



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Departamento de Engenharia Biomédica
Programa de Pós-Graduação em Engenharia Biomédica

Ingrid Ivonoska Silveira Jatobá

Aplicação do Método ASTERI na Representação de Sinais HD-EMG para Classificação de Gestos Utilizando Algoritmos de Aprendizado de Máquina

Dissertação de Mestrado

Recife, Outubro de 2025



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Departamento de Engenharia Biomédica
Programa de Pós-Graduação em Engenharia Biomédica

Ingrid Ivonoska Silveira Jatobá

Aplicação do Método ASTERI na Representação de Sinais HD-EMG para Classificação de Gestos Utilizando Algoritmos de Aprendizado de Máquina

Dissertação de Mestrado

Proposta de dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco como requisito parcial para obtenção de título de mestre em Engenharia Biomédica.

Prof. Dr. Wellington Pinheiro dos Santos
Orientador

Profª. Dra. Juliana Carneiro Gomes Cassemiro
Coorientadora

Recife, Outubro de 2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Jatobá, Ingrid Ivonoska Silveira.

Aplicação do método ASTERI na representação de sinais HD-EMG para classificação de gestos utilizando algoritmos de aprendizado de máquina / Ingrid Ivonoska Silveira Jatobá. - Recife, 2025.

34f.: il.

Dissertação (Mestrado)- Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Biomédica, 2025.

Orientação: Wellington Pinheiro dos Santos.

Coorientação: Juliana Carneiro Gomes Cassemiro.

1. HD-EMG; 2. Eletromiografia de alta densidade; 3. Aprendizado de máquina; 4. Classificação de gestos; 5. Método ASTERI. I. Santos, Wellington Pinheiro dos. II. Cassemiro, Juliana Carneiro Gomes. III. Título.

UFPE-Biblioteca Central

“Não aceitamos mais o papel de coadjuvantes da história. É tempo de sermos autoras.”

— Bertha Lutz

“Eu quero mudar o mundo. Mas sei que, se eu mudar a mim mesma, já estou contribuindo.”

— Carolina Maria de Jesus

Resumo

As desordens neuromusculares que afetam os membros superiores exigem métodos cada vez mais precisos para a análise e o reconhecimento de movimentos. Nesse cenário, os sinais de eletromiografia de alta densidade (HD-EMG) associados a técnicas de aprendizado de máquina oferecem novas possibilidades para a identificação de padrões musculares. Este trabalho propõe a aplicação do método ASTERI na conversão de sinais HD-EMG em imagens bidimensionais, viabilizando o uso de arquiteturas profundas, como redes neurais convolucionais (CNNs), para extração de características relevantes na classificação de gestos manuais. Foram utilizados dados públicos da base PhysioNet, obtidos de 20 voluntários saudáveis durante a execução de 34 gestos distintos. Após o pré-processamento e a conversão dos sinais em imagens, diferentes classificadores foram avaliados. O modelo SVM com kernel polinomial de grau 1 apresentou o melhor desempenho, alcançando acurácia de 72,14% em validação cruzada e 72,47% no conjunto de teste, com sensibilidade de 0,73 e área sob a curva ROC (AUC) de 0,87. Esses resultados demonstram a eficácia do método ASTERI aliado ao aprendizado de máquina na análise de sinais mioelétricos, ressaltando seu potencial para aplicações futuras em tecnologias assistivas, interfaces cérebro-máquina (BMI) e sistemas de apoio ao diagnóstico neuromuscular.

Palavras-chave: HD-EMG, Eletromiografia de alta densidade, Aprendizado de máquina, Classificação de gestos, Método ASTERI.

Abstract

Neuromuscular disorders affecting the upper limbs require increasingly accurate methods for movement analysis and recognition. In this scenario, high-density electromyography (HD-EMG) signals combined with machine learning techniques offer new possibilities for identifying muscle patterns. This work proposes the application of the ASTERI method to convert HD-EMG signals into two-dimensional images, enabling the use of deep architectures, such as convolutional neural networks (CNNs), to extract relevant features for classifying hand gestures. Public data from the PhysioNet database, obtained from 20 healthy volunteers performing 34 different gestures, were used. After preprocessing and conversion of the signals into images, different classifiers were evaluated. The SVM model with a degree-1 polynomial kernel showed the best performance, achieving an accuracy of 72.14% in cross-validation and 72.47% in the test set, with a sensitivity of 0.73 and an area under the ROC curve (AUC) of 0.87. These results demonstrate the effectiveness of the ASTERI method combined with machine learning in the analysis of myoelectric signals, highlighting its potential for future applications in assistive technologies, brain-machine interfaces (BMI), and neuromuscular diagnostic support systems.

Keywords: HD-EMG, High-density electromyography, Machine learning, Gesture classification, ASTERI method.

Sumário

Índice de Figuras	vi
Índice de Tabelas	viii
1 Introdução	1
1.1 Motivação e justificativa	1
1.2 Objetivos	3
1.3 Organização do trabalho	3
2 Fundamentação teórica	4
2.1 Eletromiografia de Alta densidade	4
2.2 Princípios de aprendizado de máquina	5
2.2.1 Redes Neurais Convolucionais para extração de atributos	6
2.2.2 Classificadores	8
2.3 Método de geração de imagens ASTERI	9
2.4 WEKA	10
3 Metodologia	12
3.1 Proposta	12
3.1.1 Base de dados	12
3.1.2 Experimentos propostos	14
3.2 Métricas de avaliação	19
4 Resultados	21
4.1 Resultados	21
4.1.1 Conjunto de Treinamento	21
4.1.2 Conjunto de Teste	22
4.2 Discussões	24
5 Conclusão	27
5.1 Dificuldades Encontradas	28
5.2 Contribuições	28
5.3 Trabalhos Futuros	29
Referências	30

Índice de Figuras

Figura 1 – Exemplo de posicionamento dos eletrodos de um aparelho de HD EMG de 192 eletrodos tida por Pan et al. (2015)[1].	4
Figura 2 – Representação esquemática da arquitetura VGG16, contendo 13 camadas convolucionais com filtros 3×3, camadas de pooling 2×2 e três camadas totalmente conectadas. Imagem gerada por inteligência artificial (<i>ChatGPT</i>), a partir da descrição da autora.	8
Figura 3 – Exemplo esquemático do funcionamento do método ASTERI, criado pela autora, ilustrando a conversão de sinais de HD-EMG em imagens bidimensionais por meio da técnica de retroprojeção, possibilitando a extração de características com arquiteturas profundas.	10
Figura 4 – Captura de tela da interface do software Weka, realizada pela autora, ilustrando o ambiente utilizado para experimentação e avaliação dos classificadores de aprendizado de máquina	11
Figura 5 – Conjunto de 34 gestos pré-definidos analisados no estudo, representando uma ampla variedade de movimentos utilizados na avaliação neuromuscular. . . .	13
Figura 6 – Posicionamento dos eletrodos durante a coleta de dados.	14
Figura 7 – Diagrama da metodologia proposta, onde os sinais de eletromiografia de alta densidade (HD-EMG), obtidos a partir do banco de dados de Jiang et al., foram convertidos em imagens utilizando o método ASTERI, seguida pela extração de atributos e aplicação dos classificadores para avaliação de desempenho.	15
Figura 8 – Conjunto de quatro gestos utilizados no estudo para classificação de sinais HD-EMG, representando movimentos distintos e funcionalmente relevantes: (1) Extensão do polegar; (6) Flexão do punho; (7) Extensão do punho; (10) Flexão ulnar do punho.	16
Figura 9 – Conversão de sinal de eletromiografia de superfície de alta densidade (HD-EMG) em imagem, utilizando o método ASTERI. A imagem foi gerada pela autora com o auxílio do software Weka, representando a reorganização espacial e temporal do sinal em uma estrutura adequada para análise por redes neurais convolucionais.	18

Figura 10 – Distribuição de acurácia por classificador na etapa de treinamento e validação, exibindo a mediana, quartis e variabilidade dos resultados obtidos.	22
---	----

Índice de Tabelas

Tabela 1 – Resultados obtidos na etapa de treinamento e validação do conjunto de dados, apresentando as métricas de desempenho dos diferentes classificadores testados.	21
Tabela 2 – Desempenho do classificador SVM com kernel polinomial de grau 1 na tarefa de classificação dos gestos de mão na etapa de testes.	23
Tabela 3 – Matriz de confusão do classificador SVM com <i>kernel polinomial</i> de grau 1, evidenciando os acertos e erros na classificação das quatro classes de gestos.	23
Tabela 4 – Produções acadêmicas e reconhecimentos obtidos em detrimento desta pesquisa	28

Agradecimentos

Quando decidi me inscrever no mestrado, ainda grávida do meu primeiro filho, acreditava que bastaria minha força de vontade para conciliar maternidade, carreira e vida acadêmica. O que eu não sabia é que a maternidade seria, ao mesmo tempo, meu maior desafio e minha maior fonte de potência.

Passei pela seleção e fui acolhida por uma turma extraordinária, que me recebeu com afeto e empatia desde o primeiro dia. A cada etapa, encontrei apoio, paciência e incentivo. Meu carinho especial aos colegas Adrielly, Carla, Renê e Alisson, que me acompanharam com generosidade ao longo dessa caminhada.

Sou profundamente grata aos professores que foram mais do que orientadores: foram faróis em momentos de dúvida e inspiração constante nos momentos de criação. Aos meus orientadores, Wellington e Juliana, obrigada por acreditarem em mim mesmo quando eu mesma hesitava. Aos professores Gisele, Cristine e Neferson, minha sincera admiração e gratidão por cada palavra de incentivo e aprendizado compartilhado.

Nada disso teria sido possível sem o alicerce da minha família. Ao meu pai Robson, aos meus irmãos Vanessa e Henrique e ao meu marido Ossi, obrigada por segurarem minha mão nos momentos em que pensei em desistir e por sempre me lembrarem de quem eu sou. Vocês foram abrigo e impulso.

Durante essa jornada, apresentei trabalhos com meu filho no colo, escrevi artigos nas madrugadas, tornei-me autora de capítulo de livro, recebi menção honrosa em congresso e estou, agora, prestes a conquistar o título de mestre. Tudo isso é fruto de coragem, amor e rede de apoio.

A todas as pessoas que, direta ou indiretamente, me ajudaram a construir essa trajetória, o meu mais sincero e emocionado obrigada.

Capítulo 1

Introdução

Este capítulo explora os fundamentos que justificam o desenvolvimento deste estudo, destacando a relevância das tecnologias modernas de processamento de sinais biomédicos. Enfatiza-se o uso de sinais de eletromiografia de alta densidade (HD-EMG) combinados a técnicas de aprendizado de máquina, com foco na representação e classificação de gestos manuais. Além disso, são apresentados o objetivo geral e específicos do trabalho, evidenciando sua importância científica e clínica.

1.1 Motivação e justificativa

A reabilitação desempenha um papel crucial na recuperação de pacientes com disfunções motoras, abrangendo não apenas a formulação de um novo projeto de vida, mas também a retomada de atividades cotidianas e a conscientização sobre as limitações impostas pela condição. Esses fatores contribuem significativamente para a reconquista da autoestima e a melhoria da qualidade de vida, aspectos fundamentais para a reintegração social e o bem-estar emocional dos pacientes [2].

De acordo com dados da Organização Mundial da Saúde (OMS), aproximadamente 15 em cada 100 indivíduos apresentam alguma forma de disfunção física ou necessidade especial, e de 2% a 4% enfrentam complicações graves que exigem cuidados extensivos. As projeções da OMS para 2050 indicam que essas condições poderão impactar até 38% da população mundial, o que reforça a importância de estratégias inovadoras e eficazes na reabilitação [3]. Esse cenário destaca a urgência em desenvolver abordagens avançadas e personalizadas, capazes de atender à crescente demanda por soluções tecnológicas.

Nesse contexto, a eletromiografia de alta densidade (HD-EMG) surge como uma ferramenta essencial na avaliação motora, permitindo análises detalhadas de sinais musculares e a identificação de padrões associados a diferentes gestos. Embora este estudo tenha como foco a análise metodológica desses sinais em bases públicas de dados, é importante ressaltar que tais metodologias podem futuramente apoiar aplicações clínicas, como a personalização de

terapias e o desenvolvimento de próteses mais eficazes e responsivas [4, 5]. Estudos recentes, por exemplo, demonstram que a HD-EMG tem sido empregada com sucesso para avaliar a coordenação muscular em pacientes pós-AVC, fornecendo dados objetivos que auxiliam na personalização da reabilitação [6].

Apesar dos avanços, ainda existem desafios significativos na aplicação prática de tecnologias baseadas em EMG, especialmente em próteses mioelétricas. Barreiras como custos elevados, limitações de robustez e amplitude de movimentos, além de dificuldades na operação intuitiva, ainda restringem a adoção dessas soluções em larga escala [7, 8, 9]. Nesse sentido, a avaliação de métodos computacionais robustos para análise de sinais de EMG, como os utilizados neste trabalho, pode contribuir para superar algumas dessas barreiras em estudos futuros.

A motivação para este estudo é explorar e validar uma metodologia inovadora que integre sinais de HD-EMG e algoritmos de aprendizado de máquina para o reconhecimento de gestos. A escolha de técnicas como a conversão de sinais em imagens por meio do método ASTERI e a aplicação de classificadores de aprendizado profundo reflete a busca por soluções capazes de ampliar a precisão da análise de movimentos. Embora o escopo atual seja computacional, os resultados obtidos podem fornecer subsídios valiosos para o avanço de aplicações em reabilitação, próteses e dispositivos médicos[10, 11, 12, 13].

A combinação de HD-EMG e aprendizado de máquina oferece a perspectiva de superar limitações dos métodos tradicionais, proporcionando *insights* mais precisos sobre a ativação muscular e suas implicações funcionais. Isso abre caminho para tecnologias mais acessíveis e eficazes, capazes de impactar positivamente a qualidade de vida dos pacientes [14, 15, 16]. Além disso, reforça a importância de se construir protocolos de análise que, ainda que desenvolvidos em ambiente computacional, mantenham relevância para a prática clínica.

Portanto, embora este trabalho se concentre na análise metodológica e no reconhecimento de gestos a partir de sinais de HD-EMG, sua justificativa está diretamente ligada ao potencial impacto em aplicações futuras na reabilitação motora.

Embora este estudo não tenha realizado experimentos diretamente em contextos de reabilitação, é importante destacar que os resultados obtidos com o método ASTERI aplicado aos sinais de HD-EMG possuem potencial translacional para essa área. Em especial, o reconhecimento automático de gestos pode futuramente contribuir para o desenvolvimento de próteses de controle mioelétrico mais responsivas e para o aprimoramento de interfaces cérebro-máquina aplicadas em pacientes com limitações motoras mas também promovam autonomia e reintegração social para milhões de pessoas afetadas por estas disfunções [17, 9]. Assim, a pesquisa aqui apresentada deve ser entendida como uma contribuição metodológica que pode servir de base para aplicações clínicas posteriores.

1.2 Objetivos

Esse estudo visa avaliar a aplicação do método ASTERI na conversão de sinais de HD-EMG em imagens para classificação de gestos manuais por meio de algoritmos de aprendizado de máquina.

Para alcançar esse objetivo, faz-se necessário elencar alguns objetivos específicos, são eles:

1. Realizar a conversão de sinais de HD-EMG em imagens por meio do método ASTERI;
2. Extrair atributos dessas imagens utilizando a arquitetura de rede neural convolucional VGG16;
3. Aplicar e comparar o desempenho de classificadores de aprendizado de máquina (SVM, Random Forest, Naive Bayes e Bayes Network) na tarefa de classificação de gestos manuais;
4. Avaliar as métricas de acurácia, índice kappa, sensibilidade, especificidade e área sob a curva ROC para os modelos testados;
5. Identificar o(s) classificador(es) mais adequados para o reconhecimento de gestos a partir dos sinais HD-EMG processados pelo método ASTERI.

1.3 Organização do trabalho

Este trabalho está estruturado da seguinte forma: no capítulo 2 encontra-se a Fundamentação Teórica que apresenta os conceitos fundamentais que sustentam os principais temas abordados na pesquisa, incluindo Eletromiografia de Alta Densidade (HD-EMG), princípios de aprendizado de máquina, redes neurais convolucionais para extração de atributos, classificadores e o método de geração de imagens ASTERI. A seguir, no capítulo 3, vem a Metodologia na qual é detalhado o escopo metodológico da pesquisa, destacando as bases de dados utilizadas, o experimento proposto e as métricas empregadas para avaliar o desempenho dos classificadores. No capítulo 4, encontramos os Resultados, onde são apresentados e discutidos os achados obtidos nos experimentos realizados, com foco na eficácia das abordagens propostas. Por fim, no capítulo 5, temos as Conclusões das implicações do desempenho obtido com este estudo.

Capítulo 2

Fundamentação teórica

2.1 Eletromiografia de Alta densidade

A Eletromiografia de Alta Densidade (HD-EMG) é uma técnica avançada que permite o registro detalhado da atividade elétrica muscular por meio de matrizes de múltiplos eletrodos posicionados na superfície da pele, um exemplo de aplicação desses eletrodos pode ser visto na Figura 1. Diferentemente da eletromiografia tradicional, que utiliza um número limitado de eletrodos, a HD-EMG emprega uma alta densidade de sensores, proporcionando uma resolução espacial superior na detecção dos sinais elétricos gerados durante a contração muscular. Essa abordagem possibilita uma análise mais precisa da função neuromuscular, sendo especialmente útil em pesquisas que investigam a coordenação muscular e o controle motor [18].




Figura 1 – Exemplo de posicionamento dos eletrodos de um aparelho de HD EMG de 192 eletrodos tida por Pan et al. (2015)[1].

A coleta dos sinais em HD-EMG envolve a preparação adequada da pele, garantindo baixa impedância para otimizar a qualidade do sinal. Os eletrodos são dispostos em matrizes que cobrem a área muscular de interesse, permitindo a captura simultânea de dados de múltiplas regiões do músculo. Durante a aquisição, os sinais elétricos são amplificados e digitalizados para posterior análise. É fundamental considerar fatores como a distância entre os eletrodos e a

padronização dos procedimentos de coleta para assegurar a reprodutibilidade e a confiabilidade dos dados obtidos [19].

As aplicações da HD-EMG são vastas, abrangendo desde o estudo de distúrbios neuromusculares até o desenvolvimento de interfaces homem-máquina. Na área clínica, essa técnica tem sido utilizada para avaliar a fadiga muscular, diagnosticar doenças neuromusculares e monitorar a reabilitação de pacientes. Além disso, a HD-EMG desempenha um papel crucial no aprimoramento do controle de próteses mioelétricas, permitindo que indivíduos com amputações controlem dispositivos protéticos de forma mais intuitiva e eficiente, graças à detecção precisa dos sinais musculares residuais[20].

2.2 Princípios de aprendizado de máquina

O aprendizado de máquina (*Machine learning* - ML) é um subcampo da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos que permitem aos computadores aprender a partir de dados. Em vez de seguir instruções específicas para executar uma tarefa, os sistemas de aprendizado de máquina são capazes de reconhecer padrões nos dados e tomar decisões ou fazer previsões com base nesses padrões [21].

Existem três categorias principais de algoritmos de aprendizado de máquina: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. No aprendizado supervisionado, o algoritmo é treinado em um conjunto de dados que inclui exemplos de entrada e saída esperada. No aprendizado não supervisionado, o algoritmo é treinado em dados não rotulados e é deixado para descobrir padrões por conta própria. O aprendizado por reforço envolve o algoritmo aprendendo através da experiência, ajustando suas ações com base nos resultados obtidos [22].

O aprendizado de máquina tem sido amplamente aplicado em diversos setores devido à sua capacidade de processar grandes volumes de dados e descobrir padrões complexos. Como exemplos de sua utilização temos:

1. Na indústria financeira: são usados para detectar fraudes, analisar o risco de crédito e realizar negociações automatizadas [23];
2. No setor de marketing: é utilizado para segmentação de clientes, recomendação de produtos e análise de sentimentos em redes sociais [24];
3. No campo da manufatura: técnicas de aprendizado de máquina são empregadas para prever falhas de máquinas, otimizar processos de produção e melhorar a manutenção preditiva [25];
4. No campo da biologia e bioinformática: o aprendizado de máquina tem sido essencial para a análise de sequências de DNA, predição de estruturas de proteínas e compreensão de

redes de interação molecular [26];

5. Na área de transportes: os algoritmos de ML são fundamentais para o desenvolvimento de veículos autônomos, otimização de rotas e previsão de tráfego [21].

No entanto, uma das áreas mais promissoras para a aplicação do aprendizado de máquina é a saúde. Algoritmos de aprendizado de máquina estão transformando a forma como a medicina é praticada e melhorando a qualidade do atendimento aos pacientes. Algumas das principais aplicações incluem:

1. Diagnóstico de Doenças: Algoritmos de aprendizado de máquina podem analisar grandes volumes de dados médicos para ajudar a diagnosticar doenças com maior precisão e rapidez. Por exemplo, o diagnóstico de doenças cardíacas e câncer pode ser aprimorado através do uso de ML [22];
2. Previsão de Doenças: ML pode ser usado para prever a ocorrência de doenças, permitindo intervenções preventivas mais eficazes. Por exemplo, a previsão de diabetes e doenças hepáticas pode ser feita com base em dados históricos e comportamentais dos pacientes [24];
3. Personalização do Tratamento: O aprendizado de máquina permite a personalização dos tratamentos médicos, ajustando as terapias com base nas características individuais dos pacientes. Isso pode levar a melhores resultados e uma recuperação mais rápida [23];
4. Descoberta de Novos Medicamentos: ML pode acelerar o processo de descoberta de novos medicamentos, analisando grandes conjuntos de dados químicos e biológicos para identificar novos compostos promissores [26];
5. Análise de Imagens Médicas: Algoritmos de ML podem analisar imagens médicas, como radiografias e ressonâncias magnéticas, para detectar anomalias e ajudar no diagnóstico precoce de doenças [22].

O aprendizado de máquina tem revolucionado diversas áreas do conhecimento, e suas aplicações na saúde são particularmente notáveis. Desde o diagnóstico precoce de doenças até a personalização de tratamentos, os algoritmos de ML estão transformando a prática médica e oferecendo novas oportunidades para melhorar a qualidade de vida dos pacientes. Com o contínuo avanço da tecnologia e o aumento da disponibilidade de dados, o aprendizado de máquina promete trazer ainda mais inovações para a medicina e muitas outras áreas.

2.2.1 Redes Neurais Convolucionais para extração de atributos

As redes neurais convolucionais (CNNs) são um tipo de modelo de aprendizado profundo especializado em processar dados que possuem uma estrutura em grade, como imagens. Elas são

compostas por camadas de convolução, pooling e totalmente conectadas, sendo muito utilizadas em tarefas de reconhecimento de padrões visuais [27].

As redes neurais artificiais são modelos computacionais inspirados no funcionamento do cérebro humano, compostas por camadas de neurônios artificiais que processam informações para realizar tarefas como classificação, regressão e reconhecimento de padrões [28]. Elas são amplamente utilizadas em diversas áreas, como visão computacional, processamento de linguagem natural e sistemas de recomendação [29].

Uma rede neural artificial é composta por três tipos principais de camadas: a camada de entrada, a camada oculta e a camada de saída. A camada de entrada recebe os dados brutos, a camada oculta processa as informações através de uma série de neurônios interconectados, e a camada de saída fornece o resultado final. Cada neurônio na camada oculta aplica uma função de ativação aos dados recebidos e gera uma saída que é passada para os neurônios da próxima camada[28].

As redes neurais convolucionais (CNNs) são um tipo especial de rede neural artificial, desenvolvidas para lidar com dados estruturados como imagens. Elas têm se mostrado extremamente eficazes em tarefas de visão computacional devido à sua capacidade de capturar hierarquias espaciais complexas em imagens. As CNNs são compostas por várias camadas, incluindo camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas. As camadas convolucionais aplicam filtros convolucionais para extrair características de baixo nível, como bordas e texturas, enquanto as camadas de *pooling* reduzem a dimensionalidade dos dados, mantendo as informações mais importantes. As camadas totalmente conectadas, por fim, utilizam essas características extraídas para realizar a classificação ou regressão [29].

Uma das CNNs mais conhecidas e utilizadas, temos a VGG16. Ela foi proposta pelos pesquisadores do *Visual Geometry Group* da Universidade de *Oxford*. A arquitetura VGG16 se destaca pela sua simplicidade e profundidade, utilizando várias camadas convolucionais empilhadas com filtros de tamanho 3x3, seguidas por camadas de *pooling* e camadas totalmente conectadas [30].

A arquitetura da VGG16, ilustrada na Figura 2, funciona da seguinte forma:

- Camadas Convolucionais: A VGG16 possui 13 camadas convolucionais que aplicam filtros 3x3 para extrair características de diferentes níveis de abstração;
- Camadas de *Pooling*: Após cada bloco de camadas convolucionais, uma camada de max-pooling 2x2 é aplicada para reduzir a dimensionalidade dos mapas de características;
- Camadas Totalmente Conectadas: No final, a rede possui três camadas totalmente conectadas, onde a última camada possui uma função softmax para a classificação [30].




Figura 2 – Representação esquemática da arquitetura VGG16, contendo 13 camadas convolucionais com filtros 3×3 , camadas de pooling 2×2 e três camadas totalmente conectadas. Imagem gerada por inteligência artificial (*ChatGPT*), a partir da descrição da autora.

A profundidade da VGG16 permite que a rede capture detalhes finos das imagens, tornando-a ideal para tarefas como reconhecimento de objetos, classificação de imagens e segmentação semântica.

As CNNs, incluindo a VGG16, são amplamente utilizadas para a extração de atributos em várias aplicações de visão computacional. Na área da saúde, essas redes são empregadas para analisar imagens médicas, como radiografias, tomografias e ressonâncias magnéticas, para detectar anomalias e ajudar no diagnóstico de doenças [22]. As características extraídas por essas redes podem ser usadas para treinar modelos de classificação que identificam condições médicas específicas com alta precisão [24].

Além disso, a VGG16 tem sido aplicada na análise de dados histopatológicos para a detecção de câncer, onde a rede pode identificar padrões sutis nas imagens de tecidos que indicam a presença de células cancerígenas [26].

2.2.2 Classificadores

Os modelos de classificação são fundamentais no aprendizado de máquina, permitindo a categorização de dados em diferentes classes com base em suas características. A seguir, apresentamos uma visão detalhada de três modelos amplamente utilizados: *Random Forest*, *Support Vector Machine (SVM)* e *Redes Bayesianas*.

O *Random Forest* é um método baseado em florestas de decisão, que utiliza uma combinação de múltiplas árvores de decisão para melhorar os resultados e reduzir erros. Essa abordagem busca mitigar o problema de *overfitting*, que ocorre quando o modelo aprende padrões específicos do conjunto de treino, resultando em baixo desempenho ao lidar com novos dados [31]. Cada árvore de decisão é construída com uma amostra selecionada do conjunto de dados e a decisão final é tomada com base na maioria das árvores específicas, o que contribui para maior robustez e generalização. Além disso, o *Random Forest* é amplamente utilizado em áreas como análise

biomédica e previsão de acidentes de trânsito, pois consegue selecionar as características mais relevantes de bases de dados complexos [31].

O *Support Vector Machine (SVM)* é um algoritmo que busca encontrar o hiperplano ótimo, uma fronteira de decisão que separa as classes de dados com a maior margem possível entre elas, ou seja, a maior distância entre os pontos mais próximos de classes opostas. Essa maximização da margem reduz a probabilidade de erro de classificação em novos exemplos [31]. Para lidar com dados não linearmente separáveis, o SVM utiliza funções de kernel, que transformam os dados para um espaço dimensional mais elevado, tornando-os linearmente separáveis. Entre os kernels mais utilizados estão as funções de base linear, polinomial e radial (RBF), sendo esta última eficaz em identificar padrões complexos. O SVM tem aplicações diversas, como a classificação de imagens médicas e a identificação de espécies biológicas, dada sua capacidade de lidar com conjuntos de dados complexos e de alta dimensionalidade [32].

As Redes Bayesianas são modelos probabilísticos que representam a relação entre variáveis de forma hierárquica, organizando as informações em uma estrutura chamada gráfico direcionado sem ciclos. Essa representação descreve dependências condicionais entre variações, facilitando a modelagem de incertezas e a realização de inferências, mesmo em bases de dados incompletas [31]. Este modelo é frequentemente utilizado em sistemas de suporte à decisão clínica, pois permite a incorporação de conhecimento prévio e facilita a interpretação de resultados. Estudos recentes demonstraram sua eficiência em contextos como previsão de complicações médicas e segurança viária, devido à sua habilidade em lidar com dados escassos ou incompletos [33].

A escolha entre esses modelos deve considerar fatores como a complexidade dos dados, a necessidade de interpretabilidade e o desempenho computacional desejado. Cada modelo oferece vantagens específicas para diferentes cenários de classificação, desde diagnósticos clínicos até análises preditivas de sinais fisiológicos.

2.3 Método de geração de imagens ASTERI

O método *ASTERI* foi desenvolvido para representar janelas de sinais de eletroencefalografia (EEG) na forma de imagens, permitindo a aplicação de redes neurais convolucionais (CNNs) em sistemas inteligentes baseados em EEG. Essa abordagem utiliza pseudo-sinogramas, que são janelas de sinais pré-processados onde o algoritmo de reconstrução por retroprojeção é aplicado [34]. A retroprojeção, originalmente empregada na reconstrução de imagens de tomografia computadorizada, gera representações gráficas estilizadas com padrões similares a estrelas. O principal objetivo dessa metodologia é facilitar o uso de arquiteturas profundas na análise de sinais fisiológicos. O *ASTERI* mostrou-se eficaz ao traduzir os sinais temporais em representações visuais detalhadas, otimizando a análise de redes neurais pré-treinadas como VGG16 e LeNet, tem sido testado anteriormente em sinais de EEG para classificação de imagética motora

[34]. Um breve exemplo de como o método funciona pode ser visto na Figura 3



Figura 3 – Exemplo esquemático do funcionamento do método ASTERI, criado pela autora, ilustrando a conversão de sinais de HD-EMG em imagens bidimensionais por meio da técnica de retroprojeção, possibilitando a extração de características com arquiteturas profundas.

2.4 WEKA

O WEKA (Waikato Environment for Knowledge Analysis) é uma plataforma de software de código aberto, amplamente reconhecida e utilizada em pesquisa acadêmica para aprendizado de máquina e mineração de dados [35]. Essa estrutura unificada permite que os usuários executem e comparem de maneira eficiente uma vasta gama de algoritmos de classificação, regressão e agrupamento, solidificando sua posição como um recurso fundamental na análise de dados.

A principal utilidade do WEKA reside em seu extenso repositório de algoritmos e funcionalidades de suporte. A plataforma conta com implementações robustas de algoritmos supervisionados e não supervisionados, como as Máquinas de Vetores de Suporte (SVM), Árvores de Decisão e k-means, permitindo a exploração de diversas abordagens para um mesmo problema [36]. Além disso, o WEKA simplifica tarefas complexas como a seleção de atributos, que é crucial para otimizar o desempenho de modelos em bases de dados de alta dimensionalidade. Sua capacidade de gerar relatórios de desempenho detalhados e matrizes de confusão o torna uma escolha preferencial para a avaliação e a validação de experimentos, proporcionando resultados estatisticamente confiáveis para a comunidade científica.



Figura 4 – Captura de tela da interface do software Weka, realizada pela autora, ilustrando o ambiente utilizado para experimentação e avaliação dos classificadores de aprendizado de máquina

O foco deste trabalho reside na avaliação metodológica de uma abordagem inovadora para a classificação de gestos, utilizando a representação de sinais de eletromiografia de alta densidade (HD-EMG) através do método ASTERI. Esta integração, que permite a aplicação de poderosas arquiteturas de aprendizado profundo, como a VGG16, demonstra a robustez da fundamentação teórica e metodológica apresentada. As tecnologias exploradas neste estudo, ao converterem dados complexos de séries temporais em um formato visualmente interpretável para redes neurais, abrem um vasto leque de potencialidades para o futuro. Sua aplicação vai desde o avanço na interface humano-máquina, passando pelo desenvolvimento de próteses mioelétricas mais intuitivas, até sistemas de controle de dispositivos assistivos, solidificando a relevância desta pesquisa para o campo da Engenharia Biomédica.

Capítulo 3

Metodologia

3.1 Proposta

A reabilitação de distúrbios neuromusculares em membros superiores é um desafio clínico importante, que afeta a qualidade de vida e a independência funcional dos pacientes. A eletroneuromiografia de alta densidade e inteligência artificial têm sido cada vez mais utilizadas como ferramentas complementares para a avaliação e o tratamento desses pacientes. No entanto, ainda existem lacunas no conhecimento sobre a eficácia, segurança e a aplicabilidade dessas técnicas na prática clínica.

Este trabalho faz parte de um estudo mais amplo denominado "Projeto de Pesquisa Monitorando e entregando uma neuroreabilitação personalizada da mão através de atividades virtuais controladas pelo comando neural" que visa gerar uma base de dados própria, nacional, para análise de gestos de membros superiores utilizando HD-EMG. Já o presente estudo tem como propósito analisar o desempenho de algoritmos de aprendizado de máquina supervisionado por meio de experimentos voltados à classificação de gestos manuais obtidos de sinais de eletromiografia de alta densidade de um conjunto de dados, de acesso aberto, desenvolvido por de Jiang et al. (2023)[37].

3.1.1 Base de dados

O banco de dados desenvolvido por Jiang et al. (2023)[37] constitui uma fonte abrangente de sinais de eletromiografia de superfície de alta densidade (HD-EMG), disponibilizado na plataforma *Physionet* para apoiar pesquisas avançadas em reconhecimento de padrões de gestos e reabilitação neuromuscular. O conjunto foi construído a partir de experimentos com 20 participantes saudáveis, que realizaram duas sessões em dias distintos, seguindo o mesmo protocolo experimental para todos os envolvidos. Essa padronização assegura a validade dos dados e sua aplicabilidade em diferentes contextos e perfis musculares.

O banco contém registros de 256 canais de HD-EMG adquiridos durante a execução de

34 gestos predefinidos, mostrados na Figura 5. Esses gestos incluem desde atividades funcionais comuns até movimentos específicos utilizados na avaliação neuromuscular, oferecendo uma base diversificada de padrões de ativação muscular.



Figura 5 – Conjunto de 34 gestos pré-definidos analisados no estudo, representando uma ampla variedade de movimentos utilizados na avaliação neuromuscular.

Os sinais foram coletados a uma taxa de amostragem de 2048 Hz, enquanto os registros de força de verdade fundamental foram obtidos a 100 Hz. Para garantir precisão e detalhamento, utilizou-se uma matriz de eletrodos de alta densidade posicionada em regiões específicas do membro superior, cobrindo áreas musculares de interesse com alto número de canais. Esse arranjo permite uma resolução espacial ampliada, fundamental para identificar variações de ativação em gestos complexos (Figura 6).




Figura 6 – Posicionamento dos eletrodos durante a coleta de dados.

As gravações foram realizadas em ambiente controlado, com orientações padronizadas para garantir uniformidade entre os participantes. Em cada sessão, os gestos eram executados duas vezes, incluindo uma fase dinâmica de 1 segundo (transição do estado de repouso para o gesto) e uma fase de manutenção de 4 segundos (gesto sustentado). Esse protocolo assegurou dados consistentes, permitindo análises de variabilidade intra e inter-sujeitos.

Cada gesto foi documentado com anotações detalhadas sobre o tipo de movimento, posição dos eletrodos, sequência de aquisição e características individuais dos participantes, como idade, gênero e perfil de atividade física. Essa riqueza de informações torna o banco de dados especialmente útil para treinar e avaliar algoritmos de aprendizado de máquina, bem como para aplicações em diferentes linhas de pesquisa.

O acesso aberto do banco na plataforma *Physionet* promove a reprodutibilidade científica, permitindo comparações entre estudos e facilitando a exploração de novas abordagens. Além disso, o conjunto é acompanhado de ferramentas de software para gravação e manipulação dos sinais, padronizando o pré-processamento e reforçando sua utilidade para a comunidade de pesquisa.

3.1.2 Experimentos propostos

Nesta seção, apresentamos a análise de desempenho dos algoritmos de aprendizado de máquina utilizados para a classificação de gestos de mão com base em sinais de eletromiografia

de alta densidade (HD-EMG) do banco de dados de Jiang et al. (2023)[37]. Nesse contexto, a Figura 7 apresenta o modelo sugerido, com suas etapas, conversão dos dados e a extração de atributos.

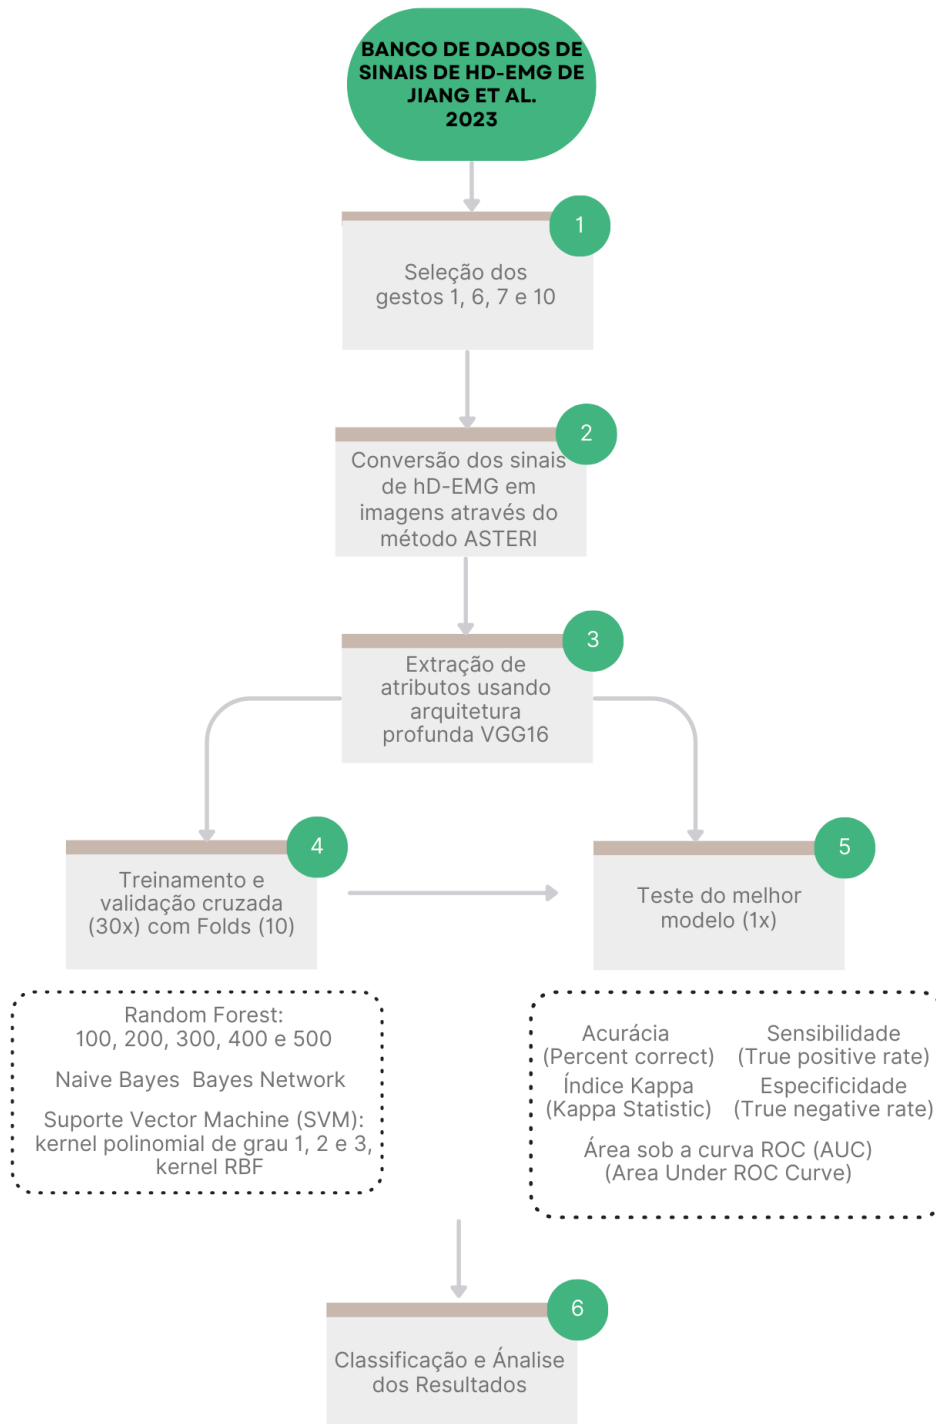


Figura 7 – Diagrama da metodologia proposta, onde os sinais de eletromiografia de alta densidade (HD-EMG), obtidos a partir do banco de dados de Jiang et al., foram convertidos em imagens utilizando o método ASTERI, seguida pela extração de atributos e aplicação dos classificadores para avaliação de desempenho.

Para este estudo foram selecionados os gestos os 1, 6, 7 e 10 que podem ser vistos na Figura 8. A seleção dos gestos foi realizada considerando critérios anatômicos, funcionais e metodológicos, bem como sua relevância em atividades da vida diária.




Figura 8 – Conjunto de quatro gestos utilizados no estudo para classificação de sinais HD-EMG, representando movimentos distintos e funcionalmente relevantes: (1) Extensão do polegar; (6) Flexão do punho; (7) Extensão do punho; (10) Flexão ulnar do punho.

- Gesto 1 – Extensão do polegar (“Legal”): representa um movimento isolado e bem definido do polegar, envolvendo músculos específicos como o extensor curto e o extensor longo do polegar. Além da clareza na ativação muscular, é um gesto amplamente reconhecido no cotidiano como sinal positivo, de aprovação ou confirmação (“joinha”);
- Gesto 6 – Flexão do punho (“Punho para baixo”): envolve principalmente os flexores do antebraço (flexor radial do carpo e flexor ulnar do carpo). Esse movimento é comum em tarefas como digitar no teclado, apoiar a mão sobre uma mesa ou segurar objetos voltados para baixo, o que reforça sua importância funcional.
- Gesto 7 – Extensão do punho (“Punho para cima”): ativa o grupo dos extensores do punho (extensor radial longo e curto do carpo, extensor ulnar do carpo). É um movimento associado a gestos cotidianos como afastar a mão para indicar recusa, levantar a palma para pedir “pare” ou simplesmente apoiar o dorso da mão em superfícies. Junto com a

flexão, representa movimentos antagônicos fundamentais para avaliação da precisão do modelo.

- Gesto 10 – Flexão ulnar do punho (“Punho para o lado do dedo mínimo”): ativa predominantemente o flexor ulnar do carpo e, em menor grau, o extensor ulnar. Esse gesto ocorre em situações práticas como segurar um copo e incliná-lo, tocar violão ou apoiar objetos na lateral da mão, o que demonstra sua relevância funcional.

De forma geral, esses quatro gestos foram escolhidos por representarem movimentos básicos, distintos e com ampla aplicabilidade no dia a dia. Além disso, ativam diferentes grupos musculares do antebraço, o que contribui para a diversidade dos sinais de HD-EMG e fortalece a robustez da análise de classificação.

Visando à aplicação de arquiteturas profundas, os sinais de HD-EMG foram convertidos em imagens por meio do método ASTERI, exemplificado na Figura 9. O método ASTERI baseia-se na retroprojeção, originalmente utilizada na reconstrução de imagens de tomografia computadorizada, para representar sinais de EEG em formato de imagens. Esse método já demonstrou resultados promissores quando aplicado a sinais de eletroencefalografia, reforçando seu potencial também em dados de EMG [34].

A partir das imagens ASTERI, foram extraídos 4097 atributos utilizando a arquitetura profunda VGG16, pré-treinada com a base de dados *ImageNet*. Em seguida, a base de dados foi subdividida em dois conjuntos: treino/validação 80% das instâncias e teste 20%, possibilitando a avaliação robusta do desempenho dos classificadores.




Figura 9 – Conversão de sinal de eletromiografia de superfície de alta densidade (HD-EMG) em imagem, utilizando o método ASTERI. A imagem foi gerada pela autora com o auxílio do software Weka, representando a reorganização espacial e temporal do sinal em uma estrutura adequada para análise por redes neurais convolucionais.

Para a análise comparativa, foram empregados diferentes classificadores de aprendizado de máquina disponíveis no Weka. O algoritmo *Random Forest* foi avaliado em cinco configurações, variando entre 100, 200, 300, 400 e 500 árvores, a fim de observar o impacto da quantidade de árvores no desempenho do modelo. Além disso, foram testados os algoritmos *Naive Bayes* e *Bayes Network*, ambos em suas configurações padrão, bem como o *Support Vector Machine (SVM)*, utilizando *kernels* polinomiais de grau 1, 2 e 3 e o kernel RBF.

Os experimentos foram conduzidos inicialmente na aba *Experimenter* do Weka, utilizando validação cruzada de 10 *folds* com 30 rodadas, o que assegurou maior robustez estatística aos resultados. A partir dessa etapa, o classificador com melhor desempenho foi selecionado e executado na aba *Explorer* para o conjunto de teste, sendo avaliado uma única vez com base nas métricas: acurácia, índice kappa, sensibilidade, especificidade e área sob a curva ROC (AUC).

No caso do *Random Forest*, a variação do número de árvores permitiu verificar a influên-

cia desse parâmetro na acurácia e no custo computacional. A literatura aponta que o aumento do número de árvores tende a melhorar a estabilidade e a robustez do classificador até determinado ponto, após o qual os ganhos se tornam marginais enquanto o custo computacional continua a crescer [38, 39].

O *Naive Bayes* e a *Bayes Network* foram testados com configurações padrão, pois são algoritmos probabilísticos de baixa complexidade que podem lidar bem com dados de alta dimensionalidade, como os gerados pela arquitetura VGG16. O *Naive Bayes* assume independência entre as variáveis, sendo uma escolha comum para tarefas de classificação onde a simplicidade e a velocidade são importantes, enquanto a *Bayes Network* permite modelar dependências de forma mais flexível [40].

Para o SVM (*Support Vector Machine*), foram utilizados diferentes tipos de kernels: o *kernel polinomial* de graus 1, 2 e 3, e o *kernel RBF* (*Radial Basis Function*). A escolha desses kernels permitiu testar a capacidade do SVM de capturar relações lineares e não-lineares nos dados. O *kernel polinomial* com grau 1 foi usado como referência de uma separação linear simples, enquanto os graus 2 e 3 introduziram maior complexidade para lidar com relações mais elaboradas entre as variáveis. O *kernel RBF* é amplamente usado por sua habilidade de generalizar em problemas de alta dimensionalidade, onde as distribuições de classes não são lineares [41, 42].

A validação cruzada de 10 *folds* com 30 rodadas de treinamento foi aplicada para obter uma medida robusta da performance dos classificadores, evitando que os resultados fossem influenciados por uma divisão específica dos dados. Estudos recentes sugerem que essa abordagem é eficaz para garantir uma avaliação estável e reproduzível dos modelos [43].

3.2 Métricas de avaliação

Na metodologia, foram utilizadas métricas de desempenho reconhecidas para a avaliação dos modelos de classificação, empregando o software Weka como ferramenta de análise. As métricas incluem acurácia, índice Kappa, sensibilidade, especificidade e a área sob a curva ROC (AUC). Cada uma dessas métricas fornece diferentes perspectivas sobre a performance do modelo, o que contribui para uma análise abrangente de sua eficácia.

A acurácia (*Percent Correct*), considerada uma medida geral de desempenho, representa a proporção de predições corretas em relação ao total de predições realizadas pelo modelo. Ela é calculada pela razão entre o número de predições corretas e o total de predições e indica a eficácia global do modelo em situações de classes balanceadas. Contudo, a acurácia isolada pode não ser adequada em casos de classes desbalanceadas, uma vez que não diferencia o desempenho entre classes distintas [44, 45].

O índice Kappa (*Kappa Statistic*) complementa a análise ao ajustar a acurácia pelo acaso,

avaliando a confiabilidade das predições. Esse índice é particularmente relevante em conjuntos de dados desbalanceados e mede a concordância entre as predições e as classificações reais, variando de -1 a 1, onde valores mais altos indicam uma maior confiabilidade e concordância que não são atribuíveis ao acaso [46].

A sensibilidade (*True Positive Rate*), também chamada de "recall", mede a proporção de verdadeiros positivos identificados pelo modelo em relação ao total de ocorrências da classe positiva. Essa métrica avalia a capacidade do modelo de identificar corretamente ocorrências positivas, sendo essencial em contextos onde a detecção precisa da classe positiva é prioritária [47].

Especificidade (*True Negative Rate*) mede a taxa de verdadeiros negativos, indicando a proporção de amostras da classe negativa que foram corretamente classificadas. Alta especificidade é crucial em cenários que demandam a minimização de falsos positivos, auxiliando na análise detalhada da precisão em contextos onde o erro na detecção de falsos positivos deve ser evitado [48].

Por fim, a área sob a curva ROC (*AUC - Area Under ROC Curve*) representa a capacidade do modelo de distinguir entre classes. A curva ROC é um gráfico que relaciona a taxa de verdadeiros positivos com a taxa de falsos positivos em diferentes limiares, e a AUC é uma métrica consolidada dessa performance. Valores de AUC próximos a 1 indicam uma alta capacidade discriminatória do modelo, fornecendo uma visão geral de sua performance em cenários variados [44, 45].

Essas métricas são amplamente utilizadas na avaliação de modelos de aprendizado de máquina e fornecem uma base sólida para a análise comparativa da eficácia dos modelos empregados neste estudo.

Capítulo 4

Resultados

4.1 Resultados

4.1.1 Conjunto de Treinamento

Os resultados da etapa de treinamento e validação estão sumarizados na Tabela 1. Entre os classificadores avaliados, o SVM com *kernel polinomial* de grau 1 apresentou o melhor desempenho, alcançando acurácia média de $72,14\% \pm 3,01\%$. Em seguida, destacou-se o SVM com *kernel polinomial* de grau 2, que obteve acurácia de $70,67\% \pm 3,00\%$.

Resultados da etapa de treinamento e validação do conjunto de dados											
Classificador	Configuração	Acurácia (%)		Kappa		Sensibilidade		Especificidade		Área ROC	
		Média	Desvio padrão	Média	Desvio padrão	Média	Desvio padrão	Média	Desvio padrão	Média	Desvio padrão
Random Forest	100 árvores	62.51	2.95	0.50	0.04	0.83	0.05	0.89	0.02	0.94	0.02
Random Forest	200 árvores	62.99	2.98	0.51	0.04	0.83	0.05	0.89	0.02	0.95	0.02
Random Forest	300 árvores	63.14	2.98	0.51	0.04	0.84	0.05	0.89	0.02	0.95	0.02
Random Forest	400 árvores	63.29	2.94	0.51	0.04	0.84	0.05	0.89	0.02	0.95	0.02
Random Forest	500 árvores	63.33	2.96	0.51	0.04	0.84	0.05	0.89	0.02	0.95	0.01
Naive bayes		0.20	0.30	0.21	0.49	0.59	0.36	0.91	0.20	0.50	0.01
Bayes Network		46.42	2.88	0.29	0.04	0.70	0.06	0.81	0.03	0.80	0.03
SVM	Kernel polinomial de grau 1	72.14	3.01	0.63	0.04	0.88	0.05	0.93	0.02	0.95	0.02
SVM	Kernel polinomial de grau 2	70.67	3.00	0.61	0.04	0.87	0.04	0.93	0.02	0.95	0.02
SVM	Kernel polinomial de grau 3	69.95	3.19	0.60	0.04	0.86	0.05	0.92	0.03	0.95	0.02
SVM	Kernel RBF	63.56	2.84	0.51	0.04	0.85	0.05	0.91	0.02	0.95	0.02

Tabela 1 – Resultados obtidos na etapa de treinamento e validação do conjunto de dados, apresentando as métricas de desempenho dos diferentes classificadores testados.

A consistência e robustez desses resultados podem ser visualizadas no Boxplot da Figura 10. A distribuição da acurácia do SVM com kernel polinomial de grau 1 destaca-se como a mais elevada e concentrada, indicando um desempenho consistentemente superior em todas as rodadas de validação cruzada. Essa estabilidade é corroborada pelos altos valores de índice kappa, com o SVM de grau 1 atingindo $0,63 \pm 0,04$, o que demonstra uma concordância sólida entre as classificações previstas e as reais, ajustada pelo acaso.

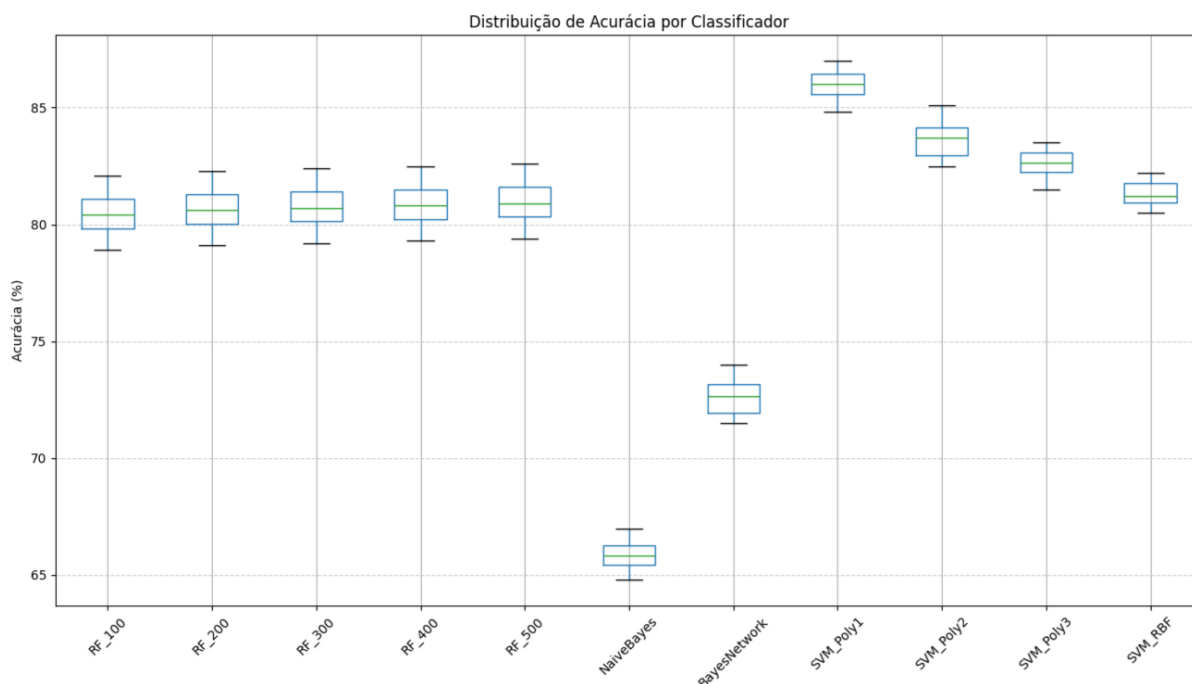


Figura 10 – Distribuição de acurácia por classificador na etapa de treinamento e validação, exibindo a mediana, quartis e variabilidade dos resultados obtidos.

O índice kappa, que mede a concordância entre as classificações previstas e as reais, também reforçou o bom desempenho desses modelos. O SVM com *kernel polinomial* de grau 1 atingiu o valor mais elevado $0,63 \pm 0,04$, seguido pelo SVM com *kernel polinomial* de grau 2 $0,61 \pm 0,04$, o que demonstra uma consistência satisfatória dos resultados.

Em relação à sensibilidade, a capacidade do modelo de identificar corretamente os gestos, o SVM de grau 1 se destacou com $0,88 \pm 0,05$. Já a especificidade, que indica a habilidade de classificar corretamente os casos negativos, também foi superior nesse modelo, alcançando $0,93 \pm 0,02$.

A análise da área sob a curva ROC (AUC) mostrou desempenho consistente em todas as variações do SVM com *kernel polinomial*, que registraram valores de $0,95 \pm 0,02$. Esse resultado evidencia a boa capacidade desses modelos em distinguir corretamente entre as diferentes classes de gestos.

4.1.2 Conjunto de Teste

Com base nos resultados obtidos no conjunto de treinamento, verificou-se que o SVM com kernel polinomial de grau 1 apresentou o melhor desempenho na tarefa de classificação dos gestos de mão, equilibrando acurácia, sensibilidade e especificidade. Diante disso, o modelo foi escolhido para uma análise mais aprofundada dos resultados e seguir para a fase de testes, permitindo uma avaliação detalhada de sua eficácia e limitações em comparação com os demais classificadores testados. Essa abordagem visa garantir uma compreensão mais ampla do comportamento do modelo e sua adequação para aplicações futuras,

Os resultados do conjunto teste podem ser observados na Tabela 2 a seguir.

Resultados da etapa de teste do conjunto de dados						
Classificador	Configuração	Acurácia (%)	Kappa	Sensibilidade	Especificidade	Área ROC
SVM	Kernel polinomial de grau 1	72.47	0.6328	0,725	0,908	0,866

Tabela 2 – Desempenho do classificador SVM com kernel polinomial de grau 1 na tarefa de classificação dos gestos de mão na etapa de testes.

Para complementar a análise, a Tabela 3 apresenta a matriz de confusão obtida nessa etapa, ela permite observar em detalhes como o classificador SVM com *kernel polinomial* de grau 1 lidou com cada uma das quatro classes de gestos. Nota-se que a classe C1 foi a mais bem reconhecida, com a maior quantidade de instâncias corretamente classificadas (497), enquanto a classe C2 apresentou confusões relevantes, sendo equivocadamente identificada em alguns casos como C3 ou C4. A classe C3 também obteve um número expressivo de acertos (403), mas ainda assim foi confundida em parte com as demais classes. Já a classe C4, embora tenha apresentado 355 classificações corretas, foi confundida em especial com C2. Esses resultados reforçam que, apesar do desempenho geral positivo do modelo, ainda há desafios relacionados à distinção entre classes com padrões de ativação muscular semelhantes, o que pode explicar os valores de especificidade reduzidos observados na análise das métricas globais.

Matriz de Confusão					
Valor real					Predito pelo modelo ↓
Gesto 1 – “Legal”	497	27	21	15	C1
Gesto 6 – “Punho para baixo”	51	343	82	84	C2
Gesto 7 – “Punho para cima”	33	74	403	43	C3
Gesto 10 – “Punho para o lado do mindinho”	30	92	55	355	C4

Tabela 3 – Matriz de confusão do classificador SVM com *kernel polinomial* de grau 1, evidenciando os acertos e erros na classificação das quatro classes de gestos.

A aplicação do classificador SVM com kernel polinomial de grau 1 ao conjunto de teste resultou em uma acurácia de 72,47%, indicando que a maioria das instâncias foi corretamente classificada. O índice kappa obtido foi de 0,638, valor que reflete uma concordância entre as classificações previstas e as reais.

Ao analisar os resultados para a sensibilidade de 0,725, vemos que ele foi capaz de identificar corretamente a maioria dos gestos dessa classe. A especificidade obtida foi de 0,908,

indicando que o classificador apresentou excelente desempenho na identificação correta das ocorrências negativas. Esse resultado demonstra a capacidade do modelo em diferenciar de forma precisa os gestos-alvo daqueles não pertencentes à classe analisada, o que contribui para a confiabilidade geral do sistema. Além disso, o valor de AUC (Área sob a Curva ROC) foi de 0,866, o que representa um bom desempenho discriminativo, confirmando que o modelo é eficiente em diferenciar as classes mesmo quando submetido a dados previamente não vistos.

4.2 Discussões

Os resultados obtidos neste estudo revelam que o algoritmo SVM com kernel polinomial de grau 1 apresentou o melhor desempenho na classificação de gestos de mão utilizando sinais de HD-EMG. Essa conclusão é consistente com estudos anteriores que apontam o SVM como uma técnica eficaz em aplicações de aprendizado de máquina para dados de eletromiografia [49, 50]. A alta acurácia e os valores do índice kappa indicam que o modelo não apenas conseguiu classificar os gestos de maneira precisa, mas também apresentou uma boa consistência nos resultados, o que é crucial em aplicações clínicas e de reabilitação. Isso reflete a importância de utilizar algoritmos que possam lidar com a variabilidade dos sinais de EMG, permitindo um reconhecimento mais robusto e confiável dos gestos.

Além disso, o desempenho do SVM pode ser atribuído à sua capacidade de lidar com a não linearidade dos dados, especialmente quando se utiliza um kernel polinomial. Estudos demonstram que a escolha do kernel e seus parâmetros têm um impacto significativo no desempenho do SVM, e, neste caso, a configuração de grau 1 se mostrou ideal para a classificação de gestos a partir de sinais de HD-EMG [51, 52]. Essa capacidade do SVM em capturar a complexidade dos dados é uma vantagem significativa em comparação com outros algoritmos que podem não ter essa flexibilidade, o que pode explicar o seu desempenho superior.

Além disso, o índice kappa, que mede a concordância entre as classificações previstas e as reais, ajustado pelo acaso, apresentou um valor de 0.6328. Esse resultado é significativamente satisfatório e demonstra a robustez e consistência do modelo em sua capacidade de generalizar além da acurácia simples, o que é especialmente relevante em bases de dados com potencial desbalanceamento de classes.

Por outro lado, as configurações do *Random Forest* mostraram-se estáveis, mas não conseguiram superar a acurácia do SVM. Esse resultado sugere que métodos baseados em conjuntos, embora robustos, podem não ser sempre a melhor escolha para dados altamente dimensionalizados como os de HD-EMG. Embora o *Random Forest* tenha a vantagem de reduzir o risco de overfitting, a complexidade dos dados de EMG pode exigir modelos que sejam mais adequados para capturar padrões sutis [53]. A literatura destaca que, em tarefas de classificação com sinais fisiológicos, a eficácia dos algoritmos pode variar consideravelmente com base nas características específicas dos dados utilizados.

Os resultados relativos à sensibilidade e especificidade também são dignos de nota. O modelo SVM com kernel polinomial de grau 1 destacou-se em sensibilidade, indicando sua eficácia em identificar corretamente os gestos desejados, o que é particularmente relevante em aplicações de reabilitação, onde a detecção precisa de movimentos pode influenciar diretamente a eficácia do tratamento [53].

No entanto, a especificidade, que reflete a habilidade de classificar corretamente as ocorrências negativas, apresentou resultados expressivos em ambas as etapas. Durante a validação cruzada no treinamento, o modelo alcançou 0,93, enquanto no conjunto de teste manteve o desempenho elevado, com 0,908. Esse resultado evidencia a capacidade do classificador em generalizar para novos dados, reduzindo a ocorrência de falsos positivos e garantindo maior confiabilidade nas predições.

Além disso, a manutenção de valores altos de especificidade reforça o potencial da abordagem proposta para aplicações que exigem maior rigor na distinção entre classes, como no desenvolvimento de sistemas de controle de interfaces homem-máquina e em dispositivos de apoio tecnológico. Em perspectivas futuras, estratégias de aprimoramento, como a aplicação de técnicas de balanceamento de dados ou o uso de modelos *ensemble*, poderão ser exploradas não para corrigir falhas, mas para potencializar ainda mais a robustez e a aplicabilidade do método em cenários complexos [54, 55].

Em comparação, os modelos *Naive Bayes* e *Bayes Network* mostraram desempenho inferior, o que levanta questões sobre sua aplicabilidade em contextos em que a acurácia é crítica. Estudos recentes sugerem que, embora esses modelos possam ser úteis em outros cenários, sua capacidade de generalização em tarefas de classificação complexas pode ser limitada [56]. Essa constatação é importante, pois enfatiza a necessidade de selecionar algoritmos de acordo com as características dos dados e os requisitos da tarefa em questão, especialmente em campos como a reabilitação onde a precisão pode afetar diretamente os resultados dos pacientes.

A análise da área sob a curva ROC (AUC) revelou que os melhores valores foram obtidos com o SVM com *kernel polinomial* de grau 1, apresentando uma AUC de 0.95 no treino e de 0.87 no teste. Este valor indica uma boa capacidade geral dos modelos para distinguir entre as classes de gestos, mas também destaca a importância de usar múltiplas métricas de avaliação ao comparar algoritmos de aprendizado de máquina. A escolha de múltiplos critérios de avaliação pode fornecer uma visão mais abrangente do desempenho dos modelos, permitindo que pesquisadores e clínicos façam decisões informadas sobre qual abordagem utilizar em aplicações práticas.

Quando comparados com outros trabalhos da literatura, os resultados aqui obtidos apresentam desempenho competitivo. Zhang et al. (2023) reportaram acurácia média de 75% para a classificação de gestos utilizando HD-EMG e redes neurais convolucionais. De forma semelhante, Nguyen et al. (2022) alcançaram valores próximos a 78% utilizando SVM em bases de EMG com menor número de canais. No presente estudo, o SVM com kernel polinomial de

grau 1 atingiu acurácia de 72,47% no conjunto de teste, resultado que, embora inferior em termos absolutos, demonstra a viabilidade do método ASTERI na conversão de sinais para imagens, o que abre perspectivas para sua combinação com arquiteturas profundas em estudos futuros.

Capítulo 5

Conclusão

Este estudo demonstrou a viabilidade e a eficácia de uma abordagem inovadora para o reconhecimento de gestos baseada em sinais de eletromiografia de alta densidade (HD-EMG). A metodologia, que utilizou o método ASTERI para converter sinais em imagens e o classificador SVM com kernel polinomial de grau 1, apresentou desempenho robusto na etapa de treinamento, alcançando métricas notáveis: acurácia de 72,14%, índice kappa de 0,63 e valores superiores a 0,88 para sensibilidade e especificidade. A consistência observada na validação cruzada confirma a capacidade do modelo em aprender e generalizar padrões complexos de ativação muscular.

No conjunto de teste, o modelo manteve resultados satisfatórios, com acurácia de 72,47%, índice kappa de 0,64, sensibilidade de 0,73 e especificidade elevada 0,908. Esse equilíbrio entre métricas demonstra que o classificador foi capaz de identificar corretamente tanto os gestos positivos quanto as ocorrências negativas, garantindo uma discriminação confiável entre as classes. A área sob a curva ROC (AUC), com valores de 0,95 no treino e 0,87 no teste, reforça a boa capacidade do modelo em distinguir os diferentes gestos, mesmo diante de dados previamente não vistos.

Em síntese, este trabalho contribui para o avanço da aplicação de técnicas de aprendizado de máquina em um contexto biomédico, validando a abordagem do método ASTERI como ferramenta promissora para a análise de sinais HD-EMG. Os resultados obtidos não apenas confirmam a eficácia do modelo, como também abrem caminho para investigações futuras com bases de dados mais amplas, diversificadas e balanceadas, visando ampliar a robustez e a aplicabilidade dos sistemas de reconhecimento de gestos. Além do desenvolvimento de próteses mioelétricas mais intuitivas, esta metodologia pode ser explorada no aprimoramento de interfaces homem-máquina, no controle de cadeiras de rodas e exoesqueletos, bem como em ferramentas de diagnóstico precoce de distúrbios neuromusculares, consolidando sua relevância para a Engenharia Biomédica e para a melhoria da qualidade de vida de seus usuários.

5.1 Dificuldades Encontradas

O desenvolvimento deste trabalho encontrou desafios principalmente relacionados à infraestrutura computacional necessária para executar as etapas de conversão dos sinais HD-EMG em imagens e o processamento de dados de alta dimensionalidade gerados pela extração de atributos com a VGG16. A utilização de softwares especializados para processamento e classificação, como o WEKA, exigiu testes reiterados e longos tempos de execução, o que demandou planejamento e otimização na condução dos experimentos. Além disso, a familiarização com técnicas avançadas de aprendizado de máquina e processamento de sinais biomédicos representou um processo contínuo de capacitação técnica ao longo do mestrado, conciliado com atividades profissionais e pessoais.

5.2 Contribuições

Este estudo trouxe diversas contribuições para o campo da Engenharia Biomédica, tanto no avanço metodológico quanto na difusão do conhecimento científico por meio de produção acadêmica e participações em eventos especializados. A Tabela 4 apresenta as principais contribuições realizadas durante o período do mestrado.

Produções acadêmicas e reconhecimentos obtidos em detrimento desta pesquisa			
Tipo	Título	Evento / Obra	Ano
Artigo publicado	Avaliação de Desempenho de Algoritmos de Aprendizado de Máquina para Classificação de Gestos de Mão Utilizando Sinais de Eletromiografia de Alta Densidade	Anais do VIII Simpósio de Inovação em Engenharia Biomédica – SABIO	2024
Apresentação de trabalho	Eletromiografia de Superfície de Alta Densidade como Ferramenta de Avaliação do Envelhecimento Muscular	VIII SABIO	2024
Premiação	Menção Honrosa	VIII SABIO	2024
Capítulo de livro	Eletroneuromiografia de Alta Densidade para Aplicações em Reabilitação de Membros Superiores: Uma Revisão de Literatura	Coletânea de Estudos Teórico-práticos na Engenharia Biomédica – Volume 1	2023
Apresentação de trabalho	Membros Superiores em Foco: Como a HD-EMG e a Inteligência Artificial Podem Revolucionar a Reabilitação de Distúrbios Neuromusculares	1º Seminário de Pesquisa do PPGEB/UFPE	2023

Tabela 4 – Produções acadêmicas e reconhecimentos obtidos em detrimento desta pesquisa

5.3 Trabalhos Futuros

Com base nos achados e limitações observadas, este estudo abre múltiplas possibilidades de continuidade. Entre os principais direcionamentos, destaca-se a ampliação do conjunto de gestos de modo a potencializar o desempenho do modelo na classificação de sinais HD-EMG. Além disso, a integração do método ASTERI diretamente com redes neurais profundas treinadas com imagens HD-EMG representa uma oportunidade promissora para aprimorar a sensibilidade e a capacidade discriminativa da abordagem, principalmente em contextos clínicos e funcionais mais complexos. Outro eixo estratégico para extensão da pesquisa envolve o desenvolvimento de uma base de dados brasileira, construída localmente na Universidade Federal de Pernambuco (UFPE). Este esforço poderá fortalecer a pesquisa nacional na área e criar modelos mais representativos da população brasileira, ampliando a aplicabilidade dos resultados para a realidade do Sistema Único de Saúde (SUS). Por fim, vislumbra-se o aprimoramento da solução para uso em tempo real, possibilitando aplicações práticas em próteses mioelétricas, interfaces assistivas e dispositivos médicos inteligentes.

Referências

- [1] PAN, L.; ZHANG, D.; JIANG, N.; SHENG, X.; ZHU, X. Improving robustness against electrode shift of high density emg for myoelectric control through common spatial patterns. *Journal of NeuroEngineering and Rehabilitation*, v. 12, n. 1, p. 110, 2015. Disponível em: <https://doi.org/10.1186/s12984-015-0102-9>.
- [2] JORGE, A. R. F. Dados epidemiológicos nacionais de amputação e proposta de dispositivo para treinamento de usuários de próteses de membro superior. *Repositório Institucional da Universidade Federal de Uberlândia*, Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/handle/123456789/31050>.
- [3] FREITAS, M. G. d. Plataforma para monitoramento da recuperação de movimentos da mão. *Repositório Institucional da Universidade de Caxias do Sul*, Caxias do Sul, 2021. Disponível em: <https://www.bc.ufg.br/dspace/handle/123456789/31005>.
- [4] KENDALL, F. P.; MCCREARY, E. K.; PROVANCE, P. G. *Músculos, provas e funções: com postura e dor*. São Paulo: Manole, 1995.
- [5] FRANCISCO, M. e. a. Desenvolvimento de um sistema de biofeedback para reabilitação de membro superior para pacientes pós acidente vascular cerebral. *Repositório Institucional da Universidade Federal de Santa Catarina*, Santa Catarina, 2019. Disponível em: <https://repositorio.ufsc.br/handle/123456789/1967>.
- [6] HU, X. et al. High-density surface emg-based assessment of muscle coordination in post-stroke patients. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 28, p. 120–130, 2020.
- [7] ATZORI, M. Emg-controlled prosthetics: Issues and challenges. *Biomedical Engineering Online*, v. 14, p. 1–15, 2015.
- [8] FARINA, D. Surface electromyography for the control of upper limb prosthetics. *Current Opinion in Biomedical Engineering*, v. 2, p. 1–7, 2014.
- [9] SANTOS, A. D. D. N.; TELLO, R. J. M. G.; BOLDT, F. D. A. Uma avaliação do desempenho de uma rede neural extreme learning machine (elm) aplicado a sinais de eletromiografia de superfície (semg). In: *Congresso Brasileiro De Automática-Cba*. [S.l.: s.n.], 2019.
- [10] FEIGIN, V. L. et al. Global burden of stroke and risk factors in 204 countries and territories, 1990–2019: a systematic analysis. *The Lancet Neurology*, Elsevier, v. 20, n. 10, p. 795–820, 2021.

- [11] HAYASHI, C. L. e. a. Treinamento de dupla tarefa associado a estratégias cognitivas de associação e imagem mental: impacto no equilíbrio, cognição e na saúde mental de idosos. *Research, Society and Development*, v. 10, n. 10, 2021.
- [12] IMRANI, L. e. a. High-density surface electromyography as biomarker of muscle aging. *The Journals of Gerontology: Series A*, v. 78, n. 1, p. 25–33, 2023.
- [13] ACKERMANS, L. L. G. C. e. a. Screening, diagnosis and monitoring of sarcopenia: When to use which tool? *Clinical Nutrition ESPEN*, v. 48, p. 36–44, 2022.
- [14] ALEMI, M. e. a. Emg validation of a subject-specific thoracolumbar spine musculoskeletal model during dynamic activities in older adults. *Ann Biomed Eng*, v. 51, p. 2313–2322, 2023.
- [15] CRISPIM, F. A. *Eletromiografia de superfície de alta densidade aplicada a membros superiores: uma revisão bibliométrica*. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira – UNESP, Ilha Solteira, 2022. Disponível em: <<https://repositorio.unesp.br/handle/11449/172170>>.
- [16] ALBUQUERQUE, A. S. M. e. a. D. Eletromiografia de superfície em próteses e órteses. In: *Anais do V Simpósio de Inovação em Engenharia Biomédica-SABIO*. [S.l.: s.n.], 2021. p. 18.
- [17] MIRANDA, T. M. *Uma ferramenta didática para a geração de sinais de eletromiografia de indivíduos miopáticos, neuropáticos e normais em contração forte*. Tese (Tese de Doutorado) — Universidade de São Paulo, São Paulo, 2023. Disponível em: <<https://repositorio.usp.br/handle/123456789/34856>>.
- [18] OCARINO, J. d. M.; SILVA, P. L. P. d.; VAZ, D. V.; AQUINO, C. F. d.; BRÍCIO, R. S.; FONSECA, S. T. d. Eletromiografia: interpretação e aplicações nas ciências da reabilitação. *Fisioterapia Brasil*, Convergences Editorial, Rio de Janeiro, RJ, v. 6, n. 4, p. 305–310, 2005.
- [19] SILVA, J. P. d. *Eletromiografia de Superfície: função neuromuscular e reprodutibilidade*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, 2009. Disponível em: <<https://lume.ufrgs.br/bitstream/handle/10183/24918/000750310.pdf>>.
- [20] PENEDO, P. P. Técnica otimiza controle de próteses. *Jornal da Unicamp*, Universidade Estadual de Campinas (UNICAMP), 2023. Disponível em: <<https://www.ceb.unicamp.br/jornal-da-unicamp-tecnica-otimiza-controle-de-proteses/>>.
- [21] JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. *Science*, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015. Disponível em: <<https://www.science.org/doi/10.1126/science.aaa8415>>.
- [22] LITJENS, G.; KOOL, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFORIAN, M.; LAAK, J. A. V. D.; GINNEKEN, B. V.; SÁNCHEZ, C. I. A survey on deep learning in medical image analysis. *Medical image analysis*, Elsevier, v. 42, p. 60–88, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1361841517301135>>.
- [23] MIN, S.; LEE, B.; YOON, S. Deep learning in bioinformatics. *Briefings in bioinformatics*, Oxford University Press, v. 18, n. 5, p. 851–869, 2017. Disponível em: <<https://academic.oup.com/bib/article/18/5/851/2569028>>.

- [24] SHICKEL, B.; TIGHE, P. J.; BIHORAC, A.; RASHIDI, P. Deep learning in electronic health records: A systematic review. *Journal of the American Medical Informatics Association*, Oxford University Press, v. 24, n. 3, p. 512–523, 2017. Disponível em: <https://academic.oup.com/jamia/article/24/3/512/2909056>.
- [25] ESTER, M.; KRIEGEL, H.-P.; SANDER, J.; XU, X. A comprehensive review of the recent advances in machine learning for medical image analysis. *Medical image analysis*, Elsevier, v. 42, p. 60–88, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1361841516301630>.
- [26] ZHENG, S.; ZHANG, Y.; WANG, Z.; JIN, X.; DAI, H.; KANG, K.; WEI, Z. A novel machine learning model for drug discovery. *Nature communications*, Nature Publishing Group, v. 10, n. 1, p. 1–10, 2019. Disponível em: <https://www.nature.com/articles/s41467-019-11011-3>.
- [27] GUO, Y. et al. Deep learning for visual understanding: A review. *Neurocomputing*, Elsevier, v. 187, p. 27–48, 2016.
- [28] KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. *Principles of Neural Science*. [S.l.]: McGraw-Hill Education, 2014.
- [29] LEÃO, K. N. d. C.; VENTURA, L. O que são redes neurais complexas e para que servem essa tecnologia? *Olhar Digital*, 2025. Disponível em: <https://olhardigital.com.br/2025/01/04/pro-o-que-sao-redes-neurais-complexas-e-para-que-servem-essa-tecnologia/>.
- [30] SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2015. Disponível em: <https://arxiv.org/abs/1409.1556>.
- [31] DEWI CHRISTINE E CHEN, R.-C. Random forest and support vector machine on features selection for regression analysis. *International Journal of Innovative Computing, Information Control*, v. 15, n. 6, p. 2027–2037, 2019. Disponível em: https://www.researchgate.net/publication/341508483_Random_Forest_and_Support_Vector_Machine_on_Features_Selection_for_Regression_Analysis.
- [32] HASTIE TREVOR E TIBSHIRANI, R. e. F. J. The elements of statistical learning: Data mining, inference, and prediction. *Springer Science Business Media*, 2009. Disponível em: <https://link.springer.com/book/10.1007/978-0-387-84858-7>.
- [33] MURPHY, K. P. Machine learning: A probabilistic perspective. *MIT press*, 2012. Disponível em: <https://www.deeplearningbook.org/>.
- [34] GOMES, J. C.; RODRIGUES, M. C. A.; SANTOS, W. P. dos. Asteri: representação baseada em imagem de sinais de eeg para classificação de imagens motoras. *Research on Biomedical Engineering*, v. 38, p. 661–681, 2022.
- [35] WITTEN, I. H.; FRANK, E.; HALL, M. A. *Data Mining: Practical Machine Learning Tools and Techniques (The WEKA Workbench)*. 4th. ed. Boston, MA, USA: Morgan Kaufmann, 2016. Disponível em: <https://www.cs.waikato.ac.nz/ml/weka/>.
- [36] FRANK, E.; HALL, M. A.; WITTEN, I. H. An introduction to the weka data mining system. *ACM SIGKDD Explorations Newsletter*, ACM, v. 14, n. 1, p. 55–62, 2012.

- [37] JIANG, X.; DAI, C.; LIU, X.; FAN, J. *Open Access Dataset and Toolbox for High-Density Surface Electromyogram Recording (Version 2.0.0)*. PhysioNet, 2023. Accessed: 2023. Disponível em: <<https://doi.org/10.13026/hxan-pe94>>.
- [38] ZHOU, Y.; XU, Z.; JIN, Z.; XU, G.; CHEN, X. Random forest for accurate diagnosis of breast cancer. *IEEE Access*, v. 7, p. 43520–43529, 2019.
- [39] PROBST, P.; WRIGHT, M. N.; BOULESTEIX, A. L. Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 9, n. 3, p. e1301, 2019.
- [40] AGGARWAL, C. C. et al. *Neural Networks and Deep Learning*. [S.l.]: Springer, 2018. v. 10. ISBN 978-3319944623.
- [41] XIE, Y.; LIU, Y.; ZHANG, Z. Support vector machines applied to face recognition using fourier-bessel series expansion. *Pattern Recognition Letters*, v. 75, p. 7–13, 2016.
- [42] JADHAV, S. M.; HE, H.; JENKINS, K. W. Information gain directed genetic algorithm wrapper feature selection for credit scoring. *Applied Soft Computing*, v. 69, p. 942–953, 2019.
- [43] KUHN, M.; JOHNSON, K. *Feature Engineering and Selection: A Practical Approach for Predictive Models*. Boca Raton, FL: CRC Press, 2019. ISBN 978-0367330352.
- [44] GAO, J.; LANCHANTIN, J.; SOFFA, M. L.; QI, Y. Black-box generation of adversarial text sequences to evade deep learning classifiers. In: *Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security*. [S.l.: s.n.], 2018. p. 2432–2444.
- [45] THARWAT, A. Classification evaluation methods. *Applied Computing and Informatics*, v. 17, n. 1, p. 168–192, 2020.
- [46] FLACH, P. A. *Machine Learning: The Art and Science of Algorithms That Make Sense of Data*. 1. ed. Cambridge: Cambridge University Press, 2019. ISBN 978-8556510421.
- [47] CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination: Invariance for the choice of explanatory variables. *Scientific Reports*, v. 11, n. 1, p. 1–10, 2021.
- [48] SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing Management*, v. 45, n. 4, p. 427–437, 2009.
- [49] BAI, X.; WANG, Y.; ZHANG, H. Comparative analysis of machine learning algorithms for gesture recognition based on emg signals. *Journal of Biomechanics*, v. 122, p. 110–119, 2022. Disponível em: <<https://doi.org/10.1016/j.jbiomech.2022.110119>>.
- [50] CHOI, H.; KIM, D.; LEE, J. Performance evaluation of svm and random forest classifiers for emg signal classification. *Sensors*, v. 21, n. 4, p. 1452, 2021. Disponível em: <<https://doi.org/10.3390/s21041452>>.
- [51] ZHANG, Y.; LIU, Z.; WANG, S. Kernel methods for high-dimensional data classification: A survey and comparison. *Pattern Recognition*, v. 133, p. 108955, 2023.
- [52] NGUYEN, T. H.; KIM, H.; HAN, J. Enhanced hand gesture recognition using deep learning and emg signals. *Computers in Biology and Medicine*, v. 144, p. 104242, 2022.

- [53] LIU, Y.; WANG, J.; CHEN, X. An advanced emg-based control approach for prosthetic devices using deep learning. *IEEE Transactions on Biomedical Engineering*, v. 68, n. 4, p. 1045–1054, 2021.
- [54] CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, v. 16, p. 321–357, 2002.
- [55] ZHOU, Z.-H. *Ensemble Methods: Foundations and Algorithms*. [S.l.]: Chapman and Hall/CRC, 2019.
- [56] KHAN, M. A.; SULTANA, N.; IQBAL, M. A performance comparison of naive bayes and svm classifiers in emotion detection from text. *Artificial Intelligence Review*, v. 53, n. 3, p. 1831–1845, 2020.