

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

THAÍS NAYARA DA CRUZ

**SELEÇÃO DE ATRIBUTOS DE IMAGEM BASEADA EM ALGORITMO GENÉTICO
E INTELIGÊNCIA COMPUTACIONAL PARA O DIAGNÓSTICO DO CÂNCER DE
MAMA UTILIZANDO MAMOGRAFIAS DIGITAIS**

Recife
2017

THAÍS NAYARA DA CRUZ

**SELEÇÃO DE ATRIBUTOS DE IMAGEM BASEADA EM ALGORITMO GENÉTICO
E INTELIGÊNCIA COMPUTACIONAL PARA O DIAGNÓSTICO DO CÂNCER DE
MAMA UTILIZANDO MAMOGRAFIAS DIGITAIS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Biomédica, da Universidade Federal de Pernambuco, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Biomédica.

Área de concentração: Computação Biomédica

Orientador: Prof. Dr. Wellington Pinheiro dos Santos

Recife

2017

Catálogo na fonte
Bibliotecária Valdicea Alves, CRB-4 / 1260.

C957s

Cruz, Thaís Nayara da.

Seleção de atributos de imagem baseada em algoritmo genético e inteligência computacional para o diagnóstico do câncer de mama utilizando mamografias digitais / Thaís Nayara da Cruz. – 2017.

81folhas, Il., Tabs. Abre. e Sigl.

Orientador: Prof. Dr. Wellington Pinheiro dos Santos.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação de Engenharia Biomédica, 2017.

Inclui Referências e Anexos.

1. Engenharia Biomédica. 2. Classificação. 3. Câncer de mama. 4. Mamografia.
5. Redução de atributos. 6. Sistema de apoio. I. Santos, Wellington Pinheiro dos
(Orientadora). II. Título.

UFPE

610.28 CDD (22. ed.)

BCTG/2017-362

THAÍS NAYARA DA CRUZ

**SELEÇÃO DE ATRIBUTOS DE IMAGEM BASEADA EM ALGORITMO GENÉTICO
E INTELIGÊNCIA COMPUTACIONAL PARA O DIAGNÓSTICO DO CÂNCER DE
MAMA UTILIZANDO MAMOGRAFIAS DIGITAIS**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Biomédica e aprovada em sua forma final pela Orientadora e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Wellington Pinheiro dos Santos, Doutor pela Universidade Federal de Campina Grande.

Banca Examinadora

Prof. Dr. Ricardo Emmanuel de Souza, Doutor pela Universidade Federal de Pernambuco.

Prof. Dr. Wellington Pinheiro dos Santos, Doutor pela Universidade Federal de Campina Grande.

Prof^a. Dra. Rita de Cássia Fernandes de Lima, Doutora pela Universidade de São Paulo.

Recife, 24 de fevereiro de 2017.

A Deus, a minha mãe Maria Cristina, a minha irmã Thamyris Mayara, a meu tio Mauro Ricardo, a minha avó Edileuza Alexandrina e ao meu avô José Francelino, que se foi cedo, mas que deixou muitas lembranças boas e realizou muitas obras positivas na minha vida e na vida da nossa família.

AGRADECIMENTOS

Agradeço e louvo primeiramente a Deus, pelo dom da vida e por toda a força que me fez caminhar aqui até hoje findando mais um ciclo importante na minha vida.

A CAPES pelo incentivo financeiro que me ajudou a seguir em frente.

A minha mãe Maria Cristina que é o alicerce da família e a quem devo agradecimentos eternos, à minha irmã Thamyris Mayara, que ao longo da vida foi além de irmã minha melhor amiga e sem ela não teria chegado até aqui. Aos meus avôs Edileuza e José Francelino (*in memorian*), por terem sido meus segundos pais e ajudar a minha mãe a me tornar o que sou hoje. Ao meu pai Edvaldo (*in memorian*) que se foi cedo, mas deixou aqui na Terra uma linda família. Aos meus tios Edmilson e Edlson que sempre me apoiaram e me ajudaram nessa caminhada.

Agradeço ao meu orientador Wellington Pinheiro por todo o ensinamento, paciência e dedicação a uma profissional de saúde que passou por diversos problemas ao longo desses dois anos, mas que sempre acreditou e confiou em mim, os meus sinceros agradecimentos e o meu muito obrigado por me mostrar essa área tão encantadora que me cativou.

A Diego Ricardo, que é e sempre será muito importante na minha vida. Ao meu tio Mauro, que mesmo distante sempre deu um jeito de estar presente, me apoiando e me incentivando a buscar sempre mais conhecimento, estendo esse agradecimento a sua esposa, tia Dayenne e aos seus filhos e meus primos Mateus e Maiara.

Sou grata também aos amigos que conquistei durante essa jornada. Juntos a carga ficou mais leve e os momentos compartilhados se tornaram inesquecíveis. Meu muito obrigado a Gabi, Valter, Tiago, David, Ossamu, Flávia, Ana Paula, Dayvisson, Heuryk e por fim Leo, que é um amigo de longa data e que pudemos compartilhar mais esse momento.

E a todos os meus amigos da vida que muitas vezes tiveram que lidar com minha ausência mais que mesmo distantes são especiais na minha vida, o meu muito obrigado a Rafael, Rafaela, Duda, Gaby, Aline, Jeyssyca, Jéssica Maricelly, Amanda Rosineide, Manuely, Victor, Anny, Eliziane, Marcela, Mariana, Priscila, e demais, que, embora não citados, o meu carinho por eles é o mesmo.

A todos o meu muito obrigado.

Thaís Nayara da Cruz

“Medo de nada, só amor”

(Padre Haroldo J. Rahm, SJ)

RESUMO

O câncer de mama é um grande problema de saúde pública mundial, onde o exame mais utilizado para realizar os diagnósticos é a mamografia. Nas últimas décadas vêm surgindo ao redor do mundo sistemas de apoio ao diagnóstico e a detecção de câncer de mama. Tendo como objetivo desenvolver um sistema de apoio ao diagnóstico do câncer de mama por análise de mamogramas a partir de classificadores baseados em redes neurais artificiais do tipo Máquinas de Aprendizado Extremo e de atributos estatísticos e de forma, reduzidos a partir da aplicação de técnicas de seleção de atributos, com enfoque em algoritmos genéticos. Esse estudo é baseado em processamento de imagens médicas que foi dividido em 4 etapas: Criação da base de dados IRMA modificada; preparação e pré processamento das imagens; seleção de atributos/redução de atributos e processo de classificação, com os classificadores SMO, MLP, IBK e RBF. Como resultados têm-se que o banco de dados construído possui um total de 505 imagens (222 de mama adiposa e 283 de mama fibroglandular) distribuídas por classificação e por tipo de lesão. Quanto ao número de atributos reduzidos, tem-se que na maioria ele se mostrou eficaz, mas que quando a redução era inferior a 50 atributos, houve uma brusca queda na taxa de acerto. Os classificadores que obtiveram melhores taxas de acertos foram respectivamente, SMO (92,86%), MLP (92,86%), IBK (75%) e RBF (51,43%). Conclui-se assim, que os resultados desse estudo fornecem informações valiosas sobre os sistemas de apoio ao diagnóstico e que o classificador de melhor escolha é o SMO.

Palavras - chave: Classificação. Câncer de mama. Mamografia. Redução de atributos. Sistema de apoio.

ABSTRACT

Breast cancer is a major public health problem worldwide, where the most commonly used diagnostic test is mammography. Systems of support to diagnosis and detection of breast cancer have been emerging around the world in the last decades. The objective of this study was to develop a support system for the diagnosis of breast cancer by analyzing mammograms from classifiers based on artificial neural networks of the Extreme Learning Machines type and statistical and form attributes, reduced by the application of selection techniques of attributes, focusing on genetic algorithms. This study is based on medical imaging processing that was divided into 4 steps: Creation of the modified IRMA database; preparation and pre-processing of images; selection of attributes / reduction of attributes and classification process, with the classifiers SMO, MLP, IBK and RBF. As a result, the database has a total of 505 images (222 of adipose breast and 283 of fibroglandular breast) distributed by classification and type of lesion. As for the number of reduced attributes, it has been found that in most of them it was effective, but when the reduction was less than 50 attributes, there was a sharp drop in the hit rate. The classifiers that obtained the best hit rates were, respectively, SMO (92.86%), MLP (92.86%), IBK (75%) and RBF (51.43%). We conclude that the results of this study provide valuable information about diagnostic support systems and that the best-fit classifier is the SMO.

Keywords: Classification. Breast cancer. Mammography. Reduction of attributes. Support system.

LISTA DE ILUSTRAÇÕES

Figura 1. Esquema do funcionamento do sistema CAD típico	31
Figura 2. Demonstração de balanceamento de instância	39
Figura 3. Demonstração das imagens utilizadas na base de dados categorizadas por tipo de densidade mamária e tipo de lesão	39
Figura 4. Representação da distribuição das imagens em pastas na primeira etapa de construção.....	46
Figura 5. Representação da distribuição das imagens em pastas após o processo de demarcação das bordas	47
Figura 6. Imagens de mama adiposa benigna distribuída por tipo de lesão	49
Figura 7. Imagens de mama adiposa maligna distribuída por tipo de lesão	49
Figura 8. Imagens de mama fibroglandular benigna distribuída por tipo de lesão	50
Figura 9. Imagens de mama fibroglandular maligna distribuída por tipo de lesão	50
Figura 10. Comparativo de imagens não demarcadas e marcadas de mama adiposa, distribuídas por classificação.....	51
Figura 11. Comparativo de imagens não demarcadas e marcadas de mama fibroglandular, distribuídas por classificação e tipo de lesão.....	51
Figura 12. Demonstração do número de atributos reduzidos após a aplicação de seleção de atributos.....	53
Figura 13. Comparação da melhor taxa de acerto encontrada em cada classificador....	62

LISTA DE TABELAS

Tabela 1. População-alvo e periodicidade dos exames no rastreamento de câncer de mama	23
Tabela 2. Classificação BI-RADS®	27
Tabela 3. Organização das 12 classes e seus respectivos significado	40
Tabela 4. Representação das seleções de atributos de acordo com sua configuração ..	43
Tabela 5. Representação dos classificadores utilizados de acordo com a sua configuração.....	44
Tabela 6. Distribuição da frequência numérica de imagens de densidade adiposa, com sua classificação e tipo de lesão	48
Tabela 7. Distribuição da frequência numérica de imagens de densidade fibroglandular, com sua classificação e tipo de lesão	48
Tabela 8. Resultado da classificação a partir de seleção de atributos 01	54
Tabela 9. Resultado da classificação a partir de Seleção de Atributos 02	55
Tabela 10. Resultado da classificação a partir de Seleção de Atributos 03	57
Tabela 11. Resultado da classificação a partir de Seleção de Atributos 04	58
Tabela 12. Resultado da classificação a partir de Seleção de Atributos 05	59
Tabela 13. Resultado da classificação a partir de Seleção de Atributos 06	60
Tabela 14. Resultado da classificação a partir de seleção de atributos 07	61

LISTA DE ABREVIATURAS E SIGLAS

BI-RADS® - Breast Imaging Reporting and Data System

CADe - Sistemas de Apoio à Detecção

CADx - Sistemas de Apoio ao Diagnóstico

CC - Crânio – Caudal

CFS - Correlation Based Feature Selection - Subset Evaluation

FN - Falsa Negativa

FP - Falsa Positiva

IBK - Aprendizagem baseada em instâncias com parâmetro k

INCA - Instituto Nacional de Câncer

IRMA - Image Retrieval in Medical Applications

KNN - K Nearest Neighbors

ML - Médio – Lateral

MLP - *Perceptron* multicamadas

OMS - Organização Mundial de Saúde

RBF - Redes de base radial

RNA - Redes Neurais Artificiais

ROI - Regiões de Interesse

SIM - Sistema de Informação sobre Mortalidade

SMO - Otimização mínima sequencial

VN - Verdadeira Negativa

VP - Verdadeira Positiva

WEKA - Waikato Environment for Knowledge Analysis

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Justificativa e motivação	15
1.2	Objetivos	16
1.2.1	Objetivo geral	16
1.2.2	Objetivos específicos.....	16
1.3	Organização do documento	17
2	FUDAMENTAÇÃO TEÓRICA.....	18
2.1	Anatomia e fisiologia da mama.....	18
2.2	Câncer	19
2.3	Câncer de mama.....	20
2.3.1	Fatores de risco.....	20
2.3.2	Manifestações clínicas	21
2.3.3	Detecção precoce.....	22
2.3.4	Diagnóstico.....	23
2.3.4.1	<i>Mamografia</i>	<i>23</i>
2.3.5	Magnitude/incidência.....	24
2.4	Padrões mamográficos e densidade mamária	25
2.5	Classificação BI-RADS®	26
2.6	Inteligência artificial.....	27
2.7	Redes neurais artificiais	28
2.8	Máquinas de aprendizado extremo.....	29
2.9	Diagnóstico auxiliado por computador (CAD).....	30
2.10	Waikato environment for knowledge analysis (WEKA).....	32
2.11	Base de imagens mamográficas	33
2.12	Atributos	33
2.13	Seleção de atributos	33
2.14	Algoritmos de busca.....	34
2.14.1	Algoritmos genéticos	34
2.15	Classificadores	35
2.15.1	Otimização mínima sequencial (SMO)	35
2.15.2	Perceptron multicamadas (MLP)	35
2.15.3	Aprendizagem baseada em instâncias com parâmetro k (IBK).....	36

2.15.4	Redes de base radial (RBF)	36
3	MATERIAIS E MÉTODOS	37
3.1	Criação da base de dados IRMA modificada	37
3.2	Preparação e pré processamento das imagens	38
3.3	Seleção de atributos/redução de atributos	41
3.4	Processo de classificação	41
4	RESULTADOS OBTIDOS E ANÁLISE	45
4.1	Banco de dados.....	45
4.2	Resultados experimentais de seleção de atributos com algoritmo genético	52
4.3	Classificações a partir das seleções de atributos.....	53
4.4	Discussão	63
5	CONCLUSÃO	66
5.1	Conclusões gerais.....	66
5.2	Contribuições	66
5.3	Trabalhos futuros.....	67
	REFERÊNCIAS	68
	ANEXO A - Artigo apresentado e publicado nos anais do 4º Encontro Brasileiro de Inovação Terapêutica	75

1 INTRODUÇÃO

O câncer também conhecido como neoplasma ou tumor maligno, é considerado um dos grandes problemas no âmbito da saúde mundial. Cerca de 70% dos óbitos causados pelo câncer em geral ocorrem em países de baixa e média renda, porém aproximadamente 30 % do número total de óbitos em decorrência do câncer podem ser evitados (WORD HEALTH ORGANIZATION, 2011).

No entanto, estudos da Agência Internacional de Investigação sobre o Câncer, relatam que o número de óbitos provocados pelo câncer continuará aumentando, com uma estimativa de 12 milhões de óbitos até meados de 2030 (INTERNATIONAL AGENCY FOR RESEARCH ON CANCER, 2009).

Quando se refere especificamente ao câncer de mama, tem-se que ele corresponde a 22% dos tipos de câncer detectado anualmente e que possui uma maior incidência em mulheres do que em homens, sendo ele considerado o tipo de câncer mais frequente no mundo e o primeiro que leva ao óbito indivíduos do sexo feminino (PEREIRA, 2009; PEREIRA et al., 2014; INCA, 2015a).

No Brasil, o Instituto Nacional de Câncer (INCA) relata que no ano de 2014 ocorreram 57.124 mil novos casos de câncer de mama, uma média de 57 casos a cada 100.000 mulheres. Quanto ao número de óbitos neste mesmo ano foi de 13.345 ocorrências. Vale salientar, que apesar da alta taxa de mortalidade atualmente encontrada, o câncer de mama é considerado uma doença de bom prognóstico (PEREIRA et al., 2014, INCA, 2015a).

Até o presente momento, ainda não foram identificadas as causas do câncer de mama, com isso, faz-se necessário para reduzir essa taxa de mortalidade tão elevada principalmente do sexo feminino, um grande investimento tecnológico e de recursos humanos capacitados. Assim no decorrer uma detecção precoce (estágio inicial) e um melhor prognóstico (PEREIRA et al., 2014).

No cenário atual, o exame de imagem mais utilizado para se realizar esse diagnóstico precoce de possíveis anormalidades no tecido mamário é a mamografia. Neste exame, são obtidas quatro imagens com duas vistas (Crânio – Caudal (CC) e Médio – Lateral (ML)). Tais imagens permitem obter visualização de neoplasias não palpáveis. Porém estudos relatam que entre 10% e 30% do câncer de mama

maligno não foram detectados em exames de rotina por especialistas (KINOSHITA et al., 2008; PEREIRA & NASCIMENTO 2009).

Nas últimas décadas, um interesse elevado no uso de técnicas de reconhecimento de padrões, processamento, análises de imagens mamográficas e de inteligência artificial vem surgindo ao redor do mundo. O conjunto dessas técnicas vem sendo utilizadas constantemente para o desenvolvimento dos sistemas de apoio à detecção (CADE) e dos sistemas de apoio ao diagnóstico (CADx) (PEREIRA, 2009; PEREIRA et al., 2014).

Os sistemas CADe são sistemas auxiliares na detecção precoce de anormalidades no tecido mamário, mas que não são capazes individualmente de fazer diagnóstico sobre as mesmas. Por outro lado, os sistemas CADx tem o objetivo de detectar as classes benignas e malignas das anormalidades encontradas.

O objetivo desses sistemas (CADE e CADx), é elevar o grau de precisão no diagnóstico e na detecção de anormalidades no tecido mamário, assim dando aos profissionais da radiologia uma segunda opinião ou até mesmo uma leitura prévia das imagens mamográficas, minimizando a necessidade de se realizar novos exames. Entretanto, muitos especialistas ainda se preocupam com a sua taxa de acurácia dos sistemas em questão (KINOSHITA et al., 2008 ; SOUZA,2011).

1.1 Justificativa e motivação

O diagnóstico de câncer de mama no Brasil vem sendo rotineiramente descoberto em estágio avançado, com isso a alta taxa de mortalidade continua presente e ascendente. Estatisticamente, o crescimento da incidência do câncer de mama não está restrito ao Brasil, sendo observado também em todo mundo, incluindo os países desenvolvidos (INCA, 2015a).

Um estudo realizado com mulheres americanas mostra que há um crescimento de 93% na taxa de sobrevivência quando o diagnóstico é realizado em estágio inicial da doença, com redução para 72% no estágio intermediário e diminui drasticamente para 13%, quando a patologia é detectada em estágio avançado (TANG et al., 2009).

Além disso, já se encontram estudos na literatura que relatam que a taxa de detecção de câncer de mama poderia crescer de 5 a 10% se o sistema CADx fosse utilizado para o apoio ao diagnóstico (PINHO, 2015).

1.2 Objetivos

Para o diagnóstico por imagem baseada em sistemas inteligentes, as imagens são representadas por vetores de atributos, muitas vezes de grande dimensão, o que poderia prejudicar o tempo de treinamento de um classificador, principalmente daqueles baseados em redes neurais artificiais.

1.2.1 Objetivo geral

Esta dissertação tem como objetivo geral desenvolver um sistema de apoio ao diagnóstico do câncer de mama por análise de mamogramas a partir de classificadores baseados em redes neurais artificiais do tipo Máquinas de Aprendizado Extremo e de atributos estatísticos e de forma, reduzidos a partir da aplicação de técnicas de seleção de atributos, com enfoque em algoritmos genéticos.

1.2.2 Objetivos específicos

Para atingir o objetivo geral, deverão ser atingidos os seguintes objetivos específicos ou metas:

- Fazer o levantamento do estado da arte de sistemas computacionais de apoio ao diagnóstico do câncer de mama por imagem;
- Construir bases de dados de vetores de atributos reduzidos a partir da base de imagens mamográficas;
- Desenvolver o sistema de apoio ao diagnóstico;
- Realizar seleção de atributos;
- Realizar classificações;
- Avaliar estatisticamente os resultados.

1.3 Organização do documento

Esta dissertação encontra-se organizada da seguinte maneira: este primeiro capítulo traz uma introdução geral da temática, motivação e justificativa, além dos objetivos gerais e específicos desse estudo.

O segundo capítulo é uma revisão dos fundamentos teóricos pertinentes à temática, tais como: anatomia e fisiologia da mama, explicação sobre o câncer de mama (definição, manifestação clínica, diagnóstico, densidade mamária e afins) classificação BI-RADS, seleção de atributos, WEKA, base de imagens mamográficas e classificadores.

O terceiro capítulo vem trazendo o aprofundamento dos materiais e métodos que foram utilizados para a construção dessa dissertação.

O quarto capítulo demonstra os resultados obtidos, análise dos experimentos e as discussões acerca desses resultados.

E por fim, são relatadas as conclusões gerais, as contribuições e a apresentação de sugestões para trabalhos futuros.

2 FUDAMENTAÇÃO TEÓRICA

2.1 Anatomia e fisiologia da mama

A mama são estruturas presentes em ambos os sexos, contudo no sexo masculino é rudimentar por toda a vida. Ela geralmente é encontrada em pares e é envolvida por fásia e recoberta por uma pele localizada a frente dos músculos grandes peitorais e do serratus anterior no espaço entre a terceira e sétima costelas, entre a linha axilar média e o bordo do esterno e são separadas pelo sulco intermamário. Possuem forma variada, contudo há aquelas que são as mais prevalentes: as semi esféricas e as cônicas. Essas formas e também as demais podem variar em função da idade, da lactação, da gestação, da obesidade e do período menstrual. Possui volume médio de 12 a 13 cm de largura, 10 a 11 cm de altura e 5 a 6 cm de espessura (ESPERANÇA PINA, 2004).

A composição mamária é de tecido glandular (parênquima), tecido conjuntivo e tecido adiposo. O tecido glandular é composto de dois sistemas: o sistema ductal constituído por ductos que inicia na papila e agrega várias ramificações e o sistema lobular constituído de lóbulos que inicia no final das ramificações ductais e são responsáveis pela formação do leite. Cada mama possui 15 a 20 lobos, onde cada lobo é formado por um conjunto de alvéolos, canalículos, ductos lactóforos e ampolas lactóforas (BIAZUS, 2000; SOUZA, 2011).

Os sistemas ductais e lobular são sustentados pelo estroma que é composto de tecido conjuntivo e tecido adiposo, e é nesse estroma que passam nervos, vasos sanguíneos e vasos linfáticos. A vascularização arterial é realizada pelas artérias torácica lateral, torácica superior, torácica interna, toráco – acromial e intercostais interiores, que são acompanhadas da drenagem venosa que além de seguirem o mesmo caminho das artérias, possuem também veias profundas menos importantes. Já os vasos linfáticos drenam a linfa para as cadeias de linfonodos mamária interna e axilar (MOORE & DALLEY, 2007; ESPERANÇA PINA, 2007).

A inervação mamária é realizada através dos nervos simpáticos que chegam através da vascularização arterial, dos ramos laterais e cutâneos do terceiro ao sexto nervo intercostais, dos ramos supraclaviculares do plexo cervical e dos ramos torácicos do plexo braquial (ESPERANÇA PINA, 2000; MOORE & DALLEY, 2007).

A mama geralmente é dividida em quadrantes são eles: quadrantes superiores (lateral e medial), inferiores (lateral e medial). Esta divisão se torna essencial como facilitadora na localização e correlação dos achados clínicos e dos resultados dos exames de imagens (BRASIL, 2013).

2.2 Câncer

Historicamente, o câncer provavelmente já era conhecido pela civilização egípcia e pelas civilizações posteriores. O caso mais antigo conhecido sobre o câncer no ser humano ou de patologia similar possui mais de quatro mil anos (DOUSSET, 1999).

Também conhecido como neoplasma ou tumor maligno, o câncer é definido como, um conjunto de mais de 100 doenças caracterizado pelo crescimento desordenado de células em qualquer tecido ou órgão do corpo formando um crescimento anormal que geralmente é denominado de tumor. Esse crescimento pode invadir tecidos adjacentes, em um fenômeno conhecido como metástase (INCA 2015a; WORD HEALTH ORGANIZATION, 2015).

O crescimento acelerado das células tende a ser incontrolável e agressivo ao tecido ou órgão atingido, fazendo com que haja um acúmulo de células cancerígenas (tumores) que são considerados neoplasias malignas. Em contraponto, temos os tumores benignos que são massas que se assemelham ao tecido original e se proliferam mais vagarosamente (INCA, 2015a).

O câncer tem causa variada, podendo ser elas externas ou internas ao organismo e ambas estão interligadas. As causas externas têm relação com o meio ambiente e com os costumes ou hábitos adotados pelos indivíduos, já as causas internas estão quase sempre relacionadas ao quesito genético. Todavia 80 a 90% dos cânceres estão ligados ao fator ambiental, que atua alterando a estrutura do DNA das células. Com isso, pode-se concluir que o surgimento do câncer vai depender da duração e da intensidade da exposição do organismo aos agentes causadores (INCA, 2015a).

2.3 Câncer de mama

O câncer de mama é o resultado da proliferação anormal das células do tecido mamário, que ocasiona um tumor com potencial de invadir outros tecidos (INCA, 2015b).

O câncer de mama é um problema de saúde pública, e é considerado como um grupo de patologias heterogêneas, que possuem diferentes comportamentos. Devido a sua heterogeneidade, ele se manifesta por diferentes apresentações clínicas e morfológicas e por variadas características genéticas (BRASIL, 2013).

A Organização Mundial de Saúde (OMS) em 2012, através da publicação da Classificação para Tumores de Mama – 4ª edição, reconheceu a existência de mais de 20 subtipos diferentes de câncer de mama, porém, também destaca nesse documento que cerca de 80% dos tumores mama se originam no epitélio ductal (carcinoma ductal invasivo). Os outros 20% dos carcinomas devido à vasta gama de subtipos podem ser diagnosticados como: lobular, tubular, mucinoso, medular, micropapilar, papilar, entre outros (INCA, 2015c).

Devido ao processo de carcinogênese ser geralmente lento, o tumor palpável pode levar anos para ser percebido, passando pelas seguintes fases: iniciação, que é a fase da exposição aos fatores relacionados; a promoção, fase na qual sofre a ação dos agentes oncopromotores nas células já afetadas; e a progressão que é a fase da proliferação desordenada das células (BRASIL, 2013).

2.3.1 Fatores de risco

O câncer de mama tem vários fatores associados, são eles: idade; fatores endócrinos/história reprodutiva; fatores ligados ao ambiente e ao comportamento adotado pelos indivíduos ao longo da vida e fatores hereditários. A idade é um dos fatores que se destaca, pois à medida que se envelhece há um acúmulo de exposição, além de poder ocorrer mudanças biológicas e hormonais ao longo dos anos. Esse dado pode ser confirmado pelo fato das mulheres acima de 50 anos assumem a liderança no que se refere ao diagnóstico de tumores de mama (cerca de 70 a 80% dos diagnósticos) (CANCER RESEARCH UK, 2011; INCA, 2015b)

A chance, por idade, é de (AMERICAN CANCER SOCIETY, 2010):

- 20 anos: 1 em 1.760;

- 30 anos: 1 em 229;
- 40 anos 1 em 69;
- 50 anos: 1 em 42;
- 60 anos: 1 em 29;
- 70 anos: 1 em 27;
- Ao longo da vida: 1 em 8.

Alguns grupos de indivíduos são indicados pelo “Documento de Consenso do Câncer de Mama” de 2004, como de risco elevado para adquirir câncer de mama, esses grupos representam apenas 1% do total de casos, porém precisam de um acompanhamento mais regular (anual) e um olhar diferenciado, são eles (BRASIL, 2013):

- Mulheres com histórico familiar de pelo menos um parente de primeiro grau (mãe, irmã ou filha) com diagnóstico de câncer de mama, abaixo dos 50 anos de idade;
- Mulheres com história familiar de pelo menos um parente de primeiro grau (mãe, irmã ou filha) com diagnóstico de câncer de mama bilateral ou câncer de ovário, em qualquer faixa etária.
- Mulheres com história familiar de câncer de mama masculino.
- Mulheres com diagnóstico histopatológico de lesão mamária proliferativa atípica ou neoplasia lobular *in situ*.

2.3.2 Manifestações clínicas

Os nódulos que geralmente possuem forma irregular, são indolores e duros. São eles que são frequentemente detectados pelas mulheres no exame clínico das mamas, sendo esses sintomas os mais comuns entre as mulheres (presentes em cerca de 90% dos casos iniciais) (KÖSTERS & GOTZSCHE, 2008; INCA, 2015d).

Outros sinais e sintomas que também estão presentes no câncer de mama são (BRASIL, 2013; INCA, 2015d):

- Saída de secreção pelo mamilo, principalmente quando ocorre de forma espontânea e unilateral;
- Coloração avermelhada da pele da mama;

- Pele com aspecto de casca de laranja;
- Inversão ou dor na região do mamilo;
- Retração cutânea;
- Nódulos pequenos na região do pescoço e das axilas;
- Descamação ou ulceração do mamilo.

2.3.3 Detecção precoce

Como relatado anteriormente, o câncer de mama pode ser detectado em sua fase inicial, e sendo descoberto nesse estágio há um prognóstico favorável (INCA, 2015b).

O *down-staging* como algumas vezes é conhecido, é uma estratégia para o diagnóstico precoce, contribuindo para detectar o câncer de mama em estágios iniciais. Nessa estratégia, a participação da mulher é essencial e para isso é fundamental que elas conheçam o seu corpo e com isso possam detectar qualquer anormalidade que venha a aparecer. Porém, para que essas estratégias funcionem é necessária a educação da mulher e dos profissionais de saúde para que juntos consigam detectar essa patologia o mais breve possível (BRASIL, 2013).

O rastreamento é a estratégia de saúde pública escolhida para que a alta incidência e a alta mortalidade regridam. Essa estratégia é fundamentada em estudos que relatam que em países com um rastreamento efetivo há uma redução na mortalidade do câncer de mama. No Brasil, atualmente o único exame utilizado para rastreamento é a mamografia (BRASIL, 2013).

Geralmente a sensibilidade desse rastreamento varia de 77% a 95%, dependendo de vários fatores tais como (BRASIL, 2013):

- Localização da lesão;
- Tamanho da lesão;
- Densidade do tecido mamário;
- Qualidade técnica dos recursos;
- Habilidade do radiologista em interpretar as imagens.

Para mamas com tecido mamário mais denso, que geralmente está presente

em mulher com idade inferior a 50 anos, a sensibilidade da mamografia de rastreamento cai para 48%. Quanto à especificidade ela varia de 94% a 97% (BRASIL, 2013).

No Brasil, a estratégia para o controle do câncer de mama se encontra no Documento de Consenso, onde o exame clínico das mamas e a mamografias são os métodos utilizados para o rastreamento seguindo as recomendações de acordo com a faixa etária como pode ser visto na Tabela 1 (BRASIL, 2014).

Tabela 1. População-alvo e periodicidade dos exames no rastreamento de câncer de mama

População	Exames de rastreamento
Mulheres a partir de 35 anos que possuam risco elevado de adquirir câncer de mama	ECM anual e mamografia anual
Mulheres de 40 a 49 anos	ECM anual e mamografia se encontrada alguma alteração
Mulheres de 50 a 69 anos	ECM anual e mamografia a cada 2 anos.

Fonte: Marques et al, 2015.

2.3.4 Diagnóstico

O diagnóstico para o câncer de mama se baseia em duas estratégias principais: a primeira se trata da realização do exame clínico das mamas, que é realizado pelos indivíduos ou por profissionais de saúde para identificar possíveis sinais e sintomas do câncer de mama e esse deve incluir a inspeção estática, inspeção dinâmica e palpação da mama e de regiões circunvizinhas tais como, as cadeias axilares glandulares e supra claviculares; a segunda estratégia é a realização de exames de imagens, tais como: mamografia, ultrassonografia e ressonância magnética (BRASIL, 2013; INCA, 2015b)

2.3.4.1 Mamografia

A mamografia consiste de emissão de Raios-X do tecido mamário e é realizado através de um mamógrafo que resulta em imagens da região interna da mama. Geralmente são realizadas quatro imagens com duas vistas de cada mama: uma médio lateral oblíqua (MLO) e uma crânio – caudal (CC), sendo a projeção

MLO considerada mais eficiente. A vista CC é feita como complemento para a visualização pósterio-medial do tecido mamário (AMERICAN CANCER SOCIETY, 2015).

Hoje em dia, existem diversas maneiras de obter imagens mamográficas e essas podem ser apresentadas em filmes (tradicionais) ou imagens digitais (BRASIL, 2014).

2.3.5 Magnitude/incidência

De acordo com a Organização Mundial de Saúde (OMS), em 2012 houve em todos os continentes 14 milhões de novos casos de câncer e 8 milhões de óbitos em decorrência do câncer, e infelizmente essa estimativa continuará crescendo (INCA, 2010; INCA, 2015c).

Os tipos de câncer com maior incidência no mundo segundo o estudo realizado pelo projeto Globocan em 2012, são respectivamente: câncer de pulmão (1,8 milhão), câncer de mama (1,7 milhão), câncer de intestino (1,4 milhão) e câncer de próstata (1,1 milhão). Quando essa incidência é separada por sexo, tem-se que os que mais acometem o sexo masculino são: câncer de pulmão (16,7%), câncer de próstata (15,0%), câncer de intestino (10,0%), câncer de estômago (8,5%) e câncer de fígado (7,5%), já no sexo feminino os mais frequentes são: câncer de mama (25,2%), câncer de intestino (9,2%), câncer de pulmão (8,7%), câncer de colo do útero (7,9%) e câncer de estômago (4,8%) (SOUZA, 2011; INCA, 2014, INCA, 2015c).

Em 2030, a estimativa é de 21,4 milhões de novos casos de câncer e 13,2 milhões de óbitos, o fato pode ser explicado através do crescimento da população idosa, e também das reduções de mortalidade por outras causas como, por exemplo, a redução da mortalidade por doenças infecciosas e da mortalidade infantil (SOUZA, 2011; INCA, 2014).

No Brasil, para o ano de 2016 que também é válida para o ano de 2017 (biênio 2016/2017), a estimativa é o surgimento de 600 mil novos casos, e no geral os mais incidentes são respectivamente: tumores de pele não melanoma (prevalente em ambos os sexos com 180 mil novos casos); tumores de próstata (mais prevalente entre os homens com 61 mil novos casos) e tumores de mama feminina

(mais prevalentes com 58 mil novos casos). Nos brasileiros, os tipos de câncer mais incidentes quando separado por sexo se diferenciam um pouco, principalmente no que se refere à ordem de incidência. Diante disso, tem-se que nos homens os mais incidentes são: câncer de próstata (28,6%), câncer de pulmão (8,1%), câncer de intestino (7,8%), câncer de estômago (6,0%) e câncer de cavidade oral (5,2%). E nas mulheres são: câncer de mama (28,1%), câncer de intestino (8,6%), câncer de colo do útero (7,9%), câncer de pulmão (5,3%) e câncer de estômago (3,7%) (INCA, 2015c).

Sendo o mais comum entre as mulheres, o câncer de mama ao redor do mundo é responsável por 1,6% dos óbitos entre mulheres, que é de 411 mil/ ano. No Brasil, o Sistema de Informação sobre Mortalidade (SIM) traz dados que mostram que no ano de 2013 ocorreram em decorrência do câncer de mama 14.388 óbitos, sendo apenas 181 óbitos no sexo masculino (INCA, 2014; BARBOSA et al., 2015; ZAPPON, 2015, INCA, 2015c).

Sem levar em consideração os tumores de pele não melanoma, o câncer de mama é o primeiro mais incidente nas mulheres das regiões: Nordeste (38,74/100 mil). Sudeste (68,08/100 mil), Centro-Oeste (55,87/100 mil), Regiões Sul (74,30/100 mil). Contudo na Região Norte, observa-se que o câncer de mama é o segundo tumor mais incidente (22,26/100 mil) (INCA, 2015c).

Nas últimas décadas, a sobrevida do câncer de mama tem se elevado em países desenvolvidos chegando a 85%. Nos países em desenvolvimento essa taxa de sobrevida ainda gira em torno de 50% a 60%. Essa taxa de sobrevida em países em desenvolvimento como é o caso do Brasil, pode ser explicada pelo fato de 60% dos cânceres de mama ser diagnosticados em estado avançado (INCA, 2014; PAIVA et al., 2015).

2.4 Padrões mamográficos e densidade mamária

Em 1976 Wolf descreve a densidade mamária com quatro aspectos de acordo com a substituição do tecido adiposo e da proeminência dos ductos, são eles (WOLF, 1976; SIQUEIRA, 2004):

- N1 – parênquima composto quase totalmente de tecido adiposo, sem ductos visíveis;

- P1 – parênquima composto principalmente de tecido adiposo, com ductos proeminentes na porção anterior, ocupando até $\frac{1}{4}$ do volume total da mama;
- P2 – padrão ductal proeminente, ocupando cerca de 25% da mama;
- DY – parênquima denso, com um padrão ductal proeminente.

Porém, houve uma modificação na classificação de Wolf, através de cinco padrões de acordo com a relação anatômica da mama que são (KALAF, 2006):

- Padrão I – Mama com substituição parcial com equilíbrio de densidade nodular, linear e áreas radioluscentes;
- Padrão II – Mama predominante de tecido adiposo, com densidades lineares;
- Padrão III – Mama predominante de tecido adiposo, contudo com proeminência dos ductos retroareolares;
- Padrão IV – Mama com proeminência de densidades nodulares e lineares;
- Padrão V – Mama com dominância do tecido fibroglandular, com heterogeneidade e de contornos convexos.

2.5 Classificação **BI-RADS®**

Os resultados das mamografias atualmente são classificados de acordo com o *Breast Imaging Reporting and Data System* (BI-RADS®). Esse sistema utiliza categorias de 0 a 6 para descrever o que foi achado e ainda prevê quais as possíveis condutas a serem adotadas (BRASIL, 2013).

Tabela 2. Classificação BI-RADS®

Classificação	Identificação	Conduta recomendada
0	Exame incompleto	Fazer uma avaliação adicional com incidências e manobras; correlacionar com outros métodos de imagem; comparar as mamografias do ano anterior.
1	Exame negativo	Realizar rastreamento de rotina conforme a faixa etária ou prosseguir a investigação, se o ECM tiver alguma alteração
2	Exame com alteração tipicamente benigno	Realizar rastreamento de rotina conforme a faixa etária
3	Exame com alteração provavelmente benigno	Controle radiológico
4	Exame com alteração suspeita	Realizar avaliações por exame de cito ou histopatológico
5	Exame com alteração altamente suspeito	Realizar avaliações por exame de cito ou histopatológico
6	Exame com alteração na qual a malignidade já está comprovada	Terapêutica específica em Unidade de Tratamento de Câncer.

Fonte: Colégio Brasileiro de Radiologia, 2000; Brasil, 2013.

2.6 Inteligência artificial

O encanto pela capacidade da inteligência de o ser humano de tomar decisões há tempos desperta curiosidade na humanidade. Um desses interesses era criar artificialmente essa inteligência (PAIVA, 2015; MARQUES, 2015).

Ao passar dos anos, a matemática que se desenvolveu juntamente com a organização do raciocínio lógico em sistemas simbólicos fez com que houvesse um avanço na tecnologia da inteligência artificial desde meados de 1936 (GANASCIA, 1997).

O matemático inglês Alan Turing por volta de 1950 descreve o desempenho de uma máquina universal em termos matemáticos. Ele pôde mostrar esses

resultados através do conhecido Teste de Turing, que tinha como foco responder a uma pergunta “a máquina pode ter um comportamento inteligente?”. O teste consistia em dois seres humanos A e B e um computador C colocados em locais diferentes, mas interligados entre si, onde A conversaria com B e C e tinha a incumbência de detectar quem era o computador. Caso o ser humano A não conseguisse obter uma precisão de pelo menos 50% de quem era o outro ser humano que estava conversando o teste seria positivo e poderia se concluir que a máquina pode simular a inteligência do ser humano (SANVITO, 1995; GANASCIA, 1997).

O termo inteligência artificial foi usado pela primeira vez em 1956, porém até hoje é difícil o consenso sobre sua definição. Basicamente podemos dividi-la em quatro aspectos: primeiro aspecto é que são sistemas que possuem pensamento semelhante aos seres humanos; segundo aspecto é que são sistemas que tomam atitudes (agem) como seres humanos; terceiro aspecto é que são sistemas que pensam de forma racional e o quarto aspecto é que são sistemas que agem de forma racional. Todos esses aspectos convergem para um só objetivo, que é realizar atividades só realizadas por seres humanos (SANTOS & TENÓRIO, 2011; PEREIRA, 2015; PAIVA, 2015b).

A inteligência artificial é um ramo da ciência da computação, porém não de forma exclusiva. Ela também é abordada na linguística, na psicologia, nas engenharias, na matemática, na biologia, na filosofia, na saúde, entre outras áreas (GUARDA, 2004; SANTOS & TENÓRIO, 2011; PEREIRA, 2015).

2.7 Redes neurais artificiais

As redes neurais ou redes neurais artificiais (RNAs) são modelos matemáticos que se desenvolveram a partir do princípio do conceito básico das redes neurais biológicas. Essas redes neurais artificiais visam realizar a simulação do funcionamento do cérebro humano (MOTTA, 2004. GUTEMBERG, 2015).

Visto do lado técnico, as redes neurais artificiais consistem em um sistema paralelo distribuído que é composto de neurônios artificiais cujo objetivo é de realizar cálculos de funções matemáticas que são determinadas. Esses neurônios artificiais estão organizados em camadas únicas ou múltiplas, e são ligados por um número

elevado de conexões. Tais conexões são de única direção e a cada uma dessas conexões existe associado um peso sináptico. Esses pesos são responsáveis pelo armazenamento do conhecimento representado pelo sistema e servem para pesar as entradas que serão recebidas por cada um dos neurônios artificiais (MOTTA, 2004).

O conhecimento é caracterizado pelo armazenamento de informações, e que pode ser utilizado por máquinas ou seres humanos para interpretar, prever e responder algum problema determinado ao mundo exterior (GUTEMBERG, 2015).

O projeto de uma rede neural artificial vai depender de uma consistente análise que em sua maioria é complexa. O fato que leva a inúmeras dificuldades tais como se encontrar uma arquitetura estrutural que melhor se adéque à resolução do problema que está sendo proposto e também na escolha dos dados que devem ser relevantes para aquele processamento. É preciso haver uma preocupação além da entrada com os parâmetros de aprendizado que necessita serem ideais. Com os pesos sinápticos que serão utilizados e com os níveis de bias que são bastante relevantes para o aprendizado do sistema (GUTEMBERG, 2015; MISHINA et al., 2015).

A primeira fase da montagem do projeto de uma rede neural consiste na aprendizagem, onde se usa um subconjunto dos dados que serão utilizados para treinar a rede neural através de um apropriado algoritmo. A segunda etapa dessa montagem consiste no teste onde há conhecimento de dados novos adquiridos pela rede neural adquiridos, com o armazenamento do conhecimento adquirido previamente. Nesta etapa verifica-se a rede neural a capacidade dela expressar uma resposta (produzir saídas) adequada para os dados que não estavam presentes antes de passarem pelo treinamento (GUTEMBERG, 2015).

2.8 Máquinas de aprendizado extremo

Máquinas de Aprendizado Extremo possuem uma proposta de programar uma rede neural tipo *feedforward* com uma camada escondida que possui um algoritmo de rápido aprendizado (TAKAHASHI, 2015).

Uma máquina de aprendizado extremo é uma rede neural artificial onde os pesos da camada de entrada e das bias são escolhidos de forma aleatória e não são

ajustados posteriormente. Sendo assim, o problema a ser resolvido é configurado em um espaço de maior dimensionalidade, facilitando com isso a separação dos dados. Quanto aos pesos e bias da camada de saída são determinados de forma analítica tendo partida da pseudo – inversa da camada escondida, essa solução teve base para minimizar a norma nos mínimos quadrados (TAKAHASHI, 2015).

Quando esse método é utilizado, propicia que o erro de classificação da rede neural artificial seja limitado, mas para que isso ocorra precisa-se que a função de ativação dos neurônios encontrados na camada de saída, seja infinitamente diferenciável. Diferente de grande parte dos métodos de treinamento de *Single Layer Feedforward Network* que tem base em gradiente, a estratégia utilizada pelas máquinas de aprendizado extremo diminui de forma considerável o tempo de treinamento das redes neurais do tipo *Single Layer Feedforward Network* (HUNG et al., 2006; TAKAHASHI, 2015).

O método das máquinas de aprendizado extremo sendo simples, ainda assim ele consegue atingir elevadas taxas de sucesso que se equivalem à máquina de vetores de suporte. Diante disso, devido à redução do tempo de treinamento, mesmo não possuindo melhora no desempenho na classificação da rede neural, pode-se afirmar que houve uma evolução no que se refere ao mecanismo de aprendizagem (TAKAHASHI, 2015).


2.9 Diagnóstico auxiliado por computador (CAD)

O Sistema CAD vem mostrando um alto potencial no auxílio aos especialistas para classificação e a detecção de anormalidades possíveis, fornecendo assim uma segunda opinião no diagnóstico de uma lesão mamária (PEREIRA, 2009; FRONER, 2015).

Existem duas aplicações básicas para o sistema CAD. A primeira visa o auxílio na detecção de lesões, a começar do local com padrão anormal através da varredura da imagem com o auxílio do computador. A segunda visa auxiliar no diagnóstico utilizando a quantificação das características presentes na imagem e também utiliza a sua classificação como condizendo com padrões anormais ou normais (FRONER, 2015).

Esse sistema se divide geralmente em três principais etapas que são as seguintes: a imagem de entrada é segmentada para se obter a região de interesse; através da textura e ou da geometria ela é classificada; e por fim através de um classificador ocorre a classificação da região de interesse, com o treinamento supervisionado que tem base nos diagnósticos realizados pelos especialistas. No caso das mamografias a segmentação é utilizada para separar anormalidades possíveis da imagem geral (Figura 1) (MARTINS, 2007).

Figura 1. Esquema do funcionamento do sistema CAD típico



Fonte: Martins, 2007.

O sistema CAD tem uma variada aplicabilidade, sendo utilizado em todos os exames de imagem e também em todas as partes do corpo. Contudo a grande parte dos sistemas desenvolvidos até hoje são aplicados na detecção de câncer de mama através de mamografias e a detecção de nódulos pulmonares em radiografias (PINHO, 2015).

Existem quatro categorias que pode classificar a eficiência do sistema CAD, que são: verdadeira positiva (VP) é quando há uma anormalidade maligna detectada, verdadeira negativa (VN) que é quando a pessoa é saudável e é classificada como tal, ou seja, não são detectadas anormalidades; falsa positiva (FP) quando é detectada uma anormalidade, porém a pessoa está saudável; e por fim a

falsa negativa (FN) que é quando não há detecção de anormalidade e a pessoa não é saudável (PINHO, 2015).

Há ainda muita preocupação no quesito de sensibilidade desses sistemas. Hoje em dia a sensibilidade desses sistemas gira em torno de 88% a 92% em mamografias (PEREIRA, 2009; PINHO, 2015).

No momento, alguns sistemas CAD foram aprovados pela *Food and Drug Administration (FDA)*. A empresa *R2 Thecnology* produziu o software *Imagechecker^R* que conseguiu uma acurácia de 98,5% para as calcificações e obteve uma especificidade de 0,74 FP por caso para nódulos. Quanto a sensibilidade vale em torno de 85,7% com taxa de FP de 1,32 por caso. O sistema *CAD MammoReaderTM* possui uma sensibilidade geral de 89,3%, com VP por caso de 1,53 e FP de 2,32 para os casos que possuíam câncer, já quanto aos casos sem câncer o FP foi de 3,32. O sistema *SecondlookTM* da empresa *CADx Medical System* obteve para o rastreamento de casos de câncer uma sensibilidade de 85%, e além disso é importante destacar que em 26,2% ele identificou através de mamografias o local de nódulos malignos com 2 anos de antecedência do indivíduo receber o diagnostico com câncer (MARTINS, 2007).

2.10 Waikato environment for knowledge analysis (WEKA)

WEKA é um projeto que foi desenvolvido na Universidade de *Waikato* na Nova Zelândia com configuração de um acervo de algoritmos de máquina de aprendizado para que possa se realizar mineração de dados. É grafado em Java e possui também código aberto na WEB (SILVA, 2004; MACIEL et al., 2015).

O sistema WEKA possui uma interface sem conflito e é composto de ferramentas para pré processamento, mineração de dados em regressão, classificação, análise de agrupamentos e associação. Além disso, seus algoritmos oferecem relatórios com dados de aspectos estatísticos e analíticos dos dados que foram minerados. É possível utilizá-lo no desenvolvimento de abordagem nova de aprendizado de máquinas (SILVA, 2004; MACIEL et al., 2015).

2.11 Base de imagens mamográficas

Para que o sistema CAD seja validado é essencial que sejam utilizadas imagens reais de mamografias. Além disso, é importante que essas imagens estejam previamente classificadas pelos profissionais radiologistas, que são responsáveis pela análise dessas imagens no dia a dia.

Todas as imagens utilizadas nesse estudo são provenientes do banco de dados IRMA (*Image Retrieval in Medical Applications*) (OLIVEIRA et al., 2008; DESERNO et al., 2012).

Essa base de dados foi criada na Universidade de Tecnologia de *Aachen* (*RWTH Aachen*) na Alemanha. Seu uso é proveniente de um esforço de cooperação entre o Grupo de Pesquisa de Computação Biomédica do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco e o Departamento de Informática Médica da Universidade Aachen, na Alemanha.

Essa base de dados é constituída pelas regiões de interesse (*ROI*) de imagens digitais do tecido mamário, que foram classificadas por radiologistas e redimensionadas para imagens de tamanho 128 x 128 pixes totalizando 2.796 imagens e 225 atributos (224 atributos + um atributo classe), a escala de imagens utilizada nessas imagens era preta e branca.

2.12 Atributos

O atributo é um dado para o qual cada objeto tem seu próprio valor. São basicamente, a estrutura de dados que vai representar a classe. E podem ser divididos em 2 tipos básicos, a instância e a de classe.

2.13 Seleção de atributos

Um relevante problema para o aprendizado de máquina é o que se refere à seleção de atributos que sejam representativos para resolver um determinado problema previamente estabelecido através do método de classificação.

A seleção de atributos é composta basicamente de duas abordagens, são elas: *Filter* e *Wrapper*. O *Wrapper* trata-se do próprio sistema classificador como métrica para avaliar o estado do funcionamento de variados subconjuntos de atributos. O *Filter*

criado como um caminho para contornar as limitações do *Wrapper*, tem seu uso ligado à métrica heurística, para que se possa encontrar um subconjunto de atributos que possa satisfazer a métrica, na espera que essa seja compatível com o classificador a ser utilizado. Contudo geralmente o subconjunto encontrado por *Filter* não é o ótimo para o classificador, porém a vantagem é que ele é independente do mesmo (HALL, 1999).

A técnica CFS se baseia na avaliação de subconjuntos (CFS Subset Evaluation), ou seja, em conjunto com uma técnica heurística busca trabalhar para não explorar incansavelmente todo espaço da busca, com a concepção de utilizar algum tipo de métrica de correlação para mensurar a dependência tanto do atributo-classe como do atributo-atributo (HALL, 1999).

Basicamente o maior objetivo dessa técnica de redução do número de atributos é pontualmente eliminar os redundantes e irrelevantes, pois esses só fazem contribuir para o aumento desnecessário do classificador e também dificultar todo o processo de classificação (HALL, 1999).

2.14 Algoritmos de busca

São algoritmos utilizados para procurar dentro, de um espaço previamente delimitado, instâncias que possua atributos ou propriedades desejadas. Geralmente essas buscas utilizam heurísticas que basicamente são abordagens para solução de problemas que emprega métodos práticos sem a segurança de gerar resultados perfeitamente corretos ou ótimos. Contudo essa abordagem obtém boas soluções para aquele problema previamente estabelecido (GOLDBERG, 1989; SANTOS; ASSIS, 2013).

2.14.1 Algoritmos genéticos

Os algoritmos genéticos refletem uma abordagem computacional evolucionária, sendo assimilados conceitos como: genótipos, cromossomos, fenótipos, mutação, seleção natural e cruzamentos. Esses algoritmos genéticos consistem em procedimentos interativos que tem como foco solucionar determinados problemas de otimização e busca, através de abordagem heurística. A solução é por sua vez

modelada como cromossomos (geralmente vetores binários). A princípio, a amostra é selecionada de forma aleatória. (GOLDBERG, 1989; SANTOS; ASSIS, 2013).

Cada interação é avaliada buscando eliminar parte do conjunto que se demonstra menos apto. O restante que previamente foi considerado apto passa pelo processo de geração de novos através de um operador de cruzamento. Geralmente o valor do ponto *cross-over* (ponto onde os pais realizam a troca de parte de suas informações) é gerado aleatoriamente. Posteriormente, ocorre a etapa de mutação, que está baseada na possibilidade de alteração de um bit no vetor dos indivíduos. Esse processo existe para que gere soluções diversas, como uma estratégia de evitar que as soluções fiquem presas em pequeníssimos locais. (GOLDBERG, 1989; SANTOS; ASSIS, 2013).

2.15 Classificadores

2.15.1 Otimização mínima sequencial (SMO)

É da categoria de classificadores lineares. O algoritmo de Otimização Mínima Sequencial (SMO) é aplicado na execução otimizada do classificador SVM do WEKA. O custo computacional é considerado linear para produção dos treinamentos de aprendizagem, o que concede lidar com maiores quantidades de arquivos na fase de teste (BARUFALDI et al., 2011).

Esse classificador transforma a saída do classificador em probabilidades através do uso de uma função sigmóide padrão. Nesse algoritmo, os atributos nominais passam por uma conversão para atributos binários, e, além disso, os valores numéricos sofrem uma normalização. Chegando à etapa final desse processo, o algoritmo SMO cria um modelo de aprendizagem, empregado na classificação dos atributos (BARUFALDI et al., 2011).

2.15.2 Perceptron multicamadas (MLP)

São redes de múltiplas camadas compostas por neurônios MCP com função de ativação do tipo sigmóide. As redes MLP introduzem o conceito de camada escondida ou oculta ou intermediária, a qual seria a camada presente entre as camadas de entrada e saída (BRAGA et al., 2000; HAYKIN, 2001).

A camada de entrada é onde ocorre a apresentação dos dados de entrada. A camada oculta é responsável pela maior parte do processamento, enquanto a camada de saída é responsável de apresentar o resultado. A adição da camada oculta tem como maior benefício à possibilidade da resolução de problemas não-lineares. A literatura mostra que uma única camada escondida é suficiente ao longo de experimentos (BRAGA et al., 2000).

2.15.3 Aprendizagem baseada em instâncias com parâmetro k (IBK)

O parâmetro K é o K Nearest Neighbors (KNN). O parâmetro KNN de IBK especifica o número de vizinhos mais próximos a serem utilizados ao classificar uma instância de teste e o resultado é determinado pela maioria dos votos (AHA et al., 1992).

A implementação de IBK no Weka tem a opção de "validação cruzada" que pode ajudar selecionando o melhor valor automaticamente (AHA et al., 1992).

2.15.4 Redes de base radial (RBF)

Nas redes de base radial (RBF) os neurônios da camada escondida processam funções de base radiais. Que formam uma classe especial de funções, com a característica de que a resposta cresce ou decresce a partir de um ponto central que é dado pelo par (x, h) (HAUYKIN, 2001).

A arquitetura da RBF envolve três camadas com responsabilidades distintas. A camada de entrada apresenta as variáveis de entrada para a camada escondida. A segunda camada, a única camada escondida da rede, é responsável pela transformação não-linear do espaço de entrada para um espaço de alta dimensionalidade. Cada neurônio da camada escondida representa uma função radial, a qual define uma hiperelipsóide no espaço de padrões de entrada. A camada de saída é linear, classificando os padrões recebidos da camada escondida (BRAGA et al., 2000; HAYKIN, 2001).

3 MATERIAIS E MÉTODOS

Esse estudo da engenharia biomédica e incorpora a área de computação biomédica. Dentro dessa área, o estudo visa produzir um sistema de apoio ao diagnóstico (CADx) para a problemática do câncer de mama. Para tal, utiliza *software* e bibliotecas já existentes e valida suas suposições através de experimentos computacionais.

Objetivamente a pesquisa pode ser vista como um procedimento sistemático e racional, que tem como foco levantar respostas a determinados problemas previamente proposto (GIL, 2002). Seguindo esta visão, tem-se que para alcançar a sistematicidade de uma pesquisa científica, a mesma precisa alcançar um método sistemático que permita que qualquer indivíduo possa reproduzir os experimentos ali expostos, ou seja, qualquer pesquisador pode ser capaz de reproduzir aquela abordagem e aqueles experimentos, na mesma condição ou em condições similares. Além disso, o mesmo precisa obter as mesmas conclusões expostas no trabalho.

Visando corroborar com o expressado acima, abordado nesse capítulo será minuciosamente todas as etapas para a construção do estudo, buscando elucidar toda abordagem experimental do mesmo.

3.1 Criação da base de dados IRMA modificada

Utilizando as imagens oriundas da base de dados IRMA foi construída uma base de dados que compreende imagens de região de interesse das densidades mamárias predominantemente adiposa e predominantemente fibroglandular. Foram escolhidas essas duas densidades mamárias pelo fato de as mesmas serem as mais prevalentes em mulheres na faixa etária 40 a 60 anos de idade que é a faixa etária que apresenta mais diagnóstico de câncer de mama.

Para o processamento ser iniciado as imagens foram inicialmente separadas em pastas de acordo com sua densidade mamária, posteriormente a essa primeira etapa, as imagens foram separadas dentro das pastas de densidade mamária de acordo com sua classificação (não-especificada, benigna e maligna) e por fim, dentro das pastas de classificação foram separadas de acordo com o tipo de lesão

(calcificação, microcalcificação, macrocalcificação, massa circunscrita, massa espículada, outras massas, distorção arquitetural e assimetria).

Quando essas imagens estavam devidamente separadas em pastas, passaram por uma prévia análise, sendo excluídas aquelas nas quais as visualizações das bordas das lesões não eram claras.


Seguindo adiante, cada imagem que passou pela etapa de análise foi submetida a uma demarcação das bordas da lesão com a cor vermelha, que foi escolhida por ser uma cor primária e esse processo foi realizado em uma ferramenta de imagem. Vale destacar que lesões do tipo calcificação quando estavam muito próximas eram demarcadas por agrupamento.

As imagens demarcadas foram recolocadas em pastas de acordo com sua densidade mamária, sua classificação (benigna e maligna) e também de acordo com seu tipo: para as lesões benignas: calcificação, massa circunscrita e distorção arquitetural e para as lesões malignas: calcificação, massa circunscrita e massa espículada.

As imagens não foram redimensionadas ficando com seu tamanho original que é de 128x128 pixels e em escala preto e branco.

3.2 Preparação e pré processamento das imagens


O pré processamento e a extração de atributos a partir das imagens da base de dados do IRMA foram realizadas utilizando o ConvIRMA, o qual frequentemente é utilizado pelo Grupo de Pesquisa de Computação Biomédica do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco. Na etapa iniciada foi realizado um balanceamento entre as amostras, o que por várias vezes é negligenciada tal balanceamento, esse pode ser observado na Figura 2.

Figura 2. Demonstração de balanceamento de instância

Legenda: Cada cor representa cada uma das classes. Fonte: *Weka*

Foram utilizadas 2796 imagens, da base de dados IRMA, das quais foram extraídos 225 atributos, obtidos, por sua vez, a partir de estatísticas dos termos da decomposição em *wavelets* morfológicas. Esse processo decompõe cada imagem em componentes com informação de forma e de orientação.

Vale evidenciar, que o aprendizado de máquina pode facilitar a detecção e classificação de lesões mamárias quando não há alterações na textura ou na morfologia (Figura 3), e quando se tem apenas o recurso de investigação visual humano.

Figura 3. Demonstração das imagens utilizadas na base de dados categorizadas por tipo de densidade mamária e tipo de lesão

Fonte: A autora

A Tabela 3 apresenta as classes obtidas a partir da base IRMA convertida e balanceada e que foi estruturada em 12 classes, organizadas de acordo com a densidade do tecido mamário (I - adiposa, II - fibroglandular, III - densa e IV - extremamente densa), a classificação BI-RADS (BI-RADS 1 - Inexistente, BI-RADS 2 – Benigna e BI-RADS 5 – Maligna) organizadas e de acordo com o tipo de lesão (0 – sem lesão, 4 – massa circunscrita e 5 – massa espiculada), Outro dado importante é que as imagens pertencentes a essa base de dados são referentes às regiões de interesse e foram previamente classificadas por profissionais especialistas em radiologia.

Tabela 3. Organização das 12 classes e seus respectivos significado

Número Correspondente da classe	Expressão Nominal na ferramenta WEKA	Significado
1	I-1-0	Mama predominantemente adiposa com ausência de nódulo.
2	I-2-4	Mama predominantemente adiposa com presença de nódulo benigno do tipo massa circunscrita.
3	I-5-5	Mama predominantemente adiposa com presença de nódulo maligno do tipo massa espiculada.
4	II-1-0	Mama predominantemente fibroglandular com ausência de nódulos.
5	II-2-4	Mama predominantemente fibroglandular com presença de nódulo benigno do tipo massa circunscrita.
6	II-5-5	Mama predominantemente fibroglandular com presença de nódulo maligno do tipo massa espiculada.
7	III-1-0	Mama densa com ausência de nódulos.
8	III-2-4	Mama densa com presença de nódulo benigno do tipo massa circunscrita.
9	III-5-5	Mama densa com presença de nódulo maligno do tipo massa espiculada.
10	IV-1-0	Mama extremamente densa com ausência de nódulos.
11	IV-2-4	Mama extremamente densa com presença de nódulo benigno do tipo massa circunscrita.
12	IV-5-5	Mama extremamente densa com presença de nódulo maligno do tipo massa espiculada.

Fonte: A autora

3.3 Seleção de atributos/redução de atributos

Tendo em vista o desempenho, é preciso observar todos os aspectos quando nos referimos à utilização de ferramentas computacionais, como é o caso de um sistema de apoio ao diagnóstico, pois não adianta poderosas ferramentas de apoio ao diagnóstico se o seu custo computacional e/ou outros aspectos são caros ou dispensáveis, principalmente devido ao elevado número de imagens e processamentos e classificações cada vez mais complexos do ponto de vista computacional.

A técnica de seleção de atributos pode ser uma alternativa para melhorar o desempenho de classificadores, visto que, nem todos os atributos contribuem de forma satisfatória e que muitos deles são redundantes no processo de classificação, ou seja, não agrega informações novas, atrapalhando muitas vezes a eficácia e o tempo de processamento dos classificadores. Esta seleção pode ser explicada através do fato que quanto menor o número de atributos, mais simples será a arquitetura do classificador.

Diante do exposto, esse estudo se baseou na abordagem de seleção de atributos pelo algoritmo de busca genético, associados à técnica de avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation).

Para essa seleção de atributos foi utilizado a ferramenta *WEKA* na versão 3.6, na aplicação “explore” utilizando a aba “seleção de atributos” dessa aplicação. Como já mencionado, a técnica de escolha foi a de CFS Subset Evaluation, porém quanto ao algoritmo de busca genético foram utilizadas diversas configurações de parâmetros: probabilidade de *cross over*, número de gerações, probabilidade de mutações, tamanho da população, frequência relatada e número aleatórios. Essas mudanças de configurações visaram buscar qual a configuração dessa técnica de seleção de atributos seria a mais eficaz, quando usados os classificadores selecionados para esse estudo.

3.4 Processo de classificação

Após a etapa de seleção de atributos/redução de atributos, veio à etapa de classificação. Para essa etapa foi levado em consideração quais os classificadores

atualmente são mais utilizados para elucidar a problemática de diagnóstico de câncer de mama. Quatro classificadores foram selecionados, são eles: perceptron multicamadas (MLP); redes de base radial (RBF); aprendizagem baseada em instâncias com parâmetro k (IBK) e otimização mínima sequencial (SMO).

Com os classificadores já selecionados foi utilizada a ferramenta Weka na Versão 3.6 na aplicação “Explore” e na aba de classificação para que os mesmos expressassem individualmente todas as suas métricas de classificação como taxas de acerto, matrizes de confusão, dentre outros.

Para se encontrar a melhor precisão (taxa de acerto), esses classificadores foram submetidos a diferentes parâmetros que variam de acordo com cada classificador e serão expostos nos resultados. Outro parâmetro importante que foi constantemente modificado em busca de um melhor resultado para o sistema foi o parâmetro opção de teste na aba de “Divisão de Percentagem”, que indica qual a porcentagem (%) será utilizada para o treino da máquina de aprendizagem e qual a porcentagem será utilizada para testar a máquina. Em alguns momentos também foi utilizado como opção de teste a opção validação cruzada *10-fold*.

Vale ressaltar que devido à característica estocástica das etapas de treinamento, tanto a seleção de atributos como a fase de classificação foram repetidas trinta vezes.

Para melhorar a compreensão da descrição dos resultados as técnicas de seleção de atributos receberam uma expressão numérica (Tabela 4) e os classificadores e suas respectivas configurações receberão uma expressão nominal (Tabela 5).

Tabela 4. Representação das seleções de atributos de acordo com sua configuração

Representação	Configuração da Seleção de Atributos
Seleção de atributos 01	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:20; G:15; C:0,4; M:0,5; R:20; S:1.
Seleção de atributos 02	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:20; G:20; C:0,8; M:0,066; R:20; S:5.
Seleção de atributos 03	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:10; G:10; C:0,1; M:0,1; R:10; S:1.
Seleção de atributos 04	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:2; G:5; C:0,5; M:0,5; R:5; S:5.
Seleção de atributos 05	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:2; G:7; C:0,7; M:0,7; R:7; S:7.
Seleção de atributos 06	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:20; G:20; C:0,6; M:0,033; R:20; S:1.
Seleção de atributos 07	Avaliação de subconjuntos por seleção de atributos baseados em correlação (CFS Subset Evaluation) com algoritmo de busca genético com os parâmetros: Z:20; G:20; C:0,6; M:0,003; R:20; S:1.

Legenda: Z= Population size; G: Number of generation; C: Probability of crossover; M: Probability of mutation; R: Reporty frequency; S: Random number seed. Fonte: A autora.

Tabela 5. Representação dos classificadores utilizados de acordo com a sua configuração

Classificador	Configuração no Weka	Representação nominal do classificador
IBK	Configuração Padrão do WEKA (K:1; W:0-A)	IBK
RBF	B:2; S:1; R:1.OE-8; M:1; W:0,1	RBF
SMO	C:1.0; L:0,001; P:1.OE-12; N:0; V:1; W:1 – K com Suporte de Vetor Poly Kernel C:25007; E:1.0	SMO*
SMO	C:3.0; L:0,001; P:1.OE-12; N:0; V:3; W:1 – K com Suporte de Vetor Poly Kernel C:25007; E:2.0	SMO**
SMO	C:2.0; L:0,001; P:1.OE-12; N:0; V:1; W:1 – K com Suporte de Vetor Poly Kernel C:25007; E:2.0	SMO***
SMO	C:3.0; L:0,001; P:1.OE-12; N:0; V:1; W:3 – K com Suporte de Vetor Poly Kernel C:25007; E:2.0	SMO****
MLP	L:0,05; M:0,5; N:500; V:0; S:0; E:20 -Ha	MLP*
MLP	L:0,3; M:0,2; N:500; V:0; S:0; E:20 -Ha	MLP**
MLP	L:0,03; M:0,2; N:500; V:0; S:0; E:20 -Ha	MLP***

Fonte: A autora.

Após todas as técnicas de seleção de atributos e de classificação, os resultados foram analisados estatisticamente através de estatística descritiva e foram comparados entre si. Para que o trabalho seja de fácil compreensão e de valia científica serão expostos os melhores resultados das classificações de acordo com cada seleção de atributos, com o intuito de mostrar qual a seleção de atributos que obteve melhores resultados e qual o/os classificadores se destacaram na resolução do problema.

Todos os experimentos foram rodados em uma máquina com processador AMD Dual Core E-300, 2GB de RAM, 320 GB de HD, 1.20GHz, sistema operacional Windows 7 de 64 bits.

4 RESULTADOS OBTIDOS E ANÁLISE

Após o término de todas as etapas descritas nos materiais e métodos propostos e consequentemente a execução de todos os experimentos computacionais, foi obtido uma gama diversificada de dados que serão expostos e analisados nesse capítulo.

A primeira etapa desse estudo é a exposição e a análise da construção do banco de dados feitas a partir do banco de dados IRMA demonstrando em imagens exemplos da marcação das bordas das lesões mamárias.

A segunda etapa desse estudo é expor e analisar a seleção de atributos com base em algoritmo genético, considerando o número de atributos obtido de cada seleção e como esse número interferiu nos resultados.

A terceira etapa desse estudo é expor como cada configuração de seleção de atributos se comportou com os classificadores escolhidos para o trabalho desenvolvido e comparar quais os melhores resultados foi obtido entre esses classificadores.


E por fim a quarta etapa desse estudo que visava discutir os resultados encontrados nas etapas 2 e 3.


4.1 Banco de dados

O banco de dados formado para análise na presente dissertação é composto de imagens de regiões de interesse de lesões de mama onde as bordas das lesões de densidade mamária adiposa e fibroglandular foram demarcadas na cor vermelha.

A primeira fase da construção de dados foi distribuída em pastas como mostrado na Figura 4.


Figura 4. Representação da distribuição das imagens em pastas na primeira etapa de construção





Após a primeira etapa, foi realizada a marcação das imagens selecionadas em outras pastas que as evidenciasse e delimitasse as configurações estabelecidas para a mesma. Essa distribuição pode ser observada na Figura 5.

Figura 5. Representação da distribuição das imagens em pastas após o processo de demarcação das bordas



Esse banco de dados construído possui um total de 505 imagens, sendo 222 imagens oriundas de mama adiposa e 283 de mama fibroglandular, as mesmas como visto na Figura 4 acima estão distribuídas por classificação e tipo de lesão que tem sua frequência separada demonstrada na Tabela 6 e 7.

Tabela 6. Distribuição da frequência numérica de imagens de densidade adiposa, com sua classificação e tipo de lesão

Mama Adiposa		
Classificação	Tipos de lesões	Frequência (nº)
Benigna	Calcificação	47
	Massa circunscrita	59
	Distorção arquitetural	1
	Total	107
Maligna	Calcificação	37
	Massa circunscrita	23
	Massa espículada	55
	Total	115
TOTAL GERAL		222


Fonte: A autora.

Tabela 7. Distribuição da frequência numérica de imagens de densidade fibroglandular, com sua classificação e tipo de lesão

Mama Fibroglandular		
Classificação	Tipos de lesões	Frequência (nº)
Benigna	Calcificação	57
	Massa circunscrita	88
	Distorção arquitetural	1
	Total	146
Maligna	Calcificação	36
	Massa circunscrita	9
	Massa espículada	92
	Total	137
TOTAL GERAL		283


Fonte: A autora.

Figura 6. Imagens de mama adiposa benigna distribuída por tipo de lesão




Fonte: A autora.

Figura 7. Imagens de mama adiposa maligna distribuída por tipo de lesão




Fonte: A autora.

Figura 8. Imagens de mama fibroglandular benigna distribuída por tipo de lesão




Fonte: A autora.

Figura 9. Imagens de mama fibroglandular maligna distribuída por tipo de lesão




Fonte: A autora.

Figura 10. Comparativo de imagens não demarcadas e marcadas de mama adiposa, distribuídas por classificação



Fonte: A autora

Figura 11. Comparativo de imagens não demarcadas e marcadas de mama fibroglandular, distribuídas por classificação e tipo de lesão



Fonte: A autora

A criação desse banco de dados baseado em demarcar as bordas das lesões mamárias a partir de imagens de regiões de interesse de mamografias tem como intenção delimitar onde especificamente se encontra a lesão, pois algumas imagens mamográficas demonstram que a lesão pode passar despercebida. Isto pode ser percebido principalmente quando se trata de lesões do tipo calcificação, por serem no estágio inicial muito pequena quando comparadas com ao volume do tecido mamário feminino, podendo atrapalhar na visualização a olho nu. Tal fato

torna muitas vezes que a lesão seja imperceptível diante a análise dos profissionais e até de uma análise computacional.

Analisando esse fato, a demarcação das bordas das lesões encontradas nesse banco de dados pode ser considerada positiva na análise da lesão de mama por sistemas de apoio ao diagnóstico. O treinamento de tais sistemas pode ser facilitado devido a essa demarcação, pois ele vai conseguir detectar mais rapidamente e precisamente a lesão e classificá-la.

Isto posto, pode-se esperar que futuramente, com o teste e a implementação de banco de dados desse tipo, que a taxa de acerto na detecção e classificação de lesões mamárias nos sistemas de apoio será elevada, ajudando a diagnosticar cada vez mais precocemente esse tipo de câncer.


4.2 Resultados experimentais de seleção de atributos com algoritmo genético

A redução de atributos oriunda da seleção de atributos (Figura 12) se mostrou positiva na maioria dos casos para se obter taxas de acertos maiores na detecção e classificação de lesões de mama através de imagens mamográficas.

Contudo quando está redução de atributos era obtida com menos de 100 atributos, ou seja, variavam de 50 a 100 atributos, os índices de taxa de acerto eram reduzidos. Pode-se ainda salientar que quando o número de atributos era reduzido para menos de 50 a queda era brusca no que se refere à taxa de acerto, deixando o sistema de apoio vulnerável a muitos erros o que é considerado negativo para qualquer sistema de inteligência computacional.

Já quando os números de atributo eram maiores que 100, os resultados encontrados foram bem mais aceitáveis, detectando o sistema de apoio muito mais eficaz.

Figura 12. Demonstração do número de atributos reduzidos após a aplicação de seleção de atributos



Fonte: A autora.

Diante desses resultados, pode-se afirmar que para esse sistema de apoio o quantitativo de atributos interfere na eficácia de detecção e classificação de lesões mamárias.

4.3 Classificações a partir das seleções de atributos

Por esse trabalho ser baseado em diversos testes de configuração em busca dos melhores resultados para cada classificador, será exposto aqui em cada tipo de seleção de atributos os resultados mais relevantes para o sistema de apoio proposto. Esses resultados terão como base as melhores taxas de acertos encontradas e menores taxas de falso positivo. Outro ponto importante que merece ser salientado é que também serão mostrados os melhores resultados em consideração o modo de teste (porcentagem para treino e para teste, ou validação cruzada 10 folds).

Tabela 8. Resultado da classificação a partir de seleção de atributos 01

Seleção de Atributos 01			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP*	0,029	67,62	80% para treino e 20% para teste
MLP**	0,014	85,71	99% para treino e 1% para teste
RBF	0,048	47,63	66% para treino e 33% para teste
RBF	0,045	50,60	88% para treino e 22% para teste
IBK	0,034	62,35	66% para treino e 33% para teste
IBK	0,031	62,77	90% para treino e 10% para teste
SMO*	0,034	62,57	66% para treino e 33% para teste
SMO*	0,026	72,29	95% para treino e 5% para teste
SMO*	0,026	78,57	99% para treino e 1% para teste

Fonte: A autora.

Analisando os resultados apresentados na Tabela 8, referente à Seleção de Atributos 01, tem-se que os melhores resultados respectivamente foram dos classificadores MLP com 85,71% e do SMO com 78,57%. Para esses classificadores apresentarem essas taxas de acertos os mesmos precisaram ter um treinamento intenso da base de dados. Os mesmos classificadores quando submetidos a taxas de treinamento menores ainda obtiveram os melhores resultados para essa seleção de atributos, contudo bem inferior à porcentagem de acertos com alto treinamento.

Tabela 9. Resultado da classificação a partir de Seleção de Atributos 02

Seleção de Atributos 02			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,029	67,70	Validação cruzada - 10 folds
MLP**	0,031	65,51	66% para treino e 33% para teste
MLP**	0,017	78,57	98% para treino e 2% para teste
MLP**	0,004	92,86	99% para treino e 1% para teste
RBF	0,047	48,39	70% para treino e 30% para teste
IBK	0,033	63,30	66% para treino e 33% para teste
IBK	0,024	71,43	98% para treino e 2% para teste
IBK	0,019	75	99% para treino e 1% para teste
SMO*	0,028	67,86	95% para treino e 5% para teste
SMO*	0,022	75	98% para treino e 2% para teste
SMO*	0,019	82,14	99% para treino e 1% para teste
SMO**	0,018	78,57	95% para treino e 5% para teste
SMO**	0,009	85,71	98% para treino e 2% para teste
SMO**	0,007	89,29	99% para treino e 1% para teste

Fonte: A autora.

No que se trata da Seleção de Atributos 02 as bases de dados que se destacam são as mesmas e na mesma ordem do caso anterior, ou seja, MLP com

92,86% e SMO com 89,29% quando foram também submetidos a um treinamento intenso de 99%.

Contudo os valores de taxas de acertos aqui apresentados foram significativamente superiores as encontradas nos mesmos classificadores da Seleção de Atributos 01. Um ponto de destaque para o classificador MLP que nessa seleção de atributos obteve seu melhor resultado dentre todas as outras, vale salientar para esse a classificação tem valores de taxa de acerto bem diferentes quando se muda o valor do treinamento, em apenas 1 ponto como pode ser observado na Tabela 9.

Vale ressaltar aqui o desempenho do classificador IBK, que assim como o MLP alcançou seu maior resultado 75% que também é visto na Seleção de Atributos 04, quando submetido a um nível de treinamento alto. Contudo, ele se destaca nessa seleção de atributos, pois além de obter seu maior resultado ele também se destacou pelo fato do crescimento progressivo significativo quando se variavam os níveis de treinamento (Tabela 9).

Isto posto, pode-se dizer que essa seleção de atributos conseguiu reunir resultados significativos em 3 dos 4 classificadores testados neste trabalho.

Outro dado que vale ser ressaltado é que a menor taxa de falso positivo de todas as seleções foi obtida no classificador MLP dessa seleção com taxa de 0,004 (Tabela 9).

Tabela 10. Resultado da classificação a partir de Seleção de Atributos 03

Seleção de Atributos 03			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,021	75,71	95% para treino e 5% para teste
MLP**	0,02	75	98% para treino e 2% para teste
RBF	0,047	48,26	66% para treino e 33% para teste
IBK	0,035	60,88	66% para treino e 33% para teste
IBK	0,031	63,43	86% para treino e 14% para teste
SMO*	0,029	67,70	Validação Cruzada - 10 folds
SMO***	0,025	73,51	85% para treino e 12% para teste
SMO***	0,025	72,77	92% para treino e 8% para teste
SMO****	0,022	76,43	95% para treino e 5% para teste
SMO****	0,011	82,14	99% para treino e 1% para teste

Fonte: A autora.

A Seleção de Atributos 03 apresentou resultados diferentes das seleções de atributos anteriormente mostradas, onde o destaque dessa seleção foi o classificador SMO com 82,14%.

Outro ponto que vale evidenciar é que para essa seleção de atributos mesmo submetendo os classificadores a diferentes configurações e níveis de treinamento os valores de taxas de acertos não variam significativamente. Inclusive quando se elevou o nível de treinamento, os resultados diminuíram e não aumentavam como pode ser observado na Tabela 10. Essa variação de taxa de

acerto, só ocorreu em uma configuração específica do SMO, que foi aquela que apresentou melhor resultado.

Tabela 11. Resultado da classificação a partir de Seleção de Atributos 04

Seleção de Atributos 04			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,029	67,85	Validação Cruzada - 10 folds
MLP**	0,028	69,29	95% para treino e 5% para teste
MLP**	0,02	75	99% para treino e 1% para teste
RBF	0,048	45,36	90% para treino e 10% para teste
IBK	0,034	61,10	85% para treino e 15% para teste
IBK	0,034	64,29	95% para treino e 5% para teste
IBK	0,018	75	99% para treino e 1% para teste
SMO****	0,023	75,07	Validação Cruzada - 10 folds
SMO****	0,012	83,93	98% para treino e 2% para teste
SMO****	0,014	89,29	99% para treino e 1% para teste

Fonte: A autora.

Seguindo os resultados obtidos na classificação da Seleção de Atributos 03 essa seleção também teve como destaque o classificador SMO com taxa de acerto de 89,29%, resultado esse superior à seleção de atributos anterior e igual ao obtido na Seleção de Atributos 02.

Nessa seleção de atributos, os valores de taxa de acerto voltaram a possuir uma elevação quando os classificadores eram submetidos cada vez mais a altos índices de nível de treinamento (Tabela 11).

Tabela 12. Resultado da classificação a partir de Seleção de Atributos 05

Seleção de Atributos 05			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,029	63,35	90% para treino e 10% para teste
MLP**	0,036	55,71	95% para treino e 5% para teste
RBF	0,048	47,76	80% para treino e 20% para teste
IBK	0,032	64,87	Validação Cruzada - 10 folds
IBK	0,033	62,29	85% para treino e 15% para teste
IBK	0,027	67,86	99% para treino e 1% para teste
SMO*	0,03	66,56	66% para treino e 33% para teste
SMO****	0,024	74,10	75% para treino e 25% para teste
SMO****	0,017	80,71	95% para treino e 5% para teste
SMO****	0,011	92,86	99% para treino e 1% para teste

Fonte: A autora.

Os resultados obtidos na Seleção de Atributos 05 foram interessantes e surpreendentes, visto que o classificador MLP obteve seu pior resultado (55,71%) entre todas as seleções e o classificador SMO, que na Seleção de Atributos 01 e 02 foi ultrapassado por ele, teve seu melhor resultado alcançando uma taxa de acerto

de 92,86% que se iguala ao resultado encontrado em MLP na Seleção de Atributos 02.

Pode ser observado também que no classificador MLP quando o nível de treinamento era aumentado a taxa de acerto diminuía. Outro ponto que merece destaque é que o classificador IBK mesmo quando estressado a diferentes níveis de treinamento não apresentou um crescimento considerável na taxa de acerto (Tabela 12).

Tabela 13. Resultado da classificação a partir de Seleção de Atributos 06

Seleção de Atributos 06			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,03	67,06	85% para treino e 15% para teste
MLP**	0,016	89,29	99% para treino e 1% para teste
RBF	0,046	49,64	90% para treino e 10% para teste
IBK	0,031	67,71	95% para treino e 5% para teste
IBK	0,033	72,43	99% para treino e 1% para teste
SMO*	0,027	70	95% para treino e 5% para teste
SMO*	0,024	82,14	99% para treino e 1% para teste
SMO****	0,022	76,49	88% para treino e 12% para teste
SMO****	0,007	92,85	99% para treino e 1% para teste

Fonte: A autora.

Resultados expressivos foram encontrados nessa seleção de atributos, pois os classificadores SMO mais uma vez alcançaram uma taxa de acerto de 92,86%.


Um fato de destaque é que a taxa de falso positivo é a menor para esse resultado (0,007) (Tabela 13). Vale ressaltar que o classificador MLP voltou a mostrar resultados expressivos (89,29%).

Tabela 14. Resultado da classificação a partir de seleção de atributos 07

Seleção de Atributos 07			
Classificador	Taxa de Falso Positivo	Taxa de Acerto (%)	Modo de Teste
MLP**	0,025	70,71	95% para treino e 5% para teste
MLP**	0,023	82,15	99% para treino e 1% para teste
RBF	0,043	51,43	95% para treino e 5% para teste
IBK	0,034	60,38	85% para treino e 15% para teste
IBK	0,033	67,86	99% para treino e 1% para teste
SMO*	0,029	67,86	95% para treino e 5% para teste
SMO*	0,019	85,71	99% para treino e 1% para teste
SMO****	0,025	72,55	85% para treino e 15% para teste
SMO****	0,017	79,29	95% para treino e 5% para teste
SMO****	0,005	89,29	99% para treino e 1% para teste

Fonte: A autora.

Assim como nas demais seleções de atributos, essa possui um destaque nos classificadores SMO com taxa de acerto de 89,29% e MLP com taxa de acerto de 82,15% quando expostos a altos níveis de treinamento. Contudo o que mais chama atenção na análise da seleção de atributos 07 é o fato de o classificador RBF apresentar seu melhor resultado que é de 51,43% (Tabela 14).

Figura 13. Comparação da melhor taxa de acerto encontrada em cada classificador

Fonte: A autora.

Sintetizando os melhores resultados obtidos em todas as seleções de atributos tem-se que os classificadores SMO e MLP obtiveram a mesma taxa de acerto 92,86% (Figura 13). Contudo, ao analisar qual delas é mais eficaz pode-se afirmar que a SMO é a melhor escolha de classificar, pois ao longo dos resultados apresentou melhores taxas de acertos em outros níveis de treinamento, além de precisarem de um menor tempo para chegar ao resultado obtido.

Quanto ao classificador IBK, não foram encontradas variações significativas de taxas de acertos ao longo do estudo, porém ainda fica em terceiro lugar como escolha para resolução desse problema. O classificador RBF apresentou resultados bem inferiores quando comparado a todos os classificadores utilizados. Além disso, o RBF possui o maior tempo de treinamento de todos os classificadores.

Um ponto bastante interessante e que se destacou nesse estudo foi o fato de que as taxas de acertos geralmente foram consideravelmente maiores quando o nível de treinamento era alto, ou seja, de 99% para treinamento e 1% para teste. Concluiu-se que significa que a classificação necessita sempre de altas taxas de treinamento e que assim os resultados obtidos geralmente são mais satisfatórios no que se refere à detecção e classificação de nódulos mamários.

Em relação à taxa de falso positivo, uma das grandes preocupações da ciência quanto aos sistemas de apoio ao diagnóstico, tem-se que as dessas

encontradas no decorrer do estudo e em todas as sete seleções de atributos foram baixas. A menor taxa foi obtida no classificador MLP** da Seleção de Atributos 02 com 0,004 seguida do classificador SMO**** da Seleção de Atributos 06 com 0,007.

4.4 Discussão

A detecção precoce de anormalidades no tecido mamário ocorre através da mamografia, está tem por sua vez uma sensibilidade de 85 a 95% em nódulos de mama em geral, ou seja, 5 a 15% desses nódulos não são identificados no exame. Isto posto pode-se afirmar que os resultados encontrados pelos classificadores SMO e MLP nesse estudo são superiores a faixa de sensibilidade, confirmando assim sua eficácia no apoio ao diagnóstico do câncer de mama (RODRIGUES; CALAS; NADRUZ, 2008; NASCIMENTO; PITTA; REGO, 2015).

Vale salientar que essa taxa de sensibilidade (85 a 90%) pode diminuir quando os profissionais radiologistas que são responsáveis pela análise dessas imagens obtidas nas mamografias não são bem treinados na interpretação de exames de imagens. Outro episódio que pode interferir na sensibilidade da mamografia é a qualidade do mamógrafo, pois atualmente no Brasil não há uma exigência de auditoria nesses aparelhos, esse decaimento pode ser confirmado por estudos, que relatam que a sensibilidade da mamografia pode varia de 71 a 98% e ainda relatam que essa sensibilidade varia de instituição para instituição, com essa redução o classificador IBK também pode ser uma alternativa no apoio ao diagnóstico de câncer de mama, visto que apresentou em 2 tipos de seleções de atributos 75% de taxa de acerto, e possuem um tempo de treinamento curtíssimo (MELLO, 2015).

Para suprir essa variação de sensibilidade de instituição para instituição, a entidade nacional Colégio Brasileiro de Radiologia e Diagnóstico Por Imagem, preocupada com a qualidade das imagens geradas em todo país, desenvolveu um programa de qualidade em Mamografia, Tomografia Computadorizada, Ultrassonografia, e Ressonância Magnética, criando assim o Programa de Acreditação em Diagnóstico Por Imagem, esse programa tem como foco avaliar criteriosamente o cumprimento de requisitos mínimos de qualidade. Contudo, sabendo que é facultativa a aderência desse programa em todos os tipos de serviço de saúde (públicos ou privados), e que muitas vezes o Sistema Único de Saúde

(setor público) não prioriza manutenções preventivas dos equipamentos que a rede possui e que geralmente a rede privada prioriza o lado financeiro e não a qualidade do serviço prestado, o uso de sistemas de apoio ao diagnóstico, como o proposto aqui, pode melhorar e ampliar a detecção precoce do câncer de mama, visto que a taxa de acerto aqui encontradas superam a faixa de sensibilidade dos mamógrafos provavelmente em todo país (MELLO, 2015).

Uma forma de aumentar a precisão diagnóstica de câncer de mama é através da comparação da realidade atual encontrada a partir de mamografias prévias ou então pelo “double reading”, mais conhecido na área da saúde como leitura dupla, onde essa visa buscar duas interpretações iguais de diferentes profissionais. Uma alternativa para essa segunda leitura podem ser os sistemas de apoio ao diagnóstico como o proposto nesse estudo, pois o mesmo possui uma boa taxa de acerto na detecção e classificação de câncer de mama, essa alternativa do sistema de apoio ao diagnóstico além de economizar muitas vezes custo com mão de obra leva a uma detecção precoce mais rápida visto que quanto antes o diagnóstico for apresentado, mais rápido a inserção do indivíduo no tratamento e consequentemente maior será sua sobrevivência (RODRIGUES; CALAS; NADRUZ, 2008).

Outra vertente que esse sistema de apoio proposto neste estudo pode influenciar positivamente é na diminuição do número de exames invasivos (biópsia), exame esse que além de incomodo formam uma porta de entrada no corpo do indivíduo que por sua vez deixa esse mais susceptível a adquirir infecções. Esse fato pode ser justificado por estudo relatado na literatura que mostra que dentre 1.000.000 indivíduos do sexo feminino que são submetidas anualmente nos Estados Unidos da América a biópsias mamárias em decorrência de achados mamográficos anormais diagnosticados nos programas de rastreamento, 700.000 a 850.000 apresentaram resultados negativos, e essa realidade não é muito diferente do Brasil (PATROCÍNIO, 2004).

Vale ressaltar também, que a mamografia seja convencional ou digital exige riscos, como por exemplo, a utilização de radiação ionizante, que mesmo em baixas quantidades seu uso ao longo dos anos pode acarretar consequências a saúde da mulher. Essa informação deixa ainda mais evidente a necessidade do surgimento e aprimoramento das técnicas de diagnóstico de câncer de mama que colabora

também na redução do número de mamografias que varias vezes precisam ser refeitas (NASCIMENTO; PITTA; REGO, 2015).

Isto posto, e sabendo que milhares de mulheres no Brasil (média de 10 mil) vão a óbito em decorrência do câncer de mama e que esta alta mortalidade está associada ao fato de 60% dos casos serem apenas descobertos em estágio tardio, o sistema de apoio proposto nesse estudo se mostra uma ótima alternativa na detecção precoce e na redução da mortalidade principalmente das mulheres em nosso país (PATROCÍNIO, 2004).

Uma abordagem que merece ser avaliada e que por várias vezes é negligenciada é que a detecção precoce muitas vezes é dificultada pela falta de acesso a mamografias de indivíduos do sexo feminino fora da faixa etária ou dos grupos de risco estipulados pelo ministério da saúde na rede pública de saúde e que após conseguirem realizar o exame ainda precisam esperar o parecer de um médico radiologista, pois os demais profissionais da área da saúde, incluindo os médicos de outras especialidades não conseguem detectar ou diagnosticar a presença de alguma anormalidade no tecido mamário em imagens mamográficas, problema esse que pode ser minimizado com a capacitação e implantação de sistemas de apoio de diagnóstico como esse, que pode servir como triagem para detectar lesões mamárias principalmente em unidades de atenção básica e em locais distantes dos centros urbanos.

Essa vertente de uso do sistema de apoio ao diagnóstico pode trazer uma gama de benefícios para os profissionais que ampliarão o seu conhecimento e poderão prestar um serviço mais rápido e humanizado aos indivíduos que por sua vez poderiam confirmar ou descartar a presença do câncer de mama que possui uma alta incidência e mortalidade entre as mulheres e ainda beneficiaria as instituições de saúde que prestam esse tipo de serviço, pois selecionaria os indivíduos acometidos pela patologia e com isso reduziria gastos que por muitas vezes eram desnecessários e os usaria em outras áreas que precisasse.

5 CONCLUSÃO

Considerando os resultados obtidos pode-se afirmar que o sistema de apoio ao diagnóstico aqui proposto é eficaz e traz ótimos resultados para o diagnóstico de câncer de mama quando utilizados inteligência computacional aplicando a seleção de atributos 6 utilizando o classificador SMO é a melhor escolha para o diagnóstico de câncer de mama.

Vale considerar que o custo computacional é relativamente baixo e é igual para qualquer técnica utilizada nesse estudo.

5.1 Conclusões gerais

O diagnóstico do câncer de mama nos dias que correm ainda é demorado, levando a uma escassez de diagnósticos em fases primárias de adoecimento. A tecnologia aqui proposta pode ser uma alternativa eficaz para o diagnóstico de câncer de mama, para isso deve ser utilizado o método de Seleção de Atributos 6 desse estudo e utilizar-se do classificador Otimização Mínima Sequencial (SMO) que é aplicado na execução otimizada do classificador SVM no *WEKA*, instrumento que se mostrou eficaz e de simples manuseio no que se refere a diagnóstico de câncer de mama.

Um ponto que vale ser ressaltado nesse estudo é que além de detectar e classificar nódulos mamários se trabalhou com variadas densidades mamárias fato que, poderia trazer várias interferências no diagnóstico de tumores de mama pelo sistema de apoio proposto diminuindo a taxa de acertos, tal fato não aconteceu.

Conclui-se assim, que os resultados desse estudo fornecem informações valiosas sobre os sistemas de apoio ao diagnóstico, alargando nossa compreensão sobre o seu uso e seus benefícios relacionados com o diagnóstico de câncer de mama. Fornece ainda evidências preliminares sobre o valor da tecnologia a favor da área da saúde da mulher.

5.2 Contribuições

Visto que a saúde além de ser o bem mais precioso é um direito de todos garantido na Constituição Federal brasileira, esse estudo contribui para evolução

tecnológica na área de inteligência computacional no que se refere ao diagnóstico de câncer de mama que é o 2º com maior incidência entre as mulheres, trazendo uma alternativa de apoio ao diagnóstico de câncer de mama para que a cada dia haja uma maior detecção em estágio inicial da doença e que diminua sua taxa de mortalidade.

Especificamente, esse estudo trouxe uma alternativa viável no diagnóstico precoce do câncer de mama, trazendo consigo a Seleção de Atributos e o classificador mais eficaz. Além disso, ele mostrou que a taxa de acerto quando utilizado o sistema de apoio proposto é numericamente maior do que a média atual dos mamógrafos. Vale ressaltar ainda que ao utilizar esse sistema de apoio ao diagnóstico, nem o paciente e nem o profissional de saúde são submetidos a qualquer risco. Então, pode-se concluir que esse estudo trouxe uma relevante contribuição para o avanço tecnológico do diagnóstico do câncer de mama.

5.3 Trabalhos futuros

Para trabalhos futuros, sugere-se ampliar a busca de métodos de seleção de atributos e classificadores que possam apresentar taxas de acertos maiores do que as encontradas nesse estudo e robustas o suficiente para suportar reduções drásticas de atributos.

Sugere-se também o uso dessa técnica de seleção de atributos e seus respectivos métodos de classificação em outros bancos de imagens de mama como imagens termográficas, a fim de ver o comportamento do sistema de apoio ao diagnóstico nessas imagens.

Sugere-se também a criação ou teste de sistemas de apoio ao diagnóstico em imagens de mama provenientes de outros exames de diagnóstico, tal como ultrassonografia da mama, por ser um exame mais acessível e de baixo custo.

A última sugestão é a implantação de testes de eficiência diretamente dos centros de apoio à saúde da mulher ou de qualquer instituição de saúde que ofereça esse tipo de exame de imagem, com o intuito de ver na prática o funcionamento do sistema e da aceitação do profissional médico radiologista a essa técnica de diagnóstico computacional.

REFERÊNCIAS

AHA, D. W. Training noisy, irrelevant and novel attributes in instance-based learning algorithms. *International Journal of Man-Machine Studies* 36(2):267-287, 1992.

AHA, D. W.; KIBLER, D.; ALBERT, M. Instance-based learning algorithms. *Machine Learning* 6:366, 1991.

AMERICAN CANCER SOCIETY, **Breast Cancer Facts & Figures 2009-2010**. 2010. Disponível em <<http://www.cancer.org>> Acesso 01/11/2015 às 08h16min.

AMERICAN CANCER SOCIETY. **Breast Cancer**. 2015. Disponível em <<http://www.cancer.org>> Acesso 01/11/2015 às 08h16min.

BARBOSA, I. R.; COSTA, I. C. C.; PÉREZ, M. M. B.; SOUZA, D. L. B. Mortalidade por câncer de mama nos estados do Nordeste do Brasil: tendências atuais e projeções até 2030. **Revista Ciência Plural**, 2015.

BARUFALDI, B.; SANTANA, E. F.; BATISTA, L. V.; SCHIABEL, H.; CARVALHO, J. F. G. Sistema Para Controle de Qualidade de Mamógrafos Através da Análise Computacional de Imagens de Phantom Utilizando a Ferramenta WEKA. *Anais: VII Workshop de Visão Computacional – WVC*, p.16-21, 2011.

BIAZUS, J. V. **Rotinas em Cirurgias Conservadoras da Mama**. Porto Alegre: Artes Médicas, v. 1, 2000.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais Teoria e Aplicações**. Livros Técnicos e Científicos Editora, Rio de Janeiro, 2000.

BRASIL. **Controle dos cânceres do colo do útero e da mama**. Ministério da Saúde, Secretaria de Atenção à Saúde, Departamento de Atenção Básica. – 2. ed. – Brasília : Editora do Ministério da Saúde, 2013.

BRASIL. **Curso de atualização em mamografia para técnicos e tecnólogos em radiologia**. Ministério da Saúde, Secretaria de Gestão do Trabalho e da Educação na Saúde, Departamento de Gestão da Educação na Saúde. – Brasília : Ministério da Saúde, 2014.

CANCER RESEARCH UK. **Breast cancer: UK incidence statistics**. 2011. Disponível em: <<http://info.cancerresearchuk.org/cancerstats/types/breast/incidence>> Acesso em: 10/11/2015 às 08h20min.

COLÉGIO BRASILEIRO DE RADIOLOGIA. **BI-RADS: sistema de laudos e registro de dados de imagem da mama**. São Paulo: Colégio Brasileiro de Radiologia, 2010.

DESERNO, T. M. et al. **Computer-aided diagnostics of screening mammography using content-based image retrieval**. 2012.

DOUSSET, M. P. **Vivendo com um câncer**. Bauru, SP: EDUSC, 1999.

ESPERANÇA PINA, J. A. **Anatomia Humana da relação**. 3ª edição, Lisboa, Lindel, 2000.

ESPERANÇA PINA, J. A. **Anatomia Humana dos Órgãos**. Lisboa, Lindel, 2004.

FRONER, A. P. P. **Caracterização de nódulos pulmonares em imagens de tomografia computadorizada para fins de auxílio ao diagnóstico**. Tese de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul, 2015.

GANASCIA, J. G. **Inteligência Artificial**. São Paulo: Ática, 1997.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. 4ª ed. [S.l.]: São Paulo, Atlas, 2002.

GOLDBERG, D. E. **Genetic algorithms in search, optimization and machine learning**. [S.l.]: Addison-Wesley, 1989.

GUARDA, A. CIC250 – **Inteligência Artificial**. 2004. Disponível em: <<http://www.ice.unifei.edu.br/ramos/download/IA/ApostilaIA.pdf>>. Acesso 01/11/2015 às 02h01min.

GUTEMBERG, J. G. I. **Importância da sensibilidade do contraste e de redes neurais artificiais na análise do prejuízo visual da esclerose múltipla**. Tese de doutorado da Universidade Federal de Pernambuco, 2015.

HALL, M. A. Correlation-based Feature Selection for Machine Learning. Tese (Doutorado), University of Waikato, 1999.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Trad. Paulo Martins Engel. Porto Alegre: Bookman, 2001.

HUANG, G. B.; YU ZHU, Q.; SIEW, C. K. **Extreme learning machine: theory and applications**. Neurocomputing, 2006.

INCA - Instituto Nacional de Câncer. **SISMAMA - Informação para o avanço das ações de controle do câncer de mama no Brasil**. 2010. Disponível em: <http://www1.inca.gov.br/inca/Arquivos/Sismama.pdf>

INCA - Instituto Nacional do Câncer. **Estimativas 2014**. Ministério da Saúde. 2014. Disponível em: <<http://www.inca.gov.br/estimativa/2014/index.asp?ID=2>>. Acesso: 10/11/2015 às 00h30min.

INCA - Instituto Nacional do Câncer. **Falando sobre Doenças de Mama**. Ministério da Saúde. 2015a. Disponível em:< <http://www.inca.gov.br>>, Acesso em 01/09/2015 às 22h53min.

INCA - Instituto Nacional de Câncer. **Câncer de mama: é preciso falar disso / Instituto Nacional de Câncer José Alencar Gomes da Silva**. – 3. ed. – Rio de Janeiro: Inca, 2015b.

INCA - Instituto Nacional de Câncer. **Estimativa 2016: incidência de câncer no Brasil**. Rio de Janeiro: INCA, Coordenação de Prevenção e Vigilância, 2015c.

INCA - Instituto Nacional de Câncer. **Controle do Câncer de Mama – Tratamento**. 2015d. Disponível em:<http://www2.inca.gov.br/wps/wcm/connect/acoes_programas/site/home/nobrasil/programa_controle_cancer_mama/tratamento> acesso 02/11/2015 às 23h12min

INTERNATIONAL AGENCY FOR RESEARCH ON CANCER. **Biennial Report 2008/2009**. 2009. Disponível em: <http://governance.iarc.fr/SC/SC46/SC46_2Text.pdf>. Acesso em 01/05/2015 às 05h24min.

KALAF, E. S. **Padrões Mamograficos e Densidade Mamária**. 2006. Disponível em:< <http://www.radiologiaclinicadecampinas.com.br/blog/?p=71>> Acesso

05/11/2015 às 09h03min.

KINOSHITA S. K., MARQUES P. M., ROBERTO R., RADON-DOMAIN. Detection of the Nipple and the Pectoral Muscle in Mammograms. **Journal of Digital Imaging**, n. 21, p. 37-49, 2008.

KÖSTERS, J. P.; GØTZSCHE, P. C. **Regular self-examination or clinical examination for early detection of breast cancer**. The Cochrane Library, [s.l.], Issue 4, 2008.

MACIEL, T. V.; SEUS, V. R.; MACHADOS, K. S.; BORGES, E. N. Mineração de dados em triagem de risco de saúde. **Revista Brasileira de Computação Aplicada** (ISSN 2176-6649), Passo Fundo, v. 7, n. 2, p. 26-40, maio. 2015.

MARQUES, C. A.V.; FIGUEIREDO, E. N.; GUTIÉRREZ, M. G. R. Políticas de saúde pública para o controle do câncer de mama no Brasil. **Rev Enferm UERJ**, Rio de Janeiro, 2015.

MARQUES, J. D. B. P. **Controlo e Optimização de Sistemas AVAC Recorrendo a Técnicas de Inteligência Artificial**. Tese de Dissertação, Março 2015.

MARTINS, L. D. **Deteccção de Massas de imagens mamográficas através do algoritmo Growing neural gás e da Função K de Ripley**. Tese de Mestrado do Programa de Pós Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão, 2007.

MELLO, J. M.R.B. **Qualidade de Imagem Radiológica: Calculando sensibilidade e especificidade em mamografias digitais diagnósticas do hcpa – auditoria interna**. Dissertação (Mestrado) da Universidade Federal do Rio Grande do Sul, 2015.

MISHINA, K. D. V; SERAFIM, R. M. S; NILO, P. S. **Avaliação de integridade de equipamentos da indústria Petrolífera através da técnica de campo magnético e inteligência artificial**. IN: Anais CONEPETRO - v. 1, n. 1, 2015.

MOORE, K.L; DALLEY, A. F. **Anatomia orientada para a clínica**. 5ª ed. Rio de Janeiro, Guanabara Koogan, 2007.

MOTTA, C. G. L. **Sistema Inteligente para Avaliação de Riscos em Vias de Transporte Terrestre**. Tese de Dissertação da Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004.

NASCIMENTO, F. B.; PITTA, M. G. R.; RÊGO, M. J. B. M. Análise dos principais métodos de diagnóstico de câncer de mama como propulsores no processo inovativo. **Arq Med**, vol.29, n°.6, Porto, dez. 2015.

OLIVEIRA, J. E. et al. **Towards a standard reference database for computer-aided mammography**. 2008.

PAIVA, C. J; CESSE, E. A. P. Aspectos Relacionados ao Atraso no Diagnóstico e Tratamento do Câncer de Mama em uma Unidade Hospitalar de Pernambuco. **Revista Brasileira de Cancerologia**, 2015.

PAIVA, G. V. **Aplicação de Sistema Especialista para Diagnóstico em Tempo Real das Condições Limite de Operação em Usinas Nucleares**. Rio de Janeiro: UFRJ/ESCOLA POLITÉCNICA, 2015.

PAROCÍNIO, A. C. **Classificador automático de achados mamográficos em imagens digitais de mamas densas utilizado técnica híbridas**. Mestrado (dissertação) da Escola de Engenharia de São Carlos, 2004.

PEREIRA, D. C. **Técnica automática de detecção de nódulo mamário usando informações de multivisão**. Tese de Mestrado do Programa de Pós Graduação em Engenharia de Informação da Universidade Federal do ABC, 2009.

PEREIRA, D.C; RAMOS, R.P; NASCIMENTO, M.Z. **Segmentation and detection of breast cancer in mammograms combining wavelet analysis and genetic algorithm**. Computer methods and programs in biomedicine 114, 2014.

PEREIRA, S. L. **Introdução à Inteligência Artificial**. USP. 2015. Disponível em: <<http://www.ime.usp.br/~slago/IA-introducao.pdf>> Acesso 05/11/2015 às 05h23min.

PEREIRA, D.C; NASCIMENTO, M. Z. **Empregando algoritmos genéticos na segmentação automática de nódulo mamário**. XLI SBPO - Pesquisa Operacional na Gestão do Conhecimento, 2009.

PINHO, S. R. A. **Apoio ao Diagnóstico de Imagens de Mamografia por Técnicas Computacionais**. Trabalhos Práticos do Mestrado em Engenharia Biomédica da

Faculdade de Engenharia da Universidade do Porto, 2015. Disponível em <
https://web.fe.up.pt/~tavares/downloads/publications/relatorios/Selma_Pinho-TP.pdf
 > Acesso em: 12/11/2015 às 12h55min.

RODRIGUES, M. C. S.; CALAS, M. J. G.; NADRUZ, E. Mamografia: exame único, tecnologias diversas. **FEMINA**, vol 36, nº 6, junho 2008.

SANTOS, L. P. R; TENORIO, M. B. **Sistema especialista para ensino-aprendizagem de algoritmo**. IN: ETIC – Encontro de Iniciação Científica, v.7, n.7, 2011.

SANTOS, W. P.; ASSIS, F. M. **Algoritmos Dialéticos para inteligência Computacional**. 1ª ed. [S.I.]: Editora Universitária, 2013.

SANVITO, W. L. Inteligência Biológica Versus Inteligência Artificial: Uma Abordagem Crítica. **Arq. Neuropsiquiatr.** 53(3-A):361 – 368, 1995.

SILVA, M. P. S. **Mineração de Dados - Conceitos, Aplicações e Experimentos com Weka**. 2004. Disponível em:
 <<http://www.lbd.dcc.ufmg.br/colecoes/erirjes/2004/004.pdf>> Acesso em; 17/11/2015 às 12h20min.

SIQUEIRA, R. F. F. B. **Densidade mamográfica em mulheres na pós-menopausa: associação com fatores epidemiológicos, antropométricos, reprodutivos e hormonais**. Dissertação, Campinas - SP, 2004.

SOUZA, U. S. **Classificação de massas na mama a partir de imagens mamográficas usando índice de diversidade de shannon – wiener**. Tese de Mestrado. Pós – Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão, 2011.

TAKAHASHI, C. C. **Mapeamento Explícito como Kernel em Aprendizado de Máquinas de Vetores de Suporte**. Dissertação, Universidade Federal de Minas Gerais, Belo Horizonte, 2015.

TANG, J.; RANGAYYAN, R. M.; XU J.; NAQA I. E.; YANG, Y. Computer-Aided Detection and Diagnosis of Breast Cancer with Mammography: Recent Advances. **IEEE Trans on Information Technology in Biomedicine**, v. 13, n. 2, p. 236-251, 2009.

WOLFE, J. N. Breast patterns as na index of risk for developing breast cancer. **Am J**

Roentegenol, 126:1130-9, 1976.

WORD HEALTH ORGANIZATION. **Câncer**. 2015. Disponível online em: <<http://www.who.int/cancer/en/>>. Acesso em: 09/11/2015 às 22h00min.

WORLD HEALTH ORGANIZATION. **Câncer**. 2011. Disponível online em: <http://www.who.int/cancer/e/>. Acesso em: 24/01/2014 às 02:11.

ZAPPON, A. L. B; TOCANTINS, F. R; VARGEN, O. M. C. O enfermeiro na detecção precoce do câncer de mama no âmbito da atenção primária. **Rev. Enferm UERJ**, Rio de Janeiro, 2015.

ANEXO

A pesquisa resultou até o momento em um artigo completo apresentado no 4º Encontro Brasileiro de Inovação Terapêutica, onde se encontra indexado nos seus anais.

ANEXO A - Artigo apresentado e publicado nos anais do 4º Encontro Brasileiro de Inovação Terapêutica

DETECÇÃO E CLASSIFICAÇÃO DE LESÕES DE MAMA EM MAMOGRAFIAS UTILIZANDO REDES NEURAIS ARTIFICIAIS E ATRIBUTOS MORFOLÓGICOS

T. N. da CRUZ¹, T. M. da CRUZ², W. P. dos SANTOS¹.

¹ Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Departamento de Engenharia Biomédica.

² Universidade Federal de Pernambuco, Centro de Ciências em Saúde, Departamento de Terapia Ocupacional.

E-mail para contato: wellington.santos@ufpe.br

RESUMO – O câncer de mama é um problema de saúde pública mundial, com uma alta taxa de incidência e mortalidade, onde o exame mais utilizado atualmente para se realizar diagnóstico de forma precoce é a mamografia. Este trabalho tem como objetivo verificar e analisar a aplicação de métodos de classificação baseados em redes neurais artificiais e descritores morfológicos na detecção da presença de nódulos mamários, visando buscar o método que otimiza a taxa de classificação e, por conseguinte, o diagnóstico de lesões de mama. Foram investigados três arquiteturas de classificadores, a saber: rede neural perceptron multicamadas (MLP), redes de função de base radial (RBF) e máquinas de vetor de suporte (SVM). Foi utilizada a base de imagens IRMA, que contém um conjunto de imagens de regiões de interesse consideradas suspeitas de ocorrência de lesão maligna ou benigna. Essas imagens foram representadas a partir da decomposição morfológica de wavelets, que tem como objetivo representar imagens a partir de componentes que combinam informação de orientação e de forma. A base possui 12 classes, organizadas de acordo com a densidade mamária (4) e classificação BI-RADS (3). O desempenho foi avaliado por meio da taxa de acerto, do índice do Kappa e da área ROC. O perceptron multicamadas com taxa de aprendizado de 0,03 atingiu o maior desempenho, com taxa de acerto de 96,21%, o que revela seu potencial para construção de sistemas de apoio ao diagnóstico por imagem.

Palavras chave: Classificação, Nódulos Mamários, Inteligência Artificial.

ABSTRACT – *Breast cancer is a worldwide public health problem, with a high rate of incidence and mortality, where the test most widely used to perform so early diagnosis is mammography. This research aims to verify and analyze the application of classification methods based on artificial neural networks and morphological descriptors in detecting the presence of breast lumps, aiming to seek the method that optimizes the classification rate and therefore the diagnosis of injury breast. Architecture softwre e classifiers have been investigated, namely, multilayer perceptron neural network (MLP), radial basis function networks (RBF) and support vector machines (SVM). In this research was employed the IRMA database, containing a set of image regions of interest suspected of occurrence of malignant or benign mammary lesions. These images were represented using wavelets morphological decomposition, which aims to represent images from components that combine information and geometric orientation. The database has 12 classes, organized according to breast density (4) and BI-RADS (3). The performance was evaluated by the accuracy rate, Kappa index, and ROC area. The multilayer perceptron with 0.03 learning rate reached the highest performance with accuracy rate of 96.21%, which shows its potential for building support diagnostic imaging.*

Keywords: Classification, Breast Lumps, Artificial Intelligence.

1. INTRODUÇÃO

O câncer de mama resulta da proliferação anormal das células da mama, que ocasiona um tumor com potencial de invadir outros tecidos. Sendo considerado um problema de saúde pública o câncer de mama é um grupo heterogêneo de patologias que possuem diferentes comportamentos. Devido a sua heterogeneidade ele se manifesta por diferentes apresentações clínicas e morfológicas e variadas características genéticas (INSTITUTO NACIONAL DO CÂNCER, 2015).

O câncer de mama corresponde a 22% dos tipos de câncer detectado anualmente, tendo sua maior incidência em mulheres do que em homens, sendo ele o tipo de câncer mais frequente no mundo e o primeiro que leva ao óbito indivíduos do sexo feminino. No Brasil, o Instituto Nacional de Câncer (INCA) relata 57.124 mil novos casos de câncer de mama no ano de 2014, uma média de 57 casos a cada 100.000 mulheres, onde 13.345 óbitos foram contabilizados em 2014. O exame mais utilizado hoje em dia para se realizarem de forma precoce, possíveis anormalidades no tecido mamário é a mamografia (KINOSHITA et al., 2008; PEREIRA, 2009; PEREIRA et al., 2014; INSTITUTO NACIONAL DO CÂNCER, 2015).

Para categorização de lesões mamárias das mamografias, é utilizado atualmente no Brasil, o Breast Imaging Reporting and Data System (BI-RADS®), que teve origem no Colégio Americano de Radiologia (EUA) e foi traduzida para o Brasil, pelo Colégio Brasileiro de Radiologia. Esse método de categorização realiza a padronização do laudo de lesões mamárias e ainda sugere quais as condutas precisam ser tomadas em cada caso (INSTITUTO NACIONAL DO CÂNCER, 2010).

Diversas técnicas computacionais vêm sendo utilizadas desde que a Inteligência Computacional (IC) começou a ser utilizada na área médica, e uma das mais extensas no que se refere à aplicabilidade de bases de dados médicos complexos para reconhecimento de padrões são as Redes Neurais Artificiais (RNA), que visam à investigação da possibilidade de uma simulação de comportamentos inteligentes, baseados no cérebro humano (BONIFÁCIO, 2010).

Nos dias de hoje, os sistemas computacionais englobam um grande volume de dados, e por esse fato os processos manuais e técnicas tradicionais de análise de dados não possibilitam a exploração de toda a informação implícita disponível. Contudo, desde o final dos anos 80, um recurso automático para a análise de dados já vem sendo utilizado, em um processo conhecido como Descoberta de Conhecimento em Banco de Dados (*Knowledge Discovery in Databases- KDD*), onde dentro das etapas da composição do processo de KDD, a Mineração de Dados (*Data Mining - DM*) é a etapa responsável pela aplicação específica de algoritmos para extrair padrões de dados que fornecem um conhecimento útil. Sendo atribuídas diversas tarefas à Mineração de Dados tais como: Análise de Agrupamentos, Regras de Associação, Predição e Classificação (BONIFÁCIO, 2010).

No que se refere à etapa de classificação, tem-se que existem diversos tipos de processo de classificação, contudo, as mais indicadas vêm sendo: a Perceptron Multicamadas (MLP), Redes de base radial (RBF) e Máquina de vetor suporte (SVM) (FRIZE, 2001; BONIFÁCIO, 2010; CONEGLIAN et al., 2010).

O aprendizado de máquina pode facilitar a detecção e classificação de lesões mamárias quando não há alterações na textura ou na morfologia (Figura 1), e quando se tem apenas o recurso de investigação visual humano. Seguindo esse pensamento, o objetivo desse estudo, é verificar e analisar a aplicação do método de classificação na detecção da presença de nódulos mamários, visando buscar qual o método de classificação é mais eficiente para resolução do problema em estudo.




Figura 1: Imagens mamográficas categorizadas.

2. MATERIAIS E MÉTODOS

Para alcançar o objetivo proposto pelo estudo presente, a base de dados foi classificada com diferentes métodos de classificação e com diferentes arquiteturas. A seguir serão apresentados os processos usados, para obter às melhores classificações e serem comparadas entre si.

Na literatura já são encontrados diversos estudos utilizando técnicas de inteligência computacional (IC), com o intuito de auxiliar o diagnóstico do câncer de mama (BILSKA-WOLAK et al., 2005; ANDRIONI et al., 2010).

Como ferramenta de apoio ao desenvolvimento da solução de apoio ao diagnóstico de lesões de mama, foi utilizado o, *software* Weka, desenvolvido em Java na Universidade de Waikato, Nova Zelândia, com um amplo acervo de algoritmos de aprendizado de máquina. A ferramenta está disponível em *software* livre. Nesta pesquisa foi utilizada a versão 3.6.13.

Neste trabalho foi utilizada a base de dados *Image Retrieval in Medical Applications* (IRMA), proveniente de um esforço de cooperação entre o Grupo de Pesquisa de Computação Biomédica do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco e o Departamento de Informática Médica da Universidade Aachen, na Alemanha, que reúne imagens de diversas outras bases de dados, disponíveis para consulta na Internet. A base consiste em regiões de interesse de imagens de mamografias digitais que foram classificadas por radiologistas e redimensionadas para imagens de tamanho 128 x 128 pixels.

Foram utilizadas 2796 imagens, das quais foram extraídos 225 atributos, obtidos por sua vez a partir de estatísticas dos termos da decomposição em wavelets morfológicas. Esse processo decompõe cada imagem em componentes com informação de forma e de orientação. A base está estruturada em 12 classes, organizadas de acordo com a densidade do tecido mamário (I - adiposa, II - fibroglandular, III - densa e IV - extremamente densa), e a classificação BI-RADS (BI-RADS 1 - Inexistente, BI-RADS 2 – Benigna e BI-RADS 5 – Maligna). Embora essas imagens também estejam organizadas de acordo com o tipo de lesão (0 – sem lesão, 4 – massa circunscrita e 5 – massa espículada), essa informação não foi utilizada, visando construir um método de classificação que minimizasse a necessidade de informação clínica adicional.

Posteriormente a essa etapa, escolheu-se os seguintes métodos de classificação para serem verificados e analisados: perceptron multicamadas (*Multi-Layer Perceptron*, MLP), rede de base radial (*Radial Basis Function*, RBF) e máquina de vetor suporte (*Support Vector Machine*, SVM). Os parâmetros dos classificadores foram definidos empiricamente.

A rede MLP foi treinada com taxas de aprendizado de 0,3 e 0,003, momento 0,2 e número de épocas 500. A rede RBF foi treinada com desvio padrão de 0,1. A SVM foi treinada com parâmetro de folga C de 0,1 e *kernel* RBF. Todos os experimentos foram rodados em uma máquina com processador Intel Core i34005U, 1.70GHz, 4GB de RAM, sistema operacional Windows 8 de 64 bits.

3. RESULTADOS E DISCUSSÃO

Na Tabela 1 são apresentados os resultados obtidos nos experimentos computacionais descritos na seção anterior, a saber, a taxa de acerto (%), o índice Kappa, e a área da curva ROC, para os classificadores perceptron multicamadas (MLP), para taxa de aprendizado de 0,3 e 0,03; rede de função de base radial (RBF); e máquina de vetor de suporte (SVM).

A partir dos resultados obtidos expostos na Tabela 1, percebe-se uma significativa melhoria do desempenho da rede MLP quando se muda a taxa de aprendizado de 0,3 para 0,03, produzindo-se um aumento da taxa de acerto de 54,76% para 96,21%, o que é praticamente o dobro do obtido com a taxa de aprendizado inicial. Isso indica que o problema

de classificação das imagens de regiões de interesse de mamografia sofre com mínimos locais e, por conseguinte, a redução da taxa de aprendizado permitiu a redução do passo de atualização dos pesos dos neurônios de forma que a área explorada pode se avizinhar da solução ótima. Isso é corroborado pelos resultados da rede RBF e da SVM. Na rede RBF obteve-se uma taxa de acerto praticamente igual à da MLP com taxa de aprendizado 0,3, o que confirma a hipótese de forte influência de mínimos locais. Já a SVM, por ser construída baseando-se no princípio de buscar otimizar a fronteira de decisão tornando-a equidistante das classes e definindo hiperplanos sobre vetores obtidos diretamente do conjunto de treino (os chamados vetores de suporte), obteve resultado muito próximo daquele da rede MLP: 93,53%. Os resultados do índice Kappa e da área da curva ROC são condizentes com esses resultados comentados.

Tabela 1 – Métodos de classificação e seus respectivos resultados

Classificador	Taxa de Acerto	Índice	Área
	(%)	Kappa	ROC
MLP 0,3**	54.76	0.5064	0.516
MLP 0,03**	96.21	0.9586	0,962
RBF	55.08	0.5099	0,530
SVM	93.53	0.9294	0,937

Legenda: *Número total de instâncias: 2796 em 12 classes **Taxa de Aprendizado

Contudo, quando se compara os tempos de aprendizado das redes MLP com taxa de aprendizado 0,03 e SVM, obtém-se para a primeira em média 2 horas, 51 minutos e 59 segundos, enquanto para a segunda apenas 15,52 segundos. Isso mostra que a SVM tem larga vantagem em termos de tempo de treinamento em relação à MLP. Contudo, a diferença de quase 3% da MLP para a SVM ainda aponta para a MLP como melhor método, uma vez que o processo de treinamento não será feito em tempo real, ou seja, o classificador será treinado uma vez e, obtendo-se os melhores parâmetros, será carregado na solução de apoio ao diagnóstico. Além disso, o custo computacional do processo de decisão, ou seja, da execução das redes, é praticamente o mesmo, podendo ser avaliado em milissegundos.

4. CONCLUSÃO

Diariamente surgem na área da saúde novas informações, métodos e técnicas a serem utilizados nos mais variados espectros, e os sistemas de apoio ao diagnóstico, estão sendo cada vez mais inserido nessa realidade.

O sistema de apoio ao diagnóstico para detecção e classificação do câncer de mama, como o mostrado nesse estudo, é uma inovadora técnica, ainda pouco utilizada, contudo, ela vem ganhando seu espaço, pois a sua utilização pode trazer grandes benefícios, tais como: identificar lesões mamárias no seu estágio inicial, otimizar o tempo de classificação de malignidade das lesões mamárias e impedir procedimentos invasivos desnecessário. Esses benefícios, consequentemente irão ajudar a elevar a taxa de sobrevivência dos indivíduos, visto que até os dias de hoje, o índice de mortalidade do câncer de mama ainda é altíssimo e também ajudará a diminuir o número de mastectomia, uma vez que, esse

procedimento cirúrgico leva a perda da autoestima das mulheres com câncer de mama.

Isto posto, pode-se concluir, que a inovação na saúde, como o uso de sistemas de apoio ao diagnóstico, precisam ser constantemente estimulados e divulgados, pois seu uso leva uma prestação de serviço cada vez mais qualificada e humanizada.

5. AGRADECIMENTOS

A autora agradece a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo financiamento parcial da pesquisa.

6. REFERÊNCIAS

ANDRIONI, V.; GUINGO, B. C.; PEREIRA, W. C. A.; INFANTOSI, A. F. C. “Rede neural artificial para redução de falso-positivos em mamografia detectados por diferença de gaussiana”. *Anais do XII CBEB*. Tiradentes: v.1, 2010.

BILSKA-WOLAK, A. O.; FLOYD, C. E.; LO, J. Y.; BAKER, J. A. Computer Aid for Decision to Biopsy Breast Masses on Mammography: Validation on New Cases. *Academic Radiology*, June, v.12, no. 6, pp. 671-680. 2005.

BONIFÁCIO, F. N. *Comparação entre as Redes Neurais Artificiais MLP, RBF e LVQ na Classificação de Dados*. Monografia da Universidade Estadual do Oeste do Paraná - Campus de Cascavel, 2010. Disponível em: < <http://www.inf.unioeste.br/~tcc/2010/TCC-FernandoNunes.pdf>>, Acesso em: 01 Dez 2015 às 23h22min.

CONEGLIAN, F. M.; GOMES, I. A.; RIBEIRO, S. R. A. Comparação entre classificações com Rede Neural Artificial em diferentes áreas de estudo no Paraná. In: *III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*, Recife - PE, 27-30 de Julho de 2010.

FRIZE, M. et al. Clinical decision support systems for intensive care units: using artificial neural networks. *Medical engineering & physics*. v.23, p.217 – 225, 2001.

INSTITUTO NACIONAL DO CÂNCER. Ministério da Saúde. *Sismama*. Coordenação Geral de Ações Estratégicas Divisão de Apoio à Rede de Atenção Oncológica (DARAO). 2010. Disponível em: <<http://www1.inca.gov.br/inca/Arquivos/Sismama.pdf>>, Acesso em: 24 Out 2016 às 14h57min.

INSTITUTO NACIONAL DO CÂNCER. Ministério da Saúde. *Falando sobre Doenças de Mama*, 2015. Disponível em:< <http://www.inca.gov.br>>, Acesso em 01 NOV 2015 às 22h53min.

KINOSHITA, S. K.; MARQUES, P. M.; ROBERTO, R.; RADON-DOMAIN. Detection of the Nipple and the Pectoral Muscle in Mammograms. *Journal of Digital Imaging*, n. 21, p. 37-49, 2008.

PEREIRA, D. C. *Técnica automática de detecção de nódulo mamário usando informações de multivisão*. Tese de Mestrado do Programa de Pós Graduação em Engenharia de Informação da Universidade Federal do ABC, 2009.

PEREIRA, D.C.; RAMOS, R.P.; NASCIMENTO, M. Z. Segmentation and detection of breast cancer in mammograms combining wavelet analysis and genetic algorithm. *Computer methods and programs in biomedicine II4*, Volume 114, p. 88-101, 2014.