <b>31</b> |
| 1.1      | MOTIVAÇÃO E JUSTIFICATIVA.....                                           | 34        |
| 1.2      | PROBLEMA DE PESQUISA.....                                                | 36        |
| 1.3      | OBJETIVOS.....                                                           | 37        |
| 1.4      | ORGANIZAÇÃO DO TRABALHO.....                                             | 38        |
| <b>2</b> | <b>FUNDAMENTAÇÃO TEÓRICA.....</b>                                        | <b>39</b> |
| 2.1      | MÉTODOS NÃO DESTRUTIVOS DE INSPEÇÃO DE PRODUTOS<br>CÁRNEOS.....          | 41        |
| 2.1.1    | <i>Sistemas de Visão Computacional.....</i>                              | 42        |
| 2.1.2    | <i>Espectroscopia de Refletância de Infravermelho Próximo.....</i>       | 43        |
| 2.1.3    | <i>Imagens Espectrais.....</i>                                           | 44        |
| 2.1.4    | <i>Espectroscopia Raman.....</i>                                         | 45        |
| 2.1.5    | <i>Imagens Ultrassônicas.....</i>                                        | 46        |
| 2.1.6    | <i>Nariz e Língua Eletrônicos.....</i>                                   | 47        |
| 2.2      | ESPAÇOS DE CORES.....                                                    | 48        |
| 2.2.1    | <i>Espaço de Cores RGB.....</i>                                          | 48        |
| 2.2.2    | <i>Espaço de Cores HSV.....</i>                                          | 49        |
| 2.2.3    | <i>Espaço de Cores HSI.....</i>                                          | 51        |
| 2.2.4    | <i>Espaço de Cores <math>L^*a^*b^*</math>.....</i>                       | 52        |
| 2.3      | APRENDIZAGEM DE MÁQUINA.....                                             | 53        |
| 2.3.1    | <i>Primitivas de Pré-Processamento de Dimensionamento dos Dados.....</i> | 54        |
| 2.3.2    | <i>Primitivas de Pré-Processamento de Características.....</i>           | 56        |
| 2.3.3    | <i>Primitivas de Balanceamento de Classes.....</i>                       | 56        |
| 2.3.4    | <i>Otimização de Hiper Parâmetros.....</i>                               | 57        |
| 2.3.5    | <i>Classificadores.....</i>                                              | 59        |
| 2.3.5.1  | <i>Aprendizagem de Máquina Automatizada.....</i>                         | 59        |
| 2.3.5.2  | <i>Ridge Classifier.....</i>                                             | 62        |
| 2.3.5.3  | <i>K-Nearest Neighbors.....</i>                                          | 62        |
| 2.3.5.4  | <i>Linear e Quadratic Discriminant Analysis.....</i>                     | 63        |
| 2.3.5.5  | <i>Passive Aggressive.....</i>                                           | 63        |
| 2.3.5.6  | <i>Decision Tree, Random Forest e Extremely Randomized Trees.....</i>    | 65        |

|          |                                                                                                                                                    |            |
|----------|----------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 2.3.5.7  | Adaptive Boosting.....                                                                                                                             | 67         |
| 2.3.5.8  | Gradient Boost.....                                                                                                                                | 69         |
| 2.3.5.9  | Stochastic Gradient Descent.....                                                                                                                   | 71         |
| 2.3.5.10 | Support Vector Machine.....                                                                                                                        | 72         |
| 2.3.5.11 | Logistic Regression.....                                                                                                                           | 73         |
| 2.3.5.12 | Naive Bayes.....                                                                                                                                   | 74         |
| 2.3.5.13 | Nearest Centroid.....                                                                                                                              | 74         |
| 2.3.5.14 | Multilayer Perceptron.....                                                                                                                         | 75         |
| 2.3.5.15 | Extreme Learning Machine.....                                                                                                                      | 76         |
| 2.3.5.16 | Ensemble.....                                                                                                                                      | 79         |
| 2.3.6    | <i>Importância de Características.....</i>                                                                                                         | 80         |
| 2.4      | SÍNTESE DO CAPÍTULO.....                                                                                                                           | 81         |
| <b>3</b> | <b>METODOLOGIA DE PESQUISA.....</b>                                                                                                                | <b>82</b>  |
| 3.1      | REVISÃO DA LITERATURA.....                                                                                                                         | 84         |
| 3.1.1    | <i>Mapeamento Sistemático da Literatura.....</i>                                                                                                   | 85         |
| 3.1.1.1  | Estratégia de Busca.....                                                                                                                           | 86         |
| 3.1.1.2  | Estudos Resultantes do Mapeamento Sistemático da Literatura.....                                                                                   | 86         |
| 3.1.1.3  | Síntese dos Estudos Resultantes do Mapeamento Sistemático da Literatura.....                                                                       | 97         |
| 3.1.1.4  | Trabalhos Relacionados.....                                                                                                                        | 101        |
| 3.2      | DESIGN SCIENCE RESEARCH.....                                                                                                                       | 106        |
| 3.3      | EXPERIMENTAÇÃO.....                                                                                                                                | 106        |
| 3.3.1    | <i>Objetivo da Experimentação.....</i>                                                                                                             | 109        |
| 3.3.2    | <i>Planejamento.....</i>                                                                                                                           | 110        |
| 3.3.3    | <i>Preparação da Experimentação.....</i>                                                                                                           | 112        |
| 3.4      | SÍNTESE DO CAPÍTULO.....                                                                                                                           | 113        |
| <b>4</b> | <b>ETAPAS PARA CONSTRUÇÃO DE UMA SOLUÇÃO AUTOMATIZADA DE CLASSIFICAÇÃO DO FRESCOR DA CARNE DE PEIXES COM BASE EM CARACTERÍSTICAS DE CORES.....</b> | <b>115</b> |
| 4.1      | ETAPA 1: PREPARAÇÃO DAS AMOSTRAS.....                                                                                                              | 115        |
| 4.2      | ETAPA 2: SISTEMA DE VISÃO COMPUTACIONAL.....                                                                                                       | 122        |
| 4.3      | ETAPA 3: PRÉ-PROCESSAMENTO DAS IMAGENS.....                                                                                                        | 131        |
| 4.4      | ETAPA 4: EXTRAÇÃO DE CARACTERÍSTICAS COLORIMÉTRICAS.....                                                                                           | 135        |

|          |                                                                                                                                                |            |
|----------|------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| 4.5      | ETAPA 5: USO DOS MODELOS DE APRENDIZAGEM DE MÁQUINA....                                                                                        | 139        |
| 4.5.1    | <i>Modelos Criados com Base em Aprendizagem de Máquina.....</i>                                                                                | 140        |
| 4.6      | MODELOS PARA A CLASSIFICAÇÃO DO FRESCOR DA CARNE DO ATUM.....                                                                                  | 162        |
| 4.7      | MODELOS PARA A CLASSIFICAÇÃO DO FRESCOR DA CARNE DO SALMÃO.....                                                                                | 169        |
| 4.8      | FRESHNESSSCOPE: UMA SOLUÇÃO AUTOMATIZADA PARA CLASSIFICAR O FRESCOR DA CARNE DE PEIXES COM BASE EM VISÃO COMPUTACIONAL E MACHINE LEARNING..... | 177        |
| 4.9      | FRESHNESSSCOPE E OS TRABALHOS RELACIONADOS.....                                                                                                | 180        |
| 4.10     | SÍNTESE DO CAPÍTULO.....                                                                                                                       | 183        |
| <b>5</b> | <b>CONSIDERAÇÕES FINAIS.....</b>                                                                                                               | <b>184</b> |
| 5.1      | RESOLUÇÃO DOS OBJETIVOS PROPOSTOS.....                                                                                                         | 184        |
| 5.2      | DIFICULDADES E LIMITAÇÕES DA PESQUISA.....                                                                                                     | 189        |
| 5.3      | SUGESTÕES DE TRABALHOS FUTUROS.....                                                                                                            | 191        |
|          | <b>REFERÊNCIAS.....</b>                                                                                                                        | <b>193</b> |
|          | <b>APÊNDICE A - CRITÉRIOS DE INCLUSÃO E EXCLUSÃO PARA REALIZAÇÃO DO MAPEAMENTO SISTEMÁTICO DA LITERATURA...</b>                                | <b>216</b> |
|          | <b>APÊNDICE B - ANÁLISE DOS MELHORES MODELOS PARA A CLASSIFICAÇÃO DE AMOSTRAS DE ATUM.....</b>                                                 | <b>218</b> |
|          | <b>APÊNDICE C - ANÁLISE DOS MELHORES MODELOS PARA A CLASSIFICAÇÃO DE AMOSTRAS DE SALMÃO.....</b>                                               | <b>253</b> |

## 1 INTRODUÇÃO

Produtos cárneos são amplamente distribuídos em todo o mundo e têm sido uma fonte de nutrição humana desde os primórdios da civilização humana. Carnes bovinas, de frango, de porco ou de peixe aparecem como produtos básicos na dieta humana (WEBB; CASEY; SIMELA, 2005). Segundo Bernardo *et al.* (BERNARDO *et al.*, 2020), a carne é uma matriz de alto valor nutricional cuja produção e consumo têm aumentado nos últimos anos. Avanços na avaliação eficiente de frescor são essenciais para aumentar a qualidade dos produtos, para garantir segurança ao consumidor, bem como para reduzir as perdas de matéria-prima. Tan (TAN, J., 2004) afirma que os métodos existentes de classificação da qualidade de produtos cárneos dependem fortemente da avaliação sensorial feita por especialistas e que o treinamento de destes é caro, dificultando a adoção do método em escala.

Especificamente sobre a carne de peixe, escopo dessa pesquisa, além de notável valor econômico, este tipo de alimento apresenta benefícios à saúde e tem aumentado significativamente na dieta humana, quando comparado ao consumo de outras carnes, apesar da existência de algumas barreiras para sua maior popularização (WU, L.; PU; SUN, 2019). Carroll (CARROLL, 2009) justifica o aumento no consumo de peixes ao redor do mundo, pela popularização da culinária japonesa.

O consumo de peixe apresenta vários benefícios positivos para a saúde, como, redução da incidência de doenças como câncer de mama (ZHENG *et al.*, 2013), doenças mentais, como depressão (SUPARTINI; OISHI; YAGI, 2017), bem como doenças neurológicas (RAJI *et al.*, 2014). Pesquisas também enfatizam o papel dos ácidos graxos ômega-3, abundante nos peixes, na redução das doenças cardiovasculares (MOZAFFARIAN *et al.*, 2005). Dados da Organização das Nações Unidas para Alimentação e Agricultura (*Food and Agriculture Organization of the United Nations* - FAO<sup>1</sup>) estimam que o consumo per capita de pescado na América Latina aumentará em 18% e que a pesca aumentará em até 24,2% em 2030. Carlucci *et al.* (CARLUCCI *et al.*, 2015) identificaram que as principais barreiras do consumo de pescado estão associadas à falta de confiança do consumidor acerca do frescor dos produtos na hora de adquiri-los.

A indústria de pescados vem exigindo inspeção da qualidade dos peixes há muito tempo, uma vez que a deterioração dos produtos pesqueiros ocorre muito

---

<sup>1</sup> <http://www.fao.org/home/en/>

rapidamente, por meio de processos bioquímicos e mecanismos de degradação microbiana (WEBB; CASEY; SIMELA, 2005). Sob condições inadequadas de manuseio, transporte e armazenamento, os peixes estão propensos a alterações nas propriedades físico-químicas e deterioração resultante de microrganismos, causando degradação de sua qualidade. O frescor é a principal característica na classificação da qualidade do peixe, portanto, mantê-lo fresco e monitorar o frescor, em tempo real, são desafios para indústrias (WU, L.; PU; SUN, 2019).

Características sensoriais como cor, textura, elasticidade e odor da carne mudam de acordo com a deterioração do peixe, sendo estas amplamente usadas por especialistas para medir níveis de frescor (OLAFSDOTTIR *et al.*, 1997). Tais características sensoriais também são amplamente usadas para avaliar o frescor de produtos cárneos em geral, como carnes de boi, de porco e de frango. Mudanças nestas características indicam degradação da qualidade do pescado, podendo tornar o consumo desses alimentos perigoso para o corpo humano (OLAFSDOTTIR *et al.*, 1997). A avaliação da qualidade do pescado, através de características sensoriais, inclui a inspeção de rugas ou ferimentos na pele, da cor e da textura da carne, das características dos olhos, da presença de sangue vivo nas guelras, da firmeza e da elasticidade da carne e, finalmente, do odor da carne (GOON *et al.*, 2014).

Segundo Bremner e Sakaguchi (BREMNER; SAKAGUCHI, 2000), o frescor da carne peixe é um conceito que resume muitos fatores. Os autores afirmam que a maior parte deles estão relacionadas a impressões sensoriais e a projeção, ou compreensão, se um determinado peixe ainda possuirá seu conjunto de características desde o momento da captura (início da cadeia pesqueira), passando pelo recebimento na indústria de pescados para processamento, até o momento do recebimento em restaurantes ou varejo (final da cadeia pesqueira). Uma descrição de “frescor” pode ser feita como o binômio tempo-temperatura integrado desde a captura, sendo esta uma suposição tácita, sendo o “nível de frescor” um parâmetro indicador de “frescor”. Esta descrição foi adotada nesta tese, acrescentando que quanto mais fresco é o pescado, mais qualidade ele possui.

A análise sensorial tem sido um dos métodos mais importantes de julgamento da qualidade alimentar. Como tal, é uma ferramenta de avaliação envolvendo sujeitos humanos com habilidades particulares para conduzir testes específicos de cada contexto alimentar (DJEKIC *et al.*, 2021).

A formação de especialistas em análise sensorial depende de treinamentos específicos ou de observação do trabalho de outros especialistas. Muitas vezes, para que o sujeito humano se familiarize com método de análise sensorial de um alimento específico e com o vocabulário usado, e por conseguinte obtenha alta capacidade de discriminação da qualidade dos alimentos observados sensorialmente, ele deve ser submetido a muitas horas de treinamento ou de observação do trabalho de outros especialistas. Problemas com olfato, visão ou paladar podem trazer dificuldades a sujeitos humanos em se especializar em análise sensorial de alimentos (LABBE; RYTZ; HUGI, 2004).

Murray, Delahunty e Baxter (MURRAY; DELAHUNTY; BAXTER, 2001) descrevem um painel formado por sujeitos humanos para análise sensorial, afirmando ser de extrema importância para o sucesso geral do projeto, o compromisso e a motivação dos participantes. Painel é um grupo de pessoas escolhidas para participar de uma análise sensorial de um alimento específico. Os autores ressaltam a importância de se aplicar questionários de frequência alimentar, que possam revelar a relutância de um participante em analisar produtos alimentares não familiares e salientam que a organização do painel deve considerar o estado de saúde dos participantes, incluindo potenciais alergias a diferentes tipos de alimentos, hábitos alimentares, bem como a acuidade sensorial. Os autores elencam desvantagens da análise sensorial manual, sendo elas: alta dependência do especialista, alto custo para treinar um novo especialista e o tempo elevado para que especialistas recém treinados adquiram maturidade no processo de análise sensorial.

Tais desvantagens limitam a aplicação de análise sensorial manual em larga escala. Com vistas a automatizar a análise sensorial, mitigando as desvantagens, diversos estudos, apresentados no Capítulo 3, propuseram soluções, robustas, não invasivas ou não destrutivas, para classificação do frescor de produtos cárneos, incluindo carnes de boi, de frango, de porco e de peixe. Muitos estudos apresentam soluções para a classificação de produtos cárneos, utilizando técnicas de visão computacional (VC) (LUGATIMAN *et al.*, 2019), de espectroscopia de refletância de infravermelho próximo (*near infrared* - NIR) (CUI; CUI, 2021), de imagens espectrais (KARTAKOULLIS *et al.*, 2018), de espectroscopia Raman (ZHANG, W.; MA; SUN, 2021), de imagens ultrassônicas (JANG *et al.*, 2015), e por fim, de nariz (*electronic nose* - *e-Nose*) e língua eletrônicos (*electronic tongue* - *e-Tongue*) (TAN, J.; XU, 2020).

Tendo tais estudos como norteadores, foi levantado o estado da arte, e com base nas lacunas percebidas, foi criada uma solução, chamada FreshnessScope, para classificação do frescor da carne de peixes através de parâmetros colorimétricos de sua carne, usando VC e aprendizagem de máquina (AM) (ALPAYDIN, 2020). A solução foi desenvolvida usando amostras da carne de atum e de salmão.

O presente capítulo está dividido em cinco seções. Além desta Introdução, a primeira seção apresenta a motivação e justificativa do trabalho. Na segunda seção, o problema de pesquisa será abordado. Na terceira seção o objetivo geral e os objetivos específicos serão explanados. E, por fim, a organização do trabalho será apresentada.

## 1.1 MOTIVAÇÃO E JUSTIFICATIVA

Diante do aumento no consumo de peixes na dieta humana, seja pela percepção do consumidor acerca do valor nutricional do pescado (BERNARDO *et al.*, 2020) ou pela popularização da culinária japonesa ao redor do mundo (CARROLL, 2009), se torna crescente o desafio das indústrias de pescados, dos distribuidores de pescados ou dos restaurantes em monitorar e assegurar o frescor da carne dos peixes fornecidos (WU, L.; PU; SUN, 2019). O aumento no consumo de peixes fez crescer a demanda na área de segurança alimentar, sendo esta a maior motivação desta pesquisa.

O frescor da carne do pescado é um indicador importante da qualidade e segurança de produtos alimentícios, que atrai intensa atenção dos produtores, vendedores e consumidores de carne (QIAO; TANG; DONG, 2017). Os métodos tradicionais usados para determinar o frescor da carne dos peixes incluem métodos instrumentais e análises químicas, além de análises sensoriais, métodos estes também usados em produtos cárneos em geral (CHEN, Q. *et al.*, 2014).

Análises químicas apresentam alto custo, e juntamente com os métodos instrumentais não são adequadas para o controle de qualidade em tempo real (KIANI; MINAEI; GHASEMI-VARNAMKHAHI, 2016). Os métodos químicos são objetivos e precisos; entretanto, eles são normalmente usados em laboratórios, sendo destrutivos e de difícil instrumentalização (SALLAM; SAMEJIMA, 2004).

A análise sensorial é uma especialidade científica usada para avaliar, estudar e explicar as particularidades dos alimentos, que são observadas e interpretadas de forma quantitativa por especialistas treinados, usando seus sentidos de visão, olfato,

paladar, tato e audição (STONE; BLEIBAUM; THOMAS, 2020). A análise sensorial, empregada como método para controle de qualidade de produtos alimentícios é altamente dependente de especialistas humanos, cuja formação depende de treinamentos, por vezes não disponíveis comercialmente ou de ensinamentos advindos de outros especialistas (LABBE; RYTZ; HUGI, 2004).

Análises sensoriais são geralmente realizadas apenas em grandes empresas, capazes de gerenciar o difícil desenvolvimento de um painel específico ou manter especialistas, por vezes escassos no contexto alimentício considerado, em seus quadros de funcionários. Para economizar tempo e dinheiro, pequenas empresas acabam por usar prestadores de serviços ou, muitas vezes, dispensam totalmente a análise sensorial, apesar da necessidade (HÖHL; BUSCH-STOCKFISCH, 2015).

A qualidade e a velocidade das análises sensoriais manuais podem ser influenciadas por fatores humanos, como fadiga física, fadiga sensorial, humor, estresse, entre outros (NJOMAN *et al.*, 2017). Em geral, os dados coletados, advindos da percepção humana mostram grande variabilidade entre diferentes especialistas devido a diferenças culturais, educacionais e predileções que estes possam apresentar (AMERINE; PANGBORN; ROESSLER, 2013). Civile e Carr (CIVILLE; CARR, 2015) acrescentam que a variabilidade de interpretação entre diferentes especialistas também se dá por diferenças no ambiente e pela falta de padronização no processo de coleta de dados. Balaban *et al.* (BALABAN *et al.*, 2008) corroboram, afirmando que tradicionalmente o controle de qualidade de produtos alimentícios feito por especialistas treinados constitui-se em método trabalhoso, demorado e difícil de quantificar.

As desvantagens da análise sensorial manual relativas ao custo e tempo de formação de especialistas, associadas a variação de velocidade de análise de especialistas quando sujeitos a diferentes condições físicas e ambientais, bem como a variabilidade de interpretação da qualidade dos alimentos analisados entre diferentes especialistas justificam a necessidade de estudar novos métodos para testes de frescor de produtos cárneos que automatizem a análise sensorial, de forma a garantir a qualidade destes, assegurando o seu consumo, sendo esta a motivação desta pesquisa.

Tal automatização constitui-se oportunidade de contribuir com a área de AM, através da construção de protocolo de preparação de amostras de carnes de peixes para captura de imagens digitais, de *hardware* e protocolo para a construção de

conjuntos de dados de amostras de carne de peixes inéditas e da proposição e extração de características de cores das amostras a serem usadas como recursos em modelos de AM de alto desempenho.

Segundo Nimbkar *et al.* (NIMBKAR *et al.*, 2021), técnicas de VC e e-Nose são mais fáceis de serem instrumentalizadas que as demais, recaindo a maior parte do custo da solução sobre a captura das amostras e conseqüentemente sobre construção dos conjuntos de dados de recursos extraídos destas.

## 1.2 PROBLEMA DE PESQUISA

Tendo a motivação supracitada, o desafio é criar *hardware* e protocolo para captura de imagens digitais de amostras de carne de peixes que permitam extrair informações de cores, de forma automática. Também se apresenta como desafio definir que informações de cores devem ser extraídas das imagens digitais das amostras, de modo que estas sirvam para classificar o frescor da carne de peixes.

A grande dificuldade é criar *hardware* e protocolo para captura de imagens digitais de amostras de carne de peixes e extrair informações de cores das imagens, de modo a compor um sistema de visão computacional (SVC) que seja adaptável a qualquer contexto de classificação de peixes, cuja análise de frescor da carne possa ser feita sensorialmente com base em padrões colorimétricos. Entende-se a relevância da automatização do processo de análise sensorial do frescor de amostras de carne de peixes, uma vez que tal automatização mitiga as desvantagens do processo manual no tocante ao custo e ao tempo de formação de especialistas e torna rápido o processo de análise, quando comparado à análise manual.

Esta tese pretende explorar os desafios supracitados como uma oportunidade para contribuir com a área de segurança alimentar, respondendo o questionamento:


***Que etapas para aquisição de imagens digitais de amostras de carne de peixes e extração de características de cores a partir das imagens devem ser adotadas para a compor uma solução que automatize a tarefa de classificação de frescor das amostras com base em AM?***

Para responder esse questionamento, foram concebidos os objetivos que norteiam essa pesquisa.

### 1.3 OBJETIVOS

O objetivo geral desta tese é criar através de VC e AM uma solução viável, de fácil e rápida instrumentalização das amostras e adaptável para classificação de níveis do frescor da carne de peixes.

Figura 1 - Passos abstratos para a construção de uma solução de classificação do frescor de carnes de peixe



FONTE: A Autora (2021)

O referido objetivo geral foi desdobrado nos seguintes objetivos específicos:

- Construir e disponibilizar conjuntos de dados de imagens digitais de amostras de carne de atum e salmão, classificadas em níveis de frescor, por especialistas;
- Construir um SVC composto de *hardware* e protocolo para a captura das imagens digitais das amostras de carne dos peixes;
- Automatizar a definição da região de interesse (RDI) das amostras;
- Criar e extrair automaticamente características de cores das amostras, a partir de suas imagens digitais;
- Usar as características de cores extraídas das imagens digitais, como recursos, em modelos de AM para a classificar as amostras em níveis de frescor;

- Apresentar solução FreshnessScope para classificar o frescor das amostras com base em padrões colorimétricos;
- Validar a adaptabilidade da solução criada;
- Publicar os resultados da pesquisa em conferência e (ou) periódicos.

A Figura 1 mostra de forma esquemática os passos que compõem uma solução para classificar o frescor da carne de peixes, composta por SVC, módulo de pré-processamento de imagens para definição da RDI, extração de características de cores da RDI de imagens das amostras e a entrega de tais características a modelos classificação baseados em AM.

#### 1.4 ORGANIZAÇÃO DO TRABALHO

Este trabalho, além desta Introdução contém mais 4 (quatro) capítulos. O Capítulo 2 traz a fundamentação teórica, passando pelo quesito de qualidade de alimentos, métodos manuais e automatizados de verificação de qualidade, uso de modelos inteligentes, e por fim, conceitos de AM. O Capítulo 3 aborda inicialmente o mapeamento sistemático da literatura (MSL), e em seguida a metodologia que foi utilizada para construção do SVC, e por fim, a metodologia usada para escolher os modelos ótimos para classificação do frescor da carne de atum e de salmão. O Capítulo 4 mostra as etapas para a construção da solução que automatiza a classificação do frescor da carne de peixes, usando imagens de amostras de atum e de salmão. Neste capítulo é apresentada a preparação das amostras, a construção do SVC, os passos do processamento das imagens digitais de amostras de atum e de salmão, e extração de características de cores. O Capítulo 4 ainda apresenta modelos de AM que utilizam as características de cores extraídas das imagens digitais das amostras e apresenta os resultados e análises de seus desempenhos no contexto de amostras de carne de atum e de salmão. Por fim, é apresentada a solução FreshnessScope. No Capítulo 5, as considerações finais são apresentadas, juntamente com as limitações deste trabalho e sugestões de trabalhos futuros. Este trabalho apresenta três apêndices. O Apêndice A contém os critérios de inclusão (CI) e os critérios de exclusão (CE) usados na condução do MSL, o Apêndice B contém os resultados dos melhores modelos para classificar o frescor de amostras de atum, enquanto o Apêndice C contém os resultados dos melhores modelos para classificar o frescor de amostras de salmão.

## 2 FUNDAMENTAÇÃO TEÓRICA

Produtos cárneos e seus derivados tornaram-se uma parte importante da dieta humana em todo o mundo. Segundo Tao e Peng (TAO; PENG, 2014), o consumo global de produtos cárneos quadruplicou, passando de 70 milhões de toneladas em 1961, para 283 milhões de toneladas em 2011. Com o crescente consumo de carnes e derivados, o consumidor tornou-se mais consciente dos atributos de qualidade da carne. A qualidade é, portanto, um dos fatores que contribuem para determinação dos preços da carne e para as decisões de compra de consumidores finais (PENG; DHAKAL, 2015). Teena *et al.* (TEENA *et al.*, 2013) corroboram afirmando que a aparência externa das carnes afeta seu valor financeiro no ponto de venda e o comportamento de compra do consumidor, impactando, sobretudo, aspectos de higiene e segurança alimentar.

A qualidade da carne inclui qualidades físicas, composição química, valor nutricional, organismos microbiológicos e atributos sensoriais. As qualidades físicas incluem fatores como marmoreio e capacidade de retenção de água. Composição química representa o valor nutricional da carne e consiste na presença de atributos como compostos orgânicos, proteína, gordura, cálcio e teor de umidade. Os organismos microbiológicos, como a contaminação bacteriana, representam um risco para o consumo humano e são responsáveis pela deterioração da carne. Atributos sensoriais são atributos perceptíveis pelos órgãos dos sentidos humanos, como cor, textura, odor e firmeza ou elasticidade da carne (PENG; DHAKAL, 2015).

A carne é produto alimentício altamente perecível, sendo sua qualidade influenciada por variáveis pré-abate (raça, sexo, idade, peso e ambiente) e fatores pós-morte (tempo de armazenamento, temperatura, estresse no abate) (ANDRÉS *et al.*, 2007). Isso significa que a carne apresenta alto risco de deterioração em toda a cadeia produtiva, desde a criação do animal até o consumo. A indústria alimentícia enfrenta o desafio de obter informações sobre a qualidade da carne, ao longo do processo de produção, para garantir a qualidade dos produtos cárneos fornecidos à consumidores (TAO; PENG, 2014).

Segundo Xiong, Z. *et al.* (XIONG *et al.*, 2014), a inspeção de atributos de qualidade tem sido feita por décadas, por métodos instrumentais e análises químicas, considerados métodos objetivos. Esses métodos e análises são eficazes e considerados confiáveis por seus resultados consistentes.

Como exemplos de métodos instrumentais, tem-se:

- Lâminas de cisalhamento padrão *Warner-Bratzler* usadas para avaliar a textura da carne (BELEW *et al.*, 2003);
- Medidores de pH inseridos em amostras de carne (KORKEALA *et al.*, 1986);
- Colorímetros usados para avaliar a coloração de amostras de carne (OLIVEIRA *et al.*, 2019);

Como exemplos de análises químicas, tem-se:

- Método *Kjeldahl* usado para análise de proteínas de amostras de carne (MIHALJEV *et al.*, 2015);
- Métodos de solvente usados para medir o teor de gordura de amostras de carne (SØRLAND *et al.*, 2004);
- Método de contagem em placas de petri usado para a detecção de microrganismos em amostras de carne (OTO *et al.*, 2013);

Embora as análises químicas tenham se mostrado consistentes e confiáveis em comparação com a inspeção manual, eles exigem longos tempos de processamento, preparação complexa de amostras e treinamento técnicos, o que os tornam caros, além de serem destrutivos. Métodos instrumentais e análises químicas não conseguem atender a indústria alimentícia no contexto em que análises de alto volume de amostras e em tempo real sejam necessárias (PENG; DHAKAL, 2015).

Nos últimos anos, assistiu-se a avanços rápidos no desenvolvimento de soluções para determinação da qualidade de produtos cárneos (NIMBKAR *et al.*, 2021). Vários métodos que apresentam soluções com capacidade de detecção rápida, não destrutivas, em tempo real e precisas, foram relatados na literatura para detecção dos atributos de qualidade de carne e de produtos à base de carne (TAHERI-GARAVAND *et al.*, 2019a).

Métodos de imagem para avaliação de atributos sensoriais foram recentemente utilizados para avaliar a qualidade de alimentos à base de carnes na linha de processamento com base na cor e na textura da superfície. Atributos sensoriais, como cor, textura, odor e firmeza são influenciados pelo processo de deterioração e impactam diretamente decisões de compra dos consumidores, pois fornecem a primeira impressão da qualidade da carne (SHI *et al.*, 2021).

Segundo Teena *et al.* (TEENA *et al.*, 2013), sistemas que automatizem a inspeção de qualidade de atributos sensoriais e a consequente classificação de

frescor de produtos cárneos, principalmente na indústria, são críticos e determinantes na área de segurança alimentar, uma vez que tradicionalmente tal tarefa é realizada de forma manual por especialistas treinados.

A inspeção do frescor de alimentos, quando feita por especialistas, consiste em tarefa repetitiva, cara, e facilmente influenciada pelo ambiente circundante sendo considerada desafiadora e de difícil adoção em larga escala (SUN, D.-W., 2016).

Em ciência de alimentos, a inteligência artificial (IA) (JACKSON, 2019) que combina sensores, processadores e outros componentes tem permitido a avaliação não destrutiva de produtos, o que resulta na forma, estado e natureza originais da amostra sendo mantidos (WANG, W. X. *et al.*, 2017). Esta tecnologia usa a mecânica, óptica, acústica, eletricidade e outras informações pertinentes do objeto medido para avaliar as características físicas, composição química, características estruturais e outros dados, de forma a obter uma avaliação não destrutiva e rápida da qualidade dos alimentos (SU; HE; SUN, 2017).

Na próxima seção será feita uma explanação de métodos automatizados não destrutivos de avaliação dos atributos de qualidade da carne, e em seguida, como escopo desta tese está na análise do frescor da carne de peixe com base em parâmetros colorimétricos, será feita explanação acerca dos espaços de cores utilizados para criar características colorimétricas a partir de imagens digitais das amostras de peixe. Por fim, será feita explanação das bases conceituais de AM utilizadas para criar os modelos automatizados de classificação.

## 2.1 MÉTODOS NÃO DESTRUTIVOS DE INSPEÇÃO DE PRODUTOS CÁRNEOS


Com a crescente preocupação e atenção dos consumidores, empresas e departamentos governamentais, qualidade e segurança alimentar têm sido alvo de pesquisa e desenvolvimento de soluções de métodos não destrutivos para a inspeção da qualidade de produtos cárneos e vem ganhando notoriedade (SHI *et al.*, 2021). Como foi dito no Capítulo 1, entre os principais métodos, detalhados a seguir, destacam-se SVC, NIR, técnicas de imagens espectrais, técnicas de espectroscopia Raman, imagens ultrassônicas, e por fim, *e-Nose* e *e-Tongue*.

### 2.1.1. Sistemas de Visão Computacional

SVCs fornecem um meio para obtenção de imagens digitais de amostras de objetos, além de tecnologias para processar informações das imagens digitais capturadas (O'BRIEN; UMA, 2021). SVC também é reconhecido como o sistema integrado de dispositivos para detecção óptica sem contato e processos de computação para receber e interpretar uma imagem de uma cena real. A tecnologia visa substituir a visão humana percebendo e compreendendo eletronicamente uma imagem (BROSNAN; SUN, 2004).

Segundo Neto *et al.* (NETO *et al.*, 2015), um SVC típico possui 6 (seis) etapas. A etapa de aquisição de imagens, que consiste no processo de captura da imagem, enquanto a etapa de pré-processamento consiste em retirar falhas e imperfeições da mesma. A segmentação é a etapa responsável por dividir a imagem em RDI. Posteriormente, a região segmentada é utilizada para extrair atributos, utilizados para identificar padrões previamente estabelecidos. Nesta tese, sem perda de entendimento, chamou-se as etapas de pré-processamento e segmentação, apenas de etapa de pré-processamento. As etapas estão ilustradas na Figura 2.

Figura 2 - Etapas de um sistema de visão computacional típico



FONTE: (NETO *et al.*, 2015)

Processamento de imagens digitais (etapas de pré-processamento e segmentação) e suas análises consistem no núcleo do SVC com numerosos algoritmos e métodos capazes de medir e avaliar a aparência de amostras capturadas através de imagens digitais (GONZALEZ; WOODS; EDDINS, 2020).

A tarefa de processamento de imagens digitais, segundo Gonzalez, Woods e Eddins (GONZALEZ; WOODS; EDDINS, 2020), inclui:

- Aquisição da imagem: consiste em adquirir uma imagem digital de uma amostra através de câmera digital, de vídeo ou de scanner;
- Pré-processamento: nesta etapa são realizadas tarefas para tornar a imagem capturada mais adequada para o trabalho de análise, podendo envolver, por exemplo, o aumento do contraste da imagem ou remoção de ruídos;
- Segmentação: consiste na etapa de identificação da RDI da imagem. Apenas a RDI das imagens será usada nas etapas a seguir;
- Representação e descrição: consiste na etapa de extração de características particulares das amostras que permite diferenciá-las entre si;
- Reconhecimento e interpretação: consiste na etapa em que rótulos que representam a classificação das amostras são associados, em função da análise das características extraídas na etapa anterior.

Segundo Mcandrew (MCANDREW, 2004), uma imagem digital pode ser definida como um conjunto de pontos, chamados de *pixels*. Em imagens preto e branco (P/B), cada *pixel* assume apenas dois valores de um bit, 0 (preto) e 1 (branco). Em imagens em escalas de cinza, cada pixel pode assumir 256 valores (8 bits), variando de 0 (preto) a 255 (branco), passando por vários tons de cinza. Em imagens coloridas do tipo *red*, *green* e *blue* (RGB) (TYAGI, 2018) cada pixel tem uma cor particular, que pode ser descrita pelos componentes vermelho (*red*), verde (*green*) e azul (*blue*). Cada componente varia de 0 a 255, o que dá um total de  $255 \times 255 \times 255 = 16.581.375$  possíveis cores distintas. Como cada cor requer 24 bits, sendo este tipo de imagem também é chamada de imagens 24-bits.

Exemplos de estudos de análise da qualidade de alimentos usando SVC são apresentados no Capítulo 3.

### **2.1.2. Espectroscopia de Refletância de Infravermelho Próximo**

NIR é uma técnica analítica que usa uma fonte de luz produtora de comprimento de onda conhecido (normalmente 900–2500 nm), o que permite a obtenção de um quadro completo da composição orgânica de uma substância ou material analisado. A técnica baseia-se no princípio de que diferentes ligações químicas na matéria orgânica absorvem ou emitem luz de comprimentos de onda diferentes quando a amostra é irradiada (PRIETO *et al.*, 2017).

A técnica NIR explora o fato de muitos produtos naturais absorverem radiação próxima ao infravermelho, numa região específica ou comprimento de onda específico, especialmente as ligações N-H, O-H e C-H. Assim, amostras com elevados níveis de proteínas (muitas ligações N-H) absorvem mais radiação em regiões de ligação amino do que amostras com baixo nível de proteína. Por outro lado, amostras com elevados níveis de umidade ou açúcar, terão absorção de radiação mais elevada na região associada com hidroxilas (O-H) (YAKUBU *et al.*, 2020).

NIR uma técnica de controle de qualidade, comum na indústria de alimentos, tipicamente usada para predizer o conteúdo de proteína bruta de amostras de alimentos, bem como para predizer aminoácidos totais e digestíveis.

Exemplos de estudos de análise da qualidade de alimentos usando NIR são apresentados no Capítulo 3.


### **2.1.3. Imagens Espectrais**

A imagem hiperespectral é adquirida ao longo dos comprimentos de onda na região do infravermelho próximo para especificar o espectro completo de comprimento de onda de cada *pixel* do plano de imagem. A banda hiperespectral cobre todas as bandas contínuas em ultravioleta, visível, infravermelho próximo, infravermelho médio, infravermelho distante e térmico. A grande vantagem da imagem hiperespectral é a capacidade de caracterizar as propriedades químicas inerentes de uma amostra observando sua distribuição no espaço. As capturas de imagens hiperespectrais e NIR geram um grande conjunto de dados em uma superfície de amostra, conhecida como hipercubo. Esta estrutura pode ser compreendida como duas dimensões espaciais e uma dimensão espectral, contendo informações químicas e físicas da matriz (MALDONADO; RODRIGUEZ-FUENTES; CONTRERAS, 2018).

Comparado ao NIR isoladamente, técnicas hiperespectrais integram espectroscopia de infravermelho próximo e tecnologia de imagem de alta resolução. O princípio técnico da imagem hiperespectral é usar a plataforma tradicional de *hardware* e *software* de imagem bidimensional e espectroscopia para obter informações espaciais e espectrais de cada *pixel* da amostra (LIU, H. *et al.*, 2018). Experimentos que se utilizam de imagens hiperespectrais e NIR, no geral, tem alto custo computacional. Abordagem computacional quimiométrica para redução da dimensionalidade dos dados precisa ser considerada para viabilizar os experimentos (ZHU *et al.*, 2017).

As diferenças entre uma imagem multiespectral e uma imagem hiperespectral são várias, mas a principal é o número de bandas espectrais. Pode-se dizer que as imagens multiespectrais são formadas relativamente por poucas bandas (normalmente entre 3 e 20) e não são necessariamente bandas contíguas umas às outras, enquanto que as imagens hiperespectrais normalmente são formadas por um maior número de bandas e estas são sempre contíguas (SETIYOKO; DHARMA; HARYANTO, 2017), como mostra a Figura 3.

Figura 3 - Diferença de imagens (a) multiespectrais e (b) hiperespectrais



Fonte: (RODRÍGUEZ VILLAMIZAR, 2015)

Exemplos de estudos de análise da qualidade de alimentos usando imagens espectrais são apresentados no Capítulo 3.

#### 2.1.4. Espectroscopia Raman

A espectroscopia Raman é uma técnica de análise espectral desenvolvida com base no efeito de espalhamento Raman (LANGER *et al.*, 2019). Sua análise se baseia em iluminação monocromática e de determinada frequência, espalhada ao incidir sobre a amostra a ser examinada, cuja maior parte da luz espalhada apresenta a mesma frequência da luz incidente. Pequena porção da luz é espalhada inelasticamente frente às rápidas mudanças de frequência, devido à interação da luz com a matéria. A luz, que manteve a mesma frequência da luz incidente, não revela qualquer informação sobre a amostra e é chamada de espalhamento *Rayleigh*, mas aquela que mudou revela a composição molecular da amostra e é conhecido como espalhamento Raman (ZHANG, W.; MA; SUN, 2021).

Esta técnica é aplicada diretamente sobre a amostra em questão, não sendo necessário fazer uma preparação especial no material. Além do mais, não há alteração na superfície que se faz a análise (PILOT *et al.*, 2019).

Nos últimos anos, a espectroscopia Raman tem sido cada vez mais aplicada na qualidade da carne. Informações representativas no espectro Raman da carne podem ser extraídas com o método de quimiometria, e a relação entre a estrutura molecular e vários grupos de radicais na carne pode ser qualitativamente analisados e, em seguida, a qualidade da carne pode ser detectada e avaliada (HERRERO, 2008).

Fowler *et al.* (FOWLER *et al.*, 2018) utilizaram a técnica de espectroscopia Raman para avaliar a qualidade de lombos bovinos e, em recente estudo, Wubshe *et al.* (WUBSHET *et al.*, 2019) fizeram uso da técnica para investigar carnes de frango.

#### **2.1.5. Imagens Ultrassônicas**

Métodos ultrassônicos de baixa intensidade tem sido usados na indústria de alimentos para a avaliação rápida e não destrutiva da qualidade de muitos alimentos através da determinação de suas propriedades acústicas (BOWLER; BAKALIS; WATSON, 2020). Os níveis de potência usados são baixos o suficiente (menos de 1 w/cm<sup>2</sup>) para evitar qualquer alteração nas propriedades físico-químicas do alimento analisado (MOHAMMADI; GHASEMI-VARNAMKHAHI; GONZÁLEZ, 2017).

Segundo González-Mohino *et al.* (GONZÁLEZ-MOHINO *et al.*, 2019), entre os parâmetros acústicos capturados (por exemplo, velocidade, atenuação e espectro de frequência), a velocidade é a mais amplamente utilizada, provavelmente porque é a medição mais simples e confiável. Os materiais apresentam valores de velocidade de ultrassom constantes sob determinadas condições operacionais, sendo estes valores dependentes apenas das respectivas propriedades físico-químicas.

As técnicas de imagens ultrassônicas para detectar a qualidade da carne são baseadas na análise de mudanças nos parâmetros acústicos para previsão da composição da carne, espessura do músculo, espessura da gordura, etc. Detecção rápida e não destrutiva e avaliação de classificação para a qualidade da carne são alcançados sem alterar as suas características internas (WIEJA *et al.*, 2021). Gordura, umidade, e proteína podem ser determinadas medindo a velocidade ultrassônica nas misturas usando uma equação semi-empírica (ARVANITOYANNIS; KOTSANOPOULOS; SAVVA, 2017).

Exemplos de estudos de análise da qualidade de alimentos usando imagens ultrassônicas são apresentados no Capítulo 3.

#### **2.1.6. Nariz e Língua Eletrônicos**

O odor sempre foi um parâmetro sensorial importante para julgar a qualidade de alimentos por consumidores. Durante o armazenamento da carne, com a diminuição do frescor, proteínas, gorduras e carboidratos são decompostos sucessivamente sob a ação de enzimas e bactérias, e assim, o odor de carne se torna forte, caracterizando estado de putrefação (JIA *et al.*, 2018).

Embora o nariz humano possa avaliar um cheiro, os julgamentos dos indivíduos podem ser tendenciosos, e o nariz humano não pode ser usado para detectar gases tóxicos. Além disso, o nariz humano tem limites de detecção para diferença de gases. Percebe-se, portanto, que o nariz humano é limitado como ferramenta universal para aspectos mais gerais relacionados a discriminação do cheiro e a classificação de amostras de alimentos (TAN; XU, 2020).

Um nariz eletrônico (*e-Nose*) é uma matriz de sensores de gás que fornece a impressão digital de gases voláteis específicos, que então pode ser usada por algoritmos para realizar discriminação e classificação. O processo de discriminação de *e-Nose* é uma imitação do olfato humano (TAN; XU, 2020).

O paladar humano consegue perceber cinco sabores básicos, incluindo doçura, acidez, amargura, salinidade e umami. Segundo Jiang *et al.* (JIANG, H. *et al.*, 2018), treinar humanos para sentir sabores é caro e demorado, e o uso de especialistas em sabores pode introduzir vieses na classificação, sugerindo o uso de línguas eletrônicas (*e-Tongue*).

Os sensores comumente empregados para uma *e-Tongue* incluem sensores eletroquímicos, biossensores e sensores óticos e de massa. Semelhante aos sensores de gás do *e-Nose*, os sensores químicos empregado pela *e-Tongue* reagem com analitos, criando mudanças reversíveis de propriedades elétricas. Sinais elétricos mensuráveis são capturados e usados para fazer reconhecimento e classificação de padrões (JIANG, H. *et al.*, 2018).

Exemplos de estudos de análise da qualidade de alimentos usando *e-Nose* e *e-Tongue* são apresentados no Capítulo 3.

## 2.2 ESPAÇOS DE CORES

Nesta seção serão explanadas as bases conceituais dos quatro espaços de cores utilizados para construção de tais características: RGB, *Hue*, *Saturation* e *Value* (HSV) (BURGER; BURGE, 2016), *Hue*, *Saturation*, e *Intensity* (HSI) (WELCH; MOORHEAD; OWENS, 1991) e CEILAB ( $L^*a^*b^*$ ) (WESTLAND; RIPAMONTI; CHEUNG, 2012).

Um espaço de cores é um modelo matemático usado para descrever cada cor a partir de fórmulas, sendo necessário perceber que o espaço é expressável apenas em termos de suas divisões, ou seja, em termos de etapas de diferença de cores (escala) que se somam para construí-lo (KUEHNI, 2001).

As bases conceituais destes espaços de cores são detalhadas a seguir.


### 2.2.1 Espaço de Cores RGB

O espaço de cores RGB regula as cores dos objetos que emitem luz sendo adequado para representação de imagens em telas de monitores e câmeras fotográficas (KUEHNI, 2001).

Para formar uma cor com RGB, três feixes de luz (um vermelho, um verde e um azul) devem ser sobrepostos, empregando o princípio da funcionalidade do olho humano (sensibilidade da retina a três tipos de espectros de luz específicos). Cada um dos feixes é chamado de componente de cor, tendo cada componente uma intensidade, variando de 0 a 255. O modelo de cores RGB é aditivo, no sentido de que os três feixes de luz são somados. Portanto, seus espectros de luz se somam para formar o espectro da cor final. As cores vermelho (componente *R*), verde (componente *G*) e azul (componente *B*) são cores primárias, uma vez que podem produzir cores secundárias a partir de suas combinações. A intensidade zero para cada componente fornece a cor mais escura (preto) e a intensidade total de cada componente fornece a cor mais clara (branco). Quando as intensidades para todos os componentes são iguais, o resultado é um tom de cinza, mais escuro ou mais claro dependendo da intensidade. Quando as intensidades são diferentes, o resultado é uma tonalidade colorida. As cores primárias foram padronizadas pela *Commission*

*Internationale de l'Éclairage*<sup>2</sup> (CIE) nos comprimentos de onda: azul (435,8 nm), verde (546,1 nm) e vermelho (700 nm) (TYAGI, 2018).

Figura 4 - Sistema de coordenadas tridimensional formado pelos componentes do espaço de cores RGB



Fonte: (CHERNOV; ALANDER; BOCHKO, 2015)

Quando um dos componentes tem a intensidade mais forte, a cor é um matiz próximo a essa cor primária (vermelho, verde ou azul), e quando dois componentes têm a mesma intensidade, sendo esta mais forte, a cor é um matiz de uma cor secundária (um tom de ciano, magenta ou amarelo). Uma cor secundária é formada pela soma de duas cores primárias de igual intensidade. Quando todas as cores primárias são misturadas em intensidades iguais, o resultado é o branco (CHANG, Y.-C.; REID, 1996).

Em resumo, deve-se entender uma imagem como uma matriz de *pixels* formada por três componentes, cujos valores variam de 0 a 255 e pode ser visualizada na forma de um cubo em sistema de coordenadas tridimensionais (CHERNOV; ALANDER; BOCHKO, 2015), como mostra a Figura 4.

### 2.2.2 Espaço de Cores HSV


O espaço de cores HSV foi criado por Alvy Ray Smith em 1978 (SMITH, 1978). Comumente utilizado em aplicação de VC, o espaço de cores HSV é formado pelos componentes *hue* (H), *saturation* (S) e *value* (V). O componente H pode ser entendido como a tonalidade da cor, mede o comprimento de onda dominante desta e pode ser interpretado como a distância para o vermelho. Seus valores variam em torno do eixo

<sup>2</sup> <https://cie.co.at/>

vertical do cone hexagonal, mostrado na Figura 5, medidos em graus, variam de 0 a 360.

O componente S pode ser entendido como a “pureza” da cor e tem valores entre 0 a 100%, e quanto menor esse valor, mais cinza a imagem será (menos pura), ao passo que quanto maior o valor, mais "pura" é a imagem. Por fim, o componente V é análogo o brilho/luz da cor, também variando entre 0 e 100% (BURGER; BURGE, 2016).

Figura 5 - Representação gráfica dos componentes do espaço de cores HSV



Fonte: (CHANG, J.-D. *et al.*, 2010)

O espaço de cores HSV é definido por uma transformação não-linear do sistema de cores RGB. As fórmulas de conversão do espaço de cores RGB para HSV são mostradas nas Equações 1, 2, 3, 4, 5, 6 e 7 (SARAVANAN; YAMUNA; NANDHINI, 2016).

Normalizando os valores de  $R$ ,  $G$  e  $B$  tem-se,  $R'$ ,  $G'$  e  $B'$  e seus valores máximos e mínimos, representados nas Equações 1, 2, 3 e 4:

$$R' = \frac{R}{255}; G' = \frac{G}{255}; B' = \frac{B}{255} \quad (\text{Eq. 1})$$

$$C_{max} = \text{MAX}(R', G', B') \quad (\text{Eq. 2})$$

$$C_{min} = \text{MIN}(R', G', B') \quad (\text{Eq. 3})$$

$$\Delta = C_{max} - C_{min} \quad (\text{Eq. 4})$$

Os valores dos componentes H, S e V são calculados pelas Equações 5, 6 e 7.

$$H = \begin{cases} 0^\circ & \Delta = 0 \\ 60^\circ \times \left( \frac{G' - B'}{\Delta} \bmod 6 \right), & C_{max} = R' \\ 60^\circ \times \left( \frac{B' - R'}{\Delta} + 2 \right), & C_{max} = G' \\ 60^\circ \times \left( \frac{R' - G'}{\Delta} + 4 \right), & C_{max} = B' \end{cases} \quad (\text{Eq. 5})$$


$$S = \begin{cases} 0, & C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & C_{max} \neq 0 \end{cases} \quad (\text{Eq. 6})$$

$$V = C_{max} \quad (\text{Eq. 7})$$

### 2.2.3 Espaço de Cores HSI

O espaço de cores HSI, criado para permitir outra forma de processamento de imagens, separa o componente *intensity* (I) dos componentes relacionados *hue* (H) e *saturation* (S). Os componentes H e S do espaço de cores HSI, representam conceitos semelhantes aos componentes H e S do espaço de cores HSV, enquanto o componente I do espaço de cores HSI incorpora a noção acromática de intensidade, sendo semelhante ao componente V do HSV (WELCH; MOORHEAD; OWENS, 1991). Porém as equações que convertem os componentes RGB em HSV, diferem das que convertem RGB em HSI. A representação gráfica do HSI é um bicone (dois cones) unidos pela base, como mostra a Figura 6. Percebe-se o componente I variando de preto a branco.

Figura 6 - Representação gráfica dos componentes do espaço de cores HSI



Fonte: (BLOTTA *et al.*, 2011)

As relações de transformações do modelo RGB para o HSI são dadas pela Equações 8, 9 e 10.

$$H = \begin{cases} \theta & \text{if } B \leq G \\ 2\pi - \theta & \text{if } B > G \end{cases} \quad (\text{Eq. 8})$$

onde,

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}} \right\}$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (\text{Eq. 9})$$

$$I = \frac{1}{3}(R + G + B) \quad (\text{Eq. 10})$$

#### 2.2.4 Espaço de Cores L\*a\*b\*

Em geral, as cores diferem em cromaticidade e luminância. Os parâmetros do espaço de cores L\*a\*b\*, criado pela CIE, correlacionam os valores das cores com a percepção visual. Este espaço de cores foi criado com base na “Teoria da Cor Oposta” (JAMESON; HURVICH, 1955), em que duas cores não podem ser verde e vermelho ao mesmo tempo, ou amarelo e azul ao mesmo tempo. O parâmetro L\* indica luminosidade e os parâmetros a\* e b\* representam as coordenadas cromáticas, sendo a\* a coordenada vermelho/verde (+a indica vermelho e -a indica verde) e b\* a coordenada amarelo/azul (+b indica amarelo e -b indica azul) (WESTLAND; RIPAMONTI; CHEUNG, 2012).

Seguindo orientações do CIE, sendo o L\*a\*b\* um dos espaços destinados a comparação de cores distintas, as indústrias como as de plástico, de tintas, de impressão, de alimentos e têxtil usam este espaço para identificar atributos de cor de produtos e desvios de uma cor padrão. Pequenas diferenças podem ser encontradas comparando os componente L\*a\*b\* capturados em imagens digitais e os respectivos valores capturados a partir da própria amostra, por um instrumento de medição de cor, como um colorímetro, mesmo quando duas cores parecem iguais para uma pessoa (GOÑI; SALVADORI, 2017).

Para converter valores RGB em L\*a\*b\*, os componentes RGB devem ser linearizados em relação à luz (CONNOLLY; FLEISS, 1997). Para tal, converte-se os componentes do espaço de cores RGB nos componentes X, Y e Z do espaço de cores CEI XYZ (KERR, 2010), através da Equação 11:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4124564 & 0.3575761 & 0.1804375 \\ 0.2126729 & 0.7151522 & 0.0721750 \\ 0.0193339 & 0.1191920 & 0.9503041 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (\text{Eq. 11})$$

A conversão do espaço de cores CEI XYZ para o L\*a\*b\* é feita, através das Equações 12, 13 e 14 (CONNOLLY; FLEISS, 1997):

$$L^* = 116 f\left(\frac{Y}{Y_n}\right) - 16 \quad (\text{Eq. 12})$$

$$a^* = 500 \left( f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad (\text{Eq. 13})$$

$$b^* = 200 \left( f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right) \quad (\text{Eq. 14})$$

sendo,

$$t = \frac{X}{X_n}, \frac{Y}{Y_n}, \text{ ou } \frac{Z}{Z_n}$$

$X, Y, Z$  descrevem o estímulo de cor considerado e  $X_n, Y_n, Z_n$  descrevem um iluminante de referência acromático branco especificado. Para o iluminante padrão D65, que considera luz do dia média (incluindo a região de comprimento de onda ultravioleta) com uma temperatura de cor correlacionada de 6500K, tem-se  $f(t)$  dada pela Equação 15.

$$f(t) = \begin{cases} \sqrt[3]{t} & \text{se } t > 0,008856 \\ 7,787t + \frac{16}{116} & \text{caso contrário} \end{cases} \quad (\text{Eq. 15})$$

## 2.3 APRENDIZAGEM DE MÁQUINA

Nesta seção serão explanadas as bases conceituas de AM necessárias para o entendimento dos experimentos usados para a concepção dos modelos para a classificação do frescor da carne de peixes com base nos padrões de cores. É feito o uso de primitivas de pré-processamento para dimensionar os dados, primitivas de pré-processamento de características, primitivas de balanceamento de classes e classificadores.


Os classificadores se basearam em aprendizagem supervisionada (ALPAYDIN, 2020), uma vez que as amostras utilizadas foram classificadas com rótulos relativos a seu respectivo nível de frescor, por especialistas. Como relata Alpaydin (ALPAYDIN, 2020), diferentemente da aprendizagem supervisionada, na aprendizagem não supervisionada, os dados são submetidos a algoritmos sem que se tenha, antecipadamente, os rótulos ou classes que eles representam. Os classificadores tentam fazer agrupamentos com base em relações entre as características.

Formalmente descreve-se AM supervisionada, como: dada a entrada para um conjunto de características  $X$  existem rótulos pré-definidos com os valores  $y$  de uma função  $f$  desconhecida,  $y = f(x)$ , onde os valores de  $x$ , são vetores da forma  $(x_{i1}, x_{i2}, \dots, x_{iM})$  cujos componentes são valores discretos ou contínuos relacionados ao conjunto de características  $X = \{X_1, X_2, \dots, X_M\}$ . Ou seja,  $x_{il}$  denota o valor do

atributo  $X_i$  do exemplo  $i$ . Dados esse conjunto de características, o algoritmo induz uma hipótese  $h$  que deve aproximar a verdadeira função  $f$ , tal que dado um novo exemplo  $x$ ,  $h(x)$  prediz o valor  $y$  correspondente (METZ, 2006).

Problemas de aprendizagem supervisionados são classificados em problemas de “regressão” e “classificação”. Em problemas de regressão, os algoritmos de AM tentam prever os resultados em uma saída contínua, o que significa a tentativa de mapear variáveis de entrada em uma função contínua. Em problemas de classificação, os algoritmos de AM tentam prever os resultados em uma saída discreta, o que significa mapear variáveis de entrada em categorias distintas (RASCHKA; MIRJALILI, 2017).

Figura 7 - Processo de Classificação



FONTE: (MONARD; BARANAUSKAS, 2003)

O processo de classificação, ilustrado na Figura 7, consiste em selecionar e pré-processar alguns exemplos, ou ainda fornecer algumas informações adicionais ao classificador, para treinamento. Após o treinamento do classificador, avalia-se a inferência, e se necessário, o processo é repetido para melhorar os resultados (MONARD; BARANAUSKAS, 2003). O pré-processamento dos dados é discutido nas seções a seguir.

### 2.3.1 Primitivas de Pré-Processamento de Dimensionamento dos Dados

Em AM, a escala e distribuição dos dados do domínio que está sendo modelado podem ser diferentes para cada característica. Os dados de entrada podem ter unidades diferentes, por vezes resultando em escalas diferentes. Diferentes escalas

nos dados de entrada podem resultar em dificuldade no treinamento ou aprendizagem de um modelo. Muitos algoritmos de AM têm melhor desempenho quando os dados de entrada numéricos são dimensionados para um intervalo padrão (BOEHMKE; GREENWELL, 2019).

Há técnicas populares para dimensionar dados numéricos, antes de submetê-los ao treinamento para criação de modelos, como normalização *min\_max*, normalização *max\_absolute*, padronização e escala de *log*.

A normalização *min\_max* dimensiona cada recurso de entrada de forma separada para um valor entre 0 e 1 (intervalo de ponto flutuante) e é calculada através da Equação 16 (BROWNLEE, 2020g):

$$x' = (x - \min(x)) / (\max(x) - \min(x)) \quad (\text{Eq. 16})$$

onde, *min* é o valor mínimo do intervalo de normalização definido e *max* é o valor máximo do intervalo de normalização definido.

A normalização *max\_absolute* redimensiona cada recurso individualmente para o intervalo [-1, 1], dividindo pelo valor absoluto máximo em cada recurso, como mostra a Equação 17 (SINGH, P., 2019).

$$x' = \frac{x}{\text{abs max}(x)} \quad (\text{Eq. 17})$$

A padronização dimensiona cada recurso de entrada separadamente subtraindo a média (chamada de centralização) e dividindo pelo desvio padrão para deslocar a distribuição, afim de ter uma média de 0 e desvio padrão de 1. A padronização dos dados é realizada através da Equação 18 (BROWNLEE, 2020g):

$$x' = (x - \text{média}) / \text{desvio\_padrão} \quad (\text{Eq. 18})$$

onde *média* é calculada através da Equação 19:

$$\text{média} = \text{soma}(x) / \text{contagem}(x) \quad (\text{Eq. 19})$$

e o *desvio\\_padrão* é calculado através da Equação 20.

$$\text{desvio\_padrão} = \sqrt{\frac{\text{soma}(x - \text{média})^2}{\text{contagem}(x)}} \quad (\text{Eq. 20})$$

A escala de *log* calcula o logaritmo de pontos a serem redimensionados para comprimir uma faixa ampla de valores em uma faixa estreita de valores e é calculada pela Equação 21 (KAPPAL, 2019):

$$x' = \log(x) \quad (\text{Eq. 21})$$

### 2.3.2 Primitivas de Pré-Processamento de Características

Primitivas de pré-processamento de características incluem técnicas de seleção e extração de características. O objetivo de selecionar ou extrair características de um conjunto de dados é reduzir o número de variáveis de entrada ou gerar novas variáveis para treinar um modelo preditivo com o objetivo de melhorar o desempenho (ALPAYDIN, 2020).

Os métodos de seleção de características têm como objetivo reduzir o número de características de entrada para aquelas que se acredita serem mais úteis para um modelo, uma vez que o desempenho se degrada ao se incluir características sem relevância para a variável de destino (KUMAR; MINZ, 2014).

Já as técnicas de extração de características visam criar conjuntos de dados com novos recursos, a partir de recursos existentes, descartando estes últimos. Esse novo conjunto de dados de recursos, deve ser capaz de resumir (ou ampliar) a maioria das informações contidas no conjunto original. Novas variáveis de entrada podem resultar em modelos preditivos com melhor desempenho (KHALID; KHALIL; NASREEN, 2014).

Entre as técnicas para a seleção de características, destaca-se a *Variance Thresholding* (*VarianceThreshold*) (ALBON, 2018) e entre as técnicas de extração de características destacam-se as técnicas: *Principal Component Analysis* (PCA) (BRO; SMILDE, 2014), *Linear Discriminant Analysis* (LDA) (XANTHOPOULOS; PARDALOS; TRAFALIS, 2013), *Locally Linear Embedding* (LLE) (BURGES, 2010) e *Autoencoder* (WANG, W. et al., 2014).

### 2.3.3 Primitivas de Balanceamento de Classes

A modelagem preditiva de classificação envolve a previsão de um rótulo de classe para uma determinada observação. Uma classificação em dados com classes desbalanceadas pode ser tendenciosa ou distorcida. A distribuição pode variar de um leve viés a um grave desbalanceamento, onde há um exemplo na classe minoritária para vários exemplos na classe ou classes majoritárias (ABD ELRAHMAN; ABRAHAM, 2013).

As classificações desbalanceadas representam um desafio para a modelagem preditiva, pois a maioria dos algoritmos de aprendizado de máquina usados para classificação foi projetada em torno da suposição de um número igual de exemplos

para cada classe. Isso resulta em modelos com baixo desempenho preditivo, especificamente para a classe minoritária (ABD ELRAHMAN; ABRAHAM, 2013).

Como técnica de sobreamostragem destaca-se a técnica *Synthetic Minority Oversampling* (SMOTE), que envolve a duplicação de exemplos na classe minoritária, embora esses exemplos não adicionem nenhuma informação nova ao modelo. Em vez disso, os exemplos recentes são sintetizados a partir das amostras existentes. A técnica SMOTE funciona selecionando exemplos que estão próximos no espaço do recurso, desenhando uma linha entre os exemplos no espaço do recurso e desenhando uma nova amostra em um ponto ao longo dessa linha (CHAWLA *et al.*, 2002).

#### 2.3.4 Otimização de Hiper Parâmetros

No treinamento de um classificador de AM, os hiper parâmetros são variáveis que, de alguma forma, governam o espaço do modelo ou o procedimento de ajuste do mesmo, visando assim a redução do seu erro de generalização. A otimização hiper paramétrica possui desafios que estão ligados ao tipo de classificador de AM utilizado, à função de custo empregada, aos conjuntos de dados de treinamento e teste, dentre outros (CLAESEN; DE MOOR, 2015).

A estratégia da otimização em grade é um método tradicionalmente utilizado na otimização hiper paramétrica de modelos com um número reduzido de hiper parâmetros. Esta técnica apresenta uma forma de resolução simples e direta, possuindo como característica: fácil implementação e paralelização (ALIBRAHIM; LUDWIG, 2021).

No método de otimização em grade, cada hiper parâmetro é testado em um intervalo de busca, no qual acredita-se que seja um potencial local para a varredura. A execução deste procedimento gera no espaço hiper paramétrico, uma estrutura em grade, formada pelo conjunto de  $T$  vetores que compõem todos os arranjos candidatos,  $\lambda_{1:T}$ , sendo estes avaliados nos treinamentos do modelo, por meio uma função de perda ( $\mathcal{E}$ ), resultando na avaliação  $f$ . A finalidade é encontrar o melhor ponto de configuração ( $\lambda^*$ ), entre todas as configurações ( $\lambda_{1:T}$ ) experimentadas, tendo alto custo computacional em caso de muitos hiper parâmetros (DE ALVARENGA JÚNIOR, 2018).

Os otimizadores de busca aleatória podem ser utilizados na resolução de problemas em que a diferenciabilidade da função não é assumida, sendo particularmente competitivos para casos em que: a função objetivo é custosa de se avaliar, a quantidade de memória computacional disponível é limitada, a função a ser minimizada possui múltiplos pontos de mínimo local e para situações em que a função possua superfície irregular (BERGSTRA; BENGIO, 2012).

Nenhum desses métodos usa resultados de treinamento anterior para melhorar os resultados no próximo ensaio, diferente da otimização *Bayesiana* que permite a determinação de probabilidades a priori, que resulta de aprendizados passados, e probabilidades a posteriori, que é a probabilidade condicionada a algum outro evento sabido (WU, J. et al., 2019).

A otimização *Bayesiana* armazena hiper parâmetros pesquisados anteriormente e resultados de uma função objetivo predefinida (por exemplo, perda de entropia cruzada binária) e os usa para criar um modelo substituto. O objetivo de um modelo substituto é estimar rapidamente o desempenho do modelo real, dado um determinado conjunto de hiper parâmetros candidatos. Isso permite decidir se deve-se usar o conjunto de hiper parâmetros candidatos para treinar o modelo real. Conforme o número de testes aumenta, o modelo substituto, atualizado com resultados de testes adicionais, melhora e começa a recomendar melhores hiper parâmetros candidatos (TAN, E., 2021).

Uma regra importante neste contexto é o teorema de Bayes, dado pela Equação 22 (THEODORIDIS, 2015).

$$p(A|B) = \frac{p(B|A)}{p(B)} p(A) \quad (\text{Eq. 22})$$

A regra de Bayes descreve uma distribuição a posteriori  $p(A|B)$ , que é a probabilidade condicional de se observar o evento  $A$  dado que  $B$  seja verdadeiro, a partir do conhecimento da evidência  $p(B)$ , da probabilidade a priori  $p(A)$  e do modelo de verossimilhança  $p(B|A)$ .

Na resolução do problema de otimização hiper paramétrica pelo método *Bayesiano*, o par  $(\lambda, f(x))$  é representado como  $(x, f(x))$ . Assim, a função de probabilidade a posteriori, que busca aproximar a função desconhecida  $f: \lambda \mapsto f$ , é expressa como mostra a Equação 23 (WU, J. et al., 2019).

$$p(f|D) \propto p(D|f)p(f) \quad (\text{Eq. 23})$$

onde  $D = (\lambda, f)$ ,  $p(f)$  representa a crença sobre o espaço de possibilidades para a função desconhecida,  $p(D|f)$  é a função de verossimilhança e  $p(f|D)$  é a distribuição a posteriori.

### 2.3.5 Classificadores

Nesta seção serão detalhados os algoritmos ou classificadores de aprendizagem supervisionada utilizados nos experimentos para a definição do modelo de classificação do frescor da carne de peixes.

#### 2.3.5.1 Aprendizagem de Máquina Automatizada

AM automatizada se refere a técnicas para descobrir automaticamente modelos com bom desempenho para tarefas de modelagem preditiva, com muito pouco envolvimento do usuário. O AM automatizado usa primitivas que permitem melhorar a eficiência de modelos de classificação e acelera a pesquisa, além de permitir automatizar a combinação das primitivas de pré-processamento de dimensionamento de dados, pré-processamento de características, balanceamento de classes e classificadores de AM, além de otimizar hiper parâmetros dos classificadores (BROWNLEE, 2020c).


Segundo Feurer *et al.* (FEURER *et al.*, 2015), a função do AM automatizada é: para  $i = 1, \dots, n + m$ , tem-se  $x_i \in R^d$ , como recursos, e  $y_i \in Y$ , como sendo suas classificações correspondentes. Dado um conjunto de dados de treinamento  $X_{train} = \{(x_1, y_1), \dots, (x_n, y_n)\}$  e um conjunto de dados de teste  $X_{test} = \{(x_{n+1}, y_{n+1}), \dots, (x_{n+m}, y_{n+m})\}$  extraídos do mesmo conjunto de dados original,  $b$  parâmetros para realização da otimização (como, por exemplo, tempo máximo para realização da otimização em cada modelo, número de modelos máximo no ensemble, entre outros) e a função de perda  $\mathcal{E}(\cdot, \cdot)$ , a função do AM automatizada é produzir uma previsão  $Y_{test} = \{(\hat{y}_{n+1}), \dots, (\hat{y}_{n+m})\}$ , sendo a perda dada por  $\frac{1}{m} \sum_{j=1}^m \mathcal{E}(\hat{y}_{n+1}, \hat{y}_{n+m})$ .

O *framework Auto-Sklearn*, uma biblioteca de código aberto escrita em *Python*, automatiza o processo de AM, através de meta-aprendizado, otimização *Bayesiana* e construção de ensemble e faz uso da biblioteca *scikit-learn*<sup>3</sup> para transformações de dados e classificadores de AM para descobrir o modelo de alto desempenho para um determinado conjunto de dados (FEURER *et al.*, 2015).

<sup>3</sup> <https://scikit-learn.org/stable/index.html>

A otimização *Bayesiana* sofre de problemas para escolha dos hiper parâmetros iniciais, uma vez que não há ensaios históricos para o modelo substituto aprender no início, sendo, portanto, os hiper parâmetros candidatos selecionados de forma aleatória, o que acarreta lentidão no processo de otimização. Para superar o problema de escolha de hiper parâmetros iniciais, o *Auto-Sklearn* usa a otimização *Bayesiana* precedida de um módulo de meta-aprendizado, como mostra a Figura 8 (FEURER et al., 2015).

Figura 8 - *Framework Auto-Sklearn* para realização de aprendizagem de máquina automatizada



Fonte: (FEURER et al., 2015)

O objetivo do meta-aprendizado é encontrar uma boa instanciação de hiper parâmetros para otimização *Bayesiana*, de modo que se tenha um desempenho melhor do que a escolha aleatória no início. Durante o treinamento *offline*, um total de 38 (trinta e oito) meta-recursos, como assimetria, curtose, número de recursos, número de classes, etc., foram tabulados para 140 (cento e quarenta) conjuntos de dados de referência do OpenML<sup>4</sup> (repositório público de conjuntos de dados). Cada conjunto de dados de referência foi treinado usando o processo de otimização *Bayesiana* e os resultados foram avaliados. Os hiper parâmetros que forneceram os melhores resultados para cada conjunto de dados de referência foram armazenados e esses hiper parâmetros servem como instanciação para o otimizador *Bayesiano* para novos conjuntos de dados com meta-recursos semelhantes. Conjuntos de dados com meta-recursos semelhantes têm desempenho semelhante no mesmo conjunto de hiper parâmetros (TAN, E., 2021).

Durante o treinamento do modelo para o novo conjunto de dados, os meta-recursos para o novo conjunto de dados são tabulados e os conjuntos de dados de referência são usados de acordo com a distância *Manhattan* (MOHIBULLAH; HOSSAIN; HASAN, 2015), para o novo conjunto de dados no espaço do meta-recurso. Os hiper parâmetros armazenados dos 25 (vinte e cinco) principais conjuntos

<sup>4</sup> <https://www.openml.org/>

de dados de referência mais próximos são usados para instanciar o otimizador *Bayesiano* (TAN, E., 2021).

Entre os classificadores testados no *Auto-Sklearn* estão o *Adaptive Boosting* (AdaBoost) (BROWNLEE, 2020d), *Bernoulli Naive Bayes* (BNB) (SINGH, G. et al., 2019), *Decision Tree* (DT) (MYLES et al., 2004), *Extremely Randomized Trees* (ExtraTrees) (BHANDARI, N., 2018), *Gaussian Naive Bayes* (GNB) (ONTIVERO-ORTEGA et al., 2017), *Gradient Boosting* (GB) (NATEKIN; KNOLL, 2013), *K-Nearest Neighbors* (KNN) (KRAMER, 2013), *LDA*, *Support Vector Machine* (SVM) (STEINWART; CHRISTMANN, 2008), *Multilayer Perceptron* (MLP) (TAUD; MAS, 2018), *Multinomial Naive Bayes* (MNB) (KIBRIYA et al., 2004), *Passive Aggressive* (PA) (CRAMMER et al., 2006), *Quadratic Discriminant Analysis* (QDA) (THARWAT, 2016), *Random Forest* (RF) (BREIMAN, 2001) e *Stochastic Gradient Descent* (SGD) (KETKAR, 2017).

Para a construção do ensemble, o *Auto-Sklearn* usa o método apresentado em (CARUANA et al., 2004). Os hiper parâmetros mostrados no Quadro 1 controlam como o ensemble é construído.

Quadro 1 - Hiper parâmetros que controlam a construção do ensemble no *Auto-Sklearn*

| Hiper parâmetro    | Descrição                                                                                                                                                                                                                                                                                                                                                                                     |
|--------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ensemble_size      | Determina o tamanho máximo do ensemble. Se for definido como zero, nenhum ensemble será construído.                                                                                                                                                                                                                                                                                           |
| ensemble_nbest     | Permite ao usuário especificar o número de modelos considerados para o ensemble. Este hiper parâmetro pode ser um inteiro $n$ , de forma que apenas os melhores $n$ modelos são usados no conjunto final. Se um real entre 0,0 e 1,0 for fornecido, o hiper parâmetro é interpretado como uma fração sugerindo a porcentagem de modelos a serem usados no processo de construção do ensemble. |
| max_models_on_disc | Define o número máximo de modelos que são mantidos no disco, como um mecanismo para controlar a quantidade de espaço do disco consumido pelo <i>Auto-Sklearn</i> .                                                                                                                                                                                                                            |

Fonte: (CARUANA et al., 2004)

Para a exploração interativa dos modelos gerados pelo *Auto-Sklearn* usa-se o *PipelineProfiler* (ONO et al., 2020). Os componentes principais do *PipelineProfiler* são as contribuições das primitivas, a matriz de *pipelines* e a visualização de comparação de modelos. A matriz de *pipelines* mostra os modelos como um conjunto de primitivas

exibidos em uma matriz concisa e representa um resumo tabular de todos os modelos investigados. A área de comparação de *pipelines* consiste em um diagrama que vincula nós (representantes das técnicas escolhidas nas primitivas) que formam um *pipeline* individual e representa uma visão geral das diferenças dos diversos modelos selecionados na matriz. No diagrama cada nó é codificado com uma cor específica, que coincide com a cor do destaque na matriz de *pipelines*, identificando a que modelo o nó pertence. Se um nó estiver presente em mais de um modelo, todas as cores correspondentes serão exibidas. Se um nó aparecer em todos os modelos selecionados, nenhuma cor será exibida (ONO *et al.*, 2020).

### 2.3.5.2 Ridge Classifier

O *Ridge Classifier* (RC) usa o método *Ridge* para regressão, uma forma de regularização, através de penalidades (VOVK, 2013). O RC, com base no método de regressão *Ridge*, converte os dados das classes para um intervalo de -1 a 1 e resolve o problema de classificação com o método de regressão. O valor mais alto na previsão é aceito como uma classe de destino e, para classificação multiclasse (várias classes), os classificadores são treinados em uma abordagem de um contra todos (HASTIE, 2020).

### 2.3.5.3 K-Nearest Neighbors

O algoritmo KNN é um algoritmo de aprendizagem supervisionada que pode ser utilizado tanto para regressão como para classificação. Todo o conjunto de dados de treinamento é armazenado, sendo feita a previsão de um novo registro através da localização dos k-registros mais semelhantes no conjunto de treinamento. Os k-registros localizados são ditos vizinhos mais próximos e desta forma uma previsão resumida é feita (KRAMER, 2013).

A similaridade entre os registros vizinhos pode ser calculada através da distância Euclidiana, *Hamming*, *Manhattan*, *Minkowski* ou Ponderada, sendo a previsão a classe que mais apareceu dentre os dados que tiveram as menores distâncias (SHALEV-SHWARTZ; BEN-DAVID, 2014).

A Equação 24 mostra a fórmula da distância Euclidiana, que representa a distância mais curta entre os ponto  $(x_1, y_1)$  e  $(x_2, y_2)$ , e é a forma mais comum utilizada para cálculo de similaridade entre registros vizinho (VAZ, 2021).

$$\textbf{Distância Euclideana} = \sqrt{((x_1 - x_2)^2 + (y_1 - y_2)^2)} \quad (\text{Eq. 24})$$

#### 2.3.5.4 Linear e Quadratic Discriminant Analysis

*Discriminant Analysis* (DA) é um dos classificadores mais básicos e simples. Em classificadores DA, uma amostra é representada por um vetor ou um conjunto de  $m$  características, que representam um ponto no espaço  $m$ -dimensional que é chamado de espaço padrão. O objetivo do processo padrão de classificação é treinar um modelo usando os padrões rotulados para atribuir um rótulo de classe para um padrão desconhecido. Os rótulos de classe são usados para calcular as funções discriminantes para cada classe. As funções discriminantes são então usadas para determinar os limites para cada classe (HART; STORK; DUDA, 2000).

Segundo Yang, X. (YANG; X., 2020), considerando um problema de classificação genérico: uma variável aleatória  $x$  vem de uma das  $k$  classes, com algumas densidades de probabilidade específicas de classe  $f(x)$ . Uma regra discriminante é dividir o espaço de dados em  $k$  regiões disjuntas que representam todas as classes. Com essas regiões, a classificação por análise discriminante significa alocar  $x$  à classe  $j$  se  $x$  estiver na região  $j$ . Pode-se seguir duas regras de alocação:

- a) Regra de máxima verossimilhança, na qual assume-se que cada classe pode ocorrer com igual probabilidade, e  $x$  é alocado para a classe  $j$  se ocorrer o caso da Equação 25:

$$j = \arg \max_i f_i(x) \quad (\text{Eq. 25})$$

- b) Regra *Bayesiana*, na qual se conhece as probabilidades anteriores da classe  $\Pi$ , então se aloca  $x$  para a classe  $j$  se ocorrer o caso da Equação 26:

$$j = \arg \max_i \Pi_i f_i(x) \quad (\text{Eq. 26})$$

Existem dois tipos de classificador DA: LDA e QDA. No classificador LDA, a superfície de decisão é linear, enquanto o limite de decisão no QDA é não linear (THARWAT, 2016).

#### 2.3.5.5 Passive Aggressive

PA é um algoritmo de aprendizagem *online* no qual o treinamento do sistemas acontece de forma incremental, sendo alimentando com instâncias sequencialmente, individualmente ou em pequenos grupos chamados minilotes (CRAMMER *et al.*, 2006).

No aprendizado *online*, um modelo de AM é treinado e posto em produção de uma maneira que continua a aprender conforme chegam novos conjuntos de dados. Entende-se o PA como adequado para sistemas que recebem dados em um fluxo contínuo, permitindo que a solução seja constantemente refinada (SHALEV-SHWARTZ *et al.*, 2003).

O PA não requer taxa de aprendizado, no entanto, inclui um parâmetro de regularização, que denota a penalização que o modelo fará em uma previsão incorreta. O algoritmo se mantém passivo nas previsões acertadas, sem fazer qualquer mudança no modelo, mas adota um comportamento agressivo no caso de previsões incorretas, fazendo ajustes no modelo (SHALEV-SHWARTZ *et al.*, 2003).

Para entender o PA segue-se os passos definidos em (BONACCORSO, 2017) e Equações 27, 28, 29 e 30.

Supõe-se um conjunto de dados, definido pela Equação 27.

$$\begin{cases} \mathbf{X} = \{\bar{\mathbf{x}}_0, \bar{\mathbf{x}}_1, \dots, \bar{\mathbf{x}}_t, \dots\} \text{ onde } \bar{\mathbf{x}}_i \in \mathbf{R}^n \\ \mathbf{Y} = \{\mathbf{y}_0, \mathbf{y}_1, \dots, \mathbf{y}_t, \dots\} \text{ onde } \mathbf{y}_t \in \{-1, +1\} \end{cases} \quad (\text{Eq. 27})$$

O índice  $t$  representa a dimensão temporal. Para simplificar a explicação, assume-se que o problema é de classificação binária baseada em rótulos bipolares.

Dado um vetor de peso  $w$ , a previsão é obtida como mostra a Equação 28.

$$\tilde{y}_t = \text{sign}(\bar{\mathbf{w}}^T \cdot \bar{\mathbf{x}}_t) \quad (\text{Eq. 28})$$

O algoritmo é baseado na função de perda  $L$  (função *Hinge*), mostrada na Equação 29.

$$L(\bar{\boldsymbol{\theta}}) = \max(0, 1 - \mathbf{y} \cdot \mathbf{f}(\bar{\mathbf{x}}_t; \bar{\boldsymbol{\theta}})) \quad (\text{Eq. 29})$$

O valor de  $L$  é limitado entre 0 (significando combinação perfeita) e  $K$  dependendo de  $f(x_t, \theta)$  com  $K > 0$  (previsão completamente errada). O algoritmo PA funciona genericamente com a regra de atualização, mostrada na Equação 30.

$$\begin{cases} \bar{\mathbf{w}}_{t+1} = \arg \min_{\bar{\mathbf{w}}} \frac{1}{2} \|\bar{\mathbf{w}} - \bar{\mathbf{w}}_t\|^2 + C\xi^2 \\ L(\bar{\mathbf{w}}; \bar{\mathbf{x}}_t, \mathbf{y}_t) < \xi \end{cases} \quad (\text{Eq. 30})$$

onde  $\xi$  é a variável de folga, e  $C$  é o grau de tolerância que controla a agressividade do algoritmo. Valores maiores de  $C$  geram maior agressividade (com consequente maior risco de desestabilização na presença de ruído), enquanto valores menores permitem uma melhor adaptação.

### 2.3.5.6 Decision Tree, Random Forest e Extremely Randomized Trees

DT ou árvores de decisão é um algoritmo que usa um modelo semelhante a uma árvores exibindo instruções que contém apenas controle condicional, iniciando com o nó raiz, que se expande em outros ramos. Se enquadra em aprendizagem supervisionada, sendo usada tanto em problemas de classificação, quanto em regressão. Entende-se uma DT como uma representação gráfica para obter todas as soluções possíveis para um problema/decisão com base em determinadas condições (MYLES *et al.*, 2004).

A DT é um classificador estruturado em árvore, onde os nós internos representam os recursos de um conjunto de dados, os ramos representam as regras de decisão e cada nó folha representa o resultado. Em uma DT, há dois nós, que são o nó de decisão e o nó folha. Os nós de decisão são usados para tomar qualquer decisão e têm vários ramos, enquanto os nós folha representam as saídas dessas decisões e não contêm nenhum outro ramo. As decisões ou o teste são executados com base nas características do conjunto de dados fornecido. Em uma árvore de decisão, para prever a classe de um determinado conjunto de dados, o algoritmo começa a partir do nó raiz da árvore. Este algoritmo compara os valores do atributo raiz com o atributo registro (conjunto de dados real) e, com base na comparação, segue a ramificação e pula para o próximo nó. Para o próximo nó, o algoritmo compara novamente o valor do atributo com os outros sub-nós e segue adiante. Ele continua o processo até atingir o nó folha da árvore (BRIJAIN *et al.*, 2014).

A função de perda compara a distribuição de classes antes e depois da divisão e pode ser dada por algoritmos de Impureza Gini e Entropia. O cálculo da Impureza Gini é dado pela Equação 31 e da Entropia pela Equação 32 (AYYADEVARA, 2018).

$$Gini(nó) = \sum_{k=1}^c p_k (1 - p_k) \quad (\text{Eq. 31})$$

$$Entropia(nó) = - \sum_{i=1}^c p_k \log(p_k) \quad (\text{Eq. 32})$$

onde  $p_k$  a probabilidade de se escolher um ponto de dados de uma classe  $k$ .

Usando a Entropia como função de perda, uma divisão só é realizada se a Entropia de cada um dos nós resultantes for menor do que a Entropia do nó pai. Caso contrário, a divisão não é *localmente ideal* (AYYADEVARA, 2018).

O algoritmo RF é um conjunto de classificadores DT, sendo, portanto, um algoritmo composto por um comitê de outros classificadores ou ensemble (POLIKAR,

2012) e pode ser usado para problemas de classificação e regressão (BREIMAN, 2001).

O RF é uma extensão da ideia de agregação de *bootstrap (bagging)* de árvores de decisão. *Bagging* é um método de conjunto que consiste em duas etapas principais. Primeiro, as amostras são inicializadas a partir dos dados de treinamento e usadas para calibrar um conjunto de classificadores, onde cada classificador é calibrado para uma amostra diferente, gerando vários modelos. Depois, o conjunto de modelos é aplicado a dados de teste e a previsão é calculada em todas as árvores de decisão, sendo a previsão mais votada, o resultado do *bagging* (BREIMAN, 2001). A previsão por *bootstrap* baseia-se na reamostragem de um conjunto de exemplos, sendo indicada para situações em que este conjunto é limitado. A partir de um conjunto de tamanho  $n$ , é formado um novo conjunto de treinamento com a retirada aleatória de elementos do conjunto de exemplos original. Os exemplos omitidos são utilizados na constituição do conjunto de teste (GARCIA, 2003).

O RF estabelece o resultado com base nas previsões das árvores de decisão. As previsões são feitas através da média das previsões de várias árvores. Aumentar o número de árvores aumenta a precisão do resultado. O RF erradica as limitações de um algoritmo DT, reduz o sobreajuste de conjuntos de dados e aumenta a precisão (BREIMAN, 2001).

Embora o RF seja uma coleção de DT, existem algumas diferenças, segundo Donges (DONGES, 2021a):

- Ao se inserir um conjunto de dados de treinamento com recursos e rótulos em uma DT, o algoritmo formulará um conjunto de regras, que será usado para fazer as previsões;
- Com a mesma inserção do conjunto de dados de treinamento com recursos e rótulos, o algoritmo RF seleciona observações e recursos aleatoriamente para construir várias árvores de decisão e, em seguida, calcula a média dos resultados.

ExtraTrees é um algoritmo de aprendizado de máquina de conjunto ou ensemble. Especificamente, é um conjunto de classificadores DT e está relacionado a outros algoritmos de árvores de decisão, como RF. O algoritmo ExtraTrees funciona criando um grande número de árvores de decisão não ajustadas a partir do conjunto de dados de treinamento. As previsões são feitas calculando a média da previsão das árvores de decisão no caso de regressão ou usando a votação por maioria no caso de classificação (GEURTS; ERNST; WEHENKEL, 2006).

Quadro 2 - Diferenças entre os classificadores DT, RF e ExtraTrees

|                                                 | DT                | RF                                | ExtraTrees                        |
|-------------------------------------------------|-------------------|-----------------------------------|-----------------------------------|
| Número de árvores                               | 1                 | Várias                            | Várias                            |
| Número de recursos usados na divisão de cada nó | Todos os recursos | Subconjunto randômico de recursos | Subconjunto randômico de recursos |
| <i>Bootstrapping</i>                            | Não aplicado      | Aplicado                          | Aplicado                          |
| Como a divisão do nó é feita?                   | Melhor divisão    | Melhor divisão                    | Divisão aleatória                 |

Fonte: (BHANDARI, N., 2018)

Ao contrário do RF que desenvolve cada árvore de decisão a partir de uma amostra de *bootstrap* do conjunto de dados de treinamento, o algoritmo ExtraTrees ajusta cada árvore de decisão em todo o conjunto de dados de treinamento. Como o RF, o algoritmo ExtraTrees irá amostrar aleatoriamente os recursos em cada ponto de divisão de uma árvore de decisão, porém diferentemente do RF, que usa um algoritmo ganancioso para selecionar um ponto de divisão ideal, este seleciona um ponto de divisão aleatoriamente. A seleção aleatória de pontos de divisão torna as árvores de decisão no conjunto menos correlacionadas, embora isso aumente a variância do algoritmo. Este aumento na variância pode ser neutralizado aumentando o número de árvores usadas no conjunto. (BROWNLEE, 2020e).

O Quadro 2 mostra um resumo das diferenças entre DT, RF e ExtraTrees.

### 2.3.5.7 Adaptive Boosting

*Boosting* é uma técnica de conjunto ou ensemble que tenta criar um classificador forte a partir de vários classificadores fracos. Isso é feito construindo um modelo a partir dos dados de treinamento e, em seguida, criando um segundo modelo que tenta corrigir os erros do primeiro modelo. Os modelos são adicionados até que o conjunto de treinamento seja previsto perfeitamente ou um número máximo de modelos seja adicionado (BROWNLEE, 2020d).

Entre os algoritmos de *boosting* destaca-se o algoritmo AdaBoost. O AdaBoost pode ser usado para impulsionar o desempenho de qualquer algoritmo de AM, tendo melhor desempenho em classificadores de aprendizagem fracos. O algoritmo mais adequado e, portanto, mais comum usado com AdaBoost são árvores de decisão com um nível, por serem muito curtas e terem apenas uma decisão para classificação (BROWNLEE, 2020d).

Segundo Brownlee (BROWNLEE, 2020d), cada instância no conjunto de dados de treinamento é ponderada. Um classificador fraco é preparado nos dados de

treinamento usando as amostras ponderadas. O peso inicial é definido na Equação 33:

$$\text{weight}(x_i) = 1/n \quad (\text{Eq. 33})$$

onde  $x_i$  é a  $i$ -ésima instância de treinamento e  $n$  é o número de instâncias de treinamento.

Um classificador fraco é preparado nos dados de treinamento usando as amostras ponderadas. Em problemas de classificação binários (duas classes) o classificador toma uma decisão em uma variável de entrada e produz um valor +1,0 ou -1,0 para o valor da primeira ou segunda classe.

A taxa de classificação incorreta (erro) é calculada para o modelo treinado segundo a Equação 34:

$$\text{error} = (\text{correct} - N)/N \quad (\text{Eq. 34})$$

onde  $\text{error}$  é a taxa de classificação incorreta,  $\text{correct}$  é o número de instâncias de treinamento previstas corretamente pelo modelo e  $N$  é o número total de instâncias de treinamento. Para usar a ponderação das instâncias de treinamento, a fim de saber a taxa de classificação incorreta, modificou-se o  $\text{error}$ , como mostrado na Equação 35:

$$\text{error} = \text{sum}(w(i) * \text{terror}(i))/\text{sum}(w) \quad (\text{Eq. 35})$$

onde  $w$  é o peso para a instância  $i$  de treinamento e  $\text{terror}$  é o erro de predição para a instância  $i$  de treinamento, que será 1 se classificado incorretamente e 0 se classificado corretamente.

Um valor de estágio é calculado para o modelo treinado que fornece uma ponderação para quaisquer previsões feitas pelo modelo. O valor do estágio ( $\text{stage}$ ) para um modelo treinado é calculado segundo Equação 36:

$$\text{stage} = \ln \left( \frac{1-\text{error}}{\text{error}} \right) \quad (\text{Eq. 36})$$

onde  $\text{stage}$  é o valor do estágio usado para ponderar as previsões do modelo,  $\ln ( )$  é o logaritmo natural e  $\text{error}$  é o erro de classificação incorreta do modelo. O efeito do peso do estágio é que modelos mais precisos têm mais peso ou contribuição para a previsão final. Os pesos de treinamento são atualizados dando mais peso às instâncias previstas incorretamente e menos peso às instâncias previstas corretamente. Este fato faz com que o peso não se altere, se a instância de treinamento foi classificada corretamente e torna o peso um pouco maior se o classificador fraco classificou incorretamente a instância.

Um segundo classificador é construído usando os novos pesos, que não são mais iguais. Novamente, dados de treinamento classificados incorretamente têm seus pesos aumentados e o procedimento é repetido. Normalmente, pode-se construir 500 ou 1000 classificadores dessa maneira. Uma pontuação é atribuída a cada classificador, e o classificador final é definido como a combinação linear dos classificadores de cada estágio (HASTIE *et al.*, 2009).

Quando aplicado a problemas de classificação de duas classes, o AdaBoost provou ser extremamente bem-sucedido na produção de classificadores precisos. No entanto, não é o caso para problemas de várias classes, embora o AdaBoost também tenha sido proposto para este fim (FREUND; SCHAPIRE, 1997). Observou-se que, para que os dados de treinamento classificados incorretamente sejam aumentados, é necessário que o erro de cada classificador fraco seja menor que  $1/2$  (com relação à distribuição na qual foi treinado). Para problemas de classificação de duas classes, esse requisito é quase o mesmo que adivinhação aleatória, mas quando a quantidade de classes ( $K$ ) é maior que 2, a precisão  $1/2$  pode ser muito mais difícil de alcançar do que a taxa de precisão de adivinhação aleatória  $1/K$ . Consequentemente, o AdaBoost pode falhar se o classificador fraco não for escolhido apropriadamente (HASTIE *et al.*, 2009).

#### 2.3.5.8 Gradient Boost

O algoritmo GB pode ser usado para regressão e classificação. O algoritmo produz um modelo de previsão na forma de um ensemble de modelos de previsão fracos (NATEKIN; KNOLL, 2013).

O GB envolve três elementos (BROWNLEE, 2020b):

- Uma função de perda a ser otimizada:
  - A função de perda depende do problema a ser resolvido, devendo ser uma função diferenciável.
- Um modelo fraco para fazer previsões:
  - As árvores de decisão são usadas como o modelo fraco no GB, sendo comum restringir a profundidade, nós, divisões dos nós ou nós folha. As árvores são construídas de forma gananciosa, escolhendo os melhores pontos de divisão com base em pontuações de pureza ou para minimizar a perda. Árvores maiores podem ser usadas geralmente variando a profundidade entre 4 a 8 níveis.

- Um modelo aditivo para adicionar modelos fracos com objetivo de otimizar a função de perda:
  - As árvores são adicionadas uma de cada vez e as árvores existentes no modelo não são alteradas. Um procedimento de descida do gradiente é usado para minimizar a perda ao adicionar árvores. Tradicionalmente, o gradiente descendente é usado para minimizar um conjunto de parâmetros, como os coeficientes em uma equação de regressão ou pesos em uma rede neural. Após calcular o erro ou perda, os pesos são atualizados para minimizar esse erro;
  - No GB, em vez de parâmetros, tem-se árvores de decisão. Depois de calcular a perda, para realizar o procedimento de descida do gradiente, deve-se adicionar uma árvore ao modelo que, através de sua parametrização, reduza a perda (ou seja, siga o gradiente).
  - Geralmente, essa abordagem é chamada de descida de gradiente funcional ou descida de gradiente com funções.


Descida do gradiente é uma técnica de otimização popular em AM e *DeepLearning* (DL) (GOODFELLOW; BENGIO; COURVILLE, 2016) e pode ser usada com a maioria, senão com todos, os algoritmos de aprendizagem. Um gradiente é a inclinação de uma função. Quanto maior o gradiente, mais acentuada será a inclinação e mais rápido um modelo pode aprender. Mas se a inclinação for zero, o modelo para de aprender. Ele mede o grau de mudança de uma variável em resposta às mudanças de outra variável. Matematicamente, a descida do gradiente é uma função convexa cuja saída é a derivada parcial de um conjunto de parâmetros de suas entradas. Quanto maior for o gradiente, mais íngreme será a inclinação (BISONG, 2019).

Começando com um valor inicial, a descida do gradiente é executada iterativamente para encontrar os valores ideais dos parâmetros dando passos do tamanho do conjunto de dados inteiro para caminhar em direção ao o valor mínimo possível da função de custo dada (BISONG, 2019).

Em um problema de AM se deseja treinar o algoritmo com gradiente descendente para minimizar a função de custo  $J(w, b)$  e atingir seu mínimo local ajustando seus parâmetros  $w$  e  $b$  (DONGES, 2021b).

A Figura 9 mostra que os eixos horizontais representam os parâmetros  $w$  e  $b$ , enquanto a função custo  $J(w, b)$  é representada no eixo vertical.

Figura 9 - Representação da descida do gradiente para minimização da função de custo  $J(w, b)$



Fonte: (DONGES, 2021b)

Para começar a encontrar os valores corretos, inicializa-se  $w$  e  $b$  com números aleatórios. A descida gradiente então começa nos pontos aleatórios inicializados e dá um passo após o outro na direção descendente mais íngreme até atingir o ponto onde o custo função é tão pequena quanto possível (indicado pela seta vermelha da Figura 9).

A Equação 37 descreve a descida gradiente de um ponto (DONGES, 2021b).

$$\mathbf{b} = \mathbf{a} - \gamma \nabla f(\mathbf{a}) \quad (\text{Eq. 37})$$

onde  $\mathbf{b}$  é a próxima posição do ponto, enquanto  $\mathbf{a}$  representa sua posição atual. O sinal de menos refere-se à parte de minimização da descida do gradiente.  $\gamma$  é um fator de espera e o termo gradiente  $\nabla f(\mathbf{a})$  é a direção da descida mais acentuada, ditando a próxima posição que em que o ponto precisa ir, que é a direção da descida mais íngreme.

#### 2.3.5.9 Stochastic Gradient Descent

SGD é um tipo de algoritmo com base na descida do gradiente, sendo uma abordagem simples, mas muito eficiente, para ajustar classificadores lineares e regressores sob funções de perda convexa. O gradiente descendente é usado para encontrar os valores de uma função (coeficientes) que minimizam uma função de custo, tanto quanto possível. A rigor, SGD é apenas uma técnica de otimização e não corresponde a uma família específica de modelos de AM. É apenas uma forma de treinar um modelo, implementando uma rotina de aprendizagem (KETKAR, 2017).

No SGD algumas amostras (lotes) são selecionadas aleatoriamente em vez de todo o conjunto de dados para cada iteração, de modo que é encontrado o gradiente da função de custo de um único lote a cada iteração ao invés da soma do gradiente da função de custo de todos os exemplos, como na descida do gradiente tradicional.

No SGD, como apenas uma amostra do conjunto de dados é escolhida aleatoriamente para cada iteração, o caminho percorrido pelo algoritmo costuma ser mais ruidoso e geralmente leva um número maior de repetições para atingir os mínimos, do que o algoritmos com base em descida do gradiente típico (BOTTOU, 2012).

#### 2.3.5.10 Support Vector Machine

SVM é um algoritmo de AM que pode ser usado para tarefas de regressão e classificação. O objetivo do algoritmo, em classificações, é encontrar um hiperplano em um espaço  $N$ -dimensional, onde  $N$  é o número de recursos, que classifica distintamente os pontos de dados. Para separar as duas classes de pontos de dados, existem muitos hiperplanos possíveis que podem ser escolhidos. O objetivo do algoritmo é encontrar um plano que tenha a margem máxima, ou seja, a distância máxima entre os pontos de dados de ambas as classes. Maximizar a distância da margem aumenta a confiança na classificação de pontos de dados futuros (STEINWART; CHRISTMANN, 2008).

Os hiperplanos são limites de decisão que ajudam a classificar os pontos de dados. Os pontos de dados que caem em lados distintos do hiperplano podem ser atribuídos a diferentes classes. A dimensão do hiperplano depende da quantidade de recursos, sendo uma reta quando existirem dois recursos, um plano bidimensional quando existirem três recursos, e assim sucessivamente (GUENTHER; SCHONLAU, 2016).

As Equações 38 a 43 formalizam como encontrar o hiperplano (BOSWELL, 2002).

Um hiperplano é representado formalmente pela Equação 38.

$$f(x) = \beta_0 + \beta^T x \quad (\text{Eq. 38})$$

onde  $\beta$  é um vetor de pesos e  $\beta_0$  é o viés.

O hiperplano ótimo pode ser representado em um número infinito de maneiras diferentes pela escala de  $\beta$  e  $\beta_0$ . Por uma questão de convenção, a representação do hiperplano será dada como mostra a Equação 39.

$$|\beta_0 + \beta^T x| = 1 \quad (\text{Eq. 39})$$

onde  $x$  simboliza os exemplos de treinamento mais próximos do hiperplano. Em geral, os exemplos de treinamento mais próximos do hiperplano são chamados de vetores de suporte. Essa representação é conhecida como hiperplano canônico. A Equação

40 mostra como se calcula geometricamente a distância entre um ponto  $x$  e um hiperplano  $(\beta, \beta_0)$ .

$$\text{distancia} = \frac{|\beta_0 + \beta^T x|}{\|\beta\|} \quad (\text{Eq. 40})$$

Em particular, para o hiperplano canônico, o numerador é igual a 1 e a distância para os vetores de suporte é dada pela Equação 41.

$$\text{distancia}_{\text{vetores suporte}} = \frac{1}{\|\beta\|} \quad (\text{Eq. 41})$$

A margem introduzida denotada por  $M$ , é duas vezes a distância para os exemplos mais próximos, como mostra a Equação 42.

$$M = \frac{2}{\|\beta\|} \quad (\text{Eq. 42})$$

Finalmente, o problema de maximização de  $M$  é equivalente ao problema de minimização de uma função  $L(\beta)$ , representada na Equação 43, sujeita a algumas restrições. As restrições modelam o requisito para o hiperplano classificar corretamente todos os exemplos de treinamento  $x_i$ .

$$\min_{\beta, \beta_0} L(\beta) = \frac{1}{2} \|\beta\|^2, \text{sujeito a } y_i(\beta^T x_i + \beta_0) \geq 1 \quad \forall_i \quad (\text{Eq. 43})$$

onde  $y_i$  representa cada um dos rótulos dos exemplos de treinamento.

Este é um problema de otimização Lagrangiana que pode ser resolvido usando multiplicadores de Lagrange para obter o vetor de peso  $\beta$  e o viés  $\beta_0$  do hiperplano ótimo.

#### 2.3.5.11 Logistic Regression

*Logistic Regression* (LR) é um algoritmo de AM utilizado para os problemas de classificação, que faz análise preditiva e é baseado no conceito de probabilidade. O LR é um método linear, mas as previsões são transformadas usando a função *sigmoid* (demonstrada na Equação 44), portanto diferentemente da regressão linear, a hipótese de regressão logística tende a limitar a função de custo entre 0 e 1. O LR modela a probabilidade da classe padrão (por exemplo, a primeira classe), ou a probabilidade de que uma entrada ( $X$ ) pertença à classe padrão ( $Y = 1$ ). A redução do valor da função de custo do LR é feita usando a descida do gradiente (KLEINBAUM *et al.*, 2002).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (\text{Eq. 44})$$

Segundo Molnar (MOLNAR, 2020), o passo da regressão linear para a regressão logística é bastante direto, como mostram as Equações 45 e 46. No modelo de regressão linear, modela-se a relação entre o resultado e as características com uma equação linear, como mostra a Equação 45.

$$\hat{y}^{(i)} = \beta_0 + \beta_1 x_1^{(i)} + \dots + \beta_p x_p^{(i)} \quad (\text{Eq. 45})$$

Para classificação, como as probabilidades estão entre 0 e 1, envolve-se apenas o lado direito da equação na função logística, forçando a saída a assumir apenas valores entre 0 e 1, como mostra a Equação 46.

$$f(y^{(i)} = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1^{(i)} + \dots + \beta_p x_p^{(i)})}} \quad (\text{Eq. 46})$$

#### 2.3.5.12 Naive Bayes

O algoritmo *Naive Bayes* (NB) é um classificador probabilístico simples baseado na aplicação do teorema de Bayes com suposições de independência fortes (ingênuas). Em termos simples, um classificador NB assume que a presença (ou ausência) de uma característica particular de uma classe, não está relacionada à presença (ou ausência) de qualquer outra característica (ZHANG, H., 2004).

O teorema de Bayes é dado pela Equação 47 (SWINBURNE, 2004):

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)} \quad (\text{Eq. 47})$$

onde,

$P(A|B)$  = Probabilidade de  $A$  dada que a evidência  $B$  já ocorreu;

$P(B|A)$  = Probabilidade de  $B$  dada que a evidência  $A$  já ocorreu;

$P(A)$  = Probabilidade de que  $A$  ocorrerá;

$P(B)$  = Probabilidade que  $B$  ocorrerá.

Variações do NB são os algoritmos BNB, projetado para recursos binários (SINGH, G. *et al.*, 2019) e GNB, que implementa o NB para classificação quando a probabilidade dos recursos é assumida como gaussiana (ONTIVERO-ORTEGA *et al.*, 2017).

#### 2.3.5.13 Nearest Centroid

O *Nearest Centroid* (NC) é um algoritmo de aprendizado de máquina de classificação, que usa o conjunto de dados de treinamento resumindo-o em um conjunto de centroides (centros), que representam o modelo. O modelo usa os centroides para fazer previsões para novos exemplos (MCINTYRE; BLASHFIELD,

1980). Um centroide é o centro geométrico de uma distribuição de dados, como a média. Em dimensões múltiplas, este seria o valor médio ao longo de cada dimensão, formando um ponto central da distribuição em cada variável (WANG, S.; ZHU, 2007).

O algoritmo NC pressupõe que os centroides dos recursos são diferentes para cada classe de destino. Os dados de treinamento são agrupados por classe e, em seguida, o centroide para cada grupo de dados é calculado. Cada centroide é o valor médio de cada uma das variáveis de entrada. O número de centroides coincide com o número de classes. Dados novos exemplos, a distância entre uma determinada linha de dados e cada centroide é calculada e o centroide mais próximo é usado para atribuir um rótulo de classe ao exemplo. Medidas de distância, como distância euclidiana, são usadas para dados numéricos ou distância de *hamming* para dados categóricos (BROWNLEE, 2020i).

Dados um conjunto de amostras rotuladas  $\{(\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n)\}$  com os rótulos das classes  $y_i \in Y$ , calcula-se os centróides por classe através da Equação 48 (BHANDARI, S., 2019).

$$\vec{\mu}_l = \frac{1}{|C_l|} \sum_{i \in C_l} \vec{x}_i \quad (\text{Eq. 48})$$

onde  $C_l$  é o conjunto de índices de amostras pertencentes à classe  $l \in Y$ .

A classe atribuída a uma observação  $\vec{x}$  é dada pela função da Equação 49 (BHANDARI, S., 2019).


$$\hat{y} = \arg \min_{l \in Y} \|\vec{\mu}_l - \vec{x}\| \quad (\text{Eq. 49})$$

#### 2.3.5.14 Multilayer Perceptron

MLP é uma Rede Neural Artificial (RNA) (YEGNANARAYANA, 2009) clássica com uma ou mais camadas ocultas com um número indeterminado de neurônios. A camada oculta possui esse nome porque não é possível prever a saída desejada nas camadas intermediárias (TAUD; MAS, 2018). A Figura 10 mostra um diagrama de um MLP, com uma camada de neurônios de entrada, duas camadas neurais ocultas e a camada de neurônios de saída.

Para treinar a rede MLP, o algoritmo comumente utilizado é o de retropropagação (*Backpropagation*). Trata-se de um mecanismo de aprendizado que permite ao MLP ajustar iterativamente os pesos na rede, com o objetivo de minimizar a função de custo. A função que combina entradas e pesos em um neurônio, por exemplo, a soma ponderada, e a função de limiar, por exemplo, ReLU, devem ser

diferenciáveis, sendo a descida do gradiente normalmente a função de otimização usada no MLP (BENTO, 2021).



Fonte: (MOREIRA, 2018)

Em cada iteração, após as somas ponderadas serem encaminhadas por todas as camadas, o gradiente do “erro quadrado médio” é calculado em todos os pares de entrada e saída. Então, para propagá-lo de volta, os pesos da primeira camada oculta são atualizados com o valor do gradiente, como mostra a Equação 50 (BENTO, 2021).

$$\Delta_w(t) = -\varepsilon \frac{dE}{dw(t)} + \alpha \Delta_w(t-1) \quad (\text{Eq. 50})$$

onde,  $\Delta_w(t)$  é o gradiente da iteração atual,  $\varepsilon$  é o viés,  $dE$  é o erro,  $dw(t)$  é o vetor de pesos,  $\alpha$  é taxa de aprendizagem e  $\Delta_w(t-1)$  é o gradiente da iteração anterior.

Esse processo continua até que o gradiente de cada par de entrada-saída tenha convergido, o que significa que o gradiente recém-calculado não mudou mais do que um limite de convergência especificado, em comparação com a iteração anterior (BENTO, 2021).

#### 2.3.5.15 Extreme Learning Machine

*Extreme Learning Machine* (ELM) é uma rede neural *feedforward* de camada oculta única (HUANG; ZHU; SIEW, 2006). Os pesos de saída são calculados analiticamente no processo de aprendizagem da ELM, enquanto os pesos de entrada são selecionados aleatoriamente. Os pesos dos nós ocultos também são atribuídos aleatoriamente e nunca atualizados (ou seja, eles são projeções aleatórias, porém com transformações não lineares), ou podem ser herdados de seus ancestrais sem

serem alterados. Arquiteturas ELM são, portanto, redes neurais com tempo de convergência muito inferior quando comparadas às RNA (PANDEY; SINGH, 2016).

Funções de ativação (FA) são funções no ELM para calcular pesos e vieses. Uma FA é usada para gerar as saídas da rede neural. A FA é o principal componente para otimizar uma rede neural porque estas aprendem padrões em um conjunto de dados (JEYANTHI; SUBADRA, 2014).

A arquitetura ELM tem base nas etapas apresentadas por Ratnawati *et al.* (RATNAWATI *et al.*, 2020). Tendo um conjunto de treinamento  $\mathfrak{N} = \{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$ , onde  $x_i$  é uma entrada,  $g(x)$  é a FA e  $\tilde{N}$  é o número de neurônios da camada oculta, os passos dos algoritmos ELM são:

- Criar pesos de entrada  $w_i$ , e vieses  $b_i$ , onde  $i = 1, 2, \dots, \tilde{N}$  através do intervalo  $[-1, 1]$ ;
- Calcular a matriz de saída da camada  $H$ , como mostra a Equação 51:

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (\text{Eq. 51})$$

- Computar o peso de saída  $\beta$ , como mostra a Equação 52:

$$\beta = H^+ T \quad (\text{Eq. 52})$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad e \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

com valor  $H^+$  definido como mostra a Equação 53:

$$H^+ = (H^T H)^{-1} H^T \text{ e } H^T H \text{ não-singular} \quad (\text{Eq. 53})$$

$$H^+ = H^T (H H^T)^{-1} \text{ e } H H^T \text{ não-singular}$$

A classe  $t_i^k$  é definida como mostra a Equação 54:

$$t_i^k = \begin{cases} 1 & \text{if } c_i = k \\ -1 & \text{if } c_i \neq k \end{cases} \text{ for } k = 1, 2, \dots, C. \quad (\text{Eq. 54})$$

onde  $\beta$  denota a matriz com pesos de saída,  $H^+$  denota a pseudo matriz inversa Moore Penrose (RATNAWATI *et al.*, 2020)  $H$ ,  $T$  denota a matriz de classes,  $H$  denota matriz de camada oculta de saída,  $H^T$  é uma matriz de camada oculta de saída transposta,  $c_i$  é um rótulo de classe para  $x_i$ , and  $C$  é o número de classes.


- Calcular o resultado da previsão usando a Equação 55:

$$y_k = H \cdot \beta_k \text{ for } k = 1, 2, \dots, C. \quad (\text{Eq. 55})$$

- Estimar o rótulo da classe usando a Equação 56:

$$\hat{c}_i = \arg \max_{k=1,2,\dots,C} y_i^k \quad (\text{Eq. 56})$$

Figura 11 - Gráficos dos comportamentos das funções de ativação implementadas no classificador ELM



FONTE: (PARASCANDOLO; HUTTUNEN; VIRTANEN, 2016; LIU, T.; QIU; LUAN, 2019; PANDEY; SINGH, 2016; BERNER; ELBRÄCHTER; GROHS, 2019; DUBEY; JAIN, 2019; MANESSI; ROZZA, 2018; (SINGH, A.; SAXENA; LALWANI, 2013; JAMEL; KHAMMAS, 2012; MOVAHEDIAN; BAKHTIAR, 2004; LIU, Q.; WANG, 2008; GUNDOGDU *et al.*, 2016; ALQEZWEEENI *et al.*, 2018; CHIENG *et al.*, 2018; RATNAWATI *et al.*, 2020; DING, B.; QIAN; ZHOU, 2018; SUN, K. *et al.*, 2019)

As funções de ativação implementadas no classificador EML são listadas a seguir:

- *Sinusoidal Function (sine)* (PARASCANDOLO; HUTTUNEN; VIRTANEN, 2016);
- *Hyperbolic Tangent Function (tanh)* (LIU, T.; QIU; LUAN, 2019);
- *Hard Hyperbolic Function (hardtanh)* (PANDEY; SINGH, 2016);
- *Rectified Linear Unit (relu)* (BERNER; ELBRÄCHTER; GROHS, 2019);
- *Leaky ReLU (lrelu)* (DUBEY; JAIN, 2019);
- *Combinação de relu e tanh (tanhre)* (MANESSI; ROZZA, 2018);
- *Triangular Basis Transfer Function (tribas)* (SINGH, A.; SAXENA; LALWANI, 2013);
- *Inverse Triangular Basis Transfer Function (inv\_tribas)* (SINGH, A.; SAXENA; LALWANI, 2013);
- *Sigmoid Function* (JAMEL; KHAMMAS, 2012);

- *Soft Limiting Function (softlim)* (MOVAHEDIAN; BAKHTIAR, 2004);
- *Hard Limiting Function (hardlim)* (LIU, Q.; WANG, 2008);
- *Gaussian Function* (GUNDOGDU et al., 2016);
- *Multiquadric Radial Basis Function (multiquadric)* (ALQEZWEENI et al., 2018);
- *Inverse Multiquadric Radial Basis Function (inv\_multiquadric)* (ALQEZWEENI et al., 2018);
- *Swish Function* (CHIENG et al., 2018);
- *Exponential Linear Squashing (elish)* (RATNAWATI et al., 2020);
- *Exponential linear units (elu)* (DING; QIAN; ZHOU, 2018);
- *Softplus Function (softplus)* (SUN, K. et al., 2019).

A

Figura 11 mostra o comportamento de cada função de ativação.

#### 2.3.5.16 Ensemble

Modelos ensemble utilizam um conjunto de modelos para fazer previsões, ao invés de modelos individuais, baseando-se na premissa que o conjunto obtém melhor desempenho preditivo do que poderia ser obtido com qualquer um dos modelos constituintes usados de forma isolada (POLIKAR, 2012). A ideia consiste em combinar diversos modelos de predição mais simples (*weak learner*), treiná-los para uma mesma tarefa, e produzir a partir desses, um modelo agrupado mais complexo (*strong learner*) que é a soma de suas partes. Portanto, os modelos ensemble devem levar em conta a maneira com a qual eles agrupam os modelos individuais de forma a minimizar suas desvantagens individuais no modelo final (ZHANG, Cha; MA, 2012).

Empiricamente, os conjuntos tendem a render melhores resultados quando existe uma diversidade significativa entre os modelos. Muitos modelos ensemble, portanto, procuram promover a diversidade entre os modelos constituintes (DIETTERICH, 2000).

Segundo Polikar (POLIKAR, 2012), existem vários tipos de ensemble, com destaque para ensemble com base em votação. Um ensemble com base em votação funciona combinando as previsões dos modelos constituintes. Pode ser usado para classificação ou regressão. No caso da regressão, a previsão do conjunto envolve o cálculo da média das previsões dos modelos constituintes. No caso de classificação, somam-se existem duas abordagens para a previsão do voto da maioria dos modelos: votos majoritários (*hard voting*) e votos ponderados (*soft voting*). A técnica “votos

majoritários” envolve somar as previsões para cada rótulo de classe e prever o rótulo de classe com mais votos. A técnica “votos ponderados” envolve somar as probabilidades previstas (ou pontuações semelhantes às probabilidades) para cada rótulo de classe e prever o rótulo de classe com a maior probabilidade (BROWNLEE, 2020f).

### **2.3.6 Importância de Características**

Os valores de importância indicam quais características tiveram o maior impacto em cada previsão gerada pela classificação. Cada valor de importância de características tem uma magnitude e uma direção (positiva ou negativa), que indicam como cada característica afeta uma determinada previsão (HOOKER *et al.*, 2018).

Geralmente, as importâncias das características podem ser divididas em importâncias modulares globais e locais. Enquanto uma importância do recurso global modular mede a importância do recurso para todo o modelo, uma importância local mede a contribuição do recurso para uma observação específica (SAARELA; JAUHIAINEN, 2021).

Entre as técnicas de definição de importância de características modulares globais, destaca-se a técnica de permutação, uma vez que esta pode ser usada para qualquer modelo independente do classificador.

A importância da característica revelada pela técnica de permutação mede o aumento no erro de predição do modelo depois que são permutados os valores da característica, o que quebra a relação entre a característica e a variável alvo. São permutados de forma aleatória os valores de todas as características, sendo uma por vez. Mede-se a importância de uma característica calculando o aumento no erro de predição do modelo depois de permutá-la. Uma característica é “relevante” se o embaralhar de seus valores aumenta o erro do modelo, porque neste caso o modelo contou com a característica para a previsão. Uma característica é menos importante se o embaralhar de seus valores deixar o erro do modelo inalterado. Salienta-se que embora um recurso possa parecer desnecessário ou menos relevante por causa de sua pontuação de importância baixa (ou negativa), pode ser que ele esteja correlacionado a outros recursos que ainda podem produzir um resultado de desempenho 'bom' (ALTMANN *et al.*, 2010).

Formalmente, para um modelo treinado  $\hat{f}$ , uma matriz de características  $X$ , um vetor alvo  $y$  e o erro  $L(y, \hat{f})$ , calcula-se a relevância da característica através de permutações, seguindo os passos descritos a seguir (MOLNAR, 2020):

- Estima-se o erro quadrático médio do modelo original,  $e_{orig} = L(y, \hat{f}(X))$ ;
- Para cada característica  $j \in \{1, \dots, p\}$  deve-se:
  - Gerar a matriz de características permutadas  $X_{perm}$ , através da permutação aleatória dos dados  $X$  da característica  $j$ . A permutação aleatória quebra a associação entre a característica  $j$  e o vetor alvo  $y$ .
  - Estima-se o erro quadrático médio,  $e_{perm} = L(Y, \hat{f}(X_{perm}))$ , de predições feitas através dos dados permutados;
  - Calcula-se a importância da característica permutada (ICP)  $j$ , como sendo  $ICP_j = \frac{e_{perm}}{e_{orig}}$ .

## 2.4 SÍNTESE DO CAPÍTULO

O capítulo inicia mostrando que a inspeção da qualidade de produtos cárneos tem sido feita há bastante tempo por métodos instrumentais e análises químicas, que embora considerados métodos consistentes e confiáveis em comparação com inspeção manual, não são viáveis para adoções em escala, em contextos de análise de frescor de produtos em tempo real.

Foram apresentados métodos não destrutivos para inspeção do frescor de produtos cárneos com base em IA, sendo eles: SVC, NIR, técnicas de imagens espectrais, técnicas de espectroscopia Raman, imagens ultrassônicas, e por fim, *e-Nose* e *e-Tongue*.

Em seguida, foram apresentadas as bases conceituais dos espaços de cores RGB, HSV, HSI e  $L^*a^*b^*$  para a proposição de características a serem extraídas das imagens digitais das amostras de carne.

As bases conceituais de AM necessárias para a construção de modelos de AM que possam classificar os níveis de frescor de amostras de carne de peixes, com base em seus parâmetros colorimétricos foram apresentadas.

No Capítulo 3 serão explanados os arcabouços metodológicos utilizados para realização da revisão da literatura, para a construção do SVC, bem como para a construção dos modelos de classificação com base em AM.

### 3 METODOLOGIA DE PESQUISA


Para o desenvolvimento da solução de classificação do frescor da carne de peixes, foi necessária a construção de 3 (três) fases metodológicas a serem seguidas de forma ordenada: Fase I, revisão da literatura; Fase II, *Design Science Research* (DSR) e Fase III, Experimentação, mostradas na Figura 12. As 3 (três) fases metodológicas em conjunto perfazem o melhor uso de recursos metodológicos para a construção da solução.

A Fase I, revisão da literatura, descrita na Seção 3.1, embasa as Fases II e III. Trata-se de uma fase exploratória acerca de soluções para classificar o frescor de produtos cárneos, na qual se busca entendimento do contexto do problema e o estado da arte. Entende-se que esta fase identifica possíveis lacunas ou limitações em soluções de IA existentes para classificar o frescor de produtos cárneos, devendo ser a fase que abre o processo metodológico, e encoraja o desenvolvimento de uma solução que possa ser mais vantajosa e que possa cobrir lacuna e limitações.

Como mostra a Figura 12, a Fase I, resulta em achados advindos dos artigos que resultam da revisão da literatura e que respondem perguntas norteadoras. Tais achados são listados na Tabela 2, estudos resultantes do MSL. Salienta-se que tais estudos tornam possível a percepção de vantagens e desvantagens de cada método de classificação do frescor de produtos cárneos com base em IA permitindo decisões acerca de sua adoção e influenciando os passos seguintes da pesquisa. Dada a decisão de usar o método de VC, foi possível identificar, dentre os estudos resultantes do MSL, os trabalhos relacionados, ainda na Fase I. Os trabalhos relacionados são assim identificados por usarem o mesmo método de classificação de frescor utilizado nesta tese (visão computacional) e usarem o mesmo produto cárneo utilizado nesta tese (carne de peixes). A síntese dos trabalhos resultantes do MSL é mostrada na Seção 3.1.1.3, por trazerem conceitos que fundamentam a construção da solução de classificação de frescor de carne de peixes desta tese.

O aprendizado advindo da Fase I, revisão da literatura, descrita Seção 3.1, alimenta, como se vê na Figura 12, a Fase II, *DSR*. A Fase II explicita a técnica de DSR com os passos usados para construção do SVC desta pesquisa, e é descrita na Seção 3.2. As diversas versões do SVC criadas segundo os passos da DSR são mostradas no Capítulo 4, resumidas no Quadro 4.

Figura 12 - Fases da metodologia para o desenvolvimento da solução para classificação do frescor da carne de peixes



Fonte: A Autora (2021)

Por fim, a metodologia experimentação, Fase III do processo metodológico, é descrita na Seção 3.3. Salienta-se que o planejamento experimental só foi possível, graças ao entendimento das lacunas dos experimentos realizados nos trabalhos resultantes do MSL advindos da Fase I, bem como após a conclusão dos passos da DSR, Fase II, que permitiu o entendimento de como o SVC impactaria os modelos de AM.

Em resumo, as 3 (três) fases metodológicas adotadas para a construção da solução de frescor da carne de peixe devem ser aplicadas sequencialmente, de modo que uma fase sirva de apoio decisório a fase subsequente.

### 3.1 REVISÃO DA LITERATURA

A revisão da literatura foi realizada em dois momentos, com o objetivo de afunilar o conhecimento, sendo no primeiro momento realizada uma busca exploratória ou *ad hoc*, de abrangência mais ampla e no segundo momento, sendo realizado um MSL, com foco nas áreas desta pesquisa. O MSL considerou os últimos 7 (sete) anos de publicações (2015 a 2021).

Na revisão exploratória ou *ad hoc*, buscou-se por estudos que apresentassem soluções automatizadas como auxílio no processo de tomada de decisão, acerca do frescor de carnes, em geral. Foram encontrados estudos apresentando soluções para classificação do frescor de carnes de boi, carnes de porco, carnes de frango e carnes de peixe. O objetivo da busca *ad hoc* foi encontrar estudos primários que pudessem proporcionar visão acerca de soluções existentes, bem como dar direcionamento acerca dos passos a serem seguidos. A busca contemplou artigos publicados em conferências e periódicos escritos em português e em inglês e foi feita no *Google Scholar*<sup>5</sup> usando a *string* a seguir:

- (meat) and (freshness or quality).

Foram analisados os estudos resultantes da busca através da leitura do *abstract* e excluindo-se os estudos que não apresentaram soluções para classificação do frescor de carnes com base em análise sensorial.

Os resultados da busca *ad hoc* também proporcionaram o conhecimento acerca dos principais mecanismos de busca nos quais os estudos são indexados: *Elsevier*

---

<sup>5</sup> <https://scholar.google.com.br/>

(ScienceDirect<sup>6</sup>), IEEE (IEEEExplore<sup>7</sup>) e Springer (SpringerLink<sup>8</sup>). Os resultados da busca *ad hoc* serviram para que se pudesse conhecer, soluções para determinação do frescor de alimentos com base na análise sensorial. Os mecanismos de busca listados nesta seção foram utilizados no MSL, apresentado na Seção 3.1.1. Através dos resultados, foi possível entender como são construídas as soluções de classificação do frescor de carnes. Especificamente, através dos estudos que usam VC para classificação de peixes com parâmetros colorimétricos, foi possível encontrar lacunas, que ajudaram a refinar a pergunta de pesquisa desta tese e de seus objetivos propostos.

### 3.1.1 Mapeamento Sistemático da Literatura

O MSL seguiu o protocolo operacional apresentado no Quadro 3 (KITCHENHAM; CHARTERS, 2007).

Quadro 3 - Etapas do processo do mapeamento sistemático da literatura

| Planejamento                                                                                                                             | Execução                                                                                                                        | Análise e Divulgação                                                                                                                            |
|------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------|
| <ul style="list-style-type: none"> <li>- Elaboração de perguntas de pesquisa;</li> <li>- Elaboração do protocolo de Pesquisa;</li> </ul> | <ul style="list-style-type: none"> <li>- Identificação dos trabalhos existentes;</li> <li>- Extração das evidências;</li> </ul> | <ul style="list-style-type: none"> <li>- Sintetização das evidências;</li> <li>- Exposição do estado da arte e de outros resultados;</li> </ul> |

Fonte: (KITCHENHAM; CHARTERS, 2007)

Neste contexto, as perguntas que norteiam o MSL são:

*P1: Quais as principais soluções utilizadas para classificar o frescor de carne bovina, de porco, de frango e de peixes, com base em análise sensorial?*

*P2: Quais as principais soluções com base em VC utilizadas para classificar o frescor de carne bovina, de porco, de frango e de peixes, com base em análise sensorial da cor?*

*P3: Quais os hardwares e softwares compõem o SVC utilizado para captura de imagens de amostras de carne das soluções encontradas em P2?*

*P4: Quais as principais vantagens e desvantagens percebidas em cada tipo de solução para classificar a qualidade de carne bovina, de porco, de frango e de peixes com base em análise sensorial?*

<sup>6</sup> <https://www.sciencedirect.com/>

<sup>7</sup> <https://ieeexplore.ieee.org/Xplore/home.jsp>

<sup>8</sup> <https://link.springer.com/>

Foram feitas buscas nos mecanismos de pesquisa *Elsevier*, *IEEE*, *Springer* e *Google Acadêmico*.

#### 3.1.1.1 Estratégia de Busca

Para realizar as buscas de forma automática nos mecanismos de pesquisa, foi concebida uma *string* de busca, através dos termos mais comuns encontrados nos títulos, *abstracts* e palavras-chaves dos artigos resultantes da busca *ad hoc*. Foram concebidos sinônimos e termos associados; tradução dos termos para língua inglesa; e por fim, agrupamento dos termos através de aspas e operadores lógicos **e** (*and*) e **ou** (*or*).

Tentou-se usar uma *string* de busca o mais ampla possível, que pudesse contemplar as áreas de estudo e ainda assim pudesse devolver como resultado, a maior quantidade de artigos possível (mesmo que fossem eliminados por força de aplicação do protocolo desta etapa).

A *string* de busca tem a estrutura apresentada a seguir:

***string de busca: (freshness or quality or color) and (meat or beef or pork or chicken or fish or tuna or salmon).***

CrITÉRIOS de inclusão (CI) e critérios de exclusão (CE) foram aplicados em etapas. Os CIs, CEs e as etapas são mostrados no Apêndice A. Considerando os artigos resultantes como semente, foi aplicada a técnica *snowball* (BIERNACKI; WALDORF, 1981), repetindo as etapas nas referências destes.

O planejamento da aplicação da técnica de *snowball* é de até cinco ciclos ou até o seu esgotamento, o que acontecer primeiro. O esgotamento é o ponto de saturação que ocorre quando as referências do trabalho analisado não retornam mais pesquisas para o presente trabalho. Esta etapa visou buscar outros artigos relevantes e que, por qualquer falha, não foram encontrados em etapas anteriores. Como resultado do *snowball*, mais um artigo, foi somado aos artigos semente, completando o MSL, resultando em 38 (trinta e oito) artigos.

#### 3.1.1.2 Estudos Resultantes do Mapeamento Sistemático da Literatura

A Tabela 1 mostra o número de artigos resultantes após a aplicação de cada etapa do MSL. Percebe-se ao final, 38 (trinta e oito) artigos resultantes (8,7156% do total de artigos), tendo o mecanismo de busca *Elsevier* fornecido a maior quantidade.


O MSL totalizou uma amostra final de 38 (trinta e oito) artigos contendo métodos de classificação de produtos cárneos. A distribuição temporal dos estudos é mostrada no Gráfico 1. Percebe-se aumento no número de publicações acerca do tema em 2020, em relação aos anos anteriores, o que demonstra atual interesse da comunidade acadêmica em estudos sobre soluções para determinar a qualidade de alimentos.

Tabela 1 - Quantidade de artigos resultantes após as etapas do mapeamento sistemático da literatura

| Mecanismo de busca | Etapa 1 | Etapa 2  | Etapa 3  | Etapa 4  | Etapa 5 |
|--------------------|---------|----------|----------|----------|---------|
| IEEE               | 82      | 82       | 51       | 25       | 11      |
| Elsevier           | 98      | 98       | 75       | 17       | 14      |
| Springer           | 131     | 131      | 110      | 9        | 2       |
| Google Acadêmico   | 125     | 43       | 22       | 12       | 10      |
| TOTAL              | 436     | 354      | 258      | 63       | 38      |
|                    | 100%    | 81,1927% | 59,1743% | 14,4495% | 8,7156% |

Fonte: A Autora (2021)

Gráfico 1 - Distribuição dos artigos do MSL por ano de publicação




Fonte: A Autora (2021)

O Gráfico 2 apresenta a quantidade de estudos versus o tipo de carne estudada. Há estudos que apresentam mais de um tipo de carne. Percebe-se que a carne de peixe, contexto desta tese, foi o tipo de carne mais explorada no desenvolvimento de soluções para determinar o seu frescor (18 artigos), divididos entre peixes de várias espécies, incluindo, 5 (cinco) estudos com atum e 2 (dois) com salmão.

O Gráfico 3 apresenta a quantidade de estudos versus o método sensorial usado para analisar o frescor das carnes estudadas. Os 38 (trinta e oito) estudos


resultantes do MSL e listados na Tabela 2 trouxe respostas às perguntas *P1*: “*Quais as principais soluções utilizadas para classificar o frescor de carne bovina, de porco, de frango e de peixes, com base em análise sensorial?*” que norteou este MSL.

Gráfico 2 - Tipo de carnes estudadas nos artigos do MSL para determinação de seu frescor



Fonte: A Autora (2021)

Gráfico 3 - Distribuição dos artigos do MSL por método de análise sensorial



Fonte: A Autora (2021)

Percebe-se que 23 (vinte e três) estudos adotam VC para classificar o frescor das carnes estudadas, sendo 100% deles com base em análise de parâmetros colorimétricos extraídos de imagens digitais de amostras e respondem a *P2*: “*Quais as principais soluções com base em VC utilizadas para classificar o frescor de carne*

*bovina, de porco, de frango e de peixes, com base em análise sensorial da cor?*”. Na Seção 3.1.1.3 são detalhadas as soluções com base em VC utilizados para classificação de carnes de peixes, já que apresentam estreita relação com a pesquisa desenvolvida nesta tese. Os demais estudos utilizam as técnicas de e-Nose, imagens ultrassônicas, imagens espectrais e NIR.

A Tabela 2 apresenta um sumário dos 38 (trinta e oito) estudos resultantes do MSL, apresentando o ano de publicação, o mecanismo de busca que o indexou, o tipo de carne estudada, o método de análise sensorial, as vantagens e desvantagens de cada método e se as amostras foram coletadas em ambiente controlado. Nos estudos que apresentam como método de análise sensorial a VC, são apresentados os recursos que foram utilizados para extração de parâmetros de cores a partir de imagens digitais das amostras das carnes estudadas, salientando que em modelos de DL e redes neurais convolucionais (RNC) (ALBAWI; MOHAMMED; AL-ZAWI, 2017) as características de cores das imagens são extraídas pelas próprias arquiteturas. Ainda são apresentados os números de amostras capturadas nos ambientes controlados e, por fim, os algoritmos ou outros métodos de análise utilizados para observação do frescor ou da qualidade das carnes estudadas, bem como as acurácias atingidas. As células da Tabela 2 que não contém informações, se dá pela ausência destas nos estudos.

Nos 23 (vinte e três) estudos que adotam VC como método para análise do frescor de produtos cárneos, tentou-se entender que *hardware* e *softwares* são utilizados para a captura das imagens digitais, salientando que todos adotam ambientes controlados para captura das imagens das amostras em laboratórios.

Apesar dos estudos relatarem *hardware* e *software* utilizados no SVC usado para captura das imagens, percebe-se a falta de informações suficientes para que *hardware* semelhantes possam ser utilizados. Também se percebe a falta de informação suficientes acerca do protocolo de captura das imagens digitais das amostras de carne, de modo a facilitar a reprodutibilidade do protocolo. Desta feita os estudos respondem de forma parcial à pergunta P3 deste MSL: “*Quais os hardwares e softwares compõem o SVC utilizado para captura de imagens de amostras de carne das soluções encontradas em P2?*”. Na Seção 3.1.1.3 estão detalhados os *hardwares* das soluções com base em VC utilizados para classificação de carnes de peixes, respondendo parcialmente a P3.

Para cada método de análise sensorial, entendeu-se as vantagens e as desvantagens citadas pelos diversos autores dos estudos como resposta à pergunta *P4: “Quais as principais vantagens e desvantagens percebidas em cada tipo de solução para classificar a qualidade de carne bovina, de porco, de frango e de peixes, com base em análise sensorial?”* que norteou esse MSL. Na Tabela 2 são apresentadas as vantagens e desvantagens de cada solução apontada pelos autores.

O escopo desta tese envolve o uso de VC, pela rapidez na instrumentalização das amostras e pelo menor custo da solução quando comparado a outros métodos de análise de qualidade de alimentos.

Tabela 2 - Estudos resultantes do mapeamento sistemático da literatura

| Estudo                            | Ano  | Base     | Tipo de Carne                                                           | Vantagens ou desvantagens                                                                | Método para Automatizar a Análise Sensorial | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras          | Algoritmos/Métodos para Observação do Frescor                          | Acurácia             |
|-----------------------------------|------|----------|-------------------------------------------------------------------------|------------------------------------------------------------------------------------------|---------------------------------------------|------------------------------|-------------------------------------------|---------------------------------|------------------------------------------------------------------------|----------------------|
| (ADI <i>et al.</i> , 2015)        | 2015 | IEEE     | Boi                                                                     | -                                                                                        | Visão Computacional                         | Ambiente controlado          | RGB, HSV                                  | -                               | KNN                                                                    | -                    |
| (CHENG <i>et al.</i> , 2015)      | 2015 | Elsevier | Peixe ( <i>Ctenopharyngodon idellae</i> ; <i>Aristichthys nobilis</i> ) | -                                                                                        | Imagens Espectrais                          | Ambiente controlado          |                                           | Imagens espectrais de 40 peixes | PLSR                                                                   | 93,6%                |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 | LS-SVM                                                                 | 92,2%                |
| (TRIENTIN; HIDAYAT; DARANA, 2015) | 2015 | IEEE     | Boi                                                                     | Desvantagem: apenas inspeção externa                                                     | Visão Computacional                         | Ambiente controlado          | RGB, HSV, Transformação <i>wavelet</i>    | 196                             | KNN                                                                    | 75%                  |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 | MLP                                                                    | 71,4286 %            |
| (JANG <i>et al.</i> , 2015)       | 2015 | IEEE     | Boi                                                                     | Vantagem: fornece ampla variedade de parâmetros mensuráveis.<br>Desvantagem: alto custo. | Imagens Ultrassônicas                       | Ambiente controlado          |                                           | -                               | MLP                                                                    | 83,33%               |
| (BARBIN <i>et al.</i> , 2016)     | 2016 | Elsevier | Frango                                                                  | -                                                                                        | Visão Computacional                         | Ambiente controlado          | Colorímetro Minolta <sup>9</sup> , L*a*b* | 52                              | Correlação das cores das amostras obtidas com colorímetro e com L*a*b* | L* = 99%             |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 |                                                                        | a* = 74%             |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 |                                                                        | b* = 88%             |
| (SUN, X. <i>et al.</i> , 2016)    | 2016 | Elsevier | Porco                                                                   | -                                                                                        | Visão Computacional                         | Ambiente controlado          | Colorímetro Minolta, RGB, HSI, L*a*b*     | 100                             | Correlação das cores das amostras obtidas com colorímetro e com L*a*b* | L* = 90%             |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 |                                                                        | a* = 80%             |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 |                                                                        | b* = 66%             |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 |                                                                        | Regressão Linear 83% |
|                                   |      |          |                                                                         |                                                                                          |                                             |                              |                                           |                                 | Regressão <i>Stepwise</i>                                              | 70%                  |

<sup>9</sup> <https://www5.konicaminolta.eu/en/measuring-instruments/products/colour-measurement/chroma-meters/cr-400-410/introduction.html>

| continuação (2/6)                          |      |          |                                            |                           |                                             |                              |                                           |                                  |                                               |          |
|--------------------------------------------|------|----------|--------------------------------------------|---------------------------|---------------------------------------------|------------------------------|-------------------------------------------|----------------------------------|-----------------------------------------------|----------|
| Estudo                                     | Ano  | Base     | Tipo de Carne                              | Vantagens ou desvantagens | Método para Automatizar a Análise Sensorial | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras           | Algoritmos/Métodos para Observação do Frescor | Acurácia |
| (GHASEMI-VARNAMKHAHI <i>et al.</i> , 2016) | 2016 | Google   | Camarão (comprados em fazendas de camarão) | -                         | Visão Computacional                         | Ambiente controlado          | RGB, HSV, HSI, L*a*b*, L*C*h              | Dados de 80 camarões             | LDA                                           | 90%      |
|                                            |      |          |                                            |                           |                                             |                              |                                           |                                  | QDA                                           | -        |
|                                            |      |          |                                            |                           |                                             |                              |                                           |                                  | KNN                                           | 83,44%   |
|                                            |      |          |                                            |                           |                                             |                              |                                           |                                  | DA-PLS                                        | 86,25%   |
| (DUTTA <i>et al.</i> , 2016)               | 2016 | Elsevier | Peixe ( <i>L. rohita</i> )                 | -                         | Visão Computacional                         | Ambiente controlado          | RGB, HSV, Transformação <i>wavelet</i>    | 24                               | Segmentação                                   | -        |
| (ASMARA <i>et al.</i> , 2017)              | 2017 | IEEE     | Frango                                     | -                         | Visão Computacional                         | Ambiente controlado          | RGB                                       | 60                               | NB                                            | 41,67%   |
|                                            |      |          |                                            |                           |                                             |                              |                                           |                                  | SVM                                           | 58,33%   |
|                                            |      |          |                                            |                           |                                             |                              |                                           |                                  | DT                                            | 41,67%   |
| (ISSAC; DUTTA; SARKAR, 2017)               | 2017 | Elsevier | Peixe ( <i>L. rohita</i> )                 | -                         | Visão Computacional                         | Ambiente controlado          | RGB, HSV, L*a*b*                          | Dados de 48 peixes               | Segmentação                                   | -        |
| (ARSALANE <i>et al.</i> , 2018)            | 2018 | Elsevier | Boi                                        | -                         | Visão Computacional                         | Ambiente controlado          | HSI                                       | 81                               | SVM                                           | 100%     |
| (KARTAKOULLIS <i>et al.</i> , 2018)        | 2018 | IEEE     | Porco                                      | -                         | Imagens Espectrais                          | Ambiente controlado          |                                           | 1924                             | RF                                            | 95,2%    |
| (SUN, X. <i>et al.</i> , 2018)             | 2018 | Elsevier | Porco                                      | -                         | Visão Computacional                         | Ambiente controlado          | RGB, HSI, L*a*b*                          | 280                              | SVM                                           | 78,9%    |
| (WINIARTI; AZHARI; AGUSTA, 2018)           | 2018 | IEEE     | Boi                                        | -                         | Visão Computacional                         | Ambiente controlado          | HSI                                       | 40                               | <i>K-Means</i>                                | -        |
| (SHAN <i>et al.</i> , 2018)                | 2018 | Springer | Peixe ( <i>Carassius auratus</i> )         | -                         | Imagens Espectrais                          | Ambiente controlado          |                                           | 40                               | DA-PLS                                        | 100%     |
| (SUXIA <i>et al.</i> , 2018)               | 2018 | IEEE     | Frango                                     | -                         | Imagens Espectrais                          | Ambiente controlado          |                                           | Imagens espectrais de 62 frangos | Rede Neural RBF                               | 100%     |

continuação (3/6)

| Estudo                                  | Ano  | Base     | Tipo de Carne                        | Vantagens ou desvantagens                                                       | Método para Automatizar a Análise Sensorial | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras | Algoritmos/Métodos para Observação do Frescor | Acurácia |
|-----------------------------------------|------|----------|--------------------------------------|---------------------------------------------------------------------------------|---------------------------------------------|------------------------------|-------------------------------------------|------------------------|-----------------------------------------------|----------|
| (AL-SARAYREH <i>et al.</i> , 2018)      | 2018 | Google   | Cordeiro                             | -                                                                               | Imagens Espectrais                          | Ambiente controlado          |                                           | Dados de 18 cordeiros  | RNC                                           | 94,4%    |
|                                         |      |          | Boi                                  |                                                                                 |                                             |                              |                                           | Dados de 13 bois       |                                               |          |
|                                         |      |          | Porco                                |                                                                                 |                                             |                              |                                           | Dados de 13 porcos     |                                               |          |
| (LV <i>et al.</i> , 2018)               | 2018 | Google   | Peixe ( <i>Larimichthys crocea</i> ) | Desvantagens: Sensibilidade dos sensores; Dificuldade de reprodução da solução. | e-Nose                                      | Ambiente controlado          | TVB-N                                     | 150                    |                                               | 76,98%   |
|                                         |      |          |                                      |                                                                                 |                                             |                              | TVC                                       |                        |                                               | 77%      |
| (ALCAYDE; ELIJORDE; BYUN, 2019)         | 2019 | IEEE     | Porco                                | -                                                                               | Visão Computacional                         | Ambiente controlado          | RGB                                       | 168                    | Regressão Linear                              | 68%      |
|                                         |      |          |                                      |                                                                                 |                                             |                              |                                           |                        | Regressão Múltipla                            | 91%      |
|                                         |      |          |                                      |                                                                                 |                                             |                              |                                           |                        | Regressão Polinomial                          | 72%      |
| (LUGATIMAN <i>et al.</i> , 2019)        | 2019 | IEEE     | Atum ( <i>Yellowfin</i> )            | Vantagem: Velocidade e baixo custo da solução;                                  | Visão Computacional                         | Ambiente controlado          | RGB                                       | Dados de 60 atuns      | KNN                                           | 86,67%   |
| (ARSALANE <i>et al.</i> , 2019)         | 2019 | Springer | Boi                                  | -                                                                               | Visão Computacional                         | Ambiente controlado          | HSI                                       | 81                     | LDA                                           | 81,48%   |
| (TAHERI-GARAVAND <i>et al.</i> , 2019b) | 2019 | Elsevier | Peixe ( <i>Cyprinus carpio</i> )     | -                                                                               | Visão Computacional                         | Ambiente controlado          | RGB, HSI, L*a*b*                          | Dados de 48 peixes     | RNA                                           | 86,41%   |
|                                         |      |          |                                      |                                                                                 |                                             |                              |                                           |                        | SVM                                           | 91,52%   |
|                                         |      |          |                                      |                                                                                 |                                             |                              |                                           |                        | KNN                                           | 90,48%   |
| (TAHERI-GARAVAND <i>et al.</i> , 2019)  | 2019 | Google   | Frango                               | -                                                                               | Visão Computacional                         | Ambiente controlado          | RGB, HSI, L*a*b*                          | Dados de 30 frangos    | MLP                                           | 93,01%   |
|                                         |      |          |                                      |                                                                                 |                                             |                              |                                           |                        | RNA                                           | 98,7%    |
| (HOSSEINPOUR; ILKHCHI; AGHBASHLO, 2019) | 2019 | Elsevier | Boi                                  | -                                                                               | Visão Computacional                         | Ambiente controlado          | RGB                                       | 167                    | MLP                                           | 97%      |

| continuação (4/6)                      |      |          |                                      |                                  |                                                              |                              |                                           |                                                     |                                               |          |
|----------------------------------------|------|----------|--------------------------------------|----------------------------------|--------------------------------------------------------------|------------------------------|-------------------------------------------|-----------------------------------------------------|-----------------------------------------------|----------|
| Estudo                                 | Ano  | Base     | Tipo de Carne                        | Vantagens ou desvantagens        | Método para Automatizar a Análise Sensorial                  | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras                              | Algoritmos/Métodos para Observação do Frescor | Acurácia |
| (ZHAO <i>et al.</i> , 2019)            | 2019 | Elsevier | Boi                                  | -                                | Imagens Espectrais                                           | Ambiente controlado          |                                           | Imagens espectrais de 75 amostras                   | PLSR                                          | 92%      |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | SVM                                           | 94%      |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | LS-SVM                                        | 94%      |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | ELM                                           | 94%      |
| (ZHOU, J. <i>et al.</i> , 2019)        | 2019 | Elsevier | Peixe ( <i>Bighead carp</i> )        | -                                | Espectroscopia de refletância de infravermelho próximo (NIR) | Ambiente controlado          | pH                                        | Dados de 150 peixes                                 | PLSR                                          | 94,5%    |
|                                        |      |          |                                      |                                  |                                                              |                              | TVB-N                                     |                                                     |                                               | 93,2%    |
|                                        |      |          |                                      |                                  |                                                              |                              | TBA                                       |                                                     |                                               | 95,4%    |
| (TAN, W. K.; HUSIN; ISMAIL, 2020)      | 2020 | IEEE     | Boi                                  | -                                | Visão Computacional                                          | Ambiente controlado          | Imagens                                   | 400 amostras originais usadas para aumento de dados | RNC                                           | 90%      |
| (TAHERI-GARAVAND <i>et al.</i> , 2020) | 2020 | Elsevier | Peixe ( <i>Cyprinus carpio</i> )     | -                                | Visão Computacional                                          | Ambiente controlado          | Imagens                                   | 48 amostras originais usadas para aumento de dados  | RNC                                           | 98,21%   |
| (HAN, F. <i>et al.</i> , 2020)         | 2020 | Google   | Boi (adulteração)                    | Vantagens: velocidade de análise | e-Nose                                                       | Ambiente controlado          |                                           | Dados de sensores 84 amostras                       | LDA                                           | 54,17%   |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | ELM                                           | 87,5%    |
| (LALABADI; SADEGHI; MIREEI, 2020)      | 2020 | Elsevier | Peixe ( <i>Oncorhynchus mykiss</i> ) | -                                | Visão Computacional                                          | Ambiente controlado          | RGB, HSV, L*a*b* dos olhos;               | 20                                                  | MLP                                           | 82,67%   |
|                                        |      |          |                                      |                                  |                                                              |                              | RGB, HSV, L*a*b* das guelras              |                                                     | SVM                                           | 68%      |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | MLP                                           | 94,67%   |
|                                        |      |          |                                      |                                  |                                                              |                              |                                           |                                                     | SVM                                           | 84%      |

continuação (5/6)

| Estudo                                  | Ano  | Base   | Tipo de Carne                 | Vantagens ou desvantagens                                                                                            | Método para Automatizar a Análise Sensorial                  | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras                              | Algoritmos/Métodos para Observação do Frescor | Acurácia |
|-----------------------------------------|------|--------|-------------------------------|----------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------|------------------------------|-------------------------------------------|-----------------------------------------------------|-----------------------------------------------|----------|
| (JAYASUNDARA <i>et al.</i> , 2020)      | 2020 | IEEE   | Atum                          | Vantagens: grande quantidade de dados extraídos das amostras. Desvantagens: alto custo e difícil instrumentalização. | Imagens Espectrais                                           | Ambiente controlado          |                                           | Imagens espectrais de 9 atuns                       | LDA                                           | 69,53%   |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | QDA                                           | 82,2%    |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | NV                                            | 65,22%   |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | K <i>Naive Bayes</i>                          | 72,23%   |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | KNN                                           | 83,88%   |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | SVM ( <i>Gaussain</i> )                       | 92%      |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | SVM ( <i>Quantum-enhanced</i> )               | 73,5%    |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              |                                           |                                                     | RNC                                           | 93,3%    |
| (NAIMULLAH; STHEVANIE; RAMADHANI, 2020) | 2020 | Google | Atum ( <i>YellowFin</i> )     |                                                                                                                      | Visão Computacional                                          | Ambiente controlado          | RGB, HSV                                  | 36                                                  | SVM                                           | 81%      |
| (MOON <i>et al.</i> , 2020)             | 2020 | Google | Salmão do Pacífico            | Vantagens: Velocidade da análise. Desvantagens: Custo da solução.                                                    | Espectroscopia de refletância de infravermelho próximo (NIR) | Ambiente controlado          |                                           | Dados de 15 peixes                                  | RNC                                           | 85%      |
|                                         |      |        | Salmão do Atlântico           |                                                                                                                      |                                                              |                              |                                           | Dados de 15 peixes                                  |                                               | 84%      |
|                                         |      |        | Atum (importado da Indonésia) |                                                                                                                      |                                                              |                              |                                           | Dados de 17 peixes                                  |                                               | 88%      |
|                                         |      |        | Boi                           |                                                                                                                      |                                                              |                              |                                           | Dados de 16 peixes                                  |                                               | 92%      |
| (PUTRA; PRAKASA, 2020)                  | 2020 | IEEE   | Frango                        | -                                                                                                                    | Visão Computacional                                          | Ambiente controlado          | Imagens 400 x 400 <i>Pixels</i>           | 100 amostras originais usadas para aumento de dados | AlexNet                                       | 50%      |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              | Imagens 300 x 300 <i>Pixels</i>           |                                                     | VGGNet                                        | 50,9%    |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              | Imagens 400 x 400 <i>Pixels</i>           |                                                     | GoogLeNet                                     | 85,7%    |
|                                         |      |        |                               |                                                                                                                      |                                                              |                              | Imagens 400 x 400 <i>Pixels</i>           |                                                     | Ayam6Net                                      | 92,9%    |

continuação (6/6)

| Estudo                       | Ano  | Base   | Tipo de Carne            | Vantagens ou desvantagens                                                     | Método para Automatizar a Análise Sensorial                  | Forma de Captura das Imagens | Recursos para extração de características | Quantidade de Amostras | Algoritmos/Métodos para Observação do Frescor | Acurácia |
|------------------------------|------|--------|--------------------------|-------------------------------------------------------------------------------|--------------------------------------------------------------|------------------------------|-------------------------------------------|------------------------|-----------------------------------------------|----------|
| (YE <i>et al.</i> , 2020)    | 2020 | Google | Camarão                  | -                                                                             | Imagens Espectrais                                           | Ambiente controlado          |                                           | 420                    | DA-PLS                                        | 88,57%   |
|                              |      |        |                          |                                                                               |                                                              |                              |                                           |                        | SVM                                           | 93,33%   |
|                              |      |        |                          |                                                                               |                                                              |                              |                                           |                        | RF                                            | 97,14%   |
|                              |      |        |                          |                                                                               |                                                              |                              |                                           |                        | ELM                                           | 98,10%   |
| (RADI <i>et al.</i> , 2021)  | 2021 | Google | Peixe ( <i>Tilapia</i> ) | -                                                                             | e-Nose                                                       | Ambiente controlado          |                                           | 50                     | RNA                                           | 93,88%   |
| (RAYAN <i>et al.</i> , 2021) | 2021 | IEEE   | Peixe ( <i>Tilápia</i> ) | -                                                                             | Visão Computacional                                          | Ambiente controlado          | Imagens                                   | Dados de 50 amostras   | RNC                                           | 98%      |
| (CUI; CUI, 2021)             | 2021 | Google | Salmão                   | Desvantagens: necessidade de modelo de referência para análise das previsões. | Espectroscopia de refletância de infravermelho próximo (NIR) | Ambiente controlado          |                                           | -                      | RNC                                           | 84%      |
|                              |      |        | Atum                     |                                                                               |                                                              |                              |                                           |                        |                                               | 88%      |

FONTE: A Autora (2021)

### 3.1.1.3 Síntese dos Estudos Resultantes do Mapeamento Sistemático da Literatura

Adi *et al.* (ADI *et al.*, 2015) utilizam SVC para captura de imagens de amostras de carne de boi, características de cores definidas a partir dos espaços de cores RGB e HSV, e classificador KNN para determinar a classificação do frescor da carne de boi.

Trientin, Hidayat e Darana (TRIENTIN; HIDAYAT; DARANA, 2015) utilizam SVC para aquisição de imagens digitais de amostras de carne bovina, recursos com base nos espaços de cores RGB, HSV e transformações *wavelet* (ZHANG, D., 2019) e classificadores KNN e MLP, com acurácias de 75% e 71,4286% na classificação do frescor das amostras.

Barbin *et al.* (BARBIN *et al.*, 2016) fazem correlações, entre dados de cores de amostras de carne de frango obtidas a partir de colorímetro e dos componentes  $L^*$ ,  $a^*$  e  $b^*$  do espaço de cores  $L^*a^*b^*$  extraídos a partir de imagens digitais obtidas através de SVC (WESTLAND; RIPAMONTI; CHEUNG, 2012).

Sun, X. *et al.* (SUN, X. *et al.*, 2016) utilizam SVC para adquirir imagens digitais e as utilizam para determinar o frescor de amostras de carne de porco. Os autores usam características extraídas das amostras de carne a partir de colorímetro e as compara com os componentes do espaço de cores  $L^*a^*b^*$ . Características de cores com base nos espaços de cores RGB e HSI são utilizadas com algoritmos de regressão linear (RODRIGUES, 2012) e regressão *stepwise* (AGOSTINELLI, 2002), atingindo acurácias de 83% e 70%, respectivamente.

Asmara *et al.* (ASMARA *et al.*, 2017) se utilizam do espaço de cores RGB para extrair características de cores de imagens digitais de amostras da carne de frango através de SVC, para classificar seu frescor. Usando os algoritmos NB, SVM e DT, os autores obtiveram acurácias de 41,67%, 58,33% e 41,67%, respectivamente, na classificação.

Arsalane *et al.* (ARSALANE *et al.*, 2018) se utilizam de SVC para adquirir imagens digitais e extrair características de cores com base no espaço de cores HSI de amostras de carne bovina. As características de cores são usadas em conjunto com o classificador SVM para classificar o frescor da carne bovina, com 100% de acurácia.

Sun, X. *et al.* (SUN, X. *et al.*, 2018) se utilizam de SVC para capturar imagens digitais de amostras de carne de porco e dos espaços de cores RGB, HSI e  $L^*a^*b^*$  para gerar características de cores das amostras. Através do classificador SVM os autores obtiveram uma acurácia de 78,9% na classificação do frescor das amostras.

Winiarti, Azhari e Agusta (WINIARTI; AZHARI; AGUSTA, 2018) usam o algoritmo *K-means* (HAMERLY; ELKAN, 2004) e checam com sucesso se características com base no espaço de cores HSI agrupam amostras de carne de boi, em distintos agrupamentos com base no nível de frescor. As características são extraídas de imagens digitais das amostras capturadas através de SVC.

Em estudo mais recente, Alcayde, Elijorde e Byun (ALCAYDE; ELIJORDE; BYUN, 2019) se utilizam de SVC para aquisição de imagens digitais de amostras de carne de porco e espaço de cores RGB para classificar o frescor das amostras. Os autores utilizaram os algoritmos regressão linear, regressão múltipla (FEIFEI; YANKUN; YONGYU, 2015) e regressão polinomial (FEIFEI; YANKUN; YONGYU, 2015), obtendo acurácias de 68%, 91% e 72%, respectivamente, na classificação.

Em outro estudo, Arsalane *et al.* (ARSALANE *et al.*, 2019) utilizam SVC para captura de imagens digitais da carne bovina, espaço de cores HSI, e classificadores LDA e RNA, com acurácias de 81,48% e 86,41%, respectivamente, para classificar o frescor das amostras.

Taheri-Garavand *et al.* (TAHERI-GARAVAND *et al.*, 2019) fazem uso de SVC para capturar imagens digitais de amostras de frango, e extraem características com base nos espaços de cores RGB, HSI e  $L^*a^*b^*$ . Através de uma RNA os autores obtêm uma acurácia de 98,7% na classificação do frescor das amostras.

Hosseinpour, Ilkhchi e Aghbashlo (HOSSEINPOUR; ILKHCHI; AGHBASHLO, 2019) através de SVC adquirem imagens digitais de amostras de boi, geram características de cores com base no espaço de cores RGB e através do classificador MLP obtêm acurácia de 97% na classificação do frescor das amostras.

Putra e Prakasa (PUTRA; PRAKASA, 2020) utilizam SVC e as imagens digitais de amostras de carne de frango capturadas para, através de arquiteturas

de RNC, classificar as amostras quanto ao nível de frescor. Foram usadas as arquiteturas AlexNet (ALOM *et al.*, 2018), VGGNet (MUHAMMAD *et al.*, 2018), GoogLeNet (BALLESTER; ARAUJO, 2016) e, por fim, a arquitetura Ayam6Net dos próprios autores, obtendo-se acurácias de 50%, 50,9%, 85,7% e 92,9%, respectivamente, na classificação.

Tan, Husin e Ismail (TAN, W. K.; HUSIN; ISMAIL, 2020) usam uma RNC para obter uma acurácia de 90% na classificação do frescor de carne de boi a partir de imagens destas obtidas através de SVC.

Moon *et al.* (MOON *et al.*, 2020) utilizam a técnica NIR para classificar o frescor de amostras de carne de salmão do pacífico, salmão do atlântico, atum e boi, obtendo acurácias de 85%, 84%, 88% e 92%, respectivamente, na classificação, através de uma RNC.

Cui e Cui (CUI; CUI, 2021) utilizam a técnica NIR e RNC para determinar a qualidade de amostras de salmão e de atum, obtendo acurácias de 84% e 88%, respectivamente, na classificação.

Zhou *et al.* (ZHOU, J. *et al.*, 2019) se utilizam de pH, *Total Volatile Basic Nitrogen* (TVB-N) (BEKHIT *et al.*, 2021) e *Thiobarbituric Acid* (TBA) (FERNÁNDEZ; PÉREZ-ÁLVAREZ; FERNÁNDEZ-LÓPEZ, 1997) adquiridos através de NIR para obter acurácia de 94,5%, 93,2%, 95,4%, respectivamente, na classificação do frescor da carne de peixe carpa (*Bighead carp*) obtidas através de *Partial Least-Square Regression* (PLSR) (ABDI, 2003).

Cheng *et al.* (CHENG *et al.*, 2015) utilizam-se de imagens hiperespectrais para classificar o frescor de peixes das espécies *Ctenopharyngodon idellae* e *Aristichthys nobilis*. Os autores fazem uso de classificadores PLSR e *Least-Squares Support Vector Machines* (LS-SVM) (SUYKENS *et al.*, 2002), obtendo acurácias de 93,6% e 92,2%, respectivamente, na classificação.

Kartakoullis *et al.* (KARTAKOULLIS *et al.*, 2018) também fazem uso de imagens hiperespectrais para classificar o frescor da carne de porco, através do algoritmo de classificação RF com acurácia de 95,2%.

A tecnologia de imagens hiperespectrais também é utilizada por Shan *et al.* (SHAN *et al.*, 2018) para classificar o frescor de peixes da espécie *Carassius auratus*. Os autores utilizam *Discriminant Partial Least Squares* (DA-PLS) (LEE; LIONG; JEMAIN, 2018) e obtêm 100% de acurácia na classificação.

Suxia *et al.* (SUXIA *et al.*, 2018) utilizam-se de imagens hiperespectrais e *redes neurais Radial Basis Function* (RBF) (HAN, H.-G.; QIAO, 2011) para classificar o frescor de amostras de frango com 100% de acurácia.

Al-Sarayreh *et al.* (AL-SARAYREH *et al.*, 2018) classificam através de imagens hiperespectrais e RNC o frescor de amostras de carne de cordeiro, de boi e de porco com acurácia de 94,4%.

Zhao *et al.* (ZHAO *et al.*, 2019) preveem a adulteração da carne de boi através de imagens hiperespectrais e classificadores: PLSR com acurácia de 92%, SVM com acurácia de 94%, LS-SVM com acurácia de 94% e, por fim, ELM com acurácia de 94%.

Ye *et al.* (YE *et al.*, 2020) fazem a classificação de frescor de amostras de camarão usando imagens hiperespectrais e DA-PLS com acurácia de 88,57%, SVM com acurácia de 93,33%, RF com acurácia de 97,14% e, por fim, através de ELM com acurácia de 98,10%.

Jayasundara *et al.* (JAYASUNDARA *et al.*, 2020) classificam o frescor de amostras de atum através de imagens multiespectrais através dos classificadores LDA com acurácia de 69,53%, QDA com acurácia de 82,2%, NB com acurácia de 65,22%, *K Naive Bayes* (JIANG, L.; ZHANG; SU, 2005) com acurácia de 72,23%, KNN com acurácia de 83,88%, *Gaussian SVM* (ZHOU, S.-S.; LIU; YE, 2009) com acurácia de 92%, *Quantum-enhanced SVM* (LIN *et al.*, 2020) com acurácia de 73,5% e RNC com acurácia de 93,3%.

Jang *et al.* (JANG *et al.*, 2015) se utilizam de imagens ultrassônicas para para classificar o frescor da carne bovina através de RNC com acurácia de 88,33%.

Lv *et al.* (LV *et al.*, 2018) utilizam-se de dados de TVB-N e *Total Viable Counts* (TVC) (FEIFEI; YANKUN; YONGYU, 2015) obtidos através de *e-Nose* para classificar o frescor de peixes da espécie *Larimichthys crocea*, com acurácias de 76,98% e 77%, respectivamente.

Han, F. *et al.* (HAN, F. *et al.*, 2020) utilizam-se de *e-Nose* e classificadores LDA e ELM, com acurácias de 54,17% e 87,5%, respectivamente, para checar a adulteração da carne bovina. Por fim, Radi *et al.* (RADI *et al.*, 2021) se utilizam de *e-Nose* e RNA para classificar peixes tilápia, com acurácia de 93,88%.

#### 3.1.1.4 Trabalhos Relacionados

Nessa seção são apresentadas sínteses dos trabalhos resultantes do MSL que usam VC como método de avaliação sensorial para avaliação do frescor de peixes. Foram encontrados 8 (oito) estudos incluindo peixes de várias espécies. Não foram encontrados no MSL estudos para análise do frescor de amostras de carne de salmão através de VC.

Dutta *et al.* (DUTTA *et al.*, 2016) propõem um método de processamento de imagem automático, eficiente e não destrutivo para segmentação de tecidos e classificação do frescor da amostra de peixe da espécie *L. rohita*. Os peixes de aquários obtidos no *Institute of Abiotic Stress Management* (NIASM), *Baramati, Pune, Maharashtra*, Índia, foram retirados e colocados em água gelada para morte súbita para evitar o *rigor mortise*. 24 (vinte e quatro) peixes posteriormente foram preservados para o estudo em caixas termocol com dimensão de 28 x 18 x 12 cm<sup>3</sup>. Imagens de guelras, de 601 x 361 pixels, foram capturadas com a câmera digital NIKON D90<sup>10</sup> no primeiro dia e em intervalos de dois dias em até treze dias. O método proposto envolve análise de imagem das brânquias e extração de características com base nos espaços de cores RGB, HSV e dos coeficientes da transformada *wavelet*. Os resultados experimentais indicam um padrão de variação monotônica dos coeficientes no terceiro nível de decomposição e estes coeficientes dão uma indicação da qualidade do peixe e representa comportamento discriminatório guardando relação com o número de dias passados. Um relacionamento entre esses recursos e os níveis de frescor é estabelecido, a partir de dados de treinamento e com base nesta relação um modelo é proposto para identificação de frescor a partir de imagens de peixes. Os autores sugerem que o protocolo sugerido pode ser aplicado para diferentes variedades de peixes.

Em outro estudo, Issac, Dutta e Sarkar (ISSAC; DUTTA; SARKAR, 2017) apresentam SVC para capturar imagens digitais para determinar o frescor das mesmas amostras de peixe da espécie *L. rohita* usadas em (DUTTA *et al.*, 2016) com base na textura das brânquias. Os autores utilizaram o mesmo SVC do referido estudo. Um método para analisar o frescor dos peixes foi desenvolvido e utilizou a cor das brânquias como parâmetro para teste de frescor das

---

<sup>10</sup> [https://www.nikon.pt/pt\\_PT/product/discontinued/digital-cameras/2015/d90](https://www.nikon.pt/pt_PT/product/discontinued/digital-cameras/2015/d90)

amostras. Conforme os dias de amostragem progrediam, as amostras tornaram-se obsoletas e a cor vermelha do sangue nas brânquias começou a desbotar e mudar para uma cor vermelha acastanhada. Um conjunto de dados com 144 (cento e quarenta e quatro) amostras foi analisado. Parâmetros do espaço de cores RGB foram inicialmente extraídos e, em seguida convertidos para HSV, tendo o canal de saturação como parâmetro analisado através de estatística de primeira ordem. O desempenho do método proposto foi relatado em termos de tempo computacional e recursos extraídos da RDI foram segmentados. O tempo total necessário para a análise completa chega a 3,76 segundos por amostra, o que, segundo os autores, é encorajador o suficiente para o desenvolvimento de qualquer aplicação em tempo real. Os autores não apresentaram a métricas de desempenho quanto acurácia ou precisão.

Em recente estudo, Lugatiman *et al.* (LUGATIMAN *et al.*, 2019) apresentaram SVC para classificação do frescor da carne do atum da espécie *YellowFin*. O estudo teve como objetivo desenvolver um aplicativo que usa parâmetros para processamento de imagem digital para avaliar o frescor da carne de atum através da cor. Para construção do SVC, os autores criaram uma caixa tipo estúdio para acoplar uma câmera *Raspberry Pi*<sup>11</sup> de 1080p, responsável por capturar a imagem da amostra da carne de atum e armazená-la via *wireless* em uma nuvem. O estúdio é formado de uma folha de fibra acrílica, com duas lâmpadas fluorescentes para a distribuição de luz adequada. A câmera *Raspberry Pi* é montada na parte superior da caixa. Não há detalhes acerca da temperatura das lâmpadas fluorescentes utilizadas, da distância entre a câmera *Raspberry Pi* e as amostras, nem acerca da cor utilizada no material no qual as amostras são postas para serem fotografadas. O algoritmo de classificação KNN foi treinado com parâmetros do espaço de cores RGB de sessenta amostras de carne de atum, fotografadas a cada 1 a 2 horas, a cada 3 a 4 horas e a cada 5 a 8 horas. Não há detalhes de como as amostras são extraídas do corpo do peixe. As amostras para o treinamento foram classificadas quanto ao frescor em excelente, bom e aceitável, com acurácia de 86,67%. Os autores incentivam o uso de outros classificadores para aumentar a acurácia e destacam o desafio de análise e posterior classificação de imagens oriundas de ambientes não

---

<sup>11</sup> <https://www.raspberrypi.org/>

controlados. Lugatiman *et al.* (LUGATIMAN *et al.*, 2019) citam VC como método rápido, robusto, não destrutivo, flexível e sem contato com a amostra, de inspeção de carne. Segundo os autores, VC diminui o custo da classificação do frescor dos produtos cárneos, quando comparada a classificação feita por humanos.

Em outro estudo, Taheri-Garavand *et al.* (TAHERI-GARAVAND *et al.*, 2019b) propõem um método baseado em RNA para avaliar o frescor da carpa comum (*Cyprinus carpio*) durante o armazenamento em gelo. Um total de 48 (quarenta e oito) carpas comuns foi obtido de uma fazenda de peixes em *Kuhdasht, Lorestan*, Irã, como amostras experimentais. As carpas foram deslocadas ao Laboratório de Engenharia de Biosistemas da Universidade de *Lorestan* em uma caixa de poliestireno contendo gelo. O deslocamento durou 20 min. O SVC de captura de imagens consiste em um sistema de iluminação, uma câmera digital CCD, um computador e *software* para processamento de imagem. Um estúdio foi construído usando madeira branca, a fim de evitar entrada de luz do ambiente circundante. O sistema de iluminação é equipado com 4 lâmpadas halógenas (cada uma de 3W e temperatura de 6500 K), localizadas no canto do estúdio e com giro de 180°. A câmera foi colocada em posição vertical fixa no topo do estúdio, distando 30 cm da superfície da amostra. Depois de capturadas as imagens de 1344 amostras das quarenta e oito carpas durante duas semanas, parâmetros dos espaços de cores RGB, HSI e L\*a\*b\* foram extraídos. Em seguida, a extração de recursos foi realizada para obter seis tipos de recursos de textura de cada canal. Posteriormente, o algoritmo híbrido *Artificial Bee Colony-Artificial Neural Network* (ABC-ANN) (ZHANG, Changsheng; OUYANG; NING, 2010) foi aplicado para selecionar os melhores recursos. Finalmente, os classificadores SVM, KNN e MLP, como os métodos mais comuns, foram usados para classificar imagens de peixes. O desempenho do classificador KNN foi de 90,48%. O desempenho do classificador SVM foi de 91,52%. O modelo de ABC-ANN obteve o melhor desempenho (93,01%). A arquitetura da ABC-ANN consiste em camada de entrada de vinte e dois neurônios com base nos recursos característicos dos espaços de cores, dez neurônios ocultos e quatro classes na camada de saída, incluindo mais fresco, fresco, razoavelmente fresco e estragado.

Em estudo mais recente, Lalabadi, Sadeghi e Mireei (LALABADI; SADEGHI; MIREEI, 2020) propõem SVC para captura de imagem digital para avaliar o frescor (com base na contagem de dias de armazenamento) de trutas da espécie *Oncorhynchus mykiss* através de atributos de cor de seus olhos e guelras. Foi usado um número total de 20 (vinte) trutas da espécie *Oncorhynchus mykiss* com tamanho de 300-400 g, produzidas em período de 6 meses em aquário do tipo cativo localizado em *Cheshmeh Dimeh, Chaharmahal e Bakhtiari, Irã*. As amostras foram imediatamente transferidas em gelo para o laboratório após a colheita. Os dados da imagem dos olhos e das brânquias de trutas armazenadas em gelo há dez dias foram coletados. Um SVC foi construído contendo uma cabine quadrada de 50 x 50 x 50 cm, com espessura de 1 cm. Um furo circular com um diâmetro de 5 cm foi criado no centro do topo do estúdio para posicionamento da câmera, mantendo distância vertical entre esta e as amostras de 24 cm. Uma câmera digital colorida (SONY Cyber-shot DSC-W220<sup>12</sup>) foi usada para coletar as imagens com resolução óptica de 12,1 MP. As imagens capturadas foram transferidas para um laptop através da porta USB de modo *offline*. A captura das imagens de 10 (dez) trutas foi realizada em dias alternados durante um período de dez dias. O banco de dados consiste em quatrocentas imagens coloridas capturadas das guelras direita e esquerda, e olhos de vinte amostras de peixes. Os componentes de cor foram extraídos em RGB, HSV e  $L^*a^*b^*$  e então submetidos a modelos de classificação MLP e SVM. Usando características dos olhos, o MLP obteve acurácia de 82,67%, enquanto o SVM obteve acurácia de 68%. Usando características das guelras, o MLP obteve acurácia de 94,67% e o SVM de 84%.

O estudo de Naimullah, Sthevanie e Ramadhani (NAIMULLAH; STHEVANIE; RAMADHANI, 2020) utilizou 36 (trinta e seis) amostras de atum da espécie *Yellowfin (Thunnus albacares)* adquirido de empresa de pescados e fotografado em laboratório. As amostras de atum foram adquiridas já cortadas, não sendo usado o peixe inteiro. Os autores não mencionam a qual região anatômica do peixe, as amostras pertencem. Um SVC de paredes brancas, de material plástico fosco, e iluminação de LED é construído para adquirir as imagens digitais das amostras, uma câmera digital é posta no topo do estúdio e

---

<sup>12</sup> <https://www.sony.pt/electronics/support/compact-cameras-dscw-series/dsc-w220/specifications>

as amostras são postas em fundo preto para serem fotografadas. Não há explicações acerca da quantidade de luzes de LED, nem tampouco acerca da temperatura usadas. A distância entre a câmera e as amostras é de 30 cm. Também não foram encontradas as especificações da câmera usada na captura, bem como detalhes acerca do tamanho ou formato das imagens geradas. Características de cores das amostras foram extraídas com base nos espaços de cores RGB e HSV. O classificador SVM foi utilizado com acurácia de 81%.

O estudo de Taheri-Garavand *et al.* (TAHERI-GARAVAND *et al.*, 2020) propõe SVC para detecção de frescor de carpas comuns (*Cyprinus carpio*) através aplicação de RNC. Imagens de 48 (quarenta e oito) amostras de carpas comuns foram capturadas pelo mesmo sistema de visão computacional usado em (TAHERI-GARAVAND *et al.*, 2019b). 4 (quatro) classificações de frescor foram utilizadas na camada de saída da RNC. Os resultados obtidos mostraram a acurácia da classificação de 98,21%.

Em estudo mais recente, Rayan *et al.* (RAYAN *et al.*, 2021) capturou amostras de 50 (cinquenta) peixes tilápia do Nilo adquiridas, ao mesmo tempo, em mercado de peixes de Bazar, Dinajpur, Bangladesh. Os peixes foram colocados em caixas de isopor com gelo e transferidos para laboratório do Departamento de Pesca de Hajee Mohammad Danesh, Universidade de Ciência e Tecnologia, Dinajpur, Bangladesh. Um SVC foi construído para a captura das imagens das amostras, contendo uma câmera digital Sony Alpha A6000<sup>13</sup>. Os autores não detalham a iluminação utilizada, nem distância entre a câmera e as amostras. Também não são detalhados se os peixes são fotografados inteiros. Faltam informações acerca da cor do material no qual as amostras são postas para serem fotografadas. Dados são analisados através de uma RNC e uma acurácia de 98% é obtida.

A seção a seguir relata a DSR, através da qual foi construído o SVC para a captura das imagens das amostras de atum e salmão que compõem os conjuntos de dados usados nesta tese.

---

<sup>13</sup> <https://www.sony.com/pt-ao/electronics/camaras-lentes-amoviveis/ilce-6000-body-kit>

### 3.2 DESIGN SCIENCE RESEARCH

Para a construção do SVC para a captura das imagens das amostras de salmão e de atum, que constitui o artefato construído segundo a metodologia DSR, seguiu-se os passos sugeridos por Peffers *et al.* (PEFFERS *et al.*, 2007). Salienta-se que o SVC foi construído, à medida que amostras de atum eram capturadas, uma vez que o conjunto de dados constituído destas amostras foi primeiramente construído. O SVC em sua versão final foi usado, sem qualquer alteração de configuração de forma a validá-lo, para a capturas das amostras de salmão, sendo este conjunto de dados o segundo a ser construído.

Segundo Peffers *et al.* (PEFFERS *et al.*, 2007), a construção do artefato deve possuir seis etapas, que se constituem nos passos sequenciais do método, sendo esta a sequência seguida nesta pesquisa: identificar o problema e sua motivação, definir os objetivos de uma solução, projetar e desenvolver artefatos, demonstrar o uso do artefato, através de sua experimentação prática, avaliar e comunicar a solução, se atingido o final do processo. A explanação da construção do SVC segundo os passos citados é explanada no Quadro 4..

A metodologia de experimentação usada para a construção dos modelos de AM é mostrada na seção a seguir.

### 3.3 EXPERIMENTAÇÃO

Nesta seção é descrita a metodologia utilizada para realizar a comparação da eficiência em relação à acurácia de treinamento dos diversos modelos testados para escolha dos mais eficientes para classificação do frescor da carne de peixes segundo padrões colorimétricos das amostras de carne de atum e de salmão, analisados através de suas imagens digitais. Salienta-se que os modelos também foram construídos à medida que o conjunto de dados de amostras de carne de atum foi sendo construído, sendo seus resultados finais apresentados por ocasião do término da captura.

Neste estudo utilizou-se a amostragem probabilística do tipo estratificada proporcional (GIL, 2008) para definição do tamanho dos conjuntos de dado de amostras de atum e de salmão que fosse representativo da população de peixes recepcionados por ano na indústria de pescados e no restaurante de culinária japonesa, parceiros desta pesquisa.

O estudo considerou a população da pesquisa superior a 100.000 peixes por ano na indústria de pescados, portanto observa-se, em termos estatísticos, uma população infinita. A indústria de pescados é de pequeno porte, atuando como fornecedora de peixes, predominantemente, na cidade de Recife. Esta recepciona, em média 120.000 peixes de várias espécies por ano, destes 2% de atuns, considerando este percentual a totalidade de atuns das espécies *Bigeye* (*Thunnus obesus*) e *Yellowfin* (*Thunnus albacares*). Salienta-se que estes dados foram fornecidos pela própria indústria. O restaurante de culinária japonesa recepciona, em média, 1200 (mil e duzentos) peixes por mês, perfazendo um total médio de 14.100 (quatorze mil e cem) peixes por ano. Salienta-se que estes dados foram fornecidos pelo próprio restaurante. Como, em um ano, a população de salmões do restaurante de culinária japonesa é muito menor que a população de atuns da indústria de pescados, optou-se por usar apenas esta última para fins de cálculo do tamanho mínimo de ambos os conjuntos de dados.

Desta forma, adotou-se fórmula definida pela Equação 57 para o cálculo de amostras para populações infinitas (excede a 100.000 elementos) considerada na teoria da amostragem (GIL, 2008):

$$n = \frac{\sigma^2 \cdot p \cdot q}{e^2} \quad (\text{Eq. 57})$$

onde:  $n$  = tamanho do conjunto de dados;  $\sigma^2$  = nível de confiança escolhido, expresso em número de desvios-padrão;  $p$  = percentual no qual o fenômeno se verifica;  $q$  = percentual complementar ( $100 - p$ ); e  $e^2$  = erro máximo permitido.

Como 2% da totalidade dos peixes recepcionados na indústria de pescados é de atuns,  $q$  é igual a  $100 - 2$ , ou seja, 98. Em seguida, adotou-se um nível de confiança de 99,7% (corresponde a três desvios-padrão) e um erro máximo de 5%. Aplicando-se a fórmula definida pela Equação 57, encontrou-se o seguinte resultado:

$$n = \frac{3^2 \times 2 \times 98}{5^2} = \frac{1.764}{25} = 70,56$$

Logo, para atender às exigências estabelecidas pelo estudo, o número de amostras nos conjuntos de dados deve ser superior a 71 (setenta e um).

O conjunto de dados de amostras de atum, contém 95 (noventa e cinco) amostras, enquanto o conjunto de dados de salmão contém 105 (cento e cinco) amostras.

Os conjuntos de dados são então entregues a modelos de AM. Um modelo é composto de primitivas de pré-processamento para dimensionar os dados, primitivas de pré-processamento de características (que incluem escolha ou extração de características”), primitivas de balanceamento de classes e classificadores de AM, tendo conjuntos de dados de parâmetros colorimétricos extraídos das imagens digitais das amostras para classificação do frescor. Para fins de comparação da eficiência dos modelos, utilizou-se 18 (dezoito) classificadores individuais, 18 (dezoito) modelos ensembles homogêneos compostos por variações de hiper parâmetros dos 18 (dezoito) classificadores individuais, e um ensemble heterogêneo composto por classificadores distintos, mantendo-os com os hiper parâmetros dos classificadores componentes em seus respectivos valores *default* definidos pela biblioteca *scikit-learn*.

Para a escolha dos 18 (dezoito) classificadores usados na experimentação, utilizou-se os classificadores usados pelo *framework Auto-Sklearn* (AdaBoost, BNB, DT, ExtraTrees, GNB, GB, KNN, LDA, SVM, MLP, PA, QDA, RF e SGD), acrescidos dos classificadores RC, LR, ELM e NC, incluídos por serem muito utilizados nas mais diversas tarefas de classificação.

Manteve-se invariáveis as primitivas de pré-processamento para dimensionar os dados e as primitivas de balanceamento de classes e variou-se as primitivas de pré-processamento de características e os classificadores. Ressalta-se que no desenho metodológico levou-se em conta a acurácia de treinamento, para fins de comparação das significâncias estatísticas dos modelos.

Um dos elementos principais da experimentação são as variáveis, sendo elas dependentes e independentes. As variáveis independentes referem-se à entrada da experimentação. Essas variáveis também são chamadas de “fatores”, seus valores são chamados de “tratamentos” e apresentam a causa que afeta o resultado da experimentação (JURISTO; MORENO, 2013). Neste estudo, os fatores são as “primitivas de pré-processamento de características” e os “classificadores”. A variável dependente refere-se à saída da experimentação. Essa variável apresenta o efeito que é causado pelos fatores. Neste estudo, a variável dependente é o desempenho geral do modelo ou sua acurácia.

### 3.3.1 Objetivo da Experimentação

O objetivo da experimentação é avaliar o impacto da utilização de diferentes classificadores quando submetidos a primitivas de pré-processamento para escolha ou extração de características, na eficiência, medida em relação à acurácia de treinamento (CARVALHO; PEREIRA; CARDOSO, 2019), de um modelo para classificar o frescor da carne de peixes através de parâmetros colorimétricos. Salienta-se que houve a inclusão, entre as opções de primitivas de pré-processamento de característica, da ausência de escolha ou de extração de características, de modo que pode haver modelos que tem melhor desempenho usando todas as características disponíveis no conjunto de dados.

São realizadas comparações, em relação à acurácia de treinamento, entre os modelos de classificação utilizando 18 (dezoito) classificadores individuais, 18 (dezoito) classificadores ensemble homogêneos, além de um ensemble heterogêneo, totalizando 37 (trinta e sete) modelos de classificação. Os modelos são testados com uma primitiva de pré-processamento para escolha de características, com quatro primitivas para extração de características e com a ausência de ambas. Ressalta-se que a aplicação de primitivas de escolha de características e primitiva de extração de características são excludentes.

A experimentação visa responder a seguinte pergunta:

*Qual(is) o(s) modelo(s) apresenta(m) desempenho estatisticamente mais significativo(s), de modo a ser(em) elencado(s) como o(s) modelo(s) adequados para a classificação do frescor da carne de peixes feita a partir de características de cores extraídas de imagens digitais de suas amostras?*

A fim de criar uma base sólida acerca da definição da experimentação e seguindo a abordagem comumente recomendada por Juristo e Moreno (2013), definimos os objetivos da experimentação segundo a abordagem *Goal, Question, Metric* (GQM) (KOZIOLEK, 2008):

- **Analisar se** existe alguma diferença de desempenho dos modelos quando utilizam diferentes primitivas de pré-processamento de características e diferentes classificadores;
- **Como o propósito de** verificar qual o modelo é mais eficiente para a classificação do frescor da carne de peixes analisada através de imagens digitais de suas amostras;

- **Em relação** ao valor da acurácia de treinamento do modelo;
- **Do ponto de vista** dos pesquisadores e da comunidade acadêmica;
- **No contexto da** segurança alimentar.

O planejamento do experimento é explanado na próxima seção.

### 3.3.2 Planejamento

Nesta seção serão apresentados hipótese nula ( $H_0$ ), tratamento, unidade experimental (UE), variável de resposta, variáveis de bloqueio e projeto experimental, que constam do planejamento da experimentação, segundo Juristo e Moreno (2013).

#### a) Hipótese nula

Para a definição da  $H_0$ , considera-se o fato de não haver diferenças estatística significativas nas acurácias de treinamento dos 37 (trinta e sete) modelos. Em outras palavras, os 37 (trinta e sete) modelos possuem hipoteticamente o mesmo desempenho.

#### b) Tratamento

Os tratamentos desta experimentação para modelos consistem em variações nos fatores “primitivas de pré-processamento de características” e “classificadores”.

- Variações do fator “primitivas de pré-processamento de características”:
  - Sem aplicação de primitivas (sem tratamento);
  - *VarianceThreshold*;
  - PCA;
  - LDA
  - LLE;
  - *Autoencoder*;
- Variações do fator “classificador”:
  - RC;
  - KNN;
  - LDA;
  - QDA;
  - PA;

- DT;
- RF;
- ExtraTrees;
- AdaBoost;
- GB;
- SGD;
- SVM;
- LR;
- BNB;
- GNB;
- NC;
- MLP;
- ELM;
- Combinações do RC;
- Combinações do KNN;
- Combinações do LDA;
- Combinações do QDA;
- Combinações do PA;
- Combinações do DT;
- Combinações do RF;
- Combinações do ExtraTrees;
- Combinações do AdaBoost;
- Combinações do GB;
- Combinações do SGD;
- Combinações do SVM;
- Combinações do LR;
- Combinações do BNB;
- Combinações do GNB;
- Combinações do NC;
- Combinações do MLP;
- Combinações do ELM;
- Combinações dos classificadores distintos;

c) Unidade Experimental

As UEs são as 30 (trinta) combinações de bases de treinamento e bases de teste, resultantes da divisão randômica dos conjuntos de dados, com as quais os classificadores serão treinados e farão previsões, gerando 37 (trinta e sete) modelos distintos.

d) Variável de Resposta

A variável de resposta consiste nas acurácias de treinamento dos modelos.

e) Variáveis de Bloqueio

Duas variáveis podem afetar a variável resposta: “primitivas de pré-processamento para dimensionar os dados” e “primitivas de balanceamento de classes”, sendo mantidas fixas durante toda a experimentação.

f) Projeto Experimental

O delineamento experimental mais adequado para modelos é o *Design Fatorial* (JURISTO; MORENO, 2013).

### 3.3.3 Preparação da Experimentação

Considerou-se um experimento como sendo o processo de calcular as acurácias de treinamento e de teste de um modelo. Um experimento consiste no uso de um modelo de classificação em 30 (trinta) repetições. As repetições se diferenciam umas das outras, por divisões randômicas feitas nos conjuntos de dados, gerando bases de treinamento e teste. As bases de treinamento constam de 80% dos dados, ficando 20% dos dados para as bases de teste. Para cada modelo, usando as bases de treinamento, foram buscadas as primitivas de pré-processamento de características e otimizados hiper parâmetros dos classificadores conforme descrito no Quadro 5. Durante a otimização dos hiper parâmetros é utilizada a validação cruzada (RODRIGUEZ; PEREZ; LOZANO, 2009) com 10 (dez) *folds*, sendo um *fold* utilizado para validação.

Obteve-se 30 (trinta) acurácias, de cada repetição, nas bases de treinamento (chamadas de “acurácias de treinamento”), também através de validação cruzadas com 10 (dez) *folds* e calculou-se sua média aritmética simples, ao final de 30 (trinta) repetições. O mesmo foi feito para as acurácias nas bases de teste (chamadas de “acurácias de teste”).

Em resumo, um experimento consistiu de 30 (trinta) repetições, com diferentes bases de treinamento e teste, e uma combinação de uma primitiva de pré-processamento de características (ou ausência desta) e de um classificador otimizado através de dados de validação, para o cálculo de suas acurácias de treinamento e de teste, através de validação cruzada com 10 (dez) *folds*.

Para checar se há diferenças estatísticas significativas entre os modelos foram utilizados os testes estatísticos de Friedman e Nemenyi (DEMŠAR, 2006). O teste de Friedman permite que se possa estudar mais de três populações, que representam medidas em uma mesma unidade amostral e verificar se há diferença entre essas medidas. O teste de Friedman não utiliza os dados numéricos das acurácias diretamente, mas sim os *rankings* ocupados por elas após a ordenação feita para cada grupo separadamente. Desta feita, foi feito o ranqueamento, a cada repetição, das acurácias de treinamento resultantes de todos os modelos, gerando trinta populações de *rankings*. Acurácias de treinamento repetidas foram ranqueadas de forma dividida. A  $H_0$  supõe que todos os modelos são equivalentes em desempenho (DEMŠAR, 2006).

Para determinar se alguma das diferenças entre as medianas é estatisticamente significativa, comparou-se o nível de significância (*p-value*) de cada população com o nível de significância *p-value* = 0,05, a fim de avaliar a  $H_0$ . Em seguida utilizou-se o teste de Nemenyi, que é um teste *post-hoc*, para a verificação de diferenças par-a-par (comparações múltiplas), concluindo os modelos mais significativamente eficientes (DEMŠAR, 2006).

### 3.4 SÍNTESE DO CAPÍTULO

Neste capítulo foram apresentados os arcabouços metodológicos para revisão da literatura, construção do SVC e construção dos modelos de AM para classificação do frescor da carne de peixes com base em parâmetros colorimétricos.

A revisão da literatura foi feita em dois momentos: *ad hoc* e MSL. O MSL resultou em 38 (trinta e oito) estudos sobre análise sensorial de carne de boi, carne de frango, carne de porco e carne de peixes. Os estudos usam VC, e-Nose, imagens ultrassônicas, imagens espectrais e NIR. 23 (vinte e três) estudos que adotam VC como método para análise do frescor de produtos cárneos,

relatam o *hardware* e os *softwares* utilizados em ambientes controlados para captura das imagens das amostras em laboratórios, apesar de não haver informações suficientes para que os mesmos *hardwares* de SVC possam ser reconstruídos, e não haver informações suficientes para reprodutibilidade do protocolo de captura de imagens das amostras.

Dos estudos resultantes do MSL, apenas 5 (cinco) se debruçam sobre a classificação do atum. Já quanto ao salmão apenas 2 (dois) estudos resultaram do MSL. Dos 18 (dezoito) artigos sobre peixes, apenas 8 (oito) são baseados em VC, sendo 2 (dois) sobre o frescor da carne do atum e nenhum sobre o frescor da carne do salmão. Os estudos relatam VC como método de inspeção de amostras de carne rápido, robusto, não destrutivo, flexível e sem contato com a amostra.

Em seguida o capítulo relatou a metodologia DSR usada para a construção do SVC, através dos passos de Peffers *et al.* (PEFFERS *et al.*, 2007).

Por fim, foi explanada a metodologia de experimentação através da qual puderam ser checadas as diferenças estatísticas nos desempenhos de 37 (trinta e sete) modelos de classificação de frescor de carne de peixe, segundo testes estatísticos de Friedman e Nemenyi (DEMŠAR, 2006). A forma como os tamanhos dos conjuntos de dados de amostras de atum e de salmão foram calculados foi mostrada.

O Capítulo 4 analisa os passos para a construção de uma solução automatizada para a classificação de peixe com base em parâmetros colorimétricos.

#### **4 ETAPAS PARA CONSTRUÇÃO DE UMA SOLUÇÃO AUTOMATIZADA DE CLASSIFICAÇÃO DO FRESCOR DA CARNE DE PEIXES COM BASE EM CARACTERÍSTICAS DE CORES**

Os passos para o desenvolvimento da solução automatizada que analisa o frescor da carne de peixes com base em análise sensorial foram construídos com base em VC e análise de parâmetros colorimétricos extraídos de amostras de carne de peixes de atum e de salmão.

Este capítulo analisa cada etapa que compõe a solução FreshnessScope. A Seção 4.1 apresenta a etapa de preparação das amostras, a Seção 4.2 apresenta a etapa que constrói o SVC utilizado para a captura das imagens digitais das amostras, a Seção 4.3 apresenta a etapa de pré-processamento das imagens digitais capturadas, a Seção 4.4 apresenta a etapa de extração das características extraídas das imagens com base nos espaços de cores RGB, HSV, HSI e  $L^*a^*b^*$ . Por fim, a Seção 4.5 apresenta a etapa do uso de modelos de AM, usando as características de cores, para classificar o frescor de amostras de carne de peixes. As etapas foram construídas à medida que as amostras de atum foram sendo coletas. Com todas as etapas da solução criadas, após a conclusão das análises no conjunto de dados de amostras de carne de atum, a solução FreshnessScope foi aplicada no conjunto de dados de amostras de carne de salmão. Sem perda de entendimento, as explicações das etapas da solução são apresentadas simultaneamente nos dois conjuntos de dados.

##### **4.1 ETAPA 1: PREPARAÇÃO DAS AMOSTRAS**

Entende-se que a fase de preparação das amostras constitui-se o primeiro passo para a construção da solução para automatizar a classificação do frescor da carne de peixes. Esta fase define um protocolo de preparação das amostras de peixes e se não seguido afeta a qualidade dos resultados aferidos pela solução.

Amostras da carne de atum da espécie *Bigeye*, pescados na cidade de Natal, no estado do Rio Grande do Norte, no Brasil, extraídas com sashibo, instrumento amplamente utilizado por especialistas, foram obtidas em uma indústria de pescados em Recife, Estado de Pernambuco, Brasil, como amostras experimentais. A amostra da carne do atum foi puncionada com sashibo a partir

do dorso do peixe, abaixo da nadadeira lateral, da parte caudal para a lombar, como mostra a Figura 13, tendo o cuidado de não transpor o outro lado do peixe.

Figura 13 - Especialista extraíndo amostra da carne do atum, recém pescado e retirado de caminhões frigoríficos, através de sashibo



Fonte: A Autora (2021)

Entende-se que amostras extraídas com sashibo tornam o processo de classificação, automatizado pela solução, fiel ao processo manual de classificação realizado por especialistas, em indústrias pesqueiras.

A imagem do sashibo utilizado na captura das amostras de atum é mostrada na Figura 14. O sashibo contém 50 cm de comprimento e  $\frac{1}{4}$  de polegada de diâmetro do tubo.

Figura 14 - Sashibo, instrumento cortante para puncionar o dorso do atum



Fonte: A Autora (2021)


Amostras de atum da espécie *Bigeye* foram escolhidas para compor o conjunto de dados, por serem a grande maioria das amostras disponíveis na indústria de pescado parceira. Também foram disponibilizados atuns da espécie *Yellowfin*, porém com número de amostras insuficientes para automatizar o processo de classificação desta espécie, acabaram por serem desprezadas. Acompanhou-se a extração de amostras de atuns congelados a 2°C negativos, saídos caminhões frigoríficos carregados de atuns pescados por grandes barcos atracados há um dia no litoral da cidade de Natal, Estado do Rio Grande do Norte, Brasil. Um baú de um caminhão frigorífico é mostrado na Figura 13. O nível de frescor da carne dos peixes pode variar, uma vez que os barcos podem passar até 30 dias em alto mar, podendo os peixes terem sido pescados entre o primeiro e o último dia da atividade pesqueira, além de poderem ter níveis de estresse diferentes entre a captura e o abate.

Para a classificação dos níveis de frescor, o especialista usou as amostras da carne para análise sensorial de cor e de transparência, bem como de textura e de odor. Como adotou-se um protocolo de modo a padronizar a captura das imagens, o especialista já retirou as amostras do sashibo diretamente em cartões brancos, feitos de papel ofício, com formato quadrado e dimensões 23 x 23 cm. Salienta-se usar cartões brancos, caso as amostras não tenham cor predominantemente branca, caso contrário, sugere-se usar cartões verdes. Os cartões usados para a retirada das amostras serão chamados, nesta tese, de “cartões de captura”.

A Figura 15 ilustra amostras de atum retiradas do sashibo e colocadas em cartões de captura para serem fotografadas. Os cartões de captura favoreceram a captura das imagens das amostras, pois evitaram sua manipulação, já que as amostras se quebravam com facilidade. Cada cartão de papel branco continha apenas uma amostra e foi colocado individualmente em um estúdio para ser fotografado.

O tempo total entre a extração da amostra do corpo do peixe e a captura da imagem levou, em média, 3 minutos, tempo médio de deterioração das amostras. As amostras foram descartadas, após a sessão de captura. A captura das amostras que compõem o conjunto de dados foi realizada entre os meses de dezembro de 2020 e maio de 2021.


Figura 15 - Amostras de carne de atum retiradas do sashibo diretamente em cartões de captura, feitos de papel, com formato quadrado e dimensões 23 x 23 cm, para serem levados ao SVC para serem fotografadas



Fonte: A Autora (2021)

Quanto mais intensa a coloração da carne quanto ao “vermelho”, maior é o nível do frescor de amostras de atum. 5 (cinco) níveis de frescor podem ser utilizados pelo especialista, sendo as amostras rotuladas como: 1, 2+, 2, 2- e 3, sendo o rótulo 1 o nível de maior frescor. Salienta-se que nesta pesquisa, o conjunto de dados não contou com amostras de nível 1 de frescor, sendo estas amostras raras, segundo o especialista. Desta feita, utilizou-se, para a classificação do frescor de amostras de atum, uma escala discreta com 4 (quatro) classes. A Figura 16 mostra uma amostra de cada classe utilizada pelo especialista.

Figura 16 - Amostras de atum representantes das classes (a) 2+, (b) 2, (c) 2- e (d) 3



Fonte: A Autora (2021)


Ao contrário do atum, cujas imagens foram capturadas em indústria de pescados (início da cadeia pesqueira), as amostras de salmão foram fotografadas em restaurante (fim da cadeia pesqueira) especializado em culinária japonesa, localizado na cidade de Caruaru, Estado de Pernambuco, Brasil. Os salmões foram comprados de empresa de pescados em Recife, sendo transportados para Caruaru congelados em caixas de isopor. Os salmões são originários de cativeiros no Chile, sendo pescados no Oceano Pacífico.

O nível de frescor da carne do salmão foi definido ainda com o peixe inteiro, por especialista, através de análise sensorial da textura, coloração e elasticidade da carne e odor da cavidade abdominal, além de presença de sangue vivo nas guelras.

Os níveis de frescor de salmão utilizados pelo especialista foram: “muito fresco”, “fresco” e “consumo imediato”, deste modo utilizou-se para a classificação do salmão, a escala discreta com 3 (três) classes. A Figura 17 mostra uma amostra de cada classe utilizada pelo especialista. Houve amostras dos três níveis de frescor para compor o conjunto de dados.

Assim como com as amostras de atum, também foram usados os mesmos cartões de captura para colocar as amostras de salmão a serem fotografadas. Salienta-se que para cada peixe, há escalas específicas e, como os classificadores são multiclases, a solução é adaptável a este fato.

Figura 17 - Amostras de salmão representantes das classes (a) “muito fresco”, (b) “fresco” e (c) “consumo imediato”



Fonte: A Autora (2021)

A Figura 18 mostra os salmões congelados chegando ao restaurante em caixa de isopor, sendo analisados sensorialmente por especialista, bem como

cortados em pedaços após serem classificados. As amostras de salmão foram capturadas com maior área de observação, quando comparadas com as amostras de atum, pelo fato de a captura das imagens ter sido feita em restaurante, fim da cadeia pesqueira, o que permitiu a destruição do peixe. A recepção do peixe foi acompanhada, bem como a classificação de seu nível de frescor por um especialista, bem como pela Autora. Pedacos de carne de salmão foram cortados (um por peixe) e disponibilizados para ser fotografados, com dimensões médias de 2,5 cm de largura e de 4 cm de comprimento e de 0,5 cm de espessura.

Figura 18 - Salmões congelados em caixa de isopor, sendo inspecionados sensorialmente por especialista e cortados em pedaços para serem servidos ou para serem congelados



Fonte: A Autora (2021)

As estratégias de preparação das amostras e de número de níveis de frescor são dependentes do contexto do peixe que está sendo estudado. Para classificação de amostras de peixes em níveis de frescor, deve-se treinar os modelos, respeitando os níveis usados pelos especialistas em cada contexto, como foi feito nesta pesquisa para amostras de atum e de salmão. Entende-se que deste modo, o FreshnessScope é fiel ao ambiente real de classificação.


Salienta-se que a captura das amostras de salmão foi mais fácil de ser realizada que a captura das amostras de atum, uma vez que os peixes estavam disponíveis e não havia necessidade de aguardar pedidos de compras para classifica-los, evitando longas horas de espera, como houve com os atuns. Ressalta-se também que o protocolo de preparação das amostras já existia e

não se fez necessária a realização de testes para encontrar a melhor configuração, bastando usar o mesmo protocolo de preparação das amostras utilizado para amostras de atum.

A Figura 19 mostra a diferença na área de observação para extração de características de cores em amostras de atum (Figura 19.a) e em amostras de salmão (Figura 19.b). As amostras não têm forma definida, e não há orientação espacial.

A captura das imagens foi feita em estúdio fotográfico, detalhado na próxima seção, na própria indústria de pescados, bem como no restaurante de culinária japonesa.

Figura 19 - (a) Amostra de atum e (b) amostra de salmão extraídas do corpo dos peixes para serem fotografadas



Fonte: A Autora (2021)

Para atender às exigências estabelecidas pelo estudo, aplicando-se a fórmula definida pela Equação 57 e definida por (GIL, 2008), o número de amostras nos conjuntos de dados deve ser superior a 71 (setenta e um), como citado no Capítulo 3.

O conjunto de dados de amostras de atum, contém 95 (noventa e cinco) amostras, enquanto o conjunto de dados de salmão contém 105 (cento e cinco) amostras. Ressalta-se que cada amostra pertence a um peixe distinto e que só foram utilizadas uma fotografia de cada amostra.

A seção a seguir explana a construção do SVC utilizado para a captura das amostras de atum e de salmão que constituem os conjuntos de dados usados na solução.

#### 4.2 ETAPA 2: SISTEMA DE VISÃO COMPUTACIONAL

A captura das amostras de atum foi iniciada sem a padronização da cor do material no qual as amostras seriam postas para serem fotografadas (fundo das imagens), da iluminação, bem como da distância e do ângulo entre a câmera e as amostras. A opção pela falta de padronização no início da fase de captura se deu pela falta de informações da melhor configuração para captura de imagens das amostras nos trabalhos relacionados, de modo a viabilizar a definição da RDI de forma automática, tendo o entendimento que várias configurações de captura seriam avaliadas e testadas, segundo os passos da DSR. Imagens das amostras, fotografadas sem padronização sobre papeis brancos postos na bancada da área de descarga da indústria de pescados e sobre o corpo do peixe, podem ser vistas na Figura 20.


Figura 20 - Imagens de amostras de carne de atum extraídas com sashibo e fotografadas sobre a bancada sobre fundo branco e sobre o corpo do peixe, sem uso de padronização de captura



Fonte: A Autora (2021)

Para a captura foi usada a câmera de um *smartphone iPhone XR* configurada sem *zoom*, sem *flash*, abertura *f/1,8*, estabilização ótica, iluminação natural e foco sensível ao toque. Porém, dificuldades em pré-processar as imagens para a definição da RDI de forma automática foram enfrentadas. Para que se pudesse mitigar as dificuldades, decidiu-se pela iluminação do ambiente de captura.

Figura 21 - Desenho do estúdio fotográfico usado no SVC (a) montado e (b) desmontado



Fonte: A Autora (2021)

Optou-se por nova configuração, usando um SVC para captura de imagens que consiste em um estúdio, que deve ter as paredes laterais, a base e o topo contendo encaixes, devendo ser de fácil montagem e desmontagem. A Figura 21.a mostra o estúdio montado, contendo a base falsa utilizada, enquanto a Figura 21.b mostra o estúdio desmontado. Salienta-se a importância da característica portabilidade do estúdio, uma vez que a duração das sessões de captura pode durar dias, semanas ou meses e a instalação em áreas de produção pode não ser permitida por empresas parceiras. Ressalta-se também a fácil mobilidade do estúdio, uma vez que não depende de tomadas elétricas, é leve, de pequenas dimensões.

O estúdio, mostrado na Figura 22, é feito de paredes brancas, de material plástico fosco, de espessura fina, e abertura frontal, e mitiga a entrada de luzes do ambiente circundante, uma vez que possui paredes laterais e dimensões de 23 cm de altura, 23 cm de largura e 23 cm de profundidade.

Contém 36 luzes de LED brancas, inseridas em fita de lâmpadas LED, modelo de 2835, e posicionadas de forma circular na parte superior. O brilho das lâmpadas de LED pode variar de 24 lm a 26 lm. As luzes de LED brancas podem ter temperaturas variando entre 3200K e 6500K. A potência varia de 5W a 11W. O estúdio pode ser construído com baixíssimo custo e a quantidade de uso está relacionada a durabilidade das lâmpadas de LED. Segundo Uddin, Shareef e Mohamed (UDDIN; SHAREEF; MOHAMED, 2013), uma lâmpada de LED é fabricada para durar, em média, 30 mil horas de uso.

Figura 22 - Configuração adotada do SVC para captura de imagens de amostras de atum e salmão, constando de estúdio fotográfico com luzes de LED circulares e abertura no topo



Fonte: A Autora (2021)

O estúdio possui abertura no topo, com diâmetro de 10 cm, para posicionamento de câmera fotográfica posicionada em frente às amostras. Em todo o processo de captura utilizou-se um carregador *powerbank* de 10.000 mAh, uma vez que o estúdio possui cabo USB para ligação na fonte de alimentação medindo 2 m, o que facilitou a instalação do estúdio dentro da área de descarga da indústria de pescados, bem como na área de recepção de peixes do restaurante de culinária japonesa, locais em que não se dispunha de tomadas de energia elétrica. Como se vê na Figura 22, uma base falsa de 6 cm foi utilizada, com objetivo de diminuir a distância entre a câmera e as amostras.

Ressalta-se que várias configurações do estúdio foram utilizadas, de modo a ter-se a configuração que permitisse a automatização da definição da RDI. Lista-se a seguir, as variações de configurações do estúdio que foram feitas. As configurações testadas estão resumidas no Quadro 4, segundo os passos da DSR.

- Optou-se a câmera do *smartphone iPhone XR* configurada sem *zoom*, sem *flash*, abertura f/1,8, estabilização ótica, iluminação natural e foco sensível ao toque. Optou-se por fazer a captura sem *flash* para que não houvesse mudança na cor da amostra em função de outra iluminação, além das lâmpadas de LED do estúdio. A câmera foi colocada na abertura localizada no topo, apoiada no próprio estúdio, sem a necessidade de uso de tripé, com distância entre esta e as amostras de 23 cm, altura padrão do estúdio. As amostras foram retiradas inicialmente do sashibo e postas em folha de isopor branco, para serem facilmente transportadas para fora

da área de descarga, diminuindo a interferência do processo de captura da pesquisa na rotina de classificação da empresa e do especialista. A Figura 23 mostra folha de isopor utilizada, com áreas demarcadas contendo as possíveis classificações e espécies. As amostras foram manuseadas e postas em cartões brancos, feitos de papel, com formato quadrado e dimensões 23x23 cm, para serem levados ao SVC. As amostras quebraram no manuseio e, por este motivo, configuração foi abortada;

- Optou-se, então, por usar os mesmos cartões brancos, presos à folha de isopor, de modo que as amostras de carne pudessem ser retiradas do sashibo diretamente sobre eles, como mostra a Figura 15. A folha de isopor, contendo os cartões de captura, cada um com apenas uma amostra de carne, foi levada para fora da área de descarga da indústria de pescados. Os cartões brancos foram destacados da folha de isopor e levados ao estúdio para serem fotografados. Usou-se a distância de 23 cm, pelo fato de ser a altura padrão do estúdio, entre as amostras e câmera fotográfica. As amostras foram fotografadas com uma temperatura de iluminação de 6500K, por ser a temperatura mais fria disponível para ser usada na fita de lâmpadas de LED. Apesar de se apresentarem com boa resolução para definição da RDI, as amostras apresentaram-se pequenas nas imagens e, por este motivo, configuração foi abortada;
- Optou-se por colocar uma base falsa, feita de caixa de papelão, sobre a base original do estúdio, com o objetivo de aproximar a câmera e as amostras. A distância foi diminuída para 17 cm sendo considerada melhor, uma vez que as amostras se apresentaram maiores nas imagens. As amostras foram fotografadas com uma temperatura de iluminação de 6500K, por ser a temperatura mais fria disponível para ser usada na fita de lâmpadas de LED;
- Testou-se capturar as amostras em fundo branco e fundo preto, como primeira tentativa de checar se outras cores de fundo trariam melhores resultados, mantendo-se a distância entre a câmera e as amostras em 17 cm, sendo o fundo branco considerado ideal, uma vez que o preto refletiu muito a iluminação, como mostra a Figura 24. As amostras foram

fotografadas com uma temperatura de iluminação de 6500K, por ser a temperatura mais fria disponível para ser usada na fita de lâmpadas de LED;

- Optou-se por utilizar iluminação branca com várias intensidades, já que o estúdio permite variar a temperatura entre 3200K e 6500K, mantendo-se a distância entre a câmera e as amostras em 17 cm. A iluminação branca e temperatura 6500K foi considerada a melhor, uma vez que as imagens se apresentaram mais claras quando comparadas com temperaturas mais quentes. Justifica-se a decisão de iluminação branca, já que a iluminação amarela mudou a cor original das amostras.
- Testou-se a configuração de fotografar as imagens com iluminação de LED com temperatura 6500K, mesma temperatura usada na iluminação de LED do topo, também por trás da amostra, abaixo de uma base falsa, feita de caixa de papelão, contendo um vidro na parte de cima, como mostra Figura 25. Apesar de visualmente se perceber a transparência das amostras, característica utilizada pelo especialista para classificar o nível de frescor, houve dificuldade de definir a RDI de forma automática e essa configuração foi abortada.


A configuração que melhor permitiu a definição da RDI e, por conseguinte, a extração das características de cores das imagens de forma automática, foi usando o estúdio e temperatura fria de 6500K. As amostras foram colocadas individualmente em cartões de captura feitos de papel, com formato quadrado e dimensões 23 x 23 cm, para serem levados ao SVC, o que permitiu não serem manuseadas.

No estúdio foi usada uma base falsa, feita de caixa de papelão, de modo a diminuir a distância do topo do estúdio, local onde é posta a câmera fotográfica, para 17 cm. A câmera de um *smartphone iPhone XR* foi posicionada no topo da abertura do estúdio, apoiada no próprio estúdio, sem a necessidade de uso de tripé, a uma altura de 17 cm da amostra e configurada sem *zoom*, sem *flash*, abertura *f/1,8*, estabilização ótica, iluminação natural e foco sensível ao toque. As imagens são capturadas com resolução de 12 MP. Após a captura, as imagens foram armazenadas no rolo da câmera do *smartphone*, em formato HEIC (proprietário da Apple) como matrizes com dimensões 4608 x 2592 *pixels*,

para serem descarregadas manualmente em computador e convertidas para JPEG para posterior pré-processamento *offline*.

Os dois conjuntos de dados foram inteiramente construídos em ambiente controlado, assim como aconteceu em 100% dos trabalhos relacionados. A utilização de um ambiente controlado constitui a primeira fase desta pesquisa, o que possibilitou o conhecimento mais rápido acerca de que informações de cores podem ser extraídas das amostras.

Figura 23 - Imagens de amostras de carne de atum extraídas com sashibo e postas em folha de isopor branco com áreas de classificação demarcadas, para serem retiradas da área de descarga da indústria de pescados e então fotografadas



Fonte: A Autora (2021)

Figura 24 - Imagem de amostra de carne de atum extraída com sashibo e fotografadas no estúdio sobre fundo preto



Fonte: A Autora (2021)


Figura 25 - Configuração alternativa de iluminação por trás das amostras de atum



Fonte: A Autora (2021)

A Figura 26 mostra as amostras de atum e de salmão, posicionadas sobre a base falsa e sobre cartão de captura, para serem fotografadas no estúdio.

Figura 26 – Amostra (a) de atum e (b) de salmão colocadas sob fundo branco para serem fotografadas



Fonte: A Autora (2021)

Porém diferentemente dos SVC dos trabalhos relacionados, o SVC proposto nesta tese é de fácil mobilidade, podendo ser instalado diretamente em indústrias parceiras. O Quadro 4 mostra um sumário dos passos para a construção do SVC para a captura das imagens das amostras de atum e salmão, segundo a metodologia DSR (WIERINGA, 2014) e seguindo os passos definidos por Peffers *et al.* (PEFFERS *et al.*, 2007).

Quadro 4 - Construção do SVC segundo a metodologia DSR

| Etapas da DSR                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   | Descrições das Ações |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------|
| <b>Identificar o problema e sua motivação</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |                      |
| <b>Problema:</b> Criar um SVC adaptável e simples para capturar imagens digitais de amostras da carne de peixes para integrar a uma solução de classificação do seu frescor;                                                                                                                                                                                                                                                                                                                                                                    |                      |
| <b>Motivação:</b> Dificuldade de escalar o processo de classificação feita por especialistas e escassez de soluções para classificação do frescor da carne de peixes na literatura.                                                                                                                                                                                                                                                                                                                                                             |                      |
| <b>Definir os objetivos para uma solução</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    |                      |
| <b>Objetivo:</b> Definir a RDI de forma automática, para permitir a extração de parâmetros de cores, a partir das amostras de carne de peixes capturadas, para que possam servir de recursos em modelos baseados em AM.                                                                                                                                                                                                                                                                                                                         |                      |
| <b>Projetar e desenvolver artefatos</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                         |                      |
| <b>Versão 1:</b> Foram feitas capturas sem padrão. A câmera fotográfica utilizada foi de um <i>iPhone XR</i> configurada sem <i>zoom</i> , <i>flash</i> , abertura <i>f/1,8</i> , estabilização ótica, iluminação natural, foco sensível ao toque e resolução de 12MP;                                                                                                                                                                                                                                                                          |                      |
| <b>Versão 2:</b> Usou-se a mesma câmera fotográfica e configurações da Versão 1. As amostras foram retiradas do sashibo e postas em folha de isopor, manuseadas e postas em cartões de captura, com formato quadrado, 23 x 23 cm, para serem levados a estúdio fotográfico de paredes brancas, de material plástico fosco, fina espessura e iluminação de LED circular superior, fita de modelo 2835, com temperatura de 6500K, e abertura no topo para colocação da câmera. Optou-se por usar distância entre a câmera e as amostras de 23 cm. |                      |
| <b>Versão 3:</b> Optou-se por usar os mesmos cartões de captura, presos à folha de isopor, para que as amostras de carne pudessem ser retiradas do sashibo sobre eles. A folha de isopor, contendo os cartões com uma amostra de carne, foram levados para fora da área de descarga da indústria de pescados. Os cartões foram destacados da folha de isopor e levados ao estúdio para serem fotografados. Usou-se a distância de 23 cm, entre as amostras e câmera fotográfica. A temperatura de iluminação de 6500K.                          |                      |
| <b>Versão 4:</b> Utilizou-se o mesmo estúdio, mantendo-se as amostras nos cartões de captura. Manteve-se a configuração de iluminação (6500K de temperatura) e configurações da câmera fotográfica. A distância entre a câmera e a amostra foi diminuída para 17 cm (foi usada uma base falsa, feita de caixa de papelão no estúdio);                                                                                                                                                                                                           |                      |
| <b>Versão 5:</b> Utilizou-se o mesmo estúdio, mantendo-se a mesma iluminação (6500K de temperatura). Manteve-se a distância entre a amostra e a câmera em 17 cm. A mesma câmera fotográfica e configurações da Versão 1 foram utilizadas e optou-se por colocar as amostras sobre fundo preto;                                                                                                                                                                                                                                                  |                      |
| <b>Versão 6:</b> Utilizou-se o mesmo estúdio, variando-se a iluminação branca entre as temperaturas de 3200K e 6500K. Manteve-se a distância entre a amostra e a câmera em 17 cm. A mesma câmera fotográfica e configurações da Versão 1 foram utilizadas. As amostras foram colocadas em cartões brancos para serem fotografadas;                                                                                                                                                                                                              |                      |
| <b>Versão 7:</b> Utilizou-se o mesmo estúdio, mantendo-se a distância de 17 cm entre a amostra e a câmera. A mesma câmera fotográfica e configurações da Versão 1 foram utilizadas, com as amostras sobre cartões brancos e adicionou-se iluminação de LED, com 6500K, atrás das amostras;                                                                                                                                                                                                                                                      |                      |
| <b>Avaliar</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |                      |
| <b>Versão 1:</b> Não foi possível automatizar a definição da RDI e a configuração foi abortada;                                                                                                                                                                                                                                                                                                                                                                                                                                                 |                      |
| <b>Versão 2:</b> As amostras quebraram no manuseio e a configuração foi abortada;                                                                                                                                                                                                                                                                                                                                                                                                                                                               |                      |
| <b>Versão 3:</b> Foi possível automatizar a definição da RDI, mas as amostras apresentaram-se pequenas e a configuração foi abortada;                                                                                                                                                                                                                                                                                                                                                                                                           |                      |
| <b>Versão 4:</b> Foi possível automatizar a definição da RDI e obteve-se resultados melhores que na Versão 3;                                                                                                                                                                                                                                                                                                                                                                                                                                   |                      |
| <b>Versão 5:</b> Não foi possível automatizar a definição da RDI, e optou-se por retornar as configurações do SVC Versão 4;                                                                                                                                                                                                                                                                                                                                                                                                                     |                      |
| <b>Versão 6:</b> Foi possível automatizar a extração de recursos, mas optou-se por retornar as configurações do SVC Versão 4, uma vez que as imagens com 6500K foram as mais claras;                                                                                                                                                                                                                                                                                                                                                            |                      |
| <b>Versão 7:</b> Não foi possível automatizar a definição da RDI, e optou-se por retornar as configurações do SVC Versão 4.                                                                                                                                                                                                                                                                                                                                                                                                                     |                      |
| <b>Comunicar a solução, se atingido o final do processo</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                     |                      |
| Os resultados foram publicados (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2020a)                                                                                                                                                                                                                                                                                                                                                                                                                                                                       |                      |

Fonte: A Autora (2021)

Ressalta-se as dificuldades encontradas em padronizar o ambiente para a captura das amostras de atum (conjunto de dados construído primeiro) pela própria falta de um padrão de captura que pudesse ser extraído dos artigos resultantes do MSL. Com a experiência na captura de amostras de atum, as amostras de salmão foram capturadas, usando o mesmo SVC, com as mesmas configurações. A dificuldade em se obter um número maior de amostras de atum é justificada, primeiro por ser este um estudo recente e pelo processo de construção do conjunto de dados ser condicionado à disponibilidade do pescado, à rotina da indústria e à disponibilidade do especialista em acompanhar o trabalho.

Como já citado, durante os testes para atingir a melhor configuração do SVC para padronizar o ambiente de captura de imagens digitais, muitas amostras fotografadas que não tiveram serventia sendo, portanto, perdidas. O descarte das amostras é justificado pelas diversas configurações do SVC implantadas no processo de captura das amostras e listadas no Quadro 4..

Outras dificuldades em se obter maior número de amostras são listadas a seguir:

- A presença de um pesquisador na área de descarga de peixes retirados de caminhões frigoríficos representou uma mudança significativa na rotina de classificação de frescor de atum, na indústria. O especialista se concentrou em puncionar os peixes e retirar as amostras do sashibo diretamente nos cartões de captura, para serem fotografadas e explicar o porquê classificou a amostra em questão com uma classificação de frescor específica, inculindo atraso no processo;
- Os barcos pesqueiros capturaram atuns de diferentes espécies, embora a grande maioria seja atum *Bigeye*. Como a classificação é feita por espécie, não foram utilizadas as amostras dos atuns da espécie *Yellowfin* que foram disponibilizadas;
- Os peixes geralmente são retirados do caminhão refrigerado, quando pedidos de compra são registrados na indústria de pescados, fazendo com que houvesse poucas amostras após longas esperas (até 8 horas) em um ambiente sem sala de espera e com cheiro forte de peixe.

A dificuldade em se obter número maior de amostras de salmão se deve à quantidade reduzida de peixes recebidos pelo restaurante parceiro por semana.

Ressalta-se que não se deve usar imagens digitais da mesma amostra mais de uma vez, uma vez que o único parâmetro observacional da imagem é a cor da amostra. Amostras de carne não possuem forma ou direção espacial, de modo que a mesma amostra capturada em duas posições diferentes, mantendo o padrão da captura, representam a mesma observação, parâmetros de cores. Este fato fez o processo de captura demandar uma quantidade maior de peixes.

Finalmente, o processo de captura de imagens digitais de amostras de atum e de salmão foi impactado pela pandemia do SARS-CoV-2, uma vez que as empresas estiveram fechadas, em algumas semanas, na época da captura, por decretos do governo do estado de Pernambuco, como medida de contenção do avanço do vírus. O processo de captura também poderia ter contado com uma equipe maior, mas as medidas sanitárias foram proibitivas, restringindo a equipe de captura apenas à Autora.

Não houve, em nenhum artigo resultante do MSL, a citação de que dificuldades foram enfrentadas para a construção dos conjuntos de dados, de modo que pensou inicialmente que este era um processo simples. Sobretudo, não houve em nenhum artigo resultante do MSL a disponibilização do conjunto de imagens, independente do produto cárneo estudado, para que novos experimentos pudessem ser realizados. A disponibilização dos conjuntos de dados é um grande diferencial desta tese em relação aos trabalhos relacionados. Os conjuntos de imagens de atum e de salmão construídos nesta tese estão disponíveis no *link* [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final).

A seção 4.3 explana o pré-processamento das imagens capturadas pelo SVC, para a definição da RDI.

### 4.3 ETAPA 3: PRÉ-PROCESSAMENTO DAS IMAGENS

O computador utilizado para realizar o pré-processamento das imagens foi um *notebook MacBook Pro* 2017, i5 2,3 GHz, 32 gb de RAM. Para pré-processar as imagens e em seguida extrair as características de cor, foi construído um *script*, que executa de forma automática os passos mostrados nas

Figuras 30 e 31, representando as etapas de pré-processamento das imagens (GONZALEZ; WOODS; EDDINS, 2020) de atum e de salmão, respectivamente. Cada amostra tem apenas uma imagem. Ressalta-se que apesar das amostras mudarem de formato, os resultados não foram afetados. Salienta-se que as etapas de pré-processamento foram definidas para as amostras de atum e validadas com as amostras de salmão, sendo ajustado apenas o intervalo de cores predominante das amostras, para definição da RDI. Os passos do pré-processamento de imagens de atum são mostrados na Figura 27 e os passos do pré-processamento de imagens de salmão são mostrados na Figura 28.


As imagens originais foram inicialmente redimensionadas para 600 x 400 *pixels* com o objetivo de reduzir o tempo de processamento e foi feita a conversão do formato das imagens de RGB original para o formato HSV. Para a definição da RDI nas imagens de amostras de carne de atum, utilizou-se uma faixa de cores tridimensional de H, S e V, com intervalo mínimo de tons de vermelho. Para as imagens das amostras de carne de salmão usou-se intervalo HSV representando variações nos tons de laranja, cor predominante nas amostras.

Foi aplicada uma máscara de tons de cinza aos *pixels* vermelhos nas amostras de atum e aos *pixels* laranjas nas amostras de salmão, encontrados nas respectivas faixas de cores, gerando imagens em tons de cinza ruidosos.

As fontes primárias de ruído gaussiano em imagens digitais são problemas de iluminação, de alta temperatura durante a captura ou problemas no processamento das imagens. No processamento de imagem digital, um ruído gaussiano pode ser causado por uma mudança abrupta nos valores de *pixels* de uma imagem. As técnicas de filtro são usadas com a desvantagem de embaçá-lo, para mitigar o ruído. O filtro gaussiano reduz o nível de ruído de um sinal de entrada para mitigar a distorção em uma imagem (JAIN; GUPTA, 2015). Um filtro gaussiano foi aplicado às imagens em tons de cinza ruidosos, obtendo imagens borradas.

A partir das imagens borradas, foi aplicada uma função para limiarizar a imagem. Limiarização é um processo de segmentação de imagens que se baseia na diferença dos níveis de cinza que compõe diferentes objetos de uma imagem (ARTERO; TOMMASELLI, 2018).

Figura 27 - Etapas de pré-processamento de imagens para amostras de atum. Legenda: Passo 1: redimensionar a imagem original para 600 x 400 *pixels*; Passo 2: criar imagem em tons de cinza, a partir da máscara que usa um limite para variações de vermelho; Passo 3: criar imagem em tons de cinza, a partir de filtro gaussiano; Passo 4: criar imagem binária, a partir de uma função de limiarização; Passo 5: definir contornos; Passo 6: fazer corte da área contornada para determinar a região de interesse



Fonte: A Autora (2021)


Foi estabelecida uma intensidade de limiar com o objetivo de segmentar as amostras nas imagens. A função de limiarização analisou cada *pixel* das imagens em tons de cinza. Os *pixels* com intensidade maior que a intensidade de limiar definida passaram a ser brancos (*pixels* pertencentes à amostra), enquanto os *pixels* com intensidade menor que a intensidade de limiar passaram a ser pretos (*pixels* não pertencentes à amostra). A função de limiarização produziu uma imagem binária.

Pode-se perceber visualmente a diferença na quantidade de informação entre as imagens geradas a partir do filtro gaussiano (Passo 3 da Figura 27 e da Figura 28) e as imagens binárias (Passo 4 da Figura 27 e da Figura 28), sendo esta última menos ruidosa.

As imagens binárias permitiram definir o contorno das amostras, dado que *pixels* com valor 1 pertencem às amostras e *pixels* com valores 0 pertencem ao

fundo. As imagens binárias foram então convertidas em RGB e através de corte retangular foi produzido o menor retângulo delimitador possível para o contorno, resultando na RDI da imagem.

Figura 28 - Etapas de pré-processamento de imagens para amostras de salmão. Legenda: Passo 1: redimensionar a imagem original para 600 x 400 *pixels*; Passo 2: criar imagem em tons de cinza, a partir da máscara que usa um limite para variações de laranja; Passo 3: criar imagem em tons de cinza, a partir de filtro gaussiano; Passo 4: criar imagem binária, a partir de uma função de limiarização; Passo 5: definir contornos; Passo 6: fazer corte da área contornada para determinar a região de interesse



Fonte: A Autora (2021)

A partir daí foi obtido o histograma e os parâmetros dos espaços de cores RGB, HSV, HSI e L\*a\*b\* das imagens pré-processadas, como mostra a Seção 4.4, para serem usados como características em modelos de classificação baseados em técnicas de AM, mostrados na Seção 4.5.

O *link* contendo os conjuntos de dados de amostras de atum e salmão, bem como o *script* de pré-processamento de suas imagens digitais está disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final).

#### 4.4 ETAPA 4: EXTRAÇÃO DE CARACTERÍSTICAS COLORIMÉTRICAS

Nesta seção são apresentadas as características extraídas de imagens digitais das amostras com base em padrões colorimétricos e que serão usadas como características para classificação de níveis de frescor de amostras de peixes em modelos de AM.

Para extração das características foram usados os espaços de cores RGB, HSV, HSI e  $L^*a^*b^*$ . Iniciou-se o processo obtendo o histograma das bandas R, G e B do canal de cores RGB, e derivando as características R, G, B através do cálculo da média de todos os *pixels* do histograma das bandas respectivas.

Os recursos `hueHSV`, `saturationHSV` e `valueHSV` representam, respectivamente, os valores dos componentes H, S e V do espaço de cores HSV, obtidos a partir das características R, G e B.

Foi calculada, para o contexto de amostras de carne de atum, a mediana dos valores de `saturationHSV`, que representa a saturação da cor, para cálculo do pico do histograma das cores das amostras da carne de atum e salmão. Usando valores acima da mediana do parâmetro `saturationHSV`, foi obtido, através da média dos *pixels*, o pico do histograma das bandas H, S e V para tons de vermelho (para amostras de atum) e tons de laranja (para amostras de salmão). Ressalta-se que valores de saturação acima da mediana representam intensidades fortes da cor em questão, pois a saturação pode ser entendida como a intensidade da cor.


Os recursos `histR`, `histG` e `histB` representam a médias dos *pixels* que compõem o pico do histograma das bandas H, S e V. Os recursos `medianR`, `medianG` e `medianB` representam as medianas dos picos dos histogramas das bandas H, S e V. Os recursos `hueHSI`, `saturationHSI` e `intensityHSI`, respectivamente, representam os valores dos componentes H, S e I do espaço de cores HSI, obtidos a partir das características R, G, B.

Finalmente, os recursos `lLab`, `aLab` e `bLab` representam os valores do espaço de cores  $L^*a^*b^*$ , também obtidos a partir das características R, G, B. O *script* para extração automática de características está disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final).

Pode-se observar a correlação entre as características de cores extraídas das amostras através da análise das matrizes de correlação das características dos conjuntos de dados de atum e de salmão mostradas na Figura 29 e na Figura 30, respectivamente.

As matrizes de correlação mostram características que apresentam uma correlação forte (acima de 90%), mostrando a presença de redundância de informações, que podem atrapalhar a aprendizagem de classificadores de AM por oferecerem a estes, informações duplicadas, nem sempre úteis para o aprendizado.


Figura 29 - Matriz de correlação das características colorimétricas extraídas de amostras de atum



Fonte: A Autora (2021)

A monotonia ou redundância dos dados sugere a aplicação de primitivas de pré-processamento de características, como seleção de características ou redução de dimensionalidade do conjunto de dados, para que os modelos de AM não tenham maiores custos computacionais para serem treinados.

Figura 30 - Matriz de correlação das características colorimétricas extraídas de amostras de salmão



Fonte: A Autora (2021)

Faz-se importante ver as classes divididas por agrupamentos de níveis de frescor, com o objetivo de validar a escolha das características colorimétricas. Para deixar clara a quantidade de amostras em cada agrupamento, são mostradas a seguir, a quantidade de amostras por nível de frescor.


Pode-se ver na Figura 31 o número de amostras em cada classe ou nível de frescor. A Figura 31.a mostra que as classes que aparecem no conjunto de dados de amostras de atum apresentam número diferente de amostras para cada classe. Os níveis de frescor da carne do atum, sendo variáveis categóricas, foram codificados em variáveis numéricas: o nível 2- foi codificado como 0, o nível 3 foi codificado como 1, o nível 2 foi codificado como 2 e o nível 2+ foi codificado como 3. A classe 0 é a classe majoritária, enquanto a classe 2 é a classe minoritária. A classe 0 apresentou 31 (trinta e uma) amostras, a classe 1 apresentou 19 (dezenove) amostras, a classe 2 apresentou 18 (dezoito) amostras e, por fim, a classe 3 apresentou 27 (vinte e sete) amostras.

O conjunto de dados de amostras de salmão também é não balanceado, conforme mostra a Figura 31.b. A classe 0 é a majoritária e a classe 1 é a minoritária. A classe 0 representa o nível de frescor mais baixo, denominado "consumo imediato" e contém 37 (trinta e sete) amostras. A classe 1 representa o rótulo "fresco", contendo 33 (trinta e três) amostras. Por fim, a classe 2

representa a classe com maior nível de frescor, rotulada como "muito fresco", possui 35 (trinta e cinco) amostras.

Um problema de classificação em conjuntos de dados desbalanceados pode variar de um leve viés a um desequilíbrio mais severo nas previsões e representam um desafio para a modelagem preditiva, pois a maioria dos algoritmos de AM usados para classificação foi projetada em torno da suposição de um número igual de amostras para cada classe. Isso resulta em modelos com baixo desempenho preditivo, especificamente para a classe minoritária (BROWNLEE, 2020a). Neste estudo, isso é um problema porque, as classes minoritárias são tão importantes quanto às majoritárias, sendo o problema mais sensível a erros de classificação para a classe minoritária do que para a classe majoritária. É necessário que as classes minoritárias de atum (classe 2) e salmão (classe 1) sejam previstas de forma acertada, pois os valores comerciais e a vida útil dos peixes mudam dependendo dessas classificações, justificando a importância do uso de primitivas de balanceamento de classes.

Figura 31 - Número de classes ou níveis de frescor existentes nos conjuntos de dados de (a) atum e (b) salmão



Fonte: A Autora (2021)


Para entender se a escolha dos recursos criados foi adequada para classificar o frescor das carnes de atum e salmão, foi utilizada a técnica de redução de dimensionalidade de *Manifold Approximation And Projection* (UMAP) (ALLAOUI; KHERFI; CHERIET, 2020). Qualquer outra técnica de redução de dimensionalidade poderia ter sido usada. O objetivo do uso de uma técnica de redução de dimensionalidade de conjunto de dados neste ponto da pesquisa, é, tão somente, permitir visualizar, em um eixo cartesiano ortogonal bidimensional,

se os dados das características de cores extraídos das imagens das amostras permitem que as classes sejam agrupadas de forma bem definida, sendo a técnica UMAP adequada para esse fim.

Na Figura 32.a, pode-se ver que o UMAP capturou com sucesso as quatro classes de frescor da carne de atum existentes no conjunto de dados, uma vez que os níveis de frescor foram agrupados claramente em agrupamentos distintos. Apenas duas amostras com legenda 0 aparecem mais longe de seu verdadeiro agrupamento e representam amostras classificadas de forma confusa.

Tal como acontece com as classes do atum, o UMAP capturou com sucesso os três níveis de frescor da carne de salmão, conforme mostrado na Figura 32.b, havendo uma amostra da classe 0 deslocada do seu verdadeiro agrupamento.

Figura 32 - Agrupamentos por níveis de frescor (a) do atum e (b) do salmão gerados pela técnica de redução de dimensionalidade UMAP



Fonte: A Autora (2021)

Os gráficos de agrupamento da Figura 32 comprovam que as características colorimétricas criadas para classificar os níveis de frescor das carnes de atum e do salmão são adequadas. Sugere-se que tais características sejam ser aplicadas a outros peixes que usem padrões de cor em suas classificações de frescor.

#### 4.5 ETAPA 5: USO DOS MODELOS DE APRENDIZAGEM DE MÁQUINA

Nesta seção será apresentada a construção dos modelos de classificação que se constituem na última etapa da solução FreshnessScope, para que

possam usar as características de cores e classificar as amostras de peixes em níveis de frescor. Os experimentos com modelos de AM foram desenvolvidos utilizando-se amostras de carne de atum, à medida que estas eram coletadas. Nenhum experimento com amostras de carne de salmão foi feito até a completude dos experimentos realizados com amostras de carne de atum. O protocolo experimental, estabelecido através do uso de amostras de carne de atum, foi usado sem qualquer alteração em amostras de carne de salmão, mostrando sua fácil adaptabilidade.

Salienta-se novamente que um “modelo” é composto de primitivas de pré-processamento para dimensionar os dados, primitivas de pré-processamento de características (que incluem escolha ou extração de características”), primitivas de balanceamento de classes e classificadores de AM.

Na Seção 4.5.1, é discutida a construção e desempenho dos modelos para a classificação do frescor da carne atum e salmão, através de AM automatiza. Também é apresentado o protocolo experimental para construção de modelos de AM, para a classificação do frescor da carne de peixes. Para os melhores modelos de classificação de frescor de amostras de atum e salmão são apresentadas a matriz de confusão (MC) (MÜLLER; GUIDO, 2016), a precisão e o *recall* (DAVIS; GOADRIC, 2006), *F1-Score* (MOHANTY *et al.*, 2021) e curva ROC (MARZBAN, 2004), bem como a importância das características, nos Apêndices B e C.

#### **4.5.1 Modelos Criados com Base em Aprendizagem de Máquina**

Existem muitas primitivas de pré-processamento de dimensionamento de dados, de pré-processamento de características, de balanceamento de classes e de classificadores de AM de modo que, definir as melhores combinações destes, bem como os hiper parâmetros de cada classificador que devem ser utilizados no processo de treinamento dos modelos para garantir as melhores previsões, tem alto custo computacional e pode desencorajar novos experimentos.

Tendo o entendimento da necessidade de rápida validação do SVC por meio de modelos de AM, bem como a necessidade da descoberta de primitivas de pré-processamento de dimensionamento de dados, pré-processamento de

características, balanceamento de classes e classificadores de AM que pudessem ser usados na tarefa de classificação do frescor da carne de peixes, foi utilizado o AM automatizada, usando otimização *Bayesiana* de hiper parâmetros.

Neste estudo, optou-se por usar o *framework Auto-Sklearn* (BROWNLEE, 2020c) para automatizar a AM, de modo que foi utilizada a camada de meta-aprendizagem, mostrada na Figura 8, para inicializar os hiper parâmetros na otimização *Bayesiana* e o *PipelineProfiler* para a explorar interativamente os modelos gerados.

Para realizar o experimento através de AM automatizada, foi feita uma divisão aleatória dos conjuntos de dados para o processo de classificação, considerando 80% para dados de treinamento e 20% para dados de teste. Testes feitos considerando outros percentuais sugerem que a divisão do conjunto de dados em 80% para base de treinamento e 20% para a base de teste trás os melhores resultados.

A base de treinamento consiste de 76 amostras no conjunto de dados de amostras de atum, enquanto a base de teste consiste 19 amostras. No conjunto de dados de amostras de salmão, a base de treinamento consiste em 84 amostras e a base de teste consiste de 21 amostras. As bases de dados de treinamento foram então usadas para buscar as primitivas e hiper parâmetros que compõem o melhor modelo em termos de desempenho.


A validação cruzada (RODRIGUEZ; PEREZ; LOZANO, 2009) com 10 (dez) *folds* foi utilizada na otimização, e previsões foram feitas usando os dados de teste. O tempo de execução para construção para cada modelo foi especificado em 720 segundos. Foram feitos testes com valores abaixo de 720 segundos, obtendo-se poucos modelos que conseguiram ser construídos, o que sugeriu valores maiores para o tempo de execução. Também foram feitos testes com valores acima de 720 segundos, que além de aumentar muito o custo computacional, não provocou aumento nos desempenhos dos modelos.

A Figura 33 mostra o fluxograma para a construção dos modelos de classificação através AM automatizada.

Como se vê na Figura 31, os conjuntos de dados de amostras de atum e salmão estão desbalanceados. Como o contexto de classificação de frescor é sensível a este fato, ou seja, classes minoritárias erroneamente classificadas

podem significar erros na precificação do peixe para revenda, bem como risco para segurança alimentar, optou-se por aplicar manualmente a técnica SMOTE como primitiva de balanceamento de classes, na base de treinamento.

Figura 33 - Fluxograma para construção dos modelos de classificação através do AM automatizada



Fonte: A Autora (2021)

Salienta-se que foram testadas duas outras técnicas de sobreamostragem, em alguns experimentos, e optou-se por usar a técnica SMOTE no experimento por não haver melhoria estatística significativa no desempenho dos modelos usando outras em relação a SMOTE. As outras técnicas de sobreamostragem utilizadas foram *adaptive synthetic sampling* (ADASYN) (HE *et al.*, 2008) e *random over-sampling* (RandomOverSampler) (BATISTA; PRATI; MONARD, 2004).


As Figuras 37 e 41 mostram o *PipelineProfiler* para comparar diferentes modelos que preveem níveis de frescor de amostras de atum e salmão, respectivamente. Para comparar os modelos, as primitivas foram ordenadas por tipo e os modelos foram ordenados por desempenho. Sem perda de compreensão, chama-se o modelo ensemble gerado pelo *Auto-Sklearn* de *AutoML\_Ensemble*.

Primeiro, será analisado o *PipelineProfiler* gerado a partir do conjunto de dados de amostras de atum e mostrado na Figura 34. 32 (Trinta e dois) modelos

foram analisados; oito excederam o limite de tempo de 720 segundos definido para o processamento. Pode-se ver que 100% dos modelos apresentaram como primitivas de pré-processamento de dimensionamento dos dados, as técnicas de transformação categórica e de transformação numérica (ZDRAVEVSKI; LAMESKI; KULAKOV, 2013).

Na Figura 34, pode-se ver os modelos, suas respectivas acurácias de teste, os respectivos pesos que apresentam no AutoML\_Ensemble e o tempo médio de treinamento.

Figura 34 - *PipelineProfiler* gerado pelo *Auto-Sklearn* com modelos para classificação do frescor de amostras de atum



Fonte: A Autora (2021)

Os modelos #1 e #21 têm o maior peso no AutoML\_Ensemble e são destacados na seção de comparação (C) na Figura 34. Salienta-se que a escolha dos modelos para compor o ensemble são mostrados em (CARUANA *et al.*, 2004).

O AutoML\_Ensemble gerado é composto pelos classificadores: SVM, RF, PA, QDA, LDA, MLP, SGD. A Tabela 3 mostra as métricas do modelo AutoML\_Ensemble, em uma previsão feita na base de teste. A acurácia de teste, precisão, *recall* e *F1-Score* têm valores iguais a 100%, demonstrando resultados excepcionais.


Tabela 3 - Métricas do AutoML\_Ensemble para a classificação do frescor de amostras de atum

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 100%   | 100%     | 7                        |
| 1                         | 100%     | 100%   | 100%     | 5                        |
| 2                         | 100%     | 100%   | 100%     | 3                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)

A curva ROC é mostrada no Gráfico 4. A AUC das quatro classes que representam o frescor da carne de atum é igual a 1,0, corroborando que o modelo AutoML\_Ensemble prevê assertivamente 100% das classes.

Gráfico 4 - Curva ROC do AutoML\_Ensemble para a classificação do frescor de amostras de atum




Fonte: A Autora (2021)

O gráfico de importância de características é mostrado no Gráfico 5. A importância das características é gerada usando a técnica de permutações. O recurso hueHSI foi considerado o mais relevante para o AutoML\_Ensemble,

seguido pelo recurso hueHSV. Os recursos histR e histB foram considerados igualmente relevantes para o ensemble, tendo menos relevância do que os anteriores. Os demais recursos não apresentaram relevância para a predição. Salienta-se que a relevância das características não deve ser usada para escolha das características a serem usadas em modelos de AM, ficando esta última a cargo das primitivas de pré-processamento de características. A técnica de permutações revela a relevância de características na predição sendo importante instrumento de interpretação do modelo. Exclusão de características e posterior retreinamento do modelo, produzem um novo modelo, diferente do original.

Gráfico 5 - Importância das características para o AutoML\_Ensemble ao classificar o frescor da carne do atum




Fonte: A Autora (2021)

A MC, mostrada na Figura 35, foi gerada a partir do uso do AutoML\_Ensemble na base de dados de testes. Percebe-se que 100% das amostras foram classificadas de forma assertiva.


Para classificação de salmão, o *Auto-Sklearn* gerou 36 modelos, conforme mostrado na Figura 36.

Figura 35 - Matriz de confusão de uma previsão do frescor da carne do atum feita pelo  
AutoML\_Ensemble



Fonte: A Autora (2021)

Figura 36 - PipelineProfiler gerado pelo sistema Auto-Sklearn com modelos para classificação do frescor de amostras de salmão



Fonte: A Autora (2021)

O AutoML\_Ensemble é composto dos classificadores: DT, LDA, MLP, RF, ExtraTrees, AdaBoost, PA, KNN e BNB. As métricas de acurácia, *recall*, *F1-Score* e precisão do AutoML\_Ensemble gerado para classificação de frescor de salmão, em uma previsão feita na base de teste, são mostradas na Tabela 4.

Tabela 4 - Métricas do AutoML\_Ensemble para a classificação do frescor de amostras de salmão


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 100%   | 100%     | 6                        |
| 1                         | 100%     | 100%   | 100%     | 9                        |
| 2                         | 100%     | 100%   | 100%     | 6                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 21                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 21                       |

Fonte: A Autora (2021)

Assim como no conjunto de dados do atum, as métricas do conjunto de dados do salmão são exibidas com seus valores máximos, sendo estes os melhores valores possíveis.


A curva ROC mostrada no Gráfico 6 apresenta um valor de AUC igual a 1,0 para todas as classes de níveis de frescor do salmão, corroborando os excelentes resultados do AutoML\_Ensemble.

Gráfico 6 - Curva ROC do AutoML\_Ensemble para a classificação do frescor de amostras de salmão



Fonte: A Autora (2021)

Gráfico 7 - Importância das características para o AutoML\_Ensemble ao classificar o frescor da carne do salmão




Fonte: A Autora (2021)

O gráfico de importância de características mostrado na Gráfico 7 destaca que os picos do histograma de HSV, representados pelas características histR, histG e histB, são relevantes para o AutoML\_Ensemble na classificação do frescor do salmão, sendo histR a mais relevante. O recurso G também tem importância relevante e, finalmente, os recursos R e intensityHSI aparecem no gráfico, mas com relevância menor do que as mencionadas anteriormente. As outras características aparecem sem relevância. Salienta-se que a relevância das características não deve ser usada para escolha das características a serem usadas em modelos de AM, ficando esta última a cargo das primitivas de pré-processamento de características. Percebe-se que a relevância de características muda, quando se compara com AutoML\_Ensemble para classificação do frescor da carne do atum, mostrado no Gráfico 5. Salienta-se que a relevância de características pode mudar em função da mudança do modelo (comportamento matemático do modelo, primitivas utilizadas, características utilizadas, dados utilizados, etc).

A Figura 37, mostra a MC da previsão feita pelo AutoML\_Ensemble, usando a base de teste, para classificação do frescor do salmão. As amostras foram classificadas de forma assertiva em sua totalidade.

Figura 37 - Matriz de confusão de uma previsão do frescor da carne do salmão feita pelo AutoML\_Ensemble



Fonte: A Autora (2021)

Os resultados obtidos pelos diversos modelos e pelo ensemble gerados pela técnica de AM automatizada validaram a etapa de preparação das amostras, o SVC, a etapa de pré-processamento de imagens e as características de cores extraídas e encorajou a realização de um experimento de construção não automatizada de modelos, detalhado a seguir, usando classificadores individuais e ensembles, cujos desempenhos pudessem ser comparados estatisticamente. Salientamos que o experimento com AM automatizada usa apenas uma amostragem, diferente dos experimentos relatados a seguir que usam 30 (trinta) amostragens. O uso de apenas uma amostragem no experimento com AM automatizada se deu porque o objetivo era validar rapidamente as etapas de preparação das amostras, SVC, de pré-processamento de imagens. Caso os resultados do experimento revelassem baixos desempenhos dos AutoML\_Ensemble, novos refinamentos seriam necessários nas etapas citadas. Como só uma amostragem foi usada na AM automatizada, esta não foi comparada estatisticamente com os demais classificadores usados nos modelos da solução e listados a seguir.

Foram gerados 37 (trinta e sete) modelos usando os classificadores: RC, KNN, LDA, QDA, PA, DT, RF, ExtraTrees, AdaBoost, GB, SGD, SVM, LR, BNB, GNB, NC, MLP, ELM e 18 (dezoito) ensembles homogêneos, compostos de variações nos hiper parâmetros de cada classificador, além de um ensemble heterogêneo, composto por um comitê de classificadores distintos. Sem perda de entendimento, utiliza-se as siglas dos classificadores para dar nome ao

modelo que usa o respectivo classificador, juntamente com hiper parâmetros otimizados e primitivas de pré-processamento de características.

O padrão de votação dos modelos ensemble foi de “votos ponderados”, porém “votos majoritários” foram usados quando o(s) classificador(es) que compõe(m) o ensemble não suporta(m) uma votação através de “votos ponderados”. Serão analisados os resultados dos modelos a partir das métricas: acurácia de treinamento, acurácia de teste e tempo médio de treinamento. Serão mostrados os desempenhos dos modelos, comparando-os estatisticamente, usando a acurácia de treinamento, para elencar os modelos com maior desempenho na classificação do frescor de amostras de peixes. Os melhores modelos têm as métricas: curva ROC, precisão e *recall*, *F1-Score* e MC, além da importância das características apresentadas, nos Apêndices B (melhores modelos para classificação de atum) e C (melhores modelos para classificação de salmão).


Para a realização dos experimentos foi feita uma divisão randômica dos conjuntos de dados, sendo 80% para base de treinamento e 20% para base de teste. A base de treinamento do conjunto de dados de amostras de atum consta de 76 amostras, enquanto a base de teste consta de 19 amostras. A base de treinamento do conjunto de dados de amostras de salmão consta de 84 amostras e a base de teste de 21 amostras.

Técnicas de normalização e padronização para dimensionar dados numéricos em alguns experimentos foram testadas, sem ganhos de desempenho de justifiquem o alto custo computacional destes testes. Desta feita, optou-se por usar a técnica de normalização *min\_max* em 100% dos experimentos, em um intervalo entre 0 e 1. De maneira semelhante ao experimento realizado com AM automatizada, foi utilizada como primitiva de balanceamento de classes a técnica SMOTE em 100% dos experimentos, nas bases de treinamento.

Com o intuito de verificar se há diferenças estatísticas significativas nos desempenhos dos modelos, a divisão randômica dos conjuntos de dados em bases de treinamento e em bases de teste foi realizada 30 (trinta) vezes e buscou-se, em cada divisão, as primitivas de pré-processamento de características, bem como os hiper parâmetros dos classificadores, através de otimização em grade. Ao final, foram calculadas as médias das acurácias de

treinamento e de teste, bem como as médias dos tempos de treinamento para cada modelo.

Figura 38 - Fluxograma para construção dos modelos de classificação, com trinta repetições



Fonte: A Autora (2021)


A Figura 38 mostra o fluxograma dos passos para a construção dos modelos. Em cada iteração, na fase de busca das primitivas de pré-processamento de características e de otimização dos hiper parâmetros específicos de cada classificador é usada a validação cruzada com 10 (dez) *folds*, sendo o melhor modelo encontrado, treinado e testado.

Na busca de primitivas de pré-processamento de características, para seleção de características, foi usada a técnica *VarianceThreshold* e para extração de características, foram usadas as técnicas: PCA, LDA, LLE e *Autoencoder*. Salienta-se que foi considerada também a ausência do uso de primitivas de pré-processamento de características.

Nesta tese, foi construído um modelo de *Autoencoder* com base na arquitetura de um MLP para aprender uma representação compactada das entradas dos conjuntos de dados. O codificador possui duas camadas ocultas, a primeira com duas vezes o número de características dos conjuntos de dados, consideradas as entradas, e a segunda com o mesmo número de características dos conjuntos de dados, seguida pela camada gargalo com metade do número


de características do conjunto de dados. Como há 18 (dezoito) características de cores extraídas das amostras de carne de peixes, o codificador tem 36 (trinta e seis) neurônios na primeira camada oculta e 18 (dezoito) neurônios na segunda camada oculta. A camada de gargalo tem 9 (nove) neurônios. O decodificador foi definido com uma estrutura semelhante, embora ao contrário. Os conjuntos de dados compactados agora têm novos 9 (nove) recursos em vez dos 18 (dezoito) recursos originais. A estrutura do *Autoencoder* é mostrada na Figura 39.

Figura 39 - Arquitetura do *Autoencoder* com base em MLP, composta de duas camadas ocultas no Codificador e duas camadas ocultas no Decodificador



Fonte: A Autora (2021)

Figura 40 - Curvas de aprendizagem de treinamento do Autoencoder construído com (a) o conjunto de dados de amostras de atum e com (b) o conjunto de dados de amostras de salmão, mostrando a reconstrução das entradas sem sobreajuste



Fonte: A Autora (2021)

As curvas de aprendizagem do treinamento do *Autoencoder*, mostradas na Figura 40, revelam um bom ajuste nas reconstruções das entradas e se mantêm estáveis durante os treinamentos, em ambos os conjuntos de dados.

Para a otimização dos hiper parâmetros de cada classificador, iniciou-se o processo pela otimização aleatória (BERGSTRA; BENGIO, 2012), pela simplicidade de implementação, testando-a em alguns poucos classificadores e observando os desempenhos. Apesar de ótimos desempenhos terem sido observados, optou-se por testar nos mesmos classificadores, a otimização em grade (ALIBRAHIM; LUDWIG, 2021), pelo fato da possibilidade da realização de ajuste fino em valores numéricos de alguns hiper parâmetros. A consideração por otimização em grade se deu também facilidade e simplicidade de implementação. Nos poucos classificadores iniciais testados, os desempenhos dos modelos com classificadores otimizados em grade foram melhores que os otimizados de forma aleatória, o que justifica a decisão pela estratégia de otimização de hiper parâmetros através de grade em todos os experimentos.

A escolha dos hiper parâmetros que foram otimizados em cada classificador se deu, seguindo sugestões das referências listadas a seguir. A otimização de outros hiper parâmetros foram adicionadas às sugestões das referências. Foram testadas se com a otimização destes hiper parâmetros adicionais, o desempenho dos respectivos modelos eram melhores do que sem a otimização e em se confirmando, foi feito o ajuste fino dos valores a serem usados. Salienta-se que pelo alto custo computacional e pelo fato de já se ter modelos com altos desempenhos, optou-se por não otimizar todos os hiper parâmetros existentes em cada classificador.

A otimização dos hiper parâmetros do RC foram encontradas em (BROWNLEE, 2020j). A otimização dos hiper parâmetros do KNN são sugeridas em (RIBEIRO *et al.*, 2021). A otimização dos hiper parâmetros do LDA são sugeridas em (CHEN, Y., 2018) e (BROWNLEE, 2020h). As sugestões para a otimização dos hiper parâmetros do PA foram encontradas em (BARBARO, 2018). As sugestões para a otimização dos hiper parâmetros do DT foram encontradas em (MANTOVANI *et al.*, 2016), (ALAWAD; ZOHDY; DEBNATH, 2018) e (RIBEIRO *et al.*, 2021). As sugestões de otimização dos hiper parâmetros do RF foram encontradas em (SCORNET, 2017), (PROBST; WRIGHT; BOULESTEIX, 2019) e (RIBEIRO *et al.*, 2021). As sugestões para a

otimização dos hiper parâmetros do ExtraTrees foram encontradas em (MANTOVANI *et al.*, 2016). As sugestões de otimização dos hiper parâmetros do AdaBoost foram encontradas em (KRITHIGA; ILAVARASAN, 2021) e (GAO; LIU, 2020). As sugestões de otimização dos hiper parâmetros do GB foram encontradas em (RIBEIRO *et al.*, 2021). As sugestões de otimização dos hiper parâmetros do SGD foram encontradas em (BREUEL, 2015). As sugestões de otimização dos hiper parâmetros do SVM foram encontradas em (RIBEIRO *et al.*, 2021) e (DUAN; KEERTHI; POO, 2003). As sugestões de otimização dos hiper parâmetros do LR foram encontradas em (RIBEIRO *et al.*, 2021) e (AMBESANGE *et al.*, 2020). As sugestões de otimização dos hiper parâmetros do BNB foram encontradas em (RIBEIRO *et al.*, 2021). As sugestões de otimização dos hiper parâmetros do GNB foram encontradas em (SHARMA, 2021). As sugestões de otimização do hiper parâmetro do NC foi encontrada em (JIMÉNEZ-GUARNEROS; GRANDE-BARRETO; RANGEL-MAGDALENO, 2021). As sugestões de otimização dos hiper parâmetros do MLP foram encontradas em (BERGSTRA *et al.*, 2011) e (RADHAKRISHNAN, 2017). Por fim, a sugestão de otimização do hiper parâmetro do classificador ELM foi encontrada em (RATNAWATI *et al.*, 2020) e (CAO *et al.*, 2017).

O Quadro 5 lista os hiper parâmetros da biblioteca *scikit-learn* que foram otimizados em cada classificador, juntamente com os valores usados na otimização. Também são listados, no Quadro 5, os hiper parâmetros de cada classificador individual que foram usados com variações para criar os ensembles homogêneos, bem como os classificadores usados no ensemble heterogêneo (Ensemble\_Heterogêneo).

A menos do *random\_state* que representa a semente que está sendo usada no experimento e foi usado com valor 0 (zero) na instanciação dos classificadores que possuem este hiper parâmetro, do *n\_jobs* que representa a quantidade de processadores utilizados e foi usado com valor -1 na instanciação dos classificadores que possuem este hiper parâmetro, e do hiper parâmetro *batch\_size* do classificador MLP, que representa o tamanho dos *minibatches* para otimizadores estocásticos, que foi usado com valor 40 (quarenta) na instanciação do classificador, os hiper parâmetros da biblioteca *scikit-learn* de cada classificador e não otimizados foram usados com seus valores *default* e são mostrados no Quadro 6. Manteve-se, no classificador ELM, que teve sua

implementação feita manualmente, uma vez que este não está disponível na biblioteca *scikit-learn*, o valor de neurônios na camada oculta em 20 (vinte).

Para a realizar a comparação dos desempenhos dos modelos a fim de checar se há diferenças estatísticas significativas, foram usados os testes estatísticos de Friedman e Nemenyi (DEMŠAR, 2006), utilizando as 30 (trinta) populações dos *rankings* de acurácias de treinamento advindas das validações cruzadas com 10 (dez) *folds*, obtidas das 30 (trinta) repetições, para cada modelo. Em havendo modelo(s) com desempenhos mais significativos, e em sendo considerado(s) o(s) modelo(s) escolhido(s) para classificar o frescor de amostras de carne de cada tipo de peixe, são apresentadas além das acurácias, todas as métricas estudadas, nos Apêndices B e C. O ensemble heterogêneo é composto dos classificadores: RC, KNN, LDA, QDA, PA, DT, RF, ExtraTrees, AdaBoost, GB, SGD, SVM, LR, BNB, GNB, NC e MLP.

Quadro 5 - Hiper parâmetros e valores utilizados na otimização dos modelos para classificação do frescor da carne de peixes

| Modelos    | Hiper parâmetros otimizados                                                                   | Valores para otimização dos hiper parâmetros                                                |
|------------|-----------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------|
| RC         | Força de regularização ( <i>alpha</i> )                                                       | [0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1,0; 1,1; 2]                                  |
|            | Solucionador ( <i>solver</i> )                                                                | [auto; svd; cholesky; lsqr; sparse_cg; sag; saga]                                           |
| KNN        | Tamanho da folha ( <i>leaf_size</i> )                                                         | [1; 2; 5; 10; 15; 30]                                                                       |
|            | Número de vizinhos ( <i>n_neighbors</i> )                                                     | [1; 2; 3; 4; 5; 7; 9; 10; 11; 12; 50]                                                       |
|            | O parâmetro da métrica de distância de Minkowski ( <i>p</i> )                                 | [1; 2; 3]                                                                                   |
| LDA        | Número de componentes para redução de dimensionalidade ( <i>n_component</i> )                 | [none; 1; 2; 5; 10]                                                                         |
|            | Encolhimento ( <i>shrinkage</i> ) <sup>14</sup>                                               | [none; 0,0; 0,5; 0,7; 0,75; 0,80; 0,85; 0,90; 0,92; 0,94; 0,95; 1]                          |
|            | Solucionador ( <i>solver</i> )                                                                | [lsqr, eigen]                                                                               |
| QDA        | Estimativa de covariância por classe ( <i>reg_param</i> )                                     | [0,0; 0,05; 0,1; 0,15; 0,2; 0,25; 0,3; 0,35; 0,4; 0,5; 0,6; 0,7; 0,8; 0,85; 0,9; 0,95; 1,0] |
|            | Tolerância ( <i>tol</i> )                                                                     | [1e-2; 1e-3; 1e-4; 1,5e-3; 2e-3; 2,5e-3; 3e-3; 3,5e-3; 4e-3]                                |
| PA         | Tamanho máximo da etapa de regularização ( <i>C</i> )                                         | [0,5; 0,9; 1,0; 1,1; 1,5; 2,0; 2,5; 3,0; 3,5; 4,0]                                          |
|            | Função de perda ( <i>loss</i> )                                                               | [hinge; squared_hinge]                                                                      |
|            | Número máximo de repetições ( <i>max_iter</i> )                                               | [500; 900; 1000; 1100; 1500; 2000; 2500; 3000; 3500; 4000]                                  |
|            | Tolerância ( <i>tol</i> )                                                                     | [1e-2; 1e-3; 1e-4; 1,5e-3; 2e-3; 2,5e-3; 3e-3; 3,5e-3; 4e-3]                                |
| DT         | Qualidade de uma divisão de um nó da árvore ( <i>criterion</i> )                              | [gini; entropy]                                                                             |
|            | Estratégia usada para escolher a divisão em cada nó ( <i>splitter</i> )                       | [best; random]                                                                              |
|            | Profundidade ( <i>max_depth</i> )                                                             | [none; 1; 2; 4; 8; 16; 32]                                                                  |
|            | Número total de nós terminais ( <i>max_leaf_nodes</i> )                                       | [none; 10; 15; 20]                                                                          |
| RF         | Profundidade máxima da árvore ( <i>max_depth</i> )                                            | [none; 70; 75; 80; 85; 110; 200]                                                            |
|            | Número mínimo de amostras necessárias para estar em um nó folha ( <i>min_samples_leaf</i> )   | [1; 2; 10; 100]                                                                             |
|            | Número mínimo de amostras necessárias para dividir um nó interno ( <i>min_samples_split</i> ) | [1; 2; 3; 8; 20; 100]                                                                       |
|            | Número de árvores na floresta ( <i>n_estimators</i> )                                         | [10; 50; 90; 95; 100; 110; 200; 290; 300; 310; 500; 1000]                                   |
| ExtraTrees | Número total de nós terminais ( <i>max_leaf_nodes</i> )                                       | [none; 1; 2; 4; 8; 16; 32]                                                                  |
|            | Profundidade máxima da árvore ( <i>max_depth</i> )                                            | [none; 10; 15; 20]                                                                          |

<sup>14</sup> Funciona apenas com solucionadores 'lsqr' e 'eigen'.

continuação (2/3)

| Modelos  | Hiper parâmetros otimizados                                                                              | Valores para otimização dos hiper parâmetros                                                                                                        |
|----------|----------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| AdaBoost | Peso aplicado a cada classificador em cada iteração de reforço ( <i>learning_rate</i> )                  | [0,001; 0,01; 0,1; 0,5; 1,0; 1,5]                                                                                                                   |
|          | Algoritmo de convergência ( <i>algorithm</i> )                                                           | [SAMME; SAMME.R]                                                                                                                                    |
|          | Número de classificadores treinados em cada iteração ( <i>n_estimators</i> )                             | [10; 40; 45; 50; 55; 60; 100]                                                                                                                       |
| GB       | O número de recursos a serem considerados ao procurar a melhor divisão ( <i>max_features</i> )           | [none; auto; sqrt; log2]                                                                                                                            |
|          | A função para medir a qualidade de uma divisão ( <i>criterion</i> )                                      | [friedman_mse; squared_error]                                                                                                                       |
|          | Função de perda ( <i>loss</i> )                                                                          | [deviance; exponential]                                                                                                                             |
| SGD      | Função de perda ( <i>loss</i> )                                                                          | [hinge; log; modified_huber; squared_hinge; perceptron; squared_error; huber; epsilon_insensitive; squared_epsilon_insensitive]                     |
|          | Força de regularização ( <i>alpha</i> )                                                                  | [0,00001; 0,0001; 0,0002; 0,001; 0,002; 0,01]                                                                                                       |
|          | Parâmetro de mistura da penalidade <i>Elastic Net</i> ( <i>l1_ratio</i> ) <sup>15</sup>                  | [0,1; 0,14; 0,15; 0,16; 0,2; 0,3; 0,9]                                                                                                              |
|          | Penalidade ( <i>penalty</i> )                                                                            | [elasticnet]                                                                                                                                        |
|          | Tolerância ( <i>tol</i> )                                                                                | [1e-2; 1e-3; 1e-4; 1,5e-3; 2e-3; 2,5e-3; 3e-3; 3,5e-3; 4e-3]                                                                                        |
| SVM      | Tamanho máximo da etapa de regularização ( <i>C</i> )                                                    | [0,1; 0,2; 0,3; 0,4; 1,0]                                                                                                                           |
|          | Tipo de kernel utilizado ( <i>kernel</i> )                                                               | [poly; rbf; sigmoid]                                                                                                                                |
|          | Coeficiente da função de kernel ( <i>gamma</i> ) <sup>16</sup>                                           | [auto; scale]                                                                                                                                       |
| LR       | Solucionador ( <i>solver</i> )                                                                           | [newton-cg; lbfgs; sag; saga]                                                                                                                       |
| BNB      | Parâmetro de suavização ( <i>alpha</i> )                                                                 | [0,0; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1,0]                                                                                             |
|          | Limite para binarização de recursos ( <i>binarize</i> )                                                  | [0,0; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 1,0; 2,0; 3,0]                                                                                                  |
|          | Possibilidade de aprender as probabilidades de treinamentos anteriores ( <i>fit_prior</i> )              | [True, False]                                                                                                                                       |
| GNB      | Estabilidade de suavização da curva ( <i>var_smoothing</i> )                                             | [1e-9; 0,0001; 0,001; 0,01; 0,015; 0,02; 0,04; 0,045; 0,05; 0,055; 0,06; 0,1; 1,0]                                                                  |
| NC       | Métrica a ser usada ao calcular a distância entre instâncias em uma matriz de recursos ( <i>metric</i> ) | [cityblock; cosine; euclidean; l1; l2; manhattan]                                                                                                   |
| ELM      | Função de ativação ( <i>activation_function</i> )                                                        | [sine; tanh; hardtanh; relu; lrelu; tanhre; tribas; inv_tribas; sigmoid; softlim; hardlim; gaussian; inv_multiquadric; swish; elish; elu; softplus] |

<sup>15</sup> Usado apenas se o hiper parâmetro *penalty* = elasticnet

<sup>16</sup> Coeficiente para kernel do tipo poly, rbf e sigmoid.

continuação (3/3)

| Modelos             | Hiper parâmetros otimizados                                       | Valores para otimização dos hiper parâmetros                                                                                                        |
|---------------------|-------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| MLP                 | Função de ativação ( <i>activation</i> )                          | [identity; logistic; tanh; relu]                                                                                                                    |
|                     | Número de neurônios da camada oculta ( <i>hidden_layer_size</i> ) | [2; 3; 4; 5; 20]                                                                                                                                    |
|                     | Solucionador ( <i>solver</i> )                                    | [lbfgs; sgd; adam]                                                                                                                                  |
|                     | Tolerância ( <i>tol</i> )                                         | [0,00001; 0,0001; 0,0002; 0,001; 0,1]                                                                                                               |
| RC_Ensemble         | <i>solver</i>                                                     | [auto; svd; cholesky; lsqr; sparse_cg; sag; saga]                                                                                                   |
| KNN_Ensemble        | <i>n_neighbors</i>                                                | [1; 2; 3; 4; 5; 7; 9; 10; 11; 12; 50]                                                                                                               |
| LDA_Ensemble        | <i>shrinkage</i>                                                  | [none; 0,0; 0,5; 0,75; 0,80; 0,85; 0,90; 0,92; 0,94; 0,95; 1]                                                                                       |
| QDA_Ensemble        | <i>reg_param</i>                                                  | [0,0; 0,05; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,85; 0,9; 0,95; 1,0]                                                                           |
| PA_Ensemble         | <i>tol</i>                                                        | [1e-2; 1e-3; 1e-4; 1,5e-3; 2e-3; 2,5e-3; 3e-3; 3,5e-3; 4e-3]                                                                                        |
| DT_Ensemble         | <i>max_features</i>                                               | [1; 2; 3; 4; 5; 8; 16]                                                                                                                              |
| RF_Ensemble         | <i>n_estimators</i>                                               | [10; 50; 100; 300; 500; 1000]                                                                                                                       |
| ExtraTrees_Ensemble | <i>max_features</i>                                               | [1; 2; 3; 4; 5; 8; 16]                                                                                                                              |
| AdaBoost_Ensemble   | <i>n_estimators</i>                                               | [10; 40; 50; 60; 100]                                                                                                                               |
| GB_Ensemble         | <i>max_features</i>                                               | [1; 2; 3; 4; 5; 8; 16]                                                                                                                              |
| SGD_Ensemble        | <i>loss</i>                                                       | [hinge; log; modified_huber; squared_hinge; perceptron; squared_error; huber; epsilon_insensitive; squared_epsilon_insensitive]                     |
| SVM_Ensemble        | <i>kernel</i>                                                     | [linear; poly; rbf; sigmoid]                                                                                                                        |
| LR_Ensemble         | <i>solver</i>                                                     | [newton-cg; lbfgs; sag; saga]                                                                                                                       |
| BNB_Ensemble        | <i>binarize</i>                                                   | [0,0; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 1,0; 2,0; 3,0]                                                                                                  |
| GNB_Ensemble        | <i>var_smoothing</i>                                              | [1e-9; 0,0001; 0,001; 0,01; 0,05; 0,06; 0,1; 1,0]                                                                                                   |
| NC_Ensemble         | <i>metric</i>                                                     | [cityblock; cosine; euclidean; l1; l2; manhattan]                                                                                                   |
| MLP_Ensemble        | <i>hidden_layer_sizes</i>                                         | [2; 3; 4; 5; 10; 20; 50; 80; 100]                                                                                                                   |
| ELM_Ensemble        | <i>activation_function</i>                                        | [sine; tanh; hardtanh; relu; lrelu; tanhre; tribas; inv_tribas; sigmoid; elu; softlim; hardlim; gaussian; inv_multiquadric; swish; elish; softplus] |

Fonte: A Autora (2021)

Quadro 6 - Modelos, hiper parâmetros não otimizados e respectivos valores utilizados

| Modelos    | Hiper parâmetros não otimizados e valores utilizados                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |
|------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| RC         | fit_intercept = True, normalize = False, copy_X = True, max_iter = None, tol = 1e-3, class_weight = None, positive = False, random_state = 0.                                                                                                                                                                                                                                                                                                                                                                                                                                                          |
| KNN        | weights = 'uniform', algorithm = 'auto', metric = 'minkowski', metric_params = None, n_jobs = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    |
| LDA        | priors = None, n_components = None, store_covariance = False, tol = 1e-4 (usado apenas se solver = svd), covariance_estimator = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |
| QDA        | priors = None, store_covariance = False.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                               |
| PA         | fit_intercept = True, early_stopping = False, validation_fraction (não usado, já que o early_stopping = False), n_iter_no_change (não usado, já que o early_stopping = False), shuffle = True, verbose = 0, n_jobs = -1, random_state = 0, warm_start = False, class_weight = None, average = False.                                                                                                                                                                                                                                                                                                   |
| DT         | min_samples_split = 2, min_samples_leaf = 1, min_weight_fraction_leaf = 0,0, max_features = None, random_state = 0, min_impurity_decrease = 0,0, class_weight = None, ccp_alpha = 0,0.                                                                                                                                                                                                                                                                                                                                                                                                                 |
| RF         | criterion = 'gini', min_weight_fraction_leaf = 0,0, max_features = 'auto', max_leaf_nodes = None, min_impurity_decrease = 0,0, bootstrap = True, oob_score = False, n_jobs = -1, random_state = 0, verbose = 0, class_weight = None, ccp_alpha = 0,0, max_samples = None.                                                                                                                                                                                                                                                                                                                              |
| ExtraTrees | n_estimators = 100, criterion = 'gini', min_samples_split = 2, min_samples_leaf = 1, min_weight_leaf = 0,0, max_features = 'auto', min_impurity_decrease = 0,0, bootstrap = False, oob_score = False, n_jobs = -1, random_state = 0, verbose = 0, warm_start = False, class_weight = None, ccp_alpha = 0,0, max_samples = None.                                                                                                                                                                                                                                                                        |
| AdaBoost   | base_estimator = None, random_state = 0.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                               |
| GB         | learning_rate = 0,1, n_estimator = 100, subsample = 1,0, min_samples_split = 2, min_samples_leaf = 1, min_weight_fraction_leaf = 0,0, max_depth = 3, min_impurity_decrease = 0,0, init = None, random_state = 0, verbose = 0, max_leaf_nodes = None, n_iter_no_change = None, validation_fraction (não usado, já que n_iter_no_change = None), tol = 1e-4, ccp_alpha = 0,0, warm_start = False.                                                                                                                                                                                                        |
| SGD        | l1_ratio = 0,15 (usado apenas quando penalty = 'elasticnet'), fit_intercept = True, max_iter = 4000, shuffle = True, verbose = 0, epsilon = 0,1 (usado apenas quando loss for 'huber', 'epsilon_insensitive', ou 'squared_epsilon_insensitive'), n_jobs = -1, learning_rate = 'optimal', eta0 = 0,0 (não usado, já que learning_rate = 'optimal'), power_t = 0,5, early_stopping = False, validation_fraction (não usado, já que o early_stopping = False), n_iter_no_change (não usado, já que o early_stopping = False), class_weight = None, warm_start = False, average = False, random_state = 0. |
| SVM        | degree = 2 (usado apenas quando kernel for 'poly'), gamma = 'scale' (usado apenas em kernel 'rbf', 'poly' ou 'sigmoid'), coef0 = 0,0 (usado apenas quando kernel for 'poly' ou 'sigmoid'), shrinking = True, probability = True, tol = 1e-3, cache_size = 200, class_weight = None, verbose = False, max_iter = -1, decision_function_shape = 'ovr', break_ties = False, random_state = 0.                                                                                                                                                                                                             |

continuação (2/2)

| Modelos |  | Hiper parâmetros não otimizados e valores utilizados                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                            |
|---------|--|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| LR      |  | penalty = 'l2', dual = False, tol = 1e-4, C = 1,0, fit_intercept = True, class_weight = None, random_state = 0, n_jobs = -1, intercept_scaling (não usado, já que só é útil para solver 'liblinear'), max_iter = 100, verbose = 0, multi_class = 'auto', warm_start = False, l1_ratio = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |
| BNB     |  | class_prior = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |
| GNB     |  | prior = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |
| NC      |  | shrink_threshold = None.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                        |
| ELM     |  | neuronios_ocultos = 20.                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                         |
| MLP     |  | alpha = 0,0001, batch_size = 40 (não usado para solver = 'lbfgs'), learning_rate = 'constant' (usado apenas quando solver = 'sgd'), learning_rate_init = 0,001, power_t = 0,5 (usado apenas quando solver = 'sgd'), max_iter = 200, shuffle = True (usado apenas quando solver = 'sgd' ou 'adam'), random_state = 0, tol = 1e-4, verbose = False, warm_start = False, momentum = 0,9 (usado apenas quando solver = 'sgd'), nesterovs_momentum = True (usado apenas quando solver = 'sgd'), early_stopping = False, validation_fraction (não usado, já que o early_stopping = False), beta_1 = 0,9 (usado apenas para solver = 'adam'), beta_2 = 0,999 (usados apenas para solver = 'adam'), epsilon = 1e-8 (usado apenas para solver = 'adam'), n_iter_no_change = 10 (útil apenas quando solver for 'sgd' ou 'adam'), max_fun = 15.000 (usado apenas quando solver = 'lbfgs'). |

Fonte: A Autora (2021)

#### 4.6 MODELOS PARA A CLASSIFICAÇÃO DO FRESCOR DA CARNE DO ATUM

A Tabela 5 mostra os modelos construídos para a classificação do frescor das amostras de atum, bem como as médias das acurácias de treinamento, as médias das acurácias de teste e os tempos médios de treinamento (em segundos) obtidos em 30 (trinta) repetições.

Tabela 5 - Médias das acurácias de treinamento, médias das acurácias de teste e médias dos tempos de treinamento dos modelos para classificação do frescor da carne do atum


| Modelos              | Médias das acurácias de treinamento | Médias das acurácias de teste | Tempo médio de treinamento em segundos |
|----------------------|-------------------------------------|-------------------------------|----------------------------------------|
| AdaBoost             | 89,4667% ( $\pm 0,0476$ )           | 88,2456% ( $\pm 0,1118$ )     | 88,2456% ( $\pm 0,0253$ )              |
| BNB                  | 87,5% ( $\pm 0,0249$ )              | 84,7368% ( $\pm 0,0819$ )     | 0,0059 ( $\pm 0,0061$ )                |
| DT                   | 96,2% ( $\pm 0,018$ )               | 95,0877% ( $\pm 0,0428$ )     | 0,0081 ( $\pm 0,0069$ )                |
| ELM                  | 96,3738% ( $\pm 0,0148$ )           | 94,2105% ( $\pm 0,0437$ )     | 0,0031 ( $\pm 0,0094$ )                |
| ExtraTrees           | 93,3333% ( $\pm 0,0194$ )           | 91,5789% ( $\pm 0,0601$ )     | 0,006 ( $\pm 0,0064$ )                 |
| GB                   | 96,3% ( $\pm 0,019$ )               | 95,9649% ( $\pm 0,0521$ )     | 0,3169 ( $\pm 0,0374$ )                |
| GNB                  | 95,4% ( $\pm 0,0169$ )              | 95,4386% ( $\pm 0,0401$ )     | 0,0041 ( $\pm 0,0041$ )                |
| KNN                  | 97,2% ( $\pm 0,0142$ )              | 96,6667% ( $\pm 0,0395$ )     | 0,0069 ( $\pm 0,0256$ )                |
| LDA                  | 95,9% ( $\pm 0,0207$ )              | 94,0351% ( $\pm 0,0588$ )     | 0,0639 ( $\pm 0,2596$ )                |
| LR                   | 97,8667% ( $\pm 0,012$ )            | 96,6667% ( $\pm 0,0396$ )     | 1,6555 ( $\pm 1,2864$ )                |
| MLP                  | 98,1% ( $\pm 0,0108$ )              | 97,193% ( $\pm 0,0325$ )      | 0,4473 ( $\pm 0,9202$ )                |
| NC                   | 96,2333% ( $\pm 0,0189$ )           | 96,1404% ( $\pm 0,0469$ )     | 0,0042 ( $\pm 0,0042$ )                |
| PA                   | 97,6333% ( $\pm 0,0125$ )           | 97,0175% ( $\pm 0,04$ )       | 0,0569 ( $\pm 0,1146$ )                |
| QDA                  | 94,1667% ( $\pm 0,0165$ )           | 93,1579% ( $\pm 0,0563$ )     | 0,0048 ( $\pm 0,0048$ )                |
| RC                   | 94,7667% ( $\pm 0,012$ )            | 91,7544% ( $\pm 0,0603$ )     | 0,0342 ( $\pm 0,0225$ )                |
| RF                   | 96,3333% ( $\pm 0,0183$ )           | 95,0877% ( $\pm 0,0591$ )     | 0,5354 ( $\pm 0,5094$ )                |
| SGD                  | 97,1% ( $\pm 0,0135$ )              | 96,4912% ( $\pm 0,0437$ )     | 0,055 ( $\pm 0,0691$ )                 |
| SVM                  | 95,8667% ( $\pm 0,0133$ )           | 94,7368% ( $\pm 0,0543$ )     | 0,0056 ( $\pm 0,0055$ )                |
| AdaBoost_Ensemble    | 83,6333% ( $\pm 0,0878$ )           | 83,3333% ( $\pm 0,1185$ )     | 0,5729 ( $\pm 0,0716$ )                |
| BNB_Ensemble         | 92,8% ( $\pm 0,0189$ )              | 92,6316% ( $\pm 0,0501$ )     | 0,0072 ( $\pm 0,0078$ )                |
| DT_Ensemble          | 97,3333% ( $\pm 0,0168$ )           | 96,3158% ( $\pm 0,0388$ )     | 0,0083 ( $\pm 0,0078$ )                |
| ELM_Ensemble         | 97,3396% ( $\pm 0,0121$ )           | 94,3859% ( $\pm 0,0525$ )     | 0,02188 ( $\pm 0,0137$ )               |
| ExtraTrees_Ensemble  | 97,5667% ( $\pm 0,0152$ )           | 97,3684% ( $\pm 0,0353$ )     | 0,0094 ( $\pm 0,0077$ )                |
| GB_Ensemble          | 96,6% ( $\pm 0,0140$ )              | 96,1404% ( $\pm 0,0489$ )     | 2,2125 ( $\pm 0,5811$ )                |
| GNB_Ensemble         | 94,9333% ( $\pm 0,0223$ )           | 94,351% ( $\pm 0,0445$ )      | 0,0367 ( $\pm 0,0367$ )                |
| KNN_Ensemble         | 95,9667% ( $\pm 0,0108$ )           | 95,2632% ( $\pm 0,0458$ )     | 0,0057 ( $\pm 0,0085$ )                |
| LDA_Ensemble         | 96,4% ( $\pm 0,0156$ )              | 95,0877% ( $\pm 0,0449$ )     | 0,0431 ( $\pm 0,0212$ )                |
| LR_Ensemble          | 97,3333% ( $\pm 0,0104$ )           | 95,7895% ( $\pm 0,0394$ )     | 0,076 ( $\pm 0,0569$ )                 |
| MLP_Ensemble         | 97,5333% ( $\pm 0,0102$ )           | 96,8421% ( $\pm 0,0442$ )     | 14,2885 ( $\pm 6,4947$ )               |
| NC_Ensemble          | 97,0667% ( $\pm 0,015$ )            | 96,4912% ( $\pm 0,0437$ )     | 0,1526 ( $\pm 0,1251$ )                |
| PA_Ensemble          | 97,5333% ( $\pm 0,0131$ )           | 97,3684% ( $\pm 0,0378$ )     | 0,0517 ( $\pm 0,0517$ )                |
| QDA_Ensemble         | 97,2667% ( $\pm 0,0103$ )           | 97,0175% ( $\pm 0,0422$ )     | 0,0186 ( $\pm 0,0094$ )                |
| RC_Ensemble          | 96,8333% ( $\pm 0,0121$ )           | 95,2632% ( $\pm 0,0342$ )     | 0,0057 ( $\pm 0,0137$ )                |
| RF_Ensemble          | 96,8333% ( $\pm 0,0155$ )           | 94,5614% ( $\pm 0,0584$ )     | 4,1385 ( $\pm 0,7544$ )                |
| SGD_Ensemble         | 97,4% ( $\pm 0,0105$ )              | 97,193% ( $\pm 0,0402$ )      | 0,1445 ( $\pm 0,0683$ )                |
| SVM_Ensemble         | 95,8667% ( $\pm 0,0123$ )           | 94,386% ( $\pm 0,0576$ )      | 0,0108 ( $\pm 0,0076$ )                |
| Ensemble_Heterogêneo | 98,4% ( $\pm 0,0108$ )              | 97,5439% ( $\pm 0,0378$ )     | 2,3953 ( $\pm 0,115$ )                 |

Fonte: A Autora (2021)

O Gráfico 8 mostra os modelos apresentados na Tabela 5 ordenados pelas médias das acurácias de treinamento, da maior para a menor. Pode-se ver também as acurácias de teste de cada modelo, salientando que em nenhum dos modelos estão sobreajustados. Por fim, o Gráfico 8 mostra os tempos médios de treinamento de cada modelo.

O Gráfico 8 mostra 15 (quinze) modelos com acurácias de treinamento maiores de 97%, sendo 14 (quatorze) destes, com acurácias de teste acima de 95%, mostrando resultados excelentes para a classificação do frescor de amostras de atum. O modelo Ensemble\_Heterogêneo foi o que apresentou a maior acurácia de treinamento em valor absoluto, sendo igual a 98,4%, e com acurácia de teste igual 97,5439%. O modelo MLP apresentou desempenho muito próximo ao Ensemble\_Heterogêneo, com acurácia de treinamento igual 98,1% e acurácia de teste igual a 97,193%, tendo gasto apenas 18% do tempo médio de treinamento do Ensemble\_Heterogêneo.

Gráfico 8 - Médias das acurácias de treinamento ordenadas da maior para a menor, médias das acurácias de teste e tempos médios de treinamento dos 37 (trinta e sete) modelos para classificação do frescor de amostras de atum



Fonte: A Autora (2021)

As acurácias de treinamento dos modelos Ensemble\_Heterogêneo, MLP, LR, PA, ExtraTrees\_Ensemble, MLP\_Ensemble, PA\_Ensemble, SGD\_Ensemble, ELM\_Ensemble, DT\_Ensemble, LR\_Ensemble,

QDA\_Ensemble, KNN, SGD e NC\_Ensemble apresentaram valores acima de 97%, sendo seus desempenhos muito próximos como podemos observar no Gráfico 8, sendo necessário testes estatísticos para checagem de modelos com desempenhos mais significativos que outros. Os modelos BNB e AdaBoost\_Ensemble apresentaram os piores desempenhos quanto às acurácias de treinamento, tendo valores iguais a 87,9333% e 83,6333%, respectivamente.

Os modelos Ensemble\_Heterogêneo, MLP, PA, ExtraTrees\_Ensemble, PA\_Ensemble e QDA\_Ensemble mostraram extremo poder de generalização, apresentando valores de acurácias de teste acima de 97%.

Com relação aos tempos médios de treinamento, pode-se observar no Gráfico 8, que os modelos MLP\_Ensemble, RF\_Ensemble, Ensemble\_Heterogêneo e GB\_Ensemble apresentaram os piores desempenhos com valores acima de 2 segundos, sendo os valores dos tempos médios de treinamento iguais a 14,2885, 4,1385, 2,3953 e 2,215, respectivamente. Salienta-se que o MLP\_Ensemble apresentou tempo médio de treinamento acima de 14 segundos, sendo o modelo que teve o pior desempenho nesta métrica. O modelo LR apresentou tempo médio de treinamento de 1,6555 segundos. Todos os demais modelos apresentaram tempos médios de treinamento abaixo de um segundo. O modelo ELM foi o modelo que apresentou o menor tempo médio de treinamento, sendo igual a 0,0031 segundos.

O modelo MLP\_Ensemble apresentou o menor valor de desvio padrão (0,0102) entre as acurácias de treinamento enquanto os modelos AdaBoost e AdaBoost\_Ensemble apresentaram os maiores valores, sendo iguais a 0,0476 e 0,0878, respectivamente.

O modelo MLP apresentou o menor valor de desvio padrão entre as acurácias de teste, com valor igual a 0,0325 e novamente, os modelos AdaBoost e AdaBoost\_Ensemble apresentaram os maiores valores, sendo iguais a 0,1118 e 0,1185, respectivamente.

Para ilustrar, valores dos hiper parâmetros otimizados, bem como hiper parâmetros variados para formar modelos ensemble, bem como, os classificadores que fazem parte do ensemble heterogêneo, o Quadro 7 apresenta um exemplo de cada modelo, sendo este o que apresentou a maior acurácia de treinamento, nas 30 (trinta) repetições. Também são apresentadas que primitivas de pré-processamento de características foram utilizadas por

estes modelos, ao fazer uma previsão usando a base de teste da repetição específica, salientando que o rótulo “Sem tratamento” significa que nenhuma primitiva foi aplicada e o modelo usou as 18 (dezoito) características originais em seu treinamento.

Percebe-se, no Quadro 7, que 17 (dezessete) modelos não aplicaram primitivas de pré-processamento de características, fazendo uso das características originais do conjunto de dados de amostras de atum, enquanto 7 (sete) aplicaram o *Autoencoder*, mostrando a importância desta primitiva. Ainda dentre as primitivas de extração de características 8 (oito) modelos aplicaram a técnica PCA. Nenhum, dentre os melhores modelos, usou as técnicas LDA e LLE. Por fim, 5 (cinco) modelo apresentaram a primitiva de seleção de características *VarianceThreshold*.

Quadro 7 - Modelos para classificação do frescor da carne do atum que apresentaram as maiores acurácias de treinamento entre as 30 (trinta) repetições, seus valores de hiper parâmetros otimizados (para o Ensemble\_Hibrido, que classificadores são utilizados) e primitiva de pré-processamento de característica aplicada

| Modelos    | Hiper parâmetros Otimizados                                                     | Primitivas de Pré-processamento de Características |
|------------|---------------------------------------------------------------------------------|----------------------------------------------------|
| AdaBoost   | learning_rate=1;<br>algorithm='SAMME.R';<br>n_estimators=50                     | <i>VarianceThreshold</i>                           |
| BNB        | alpha=0,0;<br>binarize=0,0;<br>fit_prior= True                                  | PCA                                                |
| DT         | criterion='gini';<br>splitter='best';<br>max_depth=None;<br>max_leaf_nodes=None | Sem tratamento                                     |
| ELM        | activation_function='tanh'                                                      | Sem tratamento                                     |
| ExtraTrees | max_leaf_nodes=None;<br>max_depth= None                                         | Sem tratamento                                     |
| GB         | max_features='sqrt';<br>criterion='friedman_mse';<br>loss='deviance'            | <i>Autoencoder</i>                                 |
| GNB        | var_smoothing=0,01                                                              | Sem tratamento                                     |
| KNN        | leaf_size=1;<br>n_neighbors=1;<br>p = 1                                         | PCA                                                |
| LDA        | n_components=1;<br>shrinkage=1;<br>solver='lsqr'                                | Sem tratamento                                     |
| LR         | solver='newton-cg'                                                              | Sem tratamento                                     |
| MLP        | activation='tanh';<br>hidden_layer_sizes=3;<br>solver='adam';<br>tol=0,0001     | <i>Autoencoder</i>                                 |
| NC         | metric='euclidean'                                                              | Sem tratamento                                     |

continuação (2/2)

| Modelos              | Hiper parâmetros Otimizados                                                                       | Primitivas de Pré-processamento de Características |
|----------------------|---------------------------------------------------------------------------------------------------|----------------------------------------------------|
| PA                   | C=1,0;<br>loss='hinge';<br>max_iter=1000;<br>tol=0,001                                            | PCA                                                |
| QDA                  | reg_param=0,02;<br>tol=0,001                                                                      | <i>Autoencoder</i>                                 |
| RC                   | alpha=1,0;<br>solver='auto'                                                                       | <i>Autoencoder</i>                                 |
| RF                   | max_depth=80;<br>min_samples_leaf=1<br>min_samples_split=2;<br>n_estimators=100                   | <i>Autoencoder</i>                                 |
| SGD                  | loss='log';<br>alpha=0,0001;<br>penalty='l2';<br>tol=0,001                                        | PCA                                                |
| SVM                  | C=0,3;<br>kernel='poly';<br>gamma='scale'                                                         | Sem tratamento                                     |
| Modelos              | Hiper parâmetros Variados                                                                         | Primitivas de Pré-processamento de Características |
| AdaBoost Ensemble    | n_estimators                                                                                      | Sem tratamento                                     |
| BNB Ensemble         | fit_prior                                                                                         | Sem tratamento                                     |
| DT Ensemble          | max_features                                                                                      | Sem tratamento                                     |
| ELM Ensemble         | activation_function                                                                               | Sem tratamento                                     |
| ExtraTrees Ensemble  | max_features                                                                                      | Sem tratamento                                     |
| GB Ensemble          | max_features                                                                                      | <i>Autoencoder</i>                                 |
| GNB Ensemble         | var_smoothing                                                                                     | <i>VarianceThreshold</i>                           |
| KNN Ensemble         | n_neighbors                                                                                       | Sem tratamento                                     |
| LDA Ensemble         | shrinkage                                                                                         | <i>VarianceThreshold</i>                           |
| LR Ensemble          | solver                                                                                            | PCA                                                |
| MLP Ensemble         | hidden_layer_sizes                                                                                | <i>VarianceThreshold</i>                           |
| NC Ensemble          | metric                                                                                            | PCA                                                |
| PA Ensemble          | tol                                                                                               | <i>VarianceThreshold</i>                           |
| QDA Ensemble         | reg_param                                                                                         | Sem tratamento                                     |
| RC Ensemble          | solver                                                                                            | Sem tratamento                                     |
| RF Ensemble          | n_estimators                                                                                      | <i>Autoencoder</i>                                 |
| SGD Ensemble         | loss                                                                                              | PCA                                                |
| SVM Ensemble         | kernel                                                                                            | PCA                                                |
| Modelo               | Classificadores Utilizados                                                                        | Primitivas de Pré-processamento de características |
| Ensemble_Heterogêneo | RC; KNN; LDA; QDA; PA; DT;<br>RF; ExtraTrees; AdaBoost; GB;<br>SGD; SVM; LR; BNB; GNB; NC;<br>MLP | Sem tratamento                                     |

Fonte: A Autora (2021)

Para checar se há diferença estatística significativa entre os desempenhos dos modelos apresentados, foram usados os testes estatísticos de Friedman e Nemenyi.

A análise estatística foi realizada para 30 (trinta) populações com amostras ranqueadas, com *rankings* relativos às acurácias de treinamento das

30 (trinta) repetições em cada modelo. O nível de significância (*p-value*) aplicado foi igual 0,05.

A  $H_0$  foi rejeitada uma vez que o *p-value* do teste estatístico resultou em 0,000, sendo menor que nível de significância estabelecido. Portanto, assume-se que nem todas as populações são normais, ou seja, há diferença estatísticas significativas entre algumas populações.

Utilizou-se o teste *post-hoc* de Nemenyi para inferir que diferenças são significativas. As diferenças entre as populações são significativas, se a diferença entre suas classificações média (CM) for maior do que a distância crítica (DC), sendo DC igual a 10,761.


A Figura 41 agrupa visualmente as diferenças estatísticas significativas. Os modelos que não estão ligados pelas linhas horizontais apresentam diferenças estatísticas significativas, e vice-versa.

Os melhores modelos estão ligados pela linha horizontal mais à esquerda. 17 (dezessete) modelos, como mostra a Figura 41, apresentam os melhores desempenhos (considerando as acurácias de treinamento) para a classificação do frescor da carne do atum e não apresentam diferenças estatísticas significativas em seus desempenhos, sendo eles: Ensemble\_Hibrido, MLP, LR, MLP\_Ensemble, PA, ExtraTrees\_Ensemble, SGD\_Ensemble, PA\_Ensemble, DT\_Ensemble, LR\_Ensemble, ELM\_Ensemble, QDA\_Ensemble, KNN, NC\_Ensemble, SGD, RF\_Ensemble e RC\_Ensemble.

Para a classificação do frescor da carne do atum optou-se dentre estes 17 (dezessete) modelos, por aqueles que apresentaram acurácias de teste acima de 95%, totalizando 15 (modelos) modelos, sendo eles: **Ensemble\_Heterogêneo, MLP, LR, MLP\_Ensemble, PA, ExtraTrees\_Ensemble, SGD\_Ensemble, PA\_Ensemble, DT\_Ensemble, LR\_Ensemble, QDA\_Ensemble, NC\_Ensemble, RC\_Ensemble, KNN e SGD.**

Os valores de acurácias de treinamento e acurácias de testes dos 15 (quinze) modelos elencados como igualmente eficientes em termos de desempenho para classificação do frescor da carne do atum são mostrados na Tabela 6.

Figura 41 - Diferenças estatísticas entre os modelos de classificação do frescor da carne de atum para DC = 10,761, calculada pelo teste de Nemenyi



Fonte: A Autora (2021)


Tabela 6 - Acurácias de treinamento e de teste dos 15 (quinze) modelos igualmente eficientes e elencados para a classificação do frescor da carne do atum

| Modelos              | Médias das acurácias de treinamento | Médias das acurácias de teste |
|----------------------|-------------------------------------|-------------------------------|
| Ensemble_Heterogêneo | 98,4% ( $\pm 0,0108$ )              | 97,5439% ( $\pm 0,0378$ )     |
| MLP                  | 98,1% ( $\pm 0,0108$ )              | 97,193% ( $\pm 0,0325$ )      |
| LR                   | 97,8667% ( $\pm 0,012$ )            | 96,6667% ( $\pm 0,0396$ )     |
| PA                   | 97,6333% ( $\pm 0,0125$ )           | 97,0175% ( $\pm 0,04$ )       |
| ExtraTrees_Ensemble  | 97,5667% ( $\pm 0,0152$ )           | 97,3684% ( $\pm 0,0353$ )     |
| MLP_Ensemble         | 97,5333% ( $\pm 0,0102$ )           | 96,8421% ( $\pm 0,0442$ )     |
| PA_Ensemble          | 97,5333% ( $\pm 0,0131$ )           | 97,3684% ( $\pm 0,0378$ )     |
| SGD_Ensemble         | 97,4% ( $\pm 0,0105$ )              | 97,193% ( $\pm 0,0402$ )      |
| DT_Ensemble          | 97,3333% ( $\pm 0,0168$ )           | 96,3158% ( $\pm 0,0388$ )     |
| LR_Ensemble          | 97,3333% ( $\pm 0,0104$ )           | 95,7895% ( $\pm 0,0394$ )     |
| QDA_Ensemble         | 97,2667% ( $\pm 0,0103$ )           | 97,0175% ( $\pm 0,0422$ )     |
| KNN                  | 97,2% ( $\pm 0,0142$ )              | 96,6667% ( $\pm 0,0395$ )     |
| SGD                  | 97,1% ( $\pm 0,0135$ )              | 96,4912% ( $\pm 0,0437$ )     |
| NC_Ensemble          | 97,0667% ( $\pm 0,015$ )            | 96,4912% ( $\pm 0,0437$ )     |
| RC_Ensemble          | 96,8333% ( $\pm 0,0121$ )           | 95,2632% ( $\pm 0,0342$ )     |

Fonte: A Autora (2021)

No Gráfico 9, são mostrados os tempos médios de treinamento dos modelos escolhidos para a classificação de amostras de carne de atum. Salienta-se que o MLP\_Ensemble, apesar de maior custo computacional para ser treinado, em relação aos demais classificadores, apresenta valores de acurácias que justificam a sua adoção. Todos os modelos apresentam tempos de inferência abaixo de 1 (um) segundo.

Gráfico 9 - Tempos médios de treinamento dos modelos escolhidos para a classificação do frescor da carne do atum



Fonte: A Autora (2021)

No Apêndice B são apresentadas as métricas: acurácia de teste, precisão e *recall*, *F1-Score*, MC, e curva ROC, dos modelos escolhidos para classificação do frescor da carne do atum, calculadas a partir de previsões feitas com os melhores modelos mostrados no Quadro 7.

A seguir são apresentados os modelos para classificação do frescor de amostras de carne de salmão, usando o mesmo protocolo experimental utilizado para classificação de amostras de carne de atum.

#### 4.7 MODELOS PARA A CLASSIFICAÇÃO DO FRESCOR DA CARNE DO SALMÃO

A Tabela 7 mostra os modelos que foram construídos para classificação do frescor de amostras de salmão. Na Tabela 7, pode-se ver as médias das acurácias de treinamento, as médias das acurácias de teste e tempos médios de treinamento de cada modelo.

Os modelos apresentados na Tabela 7, ordenados por suas acurácias de treinamento são mostrados no Gráfico 10. O Gráfico 10 mostra, além das acurácias de treinamento de cada modelo, suas acurácias de teste e os tempos médios de treinamento. Percebe-se que nenhum modelo apresentou sobreajuste.

Dos 37 (trinta e sete) modelos apresentados no Gráfico 10, 25 (vinte e cinco) modelos apresentam acurácias de treinamento acima de 96%, sendo 19 (dezenove) destes com acurácias de teste acima de 95%, o que demonstra excelentes resultados, além da validade da solução criada para classificação do frescor de peixes.

O modelo NC\_Ensemble apresentou acurácias de treinamento e de teste, com valores de 98,8148% e 98,5714%, respectivamente. O LDA\_Ensemble apresentou resultados muito próximos, com acurácia de treinamento igual a 98,8148% e acurácia de teste igual a 98,254%. O tempo médio de treinamento do NC\_Ensemble foi 36% menor que o tempo médio de treinamento do LDA\_Ensemble.

As acurácias de treinamento dos modelos NC\_Ensemble, LDA\_Ensemble, NC, MLP, SVM e SVM\_Ensemble apresentaram valores acima de 98%.


Tabela 7 - Médias das acurácias de treinamento, médias das acurácias de teste e tempos médios de treinamento dos modelos para classificação do frescor da carne do salmão

| Modelos              | Médias das acurácias de treinamento | Médias das acurácias de teste | Tempo médio de treinamento em segundos |
|----------------------|-------------------------------------|-------------------------------|----------------------------------------|
| AdaBoost             | 97,3333% ( $\pm 0,0211$ )           | 95,7143% ( $\pm 0,0432$ )     | 0,7123 ( $\pm 0,7617$ )                |
| BNB                  | 85,2593% ( $\pm 0,0287$ )           | 83,1746% ( $\pm 0,0756$ )     | 0,0182 ( $\pm 0,0128$ )                |
| DT                   | 96,8889% ( $\pm 0,0215$ )           | 96,0317% ( $\pm 0,0371$ )     | 0,03223 ( $\pm 0,049$ )                |
| ELM                  | 88,5972% ( $\pm 0,0235$ )           | 87,4603% ( $\pm 0,0608$ )     | 0,0031 ( $\pm 0,0094$ )                |
| ExtraTrees           | 92% ( $\pm 0,0244$ )                | 91,4286% ( $\pm 0,0711$ )     | 0,0627 ( $\pm 0,0627$ )                |
| GB                   | 97,4444% ( $\pm 0,0209$ )           | 96,1905% ( $\pm 0,0397$ )     | 1,2527 ( $\pm 1,6427$ )                |
| GNB                  | 96% ( $\pm 0,0169$ )                | 94,6032% ( $\pm 0,0401$ )     | 0,0133 ( $\pm 0,0041$ )                |
| KNN                  | 97,1852% ( $\pm 0,0124$ )           | 94,7619% ( $\pm 0,0432$ )     | 0,0071 ( $\pm 0,0054$ )                |
| LDA                  | 97,963% ( $\pm 0,0125$ )            | 95,873% ( $\pm 0,0456$ )      | 0,0596 ( $\pm 0,2656$ )                |
| LR                   | 97,7778% ( $\pm 0,0165$ )           | 96,6667% ( $\pm 0,0351$ )     | 0,552 ( $\pm 0,693$ )                  |
| MLP                  | 98,2222% ( $\pm 0,012$ )            | 96,6667% ( $\pm 0,0463$ )     | 0,2076 ( $\pm 0,3404$ )                |
| NC                   | 98,7407% ( $\pm 0,0102$ )           | 98,254% ( $\pm 0,026$ )       | 0,0027 ( $\pm 0,0019$ )                |
| PA                   | 88,5555% ( $\pm 0,0184$ )           | 85,7143% ( $\pm 0,0843$ )     | 0,0822 ( $\pm 0,0822$ )                |
| QDA                  | 96,1852% ( $\pm 0,013$ )            | 95,5556% ( $\pm 0,0459$ )     | 0,0016 ( $\pm 0,0016$ )                |
| RC                   | 86,7407% ( $\pm 0,0184$ )           | 85,7143% ( $\pm 0,0727$ )     | 0,0061 ( $\pm 0,0037$ )                |
| RF                   | 97,4444% ( $\pm 0,0126$ )           | 95,7143% ( $\pm 0,0414$ )     | 0,2124 ( $\pm 0,1619$ )                |
| SGD                  | 96,6667% ( $\pm 0,0111$ )           | 95,5556% ( $\pm 0,0475$ )     | 0,08 ( $\pm 0,1251$ )                  |
| SVM                  | 98,1111% ( $\pm 0,0119$ )           | 96,3492% ( $\pm 0,0402$ )     | 0,0139 ( $\pm 0,0078$ )                |
| AdaBoost_Ensemble    | 97,4074% ( $\pm 0,0203$ )           | 95,873% ( $\pm 0,0385$ )      | 3,1272 ( $\pm 3,1272$ )                |
| BNB_Ensemble         | 89,2222% ( $\pm 0,0195$ )           | 89,0476% ( $\pm 0,0669$ )     | 0,0115 ( $\pm 0,008$ )                 |
| DT_Ensemble          | 94,2963% ( $\pm 0,0198$ )           | 92,8571% ( $\pm 0,0682$ )     | 0,0146 ( $\pm 0,0039$ )                |
| ELM_Ensemble         | 89,7667% ( $\pm 0,0213$ )           | 89,6825% ( $\pm 0,0616$ )     | 0,0635 ( $\pm 0,0151$ )                |
| ExtraTrees_Ensemble  | 94,5556% ( $\pm 0,0237$ )           | 93,6508% ( $\pm 0,0512$ )     | 0,0115 ( $\pm 0,008$ )                 |
| GB_Ensemble          | 97,5556% ( $\pm 0,018$ )            | 94,9206% ( $\pm 0,0602$ )     | 14,7631 ( $\pm 10,2197$ )              |
| GNB_Ensemble         | 95,1481% ( $\pm 0,0148$ )           | 93,9683% ( $\pm 0,0491$ )     | 0,0078 ( $\pm 0,0079$ )                |
| KNN_Ensemble         | 97,2593% ( $\pm 0,014$ )            | 94,9206% ( $\pm 0,0459$ )     | 0,0104 ( $\pm 0,0084$ )                |
| LDA_Ensemble         | 98,8148% ( $\pm 0,0081$ )           | 98,254% ( $\pm 0,0229$ )      | 0,0865 ( $\pm 0,0358$ )                |
| LR_Ensemble          | 96,2963% ( $\pm 0,0163$ )           | 95,3968% ( $\pm 0,0434$ )     | 0,0646 ( $\pm 0,0144$ )                |
| MLP_Ensemble         | 94,2222% ( $\pm 0,0202$ )           | 92,6984% ( $\pm 0,06$ )       | 5,0177 ( $\pm 0,4934$ )                |
| NC_Ensemble          | 98,8148% ( $\pm 0,0095$ )           | 98,5714% ( $\pm 0,025$ )      | 0,0545 ( $\pm 0,064$ )                 |
| PA_Ensemble          | 90,0741% ( $\pm 0,0192$ )           | 88,7302% ( $\pm 0,0763$ )     | 0,0344 ( $\pm 0,0168$ )                |
| QDA_Ensemble         | 97,4815% ( $\pm 0,0095$ )           | 96,9841% ( $\pm 0,0336$ )     | 0,0172 ( $\pm 0,0117$ )                |
| RC_Ensemble          | 87,1111% ( $\pm 0,0196$ )           | 85,7143% ( $\pm 0,0717$ )     | 0,0609 ( $\pm 0,0136$ )                |
| RF_Ensemble          | 97,1481% ( $\pm 0,0174$ )           | 95,7143% ( $\pm 0,0449$ )     | 6,0779 ( $\pm 2,8525$ )                |
| SGD_Ensemble         | 89,8889% ( $\pm 0,0416$ )           | 87,9365% ( $\pm 0,0888$ )     | 0,0729 ( $\pm 0,0335$ )                |
| SVM_Ensemble         | 98,037% ( $\pm 0,0148$ )            | 95,5556% ( $\pm 0,0491$ )     | 0,012 ( $\pm 0,0066$ )                 |
| Ensemble_Heterogêneo | 97,2222% ( $\pm 0,0102$ )           | 96,9841% ( $\pm 0,0358$ )     | 1,988 ( $\pm 0,4631$ )                 |

Fonte: A Autora (2021)

O Gráfico 10 mostra 10 (dez) modelos com acurácias de treinamento acima de 96%, sendo eles: NC\_Ensemble, LDA\_Ensemble, NC, MLP, LDA, SVM, LR, QDA\_Ensemble, GB, Ensemble\_Híbrido e DT. Tais acurácias mostram extremo poder de generalização da solução, mostrando a confiança da solução para classificação do frescor de peixes. Os modelos RC e BNB apresentaram as acurácias de treinamento mais baixas, com valores iguais a 86,7407% e 85,2593%, respectivamente.

Gráfico 10 - Médias das acurácias de treinamento ordenadas da maior para a menor, médias das acurácias de teste e tempos médios de treinamento dos 37 (trinta e sete) modelos para classificação do frescor de amostras de salmão



Fonte: A Autora (2021)

Com relação aos tempos médios de treinamento, o modelo GB\_Ensemble apresentou a maior média, sendo igual a 14,7631 segundos, seguido dos modelos RF\_Ensemble, MLP\_Ensemble e AdaBoost\_Ensemble que apresentaram médias acima de 3 segundos. 31 (trinta e um) modelos apresentaram tempos médios de treinamento abaixo de um segundo, sendo o QDA o que apresentou o menor tempo médio de treinamento, com valor igual a 0,0016.

O modelo LDA\_Ensemble apresentou o menor valor de desvio padrão entre as acurácias de treinamento, com valor igual a 0,0081. O modelo SGD\_Ensemble apresentou o maior desvio padrão entre as acurácias de treinamento, com valor igual a 0,0335. O modelo LDA\_Ensemble apresentou o menor desvio padrão entre as acurácias de teste, com valor igual a 0,0229, enquanto o modelo SGD\_Ensemble apresentou o maior desvio padrão das acurácias de teste, com valor igual a 0,0858.

Os melhores modelos e valores dos hiper parâmetros otimizados, bem como hiper parâmetros variados para formar modelos ensemble, são mostrados na Quadro 8.

Quadro 8 - Modelos para classificação do frescor da carne do salmão que apresentaram as maiores acurácias de treinamento entre as 30 (trinta) repetições, seus valores de hiper parâmetros otimizados (para o Ensemble\_Híbrido, que classificadores são utilizados) e primitiva de pré-processamento de característica aplicada

| Modelos             | Hiper parâmetros Otimizados                                                                 | Primitivas de Pré-processamento de Características |
|---------------------|---------------------------------------------------------------------------------------------|----------------------------------------------------|
| AdaBoost            | learning_rate=1;<br>algorithm='SAMME';<br>n_estimators=50                                   | PCA                                                |
| BNB                 | alpha=0,0;<br>binarize=1,0;<br>fit_prior=True                                               | <i>Autoencoder</i>                                 |
| DT                  | criterion='gini';<br>splitter='best';<br>max_depth=None;<br>max_leaf_nodes=None             | PCA                                                |
| ELM                 | activation_function='swish'                                                                 | Sem tratamento                                     |
| ExtraTrees          | max_leaf_nodes=None;<br>max_depth=None                                                      | LDA                                                |
| GB                  | max_features='auto';<br>criterion='friedman_mse';<br>loss='deviance'                        | PCA                                                |
| GNB                 | var_smoothing=0,05                                                                          | PCA                                                |
| KNN                 | leaf_size=1;<br>n_neighbors=10;<br>p=1                                                      | Sem tratamento                                     |
| LDA                 | n_components=1;<br>shrinkage=0,75;<br>solver='lsqr'                                         | Sem tratamento                                     |
| LR                  | solver='newton-cg'                                                                          | Sem tratamento                                     |
| MLP                 | activation='identity';<br>hidden_layer_sizes=3;<br>solver='lbfgs';<br>tol=0,0001            | PCA                                                |
| NC                  | metric='euclidean'                                                                          | Sem tratamento                                     |
| PA                  | C=1,0;<br>loss='hinge';<br>max_iter=1000;<br>tol=0,001                                      | <i>Autoencoder</i>                                 |
| QDA                 | reg_param=0,3;<br>tol=0,001                                                                 | <i>Autoencoder</i>                                 |
| RC                  | alpha=0,1;<br>solver='auto'                                                                 | <i>Autoencoder</i>                                 |
| RF                  | max_depth=80;<br>min_samples_leaf=1;<br>min_samples_split=2;<br>n_estimators=300            | PCA                                                |
| SGD                 | loss='perceptron';<br>alpha=0,01;<br>l1_ratio= 0,15;<br>penalty= 'elasticnet';<br>tol=0,001 | PCA                                                |
| SVM                 | C=0,3;<br>kernel='linear';                                                                  | Sem tratamento                                     |
| AdaBoost Ensemble   | n_estimators                                                                                | PCA                                                |
| BNB Ensemble        | fit_prior                                                                                   | <i>Autoencoder</i>                                 |
| DT Ensemble         | max_features                                                                                | Sem tratamento                                     |
| ELM Ensemble        | activation_function                                                                         | Sem tratamento                                     |
| ExtraTrees Ensemble | max_features                                                                                | Sem tratamento                                     |

continuação (2/2)

| Modelos              | Hiper parâmetros Variados                                                                | Primitivas de Pré-processamento de características |
|----------------------|------------------------------------------------------------------------------------------|----------------------------------------------------|
| GB Ensemble          | max_features                                                                             | PCA                                                |
| GNB Ensemble         | var_smoothing                                                                            | Sem tratamento                                     |
| KNN Ensemble         | n_neighbors                                                                              | Sem tratamento                                     |
| LDA Ensemble         | shrinkage                                                                                | LDA                                                |
| LR Ensemble          | solver                                                                                   | Sem tratamento                                     |
| MLP Ensemble         | hidden_layer_sizes                                                                       | Sem tratamento                                     |
| NC Ensemble          | metric                                                                                   | <i>VarianceThreshold</i>                           |
| PA Ensemble          | tol                                                                                      | <i>Autoencoder</i>                                 |
| QDA Ensemble         | reg_param                                                                                | <i>Autoencoder</i>                                 |
| RC Ensemble          | solver                                                                                   | <i>Autoencoder</i>                                 |
| RF Ensemble          | n_estimators                                                                             | PCA                                                |
| SGD Ensemble         | loss                                                                                     | PCA                                                |
| SVM Ensemble         | kernel                                                                                   | Sem tratamento                                     |
| Modelo               | Classificadores Utilizados                                                               | Primitivas de Pré-processamento de características |
| Ensemble_Heterogêneo | RC; KNN; LDA; QDA; PA; DT; RF; ExtraTrees; AdaBoost; GB; SGD; SVM; LR; BNB; GNB; NC; MLP | <i>Autoencoder</i>                                 |


Fonte: A Autora (2021)

Percebe-se, no Quadro 8, que 13 (treze) modelos não aplicaram primitivas de pré-processamento de características, fazendo uso das características originais do conjunto de dados de amostras de salmão, enquanto 9 (nove) aplicaram o *Autoencoder*, mostrando a importância desta primitiva. Ainda dentre as primitivas de extração de características, 2 (dois) modelos aplicaram a técnica LDA e 11 (onze) aplicaram a técnica PCA. Nenhum, dentre os melhores modelos, usou a técnica LLE. Por fim, 2 (dois) modelos apresentaram a primitiva de seleção de características *VarianceThreshold*.

Para checar se os modelos apresentados tem desempenhos mais significativos que outros, foram usados os testes estatísticos de Friedman e Nemenyi. A análise estatística foi realizada para 30 (trinta) populações, derivadas das 30 (trinta) repetições, de médias de acurácias de treinamento ranqueadas. O nível de significância do teste estatístico foi definido em 0,05.

Foi rejeitada a  $H_0$  uma vez que o *p-value* do teste estatístico resultou em 0,000, sendo menor que nível de significância estabelecido. Portanto, assume-se que nem todas as populações são normais, ou seja, há diferença estatísticas significativas entre algumas populações.

Figura 42 - Diferenças estatísticas entre os modelos de classificação do frescor de salmão para DC = 10,761, calculada pelo teste de Nemenyi



Fonte: A Autora (2021)

O teste post-hoc de Nemenyi foi usado para inferir que diferenças são significativas, para DC igual a 10,761. As diferenças entre as populações são significativas, se a diferença entre suas CMs for maior do que a distância crítica.

A Figura 42 agrupa visualmente as diferenças estatísticas significativas. Os modelos que não estão ligados pela linha horizontal apresentam diferenças estatísticas significativas, e vice-versa. Os melhores modelos estão ligados pela linha horizontal mais a esquerda.

Percebe-se, na Figura 42, que 20 (vinte) modelos não apresentam diferenças estatísticas significativas em suas acurácias de treinamento e são os que apresentam as maiores acurácias de treinamento, uma vez que estão ligados pela linha horizontal mais à esquerda, sendo eles: NC\_Ensemble, NC, LDA\_Ensemble, MLP, SVM, SVM\_Ensemble, LDA, LR, GB, GB\_Ensemble, AdaBoost\_Ensemble, QDA\_Ensemble, AdaBoost, KNN\_Ensemble, RF\_Ensemble, RF, Ensemble\_Heterogêneo, KNN, DT e SGD.

Tabela 8 - Acurácias de treinamento e de teste dos 17 (dezessete) modelos igualmente eficientes e elencados para a classificação do frescor da carne do salmão

| Modelos              | Médias das acurácias de treinamento | Médias das acurácias de teste |
|----------------------|-------------------------------------|-------------------------------|
| NC_Ensemble          | 98,8148% ( $\pm 0,0095$ )           | 98,5714% ( $\pm 0,025$ )      |
| NC                   | 98,7407% ( $\pm 0,0102$ )           | 98,254% ( $\pm 0,026$ )       |
| LDA_Ensemble         | 98,8148% ( $\pm 0,0081$ )           | 98,254% ( $\pm 0,0229$ )      |
| MLP                  | 98,2222% ( $\pm 0,012$ )            | 96,6667% ( $\pm 0,0463$ )     |
| SVM                  | 98,1111% ( $\pm 0,0119$ )           | 96,3492% ( $\pm 0,0402$ )     |
| SVM_Ensemble         | 98,037% ( $\pm 0,0148$ )            | 95,5556% ( $\pm 0,0491$ )     |
| LDA                  | 97,963% ( $\pm 0,0125$ )            | 95,873% ( $\pm 0,0456$ )      |
| LR                   | 97,7778% ( $\pm 0,0165$ )           | 96,6667% ( $\pm 0,0351$ )     |
| GB                   | 97,4444% ( $\pm 0,0209$ )           | 96,1905% ( $\pm 0,0397$ )     |
| AdaBoost_Ensemble    | 97,4074% ( $\pm 0,0203$ )           | 95,873% ( $\pm 0,0385$ )      |
| QDA_Ensemble         | 97,4815% ( $\pm 0,0095$ )           | 96,9841% ( $\pm 0,0336$ )     |
| AdaBoost             | 97,3333% ( $\pm 0,0211$ )           | 95,7143% ( $\pm 0,0432$ )     |
| RF_Ensemble          | 97,1481% ( $\pm 0,0174$ )           | 95,7143% ( $\pm 0,0449$ )     |
| RF                   | 97,4444% ( $\pm 0,0126$ )           | 95,7143% ( $\pm 0,0414$ )     |
| Ensemble_Heterogêneo | 97,2222% ( $\pm 0,0102$ )           | 96,9841% ( $\pm 0,0358$ )     |
| DT                   | 96,8889% ( $\pm 0,0215$ )           | 96,0317% ( $\pm 0,0371$ )     |
| SGD                  | 96,6667% ( $\pm 0,0111$ )           | 95,5556% ( $\pm 0,0475$ )     |

Fonte: A Autora (2021)


Para a classificação do frescor da carne do salmão optou-se dentre estes 20 (vinte) modelos, por àqueles que apresentaram acurácias de teste acima de 95%, totalizando 17 (dezessete) modelos, sendo eles: **NC\_Ensemble, NC, LDA\_Ensemble, MLP, SVM, SVM\_Ensemble, LDA, LR, GB,**

**AdaBoost\_Ensemble, QDA\_Ensemble, AdaBoost, RF\_Ensemble, RF, Ensemble\_Heterogêneo, DT e SGD.**

Os valores de acurácias de treinamento e acurácias de testes dos 17 (dezessete) modelos elencados como igualmente eficientes em termos de acurácia para classificação do frescor da carne do salmão são mostrados na Tabela 8.

O Gráfico 11 mostra os tempos médios de treinamento dos 17 (dezessete) modelos elencados para a classificação do frescor da carne de salmão. O modelo RF\_Ensemble foi o que apresentou maior tempo médio de treinamento, porém próximo a 6 segundos, o que justifica considerá-lo entre os modelos para classificação do frescor de salmão. Todos os modelos apresentaram tempos de inferência abaixo de 1 (um) segundo.

Gráfico 11 - Tempos médios de treinamento dos modelos escolhidos para a classificação do frescor da carne do salmão




Fonte: A Autora (2021)

No Apêndice C são apresentadas as métricas: acurácia de teste, precisão e *recall*, *F1-Score*, MC, e curva ROC, dos modelos escolhidos para classificação do frescor da carne do salmão, calculadas a partir de previsões feitas com os melhores modelos mostrados no Quadro 8.

#### 4.8 FRESHNESSSCOPE: UMA SOLUÇÃO AUTOMATIZADA PARA CLASSIFICAR O FRESCOR DA CARNE DE PEIXES COM BASE EM VISÃO COMPUTACIONAL E MACHINE LEARNING

Esta seção fornece uma sumarização das etapas que compõem a solução FreshnessScope: preparação das amostras, SVC, pré-processamento das imagens, extração de características de cores e uso de modelo de AM. O objetivo desta seção é facilitar a visualização de forma conjunta das etapas que compõem a solução.

Figura 43 - Diagrama das etapas da solução FreshnessScope



Fonte: A Autora (2021)

A Figura 43 mostra um diagrama contendo as cinco etapas, a ordem em que devem ser executadas, bem como as entradas e as saídas de cada uma

delas, para que uma amostra de peixe possa ser classificada quanto ao nível de frescor pelo FreshnessScope.

A etapa 1 do FreshnessScope, preparação das amostras, mostrada na Figura 43, é o protocolo que define a forma de extração das amostras do corpo do peixe em estudo. Deve-se sempre usar, como amostras experimentais, amostras de carne de peixes frescos recém pescados. Carnes adquiridas no varejo podem ter sido tratadas com produtos químicos, como monóxido de carbono (CO), por exemplo, e terem sua coloração alteradas artificialmente, sem relação com real estado de frescor.

Para a captura das imagens das amostras, deve-se usar cartões de captura na cor branca, feitos de papel, com formato quadrado e dimensões 23 x 23 cm, para evitar o manuseio das amostras. Para contextos cuja cor predominante da carne é branca, deve-se usar cartões de captura em qualquer tonalidade de verde. Não se deve usar mais de uma amostra no cartão captura, sob pena do *script* que define a RDI de forma automática encontrar apenas uma das amostras e perder informações das demais. A captura da imagem digital de uma amostra não deve durar mais que 3 minutos, tempo em que a carne começa a se deteriorar e umedecer os cartões de captura.

Como saída da etapa 1 do FreshnessScope há amostras postas em cartões de captura, prontas para serem fotografadas e que servem de entrada, para a etapa 2, SVC.

Na etapa 2, deve-se utilizar SVC composto de estúdio fotográfico, portátil, de paredes brancas, feitas de material plástico fosco, de espessura fina. As paredes laterais, topo e base do estúdio devem mitigar a entrada de luzes do ambiente circundante. O estúdio usado tem 23 cm de altura, 23 cm de largura e 23 cm de profundidade e abertura frontal. Este deve possuir abertura no topo para posicionamento de câmera fotográfica, que deve ter a lente posicionada em frente às amostras.

O estúdio deve conter iluminação de LED circular, posta no topo do estúdio, com 36 luzes de LED brancas, modelo 2835. O brilho da lâmpada deve ser de 26 lm. As luzes de LED brancas devem ser usadas com temperatura de 6500K. No o processo de captura pode-se utilizar um carregador *powerbank* de 10.000 mAh, uma vez que a fita de LED usada possui cabo USB.

As amostras devem posicionadas em base falsa, nos cartões de captura já citados, distando 17 cm do topo, onde deve estar posicionada a câmera fotográfica, em frente às amostras, sem necessidade de uso de tripé.

A câmera utilizada deve fotografar as imagens com 12 MP, sem *zoom*, sem *flash*, com abertura  $f/1,8$ , com estabilização ótica, com iluminação natural e com foco sensível ao toque. Após a captura, as imagens devem ter dimensões 4608 x 2592 pixels, e serem descarregadas manualmente em computador, convertidas em formato JPEG, para posterior pré-processamento *offline*.

Como saída da etapa 2 do FreshnessScope, SVC, têm-se imagens digitais das amostras, que servem de entrada para a etapa 3 do FreshnessScope, pré-processamento das imagens. Deve-se usar uma imagem por amostra.

O pré-processamento das imagens deve ser feito em computador compatível com as configurações: i5 2,3 GHz, 32 gb de RAM. Para pré-processar as imagens e em seguida extrair as características de cor, deve ser usado o *script*, disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final), que define a RDI de forma automática. A etapa 3 gera como saída, um conjunto de imagens com a RDI definida e servem como entrada para a etapa 4 do FreshnessScope, extração de características colorimétricas.

Para extração das características devem ser usados os espaços de cores RGB, HSV, HSI e  $L^*a^*b^*$  e *script* disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final), que extrai as características de forma automática. Da etapa 4 do FreshnessScope, como mostra a Figura 43, derivam-se os dados das amostras relativos às 18 (dezoito) características de cores e que servem de entrada para a etapa 5, uso de modelos de AM.

A etapa 5, última etapa do FreshnessScope, refere-se ao uso de modelos de AM que possam utilizar as características de cores extraídas na Etapa 4 e usá-las como recursos para classificar o nível do frescor de peixes. A seleção das características a serem usadas deve ser de responsabilidade das primitivas de pré-processamento de características.

A saída do FreshnessScope é o nível de frescor da amostra através de um dos modelos de AM sugeridos pela solução, entre os que não apresentam diferença estatística significativa de desempenho. A solução FreshnessScope mostrou-se robusta, confiável e de fácil adaptabilidade, podendo ser operada por

peessoas interessadas em classificação de peixes cujo frescor pode ser determinado por observação de padrões de cores. O maior custo da solução está associado ao uso de uma câmera fotográfica de 12 MP, uma vez que o custo de construção do SVC é ínfimo.

#### 4.9 FRESHNESSSCOPE E OS TRABALHOS RELACIONADOS

Confrontando-se o SVC criado nesta tese e os apresentados nos trabalhos relacionados percebe-se que em 100% destes, os SVC são mais complexos que o SVC criado nesta tese e não são móveis, mantendo-se montados enquanto durar o processo de captura das imagens, o que dificulta suas instalações dentro de ambientes de produção de indústrias ou empresas parceiras, o que acarreta, por vezes, seu deslocamento para laboratórios. Entende-se que soluções de frescor de produtos criadas em laboratórios são pouco fieis ao protocolo de classificação manual.

Dutta *et al.* (DUTTA *et al.*, 2016), assim como Issac, Dutta e Sarkar (ISSAC; DUTTA; SARKAR, 2017) preparam as amostras peixes da espécie *L. rohita* em laboratório e não apresentam detalhes do SVC utilizado além de se utilizarem de câmera fotográfica, modelo NIKON D90, que foi descontinuada pelo fabricante. Esta tese apresenta SVC possível de ser instalado em áreas de produção, podendo ser desmontado ao término de cada sessão de captura, diferente dos trabalhos de (DUTTA *et al.*, 2016) e (ISSAC; DUTTA; SARKAR, 2017).

Taheri-Garavand *et al.* em (TAHERI-GARAVAND *et al.*, 2019b) e em (TAHERI-GARAVAND *et al.*, 2020) capturam imagens de carpa comum (*Cyprinus carpio*) em Laboratório de Engenharia de Biosistemas da Universidade de Lorestan. O SVC utilizado no estudo usa sistema de iluminação equipado com 4 lâmpadas halógenas. A câmera foi colocada em posição vertical fixa no topo do estúdio, distando 30 cm da superfície da amostra. Comparando os SVCs quanto as lâmpadas utilizadas, as lâmpadas de LED, usadas no SVC criado nesta tese, possuem vantagens, quando comparadas às halógenas, usadas no SVC do estudo, ao consumir menos energia, não esquentar, ter maior vida útil e melhor custo benefício. A distância entre a câmera e a amostra usada no SVC desta tese é de 17 cm, diferente da distância de 30 cm usada no SVC

dos estudos (TAHERI-GARAVAND *et al.*, 2019b) e (TAHERI-GARAVAND *et al.*, 2020). A menor distância entre a câmera e as amostras, praticada nesta tese, produz imagens das amostras maiores. Entende-se ser o SVC dos estudos citados mais complexo e sem possibilidade de ser movido de ambiente de forma fácil, diferente do SVC proposto nesta tese.

Lalabadi, Sadeghi e Mireei (LALABADI; SADEGHI; MIREEI, 2020) preparam as amostras de trutas da espécie *Oncorhynchus mykiss* em laboratório. Usam um SVC que apresenta distância vertical entre a câmera e as amostras de 24 cm, maior que a distância praticada no SVC construído nesta tese. A menor distância produz imagens contendo as amostras mais próximas segundo teste feitos nesta tese. Os autores não apresentam detalhes de iluminação do SVC, nem das cores das paredes circundantes ou da cor do fundo do material no qual as amostras são postas para serem fotografadas. O SVC do estúdio é fixo em laboratório, não portátil, diferente do SVC proposto nesta tese.

Rayan *et al.* (RAYAN *et al.*, 2021) se utilizam de um SVC para capturar imagens digitais de tilápias, adquiridas em mercado de peixes. Os autores não detalham a iluminação utilizada no SVC, nem distância entre a câmera e as amostras. Também não é detalhada a cor de fundo do material no qual as amostras são postas para serem fotografadas. Além das especificações estarem incompletas, o SVC do estúdio é fixo em laboratório, e sem possibilidade de ser movido de ambiente de forma fácil, diferente do SVC proposto nesta tese, que é de fácil mobilidade e de fácil montagem e desmontagem.

Dentre os trabalhos resultantes do MSL, especificamente relacionados à classificação do atum, Lugatiman *et al.* (LUGATIMAN *et al.*, 2019) não apresentam detalhes de como as amostras de atum são adquiridas, tornando difícil a reprodutibilidade de sua preparação, mas percebe-se pelas forma da amostras apresentadas na imagens mostradas no artigo que não é utilizado o sashibo. O fato de não haver detalhes da fase de preparação em (LUGATIMAN *et al.*, 2019) faz com que não se saiba de que região anatômica do atum as amostras usadas são extraídas. Este fato pode fazer com que o trabalho de Lugatiman *et al.* (LUGATIMAN *et al.*, 2019) não seja fiel ao protocolo de classificação manual de amostras de atum adotado por especialistas, diferente desta tese, que definiu protocolo de preparação das amostras respeitando o processo de classificação observado na indústria.

Ainda em (LUGATIMAN *et al.*, 2019), não há detalhes acerca da temperatura das lâmpadas fluorescentes utilizadas no SVC, da distância entre a câmera *Raspberry Pi* e as amostras, nem acerca da cor utilizada no material no qual as amostras são postas para serem fotografadas. O SVC também é fixo em laboratório. Entende-se ser o SVC, usado neste estudo, complexo e sem possibilidade de ser movido de ambiente de forma fácil, diferente do SVC proposto nesta tese.

Naimullah, Sthevanie e Ramadhani (NAIMULLAH; STHEVANIE; RAMADHANI, 2020) utilizaram amostras de atum da espécie *Yellowfin*, já cortado e adquirido de empresa de pescados e fotografado em laboratório. O SVC do estúdio é fixo em laboratório, e sem possibilidade de ser movido de ambiente de forma fácil, diferente do SVC proposto nesta tese. Os autores não mencionam a qual região anatômica do peixe as amostras pertencem, o que pode enviesar a classificação se amostras forem extraídas de regiões distintas e comparadas, diferentemente desta tese, que usa amostras de atum extraídas exclusivamente da região dorsal do atum, abaixo da nadadeira lateral, respeitando o protocolo manual de classificação. Os autores não detalham a iluminação utilizada no SVC. A distância entre a câmera e as amostras é de 30 cm, maior que a praticada no SVC criado nesta tese, que é de 17 cm. Usar menor distância produz imagens com amostras maiores nas imagens capturadas, considerado como vantagem. Também não foram encontradas em (NAIMULLAH; STHEVANIE; RAMADHANI, 2020) as especificações da câmera usada na captura, bem como detalhes acerca do tamanho ou formato das imagens geradas.

Ressalta-se que há diferenças entre as soluções apresentadas nos estudos resultantes do MSL e o FreshnessScope no tocando ao SVC para captura das imagens das amostras, à quantidade e forma das amostras, ao número de níveis de frescor utilizados em cada contexto, às características extraídas das imagens, bem como aos modelos de AM usados. No entanto, entende-se que cada abordagem afeta diretamente o desempenho dos modelos de classificação construídos. A solução FreshnessScope se coloca como alternativa às soluções apresentadas nos estudos citados, facilmente adaptável a novos contextos, trazendo protocolo simples para captura de amostras, com materiais de fácil instrumentalização e SVC de fácil montagem e desmontagem,

além de *script* para definição da RDI e extração de características de cores de forma automatizada de modo a trazer resultados de classificação assertivos.

#### 4.10 SÍNTESE DO CAPÍTULO

Neste capítulo foram apresentadas as etapas de construção da solução FreshnessScope. Foram apresentadas as etapas de preparação das amostras para serem capturadas, construção do SVC, pré-processamento das imagens digitais e extração de características de cores extraídas das imagens das amostras, além do uso dos modelos de AM. A solução foi construída inicialmente usando amostras de carne de atum. O conjunto de dados de amostras de carne de salmão só foi utilizado, após todas as etapas da solução FreshnessScope estarem terminadas, e por conseguinte a solução FreshnessScope estar pronta. O uso do conjunto de dados de amostras de salmão validou a solução FreshnessScope, mostrando sua fácil adaptabilidade. Foram relatadas as diversas configurações testadas segundo os passos da DSR para a construção do SVC. As explicações de cada etapa foram feitas apresentando, sem perda de entendimento, os dois conjuntos de dados. 15 (quinze) modelos de AM foram igualmente eficientes para classificar o frescor de amostras de atum, enquanto para amostras de salmão foram encontrados 17 (dezesete) modelos, todos apresentando tempos de inferência abaixo de 1 (um) segundo. A última seção confronta o FreshnessScope e os trabalhos relacionados. O Capítulo 5 apresenta as considerações finais desta pesquisa, bem como as dificuldades e limitações encontradas e sugestões de trabalhos futuros.

## 5 CONSIDERAÇÕES FINAIS

Para finalizar o presente trabalho, esse capítulo revisará os objetivos propostos, relatando como eles foram realizados (Seção 5.1). As limitações e dificuldades encontradas são relatadas na Seção 5.2. Encerrando o capítulo, a Seção 5.3 apresentará propostas de trabalhos futuros, melhorias ou complementos desta pesquisa.

### 5.1 RESOLUÇÃO DOS OBJETIVOS PROPOSTOS

Conforme apresentado na Seção 1.3, o presente trabalho guiou-se pelo seguinte objetivo geral: Criar através de VC e AM uma solução viável, rápida e adaptável para classificação de níveis do frescor da carne de peixes. O objetivo geral foi desdobrado em 8 (oito) objetivos específicos que, quando atendidos, cumpririam o objetivo supracitado.

Como insumos para atender às ações, realizou-se uma pesquisa bibliográfica, através de MSL, envolvendo trabalhos acerca de soluções para classificação do frescor de produtos cárneos, envolvendo IA. Muitos estudos apresentam soluções para a classificação de produtos cárneos, utilizando técnicas de VC, de NIR, de imagens espectrais, de imagens ultrassônicas, e por fim, de *e-Nose* e *e-Tongue*.

Nesta tese, optou-se por desenvolver a solução com base em VC, devido à facilidade de instrumentalização de materiais, para classificação do frescor de amostras de peixes usando imagens digitais. Nesta tese, foram construídos dois conjuntos de dados de imagens digitais de amostras de carne de atum e de salmão, através de protocolo criado para preparação das amostras, detalhado na Seção 4.1, e uso de SVC, detalhado na Seção 4.2, capturadas em indústria de pescados e em restaurante de culinária japonesa, respectivamente, parceiros desta pesquisa. O experimento foi realizado com amostras de atum e validado com amostras de salmão.

A indústria de pescados está sediada em Recife, enquanto o restaurante de culinária japonesa localiza-se na cidade de Caruaru, ambos no estado de Pernambuco, Brasil. A metodologia DSR foi utilizada para que fosse possível testar várias versões do SVC, até que fosse atingida uma configuração de

*hardware* e protocolo para a captura das amostras, que facilitasse o pré-processamento das imagens.

O SVC compõe-se de estúdio que apresenta as paredes laterais, base e topo do tipo encaixe, podendo sendo facilmente desmontado e pode ser alimentado através de carregador *powerbank*, dispensando a necessidade de tomadas de energia elétrica como fonte de alimentação, salientando-se a importância destas características, uma vez que a permanência de sua instalação em áreas de produção das empresas parceiras não seria permitida, enquanto durasse a pesquisa e os ambientes não dispunham de tomadas de energia elétrica.

Salienta-se que as amostras de atum foram capturadas dentro da área de descarga de peixes de indústria de pescados, ambiente real de classificação. Enquanto, as amostras de salmão foram capturadas dentro da área de recepção de peixes do restaurante de culinária japonesa, ambiente real de classificação. Ressalta-se que tal fato permitiu criar a solução FreshnessScope, tendo os protocolos de classificação usados pelos especialistas como norteadores, possibilitando implantar a solução nestes ambientes para melhorar a qualidade do trabalho dos especialistas ou por vezes, substituí-lo.

A construção dos conjuntos de dados e a sua disponibilização, a preparação das amostras e o SVC, constituído de *hardware* e protocolo para a captura de novas amostras, atende aos dois primeiros objetivos específicos, que são: i. Construir e disponibilizar conjuntos de dados de imagens digitais de amostras de carne de atum e salmão, classificadas em níveis de frescor, por especialistas e ii. Construir um SVC composto de *hardware* e protocolo para a captura das imagens digitais das amostras de carne dos peixes. A preparação das amostras constitui-se na etapa 1 da solução FreshnessScope, detalhada na Seção 4.1, enquanto o SVC, constitui-se na etapa 2, detalhada na Seção 4.1. Os conjuntos de dados de imagens de amostras de carne de atum e de salmão estão disponíveis em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final), para que novos experimentos possam ser realizados.

Para o pré-processamento das imagens digitais das amostras de carne de atum e de salmão, capturadas através do SVC, foi criado protocolo detalhado na Seção 4.3. O *script* que define de forma automática a RDI das imagens está disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final).

Com a criação do protocolo automatizado de pré-processamento de imagens e sua disponibilização via *script*, cumpriu-se o objetivo específico iii, automatizar a definição da RDI das amostras.

Foram definidas, nesta tese, 18 (dezoito) características, extraídas de forma automatizada, a partir de imagens digitais das amostras de atum e de salmão, com base nos espaços de cores RGB, HSV, HSI e  $L^*a^*b^*$ , como sendo os recursos adequados para análise do frescor da carne de peixes sob a ótica da sua cor.

Pôde-se perceber, através da visualização em plano bidimensional gerado pela técnica UMAP, que as características sugeridas são capazes de separar as amostras em grupos distintos, com poucas amostras postas em grupos errados, com base em seus níveis de frescor.

O protocolo para criar as características de cores foi documentado, na Seção 4.4, e o *script* para extração automatizada das 18 (dezoito) características criadas está disponível em [https://github.com/erikamedeiros/tese\\_versao\\_final](https://github.com/erikamedeiros/tese_versao_final), para que novos experimentos possam ser feitos, atendendo o objetivo específico iv, criar e extrair automaticamente características de cores das amostras, a partir de suas imagens digitais. A resolução do objetivo específico iv criou a etapa 4 da solução FreshnessScope.

Para atender o objetivo específico v, usar as características de cores extraídas das imagens digitais, como recursos, em modelos de AM para a classificar as amostras em níveis de frescor, recorreu-se inicialmente, visando validar os SVC criado e testar muitos modelos de AM de forma rápida, ao uso de AM automatizada, através do *framework Auto-Sklearn*. Tanto para classificação do frescor do atum, como do frescor do salmão, os ensembles resultantes da AM automatizada geraram valores de 100% nas métricas: acurácia, precisão e *recall*, *F1-Score* e AUC geradas nas curvas ROC. As CMs mostraram 100% de assertividade.

Com o SVC validado pelos resultados advindos dos testes feitos através de AM automatizada, foram construídos 37 (trinta e sete) modelos de classificação através da combinação de primitivas de pré-processamento de dimensionamento dos dados, primitivas de pré-processamento de características, primitivas de balanceamento de classes e classificadores. Salienta-se não ser esta pesquisa exaustiva, mas sendo robusta o suficiente

para que novas técnicas nas quatro primitivas possam ser testadas. Foram utilizados os classificadores: RC, KNN, LDA, QDA, PA, DT, RF, ExtraTrees, AdaBoost, GB, SGD, SVM, LR, BNB, GNB, NC, MLP, ELM e 18 (dezoito) ensembles homogêneos, compostos de variações nos hiper parâmetros de cada classificador, além de um ensemble heterogêneo, composto por um comitê de classificadores distintos.

Em 100% dos experimentos foi utilizada como primitiva de pré-processamento de dimensionamento dos dados, a técnica de normalização *min\_max* com valores entre 0 e 1, de modo a normalizar as bases de treinamento usadas para treinar os modelos. Foi utilizada como primitiva de balanceamento de classes a técnica SMOTE, nas bases de treinamento, em 100% dos experimentos.

Como primitivas de pré-processamento de características foram utilizadas técnicas de seleção e extração de características. Foi utilizada para seleção de características a técnica *VarianceThreshold* e para extração de características foram utilizadas as técnicas: PCA, LDA, LLE e *Autoencoder*. Salienta-se que também foram testados os modelos sem a aplicação de nenhuma primitiva de pré-processamento de características, na tentativa de perceber se os desempenhos eram melhores.

Com vistas a checar diferenças estatísticas significativas entre os desempenhos dos modelos, foi feito o uso dos testes estatísticos de Friedman e Nemenyi, com nível de significância *p-value* igual a 0,05, assumindo, como  $H_0$ , que todos os modelos têm desempenho equivalentes.

Para a classificação do frescor da carne do atum optou-se dentre aqueles que não apresentaram diferenças estatísticas em seus desempenhos, pelos modelos que apresentaram acurácias de teste acima de 95%, sendo eles: Ensemble\_Heterogêneo, MLP, LR, MLP\_Ensemble, PA, ExtraTrees\_Ensemble, SGD\_Ensemble, PA\_Ensemble, DT\_Ensemble, LR\_Ensemble, QDA\_Ensemble, NC\_Ensemble, RC\_Ensemble, KNN e SGD. Totalizam 15 (quinze) modelos, sendo, em todos eles, hueHSI a característica mais relevante

Dentre os modelos sem diferença estatística significativa em seus desempenhos para classificação do salmão, optou-se por aqueles com acurácias de teste acima de 95%, sendo um total de 17 (dezessete) modelos: NC\_Ensemble, NC, LDA\_Ensemble, MLP, SVM, SVM\_Ensemble, LDA, LR, GB,

AdaBoost\_Ensemble, QDA\_Ensemble, AdaBoost, RF\_Ensemble, RF, Ensemble\_Heterogêneo, DT e SGD. A menos do LR que apresentou a característica medianR, todos os demais apresentaram a característica histG como a mais relevante.

Para os modelos escolhidos como classificadores ótimos para o frescor da carne de atum e de salmão, além das acurácias de treinamento, das acurácias de teste e dos tempos médios de treinamento, foram apresentadas as métricas precisão e *recall*, curva ROC e MC de uma previsão realizada.

O uso de modelos de AM constitui-se na etapa 5 do FreshnessScope, detalhado na Seção 4.6, e acabou por cumprir o objetivo específico v, usar as características de cores extraídas das imagens digitais, como recursos, em modelos de AM para a classificar as amostras em níveis de frescor.

A solução FreshnessScope, detalhada na seção 4.8, foi então constituída de cinco etapas:

- Etapa 1: Preparação das amostras, detalhada na Seção 4.1;
- Etapa 2: Sistema de visão computacional, detalhada na Seção 4.2;
- Etapa 3: Pré-processamento das imagens, detalhada na Seção 4.3;
- Etapa 4: Extração de características colorimétricas, detalhada na Seção 4.4;
- Etapa 5: Uso de modelos de AM, detalhada na Seção 4.5.

Com a criação e demonstração da utilização da solução FreshnessScope para classificar o frescor de amostras de carne de peixes com base em padrões colorimétricos, cumpriu-se o objetivo específico vi, apresentar solução FreshnessScope para classificar o frescor das amostras com base em padrões colorimétricos;

A solução FreshnessScope foi usada primeiramente em amostras de atum. Foi validada a adaptabilidade da solução, apenas com um ajuste no intervalo de cores para busca da RDI das amostras de salmão, na etapa 3, pré-processamento de imagens e então os modelos de AM puderam ser retreinados no novo contexto. As demais etapas da solução foram utilizadas sem qualquer ajuste. A solução pode ser usada, da mesma maneira em amostras de outros peixes que possam ter seus níveis de frescor classificados segundo características colorimétricas, bem como em outros contextos de produtos

alimentícios que também tenham a coloração afetada por níveis de frescor. Desta feita, o objetivo específico vii, que ressalta a adaptabilidade da solução, foi cumprido.

Por fim, o último objetivo que trata da publicação dos resultados da pesquisa foi cumprido. Os resultados podem ser visto em (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2020a), (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2020b) e (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2021).

(MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2020a) é um artigo publicado no periódico A4, *International Journal of Science & Research Methodology*, que apresenta, através de sucessivos refinamentos, amparados na metodologia DSR, a construção do SVC, criado nesta tese e que compõe o FreshnessScope. (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2020b) é um artigo publicado no periódico B1, *International Journal of Development Research*, que apresenta o MSL. (MEDEIROS; ALMEIDA; TEIXEIRA FILHO, 2021) é um artigo publicado no periódico A1, *Informatics-Basel* e apresenta os experimentos realizados com amostras de atum e de salmão através da AM automatizada.

Com o atendimento de todos os objetivos específicos, atendeu-se o objetivo geral da pesquisa: criar através de VC e AM uma solução viável, de instrumentalização rápida e simples de materiais, adaptável para classificação de níveis do frescor da carne de peixes.

## 5.2 DIFICULDADES E LIMITAÇÕES DA PESQUISA

Diversas são as dificuldades para o desenvolvimento de uma solução do porte da FreshnessScope. Dentre elas, a que mais se destacou foi a dificuldade de encontrar empresas que pudessem ser parceiras da pesquisa. Mesmo depois de encontradas, destaca-se as dificuldades no processo de captura das amostras dos peixes, uma vez que a presença de pesquisadores, tanto na indústria de pescados, quanto no restaurante de culinária japonesa, mudou a rotina da operação destas empresas.

Em todas as visitas às empresas parceiras, houve o acompanhamento de especialistas de classificação de frescor de atum e salmão. Os especialistas classificaram as amostras, na maioria das vezes explicando o porquê do nível de frescor escolhido, entregou-as em pequenos lotes para que pudessem ser

fotografadas, dado que as amostras se deterioraram após poucos minutos em temperatura ambiente, e aguardou o termino da sessão de captura, para iniciar a classificação de um novo lote de amostras. O atraso que foi incutido no processo tradicional de classificação dos peixes foi real e perceptível.

Para que fosse mitigado o atraso, a captura das amostras de atum foi feita dentro da área de descarga de peixes da indústria de pescados. A captura das amostras de salmão foi feita dentro da área de recepção de peixes do restaurante. Este fato mudou a rotina operacional das empresas, devido a montagem do SVC e a presença constante da Autora, para as sessões de captura.

Em certas ocasiões, devido a urgência de entregas de peixes a clientes, o especialista não permitiu a captura de amostras destes peixes, sendo mais um motivo para o lento processo de captura de imagens, sendo esta outra dificuldade da pesquisa.

O fato de apenas uma amostra por peixe ser disponibilizada pelos especialistas, uma vez que estes usam apenas uma amostra por peixe no processo de classificação, fez com que houvesse a necessidade de maior quantidade de peixes para a construção dos conjuntos de dados.

O ambiente na indústria de pescados, no qual a Autora se manteve durante a captura das amostras de carne de atum, possuir cheiro forte de sangue e vísceras de peixe, apesar de constantes limpezas. Os tempos de espera foram longos, iniciando sempre as 6 horas da manhã e durando 8 horas consecutivas e, por vezes, sem a captura de nenhum peixe, por falta de pedidos de compras de clientes ou fornecedores.

A pouca disponibilidade de peixes devido à redução temporária no consumo, devido ao fechamento dos restaurantes em função de *lockdowns* no estado de Pernambuco, em função da pandemia do SARS-CoV-2, atrasou muito a fase de captura das amostras.

Estas dificuldades tornaram o processo de captura muito custoso, resultado de muitas visitas à indústria de pescados, bem como ao restaurante de culinária japonesa e, por vezes, com longas horas de espera nas empresas. A maior parte do custo do FreshnessScope está associada a esta fase.

Quanto às limitações do FreshnessScope, destaca-se o fato da solução só inspecionar a qualidade externa da carne dos peixes. Porém, entende-se que

o FreshnessScope é auxiliar, sendo por vezes, substituto do trabalho do especialista na fase de análise das cores das amostras, sendo mais eficiente que este. Essa limitação pode ser contornada associando-se o FreshnessScope a outros métodos que analisem a qualidade interna da carne, em caso de necessidade.

Outra limitação é que o FreshnessScope foi construído para que as amostras de peixes sejam capturadas em ambiente controlado, mas entende-se ser este o passo inicial de uma pesquisa maior, que permitiu o entendimento do funcionamento dos processos de classificações de peixes em empresas, o entendimento de que informações de cores as amostras possuem, o entendimento de se estas informações possibilitam agrupar as amostras em níveis de frescor distintos e a exploração muitos modelos de AM. O SVC proposto nesta tese, por sua fácil mobilidade, mitiga esta limitação.

Por fim, outra limitação é que a quantidade de amostras dos conjuntos de dados foi insuficiente para que se pudesse testar modelos de DL. Para contornar esta limitação pode-se tanto aumentar o número de amostras, como usar modelos de DL pré-treinados em reconhecimento de padrões de cores.

### 5.3 SUGESTÕES DE TRABALHOS FUTUROS

Acredita-se que este trabalho poderá ganhar novas contribuições e desdobramentos se estudos futuros analisarem, entre outros, aspectos como:

- Aumentar o número de amostras para que arquiteturas de DL possam ser testadas;
- Aumentar o número de amostras para que arquiteturas de RNC possam ser testadas;
- Investigar a existência de modelos de DL pré-treinados que tenham conhecimento em cores, para classificar o frescor de carnes de peixes através de transferência de conhecimento;
- Realizar aumento artificial de imagens usando parte dos *pixels* das imagens digitais dos conjuntos de dados propostos nesta tese;
- Realizar aumento artificial de imagens através de filtros aplicados nas imagens digitais dos conjuntos de dados propostos nesta tese;

- Extrair características de textura das imagens das amostras e fazer testes em modelos de classificação;
- Redesenhar o estúdio que compõe o SVC para que tenha dimensões menores, tenha câmera fotográfica com auto foco integrada e possa ter a captura de imagens de amostras automatizada, com imagens enviadas para nuvem remota;
- Fazer uso de modelos com os classificadores e respectivos hiper parâmetros do Quadro 6, agora otimizados, para fins de comparação com os desempenhos dos modelos desenvolvidos nesta tese;
- Testar a solução em outros contextos, tanto de produtos cárneos, como de outros alimentos cuja coloração seja parâmetro observacional para classificação do frescor;
- Associar a solução FreshnessScope com e-Nose para analisar frescor com base em dois parâmetros sensoriais: cor e odor.

Por fim, ressalta-se que a presente pesquisa buscou evoluir a temática nos aspectos acadêmicos e profissionais, sendo os trabalhos futuros supracitados possíveis ações para galgar mais um degrau. Porém a segurança de alimentos ainda necessita de muitas ações e pesquisas para suprir demandas reprimidas da área. Que este trabalho e suas propostas futuras sirvam de alicerces para a evolução da área.

## REFERÊNCIAS

- ABD ELRAHMAN, Shaza M; ABRAHAM, Ajith. A review of class imbalance problem. **Journal of Network and Innovative Computing**, [s. l.], v. 1, n. 2013, p. 332–340, 2013.
- ABDI, Hervé. Partial least square regression (PLS regression). **Encyclopedia for research methods for the social sciences**, [s. l.], v. 6, n. 4, p. 792–795, 2003.
- ADI, Kusworo *et al.* Beef quality identification using color analysis and k-nearest neighbor classification. *In:* , 2015. **2015 4th International Conference on Instrumentation, Communications, Information Technology, and Biomedical Engineering (ICICI-BME)**. [S. l.]: IEEE, 2015. p. 180–184. Disponível em: <https://doi.org/10.1109/ICICI-BME.2015.7401359>
- AGOSTINELLI, Claudio. Robust stepwise regression. **Journal of Applied Statistics**, [s. l.], v. 29, n. 6, p. 825–840, 2002. Disponível em: <https://doi.org/https://doi.org/10.1080/02664760220136168>
- AL-SARAYREH, Mahmoud *et al.* Detection of red-meat adulteration by deep spectral–spatial features in hyperspectral images. **Journal of Imaging**, [s. l.], v. 4, n. 5, p. 63, 2018.
- ALAWAD, Wedad; ZOHDY, Mohamed; DEBNATH, Debatosh. Tuning hyperparameters of decision tree classifiers using computationally efficient schemes. *In:* , 2018. **2018 IEEE First International Conference on Artificial Intelligence and Knowledge Engineering (AIKE)**. [S. l.]: IEEE, 2018. p. 168–169.
- ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. Understanding of a convolutional neural network. *In:* , 2017. **2017 International Conference on Engineering and Technology (ICET)**. [S. l.]: IEEE, 2017. p. 1–6. Disponível em: <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- ALBON, Chris. **Machine learning with python cookbook: Practical solutions from preprocessing to deep learning**. [S. l.]: “ O’Reilly Media, Inc.”, 2018.
- ALCAYDE, Marco; ELIJORDE, Frank; BYUN, Yungcheol. Quality Monitoring System For Pork Meat Using Computer Vision. *In:* , 2019. **2019 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)**. [S. l.]: IEEE, 2019. p. 1–7. Disponível em: <https://doi.org/10.1109/ITEC-AP.2019.8903838>
- ALIBRAHIM, Hussain; LUDWIG, Simone A. Hyperparameter optimization: Comparing genetic algorithm against grid search and bayesian optimization. *In:* , 2021. **2021 IEEE Congress on Evolutionary Computation (CEC)**. [S. l.]: IEEE, 2021. p. 1551–1559.
- ALLAOUI, Mebarka; KHERFI, Mohammed Lamine; CHERIET, Abdelhakim. Considerably Improving Clustering Algorithms Using UMAP Dimensionality Reduction Technique: A Comparative Study. *In:* , 2020. **International Conference on Image and Signal Processing**. [S. l.]: Springer, 2020. p. 317–

325. Disponível em: [https://doi.org/10.1007/978-3-030-51935-3\\_34](https://doi.org/10.1007/978-3-030-51935-3_34)

ALOM, Md Zahangir *et al.* The history began from alexnet: A comprehensive survey on deep learning approaches. **arXiv preprint arXiv:1803.01164**, [s. l.], 2018.

ALPAYDIN, Ethem. **Introduction to machine learning**. [S. l.]: MIT press, 2020.

ALQEZWEENI, Mohie Mortadha *et al.* Efficient solving of boundary value problems using radial basis function networks learned by trust region method. **International Journal of Mathematics and Mathematical Sciences**, [s. l.], v. 2018, 2018. Disponível em: <https://doi.org/https://doi.org/10.1155/2018/9457578>

ALTMANN, André *et al.* Permutation importance: a corrected feature importance measure. **Bioinformatics**, [s. l.], v. 26, n. 10, p. 1340–1347, 2010. Disponível em: <https://doi.org/https://doi.org/10.1093/bioinformatics/btq134>

AMBESANGE, Sateesh *et al.* Multiple Heart Diseases Prediction using Logistic Regression with Ensemble and Hyper Parameter tuning Techniques. *In: , 2020. 2020 Fourth World Conference on Smart Trends in Systems, Security and Sustainability (WorldS4)*. [S. l.]: IEEE, 2020. p. 827–832. Disponível em: <https://doi.org/10.1109/WorldS450073.2020.9210404>

AMERINE, Maynard A; PANGBORN, Rose Marie; ROESSLER, Edward B. **Principles of sensory evaluation of food**. [S. l.]: Elsevier, 2013.

ANDRÉS, Sonia *et al.* Prediction of sensory characteristics of lamb meat samples by near infrared reflectance spectroscopy. **Meat science**, [s. l.], v. 76, n. 3, p. 509–516, 2007. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2007.01.011>

ARSALANE, Assia *et al.* An embedded system based on DSP platform and PCA-SVM algorithms for rapid beef meat freshness prediction and identification. **Computers and Electronics in Agriculture**, [s. l.], v. 152, p. 385–392, 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.07.031>

ARSALANE, Assia *et al.* The assessment of fresh and spoiled beef meat using a prototype device based on GigE Vision camera and DSP. **Journal of Food Measurement and Characterization**, [s. l.], v. 13, n. 3, p. 1730–1738, 2019. Disponível em: <https://doi.org/https://doi.org/10.1007/s11694-019-00090-y>

ARTERO, ALMIR OLIVETTE; TOMMASELLI, ANTONIO MARIA GARCIA. Limiarização Automática de Imagens Digitais. **Boletim de Ciências Geodésicas**, [s. l.], v. 6, n. 1, 2018.

ARVANITOYANNIS, Ioannis S; KOTSANOPOULOS, Konstantinos V; SAVVA, Amalia G. Use of ultrasounds in the food industry—Methods and effects on quality, safety, and organoleptic characteristics of foods: A review. **Critical reviews in food science and nutrition**, [s. l.], v. 57, n. 1, p. 109–128, 2017. Disponível em: <https://doi.org/https://doi.org/10.1080/10408398.2013.860514>

ASMARA, Rosa Andrie *et al.* Chicken meat freshness identification using the histogram color feature. *In: , 2017. 2017 International Conference on Sustainable Information Engineering and Technology (SIET)*. [S. l.]: IEEE, 2017. p. 57–61. Disponível em: <https://doi.org/10.1109/SIET.2017.8304109>

- AYYADEVARA, V Kishore. Decision tree. *In: PRO MACHINE LEARNING ALGORITHMS*. [S. l.]: Springer, 2018. p. 71–103.
- BALABAN, M O *et al.* Quantifying nonhomogeneous colors in agricultural materials. Part II: comparison of machine vision and sensory panel evaluations. **Journal of food science**, [s. l.], v. 73, n. 9, p. S438–S442, 2008. Disponível em: <https://doi.org/https://doi.org/10.1111/j.1750-3841.2008.00967.x>
- BALLESTER, Pedro; ARAUJO, Ricardo Matsumura. On the performance of GoogLeNet and AlexNet applied to sketches. *In:* , 2016. **Thirtieth AAAI Conference on Artificial Intelligence**. [S. l.: s. n.], 2016.
- BARBARO, Billy. **Tuning Hyperparameters for Online Learning**. [S. l.]: Case Western Reserve University, 2018. Disponível em: <https://doi.org/10.1109/BRACIS.2016.018>
- BARBIN, Douglas F *et al.* Digital image analyses as an alternative tool for chicken quality assessment. **Biosystems Engineering**, [s. l.], v. 144, p. 85–93, 2016. Disponível em: <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2016.01.015>
- BATISTA, Gustavo EAPA; PRATI, Ronaldo C; MONARD, Maria Carolina. A study of the behavior of several methods for balancing machine learning training data. **ACM SIGKDD explorations newsletter**, [s. l.], v. 6, n. 1, p. 20–29, 2004. Disponível em: <https://doi.org/https://doi.org/10.1145/1007730.1007735>
- BEKHIT, Alaa El-Din A *et al.* Total volatile basic nitrogen (TVB-N) and its role in meat spoilage: A review. **Trends in Food Science & Technology**, [s. l.], 2021. Disponível em: <https://doi.org/https://doi.org/10.1016/j.tifs.2021.01.006>
- BELEW, J B *et al.* Warner–Bratzler shear evaluations of 40 bovine muscles. **Meat science**, [s. l.], v. 64, n. 4, p. 507–512, 2003. Disponível em: [https://doi.org/https://doi.org/10.1016/S0309-1740\(02\)00242-5](https://doi.org/https://doi.org/10.1016/S0309-1740(02)00242-5)
- BENTO, Caronlina. **Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis**. [S. l.], 2021. Disponível em: <https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141>. Acesso em: 20 mar. 2021.
- BERGSTRA, James *et al.* Algorithms for hyper-parameter optimization. **Advances in neural information processing systems**, [s. l.], v. 24, 2011.
- BERGSTRA, James; BENGIO, Yoshua. Random search for hyper-parameter optimization. **Journal of machine learning research**, [s. l.], v. 13, n. 2, 2012.
- BERNARDO, Yago A A *et al.* Fish Quality Index Method: Principles, weaknesses, validation, and alternatives—A review. **Comprehensive Reviews in Food Science and Food Safety**, [s. l.], v. 19, n. 5, p. 2657–2676, 2020. Disponível em: <https://doi.org/https://doi.org/10.1111/1541-4337.12600>
- BERNER, Julius; ELBRÄCHTER, Dennis; GROHS, Philipp. How degenerate is the parametrization of neural networks with the ReLU activation function? **arXiv preprint arXiv:1905.09803**, [s. l.], 2019.

- BHANDARI, Naman. **ExtraTreesClassifier**. [S. l.], 2018. Disponível em: <https://medium.com/@namanbhandari/extratreesclassifier-8e7fc0502c7>. Acesso em: 22 mar. 2021.
- BHANDARI, Sijan. **How Nearest Centroid Classifier works?**. [S. l.], 2019. Disponível em: <http://sijanb.com.np/posts/how-nearest-centroid-classifier-works/>. Acesso em: 20 jun. 2021.
- BIERNACKI, Patrick; WALDORF, Dan. Snowball sampling: Problems and techniques of chain referral sampling. **Sociological methods & research**, [s. l.], v. 10, n. 2, p. 141–163, 1981. Disponível em: <https://doi.org/https://doi.org/10.1177/004912418101000205>
- BISONG, Ekaba. Optimization for Machine Learning: Gradient Descent. *In*: BUILDING MACHINE LEARNING AND DEEP LEARNING MODELS ON GOOGLE CLOUD PLATFORM. [S. l.]: Springer, 2019. p. 203–207.
- BLOTTA, E *et al.* Enhancement of medical images in HSI color space. *In*: , 2011. **Journal of Physics: Conference Series**. [S. l.]: IOP Publishing, 2011. p. 12041.
- BOEHMKE, Brad; GREENWELL, Brandon. **Hands-on machine learning with R**. [S. l.]: Chapman and Hall/CRC, 2019.
- BONACCORSO, Giuseppe. **ML Algorithms addendum: Passive Aggressive Algorithms**. [S. l.], 2017. Disponível em: <https://www.bonaccorso.eu/2017/10/06/ml-algorithms-addendum-passive-aggressive-algorithms/>. Acesso em: 21 mar. 2021.
- BOSWELL, Dustin. **Introduction to Support Vector Machines**. [S. l.], 2002. Disponível em: [https://docs.opencv.org/3.4/d1/d73/tutorial\\_introduction\\_to\\_svm.html](https://docs.opencv.org/3.4/d1/d73/tutorial_introduction_to_svm.html). Acesso em: 25 abr. 2021.
- BOTTOU, Léon. Stochastic gradient descent tricks. *In*: NEURAL NETWORKS: TRICKS OF THE TRADE. [S. l.]: Springer, 2012. p. 421–436. Disponível em: [https://doi.org/https://doi.org/10.1007/978-3-642-35289-8\\_25](https://doi.org/https://doi.org/10.1007/978-3-642-35289-8_25)
- BOWLER, Alexander L; BAKALIS, Serafim; WATSON, Nicholas J. Monitoring mixing processes using ultrasonic sensors and machine learning. **Sensors**, [s. l.], v. 20, n. 7, p. 1813, 2020. Disponível em: <https://doi.org/https://doi.org/10.3390/s20071813>
- BREIMAN, Leo. Random forests. **Machine learning**, [s. l.], v. 45, n. 1, p. 5–32, 2001. Disponível em: <https://doi.org/https://doi.org/10.1023/A:1010933404324>
- BREMNER, H Allan; SAKAGUCHI, Morihiko. A critical look at whether ‘freshness’ can be determined. **Journal of Aquatic Food Product Technology**, [s. l.], v. 9, n. 3, p. 5–25, 2000. Disponível em: [https://doi.org/10.1300/J030v09n03\\_02](https://doi.org/10.1300/J030v09n03_02)
- BREUEL, Thomas M. The effects of hyperparameters on SGD training of neural networks. **arXiv preprint arXiv:1508.02788**, [s. l.], 2015.
- BRIJAIN, Mr *et al.* A survey on decision tree algorithm for classification. [s. l.], 2014.

BRO, Rasmus; SMILDE, Age K. Principal component analysis. **Analytical methods**, [s. l.], v. 6, n. 9, p. 2812–2831, 2014. Disponível em: <https://doi.org/10.1039/C3AY41907J>

BROSNAN, Tadhg; SUN, Da-Wen. Improving quality inspection of food products by computer vision—a review. **Journal of food engineering**, [s. l.], v. 61, n. 1, p. 3–16, 2004. Disponível em: [https://doi.org/https://doi.org/10.1016/S0260-8774\(03\)00183-3](https://doi.org/https://doi.org/10.1016/S0260-8774(03)00183-3)

BROWNLEE, J. **A Gentle Introduction to Imbalanced Classification**. [S. l.], 2020a. Disponível em: <https://machinelearningmastery.com/what-is-imbalanced-classification/>. Acesso em: 5 maio 2021.

BROWNLEE, J. **A Gentle Introduction to the Gradient Boosting Algorithm for Machine Learning**. [S. l.], 2020b. Disponível em: <https://machinelearningmastery.com/gentle-introduction-gradient-boosting-algorithm-machine-learning/>. Acesso em: 5 maio 2021.

BROWNLEE, J. **Auto-Sklearn for Automated Machine Learning in Python**. [S. l.], 2020c. Disponível em: <https://machinelearningmastery.com/auto-sklearn-for-automated-machine-learning-in-python/>. Acesso em: 4 mar. 2021.

BROWNLEE, J. **Boosting and AdaBoost for Machine Learning**. [S. l.], 2020d. Disponível em: <https://machinelearningmastery.com/boosting-and-adaboost-for-machine-learning/>. Acesso em: 21 maio 2021.

BROWNLEE, J. **How to Develop an Extra Trees Ensemble with Python**. [S. l.], 2020e. Disponível em: <https://machinelearningmastery.com/extra-trees-ensemble-with-python/>. Acesso em: 22 maio 2021.

BROWNLEE, J. **How to Develop Voting Ensembles With Python**. [S. l.], 2020f. Disponível em: <https://machinelearningmastery.com/voting-ensembles-with-python/>. Acesso em: 21 mar. 2021.

BROWNLEE, J. **How to Use StandardScaler and MinMaxScaler Transforms in Python**. [S. l.], 2020g. Disponível em: <https://machinelearningmastery.com/standardscaler-and-minmaxscaler-transforms-in-python/>. Acesso em: 5 maio 2021.

BROWNLEE, J. **Linear Discriminant Analysis With Python**. [S. l.], 2020h. Disponível em: <https://machinelearningmastery.com/linear-discriminant-analysis-with-python/>. Acesso em: 25 jun. 2021.

BROWNLEE, J. **Nearest Shrunken Centroids With Python**. [S. l.], 2020i. Disponível em: <https://machinelearningmastery.com/nearest-shrunken-centroids-with-python/>. Acesso em: 5 abr. 2021.

BROWNLEE, J. **Tune Hyperparameters for Classification Machine Learning Algorithms**. [S. l.], 2020j. Disponível em: <https://machinelearningmastery.com/hyperparameters-for-classification-machine-learning-algorithms/>. Acesso em: 21 jun. 2021.

BURGER, Wilhelm; BURGE, Mark J. **Digital image processing: an algorithmic introduction using Java**. [S. l.]: Springer, 2016.

BURGES, Christopher J C. **Dimension reduction: A guided tour**. [S. l.]: Now

Publishers Inc, 2010.

CAO, Weipeng *et al.* Some tricks in parameter selection for extreme learning machine. *In:* , 2017. **IOP conference series: materials science and engineering**. [S. l.]: IOP Publishing, 2017. p. 12002.

CARLUCCI, Domenico *et al.* Consumer purchasing behaviour towards fish and seafood products. Patterns and insights from a sample of international studies. **Appetite**, [s. l.], v. 84, p. 212–227, 2015. Disponível em: <https://doi.org/https://doi.org/10.1016/j.appet.2014.10.008>

CARROLL, Walter F. SUSHI: Globalization through food culture: towards a study of global food networks. [s. l.], 2009.

CARUANA, Rich *et al.* Ensemble selection from libraries of models. *In:* , 2004. **Proceedings of the twenty-first international conference on Machine learning**. [S. l.: s. n.], 2004. p. 18.

CARVALHO, Diogo V; PEREIRA, Eduardo M; CARDOSO, Jaime S. Machine learning interpretability: A survey on methods and metrics. **Electronics**, [s. l.], v. 8, n. 8, p. 832, 2019. Disponível em: <https://doi.org/https://doi.org/10.3390/electronics8080832>

CHANG, Jun-Dong *et al.* HSV-based color texture image classification using wavelet transform and motif patterns. **Journal of Computers**, [s. l.], v. 20, n. 4, p. 63–69, 2010.

CHANG, Young-Chang; REID, John F. RGB calibration for color image analysis in machine vision. **IEEE Transactions on image processing**, [s. l.], v. 5, n. 10, p. 1414–1422, 1996. Disponível em: <https://doi.org/10.1109/83.536890>

CHAWLA, Nitesh V *et al.* SMOTE: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, [s. l.], v. 16, p. 321–357, 2002. Disponível em: <https://doi.org/https://doi.org/10.1613/jair.953>

CHEN, Quansheng *et al.* Evaluation of chicken freshness using a low-cost colorimetric sensor array with AdaBoost–OLDA classification algorithm. **LWT-Food Science and Technology**, [s. l.], v. 57, n. 2, p. 502–507, 2014. Disponível em: <https://doi.org/https://doi.org/10.1016/j.lwt.2014.02.031>

CHEN, Yingyi. **How to generate an LDA Topic Model for Text Analysis**. [S. l.], 2018. Disponível em: <https://yanlinc.medium.com/how-to-build-a-lda-topic-model-using-from-text-601cdcbfd3a6>. Acesso em: 26 jun. 2021.

CHENG, Jun-Hu *et al.* Development of hyperspectral imaging coupled with chemometric analysis to monitor K value for evaluation of chemical spoilage in fish fillets. **Food Chemistry**, [s. l.], v. 185, p. 245–253, 2015. Disponível em: <https://doi.org/https://doi.org/10.1016/j.foodchem.2015.03.111>

CHERNOV, Vladimir; ALANDER, Jarmo; BOCHKO, Vladimir. Integer-based accurate conversion between RGB and HSV color spaces. **Computers & Electrical Engineering**, [s. l.], v. 46, p. 328–337, 2015. Disponível em: <https://doi.org/https://doi.org/10.1016/j.compeleceng.2015.08.005>

CHIENG, Hock Hung *et al.* Flatten-T Swish: a thresholded ReLU-Swish-like activation function for deep learning. **arXiv preprint arXiv:1812.06247**, [s. l.],

2018.

CIVILLE, Gail Vance; CARR, B Thomas. **Sensory evaluation techniques**. [S. l.]: CRC Press, 2015.

CLAESEN, Marc; DE MOOR, Bart. Hyperparameter search in machine learning. **arXiv preprint arXiv:1502.02127**, [s. l.], 2015.

CONNOLLY, Christine; FLEISS, Thomas. A study of efficiency and accuracy in the transformation from RGB to CIELAB color space. **IEEE transactions on image processing**, [s. l.], v. 6, n. 7, p. 1046–1048, 1997. Disponível em: <https://doi.org/10.1109/83.597279>

CRAMMER, Koby *et al.* Online passive aggressive algorithms. [s. l.], 2006.

CUI, Jinshi; CUI, Chengxun. Non-destructive Evaluation of Salmon and Tuna Freshness in a Room Temperature Incubation Environment Using a Portable Visible/Near-infrared Imaging Spectrometer. **Transactions of the ASABE**, [s. l.], p. 0, 2021. Disponível em: <https://doi.org/10.13031/trans.13858>

DAVIS, Jesse; GOADRIC, Mark. The relationship between Precision-Recall and ROC curves. *In*: , 2006. **Proceedings of the 23rd international conference on Machine learning**. [S. l.: s. n.], 2006. p. 233–240. Disponível em: <https://doi.org/https://doi.org/10.1145/1143844.1143874>

DE ALVARENGA JÚNIOR, Wagner José. Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária. [s. l.], 2018.

DEMŠAR, Janez. Statistical comparisons of classifiers over multiple data sets. **The Journal of Machine Learning Research**, [s. l.], v. 7, p. 1–30, 2006.

DIETTERICH, Thomas G. Ensemble methods in machine learning. *In*: , 2000. **International workshop on multiple classifier systems**. [S. l.]: Springer, 2000. p. 1–15. Disponível em: [https://doi.org/https://doi.org/10.1007/3-540-45014-9\\_1](https://doi.org/https://doi.org/10.1007/3-540-45014-9_1)

DING, Bin; QIAN, Huimin; ZHOU, Jun. Activation functions and their characteristics in deep neural networks. *In*: , 2018. **2018 Chinese control and decision conference (CCDC)**. [S. l.]: IEEE, 2018. p. 1836–1841. Disponível em: <https://doi.org/10.1109/CCDC.2018.8407425>

DJEKIC, Ilija *et al.* Review on characteristics of trained sensory panels in food science. **Journal of Texture Studies**, [s. l.], 2021.

DONGES, Niklas. **A Complete Guide to the Random Forest Algorithm**. [S. l.], 2021a. Disponível em: <https://builtin.com/data-science/random-forest-algorithm>. Acesso em: 10 ago. 2021.

DONGES, Niklas. **Gradient Descent: An Introduction to 1 of Machine Learning's Most Popular Algorithms**. [S. l.], 2021b. Disponível em: <https://builtin.com/data-science/gradient-descent>. Acesso em: 22 ago. 2021.

DUAN, Kaibo; KEERTHI, S Sathiya; POO, Aun Neow. Evaluation of simple performance measures for tuning SVM hyperparameters. **Neurocomputing**, [s. l.], v. 51, p. 41–59, 2003. Disponível em:

[https://doi.org/https://doi.org/10.1016/S0925-2312\(02\)00601-X](https://doi.org/https://doi.org/10.1016/S0925-2312(02)00601-X)

DUBEY, Arun Kumar; JAIN, Vanita. Comparative study of convolution neural network's relu and leaky-relu activation functions. *In: APPLICATIONS OF COMPUTING, AUTOMATION AND WIRELESS SYSTEMS IN ELECTRICAL ENGINEERING*. [S. l.]: Springer, 2019. p. 873–880. Disponível em: [https://doi.org/https://doi.org/10.1007/978-981-13-6772-4\\_76](https://doi.org/https://doi.org/10.1007/978-981-13-6772-4_76)

DUTTA, Malay Kishore *et al.* Image processing based method to assess fish quality and freshness. **Journal of Food Engineering**, [s. l.], v. 177, p. 50–58, 2016. Disponível em: <https://doi.org/10.1016/j.jfoodeng.2015.12.018>

FEIFEI, Tao; YANKUN, Peng; YONGYU, Li. Feature extraction method of hyperspectral scattering images for prediction of total viable count in pork meat. **International Journal of Agricultural and Biological Engineering**, [s. l.], v. 8, n. 4, p. 95–105, 2015. Disponível em: <https://doi.org/10.3965/j.ijabe.20150804.1559>

FERNÁNDEZ, Juana; PÉREZ-ÁLVAREZ, Jose A; FERNÁNDEZ-LÓPEZ, José A. Thiobarbituric acid test for monitoring lipid oxidation in meat. **Food chemistry**, [s. l.], v. 59, n. 3, p. 345–353, 1997.

FEURER, Matthias *et al.* Efficient and Robust Automated Machine Learning, 2015. **Advances in neural information processing systems**, [s. l.], n. 28, 2015.

FOWLER, Stephanie M *et al.* Preliminary investigation of the use of Raman spectroscopy to predict meat and eating quality traits of beef loins. **Meat science**, [s. l.], v. 138, p. 53–58, 2018. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2018.01.002>

FREUND, Yoav; SCHAPIRE, Robert E. A decision-theoretic generalization of on-line learning and an application to boosting. **Journal of computer and system sciences**, [s. l.], v. 55, n. 1, p. 119–139, 1997. Disponível em: <https://doi.org/https://doi.org/10.1006/jcss.1997.1504>

GAO, Rongfang; LIU, Zhanyu. An Improved AdaBoost Algorithm for Hyperparameter Optimization. *In: , 2020. Journal of Physics: Conference Series*. [S. l.]: IOP Publishing, 2020. p. 12048.

GARCIA, Simone C. O uso de árvores de decisão na descoberta de conhecimento na área da saúde. [s. l.], 2003.

GEURTS, Pierre; ERNST, Damien; WEHENKEL, Louis. Extremely randomized trees. **Machine learning**, [s. l.], v. 63, n. 1, p. 3–42, 2006. Disponível em: <https://doi.org/https://doi.org/10.1007/s10994-006-6226-1>

GHASEMI-VARNAMKHAHI, Mahdi *et al.* Application of image analysis combined with computational expert approaches for shrimp freshness evaluation. **International Journal of Food Properties**, [s. l.], v. 19, n. 10, p. 2202–2222, 2016. Disponível em: <https://doi.org/https://doi.org/10.1080/10942912.2015.1118386>

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. [S. l.]: 6. ed. Editora Atlas SA, 2008.

GOÑI, Sandro M; SALVADORI, Viviana O. Color measurement: comparison of colorimeter vs. computer vision system. **Journal of Food Measurement and Characterization**, [s. l.], v. 11, n. 2, p. 538–547, 2017.

GONZÁLEZ-MOHINO, Alberto *et al.* Changes of Ultrasonic Parameters as a Tool to Determine the Influence of Cooking in Pork Loin Samples. **Acta Acustica united with Acustica**, [s. l.], v. 105, n. 6, p. 943–952, 2019. Disponível em: <https://doi.org/https://doi.org/10.3813/AAA.919375>

GONZALEZ, R.; WOODS, R.; EDDINS, S. **Digital image processing using MATLAB**. 3. ed. [S. l.]: Gatesmark, 2020.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. [S. l.]: MIT press, 2016.

GOON, Shatabdi *et al.* Fish marketing status with formalin treatment in Bangladesh. **International Journal of Public Health Science (IJPBS)**, [s. l.], v. 3, n. 2, p. 95, 2014.

GUENTHER, Nick; SCHONLAU, Matthias. Support vector machines. **The Stata Journal**, [s. l.], v. 16, n. 4, p. 917–937, 2016. Disponível em: <https://doi.org/https://doi.org/10.1177/1536867X1601600407>

GUNDOGDU, Ozge *et al.* Multiplicative neuron model artificial neural network based on Gaussian activation function. **Neural Computing and Applications**, [s. l.], v. 27, n. 4, p. 927–935, 2016. Disponível em: <https://doi.org/https://doi.org/10.1007/s00521-015-1908-x>

HAMERLY, Greg; ELKAN, Charles. Learning the k in k-means. **Advances in neural information processing systems**, [s. l.], v. 16, p. 281–288, 2004.

HAN, Fangkai *et al.* Detection of beef adulterated with pork using a low-cost electronic nose based on colorimetric sensors. **Foods**, [s. l.], v. 9, n. 2, p. 193, 2020. Disponível em: <https://doi.org/https://doi.org/10.3390/foods9020193>

HAN, Hong-Gui; QIAO, Jun-Fei. Adaptive computation algorithm for RBF neural network. **IEEE Transactions on Neural Networks and Learning Systems**, [s. l.], v. 23, n. 2, p. 342–347, 2011. Disponível em: <https://doi.org/10.1109/TNNLS.2011.2178559>

HART, Peter E; STORK, David G; DUDA, Richard O. **Pattern classification**. [S. l.]: Wiley Hoboken, 2000.

HASTIE, Trevor *et al.* Multi-class adaboost. **Statistics and its Interface**, [s. l.], v. 2, n. 3, p. 349–360, 2009.

HASTIE, Trevor. Ridge regularization: An essential concept in data science. **Technometrics**, [s. l.], v. 62, n. 4, p. 426–433, 2020. Disponível em: <https://doi.org/https://doi.org/10.1080/00401706.2020.1791959>

HAWKINS, Douglas M. The problem of overfitting. **Journal of chemical information and computer sciences**, [s. l.], v. 44, n. 1, p. 1–12, 2004. Disponível em: <https://doi.org/https://doi.org/10.1021/ci0342472>

HE, Haibo *et al.* ADASYN: Adaptive synthetic sampling approach for imbalanced learning. *In:* , 2008. **2008 IEEE international joint conference on**

**neural networks (IEEE world congress on computational intelligence).** [S. l.]: IEEE, 2008. p. 1322–1328. Disponível em: <https://doi.org/10.1109/IJCNN.2008.4633969>

HERRERO, Ana M. Raman spectroscopy a promising technique for quality assessment of meat and fish: A review. **Food chemistry**, [s. l.], v. 107, n. 4, p. 1642–1651, 2008. Disponível em: <https://doi.org/https://doi.org/10.1016/j.foodchem.2007.10.014>

HÖHL, K; BUSCH-STOCKFISCH, M. The influence of sensory training on taste sensitivity. Effects on sweet and bitter perception over a half-year period. **Ernahrungs Umschau**, [s. l.], v. 62, n. 12, p. 208–215, 2015.

HOOKE, Sara *et al.* Evaluating feature importance estimates. [s. l.], 2018.

HOSSEINPOUR, Soleiman; ILKHCHI, Ali Hakimi; AGHBASHLO, Mortaza. An intelligent machine vision-based smartphone app for beef quality evaluation. **Journal of Food Engineering**, [s. l.], v. 248, p. 9–22, 2019. Disponível em: <https://doi.org/10.1016/j.jfoodeng.2018.12.009>

HUANG, Guang-Bin; ZHU; SIEW, Chee-Kheong. Extreme learning machine: theory and applications. **Neurocomputing**, [s. l.], v. 70, n. 1–3, p. 489–501, 2006. Disponível em: <https://doi.org/https://doi.org/10.1016/j.neucom.2005.12.126>

ISSAC, Ashish; DUTTA, Malay Kishore; SARKAR, Biplab. Computer vision based method for quality and freshness check for fish from segmented gills. **Computers and Electronics in Agriculture**, [s. l.], v. 139, p. 10–21, 2017. Disponível em: <https://doi.org/https://doi.org/10.1016/j.compag.2017.05.006>

JACKSON, Philip C. **Introduction to artificial intelligence**. [S. l.]: Courier Dover Publications, 2019.

JAIN, Abhishek; GUPTA, Richa. Gaussian filter threshold modulation for filtering flat and texture area of an image. *In*: , 2015. **2015 International Conference on Advances in Computer Engineering and Applications**. [S. l.]: IEEE, 2015. p. 760–763. Disponível em: <https://doi.org/10.1109/ICACEA.2015.7164804>

JAMEL, Thamer M; KHAMMAS, Ban M. Implementation of a sigmoid activation function for neural network using FPGA. *In*: , 2012. **13th Scientific Conference of Al-Ma'moon University College**. [S. l.: s. n.], 2012.

JAMESON, Dorothea; HURVICH, Leo M. Some quantitative aspects of an opponent-colors theory. I. Chromatic responses and spectral saturation. **JOSA**, [s. l.], v. 45, n. 7, p. 546–552, 1955. Disponível em: <https://doi.org/10.1364/JOSA.45.000546>

JANG, Eunseok *et al.* Grade prediction of meat quality in Korean native cattle using Neural Network. *In*: , 2015. **2015 International Conference on Fuzzy Theory and Its Applications (iFUZZY)**. [S. l.]: IEEE, 2015. p. 28–33. Disponível em: <https://doi.org/10.1109/iFUZZY.2015.7391889>

JAYASUNDARA, Dhananjaya *et al.* Multispectral Imaging for Automated Fish Quality Grading. *In*: , 2020. **2020 IEEE 15th International Conference on**

**Industrial and Information Systems (ICIIS)**. [S. l.]: IEEE, 2020. p. 321–326. Disponível em: <https://doi.org/10.1109/ICIIS51140.2020.9342726>

JEYANTHI, S; SUBADRA, M. Implementation of single neuron using various activation functions with FPGA. *In: , 2014. 2014 IEEE International Conference on Advanced Communications, Control and Computing Technologies*. [S. l.]: IEEE, 2014. p. 1126–1131. Disponível em: <https://doi.org/10.1109/ICACCCT.2014.7019273>

JIA, Wenshen *et al.* Electronic noses as a powerful tool for assessing meat quality: A mini review. **Food Analytical Methods**, [s. l.], v. 11, n. 10, p. 2916–2924, 2018. Disponível em: <https://doi.org/https://doi.org/10.1007/s12161-018-1283-1>

JIANG, Hongyao *et al.* Application of electronic tongue for fresh foods quality evaluation: A review. **Food Reviews International**, [s. l.], v. 34, n. 8, p. 746–769, 2018. Disponível em: <https://doi.org/https://doi.org/10.1080/87559129.2018.1424184>

JIANG, Liangxiao; ZHANG, Harry; SU, Jiang. Learning k-nearest neighbor naive bayes for ranking. *In: , 2005. International conference on advanced data mining and applications*. [S. l.]: Springer, 2005. p. 175–185.

JIMÉNEZ-GUARNEROS, Magdiel; GRANDE-BARRETO, Jonas; RANGEL-MAGDALENO, Jose de Jesus. Multiclass Incremental Learning for Fault Diagnosis in Induction Motors Using Fine-Tuning with a Memory of Exemplars and Nearest Centroid Classifier. **Shock and Vibration**, [s. l.], v. 2021, 2021. Disponível em: <https://doi.org/https://doi.org/10.1155/2021/6627740>

JURISTO, Natalia; MORENO, Ana M. **Basics of software engineering experimentation**. [S. l.]: Springer Science & Business Media, 2013.

KAPPAL, Sunil. Data normalization using median median absolute deviation MMAD based Z-score for robust predictions vs. min–max normalization. **London Journal of Research in Science: Natural and Formal**, [s. l.], 2019.

KARTAKOULLIS, Andreas *et al.* Hyperspectral Imaging for Assessing the Quality Attributes of Cured Pork Loin. *In: , 2018. 2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. [S. l.]: IEEE, 2018. p. 1–4. Disponível em: <https://doi.org/10.1109/WHISPERS.2018.8747235>

KERR, Douglas A. The CIE XYZ and xyY color spaces. **Colorimetry**, [s. l.], v. 1, n. 1, p. 1–16, 2010.

KETKAR, Nikhil. Stochastic gradient descent. *In: DEEP LEARNING WITH PYTHON*. [S. l.]: Springer, 2017. p. 113–132. Disponível em: [https://doi.org/https://doi.org/10.1007/978-1-4842-2766-4\\_8](https://doi.org/https://doi.org/10.1007/978-1-4842-2766-4_8)

KHALID, Samina; KHALIL, Tehmina; NASREEN, Shamila. A survey of feature selection and feature extraction techniques in machine learning. *In: , 2014. 2014 science and information conference*. [S. l.]: IEEE, 2014. p. 372–378. Disponível em: <https://doi.org/10.1109/SAI.2014.6918213>

KIANI, Sajad; MINAEI, Saeid; GHASEMI-VARNAMKHASTI, Mahdi. Fusion of

artificial senses as a robust approach to food quality assessment. **Journal of Food Engineering**, [s. l.], v. 171, p. 230–239, 2016. Disponível em: <https://doi.org/https://doi.org/10.1016/j.jfoodeng.2015.10.007>

KIBRIYA, Ashraf M *et al.* Multinomial naive bayes for text categorization revisited. *In:* , 2004. **Australasian Joint Conference on Artificial Intelligence**. [S. l.]: Springer, 2004. p. 488–499.

KITCHENHAM, Barbara; CHARTERS, Stuart. Guidelines for performing systematic literature reviews in software engineering. [s. l.], 2007.

KLEINBAUM, David G *et al.* **Logistic regression**. [S. l.]: Springer, 2002.

KORKEALA, Hannu *et al.* Determination of pH in meat. **Meat Science**, [s. l.], v. 18, n. 2, p. 121–132, 1986. Disponível em: [https://doi.org/https://doi.org/10.1016/0309-1740\(86\)90088-4](https://doi.org/https://doi.org/10.1016/0309-1740(86)90088-4)

KOZIOLEK, Heiko. Goal, question, metric. *In:* DEPENDABILITY METRICS. [S. l.]: Springer, 2008. p. 39–42. Disponível em: [https://doi.org/https://doi.org/10.1007/978-3-540-68947-8\\_6](https://doi.org/https://doi.org/10.1007/978-3-540-68947-8_6)

KRAMER, Oliver. K-nearest neighbors. *In:* DIMENSIONALITY REDUCTION WITH UNSUPERVISED NEAREST NEIGHBORS. [S. l.]: Springer, 2013. p. 13–23. Disponível em: [https://doi.org/https://doi.org/10.1007/978-3-642-38652-7\\_2](https://doi.org/https://doi.org/10.1007/978-3-642-38652-7_2)

KRITHIGA, R; ILAVARASAN, E. Hyperparameter tuning of AdaBoost algorithm for social spammer identification. **International Journal of Pervasive Computing and Communications**, [s. l.], 2021. Disponível em: <https://doi.org/https://doi.org/10.1108/IJPC-09-2020-0130>

KUEHNI, Rolf G. Color space and its divisions. **Color Research & Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Soc**, [s. l.], v. 26, n. 3, p. 209–222, 2001.

KUMAR, Vipin; MINZ, Sonajharia. Feature selection: a literature review. **SmartCR**, [s. l.], v. 4, n. 3, p. 211–229, 2014. Disponível em: <https://doi.org/https://doi.org/10.6029/smartcr.2014.03.007>

LABBE, D; RYTZ, A; HUGI, A. Training is a critical step to obtain reliable product profiles in a real food industry context. **Food Quality and Preference**, [s. l.], v. 15, n. 4, p. 341–348, 2004.

LALABADI, Hosna Mohammadi; SADEGHI, Morteza; MIREEI, Seyed Ahmad. Fish freshness categorization from eyes and gills color features using multi-class artificial neural network and support vector machines. **Aquacultural Engineering**, [s. l.], v. 90, p. 102076, 2020. Disponível em: <https://doi.org/https://doi.org/10.1016/j.aquaeng.2020.102076>

LANGER, Judith *et al.* Present and future of surface-enhanced Raman scattering. **ACS nano**, [s. l.], v. 14, n. 1, p. 28–117, 2019. Disponível em: <https://doi.org/https://doi.org/10.1021/acsnano.9b04224>

LEE, Loong Chuen; LIONG, Choong-Yeun; JEMAIN, Abdul Aziz. Partial least squares-discriminant analysis (PLS-DA) for classification of high-dimensional

(HD) data: a review of contemporary practice strategies and knowledge gaps.

**Analyst**, [s. l.], v. 143, n. 15, p. 3526–3539, 2018. Disponível em:

<https://doi.org/10.1039/c8an00599k>

LIN, Jie *et al.* Quantum-enhanced least-square support vector machine:

Simplified quantum algorithm and sparse solutions. **Physics Letters A**, [s. l.], v. 384, n. 25, p. 126590, 2020.

LIU, Hai *et al.* Application of hyperspectral imaging technology in meat quality evaluation. **Shipin Kexue/Food Science**, [s. l.], v. 39, n. 11, p. 276–283, 2018.

LIU, Qingshan; WANG, Jun. A one-layer recurrent neural network with a discontinuous hard-limiting activation function for quadratic programming. **IEEE transactions on neural networks**, [s. l.], v. 19, n. 4, p. 558–570, 2008.

Disponível em: <https://doi.org/10.1109/TNN.2007.910736>

LIU, Tao; QIU, Tianshuang; LUAN, Shengyang. Hyperbolic-tangent-function-based cyclic correlation: Definition and theory. **Signal Processing**, [s. l.], v. 164, p. 206–216, 2019. Disponível em:

<https://doi.org/https://doi.org/10.1016/j.sigpro.2019.06.001>

LUGATIMAN, Kenan *et al.* Tuna Meat Freshness Classification through Computer Vision. *In*: , 2019. **2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)**. [S. l.]: IEEE, 2019. p. 1–6. Disponível em: <https://doi.org/10.1109/HNICEM48295.2019.9073468>

LV, Riqin *et al.* Analysis of fish spoilage by gas chromatography–mass spectrometry and electronic olfaction bionic system. **Journal of Food Safety**, [s. l.], v. 38, n. 6, p. e12557, 2018. Disponível em:

<https://doi.org/https://doi.org/10.1111/jfs.12557>

MALDONADO, Alejandro Isabel Luna; RODRIGUEZ-FUENTES, Humberto; CONTRERAS, Juan Antonio Vidales. **Hyperspectral Imaging in Agriculture, Food and Environment**. [S. l.]: BoD–Books on Demand, 2018.

MANESSI, Franco; ROZZA, Alessandro. Learning combinations of activation functions. *In*: , 2018. **2018 24th International Conference on Pattern Recognition (ICPR)**. [S. l.]: IEEE, 2018. p. 61–66. Disponível em:

<https://doi.org/10.1109/ICPR.2018.8545362>

MANTOVANI, Rafael G *et al.* Hyper-parameter tuning of a decision tree induction algorithm. *In*: , 2016. **2016 5th Brazilian Conference on Intelligent Systems (BRACIS)**. [S. l.]: IEEE, 2016. p. 37–42. Disponível em:

<https://doi.org/10.1109/AIKE.2018.00038>

MARCONI, M de A; LAKATOS, E M. Fundamentos da Metodologia Científica. 7ª Edição–São Paulo: Atlas. [s. l.], 2010.

MARZBAN, Caren. The ROC curve and the area under it as performance measures. **Weather and Forecasting**, [s. l.], v. 19, n. 6, p. 1106–1114, 2004.

Disponível em: <https://doi.org/https://doi.org/10.1175/825.1>

MCANDREW, Alasdair. An introduction to digital image processing with matlab notes for scm2511 image processing. **School of Computer Science and**

**Mathematics, Victoria University of Technology**, [s. l.], v. 264, n. 1, p. 1–264, 2004.

MCINTYRE, Robert M; BLASHFIELD, Roger K. A nearest-centroid technique for evaluating the minimum-variance clustering procedure. **Multivariate Behavioral Research**, [s. l.], v. 15, n. 2, p. 225–238, 1980. Disponível em: [https://doi.org/https://doi.org/10.1207/s15327906mbr1502\\_7](https://doi.org/https://doi.org/10.1207/s15327906mbr1502_7)

MEDEIROS, E. C.; ALMEIDA, L. M.; TEIXEIRA FILHO, J. G. A. Computer Vision and Machine Learning for Tuna and Salmon Meat Classification. **Informatics**, [s. l.], v. 8, n. 4, p. 70, 2021. Disponível em: <https://doi.org/https://doi.org/10.3390/informatics8040070>

MEDEIROS, E. C.; ALMEIDA, L. M.; TEIXEIRA FILHO, J. G. A. Construction Of A Computer Vision System For Tuna Meat Classification: A Case Study Of Sensory Analysis Based On Color Parameters. **International Journal of Science & Research Methodology**, [s. l.], v. 17, n. 2, p. 260–273, 2020a.

MEDEIROS, E. C.; ALMEIDA, L. M.; TEIXEIRA FILHO, J. G. A. Evaluation of the freshness of meat-based on computer vision: systematic literature mapping. **International Journal of Development Research**, [s. l.], v. 10, n. 12, p. 43138–43145, 2020b.

METZ, Jean. **Interpretação de clusters gerados por algoritmos de clustering hierárquico**. [S. l.]: Universidade de São Paulo, 2006.

MIHALJEV, Željko A *et al.* Comparison of the Kjeldahl method, Dumas method and NIR method for total nitrogen determination in meat and meat products. **gas**, [s. l.], v. 2, n. 7, 2015.

MOHAMMADI, Vahid; GHASEMI-VARNAMKHAHI, Mahdi; GONZÁLEZ, Luciano Adrián. Analytical measurements of ultrasound propagation in dairy products: A review. **Trends in Food Science & Technology**, [s. l.], v. 61, p. 38–48, 2017. Disponível em: <https://doi.org/https://doi.org/10.1016/j.tifs.2016.12.004>

MOHANTY, S N *et al.* **Machine Learning for Healthcare Applications**. [S. l.]: Wiley, 2021. *E-book*.

MOHIBULLAH, Md; HOSSAIN, Md Zakir; HASAN, Mahmudul. Comparison of euclidean distance function and manhattan distance function using k-medoids. **International Journal of Computer Science and Information Security**, [s. l.], v. 13, n. 10, p. 61, 2015.

MOLNAR, Christoph. **Interpretable machine learning**. [S. l.]: Lulu. com, 2020.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, [s. l.], v. 1, n. 1, p. 32, 2003.

MOON, Eui Jung *et al.* Evaluation of salmon, tuna, and beef freshness using a portable spectrometer. **Sensors**, [s. l.], v. 20, n. 15, p. 4299, 2020. Disponível em: <https://doi.org/10.3390/s20154299>.

MOREIRA, S. **Rede Neural Perceptron Multicamadas**. [S. l.], 2018. Disponível em: <https://medium.com/ensina-ai/rede-neural-perceptron->

multicamadas-f9de8471f1a9. Acesso em: 5 maio 2021.

MOVAHEDIAN, Hamid; BAKHTIAR, Mehrdad Sharif. Design and sensitivity analysis of feed-forward neural ADC's. *In:* , 2004. **2004 IEEE International Symposium on Circuits and Systems (IEEE Cat. No. 04CH37512)**. [S. l.]: IEEE, 2004. p. V–V. Disponível em: <https://doi.org/10.1109/ISCAS.2004.1329933>

MOZAFFARIAN, Dariush *et al.* Fish intake and risk of incident heart failure. **Journal of the American College of Cardiology**, [s. l.], v. 45, n. 12, p. 2015–2021, 2005.

MUHAMMAD, Usman *et al.* Pre-trained VGGNet architecture for remote-sensing image scene classification. *In:* , 2018. **2018 24th International Conference on Pattern Recognition (ICPR)**. [S. l.]: IEEE, 2018. p. 1622–1627.

MÜLLER, Andreas C; GUIDO, Sarah. **Introduction to machine learning with Python: a guide for data scientists**. [S. l.]: “ O'Reilly Media, Inc.”, 2016.

MURRAY, J M; DELAHUNTY, C M; BAXTER, I A. Descriptive sensory analysis: past, present and future. **Food research international**, [s. l.], v. 34, n. 6, p. 461–471, 2001.

MYLES, Anthony J *et al.* An introduction to decision tree modeling. **Journal of Chemometrics: A Journal of the Chemometrics Society**, [s. l.], v. 18, n. 6, p. 275–285, 2004. Disponível em: <https://doi.org/https://doi.org/10.1002/cem.873>

NAIMULLAH, Muhammad; STHEVANIE, Febryanti; RAMADHANI, Kurniawan Nur. Tuna Meat Grade Classification Using Color Histogram And Grey Level Co-occurrence Matrix. **eProceedings of Engineering**, [s. l.], v. 7, n. 2, 2020.

NATEKIN, Alexey; KNOLL, Alois. Gradient boosting machines, a tutorial. **Frontiers in neurorobotics**, [s. l.], v. 7, p. 21, 2013. Disponível em: <https://doi.org/https://doi.org/10.3389/fnbot.2013.00021>

NETO, Edson Cavalcanti *et al.* Development control parking access using techniques digital image processing and applied computational intelligence. **IEEE Latin America Transactions**, [s. l.], v. 13, n. 1, p. 272–276, 2015.

NIMBKAR, Shubham *et al.* Novel Techniques for Quality Evaluation of Fish: A Review. **Food Reviews International**, [s. l.], p. 1–24, 2021. Disponível em: <https://doi.org/https://doi.org/10.1080/87559129.2021.1925291>

NJOMAN, Maria Fransisca *et al.* The vulnerability of human sensory evaluation and the promising senses instrumentation. **British Food Journal**, [s. l.], 2017. Disponível em: <https://doi.org/https://doi.org/10.1108/BFJ-10-2016-0505>

O'BRIEN, Bettina; UMA, V. Computer Vision Concepts and Applications. *In:* ARTIFICIAL INTELLIGENCE (AI). [S. l.]: CRC Press, 2021. p. 111–130.

OLAFSDOTTIR, G *et al.* Methods to evaluate fish freshness in research and industry. **Trends in food science & technology**, [s. l.], v. 8, n. 8, p. 258–265, 1997. Disponível em: [https://doi.org/10.1016/S0924-2244\(97\)01049-2](https://doi.org/10.1016/S0924-2244(97)01049-2)

OLIVEIRA, Sâmia Karla de *et al.* Comparação dos colorímetros Nix Color

Sensor Pro e MINOLTA CM-5 na avaliação da cor da carne bovina descongelada e maturada. **Hig. alim.**, [s. l.], p. 1012–1016, 2019.

ONO, Jorge Piazzentin *et al.* PipelineProfiler: A visual analytics tool for the exploration of AutoML pipelines. **IEEE Transactions on Visualization and Computer Graphics**, [s. l.], v. 27, n. 2, p. 390–400, 2020. Disponível em: <https://doi.org/10.1109/TVCG.2020.3030361>

ONTIVERO-ORTEGA, Marlis *et al.* Fast Gaussian Naïve Bayes for searchlight classification analysis. **Neuroimage**, [s. l.], v. 163, p. 471–479, 2017. Disponível em: <https://doi.org/https://doi.org/10.1016/j.neuroimage.2017.09.001>

OTO, Naomi *et al.* Non-destructive evaluation of ATP content and plate count on pork meat surface by fluorescence spectroscopy. **Meat science**, [s. l.], v. 93, n. 3, p. 579–585, 2013. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2012.11.010>

PANDEY, Prafull; SINGH, Ram Govind. Analysis of randomized performance of bias parameters and activation function of extreme learning machine. **International Journal of Computer Applications**, [s. l.], v. 135, n. 1, p. 23–28, 2016.

PARASCANDOLO, Giambattista; HUTTUNEN, Heikki; VIRTANEN, Tuomas. Taming the waves: sine as activation function in deep neural networks. [s. l.], 2016.

PEFFERS, Ken *et al.* A design science research methodology for information systems research. **Journal of management information systems**, [s. l.], v. 24, n. 3, p. 45–77, 2007. Disponível em: <https://doi.org/https://doi.org/10.2753/MIS0742-1222240302>

PENG, Yankun; DHAKAL, Sagar. Optical methods and techniques for meat quality inspection. **Transactions of the ASABE**, [s. l.], v. 58, n. 5, p. 1371–1386, 2015. Disponível em: <https://doi.org/10.13031/trans.58.11004>

PILOT, Roberto *et al.* A review on surface-enhanced Raman scattering. **Biosensors**, [s. l.], v. 9, n. 2, p. 57, 2019. Disponível em: <https://doi.org/https://doi.org/10.3390/bios9020057>

POLIKAR, Robi. Ensemble learning. *In*: ENSEMBLE MACHINE LEARNING. [S. l.]: Springer, 2012. p. 1–34. Disponível em: [https://doi.org/https://doi.org/10.1007/978-1-4419-9326-7\\_1](https://doi.org/https://doi.org/10.1007/978-1-4419-9326-7_1)

PRIETO, Nuria *et al.* A review of the principles and applications of near-infrared spectroscopy to characterize meat, fat, and meat products. **Applied spectroscopy**, [s. l.], v. 71, n. 7, p. 1403–1426, 2017.

PROBST, Philipp; WRIGHT, Marvin N; BOULESTEIX, Anne-Laure. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, [s. l.], v. 9, n. 3, p. e1301, 2019. Disponível em: <https://doi.org/https://doi.org/10.1002/widm.1301>

PUTRA, Ghiri Basuki; PRAKASA, Esa. Classification of Chicken Meat Freshness using Convolutional Neural Network Algorithms. *In*: , 2020. **2020**

**International Conference on Innovation and Intelligence for Informatics, Computing and Technologies (3ICT).** [S. l.]: IEEE, 2020. p. 1–6. Disponível em: <https://doi.org/10.1109/3ICT51146.2020.9312018>

QIAO, Lu; TANG, Xiuying; DONG, Jun. A feasibility quantification study of total volatile basic nitrogen (TVB-N) content in duck meat for freshness evaluation. **Food Chemistry**, [s. l.], v. 237, p. 1179–1185, 2017. Disponível em: <https://doi.org/https://doi.org/10.1016/j.foodchem.2017.06.031>

RADHAKRISHNAN, P. **What are Hyperparameters ? and How to tune the Hyperparameters in a Deep Neural Network?**. [S. l.], 2017. Disponível em: <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a>. Acesso em: 25 jun. 2021.

RADI, Radi *et al.* Freshness assessment of tilapia fish in traditional market based on an electronic nose. **Bulletin of Electrical Engineering and Informatics**, [s. l.], v. 10, n. 5, p. 2466–2476, 2021. Disponível em: <https://doi.org/https://doi.org/10.11591/eei.v10i5.3111>

RAJI, Cyrus A *et al.* Regular fish consumption and age-related brain gray matter loss. **American journal of preventive medicine**, [s. l.], v. 47, n. 4, p. 444–451, 2014. Disponível em: <https://doi.org/https://doi.org/10.1016/j.amepre.2014.05.037>

RASCHKA, Sebastian; MIRJALILI, Vahid. Python Machine Learning: Machine Learning and Deep Learning with Python. **Scikit-Learn, and TensorFlow. Second edition ed**, [s. l.], 2017.

RATNAWATI, Dian Eka *et al.* Comparison of activation function on extreme learning machine (ELM) performance for classifying the active compound. *In:* , 2020. **AIP Conference Proceedings**. [S. l.]: AIP Publishing LLC, 2020. p. 140001. Disponível em: <https://doi.org/https://doi.org/10.1063/5.0023872>

RAYAN, Muhammad Abu *et al.* Fish Freshness Classification Using Combined Deep Learning Model. *In:* , 2021. **2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI)**. [S. l.]: IEEE, 2021. p. 1–5. Disponível em: <https://doi.org/10.1109/ACMI53878.2021.9528138>

RIBEIRO, José *et al.* Prediction of Homicides in Urban Centers: A Machine Learning Approach. *In:* , 2021. **Proceedings of SAI Intelligent Systems Conference**. [S. l.]: Springer, 2021. p. 344–361. Disponível em: [https://doi.org/https://doi.org/10.1007/978-3-030-82199-9\\_22](https://doi.org/https://doi.org/10.1007/978-3-030-82199-9_22)

RODRIGUES, Sandra Cristina Antunes. **Modelo de regressão linear e suas aplicações**. [S. l.]: Universidade da Beira Interior, 2012.

RODRIGUEZ, Juan D; PEREZ, Aritz; LOZANO, Jose A. Sensitivity analysis of k-fold cross validation in prediction error estimation. **IEEE transactions on pattern analysis and machine intelligence**, [s. l.], v. 32, n. 3, p. 569–575, 2009. Disponível em: <https://doi.org/10.1109/TPAMI.2009.187>

RODRÍGUEZ VILLAMIZAR, Julián Camilo. Sistemas multiespectrales e hiperespectrales para la observación del territorio: análisis y aplicación a la prospección de hidrocarburos. [s. l.], 2015.

SAARELA, Mirka; JAUHIAINEN, Susanne. Comparison of feature importance measures as explanations for classification models. **SN Applied Sciences**, [s. l.], v. 3, n. 2, p. 1–12, 2021.

SALLAM, Kh I; SAMEJIMA, K. Microbiological and chemical quality of ground beef treated with sodium lactate and sodium chloride during refrigerated storage. **LWT-Food Science and technology**, [s. l.], v. 37, n. 8, p. 865–871, 2004. Disponível em: <https://doi.org/https://doi.org/10.1016/j.lwt.2004.04.003>

SARAVANAN, G; YAMUNA, G; NANDHINI, S. Real time implementation of RGB to HSV/HSI/HSL and its reverse color space models. *In*: , 2016. **2016 International Conference on Communication and Signal Processing (ICCSP)**. [S. l.]: IEEE, 2016. p. 462–466. Disponível em: <https://doi.org/10.1109/ICCSP.2016.7754179>

SCORNET, Erwan. Tuning parameters in random forests. **ESAIM: Proceedings and Surveys**, [s. l.], v. 60, p. 144–162, 2017. Disponível em: <https://doi.org/https://doi.org/10.1051/proc/201760144>

SETIYOKO, Andie; DHARMA, I Gede Wahyu Surya; HARYANTO, Toto. Recent development of feature extraction and classification multispectral/hyperspectral images: a systematic literature review. *In*: , 2017. **Journal of Physics: Conference Series**. [S. l.]: IOP Publishing, 2017. p. 12045.

SHALEV-SHWARTZ, Shai *et al.* Online passive-aggressive algorithms. **Advances in neural information processing systems**, [s. l.], v. 16, p. 1229–1236, 2003.

SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. **Understanding machine learning: From theory to algorithms**. [S. l.]: Cambridge university press, 2014.

SHAN, Jiajia *et al.* Comparisons of fish morphology for fresh and frozen-thawed crucian carp quality assessment by hyperspectral imaging technology. **Food Analytical Methods**, [s. l.], v. 11, n. 6, p. 1701–1710, 2018. Disponível em: <https://doi.org/https://doi.org/10.1007/s12161-018-1158-5>

SHARMA, A. **Gaussian Naive Bayes with Hyperparameter Tuning**. [S. l.], 2021. Disponível em: <https://www.analyticsvidhya.com/blog/2021/01/gaussian-naive-bayes-with-hyperparameter-tuning/>. Acesso em: 20 jun. 2021.

SHI, Yinyan *et al.* A Review on Meat Quality Evaluation Methods Based on Non-Destructive Computer Vision and Artificial Intelligence Technologies. **Food science of animal resources**, [s. l.], v. 41, n. 4, p. 563, 2021. Disponível em: <https://doi.org/10.5851/kosfa.2021.e25>

SINGH, Amarpal; SAXENA, Piyush; LALWANI, Sangeeta. A study of various training algorithms on neural network for angle based triangular problem. **International Journal of Computer Applications**, [s. l.], v. 71, n. 13, 2013.

SINGH, Gurinder *et al.* Comparison between multinomial and Bernoulli naïve Bayes for text classification. *In*: , 2019. **2019 International Conference on Automation, Computational and Technology Management (ICACTM)**. [S. l.]: IEEE, 2019. p. 593–596. Disponível em: <https://doi.org/10.1109/ICACTM.2019.8776800>

SINGH, Pramod. MLib: Machine Learning Library. *In*: LEARN PYSPARK. [S. l.]: Springer, 2019. p. 85–115.

SMITH, Alvy Ray. Color gamut transform pairs. **ACM Siggraph Computer Graphics**, [S. l.], v. 12, n. 3, p. 12–19, 1978. Disponível em: <https://doi.org/https://doi.org/10.1145/965139.807361>

SØRLAND, Geir H *et al.* Determination of total fat and moisture content in meat using low field NMR. **Meat Science**, [S. l.], v. 66, n. 3, p. 543–550, 2004. Disponível em: [https://doi.org/https://doi.org/10.1016/S0309-1740\(03\)00157-8](https://doi.org/https://doi.org/10.1016/S0309-1740(03)00157-8)

STEINWART, Ingo; CHRISTMANN, Andreas. **Support vector machines**. [S. l.]: Springer Science & Business Media, 2008.

STONE, Herbert; BLEIBAUM, Rebecca N; THOMAS, Heather A. **Sensory evaluation practices**. [S. l.]: Academic press, 2020.

SU, Wen-Hao; HE, Hong-Ju; SUN, Da-Wen. Non-destructive and rapid evaluation of staple foods quality by using spectroscopic techniques: a review. **Critical reviews in food science and nutrition**, [S. l.], v. 57, n. 5, p. 1039–1051, 2017. Disponível em: <https://doi.org/https://doi.org/10.1080/10408398.2015.1082966>

SUN, Da-Wen. **Computer vision technology for food quality evaluation**. [S. l.]: Academic Press, 2016.

SUN, Kelei *et al.* A convolutional neural network model based on improved Softplus activation function. *In*: , 2019. **International Conference on Applications and Techniques in Cyber Security and Intelligence**. [S. l.]: Springer, 2019. p. 1326–1335. Disponível em: [https://doi.org/https://doi.org/10.1007/978-3-030-25128-4\\_164](https://doi.org/https://doi.org/10.1007/978-3-030-25128-4_164)

SUN, Xin *et al.* Prediction of pork color attributes using computer vision system. **Meat science**, [S. l.], v. 113, p. 62–64, 2016. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2015.11.009>

SUN, Xin *et al.* Prediction of pork loin quality using online computer vision system and artificial intelligence model. **Meat science**, [S. l.], v. 140, p. 72–77, 2018. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2018.03.005>

SUPARTINI, Atin; OISHI, Taro; YAGI, Nobuyuki. Sex differences in the relationship between sleep behavior, fish consumption, and depressive symptoms in the general population of South Korea. **International journal of environmental research and public health**, [S. l.], v. 14, n. 7, p. 789, 2017. Disponível em: <https://doi.org/https://doi.org/10.3390/ijerph14070789>

SUXIA, Xing *et al.* Study on chicken quality classification method based on K-means-RBF multi-source data fusion. *In*: , 2018. **2018 Chinese Control And Decision Conference (CCDC)**. [S. l.]: IEEE, 2018. p. 405–410. Disponível em: <https://doi.org/10.1109/CCDC.2018.8407167>

SUYKENS, Johan A K *et al.* **Least squares support vector machines**. [S. l.]: World scientific, 2002.

SWINBURNE, Richard. Bayes' Theorem. **Revue Philosophique de la France**

Et de I, [s. l.], v. 194, n. 2, 2004.

TAHERI-GARAVAND, A. *et al.* Meat quality evaluation based on computer vision technique: A review. **Meat science**, [s. l.], v. 156, p. 183–195, 2019a. Disponível em: <https://doi.org/https://doi.org/10.1016/j.meatsci.2019.06.002>

TAHERI-GARAVAND, A. *et al.* Real-time nondestructive monitoring of Common Carp Fish freshness using robust vision-based intelligent modeling approaches. **Computers and Electronics in Agriculture**, [s. l.], v. 159, p. 16–27, 2019b. Disponível em: <https://doi.org/10.1016/j.compag.2019.02.023>

TAHERI-GARAVAND, A. *et al.* Smart deep learning-based approach for non-destructive freshness diagnosis of common carp fish. **Journal of Food Engineering**, [s. l.], v. 278, p. 109930, 2020.

TAHERI-GARAVAND, A. *et al.* A nondestructive intelligent approach to real-time evaluation of chicken meat freshness based on computer vision technique. **Journal of Food Process Engineering**, [s. l.], v. 42, n. 4, p. e13039, 2019. Disponível em: <https://doi.org/10.1111/jfpe.13039>

TAN, Edwin. **Auto-Sklearn: Scikit-Learn on Steroids**. [S. l.], 2021. Disponível em: <https://towardsdatascience.com/auto-sklearn-scikit-learn-on-steroids-42abd4680e94>. Acesso em: 29 ago. 2021.

TAN, J. Meat quality evaluation by computer vision. **Journal of Food Engineering**, [s. l.], v. 61, n. 1, p. 27–35, 2004.

TAN, J.; XU, Jie. Applications of electronic nose (e-nose) and electronic tongue (e-tongue) in food quality-related properties determination: A review. **Artificial Intelligence in Agriculture**, [s. l.], 2020. Disponível em: <https://doi.org/https://doi.org/10.1016/j.aiia.2020.06.003>

TAN, Wei Keong; HUSIN, Zulkifli; ISMAIL, Muhammad Amir Hakim. Feasibility Study of Beef Quality Assessment using Computer Vision and Deep Neural Network (DNN) Algorithm. *In*: , 2020. **2020 8th International Conference on Information Technology and Multimedia (ICIMU)**. [S. l.]: IEEE, 2020. p. 243–246. Disponível em: <https://doi.org/10.1109/ICIMU49871.2020.9243353>

TAO, Feifei; PENG, Yankun. A method for nondestructive prediction of pork meat quality and safety attributes by hyperspectral imaging technique. **Journal of Food Engineering**, [s. l.], v. 126, p. 98–106, 2014. Disponível em: <https://doi.org/https://doi.org/10.1016/j.jfoodeng.2013.11.006>

TAUD, H; MAS, J F. Multilayer perceptron (MLP). *In*: GEOMATIC APPROACHES FOR MODELING LAND CHANGE SCENARIOS. [S. l.]: Springer, 2018. p. 451–455. Disponível em: [https://doi.org/10.1007/978-3-319-60801-3\\_27](https://doi.org/10.1007/978-3-319-60801-3_27)

TEENA, M *et al.* Potential of machine vision techniques for detecting fecal and microbial contamination of food products: A review. **Food and Bioprocess Technology**, [s. l.], v. 6, n. 7, p. 1621–1634, 2013. Disponível em: <https://doi.org/https://doi.org/10.1007/s11947-013-1079-7>

THARWAT, Alaa. Linear vs. quadratic discriminant analysis classifier: a tutorial. **International Journal of Applied Pattern Recognition**, [s. l.], v. 3, n. 2, p.

145–180, 2016. Disponível em:  
<https://doi.org/https://doi.org/10.1504/IJAPR.2016.079050>

THEODORIDIS, Sergios. **Machine learning: a Bayesian and optimization perspective**. [S. l.]: Academic press, 2015.

TRIENTIN, Danika; HIDAYAT, Bambang; DARANA, Sjafril. Beef freshness classification by using color analysis, multi-wavelet transformation, and artificial neural network. *In:* , 2015. **2015 International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT)**. [S. l.]: IEEE, 2015. p. 181–185. Disponível em: <https://doi.org/10.1109/ICACOMIT.2015.7440202>

TYAGI, Vipin. **Understanding digital image processing**. [S. l.]: CRC Press, 2018.

UDDIN, Sohel; SHAREEF, Hussain; MOHAMED, Azah. Power quality performance of energy-efficient low-wattage LED lamps. **Measurement**, [s. l.], v. 46, n. 10, p. 3783–3795, 2013.

VAZ, Arthur Lamblet. **KNN —K-Nearest Neighbor, o que é?**. [S. l.], 2021. Disponível em: <https://medium.com/data-hackers/knn-k-nearest-neighbor-o-que-e-aebe0f833eb>. Acesso em: 20 abr. 2021.

VOVK, Vladimir. Kernel ridge regression. *In:* EMPIRICAL INFERENCE. [S. l.]: Springer, 2013. p. 105–116. Disponível em:  
[https://doi.org/https://doi.org/10.1007/978-3-642-41136-6\\_11](https://doi.org/https://doi.org/10.1007/978-3-642-41136-6_11)

WANG, Sijian; ZHU, Ji. Improved centroids estimation for the nearest shrunken centroid classifier. **Bioinformatics**, [s. l.], v. 23, n. 8, p. 972–979, 2007. Disponível em: <https://doi.org/https://doi.org/10.1093/bioinformatics/btm046>

WANG, Wei *et al.* Generalized autoencoder: A neural network framework for dimensionality reduction. *In:* , 2014. **Proceedings of the IEEE conference on computer vision and pattern recognition workshops**. [S. l.: s. n.], 2014. p. 490–497.

WANG, W X *et al.* Portable nondestructive detection device for nutrient components of pork. **Trans Chin Soc Agric Mach**, [s. l.], v. 48, p. 303–311, 2017.

WEBB, E C; CASEY, N H; SIMELA, L. Goat meat quality. **Small ruminant research**, [s. l.], v. 60, n. 1–2, p. 153–166, 2005. Disponível em:  
<https://doi.org/https://doi.org/10.1016/j.smallrumres.2005.06.009>

WELCH, Eric; MOORHEAD, Robert; OWENS, J K. Image processing using the HSI color space. *In:* , 1991. **IEEE Proceedings of the SOUTHEASTCON'91**. [S. l.]: IEEE, 1991. p. 722–725. Disponível em:  
<https://doi.org/10.1109/SECON.1991.147852>

WESTLAND, Stephen; RIPAMONTI, Caterina; CHEUNG, Vien. **Computational colour science using MATLAB**. [S. l.]: John Wiley & Sons, 2012.

WIEJA, K *et al.* Identification and investigation of mechanically separated meat (MSM) with an innovative ultrasonic method. **Food Chemistry**, [s. l.], v. 348, p. 128907, 2021. Disponível em:

<https://doi.org/https://doi.org/10.1016/j.foodchem.2020.128907>

WIERINGA, Roel J. **Design science methodology for information systems and software engineering**. [S. l.]: Springer, 2014.

WINIARTI, Sri; AZHARI, Ahmad; AGUSTA, Khalidia Mega. Determining Feasibility Level of Beef Quality Based on Histogram and K-Means Clustering. *In:* , 2018. **2018 International Symposium on Advanced Intelligent Informatics (SAIN)**. [S. l.]: IEEE, 2018. p. 195–198. Disponível em: <https://doi.org/10.1109/SAIN.2018.8673366>

WU, Jia *et al.* Hyperparameter optimization for machine learning models based on Bayesian optimization. **Journal of Electronic Science and Technology**, [s. l.], v. 17, n. 1, p. 26–40, 2019.

WU, Leilei; PU, Hongbin; SUN, Da-Wen. Novel techniques for evaluating freshness quality attributes of fish: A review of recent developments. **Trends in food science & technology**, [s. l.], v. 83, p. 259–273, 2019. Disponível em: <https://doi.org/https://doi.org/10.1016/j.tifs.2018.12.002>

WUBSHET, Sileshi Gizachew *et al.* Raman spectroscopy for quantification of residual calcium and total ash in mechanically deboned chicken meat. **Food Control**, [s. l.], v. 95, p. 267–273, 2019. Disponível em: <https://doi.org/https://doi.org/10.1016/j.foodcont.2018.08.017>

XANTHOPOULOS, Petros; PARDALOS, Panos M; TRAFALIS, Theodore B. Linear discriminant analysis. *In:* ROBUST DATA MINING. [S. l.]: Springer, 2013. p. 27–33. Disponível em: [https://doi.org/https://doi.org/10.1007/978-1-4419-9878-1\\_4](https://doi.org/https://doi.org/10.1007/978-1-4419-9878-1_4)

XIONG, Zhenjie *et al.* Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: A review. **Journal of food engineering**, [s. l.], v. 132, p. 1–13, 2014. Disponível em: <https://doi.org/https://doi.org/10.1016/j.jfoodeng.2014.02.004>

YAKUBU, Haruna Gado *et al.* The recent advances of near-infrared spectroscopy in dairy production—A review. **Critical Reviews in Food Science and Nutrition**, [s. l.], p. 1–22, 2020. Disponível em: <https://doi.org/https://doi.org/10.1080/10408398.2020.1829540>

YANG; X. **Linear Discriminant Analysis, Explained**. [S. l.], 2020. Disponível em: <https://towardsdatascience.com/linear-discriminant-analysis-explained-f88be6c1e00b>. Acesso em: 12 mar. 2021.

YE, Rongke *et al.* NIR hyperspectral imaging technology combined with multivariate methods to identify shrimp freshness. **Applied Sciences**, [s. l.], v. 10, n. 16, p. 5498, 2020. Disponível em: <https://doi.org/https://doi.org/10.3390/app10165498>

YEGNANARAYANA, Bayya. **Artificial neural networks**. [S. l.]: PHI Learning Pvt. Ltd., 2009.

ZDRAVEVSKI, Eftim; LAMESKI, Petre; KULAKOV, Andrea. Advanced transformations for nominal and categorical data into numeric data in supervised learning problems. *In:* , 2013. **The 10th Conference for**

**Informatics and Information Technology (CIIT).** [S. l.: s. n.], 2013.

ZHANG, Cha; MA, Yunqian. **Ensemble machine learning: methods and applications.** [S. l.]: Springer, 2012.

ZHANG, Changsheng; OUYANG, Dantong; NING, Jiaxu. An artificial bee colony approach for clustering. **Expert systems with applications**, [s. l.], v. 37, n. 7, p. 4761–4767, 2010.

ZHANG, Dengsheng. Wavelet transform. *In*: FUNDAMENTALS OF IMAGE DATA MINING. [S. l.]: Springer, 2019. p. 35–44.

ZHANG, Harry. The optimality of naive Bayes. **AA**, [s. l.], v. 1, n. 2, p. 3, 2004.

ZHANG, Wenyang; MA, Ji; SUN, Da-Wen. Raman spectroscopic techniques for detecting structure and quality of frozen foods: principles and applications.

**Critical Reviews in Food Science and Nutrition**, [s. l.], v. 61, n. 16, p. 2623–2639, 2021. Disponível em:

<https://doi.org/https://doi.org/10.1080/10408398.2020.1828814>

ZHAO, Hai-Tao *et al.* Application of invasive weed optimization and least square support vector machine for prediction of beef adulteration with spoiled beef based on visible near-infrared (Vis-NIR) hyperspectral imaging. **Meat science**, [s. l.], v. 151, p. 75–81, 2019.

ZHENG, Ju-Sheng *et al.* Intake of fish and marine n-3 polyunsaturated fatty acids and risk of breast cancer: meta-analysis of data from 21 independent prospective cohort studies. **Bmj**, [s. l.], v. 346, p. f3706, 2013. Disponível em: <https://doi.org/10.1136/bmj.f3706>

ZHOU, Jiaojiao *et al.* Evaluation of freshness in freshwater fish based on near infrared reflectance spectroscopy and chemometrics. **Lwt**, [s. l.], v. 106, p. 145–150, 2019.

ZHOU, Shui-Sheng; LIU, Hong-Wei; YE, Feng. Variant of Gaussian kernel and parameter setting method for nonlinear SVM. **Neurocomputing**, [s. l.], v. 72, n. 13–15, p. 2931–2937, 2009.

ZHU, Hongyan *et al.* Hyperspectral imaging for predicting the internal quality of kiwifruits based on variable selection algorithms and chemometric models.

**Scientific reports**, [s. l.], v. 7, n. 1, p. 1–13, 2017. Disponível em:

<https://doi.org/https://doi.org/10.1038/s41598-017-08509-6>

## **APÊNDICE A – CRITÉRIOS DE INCLUSÃO E EXCLUSÃO PARA REALIZAÇÃO DO MAPEAMENTO SISTEMÁTICO DA LITERATURA**

Neste apêndice são mostrados os critérios de inclusão e exclusão utilizados no MSL seguindo protocolo de (KITCHENHAM; CHARTERS, 2007).

### **a) Critérios de Inclusão e Exclusão**

Segundo Kitchenham e Charters (KITCHENHAM; CHARTERS, 2007), a estratégia de seleção deve ser feita a partir de critérios de inclusão (CI) e de exclusão (CE). Os critérios balizadores desta pesquisa são expostos a seguir.

#### **Critérios de Inclusão:**

- CI\_1: Estudos que apresentem soluções para classificar o frescor ou qualidade de amostras de carnes de boi, de porco, de frangos ou de peixes, com base em análise sensorial;
- CI\_2: Estudos publicados em periódico ou conferência delimitados no escopo desta pesquisa.

#### **Critérios de Exclusão:**

- CE\_1: Estudos não relacionados a classificação do frescor ou qualidade de carne de boi, de porco, de frango ou de peixes, feita através de análise sensorial;
- CE\_2: Trabalhos incompletos, rascunhos, documentos de compilação dos anais de conferência, tutoriais e apresentações em slides;
- CE\_3: Trabalhos não escritos em Inglês;
- CE\_4: Trabalhos resultantes de uma mesma pesquisa ou com pequenas mudanças em relação a uma publicação anterior (optou-se por selecionar a pesquisa mais recente);
- CE\_5: Trabalhos não publicados nos últimos 7 anos (2015 a 2021);
- CE\_6: Livros, dissertações ou teses.

### **b) Condução da Busca Automática**

A etapa de condução da busca envolve a seleção e avaliação das fontes de informação através dos CIs e CEs definidos, ou seja, durante a execução, os estudos são expostos aos critérios, com intuito de filtrá-los, deixando apenas aqueles que estão de acordo com as definições metodológicas da pesquisa. A seguir são listadas as etapas da busca:


- Etapa 1: seleção, através da aplicação da *string* de busca, no título, no *abstract*, nas palavras-chave dos artigos resultantes da busca nos mecanismos de pesquisa *Elsevier*, *IEEE*, *Springer* e *Google Acadêmico*;
- Etapa 2: eliminação de artigos duplicados resultantes da Etapa 1.
- Etapa 3: aplicação dos critérios de exclusão CE\_2, CE\_3, CE\_4, CE\_5 e CE\_6;
- Etapa 4: leitura do *abstract* dos artigos resultantes da Etapa 3 e aplicação do critério de exclusão CE\_1;
- Etapa 5: leitura completa dos artigos resultantes da Etapa 4 e aplicação dos critérios de inclusão CI\_1 e CI\_2.

## APÊNDICE B – ANÁLISE DOS MELHORES MODELOS PARA A CLASSIFICAÇÃO DE AMOSTRAS DE ATUM

Neste Apêndice são apresentadas as métricas: acurácia de teste, precisão e *recall*, *F1-Score*, MC, e curva ROC, dos 15 (quinze) modelos escolhidos para classificação do frescor da carne do atum, calculadas a partir de previsões feitas na base de teste, com os melhores modelos mostrados no Quadro 7. Ressalta-se que as previsões foram feitas nas respectivas bases de teste da repetição na qual os modelos foram escolhidos. As classes são consideradas nesta ordem 2+, 2, 2- e 3, sendo 2+ a classe de maior frescor para amostras de atum e 3 a de menor frescor.

Previsões 100% assertivas são feitas em 8 (oito) modelos, mostrados a seguir, sendo eles: MLP, PA, ExtraTrees\_Ensemble, LR\_Ensemble, QDA\_Ensemble, RC\_Ensemble, KNN e SGD.

Figura 44 - Gráfico de agrupamento das classes de frescor de amostras de atum gerado pela técnica UMAP e destaque para possíveis confusões na classificação realizada pelos modelos



Fonte: A Autora (2021)

Para entender previsões erradas de alguns classificadores, representadas em suas respectivas MCs, recorreu à Figura 32.a que agrupa as amostras por classes, através da técnica UMAP, novamente ilustrada na Figura 44, com destaques. Percebe-se no menor destaque da Figura 44, amostras de classes distintas muito próximas, o que implica que os valores de suas características estão muito próximos, sendo motivo para confusão ou erros de classificação representados em algumas MCs geradas em previsões dos modelos e mostradas a seguir. A baixa quantidade de amostras no conjunto de dados fez

com que algumas amostras fossem localizadas afastadas de seus verdadeiros agrupamentos, como se vê no maior destaque da Figura 44, motivo este também para confusão ou erros de classificação em previsões feitas pelos modelos.

Quanto a importância de características revelada pela técnica de permutações, representada em gráficos mostrados a seguir, entende-se que em geral, as características com pontuações de importância mais altas são mais sensíveis a permutação ou embaralhamento aleatório de seus valores, o que significa que eles são mais "importantes" para a previsão.

Salienta-se que o embaralhamento é executado para um recurso de cada vez e, embora um recurso possa parecer desnecessário ou menos importante por causa de sua pontuação de importância baixa (ou negativa), pode haver correlação deste com outros recursos, de modo que juntos produzam modelos com melhores desempenhos. O contrário também pode acontecer. Considera-se, por exemplo, a análise da importância dos recursos que têm um peso diferente de zero. Pode acontecer de remover-se um recurso importante e treinar-se novamente o modelo, esperando a queda no desempenho. O modelo retreinado pode, ocasionalmente, manter o mesmo o desempenho, porque outro recurso, não considerado importante anteriormente em função de correlação com o recurso removido, obtém agora uma importância maior e diferente, levando a conclusão de que o recurso removido não era importante.

Estes fatos justificam a não retirada de recursos usados por um modelo com base em pontuações baixas (ou negativas) de importância reveladas pela técnica de permutações, com o objetivo de retreiná-lo, sugerindo-se deixar a cargo das primitivas de pré-processamento de características, a escolha ou extração das características que geram o melhor modelo. De maneira mais geral, ressalta-se que os gráficos de importância de características ajudam a interpretar os modelos, trazendo à tona que características mais devem ser observadas, não sendo esta, a estratégia para escolha de características.

A importância do recurso fornece uma visão global altamente compactada do comportamento do modelo. Uma vez que a medida de importância leva em consideração automaticamente todas as interações com outros recursos, ao permutar o recurso, destrói-se os efeitos de interação com outros recursos. Isso significa que a importância do recurso de permutação leva

em consideração o efeito do recurso principal e os efeitos de interação no desempenho do modelo.

Percebe-se nos gráficos de importância de características, mostrados a seguir, que os recursos relevantes mudam entre os diversos modelos, já que os modelos são matematicamente diferentes, usam primitivas de pré-processamento de características diversas e usam dados distintos. Salienta-se que um mesmo modelo, usando primitivas de pré-processamento de características distintas ou dados distintos pode gerar gráficos de importância de características distintos.

#### **a) Ensemble\_Heterogêneo**


O melhor modelo Ensemble\_Heterogêneo, dentre as 30 (trinta) repetições, não fez uso de nenhuma primitiva de pré-processamento de características.

O modelo utiliza um comitê contendo os classificadores RC, KNN, LDA, QDA, PA, DT, RF, ExtraTrees, AdaBoost, GB, SGD, SVM, LR, BNB, GNB, NC e MLP, com seus hiper parâmetros em valores *default* definidos pela biblioteca *scikit-learn*.

A MC do modelo é mostrada na Figura 45. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 9.

A classe 2- apresentou a menor precisão, com valor de 75%. Portanto, 75% das amostras que o modelo previu como sendo pertencentes à classe 2-, realmente pertencem a esta classe. A classe 3 apresentou precisão de 80%, significando que dentre as amostras que o modelo previu como pertencentes a esta classe, 80% são verdadeiramente pertencentes. Para as classes 2 e 2+ as precisões foram iguais a 100%. Quanto ao *recall*, o modelo previu 50% das amostras da classe 2 como realmente pertencentes à esta classe, e 80% das amostras da classe 2+ como sendo realmente da classe 2+. As demais classes apresentaram *recall* de 100%. As classes que apresentaram maior *F1-Score* foram as classes 2- e 3, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo Ensemble\_Heterogêneo foi de 84%.

Figura 45 - Matriz de confusão da previsão feita pelo melhor modelo Ensemble\_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 9 - Precisão, recall, F1-Score e acurácia das previsões do melhor modelo Ensemble\_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 75%      | 100%   | 86%      | 6                        |
| 3                         | 80%      | 100%   | 89%      | 4                        |
| 2                         | 100%     | 50%    | 67%      | 4                        |
| 2+                        | 100%     | 80%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        |          | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 89%      | 82%    | 83%      | 19                       |
| <b>Média ponderada</b>    | 88%      | 84%    | 83%      | 19                       |

Fonte: A Autora (2021)

A curva ROC não foi gerada por ser uma curva baseada em probabilidades das previsões, e alguns classificadores usados no Ensemble\_Heterogêneo não suportarem o cálculo de probabilidades.

Para o melhor modelo Ensemble\_Heterogêneo, as características mais relevantes são mostradas no Gráfico 12. A característica hueHSI foi considerada a mais relevante para o modelo, salientando que apenas a característica lLab não apresentou relevância na previsão.

Gráfico 12 - Importância das características para o melhor modelo Ensemble\_Heterogêneo, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

A seguir o modelo MLP será mostrado.

## b) MLP

O melhor modelo MLP, dentre as 30 (trinta) repetições, usou o *Autoencoder* como primitiva de pré-processamento de características.

Figura 46 - Matriz de confusão da previsão feita pelo melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A MC do modelo é mostrada na Figura 46. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 10. Como se vê na MC e nos valores das métricas apresentadas na Tabela 10, o modelo previu corretamente 100% das classes.


A curva ROC do modelo é mostrada no Gráfico 13. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Para as quatro classes do modelo, o valor da AUC é igual a 1.

Tabela 10 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)

Gráfico 13 - Curva ROC do melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

Para o melhor modelo MLP, as características mais importantes são mostradas no Gráfico 14. Como o Autoencoder gera novas oito características a

partir das originais, não se sabe o significado de cada característica. A característica rotulada como “5” foi a mais relevante para o modelo.

Gráfico 14 - Importância das características para o melhor modelo MLP, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo LR será apresentado.

### c) LR

O melhor modelo LR, dentre as 30 (trinta) repetições, não fez uso de nenhuma primitiva de pré-processamento de características. A MC do modelo é mostrada na Figura 47.


Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 11.

A classe 2 apresentou a menor precisão, com valor de 80%. Portanto, 80% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. A classe 2- apresentou precisão de 86%, significando que o modelo previu amostras pertencentes a esta classe e apenas 86% delas são verdadeiramente pertencentes. Para as classes 3 e 2+ as precisões são de 100%.

Quanto ao *recall*, o modelo previu 80% das amostras da classe 2+ como realmente pertencentes à esta classe, e 75% das amostras da classe 3 como sendo realmente da classe 3. As demais classes apresentaram *recall* de 100%.

A classe que apresentou maior *F1-Score* foi a classe 2-, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo LR foi de 89%.

Figura 47 - Matriz de confusão da previsão feita pelo melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 11 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 86%      | 100%   | 92%      | 6                        |
| 3                         | 100%     | 75%    | 86%      | 4                        |
| 2                         | 80%      | 100%   | 89%      | 4                        |
| 2+                        | 100%     | 80%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        | 89%      | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 91%      | 89%    | 89%      | 19                       |
| <b>Média ponderada</b>    | 91%      | 89%    | 89%      | 19                       |

Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 15. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. A classe 0 apresentou valor de AUC igual a 0,99, a classe 1 apresentou valor de AUC igual a 1, a classe 2 apresentou valor de AUC igual a 0,97 e, por fim, a classe 3 apresentou valor de AUC igual a 1.


Para o melhor modelo LR, as características mais relevantes são mostradas no Gráfico 16. A característica hueHSI foi considerada a mais relevante para o modelo, salientando que as características medianB, medianG, saturationHSV, valueHSC, saturationHSI, lLab e bLab não apresentaram relevância na previsão. Todas as demais características têm relevância positivas.

Gráfico 15 - Curva ROC do melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 16 - Importância das características para o melhor modelo LR, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

#### d) PA

O melhor modelo PA, dentre as 30 (trinta) repetições, fez uso da técnica PCA como primitiva de pré-processamento de escolha de características.

A MC do modelo é mostrada na Figura 48. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 12.

Figura 48 - Matriz de confusão da previsão feita pelo melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 12 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)


Todas as métricas apresentam 100% de assertividade, sendo a acurácia do modelo de 100%.

A curva ROC do modelo é mostrada no Gráfico 17. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3

para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. A O valor da AUC é igual a 1 para todas as classes.


Para o melhor modelo PA, as características mais importantes são mostradas no Gráfico 18. A característica hueHSI foi considerada a mais relevante para o modelo, salientando que as características medianR, medianG, medianB, B, saturationHSV, valueHSV, saturationHSI, lLab e bLab não apresentaram relevância na previsão. As demais características têm relevância positiva.

Gráfico 17 - Curva ROC do melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 18 - Importância das características para o melhor modelo PA, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

### e) ExtraTrees\_Ensemble

O melhor modelo ExtraTree\_Ensemble, dentre as 30 (trinta) repetições, não usou nenhuma primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 49. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 13. Como se vê na MC e nos valores das métricas apresentadas na Tabela 13, o modelo previu corretamente 100% das classes.

Figura 49 - Matriz de confusão da previsão feita pelo melhor modelo ExtraTrees\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 13 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo ExtraTrees\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe             | Precisão | Recall | F1-Score | Número de amostras |
|--------------------|----------|--------|----------|--------------------|
| 2-                 | 100%     | 100%   | 100%     | 6                  |
| 3                  | 100%     | 100%   | 100%     | 4                  |
| 2                  | 100%     | 100%   | 100%     | 4                  |
| 2+                 | 100%     | 100%   | 100%     | 5                  |
| Acurácia do modelo | 100%     |        |          | Total de Amostras  |
|                    |          |        |          | 19                 |
| Média macro        | 100%     | 100%   | 100%     | 19                 |
| Média ponderada    | 100%     | 100%   | 100%     | 19                 |

Fonte: A Autora (2021)


A curva ROC do modelo é mostrada na Gráfico 19. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Para as quatro classes do modelo, o valor da AUC é igual a 1.

Gráfico 19 - Curva ROC do melhor modelo ExtraTrees\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 20 - Importância das características para o melhor modelo ExtraTrees\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)


Para o melhor modelo `ExtraTrees_Ensemble`, as características mais importantes são mostradas no Gráfico 20. A característica `hueHSI` foi a mais relevante para a previsão do modelo. Não foram usadas as características `medianR`, `medianG`, `medianB`, `histR`, `histG`, `R`, `saturationHSV`, `saturationHSI`, `intensityHSI`, `lLab`, `aLab` e `bLab`.

#### f) PA\_Ensemble

Esta seção apresenta o melhor modelo `PA_Ensemble` dentre as 30 (trinta) repetições.

O melhor modelo `PA_Ensemble`, dentre as 30 (trinta) repetições, fez uso da técnica *VarianceThreshold* como primitiva de pré-processamento de escolha de características. A MC do modelo é mostrada na Figura 50.

Figura 50 - Matriz de confusão da previsão feita pelo melhor modelo `PA_Ensemble`, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 14.

A classe 2- apresentou a menor precisão, com valor de 86%. Portanto, 86% das amostras que o modelo previu como sendo pertencentes à classe 2-, realmente pertencem a esta classe. Para as classes 3, 2 e 2+ as precisões são de 100%.

Quanto ao *recall*, o modelo previu 80% das amostras da classe 2+ como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.


As classes apresentaram maior *F1-Score* foram as classes 3 e 2, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo LR foi de 95%.

Tabela 14 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo PA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 86%      | 100%   | 92%      | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 80%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 19                       |
| <b>Média ponderada</b>    | 95%      | 95%    | 95%      | 19                       |

Fonte: A Autora (2021)

Gráfico 21 - Importância das características para o melhor modelo PA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)


Como foi utilizado o modelo de voto majoritário no PA\_Ensemble, dado que entre variações do classificador PA a votação ponderada não é suportada, não foi possível gerar a curva ROC.

Para o melhor modelo PA\_Ensemble, as características mais importantes são mostradas no Gráfico 21. A característica hueHSI foi considerada a mais importante para o modelo, salientando que as características medianR, medianG, medianB, B, saturationHSV, saturationHSI, lLab e bLab não apresentaram relevância na previsão. As demais características apresentam relevâncias positivas.

### g) MLP\_Ensemble

O melhor modelo MLP\_Ensemble, dentre as 30 (trinta) repetições, fez uso da técnica *VarianceThreshold* como primitiva de pré-processamento de características. A MC do modelo é mostrada na Figura 51.

Figura 51 - Matriz de confusão da previsão feita pelo melhor modelo MLP\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 15.

Tabela 15 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo MLP\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe             | Precisão | Recall | F1-Score | Número de amostras |
|--------------------|----------|--------|----------|--------------------|
| 2-                 | 86%      | 100%   | 92%      | 6                  |
| 3                  | 100%     | 100%   | 89%      | 4                  |
| 2                  | 100%     | 100%   | 67%      | 4                  |
| 2+                 | 100%     | 80%    | 89%      | 5                  |
| Acurácia do modelo | 95%      |        |          | Total de Amostras  |
|                    |          |        |          | 19                 |
| Média macro        | 96%      | 95%    | 95%      | 19                 |
| Média ponderada    | 95%      | 95%    | 95%      | 19                 |


Fonte: A Autora (2021)

A classe 2- apresentou a menor precisão, com valor de 86%. Portanto, 86% das amostras que o modelo previu como sendo pertencentes à classe 2-, realmente pertencem a esta classe. Para as classes 3, 2 e 2+ as precisões são iguais a 100%.

Quanto ao *recall*, o modelo previu 80% das amostras da classe 2+ como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

A classe 2- apresentou valor de *F1-Score* igual a 100%, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo MLP\_Ensemble foi de 95%.

Gráfico 22 - Curva ROC do melhor modelo MLP\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 22. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Para as quatro classes do modelo, o valor da AUC é igual a 1.

Para o melhor modelo MLP\_Ensemble, as características mais importantes são mostradas no Gráfico 23. As características medianG, medianB, G, B, saturationHSV, saturationHSI e lLab não apresentaram relevância. As demais características são relevantes e de forma positiva.

Gráfico 23 - Importância das características para o melhor modelo MLP\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo SGD\_Ensemble será mostrado.

#### h) SGD\_Ensemble

O melhor modelo SGD\_Ensemble, dentre as 30 (trinta) repetições, fez uso da técnica PCA como primitiva de pré-processamento de características.


A MC do modelo é mostrada na Figura 52. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 16.

A classe 2- apresentou a menor precisão, com valor de 86%. Portanto, apenas 86% das amostras que o modelo previu como sendo pertencentes à classe 3, realmente pertencem a esta classe. Para as classes 3, 2 e 2+ as precisões são de 100%.

Quanto ao *recall*, o modelo previu 80% das amostras da classe 2+ como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

As classes que apresentaram maior *F1-Score* foram 3 e 2, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo SGD\_Ensemble foi de 95%.

Figura 52 - Matriz de confusão da previsão feita pelo melhor modelo SGD\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 16 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo SGD\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 86%      | 100%   | 92%      | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 80%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 19                       |
| <b>Média ponderada</b>    | 95%      | 95%    | 95%      | 19                       |

Fonte: A Autora (2021)

A curva ROC não foi gerada, uma vez que o SGD\_Ensemble foi baseado em votos majoritários.

Para o melhor modelo SGD\_Ensemble, as características mais relevantes são mostradas no Gráfico 24. A característica hueHSI foi considerada a mais relevante para o modelo, salientando que as características medianG, medianB, histG, saturationHSV, saturationHSI, lLab e bLab não apresentaram relevância na previsão. As demais características têm relevância positiva.

Gráfico 24 - Importância das características para o melhor modelo SGD\_Ensemble para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo LR\_Ensemble será mostrado.

#### i) LR\_Ensemble


O melhor modelo LR\_Ensemble, dentre as 30 (trinta) repetições, fez uso da técnica PCA como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 53.

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 17. Todas as métricas apresentam 100% de assertividade, sendo o valor da acurácia do modelo igual a 100%.

A curva ROC do modelo é mostrada no Gráfico 25. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Todas as classes do modelo apresentaram o valor da AUC é igual a 1.

Figura 53 - Matriz de confusão da previsão feita pelo melhor modelo LR\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 17 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo LR\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)


Para o melhor modelo LR\_Ensemble, as características mais relevantes são mostradas no Gráfico 26. A característica hueHSI foi considerada a mais relevante para o modelo, salientando o modelo faz uso com relevância positiva apenas das características histR, histG, histB, G, B hueHSV, hueHSI e intensityHSI.

Gráfico 25 - Curva ROC do melhor modelo LR\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 26 - Importância das características para o melhor modelo LR\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo DT\_Ensemble será mostrado.

#### j) DT\_Ensemble

O melhor modelo DT\_Ensemble, dentre as 30 (trinta) repetições, não fez uso de nenhuma técnica como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 54.


Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 18.

A classe 2- apresentou a menor precisão, com valor de 86%. Portanto, apenas 86% das amostras que o modelo previu como sendo pertencentes à classe 2-, realmente pertencem a esta classe. Para as classes 3, 2 e 2+ as precisões são de 100%.

Quanto ao *recall*, o modelo previu 89% das amostras da classe 2+ como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

As classes que apresentaram maior *F1-Score* foram as classes 3 e 2, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo DT\_Ensemble foi de 95%.

Figura 54 - Matriz de confusão da previsão feita pelo melhor modelo DT\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 27. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Todas as classes apresentaram o valor da AUC é igual a 1.


Tabela 18 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo DT\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 86%      | 100%   | 92%      | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 89%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 19                       |
| <b>Média ponderada</b>    | 95%      | 95%    | 95%      | 19                       |

Fonte: A Autora (2021)


Para o melhor modelo DT\_Ensemble, as características mais relevantes são mostradas no Gráfico 28. A característica hueHSI foi considerada a mais importante para o modelo, salientando o modelo não fez uso das características saturationHSV, intensityHSI, lLab, aLab e bLab. Observa-se valores negativos de importância relativos às características B e a saturationHSI indicando que estas aumentam a perda do modelo.

Gráfico 27 - Curva ROC do melhor modelo DT\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 28 - Importância das características para o melhor modelo DT\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

A seguir o modelo QDA\_Ensemble será mostrado.

#### k) QDA\_Ensemble

O melhor modelo QDA\_Ensemble, dentre as 30 (trinta) repetições, não usou nenhuma primitiva de pré-processamento de características.

Figura 55 - Matriz de confusão da previsão feita pelo melhor modelo QDA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A MC do modelo é mostrada na Figura 55. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 19. Como se vê na MC e nos valores das métricas apresentadas na Tabela 19, o modelo previu corretamente 100% das classes.


Tabela 19 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo QDA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)


A curva ROC do modelo é mostrada no Gráfico 29. Salienta-se que os rótulos das classes foram codificados, sendo classe 2- para classe 0, classe 3 para classe 1, classe 2 para classe 2 e classe 2+ para classe 3. Para as quatro classes do modelo, o valor da AUC é igual a 1.

Gráfico 29 - Curva ROC do melhor modelo QDA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 30 - Importância das características para o melhor modelo QDA\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo QDA\_Ensemble, as características mais relevantes são mostradas no Gráfico 30. A característica hueHSI foi a mais relevante para a previsão do modelo. Não foram usadas as características B, saturationHSV, valueHSV, lLab e bLab. A característica medianB apresenta valor negativo mostrando que seu uso aumenta a perda do modelo.

### I) NC\_Ensemble

O melhor modelo NC\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características. A MC do modelo é mostrada na Figura 56.


Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 20.

A classe 2- apresentou a menor precisão, com valor de 86%. Portanto, apenas 86% das amostras que o modelo previu como sendo pertencentes à classe 2-, realmente pertencem a esta classe. Para as classes 3, 2 e 2+ as precisões são de 100%.

Quanto ao *recall*, o modelo previu 80% das amostras da classe 2+ como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

As classes que apresentaram maior *F1-Score* foram as classes 3 e 2, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo NC\_Ensemble foi de 95%.

Figura 56 - Matriz de confusão da previsão feita pelo melhor modelo NC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 20 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo NC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 86%      | 100%   | 92%      | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 80%    | 89%      | 5                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 19                       |
| <b>Média ponderada</b>    | 95%      | 95%    | 95%      | 19                       |


Fonte: A Autora (2021)

A curva ROC não é apresentada, pelo fato de modelos ensemble com base em variações do NC não aceitarem votação ponderada.

Para o melhor modelo NC\_Ensemble, as características mais importantes são mostradas no Gráfico 31. A característica hueHSI foi a mais relevante para a previsão do modelo. As características medianB, lLab e bLab não

apresentaram relevância. Todas as demais características são positivamente relevantes para o modelo.

Gráfico 31 - Importância das características para o melhor modelo NC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo RC\_Ensemble será mostrado.

#### m) RC\_Ensemble

O melhor modelo RC\_Ensemble, dentre as 30 (trinta) repetições, não usou nenhuma primitiva de pré-processamento de características.


A MC do modelo é mostrada na Figura 57.

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 21. Como se vê na MC e nos valores das métricas apresentadas na Tabela 21, o modelo previu corretamente 100% das classes.

A curva ROC não é apresentada, uma vez que o modelo usou votos majoritários.

Para o melhor modelo RC\_Ensemble, as características mais relevantes são mostradas no Gráfico 32. A característica hueHSI foi a mais relevante para a previsão do modelo.

Figura 57 - Matriz de confusão da previsão feita pelo melhor modelo RC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 21 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo RC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)

Não foram usadas as características *medianB*, *saturationHSV*. As características *saturationHSI*, *lLab* e *aLab* apresentam valores negativos, mostrando que a sua utilização aumenta a perda do modelo. Todas as demais características são relevantes de forma positiva.

Gráfico 32 - Importância das características para o melhor modelo RC\_Ensemble, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

A seguir o modelo KNN será mostrado.

#### n) KNN

O melhor modelo KNN, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características.

Figura 58 - Matriz de confusão da previsão feita pelo melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A MC do modelo é mostrada na Figura 58. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 22.

Como se vê na MC e nos valores das métricas apresentadas na Tabela 22, o modelo previu corretamente 100% das classes.


A curva ROC é apresentada no Gráfico 33, e todas as classes apresentam valor de AUC igual a 1.

Tabela 22 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> |          |        | 100%     | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |

Fonte: A Autora (2021)

Gráfico 33 - Curva ROC do melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

Para o melhor modelo KNN, as características mais relevantes são mostradas, através da técnica de permutações, no Gráfico 34.

A característica hueHSI foi a mais relevante para a previsão do modelo. Não foram usadas as características medianB, R, saturationHSV, valueHSV,

intensityHSI, lLab e bLab. Todas as demais características são relevantes de forma positiva.

Gráfico 34 - Importância das características para o melhor modelo KNN, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo SGB será apresentado.

#### o) SGB

O melhor modelo SGD, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 59.


Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 23.

Como se vê na MC e nos valores das métricas apresentadas na Tabela 23, o modelo previu corretamente 100% das classes.

A curva ROC é apresentada no Gráfico 35, e todas as classes apresentam valor de AUC igual a 1.

Para o melhor modelo SGD, as características mais relevantes são mostradas no Gráfico 36. A característica hueHSI foi a mais relevante para a previsão do modelo. Não foram usadas as características medianR, medianG, medianB, B, saturationHSV, valueHSV, saturationHSI, lLab, aLab e bLab. Todas as demais características são relevantes de forma positiva.

Figura 59 - Matriz de confusão da previsão feita pelo melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

Tabela 23 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 2-                        | 100%     | 100%   | 100%     | 6                        |
| 3                         | 100%     | 100%   | 100%     | 4                        |
| 2                         | 100%     | 100%   | 100%     | 4                        |
| 2+                        | 100%     | 100%   | 100%     | 5                        |
| <b>Acurácia do modelo</b> | 100%     |        |          | <b>Total de Amostras</b> |
|                           |          |        |          | 19                       |
| <b>Média macro</b>        | 100%     | 100%   | 100%     | 19                       |
| <b>Média ponderada</b>    | 100%     | 100%   | 100%     | 19                       |


Fonte: A Autora (2021)

Gráfico 35 - Curva ROC do melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 36 - Importância das características para o melhor modelo SGD, para classificação do frescor da carne de atum, em 30 (trinta) repetições




Fonte: A Autora (2021)

## APÊNDICE C – ANÁLISE DOS MELHORES MODELOS PARA A CLASSIFICAÇÃO DE AMOSTRAS DE SALMÃO

Neste Apêndice são apresentadas as métricas: acurácia de teste, precisão e *recall*, *F1-Score*, MC, e curva ROC, dos 17 (dezessete) modelos escolhidos para classificação do frescor da carne do salmão, calculadas a partir de previsões na respectiva base de teste, feitas com os melhores modelos mostrados no Quadro 8. Salienta-se que as previsões foram feitas nas respectivas bases de teste da repetição na qual os modelos foram escolhidos. Os gráficos e análises são feitos considerando, a classe 0 representando o nível de frescor mais baixo, denominado "consumo imediato", a classe 1 representando o rótulo "fresco", e por fim, a classe 2 representando a classe com maior nível de frescor, rotulada como "muito fresco". Percebe-se, nas análises mostradas a seguir, que nenhum modelo fez previsões com 100% de assertividade nas classificações do frescor de amostras de salmão.

Para entender previsões erradas de alguns classificadores, representadas em suas respectivas MCs, recorreu-se à Figura 32.b, gráfico de agrupamento das classes de frescor de amostras de salmão gerado pela técnica UMAP, mostrado novamente na Figura 60.

Figura 60 - Gráfico de agrupamento das classes de frescor de amostra de salmão gerado pela técnica UMAP e destaque para possíveis confusões na classificação realizada pelos modelos



Fonte: A Autora (2021)

Vê-se, no menor destaques amostras de classes distintas muito próximas, fazendo com que modelos confundam a classificação destas amostras ao fazer previsões, como se vê nas MCs mostradas a seguir. A baixa quantidade de

amostras no conjunto de dados fez com que algumas amostras fossem localizadas afastadas de seus verdadeiros agrupamentos, como se vê no maior destaque da Figura 60, motivo este também para confusão ou erros de classificação em previsões feitas pelos modelos. Salienta-se também a pouca distância entre algumas amostras da classe 0 e da classe 1, indicando valores de características próximos, sendo mais um motivo para previsões confusas.

Para a interpretação da importância de características revelada pela técnica de permutações, representada em gráficos mostrados a seguir, segue-se as mesmas justificativas apresentadas no Apêndice B, para a não retirada de recursos usados por um modelo com base em pontuações baixas (ou negativas) de importância reveladas pela técnica de permutações. A técnica de permutações revela a importância de um recurso isolado para a previsão através do embaralhamento aleatório de seus dados. Relevâncias negativas ou nulas indicam a pouca importância isolada do recurso para as previsões, sem considerar possíveis correlações deste com outros recursos. Possíveis correlações podem levar a boas previsões do modelo, de modo que o recurso em questão pode ter importância. De maneira mais geral, ressalta-se que os gráficos de importância de características ajudam a interpretar os modelos, trazendo à tona que características mais devem ser observadas, não sendo esta, a estratégia para escolha de características.

Assim como mostrado nos modelos para classificação de amostras de carne de atum, percebe-se que as relevâncias dos recursos mudam entre os modelos para a classificação de amostras de carne de salmão, mostrados a seguir, já que os modelos são matematicamente diferentes, usam primitivas de pré-processamento de características distintas e usam dados distintos.

#### **a) NC\_Ensemble**


O melhor modelo NC\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica *VarianceThreshold* como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 61. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 24.

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, apenas 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

Figura 61 - Matriz de confusão da previsão feita pelo melhor modelo NC\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 24 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo NC\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo NC\_Ensemble foi de 95%.

A curva ROC não é apresentada, pelo fato de modelos ensemble com base em variações do NC não aceitarem votação ponderada.

Gráfico 37 - Importância das características para o melhor modelo NC\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo NC\_Ensemble, as características mais importantes são mostradas no Gráfico 37. A característica histG foi a mais relevante para a previsão do modelo. As características medianR, medianB, histR, histB, R, e G foram utilizadas pelo modelo com relevância menor.


## b) NC

O melhor modelo NC, dentre as 30 (trinta) repetições, não usou nenhuma técnica como primitiva de pré-processamento de características. A MC do modelo é mostrada na Figura 62.

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 25.

A classes 1 apresentou o menor valor de precisão, sendo igual a 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 a precisão é de 100%.

Figura 62 - Matriz de confusão da previsão feita pelo melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo NC foi de 95%.

Tabela 25 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 88%      | 100%   | 93%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A curva ROC não é apresentada, uma vez que classificadores NC não usam probabilidades para fazer previsões.

Para o melhor modelo NC, as características mais importantes são mostradas no Gráfico 38. As características medianG, medianB, hueHSI, aLab e bLab não tiveram relevância. As demais características foram utilizadas pelo modelo com relevâncias menores, porém positivas.

Gráfico 38 - Importância das características para o melhor modelo NC, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


A seguir o modelo LDA\_Ensemble será apresentado.

### c) LDA\_Ensemble

O melhor modelo LDA\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica LDA como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 63.

Figura 63 - Matriz de confusão da previsão feita pelo melhor modelo LDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 26.

Tabela 26 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo LDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, apenas 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.


Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo LDA\_Ensemble foi de 95%.

A curva ROC do modelo é mostrada no Gráfico 39. As classes 0 e 2 apresentam valor de AUC igual a 0,99. Para a classe 1, o valor da AUC é igual a 1.


Para o melhor modelo LDA\_Ensemble, as características mais importantes são mostradas no Gráfico 40. A característica histG foi a mais relevante para a previsão do modelo. As características saturationHSV, hueHSV, hueHSI, lLab e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo.

Gráfico 39 - Curva ROC do melhor modelo LDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 40 - Importância das características para o melhor modelo LDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo MLP será mostrado.

#### d) MLP

O melhor modelo MLP, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características.


A MC do modelo é mostrada na Figura 64. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 27.

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, apenas 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo MLP foi de 95%.

Figura 64 - Matriz de confusão da previsão feita pelo melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 27 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)


A curva ROC do modelo é mostrada no Gráfico 41. As classes 0 e 2 apresentam valor de AUC igual a 0,99. Para a classe 1, o valor da AUC é igual a 1.

Gráfico 41 - Curva ROC do melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 42 - Importância das características para o melhor modelo MLP, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo MLP, as características mais importantes são mostradas no Gráfico 42. A característica histG foi a mais relevante para a previsão do modelo. As características medianG, medianB, saturationHSV, hueHSV, saturationHSI, hueHSI, lLab, aLab e bLab não apresentaram

relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.


### e) SVM

O melhor modelo SVM, dentre as 30 (trinta) repetições, não usou nenhuma técnica como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 65. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 28.

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.

Figura 65 - Matriz de confusão da previsão feita pelo melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 28 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |


Fonte: A Autora (2021)

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo SVM foi de 95%.

A curva ROC não é apresentada, uma vez que classificadores SVM não fazem probabilidades de previsões.

Gráfico 43 - Importância das características para o melhor modelo SVM, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo SVM, as características mais importantes são mostradas no Gráfico 43. A característica histG foi a mais relevante para a previsão do modelo. As características medianB, B, saturationHSI, hueHSI, ILab, aLab e bLab não apresentaram relevâncias. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

#### f) SVM\_Ensemble

O melhor modelo SVM\_Ensemble, dentre as 30 (trinta) repetições, não usou nenhuma técnica como primitiva de pré-processamento de características.


A MC do modelo é mostrada na Figura 66.

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 29.

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%. Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%.

A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo SVM\_Ensemble foi de 95%.

Figura 66 - Matriz de confusão da previsão feita pelo melhor modelo SVM\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 29 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo SVM\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A curva ROC do modelo não é mostrada, uma vez que o SVM\_Ensemble foi construído através de voto majoritário.

Gráfico 44 - Importância das características para o melhor modelo SVM\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo SVM\_Ensemble, as características mais importantes são mostradas no Gráfico 44. A característica histG foi a mais relevante para a previsão do modelo. As características medianB, hueHSI e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, dentre elas e com relevâncias negativas aparecem as características saturationHSV, saturationHSI e aLab.

### g) LDA


O melhor modelo LDA, dentre as 30 (trinta) repetições, não usou nenhuma técnica como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 67. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 30.

A classe 2 apresentou o menor valor de precisão, sendo igual a 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1, a precisão é de 100%. Quanto ao *recall*, o modelo previu 86% das amostras da classe 0

como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%. A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo NC foi de 95%.

Figura 67 - Matriz de confusão da previsão feita pelo melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 30 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |


Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 45. As classes 0 e 2 apresentam valor de AUC igual a 0,99. Para a classe 1, o valor da AUC é igual a 1.

Para o melhor modelo LDA, as características mais importantes são mostradas no Gráfico 46. A característica histG foi a mais relevante para a previsão do modelo. As características medianB, saturationHSI, hueHSI, lLab e


bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

Gráfico 45 - Curva ROC do melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 46 - Importância das características para o melhor modelo LDA, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


A seguir o modelo LR será mostrado.

## h) LR

O melhor modelo LR, dentre as 30 (trinta) repetições, usou a técnica *VarianceThreshold* como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 68.

Figura 68 - Matriz de confusão da previsão feita pelo melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 31.

Tabela 31 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> | 95%      |        |          | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)


A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%. A classe 1 apresentou maior *F1-Score*, mostrando melhor relação

entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo LR foi de 95%.


A curva ROC do modelo é mostrada no Gráfico 47. As classes 0 e 2 apresentam valor de AUC igual a 0,99. Para a classe 1, o valor da AUC é igual a 1.

Gráfico 47 - Curva ROC do melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 48 - Importância das características para o melhor modelo LR, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


Para o melhor modelo LR, as características mais importantes são mostradas no Gráfico 48. A característica medianR foi a mais relevante para a previsão do modelo. As características medianB, B, saturationHSI, hueHSV, intensityHSI, hueHSI, lLab e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

### i) GB

O melhor modelo GB, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 69.

Figura 69 - Matriz de confusão da previsão feita pelo melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 32.


A classe 1 apresentou a menor precisão, com valor de 78%. Portanto, 78% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 as precisões são de 100%. Quanto ao *recall*, o modelo previu 71% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo GB foi de 90%.

Tabela 32 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 71%    | 83%      | 7                        |
| 1                         | 78%      | 100%   | 88%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 90%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 93%      | 90%    | 90%      | 21                       |
| <b>Média ponderada</b>    | 93%      | 90%    | 90%      | 21                       |


Fonte: A Autora (2021)

Gráfico 49 - Curva ROC do melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 50 - Importância das características para o melhor modelo GB, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 49. A classe 0 apresenta valor de AUC igual a 0,85, a classe 1 apresenta valor de AUC igual a 0,93. Por fim, a classe 2 apresenta valor de AUC igual a 1.


Para o melhor modelo GB, as características mais importantes são mostradas no Gráfico 50. A característica histG foi a que apresentou maior relevância para a previsão do modelo. As características aLab e bLab não apresentaram relevância. Todas as demais características têm relevância para o modelo.

### j) AdaBoost\_Ensemble

O melhor modelo AdaBoost\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento para características.

A MC do modelo é mostrada na Figura 70. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 33.

Figura 70 - Matriz de confusão da previsão feita pelo melhor modelo AdaBoost\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A classe 1 apresentou a menor precisão, com valor de 78%. Portanto, 78% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 71% das amostras da classe 0 como realmente pertencentes à esta classe. As classes 1 e 2 apresentaram *recall* de

100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo AdaBoost\_Ensemble foi de 90%.

Tabela 33 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo AdaBoost\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 71%    | 83%      | 7                        |
| 1                         | 78%      | 100%   | 88%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 90%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 93%      | 90%    | 90%      | 21                       |
| <b>Média ponderada</b>    | 93%      | 90%    | 90%      | 21                       |

Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 51. A classe 0 apresenta valor de AUC igual a 0,93, a classe 1 igual a 0,93 e a classe 2 igual 1.


Para o melhor modelo AdaBoost\_Ensemble, as características mais importantes são mostradas no Gráfico 52. A característica histG foi a mais relevante para a previsão do modelo. As características aLab e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

Gráfico 51 - Curva ROC do melhor modelo AdaBoost\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 52 - Importância das características para o melhor modelo AdaBoost\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


A seguir o modelo QDA\_Ensemble será mostrado.

### k) QDA\_Ensemble

O melhor modelo QDA\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica *Autoencoder* como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 71.

Figura 71 - Matriz de confusão da previsão feita pelo melhor modelo QDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 34.

A classe 0 apresentou a menor precisão, com valor de 86%. Portanto, 86% das amostras que o modelo previu como sendo pertencentes à classe 0, realmente pertencem a esta classe. A precisão da classe 2 foi de 88%. Portanto 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente são desta classe. Para a classe 1 a precisão é de 100%.


Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. O mesmo acontece com o *recall* da classe 1. A classe 2 apresentou *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo AdaBoost\_Ensemble foi de 90%.

Tabela 34 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo QDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 86%      | 86%    | 86%      | 7                        |
| 1                         | 100%     | 86%    | 92%      | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 90%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 91%      | 90%    | 90%      | 21                       |
| <b>Média ponderada</b>    | 91%      | 90%    | 90%      | 21                       |

Fonte: A Autora (2021)

Gráfico 53 - Curva ROC do melhor modelo QDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições




Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 53. A classe 0 apresenta valor de AUC igual a 0,99. Para as demais classes do modelo, o valor da AUC é igual a 1.

Para o melhor modelo QDA\_Ensemble, as características mais importantes são mostradas no Gráfico 54. Como o modelo usa a técnica *Autoencoder* que reduz a dimensionalidade do conjunto de dados, não se sabe que novas características são geradas. A característica rotulada com 6 foi a mais relevante.

Gráfico 54 - Importância das características para o melhor modelo QDA\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo AdaBoost será mostrado.

### I) AdaBoost

O melhor modelo AdaBoost, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento para características.


A MC do modelo é mostrada na Figura 72. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 35.

A classe 1 apresentou a menor precisão, com valor de 78%. Portanto, 78% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 71% das amostras da classe 0 como realmente pertencentes à esta classe. As classes 1 e 2 apresentaram *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo AdaBoost foi de 90%.

A curva ROC do modelo é mostrada no Gráfico 55. A classe 0 apresenta valor de AUC igual a 0,93, a classe 1 igual a 0,93 e a classe 2 igual 1.

Figura 72 - Matriz de confusão da previsão feita pelo melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 35 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 71%    | 83%      | 7                        |
| 1                         | 78%      | 100%   | 88%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 90%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 93%      | 90%    | 90%      | 21                       |
| <b>Média ponderada</b>    | 93%      | 90%    | 90%      | 21                       |

Fonte: A Autora (2021)

Para o melhor modelo AdaBoost, as características mais importantes são mostradas no Gráfico 56. A característica histG foi a mais relevante para a previsão do modelo. As características aLab e bLab não apresentaram


relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

Gráfico 55 - Curva ROC do melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 56 - Importância das características para o melhor modelo AdaBoost, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


### m) DT

O melhor modelo DT, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento para características.

A MC do modelo é mostrada na Figura 73. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1 Score* mostrados na Tabela 36.

A classe 1 apresentou a menor precisão, com valor de 78%. Portanto, 78% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 as precisões são de 100%.

Figura 73 - Matriz de confusão da previsão feita pelo melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


Tabela 36 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe             | Precisão | Recall | F1-Score | Número de amostras |
|--------------------|----------|--------|----------|--------------------|
| 0                  | 100%     | 71%    | 83%      | 7                  |
| 1                  | 78%      | 100%   | 88%      | 7                  |
| 2                  | 100%     | 100%   | 100%     | 7                  |
| Acurácia do modelo | 90%      |        |          | Total de Amostras  |
|                    |          |        |          | 21                 |
| Média macro        | 93%      | 90%    | 90%      | 21                 |
| Média ponderada    | 93%      | 90%    | 90%      | 21                 |

Fonte: A Autora (2021)

Quanto ao *recall*, o modelo previu 71% das amostras da classe 0 como realmente pertencentes à esta classe. As classes 1 e 2 apresentaram *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo DT foi de 90%.


Gráfico 57 - Curva ROC do melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 57. A classe 0 apresenta valor de AUC igual a 0,86, a classe 1 igual a 0,93 e a classe 2 igual 1.

Gráfico 58 - Importância das características para o melhor modelo DT, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo DT, as características mais importantes são mostradas no Gráfico 58. A característica histG foi a mais relevante para a previsão do modelo. Apenas as características aLab e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

#### n) Ensemble\_Heterogêneo


Esta seção mostra o melhor Ensemble\_Heterogêneo, dentre as 30 (trinta) repetições.

O melhor modelo Ensemble\_Heterogêneo, dentre as 30 (trinta) repetições, usou a técnica *Autoencoder* como primitiva de pré-processamento para características.

A MC do modelo é mostrada na Figura 74. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 37.

A classe 1 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 1 e 2 as precisões são iguais a 100%.

Figura 74 - Matriz de confusão da previsão feita pelo melhor Ensemble\_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As classes 1 e 2 apresentaram *recall* de 100%.

A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo Ensemble\_Heterogêneo foi de 95%.


Tabela 37 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo Ensemble\_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 88%      | 100%   | 93%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A curva ROC não é apresentada, uma vez que o modelo foi construído através de votação majoritário.

Gráfico 59 - Importância das características para o melhor modelo Ensemble\_Heterogêneo, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)


Para o melhor modelo Ensemble\_Heterogêneo, as características mais importantes são mostradas no Gráfico 59. Como o modelo usa a técnica *Autoencoder*, não é possível saber quais as características usadas pelo modelo, sendo a característica rotulada como 6 como a mais relevante.

#### o) SGD

O melhor modelo SGB, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento para características.

A MC do modelo é mostrada na Figura 75.

Figura 75 - Matriz de confusão da previsão feita pelo melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 38.

A classe 0 apresentou a menor precisão, com valor de 75%. Portanto, 75% das amostras que o modelo previu como sendo pertencentes à classe 0, realmente pertencem a esta classe. Dentre as amostras que o modelo previu como sendo da classe 2, 88% realmente são pertencentes à classe 2. Para a classe 1 a precisão é de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe, sendo 71% de *recall* para a classe 2. A classe 1 apresentou *recall* de 100%.

A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo SGD foi de 86%.


Tabela 38 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições

| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 75%      | 86%    | 80%      | 7                        |
| 1                         | 100%     | 71%    | 83%      | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> |          |        | 86%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 88%      | 86%    | 86%      | 21                       |
| <b>Média ponderada</b>    | 88%      | 86%    | 86%      | 21                       |

Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 60. A classe 0 apresenta valor de AUC igual a 0,43 e as classes 1 e 2 apresentam valor de AUC igual a 1.


Gráfico 60 - Curva ROC do melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Para o melhor modelo SGD, as características mais importantes são mostradas no Gráfico 61. A característica histG foi a mais relevante para a previsão do modelo. As características hueHSI, lLab, aLab e bLab não apresentaram relevância. Todas as demais características são relevantes para o modelo.

Gráfico 61 - Importância das características para o melhor modelo SGD, para classificação do frescor da carne do salmão, em 30 (trinta) repetições




Fonte: A Autora (2021)

A seguir o modelo RF será apresentado.

#### p) RF

Esta seção mostra o melhor modelo RF, dentre as 30 (trinta) repetições.

Figura 76 - Matriz de confusão da previsão feita pelo melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

O melhor modelo RF, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento para características.

A MC do modelo é mostrada na Figura 76. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 39.

A classe 1 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 1, realmente pertencem a esta classe. Para as classes 0 e 2 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As classes 1 e 2 apresentaram *recall* de 100%. A classe 2 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo RF foi de 95%.

Tabela 39 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 88%      | 100%   | 93%      | 7                        |
| 2                         | 100%     | 100%   | 100%     | 7                        |
| <b>Acurácia do modelo</b> |          |        | 95%      | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 62. Todas as classes apresentam valor de AUC igual a 1.


Para o melhor modelo RF, as características mais importantes são mostradas no Gráfico 63. A característica histG foi a mais relevante para a previsão do modelo. As características lLab e aLab não apresentaram relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

Gráfico 62 - Curva ROC do melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 63 - Importância das características para o melhor modelo RF, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

A seguir o modelo RF\_Ensemble será apresentado.

#### q) RF\_Ensemble


O melhor modelo RF\_Ensemble, dentre as 30 (trinta) repetições, usou a técnica PCA como primitiva de pré-processamento de características.

A MC do modelo é mostrada na Figura 77. Para interpretar a MC, recorreu-se aos valores de precisão, *recall* e *F1-Score* mostrados na Tabela 40.

A classe 2 apresentou a menor precisão, com valor de 88%. Portanto, 88% das amostras que o modelo previu como sendo pertencentes à classe 2, realmente pertencem a esta classe. Para as classes 0 e 1 as precisões são de 100%.

Quanto ao *recall*, o modelo previu 86% das amostras da classe 0 como realmente pertencentes à esta classe. As demais classes apresentaram *recall* de 100%. A classe 1 apresentou maior *F1-Score*, mostrando melhor relação entre as respectivas métricas de precisão e *recall*. Por fim, a acurácia de teste do melhor modelo RF\_Ensemble foi de 95%.

Figura 77 - Matriz de confusão da previsão feita pelo melhor modelo RF\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Tabela 40 - Precisão, *recall*, *F1-Score* e acurácia das previsões do melhor modelo RF\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições


| Classe                    | Precisão | Recall | F1-Score | Número de amostras       |
|---------------------------|----------|--------|----------|--------------------------|
| 0                         | 100%     | 86%    | 92%      | 7                        |
| 1                         | 100%     | 100%   | 100%     | 7                        |
| 2                         | 88%      | 100%   | 93%      | 7                        |
| <b>Acurácia do modelo</b> | 95%      |        |          | <b>Total de Amostras</b> |
|                           |          |        |          | 21                       |
| <b>Média macro</b>        | 96%      | 95%    | 95%      | 21                       |
| <b>Média ponderada</b>    | 96%      | 95%    | 95%      | 21                       |

Fonte: A Autora (2021)

A curva ROC do modelo é mostrada no Gráfico 64. Para a classe 0, o valor da AUC é igual a 0,94, para a classe 1 é igual a 1,0 e para a classe 2 é igual a 0,99.


Para o melhor modelo RF\_Ensemble, as características mais importantes são mostradas no Gráfico 65. A característica histG foi a mais relevante para a previsão do modelo. A característica hueHSI não apresentou relevância. Todas as demais características são relevantes para o modelo, com relevâncias positivas.

Gráfico 64 - Curva ROC do melhor modelo RF\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)

Gráfico 65 - Importância das características para o melhor modelo RF\_Ensemble, para classificação do frescor da carne do salmão, em 30 (trinta) repetições



Fonte: A Autora (2021)