



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA, GESTÃO E
MÍDIA DO CONHECIMENTO

VALERIO JUNIOR PIANA

**MÉTODO VOLTADO À RECOMENDAÇÃO DE TRATAMENTOS
FISIOTERAPÊUTICOS PARA PACIENTES COM LESÃO NA COLUNA
ESPINHAL POR MEIO DE TÉCNICAS DE APRENDIZADO DE
MÁQUINA**

FLORIANÓPOLIS

2023

Valerio Junior Piana

**MÉTODO VOLTADO À RECOMENDAÇÃO DE TRATAMENTOS
FISIOTERAPÊUTICOS PARA PACIENTES COM LESÃO NA COLUNA ESPINHAL
POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia e Gestão do Conhecimento.

Orientador: Prof. Dr. Alexandre Leopoldo Gonçalves.

Coorientador: Prof. Dr. João Artur de Souza.

Florianópolis

2023

Ficha de identificação da obra

Piana, Valerio Junior

MÉTODO VOLTADO À RECOMENDAÇÃO DE TRATAMENTOS FISIOTERAPÊUTICOS PARA PACIENTES COM LESÃO NA COLUNA ESPINHAL POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA / Valério Junior Piana; orientador, Alexandre Leopoldo Gonçalves, coorientador, João Artur de Souza, 2023.

166 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento, Florianópolis, 2023.

Inclui referências.

1. Engenharia e Gestão do Conhecimento. 2. Lesão na Coluna Espinhal. 3. Machine Learning. 4. Sensores. 5. Sistema de Recomendação. I. Gonçalves, Alexandre Leopoldo. II. Souza, João Artur de. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento. IV. Título.

Valerio Junior Piana.

**MÉTODO VOLTADO À RECOMENDAÇÃO DE TRATAMENTOS
FISIOTERAPÊUTICOS PARA PACIENTES COM LESÃO NA COLUNA ESPINHAL
POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. José Leomar Todesco, Dr.
Universidade Federal de Santa Catarina

Prof. Vinicius Faria Culmant Ramos, Dr.
Universidade Federal de Santa Catarina

Prof. Geovani Rodrigo Scolaro, Dr.
Universidade do Oeste de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia, Gestão e Mídia do Conhecimento.

Prof. Roberto Carlos dos Santos Pacheco, Dr.
Coordenador(a) do Programa

Prof. Alexandre Leopoldo Gonçalves, Dr.
Orientador(a)

Florianópolis, 11 de dezembro de 2023.

À memória de minha mãe, e ao amor de meu pai e de meu noivo,
que deram suporte e apoio incondicional ao meu crescente
desenvolvimento.

AGRADECIMENTOS

Agradeço a minha mãe (*in memoriam*) e meu pai que continua sendo meu farol, cujo amor e dedicação moldaram minha jornada e me edificaram com fortes exemplos, agradeço por cada sacrifício e por sempre acreditarem em mim, trazendo sabedoria, fortaleza, perseverança, ética e força.

Ao meu noivo, João Paulo, pela paciência, apoio e amor incondicional durante esta intensa trajetória. Sua presença foi minha força nos momentos de dúvida e minha celebração aos triunfos e vitórias ao que brindamos juntos.

Aos meus mestres, que me guiaram com sabedoria, maestria, dedicação e compreensão, permitindo que eu me aprofundasse em minha paixão. Vocês têm sido fundamentais nesta caminhada acadêmica e na minha evolução profissional, científica e humana. Em especial, agradeço ao Doutor Alexandre Leopoldo Gonçalves, meu orientador, pelas diversas reuniões de norteamo, apoio e *insights* valiosos em toda minha trajetória, traduzindo seus éticos e competentíssimos exemplos como pessoa, profissional e pesquisador sem igual.

Ao UniSENAI (Centro Universitário SENAI/SC), ao Serviço Nacional de Aprendizagem Industrial de Santa Catarina (SENAI/SC) e a Federação das Indústrias do Estado de Santa Catarina (FIESC) pela condição e apoio a minha formação *strito-sensu*. Estas instituições são um marco na minha jornada e sou profundamente grato às entidades.

“Veni, vidi, vici. Ut est rerum omnium magister usus.” (Gaius Iulius Caesar, 47 a.C.)

RESUMO

A fisioterapia tem testemunhado avanços significativos, especialmente no tratamento de Lesão da Medula Espinhal (SCI). Estes avanços tecnológicos estão revolucionando a eficácia dos tratamentos e melhorando a qualidade de vida dos pacientes. A evolução contínua em tecnologias de ponta e a análise de grandes volumes de dados clínicos ressaltam a crescente interseção da fisioterapia com técnicas de Aprendizado de Máquina (ML). Este trabalho visa desenvolver um método integrativo para a recomendação de tratamento de SCI, unindo técnicas de Engenharia do Conhecimento e Computação à Fisioterapia. O foco é a aplicação em dispositivos sensoriais e atuadores, como Interfaces Cérebro-Máquina (BMIs), para a predição de séries temporais em Eletroestimulação Funcional (FES). Com a adoção da metodologia PRISMA-P para uma revisão sistemática da literatura, foram identificados inicialmente 168 estudos, dos quais apenas 7,14% foram considerados relevantes para análise aprofundada. Este processo foi fundamental para entender estratégias eficientes no tratamento de SCI com o suporte de ML. A metodologia de pesquisa *Design Science Research Methodology* (DSRM) foi utilizada para desenvolver e avaliar o artefato proposto. Além do método proposto, foi desenvolvida uma Rede Neural Artificial (ANN), mais especificamente uma *Long Short-Term Memory* (LSTM) para analisar séries temporais de Eletromiografia (EMG) em engenharia biomédica. O modelo alcançou uma precisão de 81% para R^2 na predição de eventos mioelétricos. Análises quantitativas revelaram que um único canal mioelétrico é mais eficaz do que múltiplos canais, enfatizando a importância da seleção de características. Os resultados demonstram o potencial do método proposto na captura e análise de biosinais complexos e na previsão de séries temporais. O estudo destaca a viabilidade de aplicar estes achados em cenários reais, como na FES, e em tecnologias assistivas para melhorar a qualidade de vida dos pacientes com SCI.

Palavras-chave: Aprendizado de Máquina. LSTM. Engenharia Biomédica. Séries Temporais. Sinais Mioelétricos. Predição. Eletroestimulação Funcional.

ABSTRACT

Physical therapy has witnessed significant advancements, particularly in the treatment of Spinal Cord Injury (SCI). These technological breakthroughs are revolutionizing the effectiveness of treatments and enhancing the quality of life for patients. The ongoing evolution in cutting-edge technologies and the analysis of large volumes of clinical data highlight the increasing intersection of physical therapy with Machine Learning (ML) techniques. This study aims to develop an integrative method for SCI treatment, combining Knowledge Engineering and Computing techniques with Physical Therapy. The focus is on the application in sensory and actuator devices, such as Brain-Machine Interfaces (BMIs), for predicting time series in Functional Electrical Stimulation (FES). Utilizing the PRISMA-P methodology for a systematic literature review, we initially identified 168 studies, of which only 7.14% were deemed relevant for in-depth analysis. This process was crucial for understanding efficient strategies in SCI treatment supported by ML. The Design Science Research Methodology (DSRM) was employed to develop and assess the proposed artifact. An Artificial Neural Network (ANN), specifically a Long Short-Term Memory (LSTM), was developed to analyze electromyography (EMG) time series in Biomedical Engineering. The model achieved an accuracy of 81% for R^2 in predicting myoelectric events. Quantitative analyses revealed that a single myoelectric channel is more effective than multiple channels, emphasizing the importance of feature selection. The findings demonstrate the potential of the proposed method in capturing and analyzing complex biosignals and in predicting time series. The study highlights the feasibility of applying these findings in real-world scenarios, such as in FES, and in advanced assistive technologies to improve the quality of life for patients with SCI.

Keywords: Machine Learning. LSTM. Biomedical Engineering. Time Series. Myoelectric Signals. Prediction. Functional Electrical Stimulation.

LISTA DE FIGURAS

Figura 1 - Proposta de modelo experimental de eletroestimulação funcional.....	23
Figura 2 - Dimensões da sinergia entre técnicas de AI e a prognose e diagnose médica.....	24
Figura 3 - Processo de seleção de trabalhos	29
Figura 4 - Comparação gráfica da distribuição de publicações por ano.....	41
Figura 5 - Comparação da distribuição de publicações por nível de formação.....	41
Figura 6 - Comparação da distribuição de publicações na área de concentração ou ferramenta	42
Figura 7 - Principais estágios para conduzir uma pesquisa por meio da metodologia DSRM.	44
Figura 8 - Fluxograma de decodificação de biosinais corpóreos para processamento e ações através de Inteligência Artificial para processamento e ação em pacientes	47
Figura 9 - Representação gráfica da inteligência artificial	49
Figura 10 - Proposta de Modelo de uma Inteligência Artificial em suas Entradas de Dados, Pré-Processamento, Modelos, Tuning e Análise Final	51
Figura 11 - Modelo de arquitetura de implementação de uma rede neural convolucional	52
Figura 12 - Relação de contraste na obtenção dos sinais elétricos do cérebro em níveis de invasividade (A), desde EEG e sinais intracorticais. (B) Exemplos de gráficos de captura de sinais neuronais	54
Figura 13 - Representação de uma BMI na leitura de atividade cerebral, decodificação, processamento e ação no usuário, em ação a utilização de algoritmos de ML e retorno a <i>feedback</i> no cérebro	55
Figura 14 - Especificação da lista de práticas de design de última geração para BMI	56
Figura 15 - Proposta de modelo de microeletrodos de mapeamento neuronal servindo como dados de entrada para uma máquina que, por meio de AI, replica impulsos elétricos no tecido muscular	58
Figura 16 - Diferentes abordagens dos autores frente a busca pelo estado da arte atual em termos de ML e SCI	59
Figura 17 - Representação do fluxo de obtenção de dados cerebrais para o treinamento de modelo de dados baseado em leitura de biosinais	60
Figura 18 - FES em tempo real através de reconhecimento 3D de CV de imagem e algoritmos de detecção de objetos	61
Figura 19 - Diagrama do referencial da pesquisa em avaliação da eficiência dos métodos de pesquisa básica e aplicada	63

Figura 20 - A DSRM, em suas fases essenciais	66
Figura 21 - Organização do trabalho em relação a DSRM e suas etapas.....	68
Figura 22 - Processo de coleta de dados do equipamento	75
Figura 23 - Processo de pré-processamento dos dados, simplificado	77
Figura 24 - Síntese da proposição do desenvolvimento de pesquisa.....	87
Figura 25 - Representação resumida do método proposto	91
Figura 26 - Conceitualização das classes que representam o método proposto	92
Figura 27 - Representação do método proposto utilizando UML	94
Figura 28 - Diagrama de sequência em UML com a interação entre diferentes classes, bibliotecas externas, processo de carregamento, processamento e visualização de dados de séries temporais para treinamento e previsão usando uma rede LSTM	105
Figura 29 - Diagrama de fluxo do cenário que ilustra o processo do Preparação e Segmentação de Dados	116
Figura 30 - Diagrama de componentes que são englobados pelo Treinamento do Modelo...	117
Figura 31 - Arquitetura de Rede LSTM implementada para o método.....	118
Figura 32 - Exemplo da representação mioelétrica de um canal muscular ao ser armazenado em um <i>Dataframe</i> e depois plotado pelo uso do <i>matplotlib</i>	120
Figura 33 - Exemplo da representação mioelétrica de um canal muscular ao ser armazenado em um <i>Dataframe</i> e depois plotado pelo uso do <i>matplotlib</i> , com o contraste da leitura real e a leitura da predição após o uso da LSTM	121
Figura 34 - Exemplo de arquivo de leitura de sinais mioelétricos de paciente armazenado em *. <i>fr</i> e aberto pelo software Notepad++®	125
Figura 35 - Exemplo de arquivo de leitura de sinais mioelétricos de paciente armazenado em alto nível *. <i>csv</i> e aberto pelo software MS Excel®	126
Figura 36 - Procedimento inicial de validação dos dados dos pacientes.....	127
Figura 37 - Épocas de treinamento da LSTM utilizando o Google Colaboratory®.....	128
Figura 38 - Comparação dos valores de perda no processo de treinamento do modelo.....	129
Figura 39 - Comparação dos valores de leitura mioelétrica de apenas um canal muscular sincronizada nos diferentes conjuntos de dados	134
Figura 40 - Comparação dos valores de leitura mioelétrica de apenas dois canais, sendo um canal muscular em conjunto do encoder, sincronizados nos diferentes conjuntos de dados..	135

LISTA DE QUADROS

Quadro 1 - Relação dos estudos encontrados por base de dados.....	28
Quadro 2 - Relação das questões de pesquisa que guiaram a revisão sistemática de literatura.....	28
Quadro 3 - Lista de resultados por autor, ano de publicação e título do trabalho	29
Quadro 4 - Categorização das informações encontradas nos estudos no que tangencia a aplicação de AI pelos autores	30
Quadro 5 - Relação sintética e de contraste dos resultados de tratamentos e terapias clínicas	32
Quadro 6 - Relação de estudos das que podem ser classificados dentro da Área da Saúde ou com o uso de Métodos e Técnicas de EC apresentados no PPGEGC/UFSC	40
Quadro 7 - Relação dos domínios de financiamento, apoio governamental, de formação e métricas da pesquisa de natureza científica básica e tecnológica aplicada	63
Quadro 8 - Requisitos do método proposto	69
Quadro 9 - Estrutura da coleta de dados.....	71
Quadro 10 - Código de conversão dos arquivos de dados binários das leituras de biosinais dos pacientes durante a utilização do cicloergômico assistido por FES	76
Quadro 11 - Síntese das classes, funcionalidades e relacionamentos do método voltado à predição de séries temporais em terapia individual muscular em SCI.....	95
Quadro 12 - Interrelação de técnicas, tecnologias e distintos elementos aplicados na instanciação do método	114
Quadro 13 - Estruturação do modelo <i>Sequential</i>	118
Quadro 14 - Relação entre os hiperparâmetros e suas implicações no contexto clínico e computacional.....	122
Quadro 15 - Hiperparâmetros da proposição do modelo e suas justificativas.....	133

LISTA DE TABELAS

Tabela 1 - <i>String</i> de busca aplicada para busca do estado da arte dentro das bases de dados..	27
Tabela 2 - Listagem de indivíduos envolvidos na pesquisa	81
Tabela 3 - Exemplo de relação de métricas entre RMSE, MAE e R^2	84
Tabela 4 - Exemplo de utilização na dimensão 1 (Canal 1)	101
Tabela 5 - Exemplo de <i>Dataframe</i> composto de doze agrupamentos musculares e do pedivela em suas leituras.....	107
Tabela 6 - Exemplo de representação após a aplicação do Escalador para normalizá-los com média e desvio padrão 1	107
Tabela 7 - Exemplo de conjunto de dados segmentados para treinamento	108
Tabela 8 - Exemplo de conjunto de dados segmentados para teste.....	108
Tabela 9 - Exemplo de arquivo CSV com medições, onde cada linha representa a observação do tempo e cada coluna uma característica de leitura mioelétrica diferente	109
Tabela 10 - Exemplo de normalização hipotética dos dados divididos em conjuntos de treinamento e teste	109
Tabela 11 - Processo de redução de erro de treinamento pelas épocas	110
Tabela 12 - Exemplo de conjunto de dados de treinamento, teste e previsões correspondentes	112
Tabela 13 - Exemplos de avaliação das métricas quando colocadas em contraste	120
Tabela 14 - Relação resumida de validações e diferentes testes de forma empírica ao modelo	121
Tabela 15 - Relação numérica entre as métricas MAE, MSE, RMSE e R^2 para os modelos onde há um canal e dois canais (canal muscular e <i>encoder</i>).....	136
Tabela 16 - Relação qualitativa entre as métricas MAE, MSE, RMSE e R^2 para os modelos onde há um canal e dois canais (canal muscular e <i>encoder</i>)	137

LISTA DE ABREVIATURAS E SIGLAS

- ACM – *Association for Computing Machinery*
- AHP – *Analytic Hierarchy Process*
- AI – *Artificial Intelligence*
- ANN – *Artificial Neural Network*
- API – *Application Programming Interface*
- ARAT – *Action Research Arm Test*
- ASCII – *American Standard Code for Information Interchange*
- AVC – *Acidente Vascular Cerebral*
- BCI – *Brain-Computer Interface*
- BMI – *Brain-Machine Interface*
- BPTT – *Backpropagation Through Time*
- CISC – *Complex Instruction Set Computer*
- CNN – *Convolutional Neural Network*
- CNS – *Conselho Nacional de Saúde*
- CPU – *Central Processing Unit*
- CS – *Cervical Spondylosis*
- CTS – *Carpal Tunnel Syndrome*
- CV – *Computer Vision*
- CWIS – *Cognitive Walkthrough for Implementation Strategies*
- DL – *Deep Learning*
- DNNs – *Deep Neural Networks*
- DS – *Design Science*
- DSR – *Design Science Research*
- DSRM – *Design Science Research Methodology*
- DSS – *Decision Support Systems*
- EC – *Engenharia do Conhecimento*

EcoG – *Electrocorticography*

EEG – *Electroencephalography*

EES – *Epidural Electrical Stimulation*

EMG – *Electromyography*

FES – *Functional Electrical Stimulation*

FIESC – *Federação das Indústrias do Estado de Santa Catarina*

FMA – *Fulg-Meyer Assessment*

GC – *Gestão do Conhecimento*

GPU – *Graphic Processing Unit*

IEEE – *Institute of Electrical and Electronics Engineers*

IoT – *Internet of Things*

ISMS – *Intramedullary Microstimulation*

KE – *Knowledge Extraction*

KM – *Knowledge Management*

LASSO – *Least Average Shrinkage and Selection Operator*

LEA – *Lightweight Encryption Algorithm*

LGPD – *Lei Geral de Proteção de Dados*

LSTM – *Long Short-Term Memory*

MAE – *Mean Squared Error*

MC – *Mídia do Conhecimento*

ML – *Machine Learning*

MRI – *Magnetic Resonance Imaging*

MS – *Ministério da Saúde*

MSE – *Mean Squared Error*

NaN – *Not a Number*

NLP – *Natural Language Processing*

NSE – *Eficiência de Nash-Sutcliffe*

PIB – *Produto Interno Bruto*

PPGEGC – Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento

PRISMA-P – *Preferred reporting items for systematic review and meta-analysis protocols*

R² – Coeficiente de Determinação

RBCI – *Robotic Brain-Computer Interface*

RMSE – *Root Mean Square Error*

RNN – *Recurrent Neural Network*

SCI – *Spinal Cord Injury*

SDR – *Service Design Research*

SENAI – Serviço Nacional de Aprendizagem Industrial

SoC – *System on a Chip*

SUS – Sistema Único de Saúde

TRM – Traumatismo Raquimedular

TS – *Time Series*

UFSC – Universidade Federal de Santa Catarina

UML – *Unified Modeling Language*

UniSENAI/SC – Centro Universitário SENAI Santa Catarina

WHO – *World Health Organization*

SUMÁRIO

1	INTRODUÇÃO	20
1.1	IDENTIFICAÇÃO DO PROBLEMA.....	22
1.2	OBJETIVOS.....	25
1.2.1	Objetivo Geral	25
1.2.2	Objetivos Específicos.....	25
1.3	JUSTIFICATIVA E RELEVÂNCIA DO TEMA.....	25
1.4	ORIGINALIDADE DA PESQUISA	26
1.4.1	Contribuições	35
1.5	ESCOPO DO TRABALHO	36
1.6	ADERÊNCIA DA TESE AO PPGEGC	36
1.6.1	Identidade.....	37
1.6.2	Contexto Estrutural do PPGEGC	38
1.6.3	Referências Factualis.....	39
1.7	ESTRUTURA DO TRABALHO	42
2	FUNDAMENTAÇÃO TEÓRICA.....	43
2.1	LESÃO NA COLUNA ESPINHAL	44
2.1.1	Tratamentos para Lesão na Coluna Espinhal	46
2.2	INTELIGÊNCIA ARTIFICIAL.....	48
2.2.1	Aprendizado de Máquina e Aprendizado de Profundo.....	50
2.3	ENGENHARIA BIOMÉDICA	53
2.3.1	Métodos de Extração de Conhecimento para tratamento de SCI	57
3.2	DESIGN SCIENCE RESEARCH METHODOLOGY.....	65
3.3	DESENVOLVIMENTO DA PESQUISA.....	67
3.3.1	Identificação do Problema e Motivação	68
3.3.2	Definição dos Objetivos para a Solução	69
3.3.3	Projeto e Desenvolvimento	70

3.3.4	Demonstração	81
3.3.5	Avaliação	82
3.3.6	Comunicação	85
3.4	SÍNTESE DA METODOLOGIA DA PESQUISA.....	85
4.1	REPRESENTAÇÃO ONTOLÓGICA DO MÉTODO	89
4.2	REPRESENTAÇÃO CONCEITUAL DO MÉTODO	93
4.2.1	Estrutura de Dados (<i>Dataframe</i>)	96
4.2.2	Escalador	96
4.2.3	Modelo de predição de séries temporais	98
4.2.4	Segmentação do Conjunto de Dados	100
4.2.5	Processo de Treinamento	101
4.2.6	Processo de Avaliação	102
4.2.7	Processo de Predição	103
4.2.8	Processo de Visualização	104
4.3	INSTANCIAMENTO DO MÉTODO PROPOSTO.....	104
4.3.1	Preparação de Dados	106
4.3.2	Treinamento do Modelo	108
4.3.3	Avaliação do Modelo	110
4.3.4	Predição	112
4.4	SÍNTESE DO CAPÍTULO	113
5.1	PREPARAÇÃO DE DADOS	115
5.2	TREINAMENTO DO MODELO	116
5.3	AVALIAÇÃO DO MODELO, VISUALIZAÇÃO E PREDIÇÃO	119
5.4	SÍNTESE DO CAPÍTULO	122
6.1	ANÁLISE DA PRECISÃO.....	124
6.1.1	Preparação dos Dados	124
6.1.2	Seleção, Transformação e Segmentação de Dados	127

6.1.3	Configuração do Modelo de Aprendizado	130
6.2	ANÁLISE QUALITATIVA E EXPLICITAÇÃO DO CONHECIMENTO	133
6.3	SÍNTESE DO CAPÍTULO	138
7.1	CONCLUSÕES.....	140
7.2	PERSPECTIVAS DE TRABALHOS FUTUROS.....	142

1 INTRODUÇÃO

A aplicação de alternativas terapêuticas na área da saúde tem sido uma das tarefas tecnológicas mais difíceis, seja pela complexidade do corpo humano ou por questões éticas, especialmente para enfrentar condições complexas, como a de Lesão Medular (do inglês *Spinal Cord Injury* - SCI). A Organização Mundial da Saúde (do inglês *World Health Organization* - WHO) descreve a SCI como uma condição que impacta a vida do paciente e das pessoas ao seu redor em nível multidisciplinar, afetando áreas de funções físicas e mentais (EHRMANN et al., 2020). Com cerca de 10.000 acidentes por ano apenas nos Estados Unidos, o resultado mais comum de SCI é a perda de massa muscular devido à inatividade, que é agravada pelo envelhecimento via sarcopenia (PISOTTA; PERRUCHOUD; IONTA, 2015).

As SCIs, segundo Lilley *et al.* (2020), causam perda da função sensorial e motora, bem como outros distúrbios, como disfunção sexual, disfunção da bexiga e do intestino, infecções, dor crônica e problemas cardíacos e respiratórios. Na pesquisa coloca-se que as escolhas terapêuticas humanas são limitadas, com ênfase maioritariamente na terapia adaptativa e reabilitação, bem como na gestão de problemas subsequentes.

Nesse processo multifatorial, que é causado por eventos traumáticos celulares locais, seguidos por processos reativos subsequentes como a isquemia, inflamação, edema, morte celular, degeneração axonal, gliose e desenvolvimento de tecido cicatricial. Geralmente, se relacionando a uma falha na regeneração das fibras nervosas resultante de danos cerebrais (LAI *et al.*, 2021).

Por isso, Pisotta, Perruchoud e Ionta (2015) em seu estudo delineiam os principais tratamentos para anormalidades sensório-motoras:

- Tratamento cirúrgico: ajuda a diminuir as deficiências funcionais e aumentam a independência da mobilidade, mas, por serem intrusivos, são menos transferíveis para situações da vida cotidiana do que soluções alternativas.
- O tratamento farmacêutico: utilizado para intervir na dor e no clônus, costuma trazer alívio dos sintomas, mas com eficácia controversa a longo prazo.
- Tratamento fisioterapêutico: focado em evitar a hipotrofia muscular através de sessões de movimentos passivos. Esse tipo de tratamento apresenta benefícios gerais, mas é afetado por limitações relacionadas à especificidade da tarefa, complexidade, consumo de tempo e dependência de especialização. Outro problema é a dificuldade de mensurar com precisão a melhora sensório-motora para equilibrar com que frequência a assistência é prestada devido à evolução contínua do paciente.

Conquanto, os profissionais de saúde coletam informações sobre os sensores mioelétricos do paciente durante a terapia a partir de medições eletromiográficas, de forma invasiva ou não invasiva, para tradução em interfaces cérebro-máquina (do inglês *Brain-Machine Interface* – BMI). Os avanços tecnológicos dos últimos anos trouxeram ganhos na reabilitação automatizada, com foco específico na repetibilidade e quantificação, onde o treinamento assistido por robôs resultou em recuperação mais precisa e duradoura das habilidades sensório-motoras dos pacientes (POPOVIC *et al.*, 2000).

Nessa linha, vetores catalíticos de terapias alternativas nas áreas fisioterapêutica e médica surgem como resultado da aplicação de tecnologias da 4ª Revolução Industrial, como o uso de Inteligência Artificial (do inglês *Artificial Intelligence* - AI) para manipulação da BMI (LAI *et al.*, 2021). Essa revolução, também conhecida como Indústria 4.0, trata-se da aplicação dos sistemas ciberconectados, habilitando que os dispositivos troquem informações. Baseia-se na integração das tecnologias de informação e comunicação, o que possibilita o desenvolvimento de novas estratégias e modelos (PIANA *et al.*, 2022).

A AI é uma das áreas que têm o potencial de melhorar as abordagens de saúde, aumentando a capacidade humana em colaboração com o computador e seus outros sistemas, por meio da aplicação de técnicas que aumentam a efetividade na tomada de decisão sob determinada situação clínica do paciente (KAHILE *et al.*, 2010).

Ela pode combinar tecnologias de propósito geral em todos os campos do conhecimento humano ao mesmo tempo, a fim de aplicar técnicas computacionais, matemáticas, mecânicas, lógicas e até biológicas para entender, associar, e descrever, a fim de processar vastos conjuntos de dados usando algoritmos de suporte a processos cognitivos humanos (KAHILE *et al.*, 2020; ROMPAEY *et al.*, 2022).

Destas tecnologias, torna-se possível colaborar com *software*, *hardware*, sensores e atuadores também via redes de Internet das Coisas (do inglês *Internet of Things* - IoT) e interagir via AI (ROMPAEY *et al.*, 2022), oferecendo inspiração para melhores tratamentos terapêuticos orquestrados pelos profissionais da área da saúde (LAI *et al.*, 2021).

Portanto, frente aos mais diversos cenários enfrentados pelos profissionais da área da saúde e pacientes, torna-se notório o uso de ferramentas tecnológicas que tenham a capacidade de alavancar o processo de avaliação dos especialistas em suas habilidades, trazendo a condição de maximização cognitiva, para uma diagnose mais assertiva e ágil, apoiada em sistemas (DILLEN *et al.*, 2022).

Com isso, o Aprendizado Profundo (do inglês *Deep Learning* - DL), tem se mostrado uma boa alternativa para realizar ações de decodificação de sistemas de controle de biosinais,

permitindo a construção de modelos de Aprendizado de Máquina (do inglês *Machine Learning* – ML), facilitando processos subsequentes de processamento de dados para predição de valores em modelos treinados, com potencial para implementação de melhorias nas terapias (DILLEN *et al.*, 2022).

1.1 IDENTIFICAÇÃO DO PROBLEMA


Cada vez mais, à medida de que as pessoas adotam um estilo de vida pouco saudável, a quantidade de indivíduos que precisam de fisioterapia no mundo vem aumentando, de forma a corroborar com o aparecimento de patologias, bem como quadros agravados oriundos dos traumas físicos que pessoas podem sofrer em seu cotidiano tornando-as debilitadas (KAHILE *et al.*, 2021). Por exemplo, a Espondilose Cervical (do inglês *Cervical Spondylosis* - CS), que representa uma das condições de desordem degenerativa de saúde, demandando cuidados fisioterapêuticos que podem acometer boa parte de toda população mundial até o final de sua vida, afetando sua saúde física e mental-psíquica (WANG *et al.*, 2018).

Habitualmente, antes de qualquer intervenção terapêutica, os profissionais da área da saúde costumam desenvolver análises a partir da condução de avaliação da atual condição dos pacientes. Para isso, um dos protocolos costuma iniciar pela avaliação dos diferentes domínios em que a SCI possa afetar, como na qualidade do sono, disfunção digestória (*bowel dysfunction*), na bexiga (*bladder dysfunction*), na vida sexual, no encurtamento permanente de músculos e ligamentos, na espasticidade, em úlceras de pressão, em problemas respiratórios e circulatórios, em infecções no trato urinário e dor em geral, bem como em diversos outros domínios, em que o(a) paciente é submetido(a) as heurísticas e *self-surveys* (InSCI survey, 2019).

De posse dos dados iniciais de questionários, evolui-se para fase laboratorial, onde são conduzidas as avaliações mioelétricas, comumente observando a atividade cerebral nos tecidos do(a) paciente de forma invasiva, através da eletrocorticografia (do inglês *Electrocorticography* - ECoG) ou não-invasiva, como a eletromiografia (do inglês *Electromyography* – EMG) ou eletroencefalografia (do inglês *Electroencephalography* - EEG) (LAI *et al.*, 2021; PISOTTA; PERRUCHOUD; IONTA, 2015), que buscam trazer medições analógico-digitais dos impulsos nervosos, conforme ilustra a Figura 1. Todos esses elementos precisam ser entendidos para uma avaliação clínica mais precisa, conectando com a visão, compreensão e experiência global do profissional para tomada de decisões assertivas (EHRMANN *et al.*, 2020)

Em âmbito fisioterapêutico, onde um dos principais elementos avaliados enfoca no movimento dos membros, a técnica de eletroestimulação funcional (do inglês *Functional Electrical Stimulation* - FES) também costuma ser aplicada para devolver movimento aos desabilitados. Deste modo, com a aplicação de técnicas computacionais, como com a aplicação de redes neurais computacionais, torna-se uma opção para um controle mais acurado de movimentos musculares (LI *et al.*, 2017).

Figura 1 - Proposta de modelo experimental de eletroestimulação funcional



Fonte: Li *et al.* (2017)

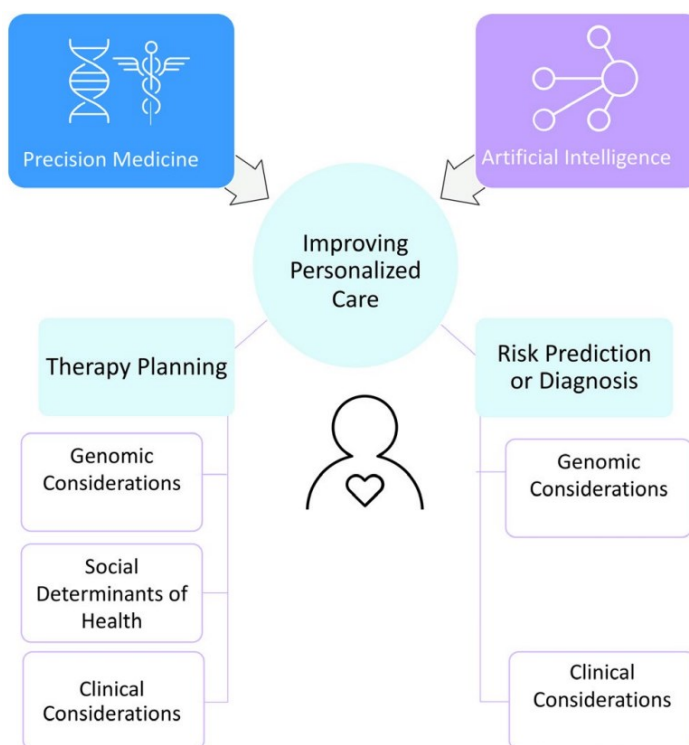
A medição das atividades cerebrais é uma tarefa complexa que leva em consideração uma quantidade elevada de elementos que, em conjunto, devem ser traduzidos pela máquina. Idealmente, quando os dados cerebrais são captados, devem passar por um algoritmo de pré-processamento, para que, com métodos de regressão ou classificação possam ser utilizados e aplicados adequadamente (DILLEN *et al.*, 2022).

Não obstante, o volume da análise de dados clínicos atuais pode em breve levar a cognição e tomada de decisão humana às suas limitações naturais, exigindo o uso de dispositivos físicos e/ou lógicos que tragam melhorias cognitivas na forma de cooperação com sistemas de AI que tenham como objetivo incrementar a capacidade humana de entender as condições globais do paciente (KAHILE *et al.*, 2021).

No contexto de AI e ML para saúde, o DL, é uma das técnicas que possui destaque, pois apresenta alto desempenho em aplicações que tenham pré-requisitos de processamento de grandes cargas de dados (WEN *et al.*, 2021). Sua utilização pode ocorrer através do uso de técnicas, como as Redes Neurais Artificiais (do inglês *Artificial Neural Network* - ANN). As

ANNs possuem a habilidade de generalizar informações distintas em modelos de treinamento para problemas que precisam de solução (DILLEN *et al.*, 2022). Com isso, áreas da saúde, como a Medicina é potencializada, facilitando o diagnóstico e o prognóstico através de recomendações médicas personalizadas, conforme consta na Figura 2 (JOHNSON *et al.*, 2020).

Figura 2 - Dimensões da sinergia entre técnicas de AI e a prognose e diagnose médica



Fonte: Johnson *et al.* (2020)

Frente a isso, cada vez mais se percebe a utilização das tecnologias de Interfaces Cérebro-Computador (do inglês *Brain-Computer Interface* - BCI) e técnicas de AI e ML, podendo assim, propiciar condições favoráveis para os quadros leves e severos de tratamentos e intervenções clínicas em pacientes, seja mitigando a perda de informações sensíveis e importantes para tomada de decisão, determinando a previsão de risco em larga escala, ou mesmo, agilizando a tomada de decisão e ação por parte dos profissionais da área da saúde (WANG *et al.*, 2018; LAI *et al.*; OOKA *et al.* 2021).

Com base neste contexto, foi elencada a pergunta de pesquisa, sendo: “Como auxiliar no tratamento fisioterapêutico de lesão medular utilizando dados de eletroestimulação funcional e a individualidade do paciente?”.

1.2 OBJETIVOS

Dentro desta seção são apresentados os objetivos geral e específicos para compreensão da estrutura desta dissertação na busca dos resultados.

1.2.1 Objetivo Geral

O objetivo geral deste trabalho consiste em propor um método voltado ao tratamento de pacientes clínicos fisioterapêuticos, em especial àqueles que sofrem de Lesão na Coluna Espinhal, utilizando-se de métodos e técnicas de Engenharia do Conhecimento e Computacionais para avaliação e recomendação de terapias clínicas.

1.2.2 Objetivos Específicos

- Elencar uma lista de parâmetros voltada ao desenvolvimento de BMIs para atuar em sinergia com a obtenção de sinais mioelétricos.
- Produzir um roteiro de coleta, armazenamento e utilização de dados operacionais para análise estatística e classificatória.
- Desenvolver um modelo de predição para a análise de biosinais que possa ser associado às terapias de FES.

1.3 JUSTIFICATIVA E RELEVÂNCIA DO TEMA

Frente a inversão da pirâmide populacional, cada vez mais pessoas chegarão aos estágios mais avançados de idade, podendo possuir fragilidades que possam aumentar a demanda por tratamentos de saúde (PARUCKER; IOCCA ASSUNÇÃO; DE OLIVEIRA, 2022). Não obstante, com o dimensionamento e contraste de dados que advém da avaliação do estilo de vida das pessoas, envolvendo por exemplo, a baixa prática de exercícios e sedentarismo (PEREIRA; FRANCISCHI; LANCHETA JR, 2003.), bem como hábitos nutricionais, surgem vetores catalisadores para compor uma nova cartela de elementos que exijam a dependência dos indivíduos aos serviços de saúde, com forte tendência ao aumento da demanda por terapias clínicas especializadas (MACEDO; FREITAS; SCHEICHER, 2014).

Pela avaliação do estado da arte atual de soluções biomédicas e de engenharia, pode-se obter diversos tipos de mecanismos para aplicação em pacientes, especialmente quando se

trata da reabilitação sensor-motora, promovendo diferentes desafios para incorporação de BMIs para *feedback* e aplicação nas atividades diárias, compondo obstáculos à serem superados (PISOTTA; PERRUCHOUD; IONTA, 2015).

Conforme discutido por Popovic *et al.* (2000), ao examinar cenários onde BMIs podem ser integradas com a FES na fisioterapia, surge a possibilidade de sua aplicação em sistemas híbridos, especialmente benéficos na recuperação de movimentos complexos. Esta abordagem tem um potencial particular para ajudar aqueles que enfrentam paralisia total dos membros inferiores, visando a restauração de seus movimentos. Embora existam desafios na integração de um sistema de controle hierárquico híbrido para reflexos artificiais e FES, o objetivo de criar sistemas que possam ser incorporados ao cotidiano do paciente sem causar inconvenientes torna-se promissor.

A tradução dos sinais cerebrais pelos profissionais, mesmo que amparada por diferentes dispositivos tecnológicos, nem sempre é uma tarefa fácil, tornando-se fundamental a aplicação de algoritmos que auxiliem no processamento e síntese de conhecimento, como com o uso de ANNs, que possam apoiar a sincronização e a resposta dos sistemas usados junto aos pacientes, estimando com maior precisão a ação dos atuadores pela leitura dos sensores. Isso pode ser calibrado pela adaptação do próprio algoritmo pela retroalimentação e dinâmicas da leitura de atividade neuronal, com trajetórias de ângulo de andar/marcha (*gait-pattern*), posição, força e torque, conduzindo à evidências sólidas da utilização da tecnologia para reabilitação através da neuroplasticidade (JEZERNIK *et al.*, 2003; ROBINSON *et al.*, 2021).

Neste campo interdisciplinar da tecnologia, em especial no que tange as diferentes opções de terapias que podem ser escolhidas para o tratamento dos pacientes com SCI, os profissionais deparam-se em embates que podem ser contornados mediante aplicação da tecnologia em favor da maximização cognitiva, bem como de informações reais e fidedignas que possam ser processadas em tempo real pela máquina em prol de um tratamento mais assertivo. Com isso, torna-se notório que os profissionais da área da saúde possam apoiar sua tomada de decisão clínica com a análise de diagnóstico e predição fornecida por sistemas inteligentes, em especial àqueles que possuem sistemas de AI (KAHILE *et al.*, 2021).

1.4 ORIGINALIDADE DA PESQUISA

Essa pesquisa visa promover a comparação de diferentes sistemas, modelos, *frameworks*, algoritmos, sistemas e práticas, propondo uma síntese holística e aplicada,

dispondo de contraste frente aos diferentes desafios de tratamentos de pacientes com SCI, com a proposição de um método integrativo que apoie o tratamento clínico.

Neste estudo a *Design Science Research Metodology* (DSRM) e *Data Science* (DS) foram implementadas na fase de obtenção de dados e fontes de pesquisa, visando fornecer uma estrutura robusta. Também adiante no Capítulo 3, especificamente nas seções 3.1 e 3.2, podem ser verificados os preceitos metodológicos aplicados estruturalmente e sistematicamente para ilustrar desde a identificação do problema até as etapas de demonstração, avaliação e comunicação dos resultados.

Assim, para compreender o estado atual da pesquisa no campo em questão, este estudo utilizou uma Revisão Sistemática baseada no Protocolo PRISMA-P (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), que é um método estruturado para coletar e avaliar informações de pesquisas existentes. A explicitação do protocolo seguindo os preceitos está documentado no Apêndice D.

A seleção dos estudos envolvidos neste processo foi realizada em três fases distintas por dois revisores independentes. Na primeira fase, uma sentença de busca pré-definida foi aplicada em diversos bancos de dados em 20 de novembro de 2022. Esta busca foi realizada sem restrições de idioma, data ou formato de publicação, garantindo assim uma ampla coleta de informações relevantes. Os resultados obtidos foram então filtrados exclusivamente com base nesta sentença de busca.

A sentença (*string*) de busca foi genérica e aderente à pesquisa por tecnologias e terminologias aderentes às proposições baseadas em técnicas de AI para fisioterapia, em especial na comunhão ao *hardware*, como com BMIs e na aplicação de SCI (Tabela 1).

Tabela 1 - *String* de busca aplicada para busca do estado da arte dentro das bases de dados

("Artificial Intelligence" OR "Machine Learning") AND ("Spinal Cord Injury" OR "SCI" OR "Mioelectric") AND ("physiotherapy") AND ("System")

Fonte: Elaborado pelo autor (2023)

As bases de conhecimento foram prioritariamente escolhidas de acordo com sua relevância científica para retorno de periódicos dentro da área da saúde e tecnologia, sendo elas Science Direct[®], ACM Digital Library[®], IEEE Xplore[®], SCIELO BR[®], Web of Science[®], PUBMED[®] e COCHRANE[®]. Utilizando a plataforma *online* Rayyan[®], foram importadas as referências dos bancos de dados (Quadro 1).

Quadro 1 - Relação dos estudos encontrados por base de dados

Database	Endereço web	Resultados
Science Direct®	https://www.sciencedirect.com/	75
ACM Digital Library®	https://dl.acm.org/	5
IEEE®	https://ieeexplore.ieee.org/	0
SCIELO BR®	http://www.scielo.org/	0
Web of Science®	https://www.webofscience.com/	84
PUBMED®	https://pubmed.ncbi.nlm.nih.gov/	0
COCHRANE®	https://www.cochranelibrary.com/en/	0

Fonte: Elaborado pelo autor (2023)

Na segunda fase, ambos os revisores leram independentemente os títulos e resumos (*blind-on*) e aplicaram critérios de elegibilidade relacionados aos objetivos do estudo (Quadro 2).

Quadro 2 - Relação das questões de pesquisa que guiaram a revisão sistemática de literatura

ID	Questão de Pesquisa	Principal motivação
QP1	Que pesquisas foram publicadas abordando os tópicos de AI para tratamento de SCI?	Identificar quais estudos focam o uso terapêutico de tecnologias de AI e quais avanços tecnológicos foram promovidos.
QP2	Quais são os impactos desses estudos na pesquisa e na prática de campo para o tratamento de pacientes com SCI?	Avaliar em quais situações as terapias são favoráveis, bem como seus benefícios e desvantagens percebidos pelos especialistas.
QP3	Os estudos levam em conta ou mencionam a ética, a regulamentação ou gestão do conhecimento no tratamento dos dados do paciente?	Identificar se os estudos possuem prerrogativas de avaliação quanto ao uso de informações do paciente com uso tecnológico de AI, se estão em conformidade com as normas e exigências legais, avaliar também a privacidade de dados sensíveis e gestão do conhecimento.

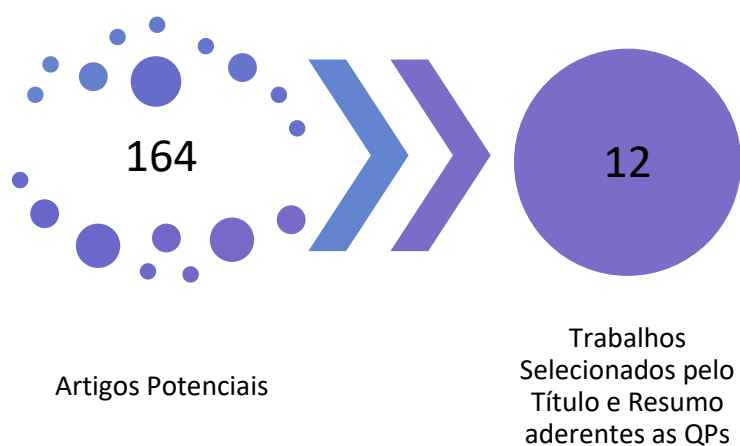
Fonte: Elaborado pelo autor (2023)

Na terceira fase, os mesmos dois revisores leram os estudos completos. Todas as informações recuperadas foram verificadas por um terceiro revisor, sendo que neste estudo foram avaliadas perspectivas abrangentes do estado atual da arte, avaliando tendências, implicações e desafios no contexto do tratamento de SCI utilizando tecnologias de AI, com

atenção a menção ética, regulatória ou de gestão do conhecimento e de dados de tratamento e/ou dos pacientes.

No processo promovido pelos revisores, a busca inicial identificou 164 referências, que, após o procedimento de avaliação inicial por título e resumo, bem como da aderência às três QPs, resultou em 12 estudos (7,3% do total), conforme mostrado na Figura 3. Os procedimentos de busca adotados em cada banco de dados não tiveram qualquer tipo de restrição às referências que pudesse limitar por tipo, ou em exclusão de artigos completos, capítulos, livros, teses, artigos de revisão, entre outros; assim, todas as obras foram incluídas.

Figura 3 - Processo de seleção de trabalhos



Fonte: Elaborado pelo autor (2023)

Numa análise dos diferentes aspectos e características dos estudos de forma a avaliar todos os artigos a fim de obter suas principais contribuições, pode ser observada a partir da Quadro 3 a relação dos resultados indicados pelo(s) autor(es), ano de publicação e título do trabalho.

Quadro 3 - Lista de resultados por autor, ano de publicação e título do trabalho

ID	Author	Title
1	Dillen; Arnau <i>et al.</i> (2022)	<i>Deep learning for biosignal control: insights from basic to real-time methods with recommendations</i>
2	Van Rompaey Jønsson e Elmose Jørgensen (2022)	<i>Designing lawful machine behavior: Roboticians' legal concerns</i>
3	Kahile <i>et al.</i> (2021)	<i>Artificial Intelligence (AI) and Machine Learning (ML) in Clinical Practice and Physiotherapy</i>
4	Robinson Mane Chouhan e Guan (2021)	<i>Emerging trends in BCI-robotics for motor control and rehabilitation</i>
5	Lai <i>et al.</i> (2021)	<i>Stem cell-derived neuronal relay strategies and functional electrical stimulation for treatment of spinal cord injury</i>
6	Ehrmann <i>et al.</i> (2020)	<i>Describing Functioning in People Living With Spinal Cord Injury</i>

		<i>Across 22 Countries: A Graphical Modeling Approach</i>
7	Lilley <i>et al.</i> (2020)	<i>Refining rodent models of spinal cord injury</i>
8	Wang <i>et al.</i> (2018)	<i>A Convenient Non-harm Cervical Spondylosis Intelligent Identity method based on Machine Learning</i>
9	Pisotta, Perruchoud e Ionta (2015)	<i>Hand-in-hand advances in biomedical engineering and sensorimotor restoration</i>
10	Walsh <i>et al.</i> (2006)	<i>Marker-based monitoring of seated spinal posture using a calibrated single-variable threshold model</i>
11	Jezernik; Sašo (2003)	<i>Robotic Orthosis Lokomat: A Rehabilitation and Research Tool</i>
12	Popovic, Sinkjær e Thomas (2000)	<i>Improved Control for Functional Electrical Stimulation to Restore Walking</i>

Fonte: Elaborado pelo autor (2023)

A compreensão obtida com a leitura dos trabalhos foi descrita na síntese das informações inseridas no Quadro 4, que categoriza as informações de acordo com abordagens propostas pelos autores para explicitar e relacionar modelos ou proposições de ferramentas de AI.

Quadro 4 - Categorização das informações encontradas nos estudos no que tangencia a aplicação de AI pelos autores

ID	Tecnologia de AI
1	O foco deste trabalho sugere diferentes métodos e desafios para a interação cibernética de interfaces entre computador e aquisição de biosinais. Uma avaliação sistemática no formato PRISMA-P é promovida, considerando critérios de inclusão para estudos que utilizam modelos de Deep Learning, bem como a exigência de que esses tenham sido validados em condições práticas de aplicação no mundo real. Os autores propõem um pipeline de DL onde o sinal neurológico é adquirido por meio de leitura digital e, em seguida, submetido a pré-processamento, o que leva a duas possíveis trajetórias para o movimento do controlador, ou seja, 1. Classificação (submetida a um controlador de alto nível) ou 2. Regressão (mapeada diretamente para o estado do dispositivo). Nesse sentido, eles enfatizam que a integração de sistemas é o maior desafio no projeto dessas soluções.
2	Este artigo aborda os desafios enfrentados pela questão legal, levantando preocupações sobre o comportamento das máquinas e os artefatos de software. Os autores consideram uma análise da etimologia utilizada em conformidade e legislação necessária, caracterizando-a como uma vulnerabilidade nos desafios regulatórios da Inteligência Artificial e Robótica. Também é sugerido que, em termos de processos de produção, a engenharia prioriza funcionalidades tecnológicas em detrimento da segurança.
3	Este trabalho destaca que os sistemas geram um volume incrível de dados que não podem ser processados ou investigados, indicando que as tecnologias de AI são fundamentais para aumentar as habilidades cognitivas dos profissionais de fisioterapia em benefício de uma melhor análise para tomada de decisão.
4	O estudo aborda o uso de Redes Neurais Profundas (do inglês <i>Deep Neural Networks - DNNs</i>) para suportar BCIs, Exoesqueletos e Braços Protéticos. Dispositivos vestíveis são combinados com métodos invasivos e não invasivos para aquisição de dados cerebrais e Aprendizado de Máquina para avaliação clínica.
5	Este estudo relata o uso da Estimulação Elétrica Peridural (do inglês <i>Epidural Electrical Stimulation-EES</i>), capaz de modular a rede neural proprioespinal. Essas interfaces cérebro-medula têm o potencial de servir como uma AI. Outra abordagem é a microestimulação intramedular (do inglês <i>Intramedullary Microstimulation - ISMS</i>), que difere da EES por fornecer o sinal elétrico por meio de microeletrodos implantados na medula espinal. Seu uso é raro em humanos, mas experimentos com animais relatam benefícios potenciais dessa abordagem.
6	LASSO (<i>Least Average Shrinkage and Selection Operator</i>) é uma das várias abordagens de ML destacadas no estudo para identificar dependência condicional entre duas variáveis com dados binários.

	Tem mostrado fornecer resultados estáveis na identificação de associações entre variáveis aleatórias. Os dados foram analisados utilizando o <i>software</i> R. Em casos com respostas ausentes, a técnica de <i>Random Forest</i> foi adotada.
7	Neste estudo, um modelo <i>in-silico</i> ¹ é definido que pode ser associado a abordagens de ML para prever melhor os resultados experimentais em humanos, reduzindo assim o uso e o sofrimento de animais. Os autores também destacam a importância de um banco de dados mundial de pesquisa em SCI para utilizar técnicas de Big Data e compreender melhor os mecanismos subjacentes da recuperação em diferentes espécies, aumentando o potencial de tradução clínica bem-sucedida. Eles sugerem que os resultados permitiriam a padronização da seleção e implementação de modelos pré-clínicos.
8	Neste trabalho, a abordagem da tecnologia de AI é realizada por meio de um modelo denominado <i>EasiAI</i> , que é sugerido em sua proposta por uma estrutura de processamento de dados em três camadas: 1. Extração de características; 2. Seleção de características; e 3. Algoritmo de classificação. O algoritmo de extração de características é aplicado com o objetivo de obter a leitura dos sinais digitais do usuário. O algoritmo de seleção de características chamado <i>EasiRF</i> utiliza Random Forest para selecionar as características mais relevantes. O algoritmo de classificação é baseado em árvores de regressão impulsionadas por gradiente para identificar a Síndrome do Túnel do Carpo (do inglês <i>Carpal Tunnel Syndrome - CTS</i>) e produzir relatórios para os usuários. Esses algoritmos são leves e podem ser integrados ao dispositivo do usuário para gerar relatórios rapidamente e sem comprometer a privacidade. Os autores também sugerem métricas de avaliação de desempenho para o modelo, como acurácia, sensibilidade, especificidade, FNR, FPR e AUC (área sob a curva de sensibilidade e especificidade).
9	De acordo com os autores, o método invasivo oferece uma qualidade de sinal superior em comparação com o método não invasivo na captura de atividades neurais. No entanto, eles relatam que é possível melhorar o sinal coletado pelo método não invasivo usando algoritmos adaptativos durante o treinamento. Uma maneira de implementar o <i>feedback</i> sensorial em futuras BCIs é combinar novos algoritmos capazes de converter a atividade neural em comandos motores específicos e tornar os dispositivos capazes de refletir a interação complexa entre diferentes mecanorreceptores.
10	Os pesquisadores utilizaram um algoritmo de ML chamado J48, baseado em árvores de decisão, para classificar os dados coletados a partir de vetores de flexão postural, com o objetivo principal de identificar a forma mais simples e precisa de medir a postura dos usuários. Como resultado, o vetor de flexão geral foi identificado como o melhor indicador de postura, capaz de fornecer 100% de precisão na validação cruzada para todos os sujeitos testados. Após a identificação do limiar, o modelo de aprendizado de máquina não foi mais necessário no trabalho proposto e um método de análise visual foi utilizado para avaliar os dados coletados.
11	O trabalho aborda o desenvolvimento de uma arquitetura de ANN para simular o circuito locomotor espinhal, com base na programação do modelo com um gerador de padrões centrais. Para isso, os pesquisadores incluíram elementos que favorecem a coordenação dos osciladores da articulação do quadril com o apoio de interneurônios motores. O modelo foi testado em conjunto com o <i>Lokomat</i> , que é um exoesqueleto altamente avançado amplamente disponível na área médica e de fisioterapia, que pode ser acoplado a um paciente imobilizado por danos no sistema nervoso para auxiliar no processo de caminhada. O <i>Lokomat</i> atuou como controlador para obter informações dos sensores de força e posição. A arquitetura de ANN também foi aplicada utilizando o <i>Simulink</i> , que é um software desenvolvido pela <i>MathWorks</i> , como ferramenta para modelagem gráfica, simulação e análise de sistemas dinâmicos, em conjunto com o MATLAB, para suportar o modelo neural espinhal.
12	O artigo não especifica em termos de linguagem ou tecnologia, fornecendo apenas <i>insights</i> sobre a importância de se analisar os dados do paciente para a produção de sistemas de reflexo artificial, visando melhorar terapias biomecânicas e a qualidade de vida individualizada do paciente. De modo geral, avalia as circunstâncias de controladores híbridos que dependem de regras sob sensores e atuadores para estimulação elétrica funcional.

Fonte: Elaborado pelo autor (2023)

Os estudos apresentados oferecem um panorama abrangente das aplicações e considerações em diversas áreas, explorando a intersecção e interfaceamento da AI com

¹ O termo "*in-silico*" refere-se a modelos computacionais que investigam hipóteses clínicas utilizando ferramentas como bancos de dados, *software* de análise e mineração de dados, modelos de homologia, aprendizado de máquina, farmacóforos, relações quantitativas estrutura-atividade e ferramentas de análise de redes, entre outras.

biosinais, a interpretação de sinais neurológicos e a união com interfaces cibernéticas, bem como dilemas éticos e regulatórios relacionados ao comportamento das máquinas. Esses estudos específicos mergulham na aplicação prática da AI na fisioterapia, utilizando métodos inovadores para análise de dados e reabilitação, porém nenhum dos estudos apresentaram métodos expressivos para o tratamento de pessoas com lesão na coluna espinhal. É notável que a partir dessas informações e estudos em conjunto, destaca-se a promissora e possível contínua contribuição da AI para avanços tecnológicos futuros, desafios éticos do uso da tecnologia e melhorias em cuidados de saúde da população em geral. No Quadro 5, é abordado o contexto de tratamento para SCI.

Quadro 5 - Relação sintética e de contraste dos resultados de tratamentos e terapias clínicas

ID	Resultados de tratamento
1	Os resultados avaliados pelos autores apresentam vários avanços promissores no uso da decodificação de biosinais por meio de DL, tornando-se uma alternativa viável aos tratamentos tradicionais, especialmente no que diz respeito ao uso de sistemas robóticos em contraste com os operados manualmente. Os pesquisadores também destacam que um dos principais desafios é o nível de sensoriamento, pois existem várias opções disponíveis comercialmente no mercado que não são confiáveis para aplicações médicas. Além disso, eles sinalizam que há pouca padronização dos protocolos de avaliação de protótipos que compararam o desempenho do sistema.
2	Engenheiros que fabricam robôs de diversas áreas foram questionados sobre a conscientização legal e ética desses robôs em relação a diversos aspectos do uso da AI, especialmente quanto ao uso de <i>cobots</i> , que são robôs colaborativos, e a análise de segurança promovida para a tecnologia. Eles avaliam o entendimento da segurança e dos riscos envolvidos no uso de AI nos diferentes níveis de posições organizacionais e domínios do conhecimento, como <i>healthcare</i> , colocando a importância da adequada análise e projeto antes da aplicação da tecnologia em um modelo de análise de <i>compliance</i> para dados. Os autores defendem que a tecnologia não seja utilizada sem que antes seja dada atenção as devidas questões legais aplicáveis, tornando seu modelo genérico para uso geral em AI.
3	O foco deste estudo abrange a fisioterapia e os estudos clínicos de forma geral, sem restringir a aplicação exclusivamente à lesão medular.
4	O estudo sugere a aplicação de DNNs para apoiar BCIs em combinação com exoesqueletos, braços protéticos e dispositivos vestíveis para auxiliar na reabilitação de pacientes. Em testes clínicos que propuseram a adição de Interfaces Robóticas Cérebro-Computador (do inglês <i>Robotic Brain-Computer Interface - RBCI</i>) aos tratamentos clínicos, os pacientes foram avaliados sob o contraste das metodologias de Avaliação Fugl-Meyer (do inglês <i>Fulg-Meyer Assessment - FMA</i>) ² e Teste de Braço de Pesquisa de Ação (do inglês <i>Action Research Arm Test - ARAT</i>) ³ , com ganhos e incrementos percebidos em feedback positivo da intervenção. Os pesquisadores também avaliaram cenários de conectividade do sistema, tanto <i>online</i> quanto <i>offline</i> , obtendo ganhos robustos nos padrões de caminhada. Além disso, o estudo expõe um contraste entre o uso de métodos invasivos e não invasivos para aquisição de dados cerebrais, processamento e categorização de acordo com as características desejadas, e em seguida, classificação e uso de ML, permitindo assim estratégias de controle diretas e discretas para BCIs (Assistivas e Reabilitativas).
5	Embora tenha havido uma boa resposta ao tratamento usando EES, alguns desafios devem ser considerados, como a possibilidade de registrar uma pequena quantidade de atividade cerebral nos pacientes, risco de infecção, possibilidade de causar respostas imunes locais e induzir a formação de

² FMA, também conhecida como Escala de Avaliação Fugl-Meyer (do inglês *Fulg-Meyer Assessment Scale FMAS*), foi desenvolvida e introduzida em 1975 por Fugl-Meyer. Essa escala foi o primeiro instrumento quantitativo para medição sensorio-motora da recuperação pós-AVC.

³ O ARAT foi criado para avaliar a recuperação da função do membro superior após lesões corticais, e recomenda-se seu uso combinado com as avaliações da FMA.

	cicatrizes gliais ao redor do eletrodo. Portanto, existe a possibilidade de uma eficácia reduzida do sistema de interface cérebro-medula espinhal. Embora essa interface transmita com sucesso os sinais nervosos motores do cérebro para a medula espinhal, a primeira geração desses sistemas não consegue enviar os sinais nervosos sensoriais de pacientes paralisados de volta ao cérebro.
6	De acordo com o estudo, os principais problemas funcionais estavam relacionados a indivíduos idosos com tetraplegia completa ou lesões de longo prazo. Os maiores problemas de independência na realização de atividades foram registrados em países com menor renda <i>per capita</i> (PIB <i>per capita</i>).
7	O estudo sugere modelos <i>in-silico</i> confiáveis para a triagem de novas terapias potenciais para lesões medulares. No entanto, apesar de altamente desejáveis, esses modelos ainda não estão disponíveis devido à falta de conhecimento abrangente dos mecanismos moleculares e celulares envolvidos na lesão medular. Portanto, os modelos <i>in vitro</i> ainda são usados para ajudar a entender os complexos mecanismos celulares envolvidos na lesão medular e identificar novos alvos terapêuticos. Esse modelo também permite a triagem de novas ferramentas farmacológicas e terapias potenciais antes dos testes em modelos animais. Alguns estudos <i>in vitro</i> também podem levantar questões éticas e de bem-estar animal.
8	Os autores observam o uso de terapias aplicadas à CTS, uma condição médica que afeta as conexões nervosas e o movimento da mão e dos dedos. Com a aplicação tecnológica proposta pelo método denominado pelos pesquisadores de <i>EasiCNCSII</i> , são identificadas opções convenientes e não invasivas para a coleta de dados e identificação da STC com bom desempenho. Também, o uso de aplicativos móveis pelos usuários em conjunto com o <i>EasiCNCSII</i> pode proporcionar acesso universal de baixo custo aos cuidados médicos fora do ambiente hospitalar, especialmente em áreas rurais remotas com recursos limitados e acesso a profissionais de saúde. Os autores sugerem que, com a aplicação, será possível promover uma distribuição equilibrada de recursos médicos de qualidade, tendendo a melhorar à medida que um banco de dados mais robusto de sinais de EMG e outras informações terapêuticas relacionadas forem estabelecidas.
9	O artigo relata sobre técnicas para controlar dispositivos robóticos por meio de métodos invasivos ou não invasivos, bem como a redução de problemas funcionais decorrentes de SCI por meio de FES.
10	Este trabalho não menciona diretamente o tratamento de SCI, mas promove uma investigação exploratória da postura espinhal durante o uso do computador, observando que muitos indivíduos são incapazes de manter uma boa postura mesmo quando instruídos a fazê-lo. A proposta sugere que uma análise da influência da curvatura dos ombros pode fornecer um modelo mais completo da postura sentada. Nos testes, nenhum dos pacientes manteve uma boa postura ao longo da tarefa, e dois deles nunca recuperaram uma boa postura após começar a usar o computador. A calibração do modelo mostrou que a amplitude de flexão e a postura ideal variavam entre os pacientes, com o objetivo de fornecer <i>feedback</i> ao usuário por meio de um único sensor flexível capaz de prevenir condições que causam danos à saúde.
11	O uso do <i>Lokomat</i> , um modelo proposto pelos pesquisadores que, quando combinado com diferentes técnicas, mostrou resultados promissores no tratamento de pessoas com lesão medular para melhorar sua capacidade de caminhar, além de reduzir espasmos musculares e fortalecer os músculos dos pacientes. Não obstante, obteve-se um controle mais preciso dos movimentos do paciente, o que sugere um processo de reabilitação mais ágil. Por fim, os autores identificaram o uso de modelos neurais como promissores para controlar o <i>Lokomat</i> e outros instrumentos utilizados no campo da saúde como suporte para as atividades dos profissionais e para as condições de mobilidade das pessoas.
12	Neste artigo, os autores propõem um sistema de controle híbrido hierárquico para restaurar movimentos por meio da FES em pacientes com paralisia. A viabilidade do sistema de controle depende da conexão precisa das vias nervosas envolvidas na marcha do paciente, o que pode beneficiar aqueles com Acidente Vascular Cerebral (AVC), bem como aqueles com lesão medular (pacientes com paraplegia completa e incompleta). Para isso, é sugerido um controle híbrido hierárquico (com BCI), permitindo a coordenação das pernas e o reconhecimento de efeitos indesejados, como a mitigação de espasmos por meio de ajustes necessários. No entanto, observa-se que o uso da FES para restaurar movimentos envolve um grau de incerteza, uma vez que os pacientes podem não estar cientes do que é realizado pelo controlador e quais serão os efeitos percebidos.

Fonte: Elaborado pelo autor (2023)

As distintas abordagens e obstáculos relativos para com a integração, desenvolvimento e aplicação da terapia clínica e fisioterapêutica que se utilizam de interfaces cibernéticas entre pacientes de SCI e computadores, trazem diversos métodos e tecnologias que também

especificam as diferentes abordagens e constructos de conhecimento, envolvendo métodos de AI (indutivos ou dedutivos), bem como uma análise de seus desafios que envolvem a aquisição e processamento de sinais bioelétricos para aplicações terapêuticas.

Por exemplo, quando abordadas questões dos sensores aplicados nos pacientes, as abordagens *in-vitro e in-silico* mostraram que as técnicas invasivas têm um melhor desempenho na aquisição de sinais em comparação com as não invasivas, de modo que os pesquisadores propuseram um filtro adaptativo que poderia limpar o sinal adquirido, a fim de permitir uma melhor promoção de sinais para conexão com as DNNs (JEZERNIK, 2003; ROBINSON *et al.*, 2021).

Quanto ao volume de dados e os diferentes construtos de conhecimento desenvolvidos para processá-los, as pesquisas enfatizam a importância do uso de bancos de dados de casos de estudo médico, que possuem o potencial de aprimorar as habilidades cognitivas dos profissionais de fisioterapia. Junto a essa proposta ainda, poder-se-ia utilizar ferramentas com a possibilidade de conectar as diferentes nuvens, fontes de dados e de *Big Data* por meio de técnicas de AI, aprimorando a análise e a tomada de decisão de médicos e profissionais de saúde pela gestão inteligente de conhecimento, de maneira lógica e sintética. Sugerindo assim, que os resultados desse sistema poderiam permitir a padronização da seleção e implementação de modelos pré-clínicos para cuidados de saúde (PISOTTA; PERRUCHOUD; IONTA, 2015; KAHILE *et al.*, 2021).

Alguns autores ainda, propõem a avaliação e uso de algoritmos de DL que foram testados em condições práticas (casos reais), com garantia prévia da segurança do tratamento dos pacientes. Apesar disso, esses mesmos autores também destacam uma sequência sugerida de etapas em que os sinais neurológicos podem ser adquiridos (modelos) por meio de codificadores digitais de BCIs e Sistemas em um Chip (do inglês *Systems on a Chip* - SoC) para facilitar a integração de *hardware e software*. O *pipeline* consiste desde a extração de características, que pode ser submetida a um pré-processamento, levando a dois caminhos possíveis para o controle de movimento do usuário - a. Classificação (submetendo-a a um controlador de alto nível) ou b. Regressão (mapeamento direto para o estado do dispositivo); a aplicação de estruturas que habilitem o uso de ferramentas de AI, como o *EasyAi*, Linguagem Python e Linguagem R, são sugeridos para facilitar a avaliação e/ou implementação dos sistemas (DILLEN *et al.*, 2022; KAHILE *et al.*, 2021; WALSH *et al.*, 2006).

Na Gestão da Informação frente às diferentes regulações de dados, uma solução provável foi identificada pela aplicação de Algoritmos de Criptografia Leve (do inglês *Lightweight Encryption Algorithm* - LEA), que podem gerar relatórios rapidamente sem

comprometer a privacidade dos dados do usuário (WALSH *et al.*, 2006). Todavia, algumas pesquisas identificam e abordam desafios legais relacionados ao comportamento de computadores e artefatos de *software*, expressando preocupações e sugerindo que uma nova análise de conformidade e legislação é necessária na área, garantindo uma melhor caracterização para a utilização de AI, BCIs e Robótica, que muitas vezes priorizam as funcionalidades tecnológicas em detrimento da segurança ou tratamento dos dados, sem que haja conhecimento ou consentimento do usuário (VAN ROMPAEY *et al.*, 2022; POPOVIC *et al.*, 2000).

Deste modo e frente a esse cenário, se faz necessária uma análise do contexto da saúde, frente ao contraste, observação e aplicação dos artefatos com atendimento aos preceitos específicos do tratamento de SCI, mas que também tangencie, observe e atenda premissas legais e de *Compliance*, bem como aplique os arcabouços tecnológicos das linguagens de Programação e suas bibliotecas em favor de proporcionar os níveis de abstração sistêmica para implementação de um método que habilite uma análise preditiva de biosinais para potencial aplicação real.

1.4.1 Contribuições

Como o principal objetivo deste trabalho consiste na proposição de um método de tratamento para pacientes com Lesão na Coluna Espinhal, objetiva-se que exista a interface entre a terapia e conhecimento técnico dos profissionais da saúde, com a gestão do conhecimento.

Com a compreensão e transformação do conhecimento tácito em conhecimento explícito e a produção do método, espera-se também alcançar possibilidades que transcendam este domínio e possam vir a desenvolver:

- **Avanços em Interfaces Cibernéticas:** A partir dos diferentes desafios da interação cibernética e interfaces cérebro-máquina, como quando abordada a interconexão entre computador e aquisição de biosinais, poderão ser desenvolvidas diferentes interfaces e *pipelines* que conectem a aquisição, processamento e interação de sinais mioelétricos e neurológicos no tratamento e recomendação de tratamento de pacientes com lesão na coluna espinhal.
- **Avaliações legais, éticas e de *Compliance* frente ao uso da tecnologia:** Não obstante das tecnologias comuns à sociedade, softwares e sistemas de saúde também devem obedecer a arcabouços de regulação, proteção e respeito a dados pessoais,

podendo emergir deste trabalho artefatos que recomendem boas práticas frente às preocupações legais e necessidade de conformidade na área de saúde e AI.

- Sistemas inteligentes e de apoio cognitivo: Com a obtenção de dados e a transformação de informações em conhecimento, poderão ser desenvolvidas tecnologias que apoiem o profissional da área da saúde, em especial fisioterapeutas, no tratamento e acompanhamento da recuperação de pacientes, de forma a levar a tomada de decisão mais assertiva.
- Modelos *in-silico*: De forma a utilizar-se das tecnologias disponíveis, este trabalho poderá potencializar, sugerir e desenvolver diferentes modelos de simulação, evitando a necessidade de modelos *in-vitro* (uso de animais ou seres humanos na pesquisa).

1.5 ESCOPO DO TRABALHO

O escopo desta dissertação engloba o desenvolvimento de um método de tratamento de pacientes com SCI e o uso de técnicas de AI e ML, tal qual sejam desenvolvidas ferramentas de apoio à decisão por parte dos profissionais da área da saúde.

Em consonância ao atingimento do objetivo proposto, serão avaliados os diferentes modelos de tratamento fisioterapêuticos e de ferramentas aplicadas buscando identificar informações que possam municiar a criação e desenvolvimento do método.

Para a isonomia e ética na coleta e manipulação de dados e informações, a corrente pesquisa está autorizada e registrada junto ao Conselho Nacional de Saúde (CNS) do Ministério da Saúde (MS) do Brasil através da Plataforma Brasil (conselho.saude.gov.br).

A partir da visualização dos resultados frente a aquisição de biosinais, o método será proposto para utilização real clínica em tratamento de pacientes, objetivando que sejam conduzidos testes por especialistas da fisioterapia, objetivando a avaliação da proposta.

1.6 ADERÊNCIA DA TESE AO PPGEGC

Esta seção objetiva demonstrar a aderência entre este trabalho de pesquisa realizado e o Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento (PPGEGC). Para descrever e narrar os principais aspectos da aderência do trabalho ao PPGEGC, esta seção será subdividida em: identidade da dissertação, contexto estrutural do Programa de Pós-Graduação e referências factuais.

1.6.1 Identidade

Quando se pensa em conhecimento, principalmente em áreas de domínios complexos como a área da saúde, dificilmente pode-se dissociar o uso da tecnologia em tratamentos e técnicas inovadoras que trazem benefícios aos pacientes em seu tratamento. É notório o uso das TICs, em especial o uso da AI para auxílio da tomada de decisão especializada.

Em tratando de SCI, as BMIs têm demonstrado potencial significativo no auxílio ao tratamento, pois fornecem a condição necessária para ligar diretamente entre o cérebro do paciente e um computador, sendo um método de extração de dados físico que garante a estruturação lógica de biosinais dentro de um computador. Cada vez mais elas têm sido utilizadas em aplicações clínicas, principalmente nas que tangenciam a proposta de restauração de movimentos dos pacientes acometidos por essas comorbidades, em conexão com a AI, com notável melhoria na classificação das informações, sendo essencial nas aplicações práticas (SLUTZKY, 2019; ROY, 2022).

Segundo Pai *et al.* (2014), existem oportunidades promissoras com o uso de AI também no Processamento de Linguagem Natural (do inglês *Natural Language Processing - NLP*) e sistemas de apoio à decisão clínica, oferecendo suporte cognitivo aos atores como profissionais de saúde, cuidadores e pacientes. Soma-se a isto a possibilidade de representações formais com o objetivo de sistematizar o conhecimento de determinado domínio. Não obstante, cada vez mais os sistemas de DL estão sendo aplicados e tornam-se mais importantes para realizar a sugestão de tratamentos clínicos, podendo prever quadros técnicos específicos e auxiliar as pessoas (IHNAINI *et al.*, 2021).

Conectando-se a essa realidade, o PPGEHC, da Universidade Federal de Santa Catarina (UFSC), possui três grandes áreas de concentração que procuram desmistificar a Engenharia do Conhecimento (EC), a Gestão do Conhecimento (GC) e a Mídia do Conhecimento (MC), para que de forma interdisciplinar, proponham a resolução de contextos práticos inerentes às organizações. Consonante, essa dissertação segue as premissas específicas de EC, buscando projetar uma solução prática envolvendo métodos e técnicas diversas, desde a representação do conhecimento até a tomada de decisão por meio da recomendação de terapias clínicas. Neste caso, buscando o auxílio aos profissionais da saúde, em especial aos fisioterapeutas que assistem pacientes que possuem Lesão na Coluna Espinhal.

Deste modo, eleva-se a necessidade de entender, medir, classificar, organizar e realizar a engenharia e a gestão do conhecimento para se obter inferências e integrar de forma profícua as capacidades sensoriais. No estudo de Chou *et al.* (2022) é enfatizada essa importância,

especialmente no uso do conhecimento na otimização em predição para resultados nas terapias de SCI. Os pesquisadores destacam como é importante a interface entre a competência clínica e o uso da AI através de ML, sugerindo melhoria nos processos de reprodutibilidade, inferência, descoberta e confiança no diagnóstico e integrações clínicas eficazes.

Não obstante, cada vez mais é destacada a importância da EC e GC em resposta eficaz a estratégias de tratamento na área da saúde, podendo ser empregadas pelos profissionais (LIU; TSUI; KIANITO, 2022). Nesta linha, Karamat *et al.* (2018) enfatizam em seu estudo, a importância da GC na melhoria da competitividade, desempenho e produtividade em organizações da área da saúde, sugerindo e destacando como a adoção eficaz da GC pode ser uma fonte de vantagem competitiva, levando não apenas a sustentabilidade, mas também a eficiência dos profissionais e organizações.

Com isso, a abordagem interdisciplinar dos campos de conhecimento fica cada vez mais estreita e necessária, sendo necessário envolvimento de diferentes profissionais na construção e consolidação de tecnologias, como as de *softwares* e *hardwares* que utilizados como entradas, processamento e saída de informação, buscando a integração de sabedoria como recurso-chave.

Isso enfatiza a necessidade crescente de sua utilização sóbria e especializada, principalmente no momento da concepção e projeto destas propostas, a partir de modelos e regulações que evitem vieses e possam vir cada vez mais a integrar no cotidiano, como pelo uso de dispositivos médicos físicos e virtuais (GIANSANTI, 2022), despertando cada vez mais atenção pela utilização, seja pela capacidade dos sistemas terem evoluído consideravelmente nos últimos anos, ou ainda pela EC tornar-se cada vez mais visada pelas organizações e pelos profissionais (STUDER *et al.*, 2000).

1.6.2 Contexto Estrutural do PPGEGC

A EC, que é tratada como uma das áreas de concentração do PPGEGC, surgiu como uma especialização e aprofundamento da AI durante a década de 70. Desde então, sua evolução se deu através de técnicas que possibilitam a extração de conhecimento e sua modelagem de acordo com os processos fundamentais, replicando a maneira humana de pensar em modelos explícitos e que possam desenvolver sistemas de conhecimento (VOISIN *et al.*, 2021; THON *et al.*, 2021).

Contemporaneamente, cada vez mais é essencial a utilização de TICs, em especial abordagens de EC, com seus métodos, *frameworks*, abordagens e instrumentos aplicados à sistemas de conhecimento (OTERO, 2023).

No contexto do PPGEGC, os propósitos da especialização em Engenharia, Gestão e Mídia do Conhecimento são:

[...] englobar a investigação e a inovação de técnicas e mecanismos para a formalização, codificação e administração do conhecimento; métodos para avaliar a estrutura e os procedimentos adotados por especialistas em tarefas intensivas em conhecimento; e a pesquisa e inovação de sistemas de conhecimento (SUN *et al.*, 2022).

A partir disso, a abordagem interdisciplinar do programa acaba manifestando interação entre três áreas de formação e concentração, que possam englobar disciplinas de formação específicas, desenvolvendo e formando profissionais de áreas diversas.

Através dessa lente, Sun *et al.* (2022) sugerem que as ações de interdisciplinaridade nas iniciativas acadêmicas se manifestem na especialização e suas atividades de pesquisa e inovação, consolidando-se na estruturação do conhecimento. Com isso, os preceitos da especialização *strito-sensu* em EC, tangencia com as formações em GC e MC nos mais diferentes aspectos da formação, evidenciando o uso de metodologias para identificar, representar e gerenciar o conhecimento organizacional; bem como o emprego de sistemas de conhecimento, inclusive na área educacional e de mídias; utilizando também sistemas de conhecimento em ambientes virtuais interativos, visando otimizar processos e aplicar conhecimento interdisciplinarmente.

1.6.3 Referências Factuais

Com objetivo de contrastar o histórico, a seguir no Quadro 6, são relacionados os diferentes estudos apresentados dentro do PPGEGC/UFSC em relação a Área da Saúde (AS) ou com o uso de Método e Técnicas de EC com indicação de autoria, título da publicação, ano de publicação e nível de formação. Na Figura 4, 5 e 6 são apresentadas a distribuição de publicações por ano, nível e área de concentração e de ferramentas.

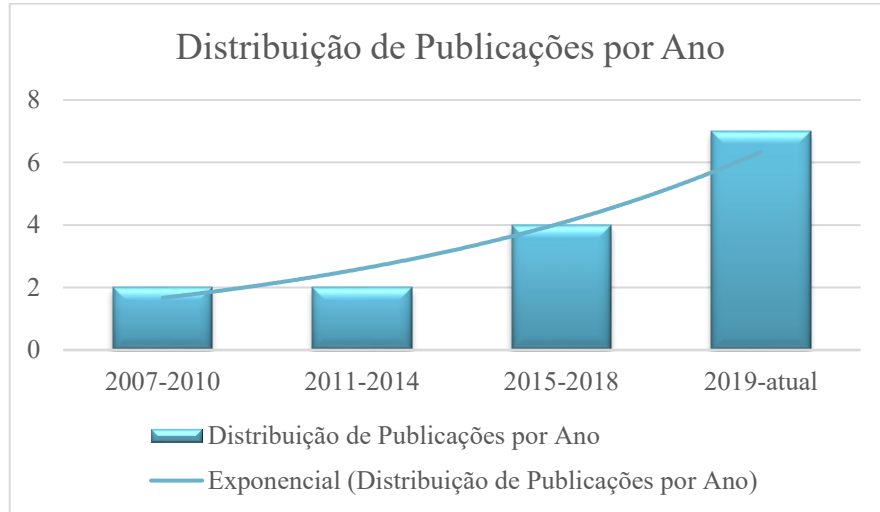
Quadro 6 - Relação de estudos das que podem ser classificados dentro da Área da Saúde ou com o uso de Métodos e Técnicas de EC apresentados no PPGECC/UFSC

Autor	Título da Publicação	Ano	Nível	Área
DONADEL, André Coelho	Um método para representação de processos intensivos em conhecimento	2007	M	R
OLIVEIRA, Leonardo Gomes	Sistema de recomendação de meios de hospedagem baseado em filtragem colaborativa e informações contextuais.	2007	M	R
CARPES, Carlos Eduardo Pereira	Avaliação do compartilhamento do conhecimento em entidades de saúde do executivo estadual de Santa Catarina	2012	M	AS
LIMA, João Carlos Damasceno	Uma Abordagem de Recomendação Sensível ao Contexto Para Apoio À Autenticação Implícita em Ambientes Móveis e Pervasivos Baseado em Conhecimento Comportamental do Usuário.	2013	D	R
CECI, Flavio	Um Modelo Baseado em Casos e Ontologia para Apoio à Tarefa Intensiva em Conhecimento de Classificação com Foco na Análise de Sentimento	2015	D	R
SILVA, Thales Do Nascimento Da	Um Modelo Baseado em Ontologia para Suporte à Tarefa Intensiva em Conhecimento de Recomendação.	2015	M	R
TAXWEILER, Rudger Nowasky Do Nascimento	Um Modelo Para a Extração de Perfil de Especialista Aplicado às Ferramentas de Expertise Location e Apoio à Gestão do Conhecimento.	2016	M	R
RIBEIRO, Alessandro Costa	Modelo de Reconhecimento de Padrões em Ideias usando Técnicas de Descoberta de Conhecimento em Textos	2018	M	R
SÉRGIO, Marina Carradore	Modelo de Avaliação de Potenciais Ideias Alinhadas ao Contexto Organizacional	2020	D	R
KASTER, Gerson Bovi	Framework Conceitual Baseado em Aprendizagem de Máquina Supervisionada para Concepção de Sistemas de Agentes Inteligentes para Área Judicial	2022	M	AS
POTTMAIER, Cassiana Mendonça	Framework conceitual para organização e representação do conhecimento em saúde pessoal	2022	M	R
SILVA, Thales Do Nascimento Da	Um Modelo de Recomendação de trabalhadores voltado à execução de tarefas no cenário de Crowdsourcing	2022	D	R
TRAUER, Eduardo	k-SCAS: Framework do Sistema de Agronegócios de Cafés Especiais Orientado ao Conhecimento	2022	D	R
PINTO, Rafael Maia	Detecção de erros e fraudes em gastos públicos nas áreas da saúde e educação: uma abordagem utilizando inteligência artificial	2023	M	R

TAXWEILER, Rudger Nowasky Do Nascimento	Framework de ciência de dados e engenharia do conhecimento para apoio à gestão do capital alumni em programas de pós-graduação	2023	D	R
-----------------------------------------------	--------------------------------------------------------------------------------------------------------------------------------	------	---	---


Fonte: Elaborado pelo autor (2023)

Figura 4 - Comparação gráfica da distribuição de publicações por ano



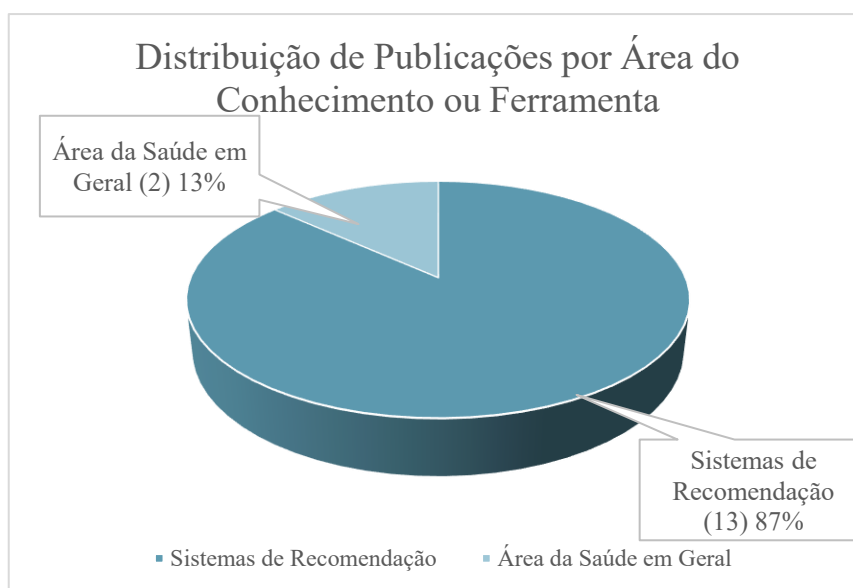
Fonte: Elaborado pelo autor (2023)

Figura 5 - Comparação da distribuição de publicações por nível de formação



Fonte: Elaborado pelo autor (2023)

Figura 6 - Comparação da distribuição de publicações na área de concentração ou ferramenta



Em análise aos estudos relacionados nas Figuras, demonstra-se aderência ao trabalho ao PPGEGC, evidenciando o potencial de inovação e ineditismo desta dissertação em contribuição a comunidade científica e a evolução científico-tecnológica nas áreas de EC e Saúde.

1.7 ESTRUTURA DO TRABALHO

Este estudo possui estrutura de 7 seções que se distribuem com os objetivos de:

- Capítulo I: Introduz o tema da dissertação, contextualização a pesquisa e sua problemática, compondo objetivos, originalidade e delimitações e a conexão com o PPGEGC;
- Capítulo II: Aborda o referencial teórico, com destaque às estruturas centrais da pesquisa (BMCs, AI e Sistemas de Recomendação para área da Saúde);
- Capítulo III: Aponta a metodologia adotada na condução da pesquisa;
- Capítulo IV: Apresenta o método proposto, elucidando seus componentes e interações;
- Capítulo V: Caracteriza o cenário de estudo prático de inserção junto aos pacientes com o método proposto;
- Capítulo VI: Analisa e discute os resultados alcançados.
- Capítulo VII: Apresenta as considerações finais, concluindo a proposição deste trabalho diante de suas reflexões para oportunidades futuras.

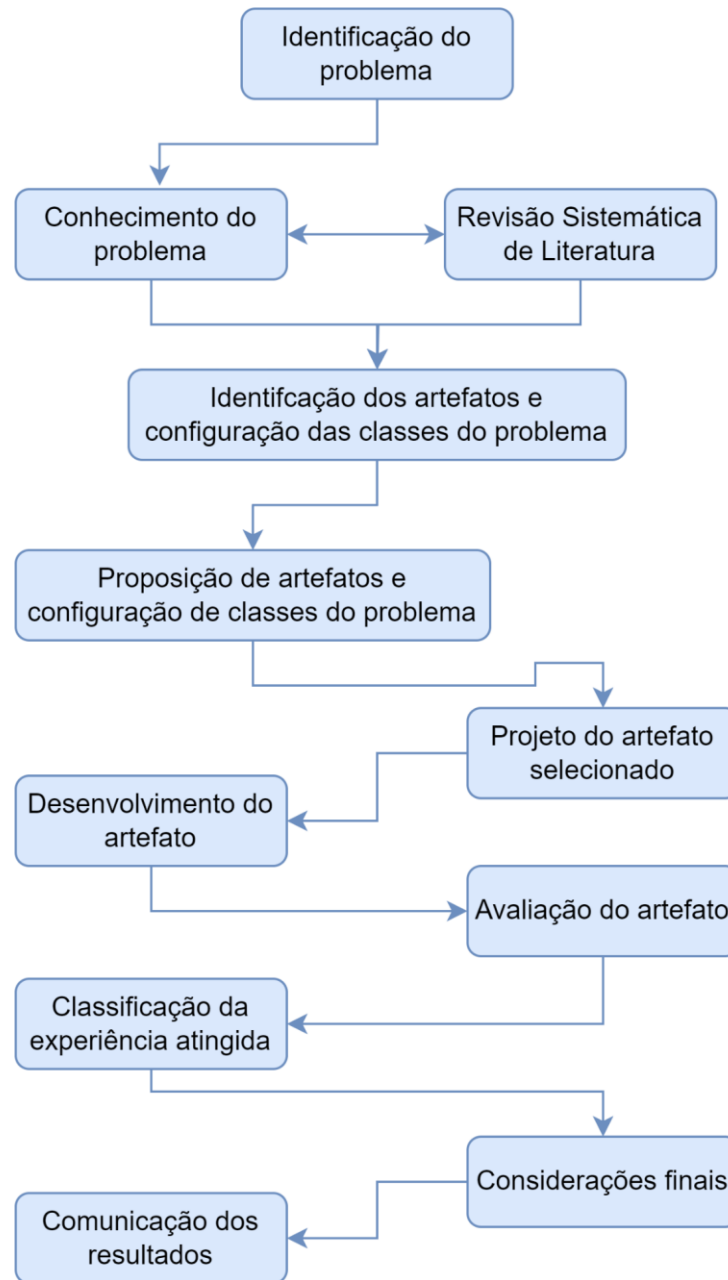
2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção será abordada a fundamentação teórica deste trabalho e sua composição. Para o desenvolvimento foram seguidos os elementos da DSRM em âmbito da operacionalização e entendimento de itens como a natureza do problema e o atual estado da arte. Isso foi definido pensando em atingir a solidez e relevância acadêmica, pois a DSRM desenvolve uma análise teórica-conceitual que busca tanto debate como também a verificação dos estágios da pesquisa (GOECKS *et al.*, 2021).

Outro ponto importante é de que ela é defendida por trazer uma aderência equilibrada, abordando em conjunto das questões científico-acadêmicas também as questões práticas, elucidando a colaboração com a indústria em contextos de Engenharia do Conhecimento (KLAUSS, 2021).

Corroborando com esse pensamento, Sengik *et al.* (2022) enfatizam a relevância da DSRM no desenvolvimento de modelos específicos e da abstração até a resolução prática, atenuando sistematicamente problemas complexos que podem ser divididos em classificação e exemplificação de classes de problemas em uma sequência de fases. A exploração deve ser principiada pela classe de passos da Figura 7.

Figura 7 - Principais estágios para conduzir uma pesquisa por meio da metodologia DSRM



Fonte: Adaptado de Dresch *et al.* (2015)

A seguir, serão observados os referenciais teóricos envolvendo as diferentes dimensões e domínios de conhecimento que dão base a este trabalho.

2.1 LESÃO NA COLUNA ESPINHAL

A WHO define que a SCI, é categorizada como uma lesão que altera a vida, levando a uma série complexa de mudanças nas funções sensoriais, motora e autonômica de uma pessoa

com uma doença que afeta os aspectos multidisciplinares da vida do paciente e de todos ao seu redor, afetando domínios das funções físicas e mentais. (EHRMANN *et al.*, 2020; PATSAKOS *et al.*, 2021).

No Canadá por exemplo, um país que possui identidade similar ao Brasil no que tange o atendimento e estrutura do Sistema Único de Saúde (SUS), em 2019 foram estimados 1199 novos casos por ano (32 por milhão), destes, 10% são casos de morte (123) e outros recebem alta (1076), acumulando uma população total média de 30 mil pessoas no país. Entre os casos em que as pessoas recebem alta do hospital, muitas adquirem uma comorbidade permanente e vivem com a necessidade de tratamento intensivo e terapias contínuas. Frequentemente, esses indivíduos falecem com uma média de 54,3 anos (THOROGOOD *et al.*, 2023).

Em contraste com uma análise no Brasil, a incidência de SCI está aumentando. No estudo de Utiyama *et al.* (2022) que foi promovido na região sudeste, foi revelado que a maior parte das pessoas que estão sendo acometidas são do gênero masculino e estão com paraplegia. Um dos destaques percebidos é de que essa população enfrenta barreiras ambientais que tornam suas vidas mais árduas, como a falta de tratamentos especializados e a má acessibilidade dos espaços públicos, sendo que em função disto, apenas 10% dessa população informou ter retornado ao trabalho após a lesão, algo que gera problemas em todas as esferas pessoais e de políticas públicas em efeito cascata. A extensão dessas mudanças é amplamente determinada pelo nível e gravidade do comprometimento da medula.

De acordo com Lilley *et al.* (2020), as pessoas que possuem SCI têm perda de função sensorial e motora, causando também indiretamente outros problemas, como disfunção sexual, disfunção da bexiga e intestino, infecções, dor crônica e problemas cardíacos e respiratórios. Em termos atuais, as opções de tratamento em humanos são limitadas, focando principalmente em terapias adaptativas, reabilitação e no gerenciamento de complicações secundárias. A SCI, quando resultante de eventos traumáticos, é um processo multifatorial que causa dano celular local seguido por processos reativos secundários, incluindo isquemia, inflamação, edema, morte celular, degeneração axonal, gliose e formação de tecido cicatricial. Comumente, é atribuído a uma falha na regeneração das fibras nervosas derivadas do cérebro através da lesão (LAI *et al.*, 2021).

Após o acometimento de uma lesão, em geral um dos primeiros objetivos buscados pelo profissional da área da saúde será a aplicação de um tratamento que minimize a lesão secundária e promova a regeneração neuronal, sendo que a implementação de um regime de tratamento, quanto mais precoce, melhor será a recuperação do paciente de forma sensoriomotora (BROWN *et al.*, 2011).

2.1.1 Tratamentos para Lesão na Coluna Espinhal

No que diz respeito aos tratamentos para SCI, segundo Pisotta, Perruchoud e Ionta (2015), existem os seguintes tratamentos usuais para pacientes que possuem distúrbios sensoriomotores:

- Técnicas cirúrgicas: Podem ser aplicadas para reduzir déficits funcionais e promover independência de movimento, mas devido à sua natureza invasiva, algumas tornam-se menos **aplicáveis** ou viáveis, se **avaliada relação de custo e benefício do retorno pleno** às condições diárias de vida da maior parte das pessoas, em comparação com outras **intervenções**.
- Tratamento farmacêutico: Usado para intervir na dor e clônus (contrações musculares involuntárias), geralmente traz alívio dos sintomas, mas com eficácia a longo prazo controversa.
- Tratamento fisioterapêutico: Focado em evitar a hipotrofia muscular por meio de sessões de movimentos passivos. Este tipo de tratamento apresenta benefícios gerais, mas é afetado por limitações relacionadas à especificidade da tarefa, complexidade, consumo de tempo e dependência de especialização. Outro problema é a dificuldade de medir com precisão as melhorias sensorimotoras em equilíbrio com a **qualidade da** assistência fornecida devido à evolução contínua do paciente.

Nos últimos anos, a partir do desenvolvimento tecnológico, houve avanços na reabilitação automatizada, com foco específico na repetibilidade e quantificação, onde o treinamento assistido por interfaces cérebro-máquina resultou em recuperação mais precisa e duradoura das funções sensorimotoras em pacientes. O uso dessas tecnologias no tratamento permite o monitoramento e avaliação do progresso na reabilitação, que em casos mais graves, como em quadros de SCI, comendo avanços significativos com a simbiose de diferentes campos como a neurociência cognitiva, engenharia biomédica e a computação (TRBOVICH *et al.*, 2021).

Tradicionalmente, a partir de leituras eletromiográficas, os profissionais da área da saúde coletam informações dos sensores mioelétricos do paciente durante a terapia (POPOVIC *et al.*, 2000). Atualmente, pela utilização de sistemas cibernéticos, é possível cruzar diferentes elementos de software, hardware, sensores e atuadores, que podem colaborar através de redes de IoT e interagir através de AI (ROMPAEY *et al.*, 2022), fornecendo inspiração para melhorar os tratamentos clínicos (LAI *et al.*, 2021).

Dentro da variedade de dispositivos e tecnologias usados nas terapias, esses equipamentos comumente se utilizam de sinais biológicos que carregam informações neurais capturadas por sensores, que traduzem sinais cerebrais usando algoritmos de decodificação. A conexão com o sistema nervoso pode ocorrer de duas maneiras: invasiva ou não invasiva, conforme descrito a seguir na Figura 8:

Figura 8 - Fluxograma de decodificação de biosinais corpóreos para processamento e ações através de Inteligência Artificial para processamento e ação em pacientes



Fonte: Adaptado de Dillen *et al.* (2022)

Dentro do uso de Aprendizado Profundo para o controle de biosinais, os usuários são habilitados a interagir com o mundo com o auxílio destes dispositivos eletrônicos que decodificam os sinais biológicos provenientes de seus movimentos ou pensamentos. Essa forma de interação com o ambiente, a partir de dispositivos protéticos e exoesqueletos (vestíveis ou assistivos), pode tornar a interação mais natural e intuitiva, melhorando as diferentes condições de comorbidades dos pacientes, permitindo a devolução do movimento às pessoas com condições paralisantes pela engenharia biomédica e suas tecnologias (PISOTTA; PERRUCHOUD; IONTA, 2015; DILLEN *et al.*, 2022).

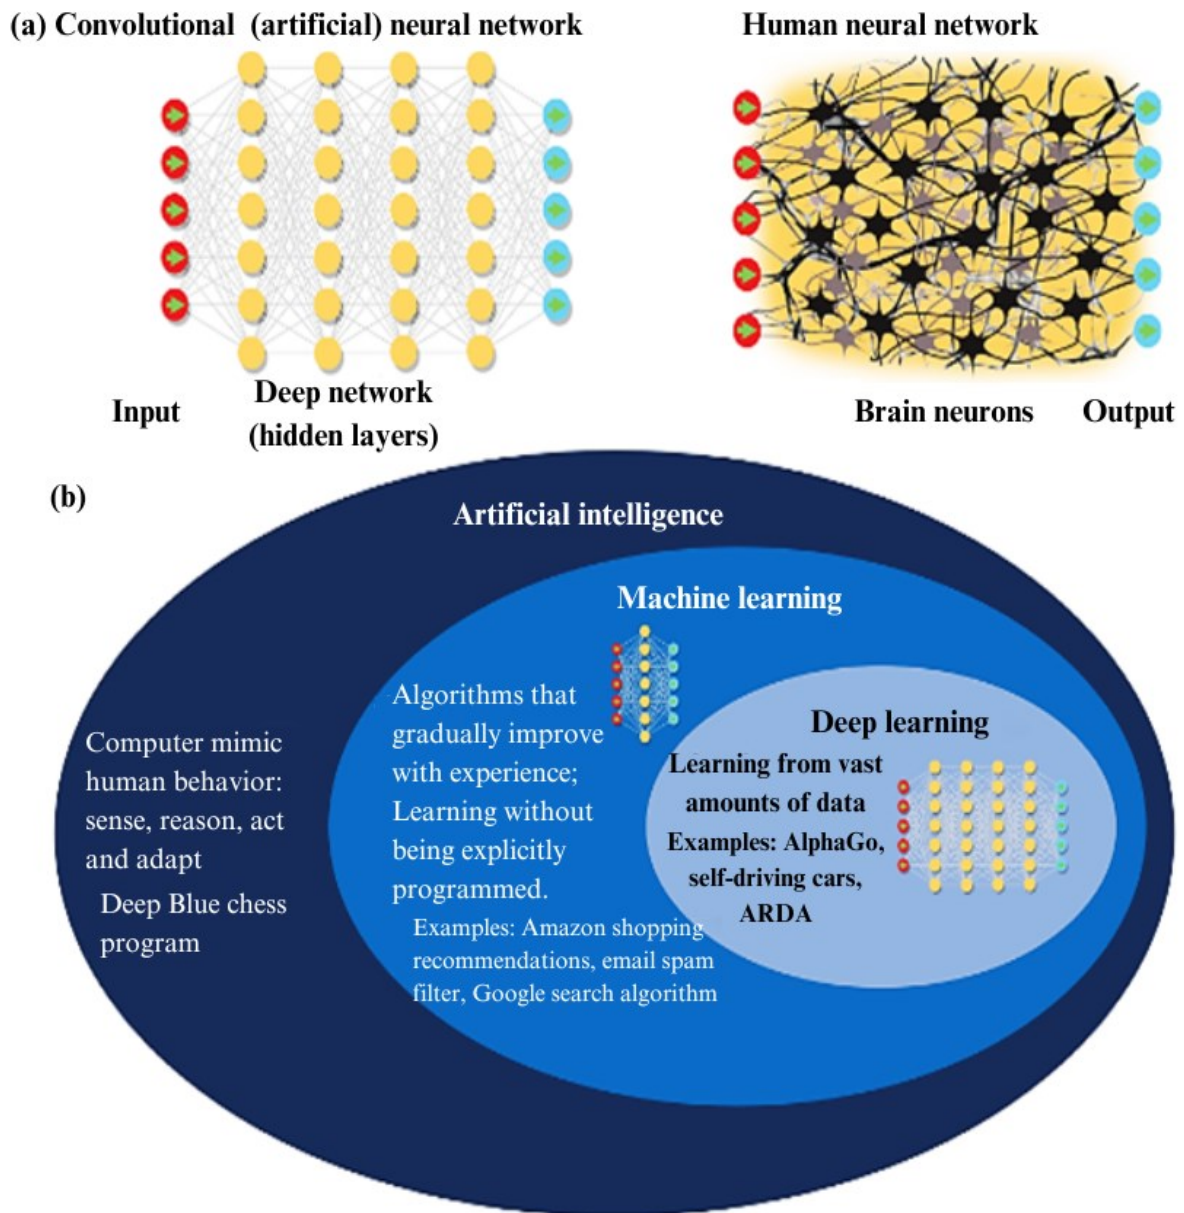
2.2 INTELIGÊNCIA ARTIFICIAL

A AI tem sido uma área de conhecimento de notória ascensão e crescimento, conectada a diversas camadas da sociedade. De maneira interdisciplinar, apresenta potencial para simular processos humanos, tanto operacionais quanto cognitivos. Isso é alcançado por meio de regras e mecanismos de autocorreção, que integram sistemas computacionais para promover o aprendizado.

No estudo de Harrison *et al.* (2021), ela é apontada como um ramo de alto interesse científico, empresarial e governamental, recebendo grandes rodadas de investimentos em tripla-hélice de inovação, tendo crescido mais de 8 vezes desde o ano 2000, esperando um investimento de quase 1 bilhão de dólares em 2025, podendo ser aplicada nas mais diferentes patologias e recuperação de pacientes.

Corroborando neste sentido e mostrando grande promessa na área da saúde, como no desenvolvimento de novos químicos (medicamentos e compostos) e apoiando decisões para o fornecimento da qualidade de diagnósticos, está cada vez mais presente no cotidiano humano, muito além da área médica, podendo ser percebida em diversas aplicações, por exemplo, carros autônomos, assistentes virtuais, previsão meteorológica, reconhecimento facial, dentre outras (DRUKKER; NOBLE; PAPAGEORGHIU, 2020; YAN *et al.*, 2022).

Figura 9 - Representação gráfica da inteligência artificial



(a) Arquitetura da rede neural humana e sua semelhança com uma rede neural artificial profunda. (b) Relação entre inteligência artificial, aprendizado de máquina e aprendizado profundo para aplicação prática.

Fonte: Drukker, Noble e Papageorghiou (2020)

Com isso, cada vez mais a AI demonstra potencial para ajudar os profissionais da saúde na tomada de decisões informadas e assertivas, visto que o prognóstico da intervenção clínica e reabilitação tradicional leva em consideração principalmente a experiência do profissional, enquanto que quando aplicadas técnicas ou abordagens dos seus subdomínios, como DL, é possível produzir uma melhor linearidade de resultados, auxiliando assim, em termos de

precisão maximizada, com uma recomendação de melhores tratamentos (MARTIN *et al.*, 2021).

A AI, uma subárea da ciência da computação dedicada ao desenvolvimento de sistemas capazes de realizar tarefas tradicionalmente requerendo inteligência humana, está se tornando cada vez mais abrangente e multifacetada, transcendendo suas raízes originais através de uma vasta interconexão de campos e disciplinas. Estas tarefas incluem aprendizado, raciocínio, percepção, reconhecimento de padrões, e tomada de decisão, entre outras. Elas têm o potencial de transformar muitos setores, incluindo a saúde, podendo ser utilizada para melhorar diagnósticos, tratamentos e a gestão do conhecimento (KARAMAT *et al.*, 2018).

Na saúde, GC e EC são cruciais para garantir que os profissionais de saúde tenham acesso às informações mais recentes e relevantes para tomar decisões mais informadas sobre o cuidado do paciente (LIU; TSUI; Kianto, 2022), podendo levar a avanços notórios, pois a GC refere-se ao processo de criar, compartilhar, usar e gerenciar o conhecimento e as informações de uma organização (STUDER, 2000).

Neste sentido, os sistemas médicos especialistas podem receber apoio da AI para treino em grandes volumes de dados (*Big Data*) e identificar padrões e tendências, que muitas vezes são imperceptíveis por humanos e podem não estar sendo utilizados em sua plenitude (MARTIN, 2021), podendo demandar de técnicas de DL para uma melhor recomendação e processamento de conhecimento, aproveitando ao máximo as oportunidades que a AI oferece (DILLEN *et al.*, 2021).

2.2.1 Aprendizado de Máquina e Aprendizado de Profundo

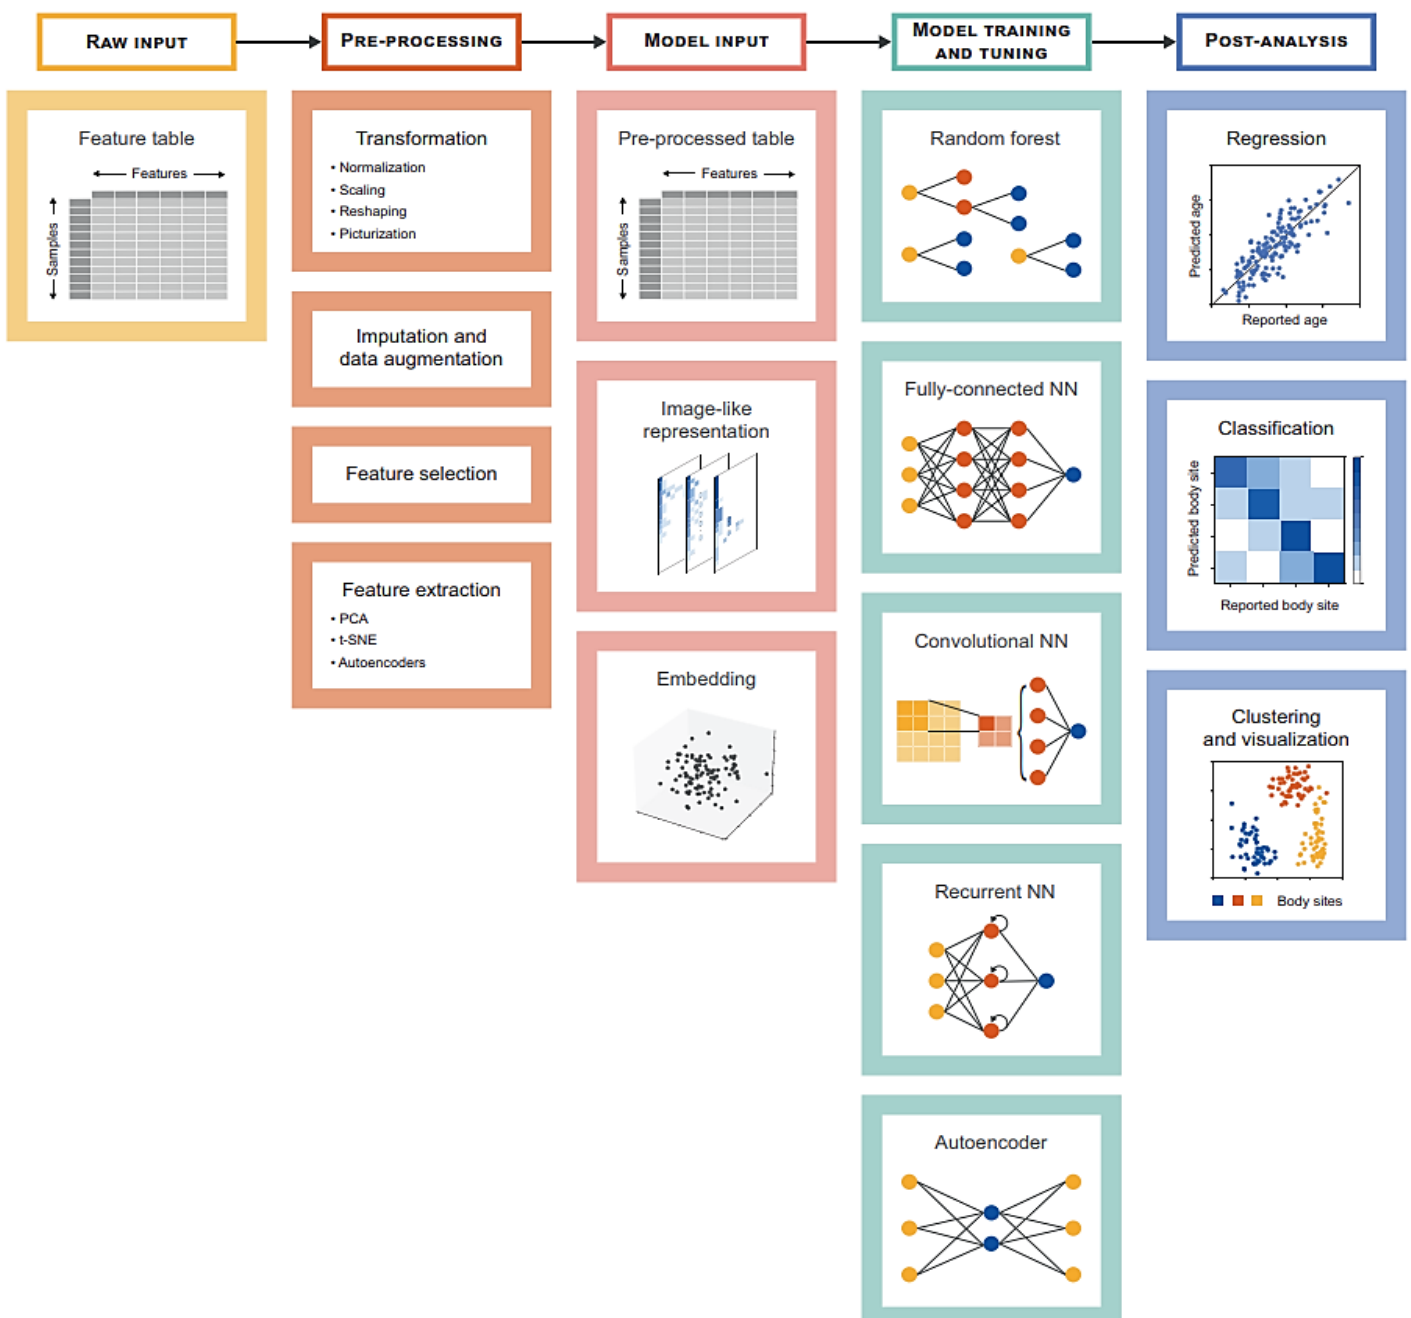
As áreas de especialização da AI que tem experimentado revoluções significativas principalmente recentemente nas mais diversas aplicações práticas são ML e DL, possibilitando avanços nas mais diversas áreas, visto que conseguem interpretar conjuntos de dados maciços através das ANNs e da Estatística (MEDINA *et al.*; YAN *et al.*; 2022; IYORTSUUN *et al.*, 2023).

Os algoritmos de ML são fundamentados em modelos estatísticos que permitem o aprimoramento contínuo do desempenho de sistemas e tarefas específicas, sendo melhorados com a experiência. Eles podem ser programados para serem supervisionados, semi-supervisionados ou não-supervisionados, adaptando-se conforme a necessidade e tarefa específica (MEDINA *et al.*, 2022). Quanto ao DL, os neurônios das redes neurais podem ter

múltiplas camadas de processamento, capazes de analisar diversos níveis de abstração de dados, onde cada neurônio pode receber um “peso” múltiplo (YAN et al., 2022).

De acordo com Medina *et al.* (2022), dentro da área da saúde, são muitas vezes utilizados os modelos em prol de uma pós-análise clínica que observe a classificação das informações médicas, diante de padrões compreensíveis ao especialista no domínio, conforme ilustrado na Figura 10:

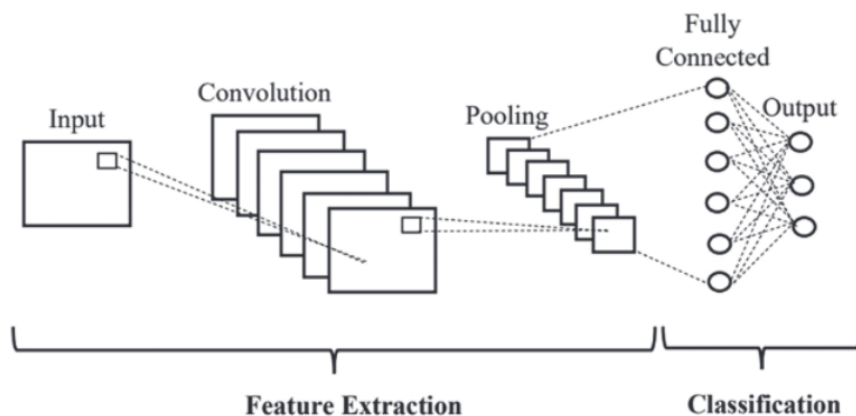
Figura 10 - Proposta de Modelo de uma Inteligência Artificial em suas Entradas de Dados, Pré-Processamento, Modelos, Tuning e Análise Final



Por outro lado, segundo o trabalho de Kumari, Kumar e Kumar (2023), os registros de casos clínicos trazem consigo uma grande riqueza de dados e, se corretamente avaliados, podem devolver informações sobre tendências e *insights* de saúde, tratamentos e suas eficácias e muito além disso, tornando-se notória a sua contribuição e possibilidades no campo específico se avaliados pela lente de EC e GC.

Esses grandes conjuntos de dados podem trazer importantes insights para diagnósticos e prognósticos, podendo ser aplicado em surtos de doenças e análise de imagens de exames. Um exemplo de aplicação é o uso de modelos (Figura 11) baseados em tecnologias como a Imagem por Ressonância Magnética (do inglês *Magnetic Resonance Imaging* - MRI) e IoT, por meio de Redes Neurais Convolucionais (do inglês *Convolutional Neural Network* - CNN) para a classificação de tumores cerebrais usando dados dos ambientes de saúde mostrando alta precisão (HAQ *et al.*, 2022).

Figura 11 - Modelo de arquitetura de implementação de uma rede neural convolucional



Fonte: Yousra *et al.* (2023)

Outra citação de sua aplicação prática, pode ser percebida na conexão entre técnicas de ML e DL em sistemas para avaliação de transtornos psiquiátricos, como na identificação, classificação e previsão de quadros de depressão, ansiedade, esquizofrenia, transtorno bipolar, transtorno de estresse pós-traumático, anorexia nervosa, transtorno de déficit de atenção e hiperatividade (IYORTSUUN *et al.*, 2023).

Não obstante, tangenciando a análise de comunidades microbianas e o desenvolvimento celular, que influenciam sistemas macroscópicos, incluindo a saúde humana, cada vez mais a previsão e predição de reações entre composição, funções e associações tem se aproveitado das técnicas de AI (MEDINA *et al.*, 2022). Isto inclui, por exemplo, a detecção precoce de câncer de pele que, dependendo do tipo de *input* e sua integração com o sistema, em

alguns casos, produz resultados em poucos segundos (YOUSRA; ABDELHAKIM; BOUDHIR; MOHAMED, 2023).

Na química fina para saúde, as aplicações que se relacionam com a descoberta e *design* de compostos peptídeos antimicrobianos, as técnicas de ML e DL têm sido utilizadas para projetos antimicrobianos e na descoberta de novos medicamentos por meio da combinação de abordagem *in-silico* (YAN *et al.*, 2022).

Embora os avanços de ML e DL ofereçam aplicações promissoras na saúde e em vários campos científicos, ainda são enfrentados desafios significativos. Entre eles estão as limitações na capacidade computacional e as questões de interoperabilidade e heterogeneidade dos sistemas, que podem obstaculizar a aplicação efetiva dessas tecnologias em sistemas especializados (ROBINSON *et al.*, 2021).

2.3 ENGENHARIA BIOMÉDICA

Diversas condições clínicas afetam dramaticamente a troca constante de estímulos entre o corpo e o cérebro, mas os avanços na engenharia biomédica têm fornecido soluções promissoras para superar esta falha de comunicação. As novas tecnologias têm sido capazes de transformar a atividade elétrica neuronal em dados computacionais para dispositivos robóticos, dando origem a BMIs que podem ser utilizadas para promoção, não apenas de tratamento, mas para possível incorporação nas atividades diárias do usuário (PISOTTA; PERRUCHOUD; IONTA, 2015).

No estudo de Pisotta, Perruchoud e Ionta (2015), os autores afirmam que a integração do dispositivo robótico e do cérebro humano pode ocorrer de forma invasiva, onde eletrodos são conectados ao cérebro vivo. Neste caso específico, a atividade neural é registrada de forma “invasiva” e traduzida em tempo real em comandos computacionais para controlar o dispositivo robótico. Contudo, a sua implementação em procedimentos clínicos ainda é muito limitada devido à limitada disponibilidade de dispositivos e também da dificuldade em tangenciar sua utilização no longo prazo. Da mesma forma, Bi-Quin *et al.* (2021) relatam que a limitação desta tecnologia é o escasso número de canais utilizáveis na maioria dos dispositivos disponíveis comercialmente, trazendo inclusive os altos riscos de infecção ou rejeição de dispositivos invasivos, a plasticidade neural anatomofuncional e a morte celular.

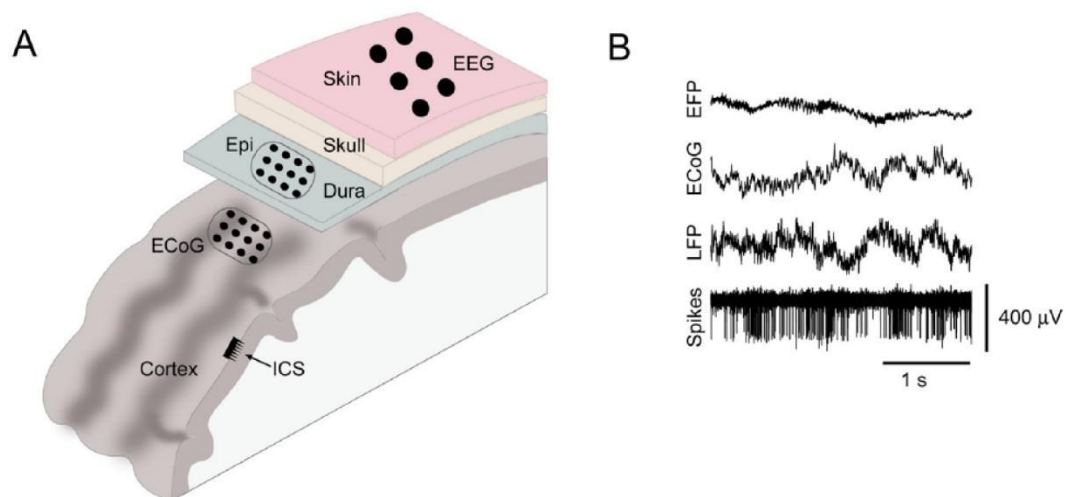
Uma alternativa para a integração com dispositivos robóticos é o método não invasivo, que utiliza EEG para captar a atividade neural através de eletrodos posicionados no couro cabeludo. Em comparação com métodos invasivos, esta abordagem apresenta uma qualidade

de sinal inferior, o que demanda que o sistema implemente estratégias adicionais de abstração para eficientemente filtrar e eliminar ruídos do sinal.

Por outro lado, em contraste ao EEG, o EMG pode ser usado quando os sinais neurais periféricos ainda estão disponíveis através da codificação da atividade muscular residual. As interfaces que combinam EEG e EMG para criar um sistema híbrido representam o avanço mais recente em neuropróteses e a direção futura mais promissora da pesquisa de BMIs (POPOVIC *et al.*, 2000; WANG *et al.*, 2018).

Consonante a isso, no estudo de Slutzky (2018), é reforçado que as BMIs podem ser utilizadas como próteses neurais. Ele indica que os dispositivos atuam como sensores e atuadores e que se comuniquem diretamente com partes do cérebro. Suas aplicações mais usuais tendem a ser com a movimentação, podendo inclusive servir para investigar quadros clínicos e também, reanimar outros conjuntos musculares, auxiliando em quadros de patologias diversas. À seguir na Figura 12, pode ser verificada uma análise à diferentes níveis de invasividade:

Figura 12 - Relação de contraste na obtenção dos sinais elétricos do cérebro em níveis de invasividade (A), desde EEG e sinais intracorticais. (B) Exemplos de gráficos de captura de sinais neuronais



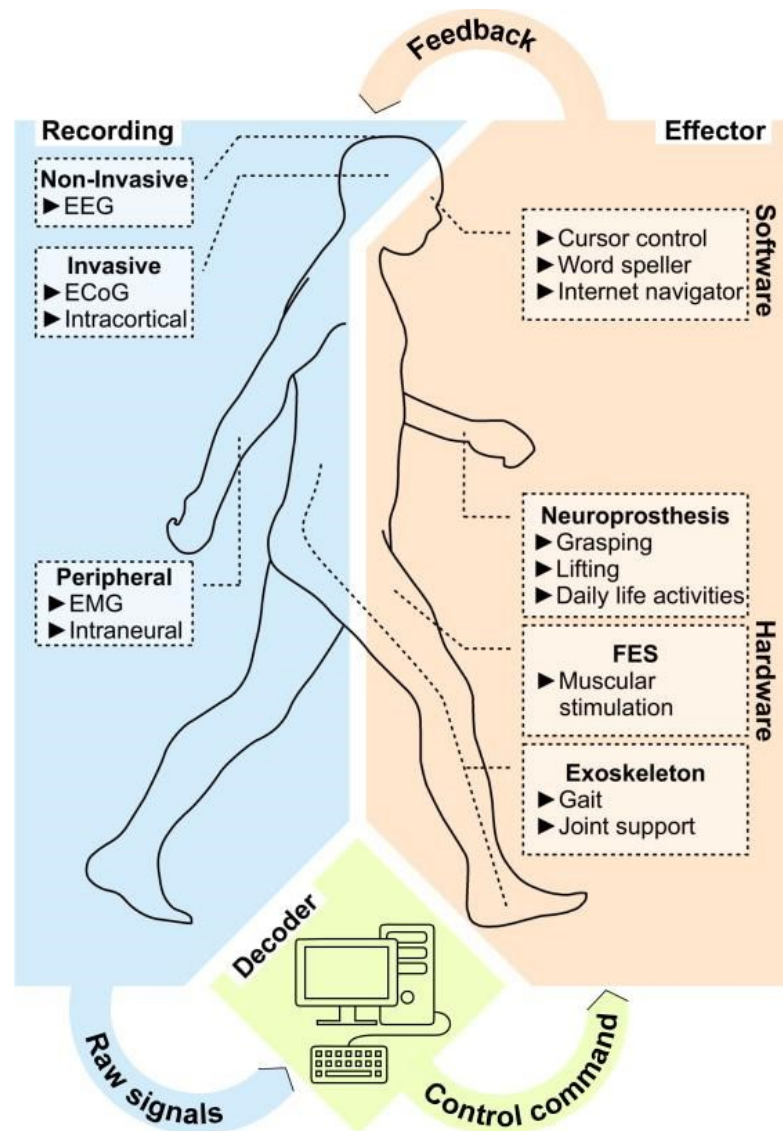
Fonte: Slutzky (2018)

Como pode ser observado, o EEG é utilizado para domínios não invasivos, uma vez que pode ser posicionado diretamente na pele do paciente, não demandando procedimentos mais complexos ou de risco, como posicionando no couro cabeludo ou nos tecidos musculares pretendidos, conforme pode ser verificado na Figura 13.

Outro ponto de atenção também, é de que apesar dos diferentes dispositivos invasivos possuírem o potencial de trazerem biosinais com menos ruído, existem poucos canais utilizáveis

e, ao aplicá-los o paciente poderá estar exposto a uma série de riscos, como infecções ou traumas cirúrgicos, trazendo desafios ao seu uso clínico. Em contraste, o EMG pode ser utilizado com sucesso nos métodos não invasivos, através da inserção segura dos eletrodos na área desejada, para obtenção dos sinais do paciente e sua transformação através de um sistema de decodificação apoiado pelo computador para *feedback* (POPOVIC; SINKJÆR, T, 2000; PISOTTA; PERRUCHOUD; IONTA, 2015; ROBINSON *et al.*, 2021).

Figura 13 - Representação de uma BMI na leitura de atividade cerebral, decodificação, processamento e ação no usuário, em ação a utilização de algoritmos de ML e retorno a *feedback* no cérebro



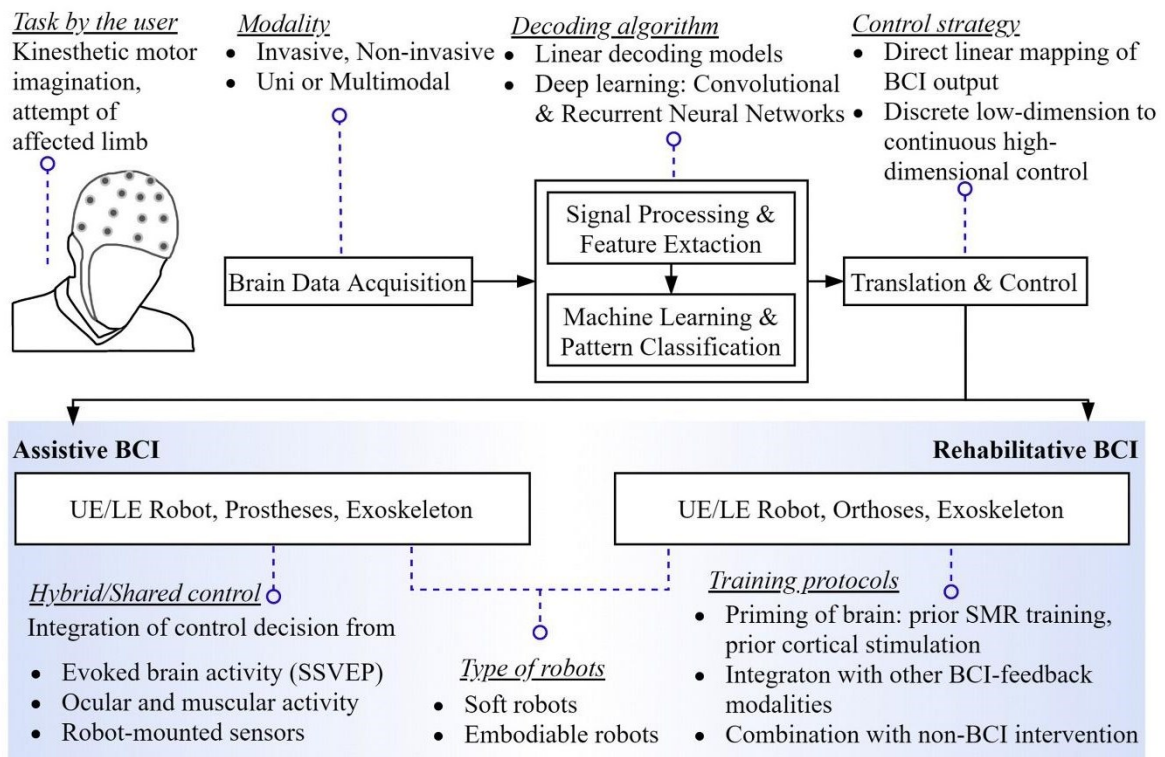
Fonte: Pisotta, Perruchoud e Ionta (2015)

Entretanto, como geralmente essas interfaces não invasivas são do tipo *biofeedback*, sua utilização pode trazer alguns desafios, como a exigência de múltiplas sessões de interação com a máquina, onde um profissional capacitado deverá aplicar gel condutor na área desejada para se obter uma boa disposição de conjuntos de dados para que seja alcançado um desempenho satisfatório (SLUTZKY, 2018).

Em adição, aplicável para ambos os casos supracitados em boa parte das soluções disponíveis no mercado, no estudo de Robinson *et al.* (2021) é identificado que há um desafio oculto quanto a integração dos sistemas e também quanto aos arquivos fonte de paciente em sistemas médicos, sendo na maior parte dos casos um grande desafio sua integração, seja pela heterogeneidade de sistemas, ou pelas soluções não explicitarem a estrutura de armazenamento, demandando a utilização de técnicas de engenharia reversa para uma efetiva integração.

Não obstante, torna-se evidente a necessidade da produção de ferramentas que habilitem estratégias de controle e extração de conhecimento mais fluidas, precisas e confiáveis, objetivando impactos clínicos ampliados e a integração dos demais sistemas de forma benéfica (ROBINSON *et al.*, 2021).

Figura 14 - Especificação da lista de práticas de design de última geração para BMI



Fonte: Robinson *et al.* (2021)

Frente a esses cenários citados, também a relação de custo e benefício, são prováveis alternativas a busca por *frameworks* de extração de conhecimento (Figura 14), como através do uso de ML, de DL e outros métodos e de aumento de dados, de forma a implementar ainda mais precisão e robustez aos modelos (ROY, 2022).


A área da saúde demanda que cada vez mais técnicas sejam desenvolvidas em favor de se buscar domínios interdisciplinares de contribuição, como através de técnicas de fusão de dados ou modelos de ML, capazes de propor respostas mais rápidas, assim como uma melhor taxa de precisão de diagnóstico, sendo aplicados para as mais diferentes abordagens de terapias clínicas (IHNAINI *et al.*, 2021).

2.3.1 Métodos de Extração de Conhecimento para tratamento de SCI

A AI combina tecnologias de uso geral que podem ser aplicadas em todos os campos do conhecimento humano, abrangendo vários tipos de indústrias e atividades simultaneamente (ROMPAEY *et al.*, 2022), a fim de aplicar técnicas computacionais, matemáticas e lógicas para compreender, associar e descrever, de modo a processar vastos conjuntos de dados, usando algoritmos de apoio aos processos cognitivos humanos (KAHILE *et al.*, 2020).

De acordo com Dillen *et al.* (2022), um dos ramos da AI e um dos métodos mais aplicados é o DL, que tem se mostrado uma boa alternativa para realizar ações de decodificação de sistemas de controle de biosinais, possibilitando a construção de um modelo de ML, com aquisição de dados complexos, facilitando processos subsequentes de processamento de dados para previsão de valores em modelos treinados, que podem ser aplicados em diferentes ramos, como para o tratamento de SCI.

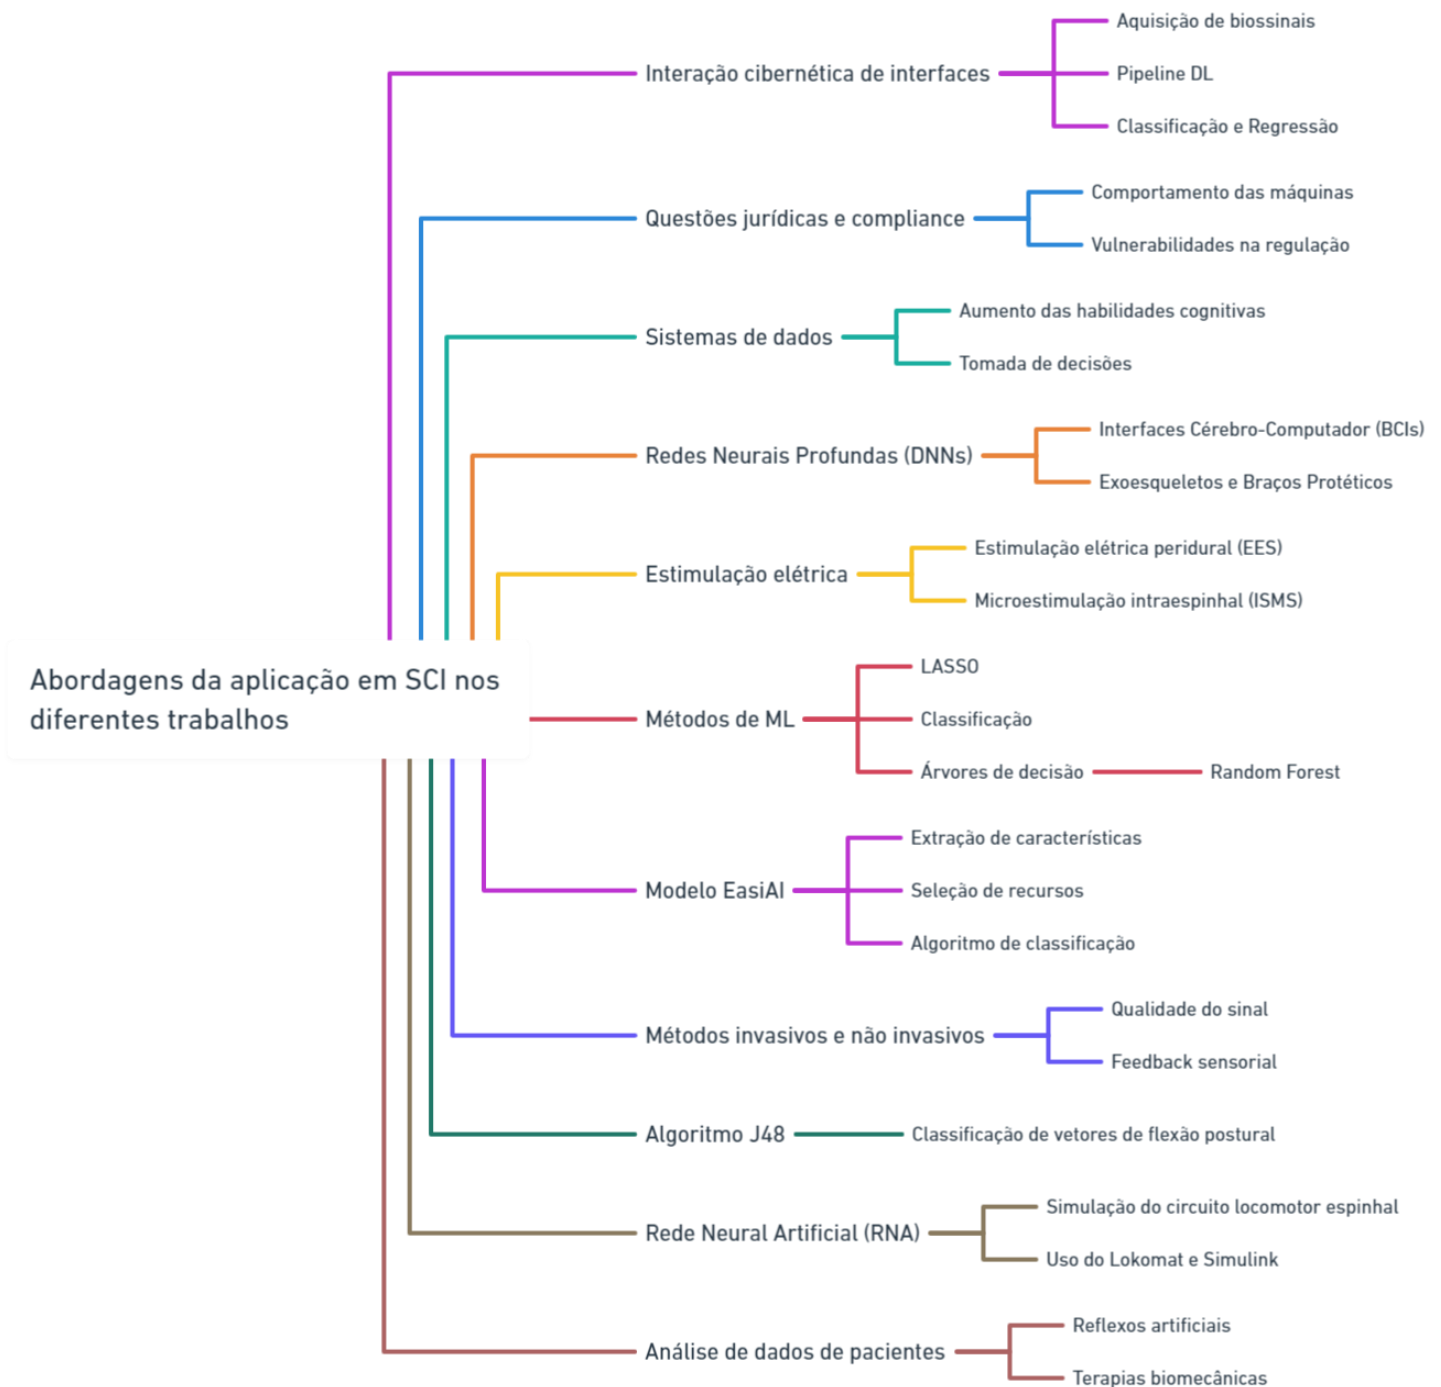
Figura 15 - Proposta de modelo de microeletrodos de mapeamento neuronal servindo como dados de entrada para uma máquina que, por meio de AI, replica impulsos elétricos no tecido muscular



Fonte: Lai *et al.* (2021)

Dentro das pesquisas realizadas, os estudos analisados exploram amplamente as aplicações e implicações das tecnologias, abordando as técnicas de interfaces para obtenção dos sinais neurológicos, aquisição de biosinais e os diferentes modelos de DL e Extração de Conhecimento (do inglês *Knowledge Extraction* - KE). A seguir (Figura 16), são ilustrados através de relação de hierarquia como os estudos tratam cada um dos assuntos.

Figura 16 - Diferentes abordagens do estado da arte atual em termos do estudo



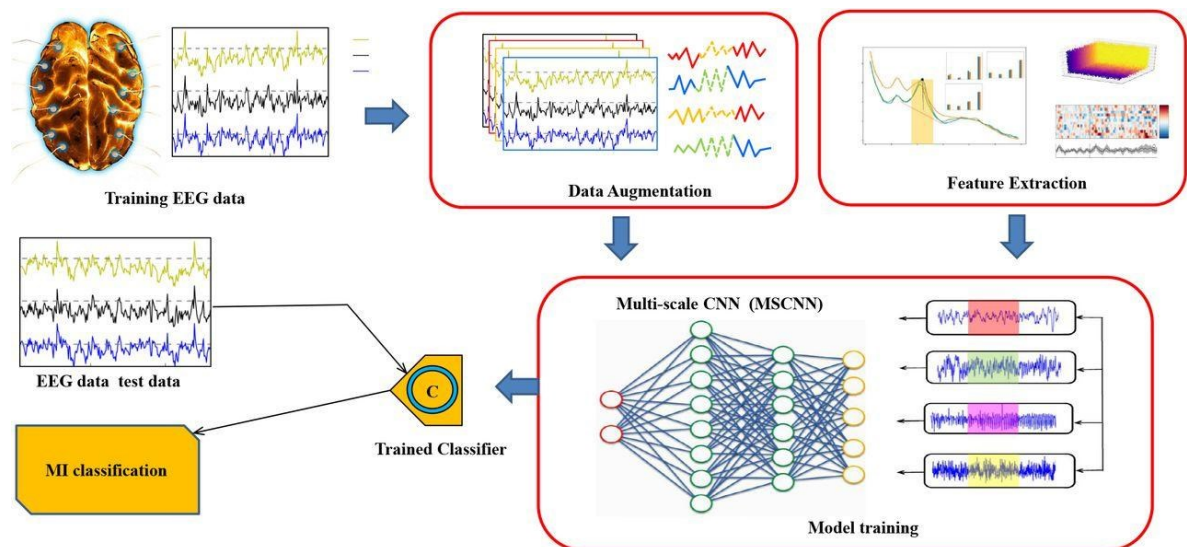
Fonte: Elaborado pelo autor (2023)

Como pode ser observado, os diferentes trabalhos trazem consigo diversos tópicos que permeiam a aplicação de algoritmos, sistemas de dados, integração de interfaces e análise de dados dos pacientes. Dentro das representações de conhecimento potenciais que se conectam com a proposta deste estudo, pela condição de serem advindos convenientemente e eficientemente através de um EMG, por exemplo, os dados podem ser processados e depois

classificados pela máquina de acordo com os critérios estabelecidos pelo especialista no domínio de conhecimento (fisioterapeuta).

Segundo o Wang *et al.* (2018), há o potencial de reduzir potencialmente o sofrimento clínico de longo prazo de pessoas que sofrem com SCI pelo uso de AI aplicada a BMIs para KE. Com essa abordagem, os impulsos elétricos produzidos pelos tecidos podem ser mapeados e reproduzidos por geradores artificiais de impulsos elétricos, recriando a estimulação nos miócitos (músculos) do paciente (LILLEY *et al.*, 2020; LAI *et al.*; ROY 2021). A representação a seguir (Figura 17) demonstra o fluxo de obtenção de dados em EEG, separados em conjuntos de teste e treinamento para processamento de modelo e extração de resultados.

Figura 17 - Representação do fluxo de obtenção de dados cerebrais para o treinamento de modelo de dados baseado em leitura de biosinais



Fonte: Roy (2022)


No estudo de Barelli, Avelino e Castro (2022), sugere-se que através da FES, uma técnica de AI pode atuar na coordenação e replicação de correntes elétricas em pacientes desabilitados visando melhorar ou até restaurar suas funções motoras. Para isso, utilizaram a proposta de sistema intitulado STIMGRASP, desenvolvido como uma tecnologia assistiva para usuários com tetraplegia ou hemiplegia.

O STIMGRASP é um estimulador funcional elétrico baseado em microcontrolador SoC, com estrutura de oito canais de saída para geração de pulsos com frequência de 20 Hz, largura de 300 μ s/fase e amplitude máxima definidas em 40 mA (carga de 1 k Ω), desenvolvido

para ser utilizado de forma vestível, podendo ser portado nas atividades diárias de forma muito versátil (BARELLI; AVELINO; CASTRO, 2022).

Já no trabalho de ŠTRBAC *et al.* (2014) houve uma abordagem diferente, onde a invés de se apropriar de sinais cerebrais para o treinamento do modelo e proposta, a abordagem difere-se pelo uso de Visão Computacional (do inglês *Computer Vision - CV*) e a FES, que também são assistidos por algoritmos computacionais e interfaces cérebro-máquina. Na proposta (Figura 18), o algoritmo avalia a imagem em um modelo heurístico, de forma a estimar o controle biológico na preensão (ato de segurar, pegar ou agarrar), rastreando os movimentos dos membros superiores, sincronizando com uma câmera Microsoft© Kinect® para identificar em tempo real a análise dos objetos e propor sinergias com o espaço.

Figura 18 - FES em tempo real através de reconhecimento 3D de CV de imagem e algoritmos de detecção de objetos



Fonte: Štrbac *et al.* (2014)

Desta forma, a integração de técnicas unindo áreas interdisciplinares e inovadoras como AI e seus subdomínios, fisioterapêutica e biomédica, abre-se uma grande gama de possibilidades para a reabilitação motora e recuperação efetiva de pacientes, podendo trazer análises profundas, em tempo real ou não, adaptando-se às necessidades específicas e proporcionando formas de integração com o cotidiano e recuperação mais profícuas para ambientes clínicos e domésticos.

3 METODOLOGIA DA PESQUISA

A pesquisa científica e a tecnológica constituem pilares essenciais para o avanço humano, desempenhando papéis cruciais tanto no ambiente acadêmico quanto no industrial. Ambas visam ampliar o conhecimento e a compreensão, oferecendo através de suas abordagens únicas impactos significativos na sociedade. Portanto, é imperativo explorar e detalhar esses aspectos para compreender adequadamente o desenvolvimento deste trabalho.

3.1 NATUREZA DA PESQUISA TECNOLÓGICA E CIENTÍFICA

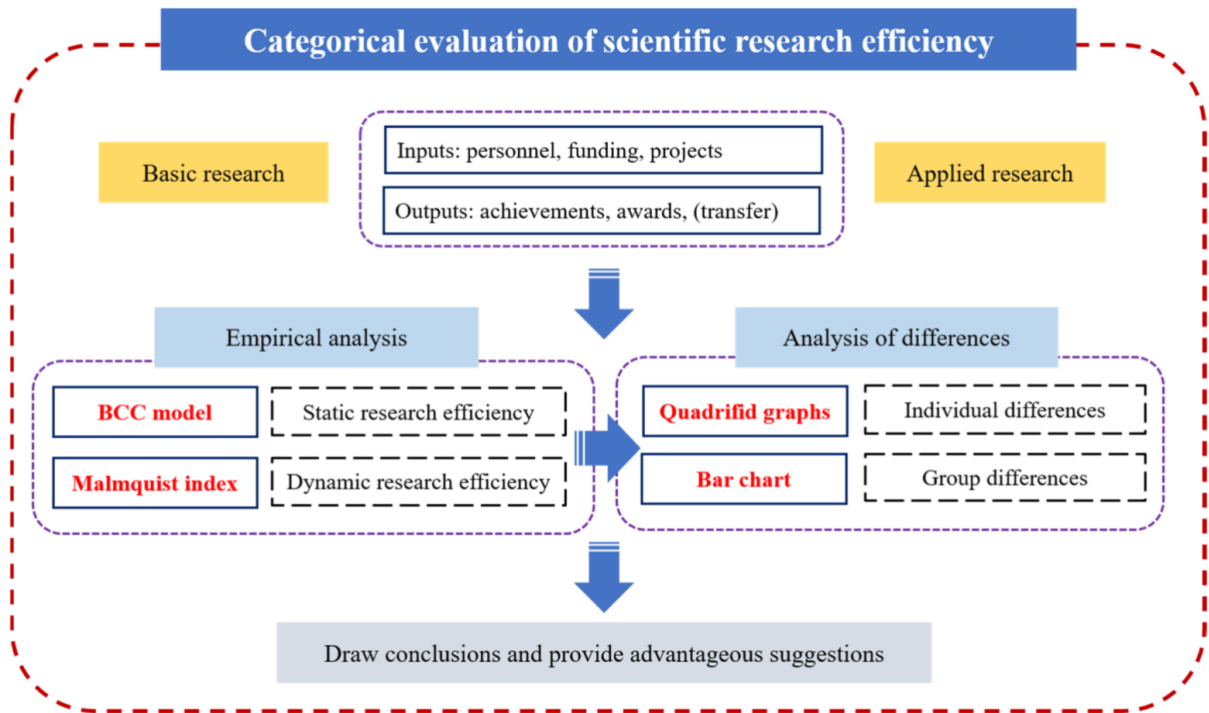
Segundo Lacey (2014), a pesquisa científica busca compreender os princípios fundamentais que governam o universo, desde as menores partículas subatômicas até as vastas galáxias no espaço. Ela é motivada pela curiosidade e pelo desejo de expandir o conhecimento humano. Por outro lado, a pesquisa tecnológica é orientada para a aplicação prática desse conhecimento, pois busca desenvolver soluções para problemas específicos, levando a inovações que podem ser comercializadas e utilizadas na vida cotidiana (ZHU, 2020).

Conforme pode ser verificado na Figura 19, enquanto a pesquisa científica frequentemente utiliza métodos dedutivos para formular teorias e hipóteses, a pesquisa tecnológica acaba por observar fenômenos que conduzem prioritariamente à sua aplicação, por meio de métodos indutivos para desenvolver novas tecnologias e inovações (LACEY, 2014).

No estudo de Shi, Wang e Zhang (2022), os pesquisadores promoveram a avaliação a partir de 32 universidades chinesas diretamente sob a supervisão do Ministério da Educação na China, obtendo resultados que indicam ônus e bônus de cada tipo de pesquisa. Se por um lado a eficiência a curto prazo da pesquisa básica perde para pesquisa aplicada, no longo prazo seus resultados acabam trazendo uma maior contribuição e avanço do conhecimento. Neste contraste ainda, a pesquisa básica acaba sendo mais lenta em geral do que a pesquisa tecnológica aplicada.

Notoriamente, isso pode ser compreendido de diferentes formas, pois a pesquisa aplicada e a básica são complementares dentro do ecossistema científico. A pesquisa aplicada busca resolver problemas imediatos e específicos, alcançando rapidamente resultados esperados, mas com uma perspectiva que pode ser restrita. Numa comparação, a pesquisa básica visa a descobertas de longo prazo, oferecendo um potencial de avanço mais substancial à medida que supera os desafios que podem ser diversos, conforme ilustrado no Quadro 7.

Figura 19 - Diagrama do referencial da pesquisa em avaliação da eficiência dos métodos de pesquisa básica e aplicada



Fonte: Shi; Wang; Zhang (2022)

Deste modo, pode-se dizer que a relação da pesquisa científica básica é de expandir a fronteira do conhecimento humano, enquanto a pesquisa tecnológica aplicada transforma esse conhecimento em inovações práticas que têm impacto direto na vida das pessoas (LACEY, 2014).

Quadro 7 - Relação dos domínios de financiamento, apoio governamental, de formação e métricas da pesquisa de natureza científica básica e tecnológica aplicada

Item	Pesquisa Básica Científica	Pesquisa Tecnológica Aplicada	Fonte
Financiamento e Apoio	A pesquisa básica científica frequentemente depende de financiamento público e de fundações de apoio à ciência, pois seu retorno é a longo prazo e não está diretamente ligado a produtos comerciais.	A pesquisa aplicada é frequentemente financiada por entidades privadas e indústrias devido ao seu potencial de gerar novos produtos e tecnologias com retorno financeiro direto.	ZHU <i>et al.</i> ; ALZHANOVA <i>et al.</i> , 2020.
Colaboração Interdisciplinar	Este tipo de pesquisa se beneficia grandemente da colaboração entre diferentes disciplinas, promovendo uma compreensão mais profunda dos fenômenos estudados.	Embora também beneficie de abordagens interdisciplinares, a pesquisa aplicada tende a ser mais focada em resolver problemas específicos do setor.	LACEY, 2014.

Desafios Éticos	Os desafios éticos na pesquisa básica podem incluir questões de consentimento informado, uso de animais em experimentos e a integridade na condução e publicação de pesquisas.	Os desafios éticos podem estar relacionados à privacidade de dados, consentimento para uso de tecnologias e implicações de longo alcance de inovações tecnológicas.	VOISIN, 2021.
Aplicações	As aplicações da pesquisa básica são muitas vezes indiretas, contribuindo para o conhecimento fundamental que pode ser a base para futuras aplicações práticas.	As aplicações são diretas e visam resolver problemas práticos ou criar novos produtos e serviços.	ALZHANOVA <i>et al.</i> , 2020; THON <i>et al.</i> , 2021.
Impacto na Economia	O impacto econômico é geralmente indireto e a longo prazo, mas fundamental para o avanço tecnológico e inovação.	O impacto econômico é mais imediato e mensurável, com a criação de empregos, produtos e serviços que impulsionam o crescimento econômico.	SHI <i>et al.</i> , 2022.
Formação e Educação	A pesquisa básica é essencial na formação de cientistas e na educação avançada, fornecendo a base teórica para futuras investigações aplicadas.	A pesquisa aplicada contribui para a formação de profissionais com habilidades práticas e foco na resolução de problemas do mundo real.	LACERDA <i>et al.</i> , 2013.
Avaliação e Métricas	A avaliação é muitas vezes baseada em publicações e citações, refletindo o impacto e a relevância dentro da comunidade científica.	A avaliação muitas vezes inclui o sucesso comercial, patentes, e a implementação prática de soluções tecnológicas.	ZHU, 2020.

Fonte: Elaborado pelo autor (2023)

Ao comparar as duas vertentes, pode-se perceber uma relação de complementaridade intrínseca entre a pesquisa básica e a aplicada. A primeira constitui-se como o alicerce para a expansão do conhecimento humano, fornecendo substrato teórico para futuras explorações. A segunda, por sua vez, atua na concretização desse saber em intervenções pragmáticas que endereçam demandas contemporâneas. Com isso, ambas são pilares fundamentais para o avanço da ciência e da tecnologia, culminando no aprimoramento da qualidade de vida e no crescimento econômico. A pesquisa básica é frequentemente encarada como um investimento de longa maturação, cujos frutos podem ser disruptivos e transformadores. Em contrapartida, a pesquisa aplicada é direcionada para a geração de um impacto econômico mais célere, por meio da resolução de problemáticas mais imediatas. A sinergia entre essas modalidades pode potencializar o ritmo da inovação, propiciando a transposição de descobertas científicas em benefícios concretos e mensuráveis para o tecido social.

3.2 DESIGN SCIENCE RESEARCH METHODOLOGY

A DSRM é uma abordagem sistemática para a criação e avaliação de artefatos com o objetivo de resolver problemas especificamente identificados. Frequentemente utilizada em campos como a engenharia, informática, saúde ou educação, onde a necessidade de soluções inovadoras é constante e a aplicação prática de teorias é essencial para o êxito de um negócio.

Gregório *et al.* (2021) exploram o uso da DSRM no desenvolvimento de serviços de *eHealth* em farmácias, destacando como a metodologia pode ser aplicada para criar soluções que melhorem a prestação de serviços de saúde, com o argumento de que ela é particularmente útil em contextos em que a colaboração interdisciplinar é necessária para inovar e resolver problemas complexos.

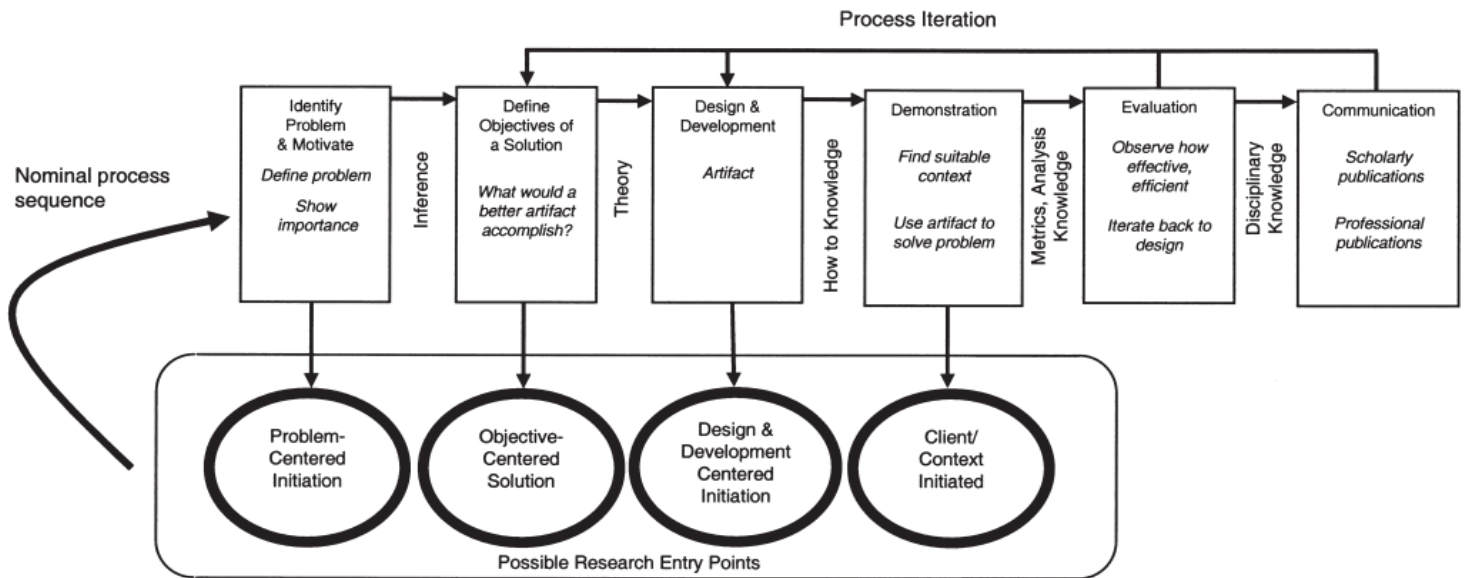
Apiola e Sutinen (2020) apresentam diversos estudos de caso em que a metodologia foi aplicada para ensinar engenharia de software e pensamento computacional. Em sua demonstração, eles inserem como pode ser usada para desenvolver ferramentas educacionais que promovem o aprendizado ativo e a resolução de problemas, enfatizando a importância da interação e da reflexão no processo de *design*, conotando sua aplicação direta na educação.

Consonante, Wulf (2020) utiliza a DSRM para desenvolver um Processo de Hierarquia Analítica (do inglês *Analytic Hierarchy Process - AHP*) para gerenciar capacidades *omnichannel*, mostrando como a metodologia pode ser empregada para estruturar problemas de decisão complexos e desenvolver soluções baseadas em critérios bem definidos, podendo ser exitosa no atendimento dos clientes.

Ainda, Benfell (2020) aborda o desafio de modelar requisitos funcionais em engenharia de *software* usando conhecimento tácito na área de sistemas. Ele propõe uma abordagem informada pela DSRM para capturar e utilizar esse conhecimento, como uma forma de engenharia e gestão de conhecimento, identificando que muitas vezes é subutilizado no desenvolvimento de sistemas.

A DSRM (Figura 20) é estruturada em seis etapas principais: identificação do problema, definição dos objetivos do artefato, design e desenvolvimento, demonstração, avaliação e comunicação. Cada etapa é crucial para garantir que o artefato desenvolvido seja não apenas teoricamente sólido, mas também prático e eficaz na resolução do problema identificado (PEFFERS *et al.*, 2007).

Figura 20 - A DSRM, em suas fases essenciais



Fonte: Peffers *et al.* (2007)

A identificação do problema é a fundação sobre a qual todo o projeto de pesquisa é construído. É essencial que o problema seja bem compreendido e claramente definido, pois isso orientará todas as etapas subsequentes do processo de pesquisa.

Definir os objetivos do artefato é o próximo passo crítico, pois os objetivos devem ser mensuráveis e alcançáveis, e devem refletir as necessidades das partes interessadas e envolvidas (*stakeholders*). Isso garante que o artefato desenvolvido seja relevante e valioso para aqueles que enfrentam o problema.

O design e desenvolvimento envolvem a criação do artefato propriamente dito. Esta etapa é iterativa e criativa, exigindo a aplicação de conhecimentos e habilidades técnicas para produzir uma solução funcional.

A demonstração é a fase em que o artefato é testado em um contexto que simula ou replica o problema identificado, permitindo que os pesquisadores observem e compreendam como o artefato funciona na prática.

A avaliação é fundamental para validar a eficácia do artefato, de forma a envolver testes rigorosos do artefato contra os objetivos definidos e a coleta de *feedback* dos usuários. Esta etapa pode levar a refinamentos adicionais e melhorias no artefato.

Por fim, a comunicação dos resultados é essencial para compartilhar o conhecimento gerado. Isso inclui a publicação em periódicos acadêmicos, apresentações em conferências e, em alguns casos, a comercialização do artefato, que será avaliado por métricas de forma a iniciar e mensurar o sucesso e o impacto dos artefatos desenvolvidos nos diferentes

elementos supracitados, desenhando objetivos que possam ser atingidos e que os resultados sejam significativos e replicáveis.

Ao longo do processo de DSRM, a colaboração interdisciplinar é frequentemente necessária, uma vez que problemas complexos raramente se enquadram em um único domínio do conhecimento, e a contribuição de diferentes áreas do saber pode enriquecer o processo de *design*, bem como garantir que o artefato seja robusto e aplicável em diversos contextos. Os desafios éticos também são uma consideração importante na metodologia, visto que os pesquisadores devem garantir que os artefatos desenvolvidos sejam seguros, justos e respeitem a privacidade e a autonomia dos usuários, observando o impacto ambiental e social de suas inovações.

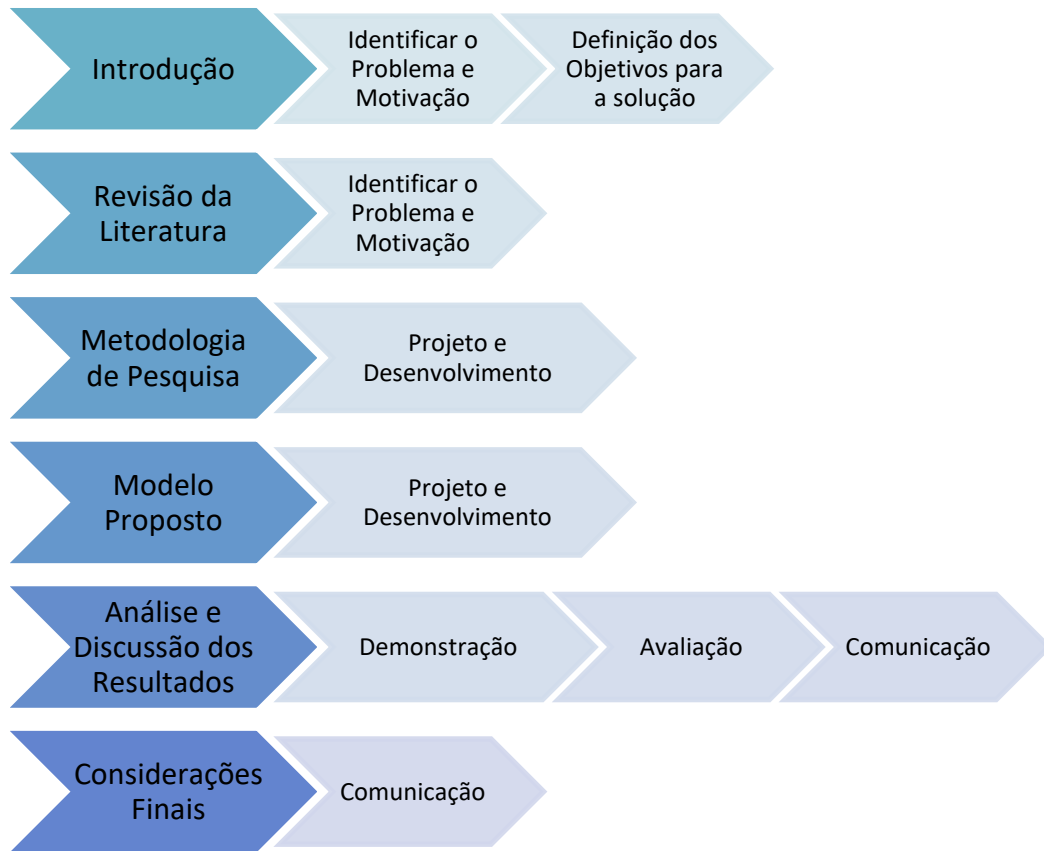
As aplicações da DSRM são vastas e variadas. Desde o desenvolvimento de novos medicamentos até a criação de sistemas de informação avançados, a DSRM tem o potencial de impulsionar o progresso em muitos campos, com um impacto na economia que pode ser significativo. Ao promover suporte para a resolução de problemas reais e melhorias em processos e serviços, as inovações resultantes podem levar a ganhos de eficiência, novos produtos e mercados, e até mesmo a criação de novas indústrias pela inovação de produtos e serviços.

Em consideração final, essa pesquisa se utilizou da DSRM em suas proposições, visto que esta é capaz de oferecer uma estrutura para a inovação orientada à problemas. Ela é essencial para o avanço da pesquisa aplicada e tem um papel crucial na transformação do conhecimento teórico em soluções práticas que beneficiam a sociedade como um todo. Na seção seguinte, podem ser observados os objetivos exploratórios e descritivos da realização deste trabalho.

3.3 DESENVOLVIMENTO DA PESQUISA

Esta investigação é de caráter aplicado, visando explorar e descrever fenômenos específicos de EC aplicados à reabilitação de pacientes com SCI. Seu objetivo primordial é o desenvolvimento de ferramentas que contribuam para a elaboração de um modelo assistencial no processo de fisioterapia clínica, assistida, a partir de FES em pacientes com paraplegia. A correlação entre as fases da Metodologia de Pesquisa em DSRM e as seções correspondentes desta dissertação pode ser observada na Figura 21.

Figura 21 - Organização do trabalho em relação a DSRM e suas etapas



Fonte: Elaborado pelo autor (2023)

As subseções a seguir elucidam as atividades em cada estágio da DSRM frente ao desenvolvimento proposto nesta dissertação.

3.3.1 Identificação do Problema e Motivação

Empregou-se uma abordagem de revisão sistemática de literatura utilizando as premissas do PRISMA-P, objetivando os desafios pertinentes ao domínio da Engenharia Biomédica e o domínio de SCI. Este método estabeleceu uma base sólida que guiou todas as decisões estratégicas na formulação do modelo proposto.

Através da meticulosa revisão sistêmica delineada na Seção 1.4, procedeu-se com a avaliação do panorama atual e das investigações existentes que tangem aos desafios reconhecidos pela literatura. A revisão abrangeu uma pesquisa nas bases científicas Science Direct®, ACM Digital Library®, IEEE® Explore, SCIELO BR®, Web of Science®, PUBMED® e COCHRANE®, sendo escolhidas por tradicionalmente serem fontes de busca da área médica, fisioterapêutica, engenharia biomédica e de sistemas especialistas. Na revisão

sistemática, foi assegurada a revisão em duplo cego com o *software* Rayyan®, em busca de transparência, replicação e conclusão de resultados metodológicos.

Conforme os princípios da Metodologia de Pesquisa em DSRM, a problemática e a motivação subjacentes foram cuidadosamente desenvolvidas a partir da análise literária obtida. Tal qual foi estruturada a originalidade em avaliação do exame detalhado do estado da arte, o que viabiliza a criação de artefatos dotados de relevância tanto técnica quanto científica nesse campo de estudo.

3.3.2 Definição dos Objetivos para a Solução

A partir da cuidadosa contextualização do problema em questão, foi possível estabelecer os objetivos específicos desta pesquisa e, conseqüentemente, propor o modelo teórico que fundamenta esta dissertação, o qual também orienta o desenvolvimento do protótipo correspondente. A articulação desses objetivos pode ser encontrada detalhadamente na Seção 1.2.

Com a clara compreensão da problemática, dos objetivos delineados e do panorama atual da área de estudo, tornou-se viável especificar um conjunto de requisitos essenciais para o modelo em desenvolvimento. Estes requisitos são detalhadamente identificados e descritos no Quadro 8, servindo como alicerce para o método aprofundado apresentado no Capítulo 4.

Quadro 8 - Requisitos do método proposto

Requisito	Descrição	Literatura
R01	Elencar uma lista de parâmetros voltada ao desenvolvimento de BMIs para atuar em sinergia com a obtenção de sinais mioelétricos.	A lista de parâmetros para o desenvolvimento de BMIs que operam em sinergia com a captação de sinais mioelétricos deve ser elaborada para garantir a eficácia e a precisão na interpretação dos sinais neurais. Estes parâmetros incluem, mas não se limitam a, a seleção de algoritmos de decodificação apropriados, a integração de feedback sensorial, a otimização da interface de usuário e a garantia de robustez contra artefatos de sinal. A pesquisa de Slutsky (2018) destaca a importância de interfaces intuitivas que possam ser facilmente manipuladas pelos usuários, sugerindo que a usabilidade é um parâmetro crítico para o sucesso das BCIs. Também, a integração de feedback sensorial, como discutido por Pisotta <i>et al.</i> (2015), é essencial para a criação de um sistema de controle mais natural e eficiente. A robustez do sistema contra interferências e artefatos é também um fator crucial, conforme explorado por Dillen <i>et al.</i> (2022), que investigaram métodos de DL para controle de biossinais em tempo real. A pesquisa de Robinson <i>et al.</i> (2021) complementa essa visão ao

		discutir as tendências emergentes em BCIs para controle motor e reabilitação, ressaltando a necessidade de sistemas adaptativos e personalizáveis.
R02	Produzir um roteiro de coleta, armazenamento e utilização de dados operacionais para análise estatística e classificatória.	Para definir métodos de armazenamento de dados operacionais que habilitem análise estatística, classificação e pré-processamento, é importante considerar as características intrínsecas e a complexidade dos dados em questão. O armazenamento e a análise de dados operacionais são fundamentais para a pesquisa e desenvolvimento em diversas áreas, incluindo aquelas que lidam com lesões na medula espinhal e reabilitação, como indicado por Brown <i>et al.</i> (2011) e na otimização de preditores hemodinâmicos para resultados de lesões na medula espinhal, como explorado por Chou <i>et al.</i> (2022). Não obstante, a aplicação de ML e AI na análise de dados de saúde é um campo em crescimento, como discutido por Giansanti (2022), que pode ser relevante para o desenvolvimento de métodos de armazenamento e análise de dados operacionais.
R03	Desenvolver um modelo de predição para a análise de biosinais que possa ser associado às terapias de FES.	A proposta de um modelo computacional para FES assistida deve incorporar avanços recentes em engenharia biomédica e restauração sensorimotor, como destacado por Pisotta, Perruchoud e Ionta (2015), que enfatizam a importância de avanços conjuntos em engenharia biomédica e restauração sensorimotor. A integração de FES com tecnologias de suporte robótico, como o Lokomat®, oferece uma plataforma promissora para reabilitação e pesquisa, conforme explorado por Jezernik <i>et al.</i> (2003). Além disso, a aplicação de ML e AI, como discutido por Popovic e Sinkjær (2000), pode melhorar o controle da FES para restaurar o movimento. A pesquisa de Lai <i>et al.</i> (2021) também é relevante, porque pode ser observada a exploração de estratégias de retransmissão neuronal derivadas de células-tronco em combinação com FES para o tratamento de SCI.

Fonte: Elaborado pelo autor (2023)

A apresentação dos requisitos foi fundamental para guiar a formulação do método teórico. Esta estratégia assegurou que a proposta se mantivesse focada em questões de relevância e atualidade, ao mesmo tempo em que preservou a objetividade em relação aos diversos componentes que integram o modelo.

3.3.3 Projeto e Desenvolvimento

Na DSRM, a fase de projeto e desenvolvimento representa um momento crítico onde o artefato conceitualizado pode ser trazido à realidade. No contexto da presente pesquisa, o artefato em questão é moldado para se adequar aos modelos que demandam a execução de

tarefas complexas, requerendo a expertise de especialistas da área fisioterapêutica em áreas específicas. As nuances deste processo, que envolvem desde a concepção inicial até a materialização do método proposto, são detalhadas nas seções subsequentes.

Este processo de projeto e desenvolvimento é intrinsecamente iterativo, permitindo ajustes e refinamentos contínuos para assegurar que o artefato não apenas atenda às necessidades teóricas, mas que também se alinhe efetivamente com as exigências práticas do ambiente da área da saúde. A interação constante com especialistas de domínio durante esta fase é vital para garantir que o modelo proposto possa ser aplicado com sucesso, proporcionando soluções inovadoras e eficientes para as complexidades inerentes às tarefas que serão executadas.

3.3.3.1 Conjunto de Dados

Para criar o método proposto, foram empregados dados extraídos durante sessões de terapia com um cicloergômetro assistido pela FES. Participantes saudáveis submeteram-se a sessões de terapia, durante as quais seus parâmetros fisiológicos foram registrados, proporcionando uma base de dados rica para análise. Os dados coletados incluíram variáveis de 6 agrupamentos musculares por cada perna (12 ao total), mais um *encoder*, todos cruciais para a compreensão da interação entre o usuário e o dispositivo de FES.

Os dados foram inicialmente submetidos a um processo de condicionamento de dados e pré-processamento, assegurando a qualidade e a precisão das informações para a subsequente fase de modelagem. O Quadro 9 detalha os tipos de dados coletados e os critérios utilizados para sua seleção e inclusão na análise.

Quadro 9 - Estrutura da coleta de dados

Tipo de dado	Canal ou Dimensão	Descrição
Quadríceps Esquerdo	0	O quadríceps esquerdo é um grupo muscular composto por quatro músculos localizados na parte frontal da coxa. Esses músculos são o vasto lateral, vasto medial, vasto intermédio e o reto femoral, e são responsáveis pela extensão do joelho e desempenham um papel crucial na caminhada, corrida e saltos.
Bíceps Femoral Esquerdo	1	O bíceps femoral esquerdo é um dos músculos da parte posterior da coxa, composto por duas cabeças: a longa e a curta. Ele atua principalmente na flexão do joelho e na extensão do quadril, sendo essencial para movimentos como correr, saltar e agachar.
Isquiotibiais Esquerdo	2	Os isquiotibiais esquerdo são um grupo de músculos situados na parte posterior da coxa, incluindo o bíceps

		femoral, o semitendinoso e o semimembranoso. Eles são responsáveis pela flexão do joelho e pela extensão do quadril, desempenhando um papel crucial em atividades que envolvem corrida e saltos, além de contribuir para a estabilidade do joelho.
Tibial Anterior Esquerdo	3	O músculo tibial anterior esquerdo está localizado na parte frontal da perna, ao lado da tibia. É responsável pela dorsiflexão do pé no tornozelo e pela inversão do pé, movimentos essenciais para a marcha, corrida e manutenção do equilíbrio ao caminhar em superfícies irregulares. Este músculo também ajuda a suportar o arco do pé.
Gastrocnêmio Medial Esquerdo	4	O gastrocnêmio medial esquerdo é um dos dois músculos que compõem o gastrocnêmio, situado na parte posterior da perna inferior. É o mais proeminente e visível dos músculos da panturrilha, contribuindo para a flexão plantar do pé no tornozelo e flexão do joelho. Quando ativo, o gastrocnêmio medial auxilia na propulsão do corpo para frente durante atividades como caminhar, correr e saltar.
Gastrocnêmio Lateral Esquerdo	5	O gastrocnêmio lateral esquerdo é o músculo mais lateral e menor dos dois músculos que compõem o gastrocnêmio, localizado na parte de trás da perna, abaixo do joelho. Este músculo trabalha em conjunto com o gastrocnêmio medial para realizar a flexão plantar do pé no tornozelo e auxiliar na flexão do joelho, desempenhando um papel crucial na locomoção, como correr e saltar.
Quadríceps Direito	6	O quadríceps direito é um grupo muscular composto por quatro músculos localizados na parte frontal da coxa. Esses músculos são o vasto lateral, vasto medial, vasto intermédio e o reto femoral. Eles são responsáveis pela extensão do joelho, sendo fundamentais para atividades como caminhar, correr, saltar e subir escadas. O quadríceps também ajuda a estabilizar o joelho quando está em pé.
Bíceps Femoral Direito	7	O bíceps femoral direito é um dos principais músculos dos isquiotibiais, localizado na parte posterior da coxa. É composto por duas cabeças, a longa e a curta, que se originam no ísquio e no fêmur, respectivamente, e se inserem no osso da perna, o fibular. Este músculo é crucial para a flexão do joelho e a extensão do quadril, desempenhando um papel importante em atividades como correr, saltar e qualquer movimento que envolva puxar as pernas para trás ou dobrar os joelhos.
Isquiotibiais Direito	8	Os isquiotibiais direitos são um grupo de músculos situados na parte posterior da coxa, compreendendo o bíceps femoral, o semitendinoso e o semimembranoso. Esses músculos estendem-se desde o ísquio, na pelve, até os ossos da perna. Eles são essenciais para movimentos como a flexão do joelho e a extensão do quadril, sendo fundamentais em atividades que envolvem corrida, salto e estabilização do tronco durante o movimento. Os isquiotibiais são frequentemente foco de fortalecimento e reabilitação devido à sua propensão a lesões, especialmente em atletas.
Tibial Anterior Direito	9	O tibial anterior direito é um músculo localizado na parte frontal da perna, adjacente à tibia. Este músculo é responsável pela dorsiflexão do pé no tornozelo (movimento de elevar o pé em direção à canela) e pela

		inversão do pé (movimento de girar a sola do pé para dentro). O tibial anterior é crucial para atividades como caminhar, correr e manter o equilíbrio enquanto se está em pé, pois ajuda a controlar o impacto do pé com o solo e a estabilizar o tornozelo após o contato do calcanhar durante a marcha.
Gastrocnêmio Medial Direito	10	O gastrocnêmio medial direito é um dos dois músculos principais que compõem a panturrilha, situado na parte posterior da perna inferior. Este músculo, junto com o gastrocnêmio lateral, forma o que é comumente conhecido como o "músculo da panturrilha". O gastrocnêmio medial é responsável pela flexão plantar do pé no tornozelo (empurrando o pé para baixo, como ao ficar na ponta dos pés) e auxilia na flexão do joelho. Devido à sua localização e função, é um músculo que contribui significativamente para atividades como correr, saltar e subir escadas.
Gastrocnêmio Lateral Direito	11	O gastrocnêmio lateral direito é o músculo mais superficial e lateral da panturrilha, localizado na parte de trás da perna inferior. Trabalha em conjunto com o gastrocnêmio medial para realizar a flexão plantar do pé no tornozelo, o que é essencial para atividades como correr, pular e manter a postura ao ficar em pé. Este músculo também ajuda na flexão do joelho e, devido à sua potência e localização, é crucial para gerar a força necessária em movimentos explosivos e para a estabilização durante o movimento.
Pedivela (<i>Encoder/Crankset</i>)	12	O pedivela, também conhecido como <i>crankset</i> em inglês, é um componente essencial de uma bicicleta, conectando os pedais ao movimento central e à corrente. No caso do sistema, ele serviu de ponto de associação do sistema pelo movimento angular realizado na bicicleta ergométrica horizontal aplicada nos pacientes. É composto pelos braços de pedal (<i>cranks</i>) e um ou mais pratos (<i>chainrings</i>) que, quando acionados pelo paciente, convertem o movimento circular dos pedais em movimento linear da corrente, impulsionando a bicicleta para frente. No sistema proposto com sensores (<i>encoder</i>), o pedivela coletou informações valiosas para treinamento do algoritmo.

Fonte: Elaborado pelo autor (2023)

Desta forma, foram criados conjuntos de dados distintos para testar o método. Cada um dos conjuntos foi separado por paciente, com atendimento às exigências legais (como mais bem detalhado na Seção 3.3.4), a fim de garantir uma distribuição equitativa de sessões por indivíduo, refletindo uma variedade ampla de interações com o cicloergômetro assistido por FES.

Crítérios de exclusão foram meticulosamente aplicados para assegurar a integridade dos conjuntos de dados. Dados incompletos ou inconsistentes foram descartados, e apenas sessões que forneceram um conjunto completo de variáveis foram incluídas. Os conjuntos de dados estão documentados no Apêndice A.

3.3.3.2 Coleta dos Dados

Na condução deste estudo, foi empregada uma abordagem na coleta de dados, que foi promovida por dispositivos eletrônicos, placas de circuito e SoC customizados. Esses dispositivos foram meticulosamente projetados para integrarem-se com sensores de precisão, que foram cuidadosamente acoplados a cada um dos doze agrupamentos musculares dos participantes. Essa configuração permitiu a captação de sinais mioelétricos em tempo real, proporcionando um panorama detalhado da atividade muscular durante as sessões de eletroestimulação funcional.

Também foram coletados dados do *crankset*, que em conjunto com os dados de ativação muscular, podem fornecer informações sobre a cadência das pedaladas; elemento importante para avaliar a interação entre a estimulação elétrica e a resposta motora. Este arranjo de sensores e circuitos, aliado a programação do sistema, possibilitou a aquisição de dados robustos e detalhados, para a análise subsequente do impacto da FES na funcionalidade muscular.

Durante a fase de coleta de dados, foi adotada uma estratégia de validação cruzada, utilizando equipamentos proprietários de mercado de reconhecida precisão para assegurar a veracidade das informações obtidas pelos dispositivos customizados. Essa comparação meticulosa foi essencial para confirmar a acurácia dos dados coletados, especialmente no que tange à fidelidade dos sinais mioelétricos. A correlação dos dados com os padrões estabelecidos pelos equipamentos comerciais não apenas reforçou a confiabilidade das medições, mas também proporcionou uma camada adicional de confiança na integridade dos dados, garantindo que as análises subsequentes estivessem fundamentadas em informações precisas e validadas.

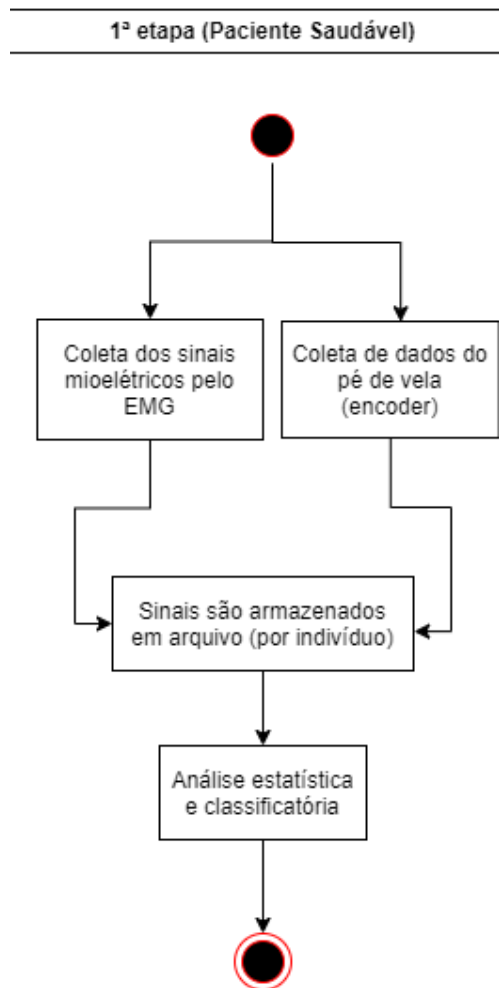
A concepção dos circuitos e sensores personalizados foi impulsionada pela limitação imposta pelos equipamentos proprietários, que embora precisos, não oferecem a flexibilidade de exportar todos os dados para além de seus sistemas fechados. Esta restrição representa um obstáculo significativo para a pesquisa e desenvolvimento de sistemas especializados, que demandam a integração e análise de dados em plataformas heterogêneas.

A necessidade de uma arquitetura aberta e adaptável, capaz de se comunicar e operar em conjunto com uma variedade de sistemas e dispositivos, foi um dos catalisadores para a criação desta solução customizada.

Ao desenvolver uma própria tecnologia de coleta de dados, garante-se a autonomia necessária para manipular, exportar e analisar as informações conforme a especificidade do projeto, superando as barreiras impostas pelos sistemas proprietários e avançando em direção a

uma pesquisa mais integrada e abrangente. Na Figura 22 pode ser verificado o diagrama que representa o processo de coleta de dados validado com os fisioterapeutas.

Figura 22 - Processo de coleta de dados do equipamento



Fonte: Elaborado pelo autor (2023)

Como pode ser observado, a metodologia adotada para a coleta de dados musculares e do cicloergômetro permitiu a construção de um banco de dados robusto, essencial para a validação do modelo computacional desenvolvido na análise estatística e classificatória, para posterior utilização no modelo computacional.

Durante o processo foi observada a necessidade de dados abertos: a coleta de dados em um formato aberto e exportável foi essencial para a integração com sistemas heterogêneos, facilitando a análise e o pré-processamento estatístico, por isso os dados foram extraídos em formato binário (*.ftr) para agilidade do sistema em salvar as informações dos biosinais e, posteriormente, transpostos em um arquivo simples de texto separado por vírgulas, no Código

Padrão Americano para o Intercâmbio de Informação (do inglês *American Standard Code for Information Interchange - ASCII*) (*.csv), para facilitar o processamento em alto nível em Linguagem Python.

3.3.3.3 Pré-processamento dos dados

Depois dos dados serem coletados, desenvolveu-se um algoritmo para transformação dos dados dos agrupamentos musculares e do *crankset* para possibilitar a organização dos dados em formato legível para algoritmos em Linguagem Python, que foi escolhida pela sua vasta disponibilidade de bibliotecas específicas para essa aplicação, conforme pode ser verificado no Quadro 10.

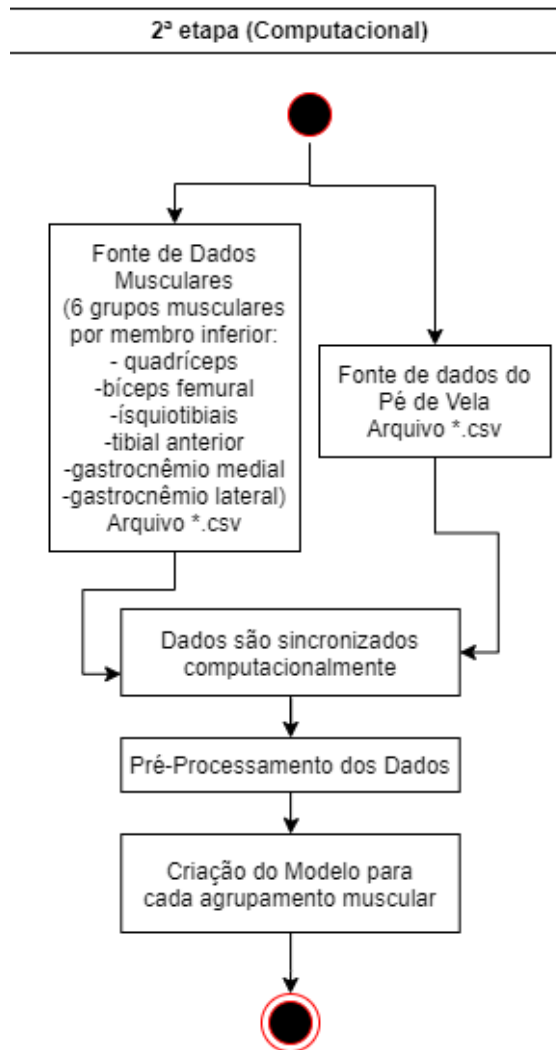
Quadro 10 - Código de conversão dos arquivos de dados binários das leituras de biosinais dos pacientes durante a utilização do cicloergômetro assistido por FES

```
import csv
dados = []
with open('arquivo_de_leitura_do_paciente.ftr', 'rb') as f:
    for _ in range(37):
        f.readline()
    while True:
        conjunto_canais = []
        for i in range(13):
            high = f.read(1)
            low = f.read(1)
            if not high or not low:
                break
            valor = (high[0] << 8) + low[0]
            tensao = valor * 3.3 / 4095.0
            conjunto_canais.append(tensao)
        if len(conjunto_canais) < 13:
            break
        dados.append(conjunto_canais)
with open('arquivo_de_leitura_convertido.csv', 'w', newline='') as csvfile:
    writer = csv.writer(csvfile)
    for linha in dados:
        writer.writerow(linha)
```

Fonte: Elaborado pelo autor (2023)

De posse do arquivo e do conjunto de canais, criou-se o método que admite um modelo para cada agrupamento muscular conforme a Figura 23.

Figura 23 - Processo de pré-processamento dos dados, simplificado



Fonte: Elaborado pelo autor (2023)

3.3.3.4 Estratégias do algoritmo

A solução em questão adotada foi pela implementação de uma Rede Neural Recorrente (do inglês *Recurrent Neural Network* - RNN) com células de Memória de Longo e Curto Prazo (do inglês *Long Short-Term Memory* - LSTM) para processar dados sequenciais. A matemática por trás desse tipo de rede neural é rica e complexa, envolvendo várias equações e conceitos fundamentais.

As RNNs são redes neurais que adicionam conexões recorrentes aos neurônios, permitindo que a informação persista. Para o modelo, foi aplicado uso de interação com adição

de camadas recorrentes ao modelo; para isso, foi utilizado o módulo Keras⁴, que é uma biblioteca de redes neurais de alto nível escrita em Linguagem Python disponível através de *frameworks* de ML como TensorFlow, Theano ou CNTK, tendo sido desenvolvida com o objetivo de permitir a experimentação rápida com redes neurais profundas, utilizada habitualmente via uma Interface de Programação de Aplicativos (do inglês *Application Programming Interface* - API).

No baixo nível, em termos matemáticos da utilização das técnicas da API, a saída h_t de um neurônio em um tempo t é uma função da entrada atual x_t e da saída anterior h_{t-1} , onde W_{hh} e W_{xh} são matrizes de pesos, b_h é um vetor de viés, e f é uma função de ativação não-linear, como a tangente hiperbólica ilustrada na Equação 1.

$$h_t = f(w_{hh}h_{t-1} + w_{3xt} + b_h) \quad (1)$$

Entretanto, durante o treinamento, o gradiente pode desvanecer (tornar-se muito pequeno) ou explodir (tornar-se muito grande), o que pode dificultar a aprendizagem de dependências de longo prazo (problema do desvanecimento do gradiente). As LSTMs resolvem este problema introduzindo uma estrutura de célula com portas que controlam o fluxo de informações. A seguir, são apresentadas as equações que regem uma célula LSTM:

- Porta de esquecimento (Equação 2):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

- Porta de entrada (Equação 3):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

- Candidato a célula de memória (Equação 4):

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

⁴ Documentação disponível em: <https://keras.io/>

- Atualização da célula de memória (Equação 5):

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

- Porta de saída (Equação 6):

$$\sigma_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

- Saída (Equação 7):

$$h_t = \sigma_t * \tanh(C_t) \quad (7)$$

Aqui, σ denota a função sigmoide, que é usada para ativar as portas, e \tanh é a função tangente hiperbólica, que é usada para criar o candidato a célula de memória. W e b são as matrizes de pesos e vetores de viés para cada porta e o candidato a célula de memória, respectivamente.

Outro elemento importante de atenção refere-se a regularização em se pode aplicar a técnica de *dropout* (Equação 8). Esta envolve a desativação aleatória de neurônios durante o treinamento de uma ANN com o objetivo de minimizar o sobreajuste (do inglês *overfitting*).

$$h'_t = D \cdot h_t \quad (8)$$

Matematicamente, isso pode ser representado como multiplicar a saída da camada por uma máscara binária D (com elementos sendo 0 ou 1 com probabilidade p). O *Dropout* habitualmente segue um quociente de redução que a cada operação tende a excluir parte desses dados aleatoriamente.

Diante disso, torna-se necessária a concepção das camadas densas da LSTM, objetivando a predição final. A saída da camada densa é uma combinação linear dos inputs seguida por uma função de ativação (Equação 9):

$$y = W_y h_t + b_y \quad (9)$$

Para a função de perda, a Equação 10 ilustra como é utilizado o erro quadrático médio (do inglês *Mean Squared Error* - MSE), que é a média dos quadrados das diferenças entre as previsões \hat{y} e os valores verdadeiros y :

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y} - y_i)^2 \quad (10)$$

O otimizador Adam⁵ é utilizado para ajustar os pesos dos neurônios. Este combina as ideias de *momentum* e RMSprop, para que em cada passo t , o Adam atualize os pesos θ conforme segue ilustrado na Equação 11.

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) \cdot g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) \cdot g_t^2 \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} &= \theta_t - \frac{\alpha \cdot \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \end{aligned} \quad (11)$$

Essas equações são a base matemática para o treinamento do modelo LSTM, permitindo que ele aprenda a partir de dados sequenciais complexos, onde g_t é o gradiente do erro em relação aos pesos no tempo t , m_t e v_t são estimativas dos primeiros e segundos momentos dos gradientes. Tanto β_1 como β_2 são taxas de decaimento exponencial para esses momentos, e por fim, α é a taxa de aprendizado. A integração entre *keras.models* e RNNs é feita através da adição de camadas recorrentes ao modelo, que ocorre quando é promovida a instrução ao Keras para construir a arquitetura de rede neural com a capacidade de processar dados sequenciais junto a mecânica das LSTMs.

⁵ Documentação disponível em: <https://keras.io/api/optimizers/adam/>

3.3.4 Demonstração

A fase de demonstração do método foi marcada pela implementação de um protótipo que se utilizou de conjuntos de dados descritos na Seção 3.3.3.1. Neste caso específico, a tarefa foi simbolizada pela coleta e análise de dados mioelétricos durante sessões de FES.

Os participantes, foram um grupo selecionado de indivíduos submetidos a ciclos de eletroestimulação, cujos dados foram coletados e analisados para avaliar a precisão do método, conforme Tabela 2.

Tabela 2 - Listagem de indivíduos envolvidos na pesquisa

Paciente	Idade
A/1	21
B/2	18
C/3	23
D/4	26
E/5	23
F/6	22
G/7	23
H/8	21
I/9	26
J/10	20
K/11	23
L/12	23

Fonte: Elaborado pelo autor (2023)

A obtenção e manipulação dos dados no estudo foram cuidadosamente planejados para alinharem-se com os padrões de ética e conformidade legal, abrangendo a Lei Geral de Proteção de Dados (LGPD) e outras normativas aplicáveis à saúde e segurança da informação, de forma que não foram cedidos dados sensíveis para realização desta pesquisa. Não obstante, essa pesquisa foi cadastrada como projeto, denominado "Desenvolvimento de um cicloergômetro assistido por condução mioelétrica no tratamento de pacientes com sequelas de Traumatismo Raquimedular (TRM)", oficialmente inscrita na plataforma Brasil, recebendo atualização mais recente em 02/08/2023, assegurando a integridade e a responsabilidade no manejo dos dados recolhidos junto ao Governo Brasileiro e autoridades competentes como o Ministério da Saúde do Brasil.

No decorrer da pesquisa, a anonimização dos dados foi rigorosamente aplicada para salvaguardar a privacidade dos participantes. As sessões de recolha de dados foram executadas com estrito controle, utilizando dispositivos eletrônicos projetados especificamente para a captação precisa de sinais mioelétricos. Equipados com SoC, tais como placas de circuito

personalizadas, esses dispositivos foram acoplados aos 12 conjuntos musculares dos pacientes, além de sincronizar informações do cicloergômetro.

Este meticuloso processo não só garantiu a exatidão dos dados recolhidos como também viabilizou um pré-processamento eficiente, crucial para análises posteriores conforme mencionado na seção 3.3.3.3. Esses mecanismos de proteção e de integridade dos dados foram uma constante preocupação ao longo de todas as fases do projeto. Protocolos de segurança com senhas de acesso individuais e restritas foram implementados para o armazenamento e transferência de dados, além da utilização de Sistemas Operacionais com suporte a criptografia e utilização de PIN de acesso, visando que todas as informações estivessem resguardadas contra acessos não consentidos e utilizações impróprias. Com estas ações, o projeto não somente cumpriu com os requisitos legais, mas também buscou um marco de qualidade para a pesquisa na consonância entre tecnologia e reabilitação neuromuscular e sistemas especialistas.

O método em questão foi desenhado com elementos conceituais flexíveis, permitindo sua aplicação em situações práticas variadas. Assim, as sessões de eletroestimulação representam instâncias específicas de tarefas em série temporal. A base de conhecimento construída para este projeto foi essencial para mapear a interação entre os estímulos elétricos e a resposta muscular.

Utilizando esta ferramenta, foi possível identificar padrões e correlações significativas nos dados coletados. Cada sessão de eletroestimulação foi documentada paralelamente clinicamente com detalhes como intensidade, duração, angulação, videocâmera, frequência dos estímulos e a resposta mioelétrica correspondente. Além da documentação básica dos dados coletados, o modelo foi equipado para realizar a extração de características. Esta abordagem permitiu uma análise mais profunda e a criação de representações vetoriais dos dados, facilitando a identificação de padrões complexos e auxiliando na personalização do perfil de eletroestimulação para cada indivíduo.

3.3.5 Avaliação

Na fase de avaliação do modelo, conforme delineado pela metodologia dessa pesquisa (DRSM), o foco foi aprofundar a compreensão dos elementos do método e determinar as configurações ótimas para os dados coletados, permitindo uma análise criteriosa dos resultados após a segmentação dos perfis dos pacientes e suas séries temporais na ANN.

Para avaliar sua eficácia e interpretar os resultados, a Raiz Quadrada do Erro-Médio (do inglês *Root Mean Square Error* - RMSE) provou ser uma métrica de desempenho importante.

Por ser uma métrica amplamente utilizada nas áreas de climatologia, ciências ambientais, mercado financeiro e outras que utilizam séries temporais, servindo como um padrão para avaliação de desempenho de modelos, a RMSE é particularmente valorizada por sua capacidade de quantificar a magnitude dos erros de previsão, oferecendo uma imagem clara da precisão do modelo (WILLMOTT; MATSUURA, 2005; CHNITI; BAKIR; ZAHER, 2017). No entanto, a adequação da RMSE tem sido debatida, especialmente quando comparada a outras estatísticas, como o Erro Absoluto Médio (do inglês *Mean Absolute Error* - MAE).

O RMSE é calculado tomando a raiz quadrada da média dos quadrados das diferenças entre os valores previstos e os valores reais, conforme pode ser verificado na Equação 10. Esse processo de elevar ao quadrado penaliza erros maiores, o que pode ser tanto uma força quanto uma fraqueza. Erros maiores se tornam mais proeminentes na RMSE, tornando-a sensível a valores extremos e potencialmente distorcendo a avaliação do modelo se a distribuição de erros não for uniforme (WILLMOTT; MATSUURA, 2005).

Willmott e Matsuura (2005) ainda, argumentam que a RMSE pode ser enganosa porque é influenciada por três características dos conjuntos de erros: a variabilidade dentro da distribuição de magnitudes de erro, a raiz quadrada do número de erros e a magnitude média do erro. Eles sugerem que o MAE (Equação 12) pode ser uma medida mais natural de erro médio, pois é inequívoco e focado exclusivamente na magnitude média do erro.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

O MAE fornece uma medida direta da média dos erros absolutos, sem penalizar tanto os *outliers* quanto a RMSE. Chai e Draxler (2014) contrapõem o argumento contra a RMSE, afirmando que ele não é ambíguo e é mais apropriado do que o MAE quando a distribuição de erros é esperada para ser gaussiana. Eles enfatizam que a RMSE satisfaz o requisito da desigualdade triangular para uma métrica de distância, que é uma propriedade crucial para uma medida de erro.

O uso da RMSE é particularmente prevalente em problemas de regressão e previsão de séries temporais, onde dados contínuos estão envolvidos. Nestes contextos, a RMSE fornece uma medida útil de quão bem um modelo pode prever uma variável de resultado contínua, que acaba ser especialmente comum na avaliação de modelos como RNNs, frequentemente em aplicação para análise de séries temporais (CHAI; DRAXLER, 2014).

Um nível aceitável de RMSE varia de acordo com o contexto e é frequentemente determinado comparando-o com o desvio padrão da variável dependente. Uma regra geral é que uma RMSE menor que o desvio padrão indica um modelo com capacidade preditiva melhor. No entanto, esta não é uma regra absoluta, e o conhecimento específico do domínio é essencial para interpretar os valores de RMSE (CHAI; DRAXLER, 2014).

A RMSE também é usada ao lado de outras métricas para fornecer uma avaliação mais abrangente do desempenho do modelo. Neste sentido, o Coeficiente de Determinação (R^2) e a Eficiência de Nash-Sutcliffe (NSE) são frequentemente usados em conjunto com o RMSE para avaliar o ajuste de modelos hidrológicos (MORIASI *et al.*, 2015).

Apesar de seu uso generalizado, a RMSE tem limitações, pois não fornece informações sobre a direção dos erros (sobre ou subestimação) e pode ser sensível a valores extremos. Essa sensibilidade pode ser tanto uma vantagem quanto uma desvantagem, dependendo dos objetivos específicos da avaliação do modelo (WILLMOTT *et al.*, 1981).

Na prática, a RMSE é frequentemente usada na calibração de modelos, onde o objetivo é ajustar os parâmetros do modelo para minimizar a RMSE entre as previsões do modelo e os dados observados. Este processo é iterativo e requer um equilíbrio cuidadoso entre a complexidade do modelo e a precisão preditiva (MORIASI *et al.*, 2015).

Ao utilizar o RMSE, é importante fornecer contexto, comparando-o com outros modelos ou *benchmarks* pela primazia da garantia de uma utilização adequada. Esta abordagem comparativa ajuda a interpretar o valor da RMSE de forma significativa e determinar sua aceitabilidade (CHAI; DRAXLER, 2014). Em termos de avaliação de modelos, a RMSE pode ser visualizada em uma relação de desempenho ao lado de outras métricas para fornecer uma visão abrangente, conforme exemplo na Tabela 3.

Tabela 3 - Exemplo de relação de métricas entre RMSE, MAE e R^2

Métrica	Valor
RMSE	X
MAE	Y
R^2	Z

Fonte: Elaborado pelo autor (2023)

No campo de ML, a RMSE é comumente usada em procedimentos de validação cruzada para selecionar modelos e ajustar hiperparâmetros, onde o modelo com o menor RMSE em um conjunto de validação é frequentemente escolhido como o melhor modelo para fazer previsões em novos dados (CHAI; DRAXLER, 2014).

Mesmo o contraste e os diferentes ônus e bônus da utilização de cada técnica, com alguns pesquisadores defendendo o uso de um em detrimento do outro, a escolha entre essas métricas deve ser informada pelo tipo de dados, a distribuição dos erros, e os objetivos específicos da modelagem (WILLMOTT; MATSUURA, 2005).

3.3.6 Comunicação

A disseminação dos achados, artefatos e elementos diversos deste estudo será realizada por meio do detalhamento da dissertação, destinada à apreciação e ao debate pela comunidade acadêmica. Com isso, a partilha de conhecimento será ampliada através de artigos que já foram produzidos e submetidos em periódicos científicos, bem como por futuras publicações que visam contribuir para o corpo de conhecimento existente. Estas publicações servirão como um veículo para a troca de ideias, permitindo a evolução contínua do campo de estudo em questão e dessa pesquisa.

3.4 SÍNTESE DA METODOLOGIA DA PESQUISA

A pesquisa científica é frequentemente descrita como uma jornada pragmática e sistemática através do método científico, buscando soluções para problemas complexos e contribuindo para o avanço do conhecimento. No campo da Engenharia de Produção, por exemplo, Lacerda *et al.* (2013) destacam a importância de adotar uma estratégia de pesquisa focada na evolução da Engenharia de Produção como uma Ciência do Design (do inglês *Design Science* - DS), ressaltando a relevância dos conceitos associados à DSR e propondo etapas adequadas para conduzir esse contexto.

Já se tratando da EC, no estudo de Beck *et al.* (2012) argumentam que é necessária uma nova abordagem entre a comunidade médica, a pesquisa científica e a prática especialista, identificando a existência de um “abismo” entre a otimização efetiva das decisões clínicas.

Em outra pesquisa, Miah, Kerr e Hellens (2014) exploram o conhecimento de artefato de *design* na pesquisa de DS e sua aplicação na melhoria do desenvolvimento de Sistemas de Suporte à Decisão (do inglês *Decision Support Systems* - DSS). Eles desenvolvem um artefato coletivo de design de DSS como método em um contexto prático da indústria, utilizando princípios de *design* de interação orientados a objetivos e técnicas de ambiente de *design* e ontologia, ilustrando como a DSR pode ser aplicada para atender às necessidades contextuais dos tomadores de decisão em um contexto da indústria agrícola.

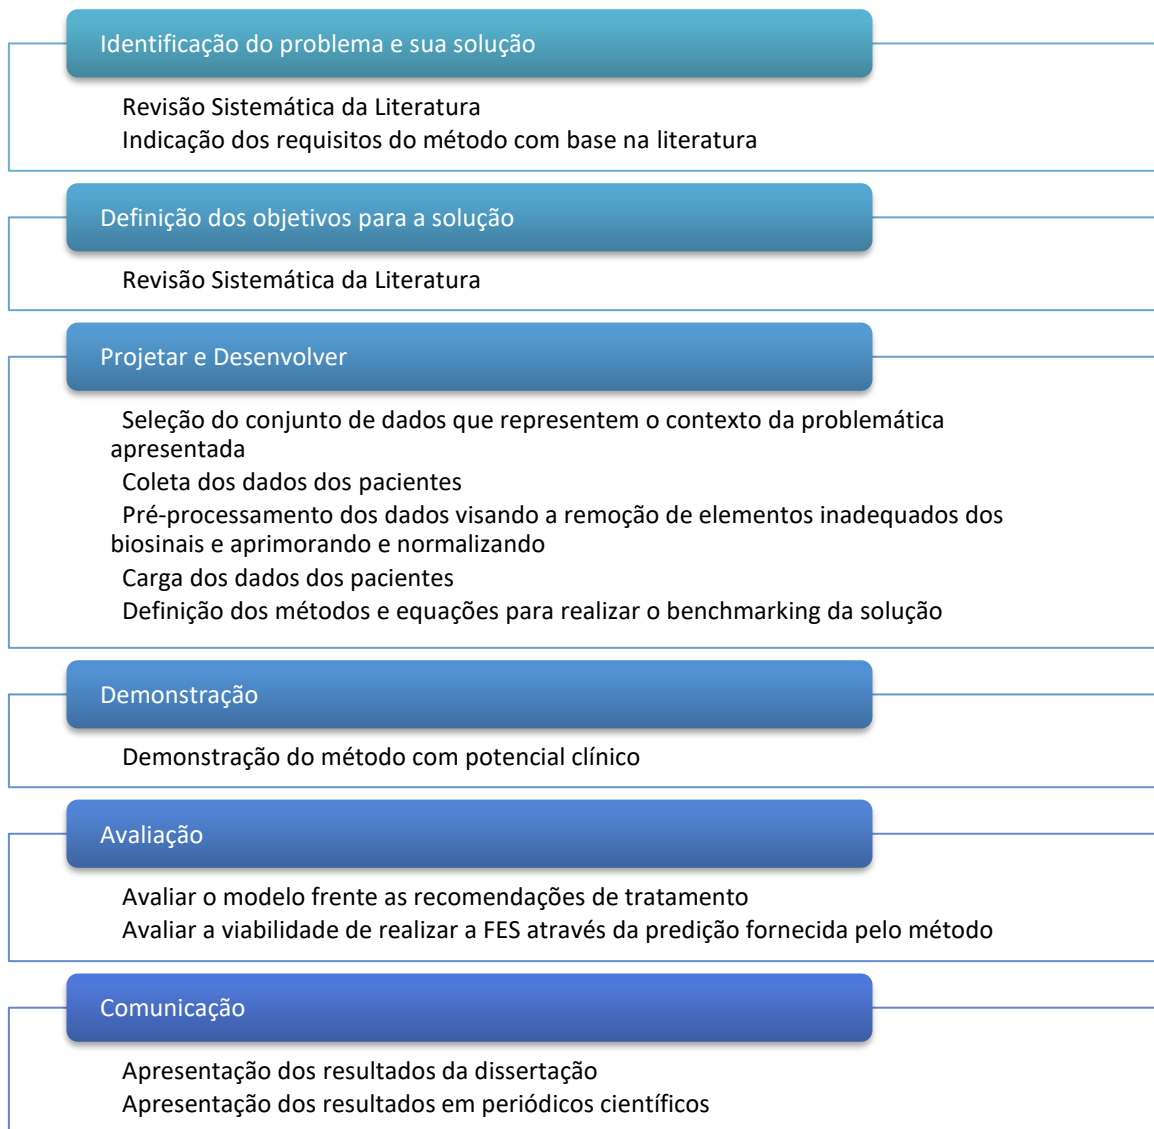
Teixeira, Patrício e Tuunanen (2019) apresentam a pesquisa de Design de Serviços (do inglês *Service Design Research* - SDR) e examinam como a metodologia de pesquisa DSR, de forma que pode ser útil para o desenvolvimento de novos artefatos, como construtos, métodos e modelos de design de serviços. Eles propõem a DSR como uma metodologia para desenvolver soluções prescritivas para classes de problemas, apoiando a pesquisa de design de serviços no desenvolvimento de pesquisas rigorosas e relevantes. Não obstante, o trabalho demonstra como ela pode ser adaptada para alavancar a abordagem participativa, iterativa, centrada no ser humano e criativa da pesquisa de design de serviços.

Por fim, Lyon *et al.* (2021) introduzem o *Cognitive Walkthrough for Implementation Strategies* (CWIS), um método pragmático e de métodos mistos para avaliar estratégias de implementação complexas e socialmente mediadas. O CWIS inclui etapas como análise de tarefas hierárquicas e identificação, classificação e priorização de problemas de usabilidade. Este método pode ser especialmente útil para avaliar a usabilidade de estratégias de implementação em contextos clínicos e de saúde mental.

Deste modo, a elaboração das etapas (Figura 24) e a construção dos artefatos ocorreu por meio da representação sintética a seguir:

- Essência da pesquisa: prática;
- Caráter da pesquisa: tecnológico;
- Método de abordagem do problema: quantitativo;
- Finalidades: investigativa e elucidativa;
- Estratégia metodológica: Metodologia de Pesquisa em DSRM.

Figura 24 - Síntese da proposição do desenvolvimento de pesquisa



Fonte: Elaborado pelo autor (2023)

4 MÉTODO PROPOSTO

Neste segmento do trabalho, é apresentado o método proposto nesta pesquisa, exemplificando todas as suas fases, que visa ser aplicado com potencial para recomendar tratamentos para pacientes com SCI. O foco está em descrever as nuances e as etapas cruciais que o compõem, facilitando a compreensão da metodologia aplicada.

Para a instanciação do método, desenvolveu-se um sistema, na qualidade de protótipo, com o intuito de sugerir tratamentos de eletroestimulação personalizados, baseando-se em dados mioelétricos e respostas fisiológicas de pacientes. Para tal, foram coletados dados através de sensores especializados, que capturam sinais elétricos musculares e os traduzem em representações numéricas. Esses dados são então processados utilizando técnicas avançadas de aprendizado de máquina, incluindo a transformação dos sinais em que podem ser comparados e analisados pelo algoritmo.

Através da análise dos dados, o sistema é capaz de identificar padrões e sugerir o protocolo de eletroestimulação mais eficaz para cada grupo muscular específico. Neste sentido, desenvolveu-se um modelo avançado de rede neural recorrente, especificamente uma LSTM, para recomendar protocolos de FES personalizados. A LSTM é alimentada com um conjunto de dados de treinamento composto por sequências de entrada, onde nesse contexto, os últimos “ n ” pontos de dados de uma série temporal, e o valor alvo correspondente, que seria o próximo ponto na série temporal são utilizados, sendo esses conjuntos de dados cruciais para o aprendizado e a precisão do modelo.

Durante o treinamento, os dados são processados de maneira *feedforward*, passando sequencialmente pela rede, camada por camada, até a saída. A LSTM foi escolhida, sendo particularmente adequada, uma vez comparada aos diferentes métodos utilizados na literatura para tratamento em SCI, em especial na atuação de biosinais, visto que processam as informações de forma sequencial, utilizando células de memória e o estado oculto a cada passo de tempo, o que é essencial para capturar as dinâmicas temporais dos sinais mioelétricos em séries temporais.

Após a obtenção da saída, o modelo utiliza *backpropagation* para calcular o erro usando a função de perda, que expõe seu desempenho através do MSE. Esse erro é então propagado de volta pela rede, permitindo o ajuste dos pesos para minimizar o erro. As LSTMs utilizam uma forma especializada de *backpropagation* conhecida como *Backpropagation Through Time* (BPTT), que é adaptada para lidar com as dependências temporais dos dados.

O otimizador Adam foi utilizado para ajustar os pesos da rede, se baseando no gradiente do erro. Sua escolha ocorreu devido a sua capacidade de ajustar a taxa de aprendizado para cada parâmetro de forma individual, utilizando estimativas dos primeiros e segundos momentos dos gradientes. Este método de otimização é iterativo com os dados, repetindo o processo de *feedforward* e *backpropagation* por várias épocas (do inglês *epoch*), com o modelo ajustando seus pesos a cada iteração para reduzir a função de perda e aumentar sua acurácia preditiva.

Após o treinamento, o método pode ser avaliado utilizando um conjunto de dados de teste distintos por meio de métricas como MAE, MSE e R^2 , possibilitando verificar sua capacidade preditiva do mesmo. A escolha da arquitetura LSTM para esse estudo reforça-se pela sua capacidade de capturar dependências de longo prazo nos dados sequenciais das séries temporais, que são robustas contra problemas como o desaparecimento do gradiente, comum em outras variantes de redes neurais recorrentes. Este modelo torna-se uma alternativa na personalização do tratamento de pacientes com sequelas neuromusculares, em busca de precisão da FES, que terá a relevância de cada protocolo sendo determinada pelo modelo de predição em atenção ao perfil específico do paciente. O profissional da saúde poderá conferir a representação dos dados em gráficos para habilitar uma visão intuitiva das conexões entre diferentes grupos musculares e respostas ao tratamento, com potencial de enriquecer a análise clínica.

As seções adiante oferecem uma explanação conceitual sobre os elementos e artefatos que constituem o método proposto que, sob uma perspectiva holística teórica e também técnica, detalha os componentes e o funcionamento prático do mesmo. Este enfoque bifurcado assegura que tanto a fundamentação teórica quanto a aplicação prática sejam compreendidas, garantindo uma visão holística dessa pesquisa.

4.1 REPRESENTAÇÃO ONTOLÓGICA DO MÉTODO

Há mais de três décadas, os campos do conhecimento têm testemunhado, em especial o da IA, um crescente interesse nas ontologias para representar conhecimento, evidenciado por intensas pesquisas em áreas como EC, processamento de linguagem natural e representação do conhecimento (STUDER; BENJAMINS; FENSEL, 1998).

O uso do conceito se difunde significativamente nos domínios em que seja necessária a integração de informações inteligentes, como a busca de informações em tempo real localmente e na web, demandando um controle para facilitar a troca de dados e o gerenciamento do conhecimento (SARRAIPA *et al.* 2008). Na área médica, as ontologias podem ajudar a buscar

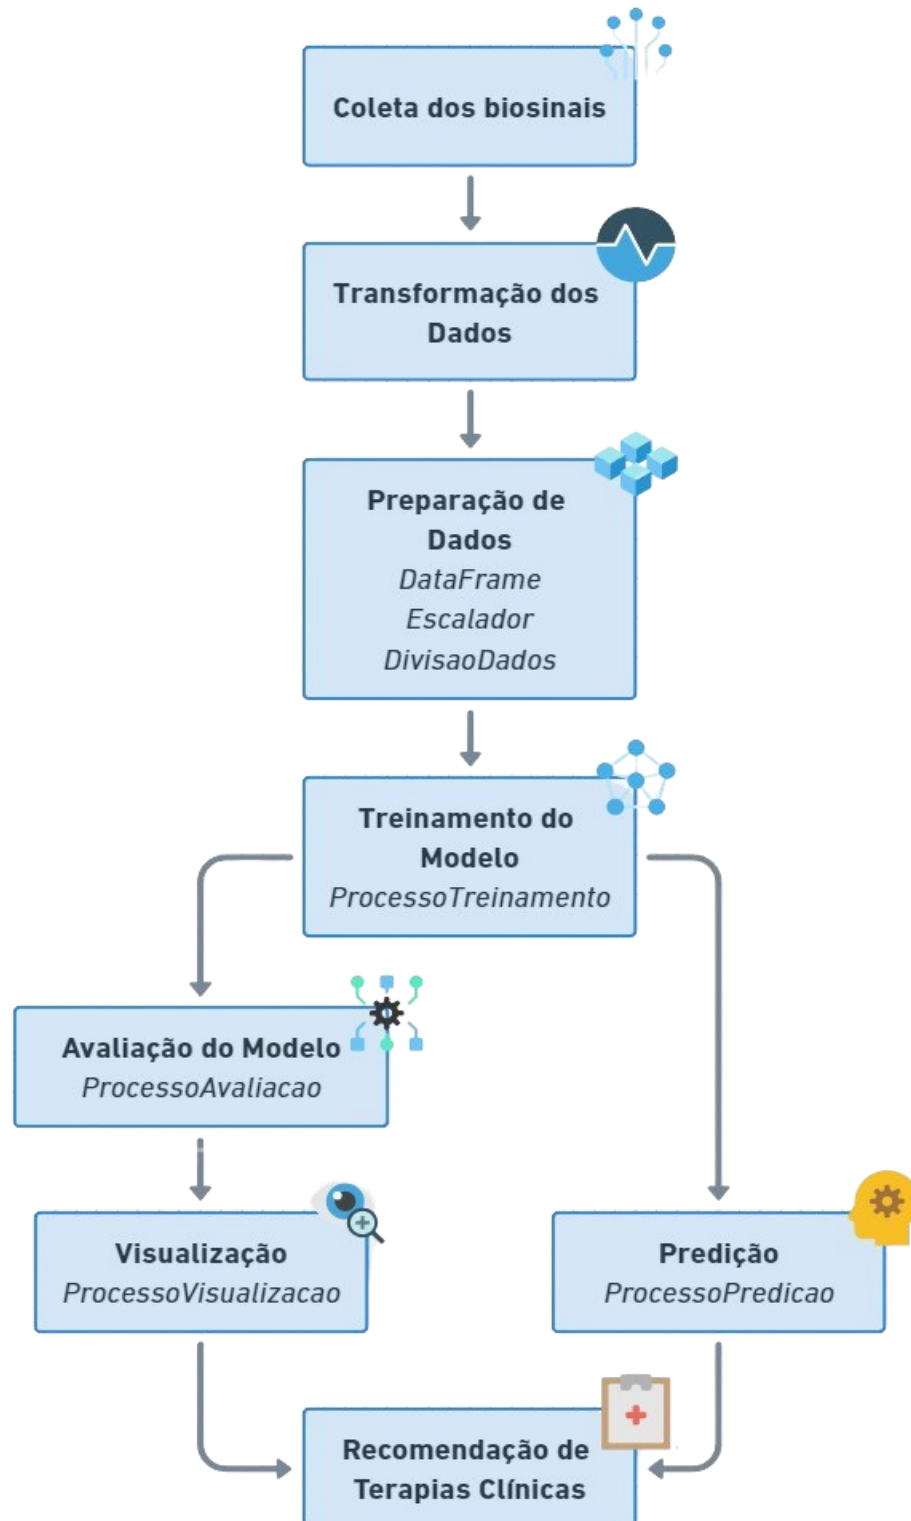
um entendimento comum entre os indivíduos, especificando a terminologia através de uma representação formalizada, descrevendo funções e relações de forma mais precisa e acessível entre as inter-relações humano-máquina, delineando inclusive a semântica fundamental da representação de conhecimento clínica, incluindo aplicações de IA (CHEPELEV *et al.*, 2023).

A razão fundamental para essa ascensão das ontologias reside em sua capacidade de estabelecer um entendimento comum e compartilhado sobre domínios específicos, facilitando a comunicação tanto entre indivíduos quanto entre sistemas computacionais (STUDER; BENJAMINS; FENSEL, 1998; MOHSEN AFSHARCHI *et al.* 2012).

Deste modo, a elaboração da representação do método por meio de uma ontologia visa estabelecer de forma clara os conceitos que são a base para a proposição deste trabalho. Tal abordagem ajuda a criar definições mais exatas e facilita a compreensão da estrutura do método, bem como de seus mecanismos internos. O que se busca, portanto, é uma apreensão mais aprofundada dos conceitos, sem que se atribua um papel funcional rígido à ontologia, preservando assim a versatilidade do método quanto às suas aplicações futuras.

Para visualização conceitual inicial, o diagrama a seguir objetiva elucidar as fases de Início, Coleta dos biosinais, Transformação dos Dados, Preparação de Dados, Treinamento do Modelo, Avaliação do Modelo, Visualização, Predição e Final conforme ilustrado e conceituado na Figura 25 e na Figura 26.

Figura 25 - Representação resumida do método proposto



Fonte: Elaborado pelo autor (2023)

Figura 26 - Conceitualização das classes que representam o método proposto



Fonte: Elaborado pelo autor (2023)

Como pode ser observado, cada uma dessas fases possui entidades específicas que fazem-se necessárias ao entendimento da proposta deste trabalho para formalização do conhecimento específico. Seguindo nesse raciocínio, para a elaboração dessa representação

ontológica, recorre-se à Linguagem Unificada de Modelagem (do inglês *Unified Modeling Language* - UML), uma linguagem padrão para modelagem de sistemas, que possui o potencial de especificar as relações estruturais do modelo, e que será detalhada na seção à seguir.

4.2 REPRESENTAÇÃO CONCEITUAL DO MÉTODO

A UML se mostra eficaz na representação do conhecimento, especialmente quando se trata de modelagem conceitual, conforme discutido por Al-Fedaghi (2022). A representação do método proposto está ilustrada na Figura 27, que oferece uma visão Conceitual e das Classes, destacando a inter-relação entre seus componentes e facilitando o entendimento de sua arquitetura.

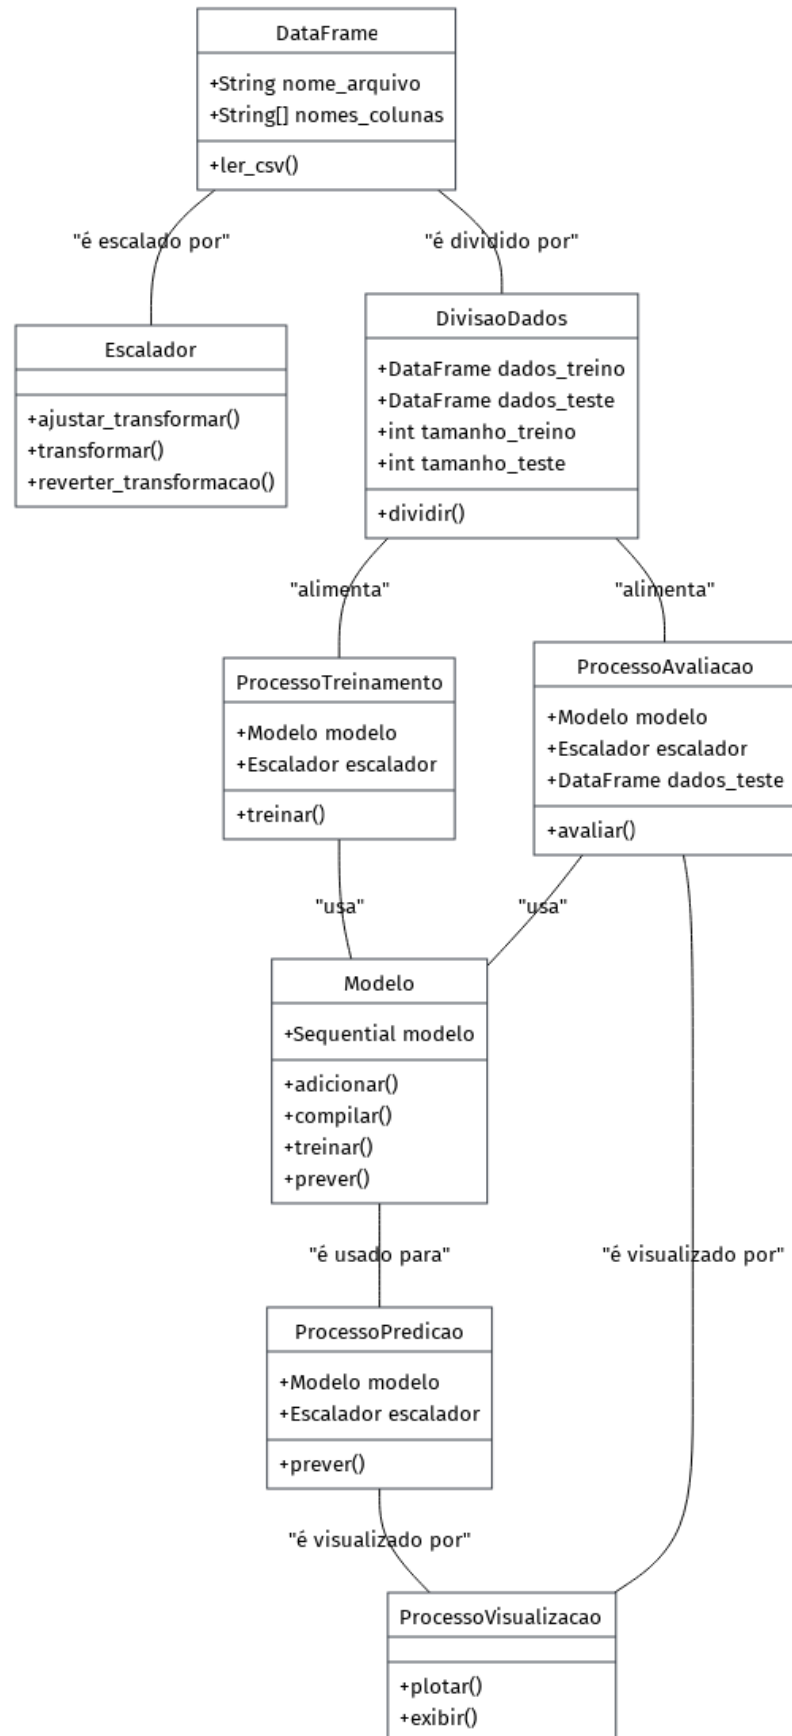
De forma conceitual, esse diagrama também consegue elucidar e representar o encapsulamento da estrutura de previsão de séries temporais utilizando uma RNN do tipo LSTM, servindo como a representação abstrata e conceitual do processo de manipulação de dados, treinamento de modelo e avaliação de desempenho, bem como a subsequente aplicação do modelo treinado para prever valores futuros.

No núcleo do diagrama, a classe “*DataFrame*” simboliza a estrutura de dados primária, contendo séries temporais, cujos nomes de colunas são especificados e manipulados através do método “*ler_csv*”. A classe “*Escalador*” reflete o mecanismo de pré-processamento, responsável por normalizar os dados, essencial para o desempenho eficaz do modelo de aprendizado a ser utilizado, e inclui métodos para ajustar e aplicar a transformação, bem como reverter os dados para sua escala original após a previsão.

O “*Modelo*”, representado como uma sequência de camadas em uma arquitetura de rede neural, é construído e refinado através de métodos que adicionam camadas, compilam a estrutura para otimização e conduzem o processo de aprendizado “*treinar*”, pois o modelo é elaborado para realizar previsões sobre novos conjuntos de dados da série temporal de sinais mioelétricos.

A divisão dos dados é abstraída pela classe “*DivisaoDados*”, que aloca os dados em conjuntos de treino e teste, fundamentais para o treinamento e a validação subsequente do modelo. O “*ProcessoTreinamento*” e o “*ProcessoAvaliacao*” são, respectivamente, processos inter-relacionados que utilizam os conjuntos de dados apropriados para ajustar o modelo e avaliar seu desempenho por meio de métricas estatísticas.

Figura 27 - Representação do método proposto utilizando UML



Por sua vez, os “*ProcessoPredicao*” e “*ProcessoVisualizacao*” representam as etapas finais da proposta, onde o modelo treinado é utilizado para prever valores futuros e os resultados são visualizados, sendo esses últimos cruciais para a interpretação dos resultados pelos profissionais da saúde, bem como a validação dos artefatos e descobertas, permitindo a obtenção de insights das previsões do modelo em comparação com os dados reais, conforme ilustra o Quadro 11.

Quadro 11 - Síntese das classes, funcionalidades e relacionamentos do método voltado à predição de séries temporais em terapia individual muscular em SCI

Classe	Funcionalidades	Descrição	Relacionamentos
DataFrame	ler_csv()	Estrutura de dados para armazenar e manipular séries temporais.	É escalado pelo Escalador. É dividido pela DivisaoDados.
Escalador	ajustar_transformar(), transformar(), reverter_transformacao()	Normaliza os dados para o treinamento do modelo e reverte a normalização para interpretação dos resultados.	Escala o DataFrame.
Modelo	adicionar(), compilar(), treinar(), prever()	Representa a arquitetura da rede neural, incluindo as operações de treinamento e previsão.	Utilizado nos Processos de Treinamento, Avaliação e Predição.
DivisaoDados	dividir()	Separa os dados em conjuntos de treino e teste.	Divide o DataFrame. Alimenta os Processos de Treinamento e Avaliação.
ProcessoTreinamento	treinar()	Engloba o treinamento do modelo com os dados de treino.	Usa o Modelo e o Escalador. Alimenta o Modelo.
ProcessoAvaliacao	avaliar()	Avalia o desempenho do modelo utilizando os dados de teste e métricas estatísticas.	Usa o Modelo e o Escalador. É visualizado pelo Processo de Visualização.
ProcessoPredicao	prever()	Utiliza o modelo treinado para fazer previsões sobre novos dados.	Usa o Modelo. É visualizado pelo Processo de Visualização.
ProcessoVisualizacao	plotar(), exibir()	Visualiza os resultados do treinamento, avaliação e previsões do modelo.	Visualiza os resultados dos Processos de Avaliação e Predição.

Fonte: Elaborado pelo autor (2023)

Cada linha do Quadro corresponde a uma classe distinta da proposta, detalhando as funcionalidades específicas que ela encapsula, uma descrição de suas responsabilidades e como se relaciona com outras classes dentro do ecossistema do método. Esta representação tabular serve como para facilitar a compreensão das funções e interações entre os diferentes componentes, desde a captura dos dados até a visualização de previsões. Nas seções a seguir,

serão detalhados os relacionamentos, classes e funcionalidades específicas de cada um dos elementos.

4.2.1 Estrutura de Dados (*Dataframe*)

Considerando o passo responsável pela previsão de séries temporais, a Estrutura de Dados, aqui denominado *Dataframe* é a espinha dorsal do processo de manipulação de dados. Neste contexto específico, é inicialmente carregado com dados de séries temporais a partir de um arquivo por meio do método “*ler_csv()*”, introduzindo-os no ambiente de análise como um *Dataframe*. Esses dados são a matéria-prima para a análise subsequente e o treinamento do modelo LSTM. Cada coluna no *Dataframe*, nomeada como “*dim1*”, “*dim2*”, até “*dim13*”, representam uma dimensão temporal específica da série, variando entre os 6 (seis) diferentes agrupamentos musculares de cada perna e o *crankset*.

Como o *Dataframe* possui a capacidade de permitir transformações complexas com facilidade, a normalização dos dados é um passo crítico para garantir que o método LSTM funcione de maneira otimizada. Sua interação será promovida com o objeto *Scaler*, que ajusta os dados para uma escala apropriada para processamento neural.

Outro ponto importante, é que pela necessidade de avaliar a performance do método em dados não vistos, e o *Dataframe* facilita essa divisão, garantindo que os dados de treino e teste sejam separados corretamente e de forma eficiente, para que então, após o treinamento da LSTM, esses mesmos dados de entrada sejam fornecidos em formato compatível com as exigências da rede neural. Essa estrutura permite que os dados sejam remodelados e reestruturados de acordo com a necessidade para se adequarem às necessidades de entrada do modelo, habilitando a sequência temporal como entrada e também adaptando-se às saídas.

4.2.2 Escalador

No universo do processamento de dados e ML, a classe “*Escalador*” emerge como uma figura central na preparação de dados, uma etapa prévia indispensável para a modelagem preditiva. O Escalador é uma abstração que representa os métodos de normalização e padronização de dados, essenciais para harmonizar as diferentes escalas e distribuições que as variáveis de um conjunto de dados podem apresentar. Nesse contexto específico, o Escalador é responsável por transformar os dados de séries temporais, garantindo que sejam recebidas entradas numéricas em um formato otimizado para processamento.

Dentro do processo de normalização de dados, as funcionalidades “*ajustar_transformar()*”, “*transformar()*”, e “*reverter_transformacao()*” desempenham papéis fundamentais no manuseio e preparação dos dados para o treinamento e avaliação. Estas funcionalidades são incorporadas na classe "Escalador", que é uma abstração dos processos de normalização e padronização de dados.

A funcionalidade “*ajustar_transformar()*” é aplicada ao conjunto de dados de treinamento e é responsável por aprender e aplicar a transformação necessária. Ela calcula as estatísticas descritivas, como média e desvio padrão para a padronização, ou os valores mínimo e máximo para a normalização, e imediatamente aplica essa transformação aos dados. Este ajuste é crucial, pois prepara o modelo para entender e processar os dados dentro de uma escala consistente e otimizada.

A funcionalidade “*transformar()*” é utilizada após o ajuste inicial e é aplicada aos dados de teste. Ela usa as estatísticas aprendidas durante o ajuste do conjunto de treinamento para aplicar a mesma transformação aos dados de teste, garantindo que ambos os conjuntos de dados estejam na mesma escala e, portanto, sejam comparáveis e consistentes para o modelo.

Após o método realizar suas previsões, a funcionalidade “*reverter_transformacao()*” é empregada para traduzir os dados previstos de volta à sua escala original. Este passo é vital para a interpretação dos resultados, pois permite que as previsões sejam comparadas de forma significativa com os valores reais. A capacidade de reverter a transformação é essencial para a avaliação do desempenho do modelo, pois fornece uma visão clara de como o modelo performa em termos dos dados reais que representam o fenômeno estudado.

Essas características, em conjunto, garantem que a LSTM possa ser treinada e avaliada de maneira eficaz, permitindo que os dados sejam manipulados de forma que preserve sua integridade e relevância. A aplicação dessas técnicas de escalonamento e a subsequente reversão para a escala original são passos que reforçam a precisão e a utilidade das previsões geradas pelo método, tornando os resultados tanto verificáveis quanto valiosos para os profissionais da área da saúde e demais partes interessadas.

A relevância do Escalador é amplificada quando consideram-se a diversidade e a natureza heterogênea dos dados com os quais os modelos de ML são treinados. Considerando que as variáveis podem oscilar significativamente em termos de magnitude, unidades e faixas, como ocorre com os dados de EMG, onde não há valores de escala definidos (apenas no que é advindo da literatura como um alcance aproximado de 400uV), torna-se necessário esse procedimento, visto que, sem um escalonamento apropriado, a RNN pode ter seu desempenho

prejudicado. O Escalador, portanto, atua como um equalizador, nivelando para que cada variável contribua de forma equitativa para o aprendizado do modelo.

No contexto do algoritmo, o Escalador não é uma classe estática: ele é dinâmico e adaptativo, para que a cada interação, ele aprende a escala dos dados de treinamento por meio de um processo conhecido como “*ajuste*”. Este processo envolve o cálculo de estatísticas descritivas necessárias para a transformação subsequente dos dados, como a média e o desvio padrão, no caso da padronização, ou os valores mínimo e máximo, no caso da normalização. Uma vez que estas estatísticas são aprendidas, o Escalador aplica a transformação tanto ao conjunto de treinamento quanto ao conjunto de teste, garantindo a consistência e a validade do processo de modelagem.

A transformação dos dados é uma operação matemática que reescala cada característica para um intervalo comum. Neste caso, aplica-se a normalização “*Min-Max*”, para que os dados sejam reescalados em valores de cada característica dentro do intervalo $[0, 1]$.

Por fim, após o método fazer suas previsões, objetivando que tenhamos a possibilidade de interpretar esses resultados no contexto original dos dados, podendo reverter as previsões para a escala original dos dados através do Escalador, facilitando a comparação com os valores reais e a avaliação do desempenho do modelo. Esta etapa é essencial para a apresentação dos resultados de uma maneira que seja significativa para os *stakeholders* da área da saúde.

4.2.3 Modelo de predição de séries temporais

No domínio da ciência de dados e de ML, o termo “*Modelo*” adquire uma conotação que transcende sua definição coloquial, representando uma construção matemática e computacional que é capaz de aprender padrões a partir de dados. No contexto dessa proposta, o modelo utilizou-se da LSTM projetada para capturar as dependências temporais em séries de dados complexas, como as encontradas em sinais de EMG.

A arquitetura LSTM é uma evolução das redes neurais tradicionais, projetada para superar o desafio de dependências de longo prazo, que é um ponto crítico nas séries temporais onde o sinal relevante pode ser separado por intervalos de tempo indeterminados. O modelo LSTM incorpora unidades de memória que permitem que ele retenha informações por períodos prolongados, tornando-o ideal para a análise de sinais de EMG, onde a informação da ativação mioelétrica pode emergir em qualquer ponto da série temporal, também podendo se correlacionar com os demais conjuntos de dados.

A construção do modelo começa com a definição da arquitetura, que no caso da LSTM, envolve a determinação do número de camadas e a quantidade de neurônios em cada uma dessas camadas. A complexidade do modelo deve possuir balanceamento, evitando os extremos onde o modelo não seja demasiadamente simples, podendo não capturar a totalidade dos padrões nos dados, e também o cuidado por não desenvolver um modelo excessivamente complexo, que também pode por sua vez demorar demais para aprender e/ou perder sua capacidade de generalização.

Com isso, o modelo foi pensado para que o treinamento sob os biosinais advindos do conjunto de dados dos pacientes para o modelo torne-se um processo iterativo e computacionalmente possível, onde o algoritmo de aprendizado ajusta os pesos sinápticos da rede neural com base nos dados de entrada e suas respectivas saídas. Especificamente, o modelo possui seu treinamento feito utilizando uma série de exemplos nos quais os padrões de ondas mioelétricas possuem seu correlacionamento com estados de ativação muscular. Na sua concepção fora observado a minimização da função de custo, o erro quadrático médio e a discrepância entre as previsões do modelo e os valores reais.

Uma vez treinado e armazenado, o modelo LSTM é capaz de processar novos dados e prever, com base no aprendizado adquirido, as séries temporais futuras. Esta capacidade preditiva é avaliada utilizando um conjunto de dados de teste, que não foi visto pelo modelo durante o treinamento, garantindo assim uma avaliação imparcial do seu desempenho.

Para que esse processo seja consumado, são inclusas as funcionalidades “*adicionar()*”, “*compilar()*”, “*treinar()*” e “*prever()*”. Cada uma dessas funcionalidades desempenha um papel específico na construção e operação. A *adicionar()* é aplicada na fase inicial de construção, permitindo a inserção de camadas sequenciais, como as camadas LSTM e *Dense*.

Após a adição das camadas necessárias, a funcionalidade *compilar()* é invocada para configurar o processo de aprendizado do modelo. Ela especifica o otimizador (*Adam*) a ser usado e a função de perda. Essa etapa prepara o modelo para ser treinado com eficiência, alinhando a arquitetura do método com algoritmos que irão ajustar os pesos durante o treinamento.

Na sequência, a funcionalidade *treinar()* (*fit*), é onde o modelo é efetivamente treinado, sendo promovido durante o treinamento o ajuste dos pesos internos com base nos dados de entrada e nas saídas esperadas, por quantas épocas forem necessárias, com o modelo aprendendo e melhorando a cada iteração, minimizando a função de custo e a discrepância entre as previsões e os valores reais.

Ao final, a funcionalidade *prever()* é utilizada para avaliar a capacidade preditiva do modelo. Uma vez que o modelo foi treinado e os pesos foram ajustados, ele pode receber novos dados de entrada e prever os resultados futuros.

Esses métodos, quando aplicados em conjunto, permitem que o método LSTM seja construído, treinado e utilizado para fazer previsões precisas. A capacidade de prever séries temporais futuras é de particular interesse na área da saúde, onde tais previsões podem oferecer *insights* valiosos para o tratamento clínico e a compreensão dos padrões mioelétricos dos pacientes.

A interpretação dos resultados do método é uma etapa crucial, que no contexto de pesquisas da área da saúde, não apenas a precisão das previsões é interessante, mas também, a capacidade do modelo de fornecer *insights* que possam contribuir com o domínio específico de conhecimento ao *expert* envolvido no tratamento clínico do indivíduo.

4.2.4 Segmentação do Conjunto de Dados

A Segmentação do Conjunto de Dados é uma designação de uma das fases mais críticas no desenvolvimento de modelos de ML: a segmentação do conjunto de dados em partes distintas para treinamento e teste. Esta divisão é fundamental para avaliar a capacidade de generalização do método, isto é, sua habilidade de fazer previsões acuradas sobre dados novos, não observados durante a fase de treinamento.

No algoritmo em questão, a Segmentação do Conjunto de Dados é promovida pela classe “*DivisaoDados*” (método *dividir()*), que ocorre a partir da utilização da biblioteca *Pandas*⁶. O conjunto de dados é inicialmente carregado no *Dataframe*, para que a partir deste ponto, seja dividido em duas partes principais: a) dados de treinamento e b) dados de teste. A proporção dessa divisão é de importância estratégica e é determinada com base na quantidade de dados disponíveis e na complexidade do problema. Nessa implementação especificamente, a divisão foi promovida de forma que um segmento final do conjunto de dados do paciente seja reservado para teste, garantindo que o método seja avaliado em condições que simulam a realidade operacional na qual será aplicado, conforme pode ser visualizado na Tabela 4.

⁶ Documentação disponível em: <https://pandas.pydata.org/>

Tabela 4 - Exemplo de utilização na dimensão 1 (Canal 1)

Conjunto	Quantidade
Dados de Treinamento	16381
Dados de Teste	310

Fonte: Elaborado pelo autor (2023)

A escolha do tamanho do conjunto de teste deve ser observada em equilíbrio, uma vez que um conjunto de teste muito grande pode reduzir a quantidade de dados disponíveis para treinamento, potencialmente privando o modelo da riqueza de informações necessárias para aprender eficazmente, mas que por outro lado, se este for muito pequeno pode não ser representativo das variações nos dados, levando a uma avaliação imprecisa do desempenho. No contexto do algoritmo em estudo, um tamanho de teste de 300 (trezentos) mais o tamanho da entrada é selecionado, refletindo uma consideração cuidadosa das necessidades do método e da quantidade de dados disponíveis.

Após a divisão, o processo de *Escalonamento* é aplicado separadamente aos dados de treino e teste. Este passo é crucial para neutralizar qualquer viés que possa surgir devido a diferenças de escala entre as variáveis. O “*StandardScaler*” é empregado para normalizar os dados, subtraindo a média e dividindo pelo desvio padrão, resultando em dados com uma média de zero e variância de um. Esta normalização é essencial para modelos baseados em ANNs, como o LSTM, que são sensíveis à escala dos dados de entrada.

O conjunto de treinamento é então utilizado para promover o ajuste, alimentando a rede com os dados e permitindo que ela aprenda a partir dos padrões emergentes. O conjunto de teste, por sua vez, permanece intocado durante esta fase de treinamento. Sua função primordial é servir como um campo de prova para o modelo treinado, oferecendo uma avaliação imparcial de como o modelo irá performar quando confrontado com novos dados.

4.2.5 Processo de Treinamento

O Processo de Treinamento constitui o cerne do desenvolvimento de um modelo de ML, sendo o estágio onde o modelo aprende a partir dos dados para realizar previsões futuras. Este processo por ser complexo e multifacetado, envolve várias etapas críticas que devem ser executadas com precisão para garantir a eficácia do modelo final para atendimento ao que se espera na predição da série temporal.

Na proposta, sua estruturação se deu pela utilização da biblioteca *Keras*, uma escolha que oferece uma interface de alto nível para a construção de redes neurais, aplicada em

diferentes contextos e domínio do conhecimento. A rede é composta por uma camada de entrada, que recebe os dados, seguida por uma ou mais camadas LSTM, onde a memória de longo prazo é mantida, para que então a arquitetura seja finalizada com uma camada densa que reúne a informação processada para produzir a saída do método.

O treinamento do método é realizado através da alimentação iterativa dos dados de treino, onde *epoch* representa uma passagem completa pelo conjunto de dados. Na *epoch*, o modelo faz previsões com base nos dados de entrada, e os erros dessas previsões são calculados usando uma função de perda, neste caso o MSE. Este erro é então propagado de volta pela rede, um processo conhecido como *backpropagation*, permitindo que o método ajuste seus pesos e vieses internos para minimizar o erro.

A taxa de aprendizado e o número de épocas são parâmetros cruciais no *ProcessoTreinamento* (método *treinar()*). Uma taxa de aprendizado muito alta pode fazer com que o modelo não convirja, enquanto uma muito baixa pode tornar o treinamento excessivamente lento e suscetível a ficar preso em mínimos locais. No algoritmo em questão, o número de *epochs* foi definido como 10, um valor que deve ser suficiente para permitir que o modelo aprenda os padrões sem correr o risco de sobreajuste, conseguindo aprender os demais os detalhes do conjunto de treino, sem prejudicar sua performance em dados novos.

O tamanho do lote (do inglês *batch size*), é outro fator que possui influência no algoritmo. Um lote pequeno pode levar a atualizações de peso mais frequentes, o que pode ser benéfico para encontrar mínimos globais, mas também, pode aumentar a variabilidade das atualizações e o tempo de treinamento; por outro lado, um lote maior proporciona uma estimativa mais estável do gradiente, mas que pode exigir mais memória e levar a convergências para mínimos locais. Assim, neste contexto foi adotado um tamanho de lote de 50, buscando um equilíbrio entre eficiência computacional e qualidade de aprendizado.

Finalmente, a divisão de validação é uma prática que permite monitorar o desempenho do modelo em um subconjunto dos dados de treino que não é utilizado para o ajuste dos pesos, ajudando a detectar o sobreajuste e a ajustar os hiperparâmetros do modelo de forma mais eficaz. Adotou-se uma divisão de validação de 0,1, significando que 10% dos dados de treino são reservados para validar o desempenho do modelo a cada época.

4.2.6 Processo de Avaliação

O Processo de Avaliação da LSTM, denominado *ProcessoAvaliacao*, é uma fase de muita importância, visto que nela será determinada a capacidade do modelo de

generalizar o aprendizado para dados não vistos anteriormente, uma métrica essencial para a aplicabilidade prática em situações reais e da efetividade dessa proposição da dissertação.

A Avaliação começa com a utilização do modelo treinado sobre o conjunto de teste, resultando em um conjunto de previsões que são comparadas com os valores reais. Esta comparação é quantificada através de métricas de desempenho estatístico. No modelo em questão, métricas como do MAE, MSE e R^2 são calculadas, pois cada uma dessas métricas oferece insights diferentes sobre o desempenho:

- MAE: fornece uma média linear das diferenças de erro;
- MSE: penaliza erros maiores;
- R^2 : Utilizado para avaliar a proporção da variância nos dados de teste que é previsível a partir dos dados de treinamento.

Não obstante, ao processo de avaliação visual, mesmo que mais moroso ou demorado, também desempenha um papel crucial no Processo de Avaliação: Gráficos de linha são gerados para ilustrar as previsões do modelo em comparação com os dados reais, sendo essas visualizações instrumentais para a identificação visual de padrões de acertos e erros do modelo. Para tanto, o uso da biblioteca *Matplotlib*⁷ foi aplicado, pois permite a criação de gráficos que mostram as previsões de treino e teste lado a lado com os valores reais, oferecendo uma representação gráfica intuitiva do desempenho do modelo. Assim, esta análise pode revelar tendências, vieses e características dos dados que podem ser endereçados em iterações futuras do processo de modelagem, sendo um passo iterativo e reflexivo.

4.2.7 Processo de Predição

O Processo de Predição, denominado *ProcessoPredicao* é a culminação do desenvolvimento do modelo de ML, onde o modelo treinado e avaliado é finalmente utilizado para fazer previsões sobre dados novos.

A previsão começa com a entrada de novos dados no modelo, sendo estes a sequência de leitura de valores de EMG que foram transformados e escalonados para corresponder ao formato dos dados sobre os quais o método foi treinado. A importância dessa etapa não pode ser subestimada, pois a consistência na forma e escala dos dados de entrada é crucial para a precisão das previsões.

⁷ Documentação disponível em: <https://matplotlib.org/>

Quando o método processa os dados de entrada, ele gera uma saída que é a previsão do valor ou valores subsequentes na série temporal. Essa saída é uma previsão do próximo ponto na série temporal de EMG, indicando qual seria a força específica do agrupamento muscular em um período futuro simulado.

A previsão gerada é então comparada com o valor real subsequente para avaliar a precisão. No entanto, neste momento não existe apenas o interesse em uma única previsão, mas na capacidade do modelo de continuar a fazer previsões precisas à medida que recebe novos dados, podendo portanto, ser utilizado de modo interativo, onde cada uma das etapas de FES possa ser orquestrada com base na posição anterior, sendo continuamente alimentadas de volta como entrada para prever os próximos pontos na série.

4.2.8 Processo de Visualização

O Processo de Visualização, aqui chamado de *ProcessoVisualizacao*, é a etapa que transcende a mera apresentação de dados, sendo discutida mais amplamente na Seção de Discussão e Resultados, pois é através desse processo que traz-se à luz a interpretação das complexidades e insights do modelo.

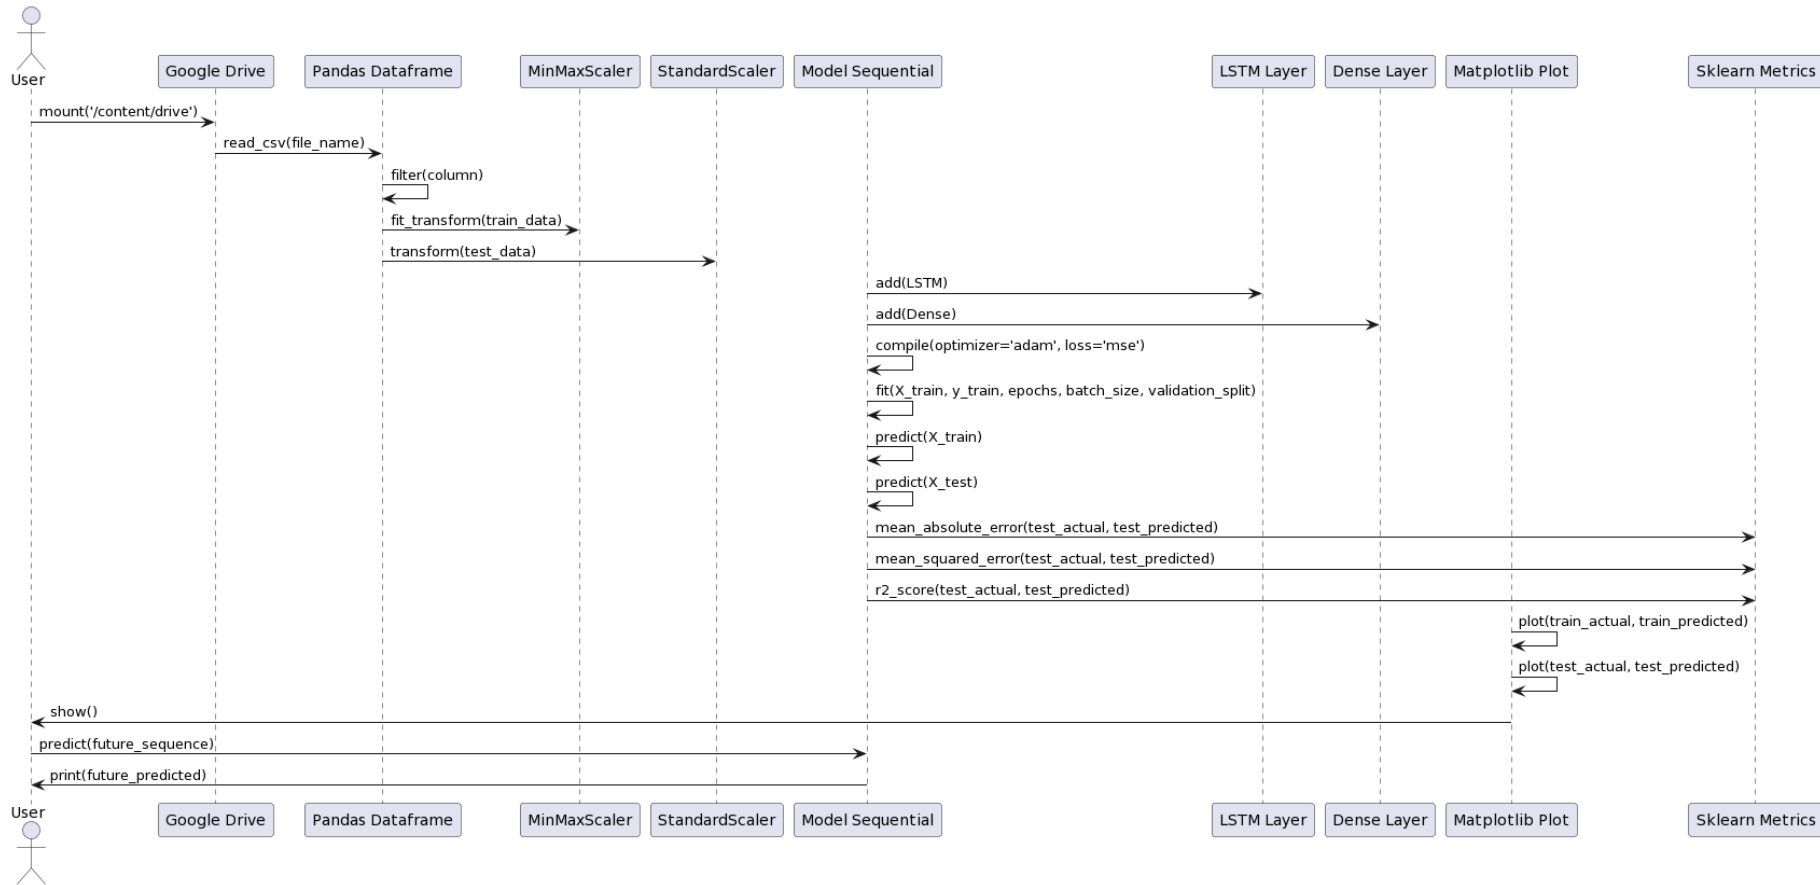
Para sua operação, foram exibidos gráficos de linha para ilustração das séries temporais em comparação com leituras reais, prevista, simuladas e seu contraste de comparação, identificando claramente o desempenho do método em caso de replicação e simulação de condições reais, trazendo não apenas a representação dos dados, mas a manifestação visual da performance do modelo.

4.3 INSTANCIÇÃO DO MÉTODO PROPOSTO

Conforme evidenciado, na seção anterior delineou-se o método a partir de uma ótica conceitual, apresentando sua estrutura em nível mais teórico. Por outro lado, nesta seção será desdobrado acerca do detalhamento dos mecanismos técnicos e tecnológicos voltados à instanciação.

A Figura 28 revela a arquitetura através de um diagrama de sequência em UML para melhor entendimento das operações e seus elementos enquanto funcionamento do sistema de sugestão de tratamento, conforme mencionado anteriormente, em nível de protótipo.

Figura 28 - Diagrama de sequência em UML com a interação entre diferentes classes, bibliotecas externas, processo de carregamento, processamento e visualização de dados de séries temporais para treinamento e previsão usando uma rede LSTM



Fonte: Elaborado pelo autor (2023)

A Figura 28 desvenda uma representação do método que detalha os componentes essenciais já apresentados no esquema conceitual, mas agora sob uma ótica processual. Esta representação estabelece uma clara diferenciação entre os artefatos e os procedimentos. Com ela, é possível discernir os processos que são desencadeados em decorrência das funções e do funcionamento do método, de forma que as interrelações e chamadas são traçadas para a identificação de cada uma das etapas.

Nas seções subsequentes, as fases serão descritas de forma a abordar a ordenação do funcionamento.

4.3.1 Preparação de Dados

A Preparação dos Dados, ou *DataPreparation*, assume um papel relevante, visto que é nesta fase que se estabelecem as fundações para a análise subsequente e a modelagem preditiva; suas classes são *Dataframe*, *Escalador* e *DivisaoDados*.

O *DataFrame*, em sua essência, é uma estrutura de dados bidimensional, onde cada coluna pode ser considerada uma variável independente e cada linha uma observação. No contexto da instanciação em questão, o *Dataframe* é carregado com dados de séries temporais, extraídos de um arquivo de extensão **.csv*. Estes dados são compostos por múltiplas dimensões, cada uma representando uma variável temporal específica, que, para o presente estudo, correspondem a diferentes agrupamentos musculares e suas ativações durante um ciclo de pedalada. A manipulação e transformação desses dados são cruciais para o sucesso do modelo preditivo subsequente, e o *Dataframe* oferece uma interface intuitiva e poderosa para realizar tais operações.

Para ilustrar a explicação com exemplos concretos, considerando um conjunto de dados hipotético (Tabela 5) que passa pelo processo de *DataPreparation*. Este conjunto de dados é composto por medições de atividade muscular em 13 dimensões diferentes (Quadro 9), representando diferentes agrupamentos musculares durante um ciclo de pedalada.

Tabela 5 - Exemplo de *Dataframe* composto de doze agrupamentos musculares e do pedivela em suas leituras

dim1	dim2	dim3	dimⁿ	dim13
4.926227106227106	4.984249084249084	5.013260073260073	...	4.969743589743589
4.998754578754578	5.012454212454212	4.985860805860805	...	5.012454212454212
4.922197802197801	4.989084249084249	4.976190476190476	...	5.0035897435897425
4.842417582417583	4.967326007326006	5.0189010989010985	...	4.992307692307692

Fonte: Elaborado pelo autor (2023)

Na sequência, o *Escalador* é a classe responsável pela normalização ou padronização dos dados, processos estes que são vitais para o desempenho eficaz do modelo de ML subsequente. Na instanciação, utilizou-se o *StandardScaler*, uma funcionalidade que normaliza os dados mapeando-os em uma distribuição tal que a média é definida como 0 (zero) e o desvio padrão como 1 (um) conforme Equação 13, onde u é a média das amostras de treinamento e s é o desvio padrão de desvio das amostras de treinamento.

$$Z = \frac{x - u}{s} \quad (13)$$

Após a aplicação do *StandardScaler*, os dados podem ser representados conforme consta na Tabela 6.

Tabela 6 - Exemplo de representação após a aplicação do Escalador para normalizá-los com média e desvio padrão 1

dim1	dim2	dim3	dimⁿ	dim13
-1.00	-0.87	0.95	...	0.50
-0.50	-0.43	1.05	...	0.75
...
0.50	0.34	1.15	...	1.00

Fonte: Elaborado pelo autor (2023)

Este procedimento é fundamental, pois redes neurais como a LSTM, são sensíveis à escala dos dados de entrada. A normalização assegura que todas as variáveis contribuam igualmente para a capacidade de aprendizado do modelo, evitando que variações de escala induzam a distorções.

Logo, para que se possa seguir na preparação de dados, a classe *DivisaoDados* é necessária, visto que neste processo o conjunto de dados é segmentado em subconjuntos exemplificados na Tabela 7 e Tabela 8, como de treino e teste, respectivamente.

Tabela 7 - Exemplo de conjunto de dados segmentados para treinamento

dim1	dim2	dim3	dim ⁿ	dim13
-1.00	-0.87	0.95	...	0.50
-0.50	-0.43	1.05	...	0.75
...

Fonte: Elaborado pelo autor (2023)

Tabela 8 - Exemplo de conjunto de dados segmentados para teste

dim1	dim2	dim3	dim ⁿ	dim13
0.25	0.10	1.10	...	0.85
0.50	0.34	1.15	...	1.00
...

Fonte: Elaborado pelo autor (2023)

É crucial a divisão do conjunto de dados em partes específicas para treinamento, validação e teste. Essa estratégia é fundamental para assegurar que o modelo seja treinado e validado em dados distintos, prevenindo o fenômeno de *overfitting*. Dessa forma, a generalização do modelo se torna mais robusta e confiável. A divisão é geralmente realizada definindo-se previamente um tamanho para o conjunto de teste, garantindo assim que uma parcela dos dados seja exclusivamente reservada para a avaliação final do modelo preditivo.

O uso de *Dataframes* oferece vantagens significativas nesse processo, pois suas funcionalidades permitem uma manipulação e preparação eficientes dos dados, facilitando a separação dos conjuntos de treino, validação e teste. Essa separação eficaz é essencial para o desenvolvimento de modelos de predição mais precisos e confiáveis, assegurando que eles sejam capazes de performar bem não apenas nos dados de treino, mas também em novos dados, refletidos pelo conjunto de teste.

Em síntese, o *Dataframe* serve como o repositório dos dados, o *Escalador* como o equalizador das variáveis, e a *DivisaoDados* como o separador entre treinamento, validação e teste. Cada classe desempenha seu papel específico para compor a interface sobre o qual a instância do método proposto, assim como o modelo preditivo, serão construídos e avaliados em integração harmoniosa para habilitar sugestões de tratamentos.

4.3.2 Treinamento do Modelo

A fase de preparação de dados, ou *DataPreparation*, é um estágio crucial no desenvolvimento de modelos de aprendizado de máquina, especialmente em contextos em que

a precisão e a validade dos resultados são de suma importância, como é o caso de aplicações de engenharia biomédica.

O *ProcessoTreinamento* se inicia com a seleção e a transformação dos dados, onde são inicialmente carregados, conforme ilustra a Tabela 9 em uma estrutura (*Dataframe*) de dados bidimensional que oferece ferramentas potencialmente úteis para a manipulação de grandes conjuntos de dados. Conjunto é então submetido a um processo de normalização (frequentemente um passo necessário para modelos de aprendizado de máquina), para assegurar que as variações nas escalas das variáveis não distorçam ou prejudiquem o processo de aprendizado.

Tabela 9 - Exemplo de arquivo CSV com medições, onde cada linha representa a observação do tempo e cada coluna uma característica de leitura mioelétrica diferente

Tempo	dim1	dim2	dimⁿ	dim13
1	4.926227106227106	4.984249084249084	...	5.013260073260073
2	4.998754578754578	5.012454212454212	...	4.985860805860805
...
t ⁿ	4.842417582417583	4.967326007326006	...	5.0189010989010985

Fonte: Elaborado pelo autor (2023)

Assim, a normalização então é promovida por meio de um *StandardScaler*, que se trata de uma funcionalidade da suíte do *scikitlearn*⁸, representada por um conjunto de ferramentas eficientes para predição e análise de dados construída com licença *open source*. Com essa aplicação, é realizado o ajuste dos dados para terem uma média de 0 (zero) e um desvio padrão de 1 (um), que é o momento da normalização, conforme ilustrado na Tabela 10.

Tabela 10 - Exemplo de normalização hipotética dos dados divididos em conjuntos de treinamento e teste

Conjunto	Tempo	dim1 (normalizada)	dim2 (normalizada)	dimⁿ	dim3 (normalizada)
Treino	1	-0.5	0.3	...	-0.1
Treino	2	-0.45	0.35	...	-0.05
...
Teste	N-1	0.5	-0.3	...	0.1
Teste	N	0.55	-0.35	...	0.15

Fonte: Elaborado pelo autor (2023)

⁸ Documentação disponível em: <https://scikit-learn.org/>

Neste momento, este procedimento é aplicado apenas ao conjunto de treinamento para que os parâmetros obtidos sejam utilizados para transformar o conjunto de teste, garantindo que ambos os conjuntos sejam comparáveis e distintos, uma vez que não é desejada a exposição do modelo a dados do conjunto de teste durante o treinamento buscando evitar *bias*.

Após a normalização, o modelo LSTM é definido e compilado e composto por uma camada LSTM seguida por uma camada densa, que é a configuração típica para problemas de regressão. A função de perda escolhida é o MSE e o otimizador é o *Adam*, um algoritmo de otimização baseado em gradiente que ajusta os pesos da rede durante o treinamento.

O treinamento do modelo é então realizado utilizando o conjunto de treinamento normalizado, com a quantidade de 10 (dez) épocas, conforme Tabela 11. Durante o treinamento, uma fração dos dados é reservada como um conjunto de validação, visando que seja aplicado para monitorar o desempenho do modelo e evitar o *overfitting*, que pode ocorrer quando o modelo aprende padrões específicos dos dados de treinamento que não são generalizáveis para novos dados.

Tabela 11 - Processo de redução de erro de treinamento pelas épocas

Época	Erro de Treinamento
1	0.10
2	0.0035
...	...
10	0.9×10^{-6}

Fonte: Elaborado pelo autor (2023)

Por fim, o modelo treinado é usado para fazer previsões tanto no conjunto de treinamento, simplesmente com o objetivo de entender o processo, quanto no conjunto de teste sendo exibidas e utilizadas posteriormente. Estas previsões são então revertidas para a escala original dos dados usando os parâmetros do *StandardScaler*, permitindo uma comparação direta com os valores reais e uma avaliação objetiva do desempenho do modelo para a área da saúde.

4.3.3 Avaliação do Modelo

Visto que a avaliação de um modelo de ML é um passo crítico no desenvolvimento de algoritmos preditivos, especialmente em contextos onde as decisões baseadas em previsões incorretas podem ter consequências significativas (XU *et al.*, 2022), a *ProcessoAvaliacao* torna-se uma fase de muita atenção para o treinamento da rede LSTM, onde objetiva-se a mensuração do desempenho do modelo em dados aquém do treinamento.

O processo de avaliação se inicia com a previsão dos dados de teste pelo modelo treinado e armazenado, para que as previsões sejam geradas pelo método implementado *predict()*, que tem a função de aplicar o conhecimento adquirido pelo modelo durante o treinamento, na busca de valores e sua estimativa de saída correspondentes às entradas de teste. O *test_predicted* recebe o *model.predict(X_test.reshape(X_test.shape))* para executar essa tarefa, produzindo um conjunto de previsões que são posteriormente reestruturadas para a escala original dos dados usando o método *inverse_transform()* do objeto *scaler*, habilitando que as previsões possam ser diretamente comparáveis aos valores reais de leitura, facilitando a interpretação dos resultados.

Com a obtenção das previsões, uma série de métricas de desempenho são invocadas e calculadas na implementação para avaliar a precisão do modelo através de:

- *mean_absolute_error* (métrica MAE): mede a média das diferenças absolutas entre previsões e valores reais, fornecendo uma ideia da amplitude média dos erros.
- *mean_squared_error* (métrica MSE): elevando ao quadrado as diferenças antes de calcular a média, penaliza mais fortemente os erros maiores e é aplicado devido à sua sensibilidade a esses tipos de erros.
- *root_mean_squared_error* (métrica RMSE – dependente do MSE): que é potencialmente interpretável na mesma escala dos dados de entrada e saída.
- *r2_score*: (métrica R²): coeficiente de determinação, indica a proporção da variância dos dados que é explicada pelo modelo, sendo um indicador de “quão bem” as previsões correspondem aos valores reais.

De forma visual, a avaliação do modelo é complementada pela plotagem dos gráficos dos valores reais e preditos, como demonstrado pelas linhas de código em que aplica-se a biblioteca externa *Matplotlib*. A geração de gráficos que é inserida em sobreposição das séries temporais reais e as previsões do modelo tem a capacidade de habilitar uma análise intuitiva do desempenho do modelo, onde discrepâncias podem ser rapidamente identificadas e investigadas.

4.3.4 Predição

A classe Predição, em especial o *ProcessoPredicao*, possui em sua funcionalidade o *model.predict()*, que nada mais é do que um processo de inferência de valores futuros com base nos históricos da série temporal da rede LSTM.

Para que o processo de predição aconteça, devem ser satisfeitas duas etapas distintas:

1. Processamento dos dados de treinamento (X_{train});
2. Processamento dos dados de teste (X_{test}).

Na geração de previsões correspondentes, o *train_predicted* recebe a etapa 1 (X_{train}) e o mesmo ocorre com o *test_predicted* que recebe a etapa 2 (X_{test}), conforme Tabela 12. Esta operação assegura que o modelo seja capaz de validar sua capacidade preditiva tanto em dados familiares quanto em novos conjuntos de dados, um passo crucial para aferir a generalização e capacidade do modelo.

Tabela 12 - Exemplo de conjunto de dados de treinamento, teste e previsões correspondentes

Índice	X_train	train_predicted	train_actual	X_test	test_predicted	test_actual
1	[4.98, 4.94, 5.02, ...]	4.99	4.98	[5.06, 5.03, 4.98, ...]	5.00	5.01
2	[4.99, 4.94, 5.02, ...]	4.97	4.99	[4.99, 5.00, 4.99, ...]	5.00	4.98
...
N	[5.01, 5.01, 4.99, ...]	5.02	5.00	[4.97, 4.99, 5.00, ...]	5.02	5.01

Fonte: Elaborado pelo autor (2023)

Após a geração das previsões, o algoritmo emprega o método *scaler.inverse_transform()* para reverter as previsões à sua escala original, permitindo uma comparação direta com os valores reais. Esta reversão acaba sendo fundamental, observando que as métricas de avaliação do modelo, tais como o MAE, o MSE e o R^2 são calculadas com base na fidelidade das previsões em relação aos dados verdadeiros; assim, a precisão destas métricas é vital para a validação científica do modelo à ser aplicado no paciente.

Por fim, a atribuição do *Predição* reside em contemplar a extensão do modelo para além do horizonte conhecido, onde surge o *future_predicted* em representação da predição do modelo para dados futuros. Este passo final transcende a mera validação e se aventura na aplicação prática do modelo pela comparação entre os valores preditos e um valor esperado específico serve como um indicativo da precisão e da utilidade prática do modelo em contextos reais, um aspecto de suma importância para a pesquisa aplicada conforme a proposta.

Cada etapa mencionada é uma parte fundamental do ProcessoPredicao, contribuindo de forma prática e direta para o funcionamento do algoritmo. Esses passos detalham como o modelo LSTM é eficaz e aplicável na previsão de séries temporais.

4.4 SÍNTESE DO CAPÍTULO

Neste capítulo foram detalhados os desdobramentos do método proposto, podendo ser observado em duas diferentes dimensões (ontológica conceitual e a técnica processual). Na dimensão ontológica, foi possível abordar os componentes do modelo, buscando uma compreensão mais nítida dos conceitos que fundamentam a técnica. Não obstante, foi promovida a ilustração das classes ontológicas por meio da UML, que é uma linguagem amplamente aplicada para a compreensão de encapsulamento de projetos de *software* e de demais domínios de conhecimento aplicado ao negócio, tornando vívida a expressão e exposição gráfica das classes, entidades e funcionalidades; bem como a conexão e funcionamento de interrelações do método.

Sob uma perspectiva processual, foram detalhados também os elementos da ontologia em um panorama mais aprofundado para delinear o método e sua sequência de operações de implementação, separando em componentes de recepção de dados, processamento de artefatos, interação com a base de dados mioelétrica, o raciocínio do desenvolvimento e, finalmente, a geração de resultados e sua observação.

Com isso, o objetivo de enriquecer a compreensão do método proposto foi atingido, visto que foram desvendados aspectos conceituais e práticos, fundamentais para o cenário de estudo que será demonstrado no próximo Capítulo.

5 CENÁRIO DE ESTUDO

Objetivando a instanciação e entendimento do método proposto após as etapas de Coleta de Dados mioelétricos, conforme explicitado nas Seções 3.3.3.1 e 3.3.3.2, este Capítulo apresenta um cenário de estudo, bem como o conjunto de alternativas que podem ser selecionadas no contexto do trabalho com ênfase nas tecnologias, ferramentas, técnicas e estratégias utilizadas para implementação do modelo.

O Quadro 12 discrimina os itens, abrangendo os domínios de arquitetura e *design* da estrutura, assim como dos componentes e subcomponentes de programação, técnicas de matemática, estatística e demais contextos de configurações e sua aplicação no desenvolvimento da pesquisa.

Quadro 12 - Interrelação de técnicas, tecnologias e distintos elementos aplicados na instanciação do método

Funcionalidade	Subcomponente	A	B	C	D	E	F	G	H	I	J	L	M
Preparação de Dados	<i>DataFrame</i>	X	X				X				X	X	
	<i>Escalador</i>	X			X			X					
	<i>DivisaoDados</i>	X			X						X		
Treinamento do Modelo	<i>ProcessoTreinamento</i>	X		X				X		X	X		X
Avaliação do Modelo	<i>ProcessoAvaliacao</i>	X		X				X	X	X			
Visualização	<i>ProcessoVisualizacao</i>	X	X			X							
Predição	<i>ProcessoPredicao</i>	X		X				X		X	X		

A) Linguagem Python; B) Bibliotecas de Análise de Dados; C) Bibliotecas de ML; D) Bibliotecas de Pré-processamento; E) Bibliotecas de Visualização; F) Ferramentas de Armazenamento; G) Estatística e Matemática, H) Métricas de Avaliação de Modelo; I) Técnicas de ML; J) Técnicas de Séries Temporais; L) Integração de Dados; M) Adam Optimizer

Fonte: Elaborado pelo autor (2023)

Esse mapeamento ilustra a aplicação de diferentes elementos nos vários componentes do processo incluso ao método proposto como pode ser observado, o *Dataframe* é empregado tanto nas bibliotecas de análise de dados quanto na integração destes, enquanto o *Escalador* tem sua relevância nas bibliotecas de pré-processamento, bem como nas de estatística e

matemática. A *DivisaoDados*, por sua vez, é um componente que se entrelaça com a gestão do ambiente de desenvolvimento e com os princípios de séries temporais.

O *ProcessoTreinamento* se estende por múltiplas esferas, englobando as bibliotecas de ML, estatística e matemática, além da otimização. O *ProcessoVisualizacao* aplica métricas específicas para aferir a eficácia do modelo e se aprofunda nos conceitos de aprendizado de máquina; já o *ProcessoVisualizacao* se beneficia das bibliotecas dedicadas à visualização e à análise de dados por meio de gráficos e plotagem; e, por fim, o *ProcessoPredicao* se vale do resultado do modelo de predição produzido para viabilizar a sugestão de tratamentos para pacientes com SCI.

5.1 PREPARAÇÃO DE DADOS

Para o modelo da pesquisa, as entradas para a rede neural LSTM são originadas dos conjuntos de dados de séries temporais, conforme delineado previamente na subseção 3.3.3.1. Sendo assim, para que o processo de análise de sinais mioelétricos capturados por EMG sirva como base para as séries temporais, refletindo os aspectos cruciais do fenômeno estudado, como a complexidade dos sinais, a necessidade de precisão na captura de padrões temporais, a diversidade de sinais entre diferentes indivíduos e a influência de fatores externos como ruído e movimento, deve-se então prepará-los para utilização conforme Quadro 10.

Ao decifrar a natureza de biosinais, torna-se possível especificar as características do componente de entrada para este cenário, que não deve ser encarado como uma simples estrutura de valores numéricos, mas sim, como uma fonte de artefato de conhecimento do funcionamento do corpo humano, isto é, é um conhecimento estruturado de padrões cerebrais que são disparados pelos sistemas para habilitar o movimento de membros. Entender isso, é compreender que este componente se torna responsável por traduzir as sequências de biosinais captados por uma interface muscular, para então deixá-los aptos a serem configurados na estrutura responsável por habilitar o funcionamento das demais camadas do modelo de aprendizado, sem a qual, não seria possível, pois a qualidade dos dados admitidos afeta diretamente nos resultados das sugestões de tratamento.

No contexto deste método pode ser representada tanto pela série temporal completa quanto por segmentos selecionados em momentos, que no contexto do trabalho são referidos como “janelas de tempo” dentro da série completa, como, por exemplo, um conjunto de leituras consecutivas.

A decisão entre utilizar a série temporal completa ou segmentos selecionados tem seu impacto direto na representação vetorial da sequência, sendo influenciada pelo tempo e recursos de processamento necessários, uma vez que quanto mais dados são inseridos para produção do modelo de aprendizado, maior será o custo computacional. A Tabela 4 na seção 4.1.4 ilustra a dinâmica de divisão escolhida quanto aos dados e as janelas de tempo, bem como a Figura 29, demonstra o processo completo da preparação de dados.

Figura 29 - Diagrama de fluxo do cenário que ilustra o processo de Preparação e Segmentação de Dados



Fonte: Elaborado pelo autor (2023)

Como pode ser observado, esse fluxograma fornece uma representação visual clara das etapas envolvidas na preparação dos dados para o modelo de ANN baseado na arquitetura LSTM, desde o carregamento dos dados até a divisão em conjuntos de treino e teste. As seções subsequentes possuem o intuito de detalhar e elucidar os demais elementos e processos para o cenário proposto neste trabalho.

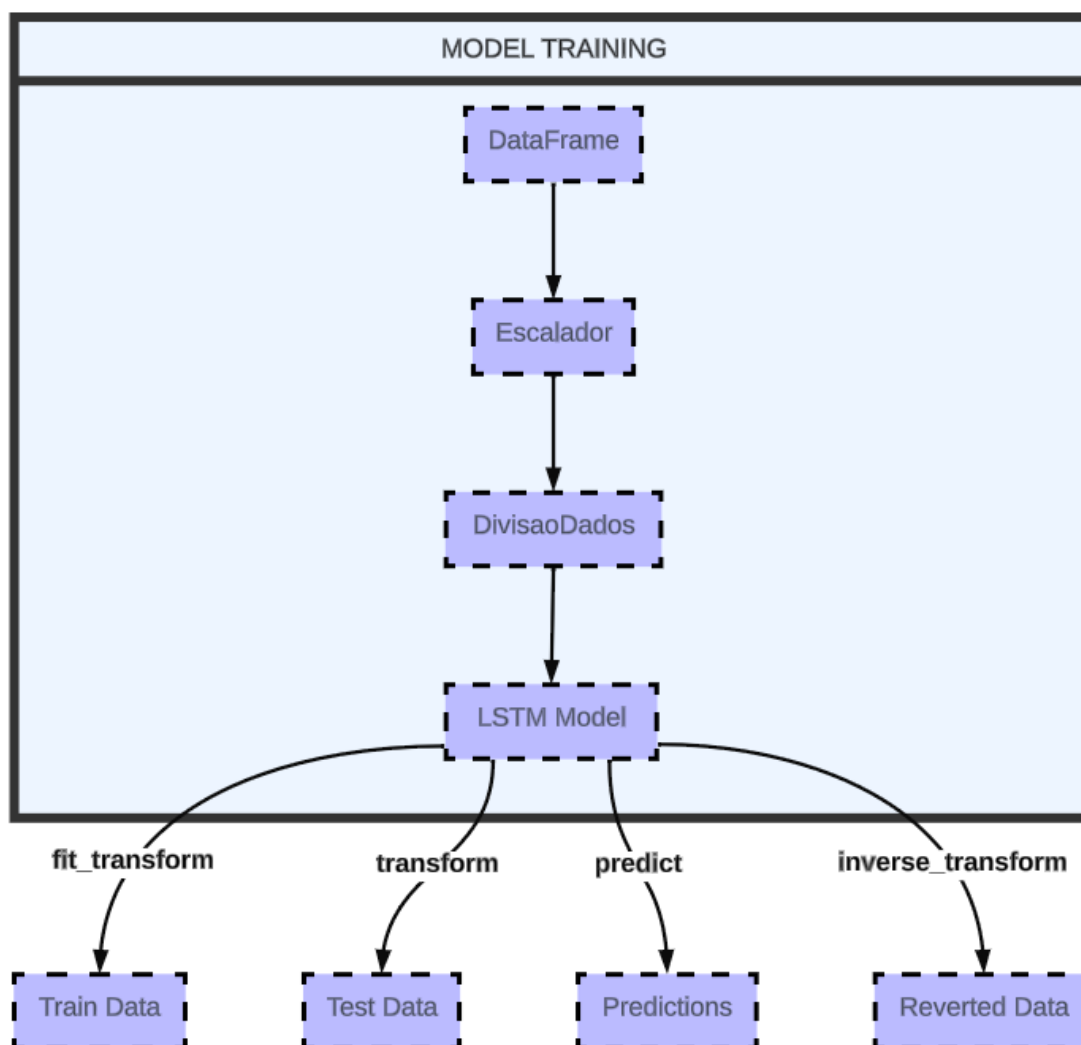
5.2 TREINAMENTO DO MODELO

Inicialmente, a implementação do “*ProcessoTreinamento*” na arquitetura LSTM, destinado à previsão de séries temporais, torna clara a ilustração da sinergia entre teoria estatística avançada e prática de engenharia de dados.

A arquitetura da ANN, que foi fundamentada por uma revisão da literatura, sublinha sua habilidade em capturar dependências temporais complexas, cruciais para a análise de dados biomédicos, como os de ativação mioelétrica, que em sua premissa, distinta das redes neurais recorrentes tradicionais, é especialmente ideal para o contexto da engenharia biomédica, uma vez que tem a capacidade de contornar o problema do desvanecimento do gradiente, permitindo o aprendizado de dependências de longo alcance por meio de suas células de memória e portas de controle, que gerenciam o fluxo de informações ao longo do tempo, podendo se aproximar da compreensão de ativação de padrões mioelétricos musculares humanos.

Conseqüentemente, no cerne do processo “*ProcessoTreinamento*” ilustrado na Figura 30, encontra-se a biblioteca *Keras*, uma interface de alto nível para redes neurais que opera sobre o *TensorFlow*. *Keras* proporciona uma abstração que simplifica operações complexas, facilitando a construção e o treinamento de modelos conforme Figura 30.

Figura 30 - Diagrama de componentes que são englobados pelo Treinamento do Modelo



Fonte: Elaborado pelo autor (2023)

De forma a compor camadas de neurônios artificiais, foi aplicado o modelo *Sequential* do *Keras*, iniciando com a camada LSTM e finalizando com uma camada densa para a saída. Desta forma, a camada LSTM foi configurada com 100 unidades e função de ativação “*relu*”, selecionada por sua eficiência e por promover uma rápida convergência durante o treinamento conforme Quadro 13.

Quadro 13 - Estruturação do modelo *Sequential*

```


model = Sequential()
model.add(LSTM(100, activation='relu', input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')

```

Fonte: Elaborado pelo autor (2023)

Aqui, $X_train.shape[1]$ e $X_train.shape[2]$ se referem à forma dos dados de entrada, que são organizados em sequências temporais; a primeira dimensão representa o número de amostras de tempo e a segunda dimensão representa o número de características em cada amostra de tempo. Com isso, foi promovida a calibração dos hiperparâmetros, como o número de épocas indicado em 10 (dez), o tamanho do lote em 50 (cinquenta) e a taxa de divisão em 0.1 (zero vírgula um) para validação. Essa configuração de elementos, como o número de épocas, foi estabelecido para assegurar que o modelo tivesse tempo adequado para aprender os padrões nos dados, mitigando o risco de *overfitting* conforme Figura 31.

Figura 31 - Arquitetura de Rede LSTM implementada para o método



Fonte: Elaborado pelo autor (2024)

Outras configurações como o número de épocas foram definidas para garantir que o modelo tivesse tempo suficiente para aprender padrões nos dados e reduzir o risco de *overfitting*. Já o tamanho do lote influencia diretamente a estimativa do gradiente e a velocidade de convergência do treinamento. Neste aspecto, buscou-se um equilíbrio entre o custo computacional e a eficácia; e, por último, a taxa de divisão inserida, para validação e monitoramento adequados do desempenho do modelo com dados não vistos, permitindo ajustes antes do treinamento definitivo.

Subsequentemente, para a normalização dos dados, efetuada pelo “*Escalador*”, fez-se um passo crítico no pré-processamento em atenção *sine qua non*, visto que, no campo da engenharia biomédica, a amplitude dos sinais de EMG pode variar substancialmente, resultando em um desempenho inconsistente do modelo se as variáveis não forem normalizadas. Visando mitigar tal comportamento, foi aplicado o *StandardScaler* do *Scikit-learn* para normalizar os dados, garantindo que cada variável contribua de forma equitativa para o aprendizado do modelo.

Por fim, entendendo que a preparação dos dados em sequências temporais é um procedimento chave para a modelagem, bem como essencial para captar a dinâmica dos sinais de EMG, a estruturação adequada dos dados de entrada para espelhar janelas, foi realizada por meio da interface da biblioteca externa *Pandas*, tornando possível manipular grandes *Dataframes* para criar sequências que refletem as janelas temporais relevantes para a previsão mioelétrica. Essa operação permitiu que o LSTM aprendesse as relações temporais entre sequências de pontos específicos de coleta de biosinais, entendendo as relações e padrões. Esse se torna um aspecto crítico na pesquisa em engenharia biomédica, onde a precisão e a confiabilidade das previsões podem ter implicações significativas para aplicações clínicas em pacientes.

5.3 AVALIAÇÃO DO MODELO, VISUALIZAÇÃO E PREDIÇÃO

Ao observar os elementos, como o “*Avaliação do Modelo*”, imediatamente depara-se com a necessidade intrínseca de aliar precisão analítica à relevância clínica, uma vez que invariavelmente, a avaliação de um modelo em engenharia biomédica, especialmente ao lidar com dados de EMG, não se limita a métricas de desempenho computacional, ela se estende para as implicações práticas dessas métricas no diagnóstico e tratamento de pacientes. Consequentemente, o “*Processo Avaliacao*” não é apenas uma etapa somente técnica, mas um elo crítico que conecta a teoria à prática, a computação à clínica e a potencial aplicabilidade do modelo.

Especificamente, ao considerar a avaliação de modelos que processam séries temporais de EMG, a precisão das previsões se torna primordial. Por outro lado, deve-se também ponderar sobre a interpretabilidade dessas previsões, aplicando a utilização de métricas como o MAE, MSE e da análise de correlação, interconectando estimativas das métricas de avaliação (Tabela 13) para valores previstos com os reais de maneira que potencializa-se sua aplicação à prática clínica.

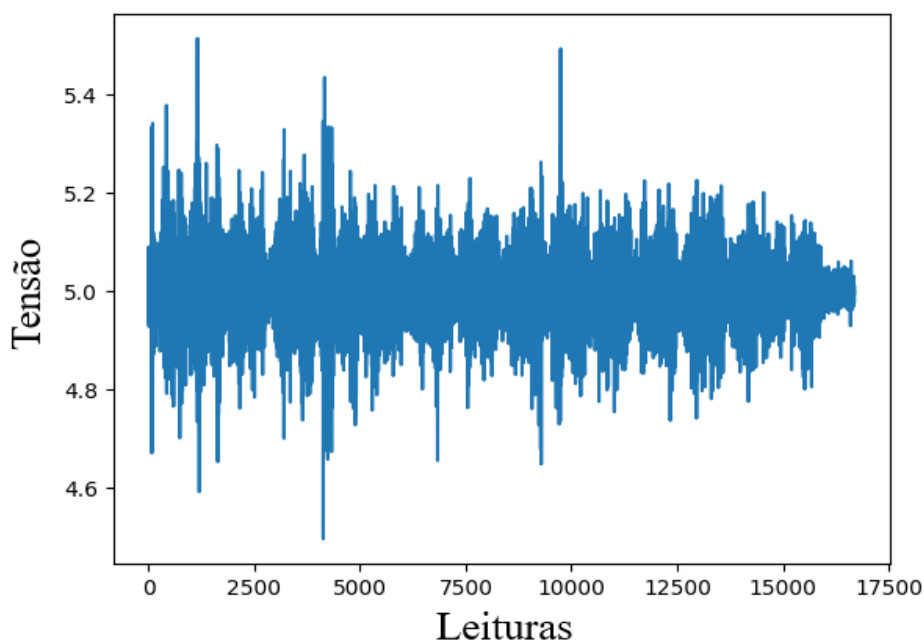
Tabela 13 - Exemplos de avaliação das métricas quando colocadas em contraste

Métrica	Valor com 1 dimensão	Valor com 2 dimensões
MAE	0.006415199709695543	0.03139613684932511
MSE	$6.22837854469564 \times 10^{-5}$	0.0010999913127913601
RMSE	0.007892007694304181	0.033166116938697546
R ²	0.8306829926267378	-1.9903005394082118

Fonte: Elaborado pelo autor (2023)

Conquanto, a “*Visualização*” transcende a sua função básica de representação gráfica, pois estrategicamente, ela se torna um meio de traduzir dados complexos em *insights* acionáveis para profissionais de saúde, conforme exemplo plotado e representado na Figura 32.

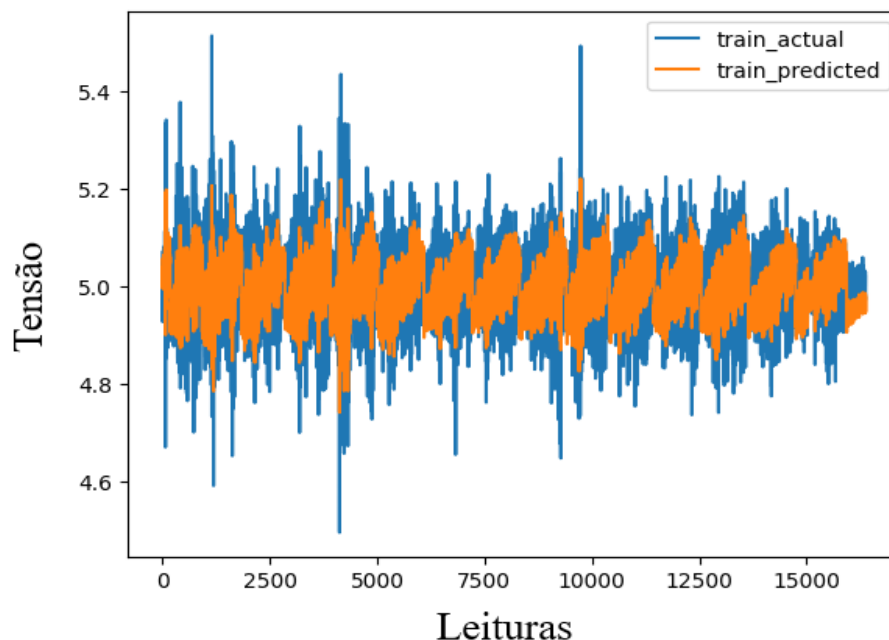
Figura 32 - Exemplo da representação mioelétrica de um canal muscular ao ser armazenado em um *Dataframe* e depois plotado pelo uso do *matplotlib*



Fonte: Elaborado pelo autor (2023)

Também, a “*Predição*”, presente e fundamental para a proposição, antecipa a atividade mioelétrica, que pode ser crucial para intervenções terapêuticas e reabilitação. Esta consegue prever esses padrões com precisão, conforme verificado na Figura 33.

Figura 33 - Exemplo da representação mioelétrica de um canal muscular ao ser armazenado em um *Dataframe* e depois plotado pelo uso do *matplotlib*, com o contraste da leitura real e a leitura da predição após o uso da LSTM



Fonte: Elaborado pelo autor (2023)

Deste modo, utilizando as técnicas da EC, consegue-se desenvolver métodos eficientes para capturar, desenvolver e aplicar conhecimento em conjuntos sequenciais de dados, os quais são fundamentais na interpretação e no suporte do modelo. O Quadro 14 ilustra a aplicação deste conhecimento na análise de leitura mioelétrica para fisioterapia em pacientes com SCI.

Neste exemplo, os hiperparâmetros e as interpretações para possíveis objetivos clínicos foram estabelecidos manualmente, através de diversas configurações testadas. É importante destacar que, neste processo, não foram utilizadas técnicas automáticas de otimização para definir os valores dos hiperparâmetros; todas as escolhas foram feitas de forma empírica, com base na análise e experiência empírica dos pesquisadores, conforme ilustrado na Tabela 14.

Tabela 14 - Relação resumida de validações e diferentes testes de forma empírica ao modelo

Cenário	A	B	C	D	E
Taxa de Aprendizado	0.005	0.01	0.02	0.05	0.1
Número de Camadas	1	2	5	10	20
Neurônios por Camada	50	100	150	200	300
Épocas	5	10	20	30	40
MAE	7.53×10^{-3}	6.42×10^{-3}	7.00×10^{-3}	7.50×10^{-3}	8.00×10^{-3}
MSE	8.78×10^{-5}	6.23×10^{-5}	7.00×10^{-5}	7.50×10^{-5}	8.00×10^{-5}
RMSE	9.37×10^{-3}	7.89×10^{-3}	8.37×10^{-3}	8.66×10^{-3}	8.94×10^{-3}
R ²	8.32×10^{-1}	8.31×10^{-1}	8.10×10^{-1}	8.00×10^{-1}	7.90×10^{-1}

Fonte: Elaborado pelo autor (2023)

Quadro 14 - Relação entre os hiperparâmetros e suas implicações no contexto clínico e computacional conforme adotado

Hiperparâmetro	Valor	Implicação Clínica	Implicação Computacional
Taxa de Aprendizado	0.01	Assegura a sensibilidade a variações sutis nos sinais de EMG	Evita oscilações excessivas durante o treinamento
Número de Camadas	2	Captura a complexidade dos padrões mioelétricos	Equilibra a capacidade de aprendizado e o risco de <i>overfitting</i>
Neurônios por Camada	100	Permite uma representação detalhada da atividade muscular	Proporciona um modelo com capacidade computacional gerenciável
Épocas	10	Tem impacto para precisão e a relevância clínica para o resultado junto a eficácia	Afeta o desempenho do modelo, influenciando tanto a convergência do aprendizado quanto a prevenção do <i>overfitting</i>
Função de Ativação	ReLU	Favorece a não-linearidade necessária para padrões complexos	Acelera a convergência devido à sua eficiência computacional

Fonte: Elaborado pelo autor (2023)

Em resumo, tanto “Avaliação do Modelo”, “Visualização” e “Predição” e seus subcomponentes “ProcessoAvaliacao”, “ProcessoVisualizacao” e “ProcessoPredicao” são implementados com uma visão holística que abrange tanto a precisão computacional quanto a relevância clínica. Através de uma abordagem criteriosa, esses processos foram escolhidos com base no histórico de validação dos pesquisadores, que não apenas refletem a precisão das previsões, mas também a capacidade do modelo de se traduzir em melhorias tangíveis no cuidado e tratamento dos pacientes que possam ter sido acometidos com SCI.

5.4 SÍNTESE DO CAPÍTULO

Este capítulo se dedicou a apresentar o cenário de estudo do método proposto, visando elucidar ao leitor as nuances e as sinergias entre os diversos componentes. Em poucas palavras, o cenário de estudo revelou aspectos técnicos intrínsecos ao método que transcendem a sua representação conceitual e visam sua visão prática, que, embora flexível, necessita de atenção para sua utilização adequada no campo da saúde e aplicação clínica.

Neste contexto, a seção explorou a aplicação do método no campo da engenharia biomédica, com ênfase na análise de séries temporais de EMG pela leitura de canais de agrupamento muscular. A seleção de componentes foi influenciada pelas peculiaridades deste domínio em contraste com a literatura, o que, por sua vez, orientou as decisões metodológicas do estudo. O cenário de estudo foi desenrolado a partir do componente “*DataPreparation*”,

onde as séries temporais de EMG são tratadas como entradas e os especialistas em engenharia biomédica como os operadores do modelo.

O “*Treinamento do Modelo*”, ou “*ProcessoTreinamento*”, foi o próximo foco, detalhando a construção e o ajuste da arquitetura LSTM. Aqui, a transformação dos dados em vetores numéricos e a subsequente calibração do modelo foram discutidas, revelando as técnicas de normalização e as estratégias de otimização dos hiperparâmetros adequadas para o cenário.

Avançando, para o “*Avaliação do Modelo*”, ou “*ProcessoAvaliacao*”, foi abordado, destacando como o modelo de aprendizado é validado e testado; onde a estrutura dos dados e a metodologia de avaliação foram apresentadas, com especial atenção à precisão e à interpretabilidade dos resultados no contexto clínico.

O “*Visualização*”, ou “*ProcessoVisualizacao*”, foi responsável por transformar os dados e resultados complexos em representações gráficas intuitivas, facilitando a análise e a compreensão dos padrões mioelétricos, não apenas possibilitando interpretação, mas também o julgamento dos resultados e sua real potencial aplicabilidade.

Por último e não menos importante, o componente “*Predição*”, ou “*ProcessoPredicao*”, foi abordado demonstrando como o modelo de aprendizado, uma vez treinado e testado, é capaz de prever futuras séries temporais de EMG em recortes e ajustes personalizados em séries temporais de pacientes. Este componente é crucial para a aplicação prática do método, pois permite antecipar eventos mioelétricos que habilitam a sua aplicação na replicação de movimentos e no potencial utilidade de criação de dispositivos que façam uso dessas leituras.

Em suma, cada componente foi desenhado e integrado visando propor um método coeso que não só atende aos requisitos computacionais, mas também ressoa com as necessidades e desafios do domínio da engenharia biomédica.

6 ANÁLISE E APRESENTAÇÃO DOS RESULTADOS

Neste segmento da dissertação, inicia-se a exploração dos resultados obtidos a partir do método proposto em um contexto de engenharia biomédica, especificamente na análise de séries temporais de EMG. O desempenho do modelo de aprendizado é avaliado em múltiplas configurações, refletindo a complexidade e a variabilidade dos dados biomédicos. A análise dos resultados do modelo de aprendizado é bifurcada em duas perspectivas principais: a) a acurácia na predição de eventos mioelétricos, fundamentada nos conjuntos de dados previamente delineados; e b) a interpretação qualitativa dos resultados, com ênfase na capacidade de revelar *insights* clínicos valiosos.

Na subsequente Seção 6.1, a atenção é voltada para a acurácia do modelo de aprendizado, onde métricas de desempenho como o MAE e R^2 são utilizadas para quantificar a precisão das previsões. Por outro lado, a Seção 6.2 se dedica à interpretação qualitativa dos resultados, onde a ausência de métricas quantitativas padrão devido à singularidade dos dados de EMG não impede uma análise profunda do conhecimento extraído, demonstrando como o método pode contribuir para o entendimento e a intervenção em condições neuromusculares.

6.1 ANÁLISE DA PRECISÃO

Ao adentrarmos na análise dos resultados obtidos, é imperativo reconhecer a complexidade inerente à predição de eventos mioelétricos em séries temporais de EMG, onde a precisão do modelo não se manifesta apenas na acurácia das previsões, mas também na sua habilidade de discernir padrões ocultos em dados que são, por natureza, altamente variáveis e ricos em informação.

6.1.1 Preparação dos Dados

Ao adentrarmos na análise dos resultados obtidos pela rede neural utilizada, neste caso a LSTM, é importante reconhecer a complexidade inerente à predição de eventos mioelétricos em séries temporais de EMG, onde a precisão do modelo não se manifesta apenas na acurácia das previsões, mas também na sua habilidade de discernir padrões ocultos em dados que são, por natureza, altamente variáveis e ricos em informação.

A preparação dos dados, uma etapa que precede o treinamento, foi realizada com um cuidado meticuloso, onde protocolos rígidos foram seguidos para padronização dos dados.

Inicialmente, todos os conjuntos de dados passaram por testes e validações através de análise cruzada. Isso significa que foram avaliados tanto em sua forma bruta quanto após serem transformados, visto que inicialmente a coleta de informações dos diferentes agrupamentos musculares dos pacientes ocorreu por um sistema que armazena as informações em valores binários em arquivo de formato *.ftr (Figura 34).

Figura 34 - Exemplo de arquivo de leitura de sinais mioelétricos de paciente armazenado em *.ftr e aberto pelo software Notepad++®

```

1  NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL NUL
2  DC2 ESC DC1 ú DC2 ; DC1 ã SUB DC4 ç DC3 r DC2 7 DC1 ç DC2 ST DC1 \ D
3  ETB * ETB " SUB à ETB j ETB x ETB : SYN ò SYN ñ SYN ï SYN ¶ SYN ó SYN ó
4  CAN # SYN Á ETB ± ETB Ý ETB ~ ETB ~ ETB p ETB , ETB ° ETB ¥ ETB í ETB E
5  CAN / CAN CAN CAN @ CAN < ESC " CAN § ETB Ø CAN é CAN ž CAN > CAN š C
6  CAN é CAN M CAN f CAN ú CAN ; CAN ï CAN ¨ CAN í CAN - ESC % ETB Ø EM NUL
7  ETB ETB p ESC / CAN v CAN © ETB ç CAN
8  CAN - ETB ò ETB é ETB ï ETB ó ETB ö SYN Á CAN DC3 ESC 0 CAN x CAN > CA
9  ETB ù CAN DC2 CAN Y ESC J CAN ETB CAN U CAN = CAN SOH CAN \ CAN " CA
10 CAN < ESC | CAN À CAN À CAN ù CAN k CAN ç CAN ï CAN ~ CAN G SCAN NUL C
11 CAN 7 EM Y CAN = ESC f ETB ç CAN * CAN
12 CAN > ETB ó CAN l ETB ÷ CAN SO CAN G CAN SUB EM ENO CAN ; ESC g CAN J
13 ETB ý ETB / CAN 9 ESC k CAN l ETB á CAN œ ETB ÷ CAN Y ETB ú ETB ö CAN A
14 CAN ) CAN NAK CAN S CAN
15 ETB Ø CAN - SYN | ETB ó ESC n CAN # ETB Ý ETB » CAN ACK CAN DLE ETB Ø
16 CAN CAN NAK CAN 8 CAN DC1 CAN 5 CAN ! CAN ð CAN r CAN * CAN ; CAN N
17 CAN - CAN ESC / ETB ï CAN D CAN EOT CAN > CAN ST CAN L CAN K CAN O C
18 ETB Ž CAN H ESC CAN A CAN m CAN * CAN NAK CAN G CAN ! CAN
19 CAN e CAN c CAN " ETB ¥ CAN N ESC ° CAN ² CAN Ý CAN < CAN G SCAN t CAN
20 ESC ± CAN ¶ CAN © CAN Q CAN + CAN © CAN ETB ETB Ú ETB Ú ETB - CAN 4 ET
21 CAN CAN DLE CAN P CAN " CAN 6 ESC · CAN H CAN ACK ETB Q CAN G CAN N
22 CAN d CAN † CAN M CAN G S ETB Ø ETB ó CAN ? ETB CAN \ ESC Á CAN [ CAN
23 ETB † ETB ò CAN K SYN ESC CAN - ESC † CAN p EM 9 CAN * CAN 7 CAN é CAN 4 I

```

Fonte: Elaborado pelo autor (2023)

Esse formato de dados é usualmente utilizado pelo consumo de recursos do *hardware* em captar todos os sinais emitidos pelo corpo e estruturá-los em arquivos de texto em ASCII. Assim, para que seja mais viável captar todas as informações geradas pelo corpo numa faixa de tempo, é computacionalmente mais adequado armazenar em arquivos binários, para que posteriormente sejam convertidos em extensões de alto nível (como *.csv), capazes de serem admitidas nos *Dataframes* da Linguagem Python, conforme Figura 35.

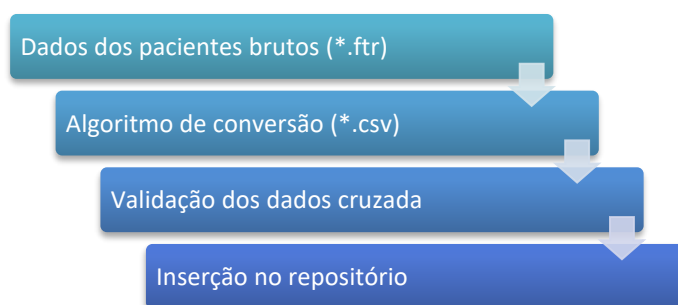
Figura 35 - Exemplo de arquivo de leitura de sinais mioelétricos de paciente armazenado em alto nível *.csv e aberto pelo software MS Excel®

	A	B	C	D	E	F	G	H	I	J
1	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
2	4.946373626373626,	4.942344322344322,	4.92058608058608,	5.008424908424908,	5.123663003663003,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
3	5.0245421245421245,	5.02051282051282,	5.093040293040293,	5.016483516483516,	5.058388278388278,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
4	5.060805860805861,	5.043076923076923,	5.016483516483516,	5.0148717948717945,	5.0035897435897425,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
5	5.0100366300366295,	4.968131868131868,	4.901245421245421,	5.0076190476190465,	5.0221245421245415,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
6	4.985860805860805,	4.97054945054945,	5.0438827838827835,	4.986666666666666,	4.9995604395604385,	4.985054945054945,	4.994725274725274,	4.972161172161172,	4.9955311355311345,	5.062417582417582,
7	5.001978021978021,	5.005201465201465,	5.05032967032967,	4.986666666666666,	4.988278388278388,	5.001978021978021,	5.005201465201465,	5.05032967032967,	4.986666666666666,	4.988278388278388,
8	5.001172161172161,	4.9955311355311345,	4.957655677655677,	5.0100366300366295,	5.0148717948717945,	5.0398534798534795,	5.0358241758241755,	5.0414652014652015,	4.9995604395604385,	4.984249084249084,
9	5.0398534798534795,	5.0358241758241755,	5.0414652014652015,	4.9995604395604385,	4.984249084249084,	5.090622710622711,	5.066446886446886,	5.085787545787546,	4.98021978021978,	4.98021978021978,
10	5.090622710622711,	5.066446886446886,	5.085787545787546,	4.98021978021978,	4.98021978021978,	4.97054945054945,	4.99069597069597,	4.9874725274725265,	5.0189010989010985,	4.997142857142857,
11	5.0390476190476186,	5.015677655677655,	5.0277655677655675,	4.997948717948717,	5.0301831501831495,	4.9874725274725265,	5.0140659340659335,	4.952014652014652,	5.023736263736263,	4.952014652014652,
12	4.9874725274725265,	5.0140659340659335,	4.952014652014652,	5.023736263736263,	4.952014652014652,	5.012454212454212,	5.019706959706959,	4.992307692307692,	5.021318681318681,	5.002783882783882,
13	5.012454212454212,	5.019706959706959,	4.992307692307692,	5.021318681318681,	5.002783882783882,	4.988278388278388,	4.988278388278388,	5.056776556776557,	5.005201465201465,	5.056776556776557,
14	4.988278388278388,	4.988278388278388,	5.056776556776557,	5.005201465201465,	5.056776556776557,	4.949597069597069,	4.947985347985348,	4.986666666666666,	4.998754578754578,	5.0495238095238095,
15	4.949597069597069,	4.947985347985348,	4.986666666666666,	4.998754578754578,	5.0495238095238095,	4.927838827838828,	4.931062271062271,	4.896410256410256,	5.0116483516483505,	5.021318681318681,
16	4.927838827838828,	4.931062271062271,	4.896410256410256,	5.0116483516483505,	5.021318681318681,	4.935897435897436,	4.942344322344322,	4.909304029304029,	5.015677655677655,	5.008424908424908,
17	4.935897435897436,	4.942344322344322,	4.909304029304029,	5.015677655677655,	5.008424908424908,	4.978608058608058,	4.981025641025641,	4.942344322344322,	5.004395604395604,	5.0035897435897425,
18	4.978608058608058,	4.981025641025641,	4.942344322344322,	5.004395604395604,	5.0035897435897425,	5.021318681318681,	5.016483516483516,	4.986666666666666,	4.996336996336996,	4.983443223443222,
19	5.021318681318681,	5.016483516483516,	4.986666666666666,	4.996336996336996,	4.983443223443222,	5.0285714285714285,	5.0180952380952375,	5.009230769230769,	5.0100366300366295,	4.972161172161172,
20	5.0285714285714285,	5.0180952380952375,	5.009230769230769,	5.0100366300366295,	4.972161172161172,	5.006813186813186,	5.008424908424908,	4.972161172161172,	5.0277655677655675,	4.976996336996337,
21	5.006813186813186,	5.008424908424908,	4.972161172161172,	5.0277655677655675,	4.976996336996337,					
22	5.006813186813186,	5.008424908424908,	4.972161172161172,	5.0277655677655675,	4.976996336996337,					

Fonte: Elaborado pelo autor (2023)

Outro ponto importante é que a inserção dos dados foi promovida apenas após a sua validação com os dados originais com prova real, isto é, de forma cruzada, garantindo que as fontes de dados do sistema fossem isentas de qualquer inconsistência ou dado diferente da leitura original. Assim, o procedimento inicial de validação dos dados mioelétricos dos pacientes se fez necessário (Figura 36).

Figura 36 - Procedimento inicial de validação dos dados dos pacientes



Fonte: Elaborado pelo autor (2023)

Esse item é relacionado diretamente com a precisão do modelo, pois ainda que a arquitetura do sistema atenda plenamente os requisitos da solução e seja idealmente desenhada computacionalmente, se os dados coletados não forem fidedignos, os resultados sempre serão falhos.

6.1.2 Seleção, Transformação e Segmentação de Dados

Ao se considerar a seleção e transformação de dados, constitui-se o alicerce sobre o qual o modelo de ML é construído e otimizado. No contexto da arquitetura LSTM aplicada à engenharia biomédica, essas etapas são vitais para garantir que os padrões temporais complexos presentes nos sinais mioelétricos sejam capturados e utilizados de forma eficaz pelo modelo.

Em específico, a seleção dos dados foi guiada pela necessidade de capturar a essência dos sinais mioelétricos, que são caracterizados por sua natureza temporal e multidimensional. Para isso, foram separados os 12 agrupamentos musculares ilustrados na Quadro 9, mais o Pedivela (*crankset*) na importação do arquivo **.csv* para processamento no *Dataframe*. Essa ação foi realizada de forma individual por paciente, evitando contaminar os conjuntos de dados com informações que pudessem gerar ruído, uma vez que os tipos físicos variados e características de cada indivíduo são únicas, não devendo ser processadas uniformemente.

Já em termos da transformação dos dados houveram duas etapas principais: normalização e segmentação. Na normalização os dados foram normalizados utilizando o *StandardScaler* do *sklearn.preprocessing*. Esta etapa é crucial para modelar sinais mioelétricos, pois normaliza a amplitude dos sinais (Equação 13), permitindo que o modelo trate todas as dimensões de forma equitativa.

Na segmentação, os dados foram divididos em janelas temporais. Cada janela foi definida para conter um número específico de passos temporais, correspondendo ao *input_size*

de 300 (trezentas) posições no modelo LSTM, que são equivalentes a 5 (cinco) minutos de operação. Essa escolha ocorreu pelo equilíbrio em providenciar a solução em tempo adequado de processamento, uma vez que redes densas exigem mais custo computacional a medida que são demandadas, além de que, em experimentos realizados com a inserção de conjuntos de dados maiores, o sistema tendeu a apresentar *overfitting* e a gerar erros como *NaN (Not a Number)* e parando de apresentar sua funcionalidade.

Já na preparação final dos dados, foi envolvida a divisão em conjuntos de treinamento e teste, utilizando a variável *train_size* para determinar o ponto de corte, onde o conjunto de treinamento foi utilizado para ajustar o modelo, enquanto o conjunto de teste foi reservado para avaliar o desempenho do modelo de forma imparcial. Essa divisão foi idealizada para evitar o *bias* potencial de utilizar os mesmos dados para os procedimentos.

Outro ponto importante da escolha dessa separação, é que a divisão foi promovida em faixas de tempo que possam ser factualmente aplicáveis em cenários reais, onde o custo computacional para processar 300 (trezentos) impulsos subsequentes fosse de poucos milissegundos. Isso pode ser considerado um atraso razoável, imaginando em um contexto onde as pernas da pessoa estejam em movimento constante de marcha, seja num dispositivo de pedalar ou mesmo utilizando um exoesqueleto estimulado pelo algoritmo.

A Figura 37 ilustra o tempo médio em processar um conjunto de dados durante o treinamento, lembrando que, para cada paciente, existe um conjunto específico de dados coletados.

Figura 37 - Épocas de treinamento da LSTM utilizando o Google Colaboratory®

```
Epoch 1/10
295/295 [=====] - 5s 13ms/step - loss: 0.5082 - val_loss: 0.0948
Epoch 2/10
295/295 [=====] - 5s 16ms/step - loss: 0.1931 - val_loss: 0.1028
Epoch 3/10
295/295 [=====] - 5s 15ms/step - loss: 0.1517 - val_loss: 0.0608
Epoch 4/10
295/295 [=====] - 4s 12ms/step - loss: 0.1367 - val_loss: 0.0621
Epoch 5/10
295/295 [=====] - 4s 12ms/step - loss: 0.1348 - val_loss: 0.0566
Epoch 6/10
295/295 [=====] - 6s 19ms/step - loss: 0.1333 - val_loss: 0.0582
Epoch 7/10
295/295 [=====] - 4s 12ms/step - loss: 0.1362 - val_loss: 0.0574
Epoch 8/10
295/295 [=====] - 3s 12ms/step - loss: 0.1326 - val_loss: 0.0600
Epoch 9/10
295/295 [=====] - 5s 16ms/step - loss: 0.1322 - val_loss: 0.0652
Epoch 10/10
295/295 [=====] - 4s 15ms/step - loss: 0.1324 - val_loss: 0.0574
```



Como pode ser observado, cada passo de treinamento levou em torno de 14,2ms (milissegundos) para ser completado. O que faz crer na possibilidade viável de implementação do modelo em conjunto com *hardwares* vestíveis ou outras soluções de mobilidade com poucos recursos de processamento.

Se pensarmos nesse sentido, a agilidade na transformação de dados pode se tornar um pilar crítico na construção de modelos de ML que sejam leves, especialmente quando aplicados a dispositivos vestíveis ou exoesqueletos em engenharia biomédica para popularização da tecnologia.

Estes dispositivos, que muitas vezes prometem revolucionar a reabilitação e a assistência a pacientes com limitações motoras, dependem fortemente da precisão e da rapidez com que os dados são processados e interpretados. Assim, a ágil normalização dos biosinais, pode garantir que o modelo trate todas as dimensões dos dados de forma equitativa, independentemente das variações individuais, possibilitando sua utilização junto à integração de microcontroladores e processadores especializados, como os de SOCs, com uma boa relação de custo e benefício, tangenciando processamento em tempo hábil, seguro e natural aos comandos mioelétricos dos usuários ou pacientes.

Ainda, em termos de escolha de transformação de dados, gráficos de linha foram gerados, mostrando os sinais antes e depois da normalização. Para nossos testes, foram testadas diferentes dimensões como com a utilização de um único canal muscular individual, bem como a utilização do canal muscular individual e em conjunto do *encoder* conforme Figura 38:

Figura 38 - Comparação dos valores de perda no processo de treinamento do modelo



(A) demonstra o treinamento com um único canal individual e (B) demonstra o treinamento com dois canais, sendo um deles o canal muscular e o outro o *encoder* sincronizados no mesmo momento temporal.

Fonte: Elaborado pelo autor (2023)

Estes gráficos oferecem uma visão clara de como o processo de perda é distinto nos dois modelos. Nesse contraste, torna-se nítido o contraponto, de que pela perda gerada ser maior no treinamento realizado com o canal muscular e o *encoder*, faz mais sentido manter o canal muscular isolado para sua utilização em previsão de séries temporais de movimentos futuros.

Essas etapas técnicas no desenvolvimento do modelo para utilização clínica se tornam decisões que transcendem a computação, tornando-se estratégias que definem a capacidade do método proposto, suportado pelo modelo de aprendizado, de operar de forma generalizada e robusta na prática. No contexto da previsão de séries temporais, a adequação dessas etapas é o que permite que o modelo não apenas aprenda com os dados disponíveis, mas também se adapte e generalize para novos pacientes com perfil similar ou condições de uso, que podem se tornar cada vez mais robustas, a medida que novos dados sejam incorporados.

Em suma, a escolha cuidadosa de como os dados são selecionados, normalizados e segmentados tem um impacto direto na qualidade das previsões e na utilidade prática do modelo em situações reais. Portanto, é essencial que essas decisões sejam informadas por uma compreensão profunda do domínio de aplicação e por uma contínua avaliação dos resultados à medida que o mesmo é exposto a novos dados e desafios.

6.1.3 Configuração do Modelo de Aprendizado

A configuração do modelo é um passo crítico no desenvolvimento de sistemas de ML, especialmente em aplicações de engenharia biomédica onde a precisão e a capacidade de generalização são fundamentais.

Para a LSTM funcionar adequadamente, a documentação indica a atribuição e ajustes em diversos parâmetros, como número de épocas de iterações, tamanho de lote, divisão de validação, entre outros. Uma atribuição errônea pode prejudicar todo o código e sua funcionalidade.

Para tanto, a escolha de 10 (dez) épocas foi determinada após várias iterações experimentais. Foi observado que, após as *epochs*, o modelo começava a mostrar sinais de *overfitting*, com uma melhora insignificante ou nenhuma melhora na precisão obtida por meio do conjunto de validação. Outro ponto importante percebido, foi que limitar o número de épocas, pode ajudar a manter um tempo de treinamento razoável, o que é crucial em um ambiente clínico onde os modelos podem precisar ser reajustados ou retreinados com novos dados regularmente.

Nessa linha de raciocínio, o tamanho do lote de 50 (cinquenta) foi escolhido para equilibrar a eficiência computacional e a qualidade do gradiente estimado, visto que um tamanho de lote muito pequeno pode levar a uma estimativa de gradiente ruidosa, enquanto um tamanho de lote muito grande pode causar problemas de memória e pode não capturar a diversidade dos dados de forma eficiente para a aplicação, se mostrando como atribuição eficaz, proporcionando atualizações de gradiente estáveis e permitindo que o modelo se beneficie do paralelismo em Unidades Gráficas de Processamento (do inglês *Graphic Processing Unit* – GPU), que possuem uma quantidade muito vasta de CUDA[®] Cores, em geral, com menor frequência do que um processador, mas em número milhares de vezes maior.

CUDA[®] Cores são unidades de processamento paralelo encontradas nas GPUs da NVIDIA[®], projetadas especificamente para realizar cálculos de alta intensidade que são comuns em gráficos 3D e aplicação de AI e ML. Eles são altamente eficientes em operações de ponto flutuante e podem executar milhares de operações simultaneamente, o que os torna ideais para o treinamento de redes neurais, onde muitas operações matemáticas precisam ser realizadas em paralelo. Já, os núcleos de Unidades Centrais de Processamento (do inglês *Central Processing Unit* – CPU) por sua vez, são mais versáteis e são projetados para lidar com uma ampla variedade de tarefas de computação, sendo adequados para tarefas sequenciais, podendo executar operações complexas que dependem de uma série de passos dependentes (*Complex Instruction Set Computer* – CISC). No entanto, mesmo os processadores modernos com múltiplos núcleos e *threads* não podem igualar a capacidade de processamento paralelo de uma GPU.

Quando se trata do tamanho do lote no treinamento de modelos, as GPUs com seus múltiplos CUDA[®] Cores podem processar grandes lotes de dados simultaneamente, o que acelera significativamente o treinamento, onde por exemplo, uma placa gráfica com 2 (dois) mil CUDA[®] Cores pode processar dados em lotes de 50 (cinquenta) muito mais rapidamente do que uma CPU com 16 (dezesseis) núcleos, visto que cada CUDA[®] Core pode ser atribuído a uma parte do lote para processamento simultâneo. Sendo então essa escolha embasada pela capacidade de processamento paralelo das GPUs.

Ao utilizar uma GPU para treinar uma rede neural LSTM, pode-se tirar proveito dos CUDA[®] Cores para processar cada lote de forma eficiente, reduzindo o tempo de treinamento sem comprometer a qualidade do gradiente, podendo ser particularmente benéfico em engenharia biomédica, onde o modelo pode crescer à medida que mais pacientes possam ser adicionados e, os conjuntos sejam cada vez mais complexos, estando o modelo preparado em

sua arquitetura para sofrer esses acréscimos sem perder desempenho em infraestruturas que possuam tais itens à disposição.

Ademais, a taxa de divisão para validação foi aplicada, após diferentes configurações, em 0,1, significando que 10% do conjunto de dados de treinamento está reservado para validação. Ressalta-se que em redes neurais, diferentemente de outros modelos de aprendizado de máquina, o conjunto de treinamento é dividido em parte destinada ao treinamento e outra, menor, destinada à validação. Neste sentido, em cada época a parte menor, destinada à validação, permite avaliar a taxa de aprendizado considerando o conjunto de treinamento. Esta proporção foi escolhida para fornecer uma amostra suficiente para validar a generalização do modelo sem sacrificar demasiados dados para o treinamento, que são escassos neste momento inicial de pesquisa.

Já as camadas da LSTM, foram configuradas para capturar as dependências de longo prazo nos dados de séries temporais mioelétricas, onde a arquitetura específica, incluindo o número de camadas e o número de neurônios artificiais em cada camada, foram determinados empiricamente. Assim, foi encontrada uma configuração que equilibra a capacidade do modelo de aprender padrões complexos com a necessidade de evitar a complexidade excessiva que poderia levar ao *overfitting*.

Em adição, a função de ativação “*relu*” foi escolhida por sua eficiência computacional e por sua capacidade de mitigar o problema do desaparecimento do gradiente, que é comum em redes neurais profundas. Ela torna-se adequada em redes recorrentes como a da proposição - LSTM, pois ajuda a manter gradientes adequados durante o treinamento.

No caso do otimizador “*Adam*”, foi aplicado por ser conhecido por sua eficiência e por ajustar automaticamente a taxa de aprendizado durante o treinamento, trazendo praticidade e facilidade na implementação. Inclusive, é adequado para o modelo, pois reduz a necessidade de ajustes manuais da taxa de aprendizado, facilitando a convergência para uma solução ótima, onde tempo e esforços podem ser focados na engenharia do conhecimento, desenho da solução e sua arquitetura e, menos em camadas mais nucleares como as de implementação matemática e estatística.

Por último, a função de perda MSE é padrão para problemas de regressão, como é o caso na previsão de séries temporais mioelétricas, medindo a média dos quadrados das diferenças entre os valores previstos e os reais, fornecendo uma medida clara de quão bem o modelo está realizando previsões e na sua aplicação, que será aprofundada posteriormente. A seguir, o Quadro 15 ilustra o resumo dos hiperparâmetros selecionados e suas justificativas.

Quadro 15 - Hiperparâmetros da proposição do modelo e suas justificativas

Hiperparâmetro	Valor	Justificativa
Número de épocas	10	Equilíbrio entre aprendizado e tempo de computação.
Tamanho do lote	50	Otimiza a eficiência do treinamento.
Taxa de divisão de validação	0.1	Permite monitorar o sobreajuste durante o treinamento.
Número de camadas LSTM	1 (100 unidades)	Suficiente para capturar a complexidade dos dados sem causar sobreajuste.
Função de ativação	relu	Promove a não-linearidade necessária para o aprendizado.
Otimizador	adam	Eficiente para grandes volumes de dados e ajustes de taxa de aprendizado automáticos.
Função de perda	mse	Adequada para problemas de regressão e fácil interpretação dos erros.

Fonte: Elaborado pelo autor (2023)

Neste cenário, optou-se por uma máquina virtual na nuvem como a arquitetura para implementação do modelo, devido à sua agilidade e à facilidade de expandir os recursos computacionais conforme a necessidade. Para isso, utilizou-se a infraestrutura do Google Colab®, a partir de uma arquitetura de *hardware* de 2 processadores virtuais (vCPU) Intel(R) Xeon® (Frequência de 2,20GHz e Memória Cache de 56320 KB), RAM de 12GB e espaço de HDD de 107GB.

A configuração da arquitetura LSTM foi projetada para atender às exigências específicas da aplicação em engenharia biomédica, sendo as decisões tomadas um reflexo de equilíbrio entre teoria e prática, eficiência e precisão, e são fundamentadas em uma compreensão sólida dos princípios de ML e das necessidades do domínio de aplicação. A transparência e a justificativa de cada escolha são essenciais para a confiança no modelo e para a sua adoção em ambientes clínicos.


6.2 ANÁLISE QUALITATIVA E EXPLICITAÇÃO DO CONHECIMENTO

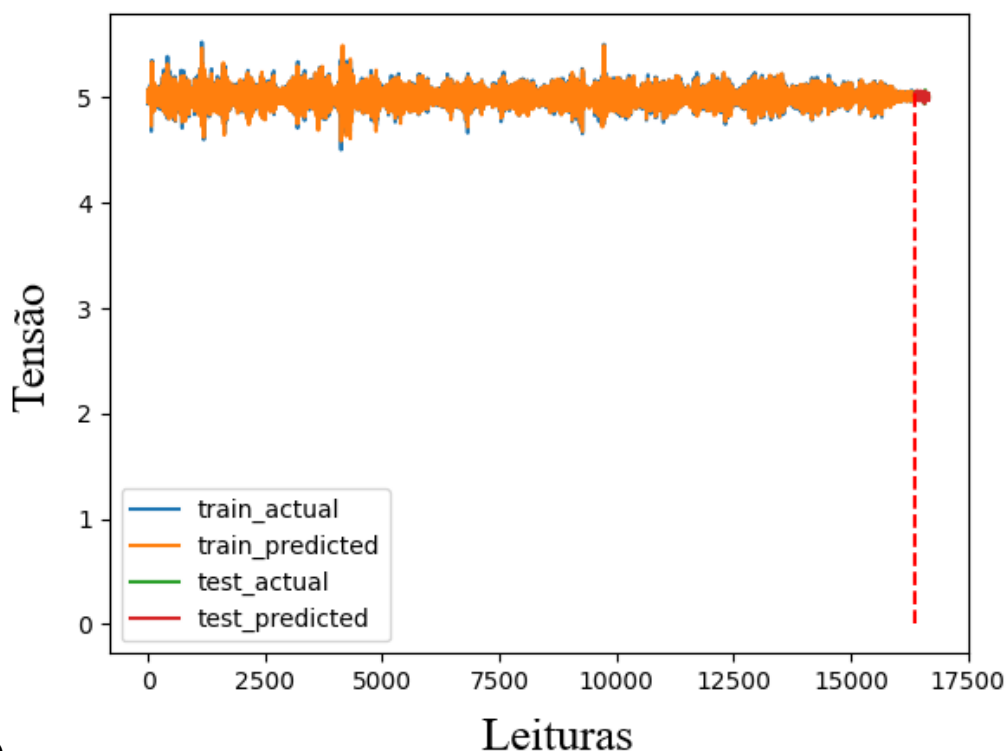
No domínio da análise qualitativa e da explicitação do conhecimento, existe uma esfera onde os números cedem lugar à interpretação e ao significado mais profundo dos resultados. Através da exploração do “como” e do “porque”, das recomendações geradas pelo modelo em previsões futuras, desmembram-se as nuances e contextos em que os resultados obtidos são contrastados para melhor entendimento dos *insights* da aplicação na área da saúde.

Ao abordar a análise qualitativa, é crucial reconhecer a complexidade inerente à interpretação dos resultados de um algoritmo tão sofisticado quanto de uma rede neural LSTM, visto que se abre uma janela para a compreensão profunda dos padrões de séries temporais nos dados mioelétricos de pacientes; contudo, essa compreensão exige uma exploração meticulosa dos resultados gerados.

De forma inicial, para ilustrar a eficácia do modelo, a Figura 37 demonstra a comparação dos conjuntos de treino reais (*train_actual*) e preditos (*train_predicted*), bem como testes reais (*test_actual*) e preditos (*test_predicted*), para um canal mioelétrico exclusivamente, onde ilustra-se também através de uma linha vermelha tracejada, o momento em que exibe-se a plotagem de dados do teste de predição com a apresentação dos dados reais e preditos na Figura 39.

Figura 39 - Comparação dos valores de leitura mioelétrica de apenas um canal muscular sincronizada nos diferentes conjuntos de dados



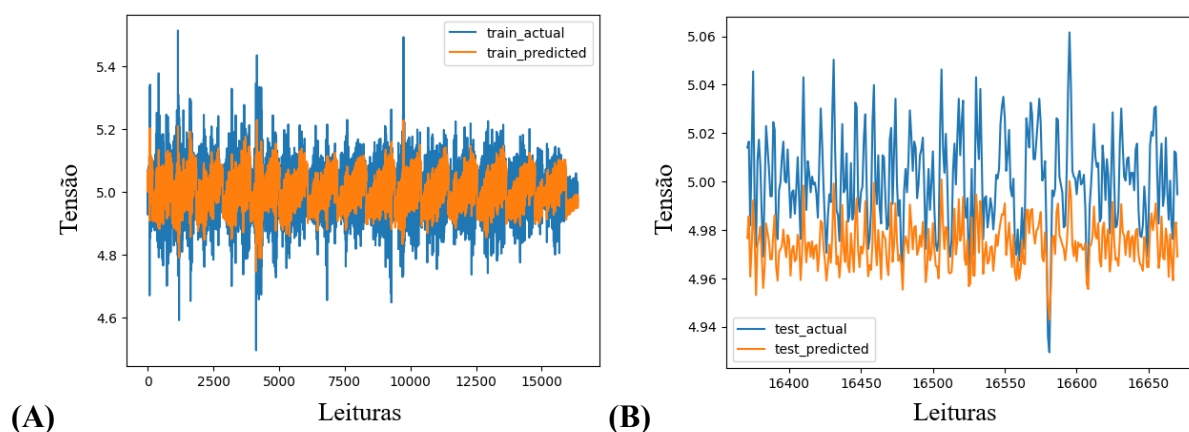


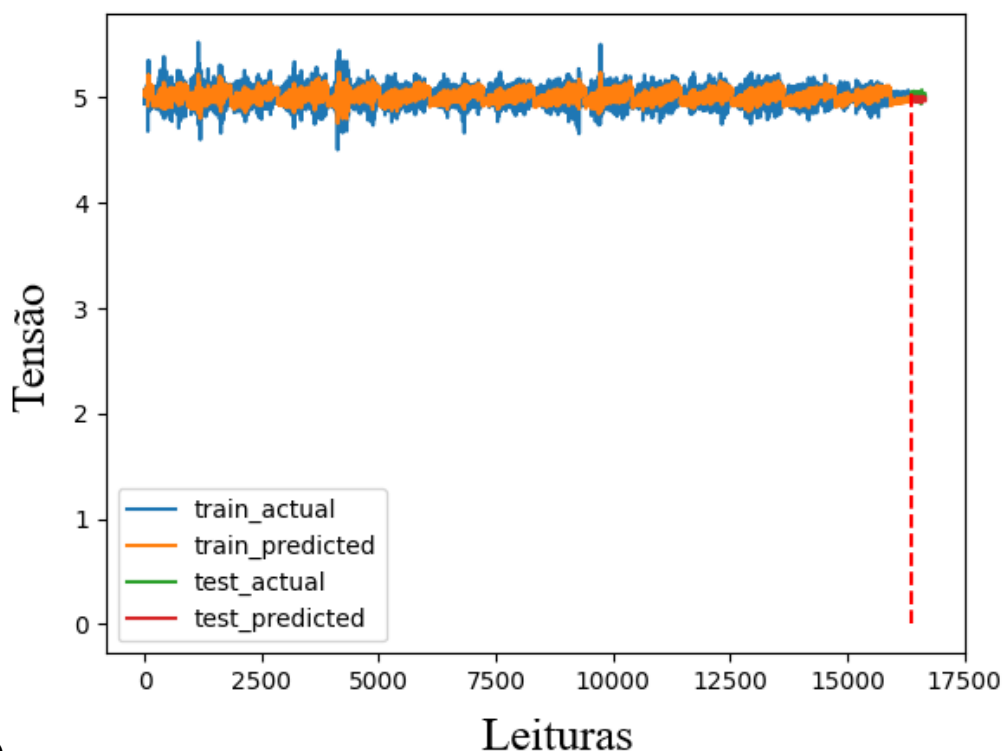
(A) representa o conjunto de dados de treino reais e preditos, (B) representa o conjunto de dados de teste reais e preditos e, (C) representa o contraste completo entre todos.

Fonte: Elaborado pelo autor (2023)

Como pode ser observado, os valores se aproximam bastante do ideal real, onde tem-se uma relação muito próxima dos valores originais e orgânicos naturais do paciente. Agora, apresenta-se a comparação com a utilização com dois canais, onde o *Dataframe* utilizado segmenta-se em dois itens para serem aplicados, onde o primeiro é composto por um canal mioelétrico muscular e o segundo o *encoder* (Figura 40)

Figura 40 - Comparação dos valores de leitura mioelétrica de apenas dois canais, sendo um canal muscular em conjunto do encoder, sincronizados nos diferentes conjuntos de dados





(C)

(A) representa o conjunto de dados de treino reais e preditos, (B) representa o conjunto de dados de teste reais e preditos e, (C) representa o contraste completo entre todos.

Fonte: Elaborado pelo autor (2023)

Conforme pode ser observado, existe uma diferença significativa entre os dados apresentados nas Figura 38 e Figura 39, denotando que para maior acurácia do modelo, os canais não devem ser unidos para treinamento e predição, tendo maior desempenho dissociados em operações separadas. Na sequência é apresentada a comparação entre as métricas de MAE, MSE, RMSE e R^2 de cada um dos modelos (Tabelas 15 e 16).

Tabela 15 - Relação numérica entre as métricas MAE, MSE, RMSE e R^2 para os modelos onde há um canal e dois canais (canal muscular e *encoder*)

Métrica de Avaliação	Caso 1 (Canal Muscular Único)	Caso 2 (Canal Muscular e <i>Encoder</i>)
MAE	0.006615997830764625	0.027212253182332922
MSE	$6.927873979754307 \times 10^{-5}$	0.0008542637905548791
RMSE	0.00832338511649816	0.029227791407406736
R^2	0.8116673735718785	-1.3222960436031026

Fonte: Elaborado pelo autor (2023)

Tabela 16 - Relação qualitativa entre as métricas MAE, MSE, RMSE e R^2 para os modelos onde há um canal e dois canais (canal muscular e *encoder*)

Métrica de Avaliação	Caso 1 (Canal Muscular Único)	Caso 2 (Canal Muscular e Encoder)
MAE	Melhor ✓	Pior ✗
MSE	Melhor ✓	Pior ✗
RMSE	Melhor ✓	Pior ✗
R^2	Adequado ✓	Inadequado ✗

Fonte: Elaborado pelo autor (2023)

Ao analisar as tabelas acima, observa-se que o Caso 1, baseado em um único canal muscular mioelétrico, apresenta métricas de erro significativamente mais baixas (MAE, MSE, RMSE) do que o Caso 2, que combina um canal muscular com um *encoder*. O MAE e o MSE são métricas que oferecem uma visão direta da magnitude dos erros do modelo. Já o RMSE, sendo a raiz quadrada do MSE, também fornece uma medida da magnitude dos erros, mas atribui mais peso a erros maiores: em todos esses índices, quanto menor o valor, melhor o desempenho do modelo.

Não obstante, o coeficiente de determinação (R^2), que é uma métrica que indica o quão bem as variáveis independentes predizem a variável dependente, tem-se um valor de 0,8117 no Caso 1, indicando boa capacidade preditiva, atingindo aproximadamente 81% da variabilidade dos dados. Por outro lado, o R^2 negativo no Caso 2 indica que o modelo é inadequado, pois está fazendo previsões piores do que se simplesmente fosse utilizada a média dos dados como previsão.

Com base nestas métricas, o Caso 1 é claramente o modelo superior. No contexto da engenharia biomédica e, mais especificamente, na leitura de sinais mioelétricos para FES, a precisão é de suma importância. Um modelo com menor erro e maior coeficiente de determinação é mais confiável e, portanto, mais seguro para aplicar em dispositivos que podem estar diretamente influenciando a mobilidade e a saúde dos pacientes.

A escolha do Caso 1 como o modelo preferencial é reforçada pela necessidade de precisão em aplicações de FES, onde a estimulação precisa ser aplicada de maneira precisa para ser eficaz e evitar desconforto ou dano ao paciente. Nesse sentido, a simplicidade do modelo de um único canal pode ser benéfica em termos de computação em tempo real, pois modelos mais simples geralmente requerem menos recursos computacionais como dito anteriormente, o que é crucial para aplicações em dispositivos vestíveis que têm capacidade de processamento limitada e ainda, mais competitivo em razões de mercado, requerendo investimentos menores de infraestrutura *On-Premises* ou *On-Demand*.

Em suma, o Caso 1 não só apresenta um desempenho estatístico superior, mas também é mais viável para implementação em tempo real em aplicações de engenharia biomédica, como FES, onde a precisão e a eficiência computacional são críticas.

6.3 SÍNTESE DO CAPÍTULO

Este capítulo proporcionou uma análise abrangente dos resultados obtidos a partir do método proposto e do modelo de aprendizado de máquina utilizado, com foco particular na engenharia biomédica e na leitura de sinais mioelétricos para aplicações como a FES. Pelo detalhamento, que foi dividido em duas seções principais, foi possível não apenas avaliar a precisão do modelo, mas também entender a qualidade do conhecimento que ele foi capaz de extrair e explicitar.

Abordando avaliação e discussão quantitativa do modelo, utilizando métricas estabelecidas como MAE, MSE, RMSE e R^2 , a precisão foi detalhada em diferentes configurações, refletindo a robustez do modelo de aprendizado em capturar e prever a dinâmica complexa dos biosinais. A análise revelou que o mesmo, quando ajustado com um único canal mioelétrico, superou significativamente a configuração que incluía dados adicionais do *encoder*. Isso reforça a importância de uma seleção criteriosa de características na melhoria da performance do modelo, especialmente em um campo tão delicado quanto a engenharia biomédica, onde a precisão é vital.

Também, foi possível determinar e interpretar resultados para além dos números, onde a ênfase foi dedicada na capacidade do modelo em fornecer *insights* compreensíveis e aplicáveis. Pela análise qualitativa, foi possível discernir como o modelo processa e atribui pesos às diferentes características dos dados, o que é crucial para a aplicação prática em dispositivos de FES. A explicitação do conhecimento, ilustrada por gráficos e tabelas, permitiu uma compreensão mais profunda das relações aprendidas pelo modelo, destacando sua aplicabilidade em cenários reais de uso. Uma análise completa de todos os múltiplos canais está ilustrada no Apêndice E.

A análise temporal de múltiplos canais tem o potencial de servir como uma ferramenta para diagnósticos, especialmente em áreas como neurologia e reabilitação muscular, objetivando que o profissional que esteja conduzindo a terapia tenha condição de avaliar detalhadamente a coordenação e função muscular, podendo relevar anomalias específicas, trazendo os padrões de ativação muscular históricos e previstos de forma visual.

Conclui-se assim que, a síntese deste capítulo reflete a complexidade e a profundidade do estudo realizado e discutido. A precisão do modelo de predição e a explicitação do conhecimento são dois pilares que sustentam a confiabilidade e a aplicabilidade do método em contextos reais da área da saúde. A análise conduzida oferece uma base sólida para futuras pesquisas e desenvolvimentos, abrindo caminho para avanços significativos no uso de algoritmos de ML na engenharia biomédica e na melhoria da qualidade de vida de pacientes que dependem de tecnologias assistivas avançadas, bem como em ações capacitivas de engenharia, gestão e mídia do conhecimento.

7 CONCLUSÕES E TRABALHOS FUTUROS

Este estudo apresentou um método voltado ao tratamento fisioterapêutico de FES com o uso de um método apoiado em ML. As conclusões extraídas deste trabalho são multifacetadas e serão detalhadas na seção 7.1, seguida da seção de perspectivas de trabalhos futuros, 7.2.

7.1 CONCLUSÕES

Na área da fisioterapia, enfrentar as SCIs é um desafio significativo, demandando estratégias terapêuticas inovadoras e adaptadas para aprimorar a recuperação e bem-estar dos pacientes. A incorporação de tecnologias emergentes, como a FES, tem se mostrado eficiente, proporcionando abordagens terapêuticas mais eficientes. Diante deste cenário, emerge a necessidade de desenvolver novos métodos que possam refinar o tratamento fisioterapêutico, particularmente para casos complexos de lesão medular. A implementação de técnicas avançadas como ML, representa uma direção promissora para atingir essa meta, adaptando-se especificamente às exigências de cada paciente.

No presente estudo, foi desenvolvido um método detalhado que incorpora um modelo de predição baseado em ANNs, especificamente a arquitetura LSTM, para a análise de séries temporais de biosinais. Este método, aplicável em contextos musculares através da FES na área de fisioterapia e engenharia biomédica, é projetado para oferecer um tratamento mais eficiente e personalizado para pacientes com SCI. O passo a passo do método, juntamente com a implementação do modelo LSTM, foi avaliado em diversas configurações, revelando a complexidade dos dados biomédicos. Essa avaliação comprova a validade e a eficiência da abordagem proposta, destacando sua capacidade de atender às necessidades específicas de cada caso de lesão medular.

Consequentemente, o foco foi dividido entre a acurácia na predição de eventos mioelétricos e a interpretação qualitativa dos resultados. Essa bifurcação enfatiza a capacidade do modelo de aprendizado de revelar *insights* clínicos valiosos, destacando a multifuncionalidade da proposição desenvolvida.

Ademais, é imperativo reconhecer a complexidade inerente à predição de eventos mioelétricos em séries temporais de EMG. A precisão do modelo de aprendizado manifesta-se não apenas na acurácia das previsões, mas também na habilidade de discernir padrões ocultos em dados altamente variáveis e ricos em informação, uma característica essencial para o sucesso do modelo em aplicações práticas.

No processo de preparação dos dados, uma etapa crucial que precede o treinamento, observou-se a necessidade de se adotar protocolos para a padronização dos dados, em observação a sua qualidade e também, a fidelidade das informações utilizadas.

Não obstante, a inserção dos dados no modelo foi precedida por uma validação cruzada, assegurando que as fontes de dados do sistema fossem isentas de qualquer inconsistência ou erro. Esse procedimento de validação dos dados mioelétricos dos pacientes mostrou ser importante no processo de certificação para a integridade do modelo de aprendizado e do método proposto como um todo.

É essencial considerar também, que a seleção e transformação de dados constituem o alicerce sobre o qual o modelo de aprendizado é construído e otimizado. No contexto da arquitetura LSTM aplicada à FES, estas etapas são vitais para garantir que os padrões temporais complexos nos sinais mioelétricos sejam eficazmente capturados e utilizados.

Na preparação, transformação e segmentação dos dados, foram realizadas duas etapas principais: normalização e segmentação. A normalização, realizada com o *StandardScaler* do *sklearn.preprocessing*, foi condição *sine qua non* para modelar as séries temporais dos biosinais, normalizando a sua amplitude, permitindo tratar as informações de forma equitativa nas janelas temporais, sendo observada a adequada separação entre treino/validação e treino para a ANN.

Focando na decisão crítica entre estruturar o modelo de maneira individual para cada paciente ou de forma global, abrangendo todos os pacientes, foram estabelecidas e avaliadas as bases para a concepção da arquitetura LSTM. Esta decisão foi guiada pelo grande volume de dados disponíveis e pela avaliação de métricas de desempenho. Após uma análise cuidadosa, optou-se por desenvolver modelos de aprendizado individualizados, justificados pela necessidade de atender às variações e especificidades únicas de cada paciente, que é crucial em tratamentos de fisioterapia para lesões medulares.

A rede LSTM, desenvolvida individualmente para cada paciente, foi submetida a uma avaliação tanto qualitativa quanto quantitativa. Foram observadas métricas de desempenho como MAE, MSE, RMSE e R^2 , além de análises gráficas. Nessa linha, contrariando as perspectivas apresentadas por certos acadêmicos na literatura, que sugerem uma aplicação problemática do MSE, neste estudo, a sua implementação mostrou-se não apenas bem-sucedida, mas também livre de contratempos significativos. Demonstrou-se uma ferramenta eficiente para a avaliação da acurácia do modelo proposto para predição, desafiando as concepções prévias sobre suas limitações e reafirmando sua relevância no contexto da mensuração de desempenho de modelos estatísticos.

As avaliações realizadas neste estudo demonstraram não apenas a eficiência e a eficácia do modelo proposto, evidenciando sua aplicabilidade em contextos de FES na fisioterapia, mas também destacaram seu potencial em contribuir para melhorias em exoesqueletos, engenharia biomédica e outros dispositivos vestíveis. Fundamentalmente, o método desenvolvido se revela como uma parte crucial de um projeto mais amplo que transcende os limites do software, incorporando modelagem avançada através de redes neurais e integrando componentes de *hardware* essenciais. Esta abordagem holística, enfatizando a sinergia entre software e hardware, é vital para a aplicação prática em equipamentos terapêuticos e pavimentando o caminho para inovações futuras na área.

A abordagem de modelagem individualizada mostrou-se particularmente eficaz, permitindo uma adaptação mais precisa às necessidades terapêuticas e características físicas de cada paciente, oferecendo um caminho promissor para intervenções mais personalizadas e efetivas.

É imperativo destacar que o sucesso do método não se restringe à sua implementação computacional; ele está intrinsecamente ligado ao desenvolvimento paralelo de soluções de hardware. A sinergia entre software e hardware emerge como um componente fundamental, especialmente ao considerar as implicações práticas em engenharia biomédica e fisioterapia. Esta compreensão integrada é essencial para assegurar que os avanços no modelo computacional se traduzam eficazmente em melhorias tangíveis nos dispositivos de fisioterapia utilizados.

Adicionalmente, as etapas técnicas no desenvolvimento do modelo de aprendizado para utilização clínica revelam oportunidades do método e sua capacidade de operar de forma generalizada e robusta, permitindo que a rede neural utilizada não apenas aprenda com os dados disponíveis, mas também se adapte e generalize para novos pacientes.

Em suma, as conclusões extraídas deste trabalho são multifacetadas e interdisciplinares, proporcionando *insights* valiosos sobre o processo de aprendizado do modelo e a relevância das características dos dados que podem ser potencialmente aplicados na fisioterapia para tratamento de pacientes com SCI e áreas correlatas.

7.2 PERSPECTIVAS DE TRABALHOS FUTUROS

A pesquisa atual abre um leque de possibilidades para futuros desenvolvimentos e pesquisas no campo da engenharia biomédica e da estimulação elétrica funcional FES, onde

perspectivas para trabalhos futuros se tornam amplas e podem ser categorizadas em melhorias técnicas, expansão de aplicabilidade e validação clínica.

Uma linha de pesquisa futura envolve a otimização contínua do modelo, explorando arquiteturas de redes neurais artificiais profundas ou híbridas, que possam capturar ainda mais nuances dos sinais mioelétricos. Com isso, a implementação de técnicas de aprendizado por transferência poderia ser investigada para acelerar o processo de treinamento e aumentar a generalização do modelo para diferentes pacientes e tipos de movimento. Assim, a aplicação de algoritmos de aprendizado não-supervisionado para a detecção de anomalias poderia melhorar a segurança e a eficácia do sistema de FES.

Outra direção promissora é a expansão do método proposto para outras aplicações dentro da engenharia biomédica, como a monitorização da fadiga muscular em atletas ou pacientes em reabilitação. Imaginando a integração com dispositivos vestíveis avançados e exoesqueletos inteligentes, que podem se ajustar em tempo real às necessidades do usuário, representa um campo de aplicação particularmente interessante. A pesquisa poderia também explorar a viabilidade de usar o modelo em conjunto com outras formas de terapia de reabilitação, como *biofeedback* ou realidade virtual.

Outrossim, para garantir a eficácia e a segurança do modelo, pode ser uma alternativa realizar estudos longitudinais com mais pacientes. Isso permitiria não apenas testar a robustez do método em condições reais de um agrupamento maior de pessoas, mas também coletar dados valiosos para refinar o algoritmo a partir de características únicas do ser humano. Desta forma, a colaboração contínua com profissionais de saúde para desenvolver protocolos de teste e avaliação, poderia ajudar a alinhar o método com as mais necessidades clínicas e melhorar a aceitação por parte dos usuários finais ou pacientes.

Não obstante, os trabalhos futuros também podem se beneficiar de uma abordagem interdisciplinar como foi este caso, combinando conhecimentos de engenharia, neurociência, fisioterapia e psicologia. Sendo assim a colaboração com especialistas dessas áreas poderia conduzir a novas ideias em como os pacientes interagem com a tecnologia de FES, AI, e outros domínios, objetivando melhorar a reabilitação.

Por último, é importante ressaltar e considerar os aspectos éticos e regulatórios relacionados ao uso de AI na saúde. Portanto, o desenvolvimento de diretrizes éticas para o uso de algoritmos de previsão em tratamentos médicos e a conformidade com as regulamentações de dispositivos serão essenciais para a implementação bem-sucedida de tais tecnologias.

Em resumo, o potencial para trabalhos futuros é vasto e promissor, sendo a pesquisa e o desenvolvimento nessas áreas não só uma possibilidade para o campo da engenharia

biomédica, mas também um impacto significativo na melhoria da qualidade de vida das pessoas que dependem de tecnologias de FES para sua reabilitação e independência diária.

E assim, à medida que se encerra esta jornada de inovação e descoberta, é essencial reconhecer que uma era promissora se apresenta na engenharia biomédica, onde a fusão da tecnologia e da compreensão humana abre portas para possibilidades antes inimagináveis. Este trabalho não é apenas um compêndio de dados e análises; é um farol de esperança para aqueles que buscam recuperar a autonomia sobre seus movimentos e suas vidas. Com cada avanço, ocorre uma aproximação com um futuro em que as limitações físicas são transcendidas pela engenhosidade humana e pela compaixão, onde determinado obstáculo é uma oportunidade para inovação e onde uma descoberta pode proporcionar meios de restaurar a força e a graça do corpo humano. Que este trabalho seja um convite à comunidade científica e aos visionários do mundo todo para continuarem a busca incansável pelo conhecimento e pela aplicação prática da ciência, para que se construa um amanhã mais brilhante e inclusivo para todos.

REFERÊNCIAS

- AL-FEDAGHI, S. Conceptual Modeling with Constraints. **Cornwell University Software Engineering**, 5 jun. 2022. <https://doi.org/10.48550/arXiv.2206.02277>
- ALZHANOVA, F. G. et al. Analysis of the Level of Technological Development and Digital Readiness of Scientific-Research Institutes. **The Journal of Asian Finance, Economics and Business**, v. 7, n. 12, p. 1133–1147, 31 dez. 2020. <https://dx.doi.org/10.13106/jafeb.2020.vol7.no12.1133>
- APIOLA, M.; SUTINEN, E. Design science research for learning software engineering and computational thinking: Four cases. **Computer Applications in Engineering Education**, v. 29, n. 1, p. 83–101, 19 jun. 2020. DOI:10.1002/cae.22291
- BARELLI, R. G.; AVELINO, V. F.; CASTRO, M. STIMGRASP: A Home-Based Functional Electrical Stimulator for Grasp Restoration in Daily Activities. **Sensors**, v. 23, n. 1, p. 10–10, 20 dez. 2022. <https://doi.org/10.3390/s23010010>
- BECK, T. et al. Knowledge engineering for health: A new discipline required to bridge the “ICT gap” between research and healthcare. **Human Mutation**, v. 33, n. 5, p. 797–802, 4 abr. 2012. <https://doi.org/10.1002/humu.22066>
- BENFELL, A. Modeling functional requirements using tacit knowledge: a design science research methodology informed approach. **Requirements Engineering**, 21 mar. 2020. DOI:10.1007/s00766-020-00330-4
- BROWN, A. K. et al. Exercise therapy and recovery after SCI: evidence that shows early intervention improves recovery of function. **Spinal Cord**, v. 49, n. 5, p. 623–628, 18 jan. 2011. <https://dx.doi.org/10.1038/sc.2010.167>
- CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247–1250, 30 jun. 2014. doi: 10.5194/GMD-7-1247-2014
- CHEPELEV, L. L. et al. Ontologies in the New Computational Age of Radiology: RadLex for Semantics and Interoperability in Imaging Workflows. **Radiographics**, v. 43, n. 3, 1 mar. 2023. <https://doi.org/10.1148/rg.220098>
- CHNITI, G.; BAKIR, H.; ZAHER, H. E-commerce Time Series Forecasting using LSTM Neural Network and Support Vector Regression. **Proceedings of the International**

Conference on Big Data and Internet of Thing - BDIOT2017, 2017.
DOI:10.1145/3175684.3175695

CHOU, A. et al. Expert-augmented automated machine learning optimizes hemodynamic predictors of spinal cord injury outcome. **PLOS ONE**, v. 17, n. 4, p. e0265254–e0265254, 7 abr. 2022. <https://dx.doi.org/10.1371/journal.pone.0265254>

DILLEN, A. et al. Deep learning for biosignal control: insights from basic to real-time methods with recommendations. **Journal of Neural Engineering**, v. 19, n. 1, p. 011003, 1 fev. 2022.
DOI: 10.1088/1741-2552/ac4f9a

DRESCH, A.; LACERDA, D. P.; ANTUNES JR, J. A. V. **Design Science Research**. Cham: Springer International Publishing, 2015. <http://dx.doi.org/10.1007/978-3-319-07374-3>

DRUKKER, L.; NOBLE, J. A.; PAPAGEORGHIOU, A. T. Introduction to artificial intelligence in ultrasound imaging in obstetrics and gynecology. **Ultrasound in Obstetrics & Gynecology**, v. 56, n. 4, p. 498–505, out. 2020. <https://doi.org/10.1002/uog.22122>

EHRMANN, C. et al. Describing Functioning in People Living With Spinal Cord Injury Across 22 Countries: A Graphical Modeling Approach. **Archives of Physical Medicine and Rehabilitation**, v. 101, n. 12, p. 2112–2143, dez. 2020. DOI: 10.1016/j.apmr.2020.09.374

GIANSANTI, D. The Regulation of Artificial Intelligence in Digital Radiology in the Scientific Literature: A Narrative Review of Reviews. **Healthcare**, v. 10, n. 10, p. 1824, 21 set. 2022. <https://dx.doi.org/10.3390/healthcare10101824>

GOECKS, L. S. et al. Design Science Research in practice: review of applications in Industrial Engineering. **Gestão & Produção**, v. 28, n. 4, 2021. <https://doi.org/10.1590/1806-9649-2021v28e5811>

GREGÓRIO, J. et al. The role of Design Science Research Methodology in developing pharmacy eHealth services. **Research in Social and Administrative Pharmacy**, v. 17, n. 12, p. 2089–2096, dez. 2021. DOI:10.1016/j.sapharm.2021.05.016

HAQ, A. UL et al. DACBT: deep learning approach for classification of brain tumors using MRI data in IoT healthcare environment. **Scientific Reports**, v. 12, p. 15331, 12 set. 2022. <https://dx.doi.org/10.1038/s41598-022-19465-1>

HARRISON, J. H. et al. Introduction to Artificial Intelligence and Machine Learning for Pathology. **Archives of Pathology & Laboratory Medicine**, 22 jan. 2021. <https://doi.org/10.5858/arpa.2020-0541-CP>

HSIEH, C.-L., HSUEH, I-PING., CHIANG, F.-M., & LIN, P.-H. (1998). Inter-rater reliability and validity of the Action Research arm test in stroke patients. **Age and Ageing**, 27(2), 107–113. <https://doi.org/10.1093/ageing/27.2.107>

IHNAINI, B. et al. A Smart Healthcare Recommendation System for Multidisciplinary Diabetes Patients with Data Fusion Based on Deep Ensemble Learning. **Computational Intelligence and Neuroscience**, v. 2021, p. 1–11, 17 set. 2021. <https://dx.doi.org/10.1155/2021/4243700>

InSCI Survey. Disponível em: <<https://insci.network/insci/T1/en/download.php>>. Acesso em: 2 out. 2023.

IYORTSUUN, N. K. et al. A Review of Machine Learning and Deep Learning Approaches on Mental Health Diagnosis. **Healthcare**, v. 11, n. 3, p. 285, 17 jan. 2023. <https://dx.doi.org/10.3390/healthcare11030285>

J. MIAH, S.; KERR, D.; VON HELLENS, L. A collective artefact design of decision support systems: design science research perspective. **Information Technology & People**, v. 27, n. 3, p. 259–279, 29 jul. 2014. <https://dx.doi.org/10.1108/ITP-04-2012-0041>

JEZERNIK, S. et al. Robotic Orthosis Lokomat: A Rehabilitation and Research Tool. Neuromodulation: **Technology at the Neural Interface**, v. 6, n. 2, p. 108–115, abr. 2003. DOI: 10.1046/j.1525-1403.2003.03017.x

JOHNSON, K. B. et al. Precision Medicine, AI, and the Future of Personalized Health Care. **Clinical and Translational Science**, v. 14, n. 1, 12 out. 2020. <https://dx.doi.org/10.1111/cts.12884>

KARAMAT, J. et al. Enablers Supporting the Implementation of Knowledge Management in the Healthcare of Pakistan. **International Journal of Environmental Research and Public Health**, v. 15, n. 12, p. 2816, 10 dez. 2018. <https://doi.org/10.3390/ijerph15122816>

KIM, K.-T. The Importance of Vascular Repair as the First Step in Spinal Cord Injury Treatment: Commentary on “Therapeutic Approaches Targeting Vascular Repair After Experimental Spinal Cord Injury: A Systematic Review of the Literature”. **Neurospine**, v. 19, n. 4, p. 976–977, 31 dez. 2022. <https://dx.doi.org/10.14245/ns.2245022.511>

KNAUSS, E. Constructive Master’s Thesis Work in Industry: Guidelines for Applying Design Science Research. **arXiv (Cornell University)**, 1 maio 2021. <https://dx.doi.org/10.1109/ICSE-SEET52601.2021.00021>

KUMARI, J.; KUMAR, E.; KUMAR, D. A Structured Analysis to study the Role of Machine Learning and Deep Learning in The Healthcare Sector with Big Data Analytics. **Arch Computat Methods Eng**, v. 30, 3673–3701. 31 mar. 2023. <https://doi.org/10.1007/s11831-023-09915-y>

LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741–761, 26 nov. 2013. <https://doi.org/10.1590/S0104-530X2013005000014>

LACEY, H. Scientific research, technological innovation and the agenda of social justice, democratic participation and sustainability. **Scientiae Studia**, v. 12, n. spe, p. 37–55, 2014. <https://dx.doi.org/10.1590/S1678-31662014000400003>

LAI, B.-Q. et al. Stem cell-derived neuronal relay strategies and functional electrical stimulation for treatment of spinal cord injury. **Biomaterials**, v. 279, p. 121211, 1 dez. 2021. DOI: 10.1016/j.biomaterials.2021.121211

LI, M. et al. Adaptive Sliding Mode Control of Functional Electrical Stimulation (FES) for Tracking Knee Joint Movement. **White Rose Research Online (University of Leeds)**, 1 dez. 2017. <https://dx.doi.org/10.1109/ISCID.2017.53>

LIU, G.; TSUI, E.; KIAN TO, A. An emerging knowledge management framework adopted by healthcare workers in China to combat COVID -19. **Knowledge and Process Management**, 5 jul. 2022. <https://doi.org/10.1002/kpm.1724>

LYON, A. R. et al. The Cognitive Walkthrough for Implementation Strategies (CWIS): a pragmatic method for assessing implementation strategy usability. **Implementation Science Communications**, v. 2, n. 1, 17 jul. 2021. <https://dx.doi.org/10.1186/s43058-021-00183-0>

MACEDO, D. DE O.; FREITAS, L. M. DE; SCHEICHER, M. E. Preensão palmar e mobilidade funcional em idosos com diferentes níveis de atividade física. **Fisioterapia e Pesquisa**, v. 21, p. 151–155, 2014.

MAKI, T., QUAGLIATO, E., CACHO, E., PAZ, L., NASCIMENTO, N., INOUE, M., & VIANA, M. (2006). Estudo de confiabilidade da aplicação da escala de Fugl-Meyer no Brasil. **Revista Brasileira de Fisioterapia**, 10(2), 177–183. <https://doi.org/10.1590/s1413-35552006000200007>

MARTIN, R. M. et al. Artificial intelligence and machine learning: an introduction for orthopaedic surgeons. **Knee Surg Sports Traumatol Arthrosc**, v. 30, n. 2, p. 361–364, 15 set. 2021. <https://doi.org/10.1007/s00167-021-06741-2>

MEDINA, H. R. et al. Machine learning and deep learning applications in microbiome research. **ISME Communications**, v. 2, n. 1, 6 out. 2022. <https://dx.doi.org/10.1038/s43705-022-00182-9>

MITIYO, D. et al. Results from the International Spinal Cord Injury Community Survey: The Lived Experience of People with Spinal Cord Injury in South-Eastern Brazil. **Journal of Rehabilitation Medicine**, v. 54, p. jrm00342–jrm00342, 29 nov. 2022. <https://dx.doi.org/10.2340/jrm.v54.2157>

MOHSEN AFSHARCHI et al. Common understanding in a multi-agent system using ontology-guided learning. **Knowledge and Information Systems**, v. 36, n. 1, p. 83–120, 28 ago. 2012. <https://doi.org/10.1007/s10115-012-0524-7>

MORIASI, D., GITAU, M., PAI, N., DAGGUPATI, P. Hydrologic and Water Quality Models: Performance Measures and Evaluation Criteria. **Transactions of the ASABE**, v. 58, n. 6, p. 1763–1785, 30 dez. 2015. doi: 10.13031/TRANS.58.10715

OOKA, T. et al. Random forest approach for determining risk Predição and predictive factors of type 2 diabetes: large-scale health check-up data in Japan. **BMJ Nutrition, Prevention & Health**, p. bmjnph, 9 mar. 2021. <https://dx.doi.org/10.1136/bmjnph-2020-000200>

OTERO, P. Will artificial intelligence shift the paradigm in pediatrics? **Archivos Argentinos De Pediatría**, v. 121, n. 6, 1 dez. 2023. <https://dx.doi.org/10.5546/aap.2023-10090.eng>

PAI, V. M. et al. Workshop on using natural language processing applications for enhancing clinical decision making: an executive summary. **Journal of the American Medical Informatics Association**, v. 21, n. e1, p. e2–e5, fev. 2014. <https://doi.org/10.1136/amiajnl-2013-001896>

PARUCKER, A. P.; IOCCA ASSUNÇÃO, T. K.; DE OLIVEIRA, E. L. A Importância da Fisioterapia nos Cuidados Paliativos:: Uma Revisão de Literatura. **Monumenta - Revista de Estudos Interdisciplinares**, v. 2, n. 4, p. 48-67, 24 mar. 2022.

PATSAKOS, E. M. et al. Development of the Canadian Spinal Cord Injury Best Practice (Can-SCIP) Guideline: Methods and overview. **The Journal of Spinal Cord Medicine**, v. 44, n. sup1, p. S52–S68, 30 set. 2021. <https://doi.org/10.1080/10790268.2021.1953312>

PEFFERS, K. et al. A Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45–77, dez. 2007. doi:10.2753/mis0742-1222240302

PEREIRA, L. O.; FRANCISCHI, R. P. DE; LANCHÁ JR., A. H. Obesidade: hábitos nutricionais, sedentarismo e resistência à insulina. *Arquivos Brasileiros de Endocrinologia & Metabologia*, v. 47, n. 2, p. 111–127, 1 abr. 2003.

PIANA, V. J., SILVA PINTO JUNIOR, J., & GONÇALVES, A. L. (2022). Accessibility of the node-red iot framework: an integrative review. **Revista E-TECH: Tecnologias Para Competitividade Industrial** - ISSN - 1983-1838, 15(4). <https://doi.org/10.18624/etech.v15i4.1231>

PISOTTA, I.; PERRUCHOUD, D.; IONTA, S. Hand-in-hand advances in biomedical engineering and sensorimotor restoration. **Journal of Neuroscience Methods**, v. 246, p. 22–29, maio 2015. 10.1016/j.jneumeth.2015.03.003

POPOVIC, D.; SINKJÆR, T. Improved Control for Functional Electrical Stimulation to Restore Walking. **Hong Kong Physiotherapy Journal**, v. 18, n. 1, p. 12–20, 2000. DOI: 10.1016/S1013-7025(09)70012-0

Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015: elaboration and explanation. **BMJ**, p. i4086, 21 jul. 2016.

Refining rodent models of spinal cord injury. **Experimental Neurology**, v. 328, p. 113273, 1 jun. 2020. DOI: 10.1016/j.expneurol.2020.113273

ROBINSON, N. et al. Emerging trends in BCI-robotics for motor control and rehabilitation. **Current Opinion in Biomedical Engineering**, v. 20, p. 100354, dez. 2021. DOI: 10.1016/j.cobme.2021.100354

ROY, A. M. A CNN model with feature integration for MI EEG subject classification in BMI. **bioRxiv**. 6 jan. 2022. <https://doi.org/10.1101/2022.01.05.475058>

SARRAIPA et al. MENTOR — A methodology for enterprise reference ontology development. **2008 4th International IEEE Conference Intelligent System**. 11 nov. 2008. DOI: 10.1109/IS.2008.4670436

SENGIK, A. R. et al. Using design science research to propose an IT governance model for higher education institutions. **Education and Information Technologies**, 3 maio 2022. <https://dx.doi.org/10.1007/s10639-022-11088-3>

SHI, Y.; WANG, D.; ZHANG, Z. Categorical Evaluation of Scientific Research Efficiency in Chinese Universities: Basic and Applied Research. **Sustainability**, v. 14, n. 8, p. 4402, 7 abr. 2022. <https://dx.doi.org/10.3390/su14084402>

SLUTZKY, M. W. Brain-Machine Interfaces: Powerful Tools for Clinical Treatment and Neuroscientific Investigations. **The Neuroscientist**, v. 25, n. 2, p. 139–154, 17 maio 2018. <https://doi.org/10.1177/1073858418775355>

ŠTRBAC, M. et al. Microsoft Kinect-Based Artificial Perception System for Control of Functional Electrical Stimulation Assisted Grasping. **BioMed Research International**, v. 2014, p. 1–12, 2014. <https://doi.org/10.1155/2014/740469>

STUDER, R. Situation and Perspective of Knowledge Engineering. In: **SCIENTIFIC Literature Digital Library**. [S. l.]: [s. n.], 2000. [https://doi.org/10.1016/S0169-023X\(97\)00056-6](https://doi.org/10.1016/S0169-023X(97)00056-6)

STUDER, R.; BENJAMINS, V. RICHARD.; FENSEL, D. Knowledge engineering: Principles and methods. **Data & Knowledge Engineering**, v. 25, n. 1-2, p. 161–197, mar. 1998.

SUN; CHU, P.; ZHU, R. Navigation Signal Radio Frequency Channel Modeling and Predistortion Technology Based on Artificial Intelligence Technology and Neural Network. **Mobile Information Systems**, v. 2022, p. 1–11, 18 ago. 2022. <https://doi.org/10.1155/2022/5745907>

TACK, C. Artificial intelligence and machine learning | applications in musculoskeletal physiotherapy. **Musculoskeletal Science and Practice**, v. 39, p. 164–169, fev. 2019. Doi: 10.1016/j.msksp.2018.11.012

TEIXEIRA, J. G.; PATRÍCIO, L.; TUUNANEN, T. Advancing service design research with design science research. **Journal of Service Management**, v. 30, n. 5, p. 577–592, 29 nov. 2019. <https://dx.doi.org/10.1108/josm-05-2019-0131>

THON, C. et al. Artificial Intelligence in Process Engineering. **Advanced Intelligent Systems**, v. 3, n. 6, p. 2000261, 24 mar. 2021. <https://doi.org/10.1002/aisy.202000261>

THOROGOOD, N. P. et al. Incidence and prevalence of traumatic spinal cord injury in Canada using health administrative data. **Frontiers in Neurology**, v. 14, 24 jul. 2023. <https://dx.doi.org/10.3389/fneur.2023.1201025>

TRBOVICH, M. et al. The treatment of neurogenic lower urinary tract dysfunction in persons with spinal cord injury: An open label, pilot study of anticholinergic agent vs. mirabegron to

evaluate cognitive impact and efficacy. *Spinal Cord Series and Cases*, v. 7, n. 1, 10 jun. 2021. <https://dx.doi.org/10.1038/s41394-021-00413-6>

VAN ROMPAEY, L.; JØNSSON, R.; ELMOSE JØRGENSEN, K. Designing lawful machine behaviour: Roboticians' legal concerns. **Computer Law & Security Review**, v. 47, p. 105711, nov. 2022. DOI: 10.1016/j.clsr.2022.105711

VOISIN, N. A science paradigm shift is needed for Earth and Environmental Systems Sciences (EESS) to integrate Knowledge-Guided Artificial Intelligence (KGAI) and lead new EESS-KGAI theories. **OSTI OAI (U.S. Department of Energy Office of Scientific and Technical Information)**, 15 abr. 2021. <https://doi.org/10.2172/1769651>

WALSH, P. et al. Marker-Based Monitoring of Seated Spinal Posture Using a Calibrated Single-Variable Threshold Model. **2006 International Conference of the IEEE Engineering in Medicine and Biology Society**, ago. 2006. DOI: 10.1109/IEMBS.2006.259806

WANG, N. et al. A Convenient Non-harm Cervical Spondylosis Intelligent Identity method based on Machine Learning. **Scientific Reports**, v. 8, n. 1, 27 nov. 2018. DOI: 10.1038/s41598-018-32377-3

WEN, S. et al. Capturing spike train temporal pattern with wavelet average coefficient for brain machine interface. **Scientific Reports**, v. 11, n. 1, 24 set. 2021. DOI: <https://doi.org/10.1038/s41598-021-98578-5>

WILLMOTT, C. J. ON THE VALIDATION OF MODELS. **Physical Geography**, v. 2, n. 2, p. 184–194, jul. 1981. doi: 10.1080/02723646.1981.10642213

WILLMOTT, C.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, v. 30, n. 1, p. 79–82, 2005. doi: 10.3354/CR030079

WULF, J. Development of an AHP hierarchy for managing omnichannel capabilities: a design science research approach. **Business Research**, 12 mar. 2019. DOI:10.1007/S40685-019-0095-5

XU, J. et al. Development and validation of a machine learning algorithm–based risk Prediction model of pressure injury in the intensive care unit. **International Wound Journal**. v. 19, n. 7, p. 1637–1649, 25 jan. 2022. <https://doi.org/10.1111/iwj.13764>

YAN, J. et al. Recent Progress in the Discovery and Design of Antimicrobial Peptides Using Traditional Machine Learning and Deep Learning. **Antibiotics**, v. 11, n. 10, p. 1451–1451, 21 out. 2022. <https://dx.doi.org/10.3390/antibiotics11101451>

YOUSRA, D.; ABDELHAKIM, A. B.; BOUDHIR; MOHAMED, B. A. A New Approach using Deep Learning and Reinforcement Learning in HealthCare. **International journal of electrical and computer engineering systems**, v. 14, n. 5, p. 557–564, 5 jun. 2023. <https://dx.doi.org/10.32985/ijeces.14.5.7>

ZHU, J. Evaluation of Scientific and Technological Research in China's Colleges: A Review of Policy Reforms, 2000–2020. **ECNU Review of Education**, p. 209653112093838, 9 jul. 2020. <https://dx.doi.org/10.1177/2096531120938383>

APÊNDICE A – CONJUNTO DE DADOS DE TESTE

A seguir, uma série de conjuntos de dados de teste, cada um identificado por data e hora, para refletir o escopo e o período específico de coleta. Esses conjuntos são cruciais para entender a dinâmica e a resposta dos pacientes ao tratamento. Os dados, coletados em sessões distintas e em datas específicas, estão listados abaixo.

Conjunto de Dados	Link
27-09-2023 14,58,07	https://drive.google.com/file/d/1dwFGuv35vHgtPTYDQIUhwGORsPowmsHt
26-09-2023 15,46,25	https://drive.google.com/file/d/1AZ2YfoiXHbk_wBhCqSF0bymd8Czzrg_s
26-09-2023 15,48,36	https://drive.google.com/file/d/1x8-Vzlt_rXDPIjFXwLCJMHIRvwBn4hTJ
26-09-2023 16,08,56	https://drive.google.com/file/d/1t547PzttS9PHn0oK5vuVYaPP-3z_QXH
26-09-2023 16,16,41	https://drive.google.com/file/d/1cKS-Kb0BOYTJMm5F3B9hsYEjszfEVcZZ
10-10-2023 17,23,32	https://drive.google.com/file/d/1tQzfb9vs0qOk0LUhpMX-GMUk00pmR5y
26-09-2023 15,23,16	https://drive.google.com/file/d/1IAsh6XcGhx2b0KKuTk_tfTb6qBpDEuQI
26-09-2023 15,28,39	https://drive.google.com/file/d/1c2zND1h48de_URrZQpihaRCCZq6f_ZM5

APÊNDICE B – CÓDIGO FONTE DO MODELO DE PREDIÇÃO DE UM CANAL BASEADO NA ARQUITETURA LSTM

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_absolute_error
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
from keras.models import Sequential, load_model
from keras.layers import LSTM, Dense

from google.colab import drive
drive.mount('/content/drive')

file_name = '/content/drive/MyDrive/Colab Notebooks/Testes/all13-7.csv'
col_names = ['dim1', 'dim2', 'dim3', 'dim4', 'dim5', 'dim6', 'dim7', 'dim8', 'dim9', 'dim10', 'dim11',
'dim12', 'dim13']

df = pd.read_csv(file_name, usecols=[0,1,2,3,4,5,6,7,8,9,10,11,12], header=None,
names=col_names)
df

column='dim3'
df= df[[column]]
df.head()

plt.plot(df[column])

input_size = 10
epochs = 10
batch_size = 50
validation_split = 0.1
test_size = 300 + input_size

train_size = int(len(df) - test_size)
train_data = df.iloc[:train_size]
test_data = df.iloc[train_size:]

print("df",len(df))
print("train_data",len(train_data))
print("test_data",len(test_data))

scaler = StandardScaler()
train_scaled = scaler.fit_transform(train_data)
test_scaled = scaler.transform(test_data)

def create_sequences(data, input_size):
    X, y = [], []
    for i in range(len(data) - input_size):
        X.append(data[i:i + input_size])

```

```

    y.append(data[i + input_size])
    return np.array(X), np.array(y)

X_train, y_train = create_sequences(train_scaled, input_size)
X_test, y_test = create_sequences(test_scaled, input_size)

print(X_train.shape)
print(X_test.shape)

print('X_train.shape[0]', X_train.shape[0])
print('X_train.shape[1]', X_train.shape[1])
print('X_train.shape[2]', X_train.shape[2])
print()
print('y_train.shape[1]', y_train.shape[0])
print('y_train.shape[1]', y_train.shape[1])
print()
print('X_test.shape[1]', X_test.shape[0])
print('X_test.shape[1]', X_test.shape[1])
print('X_test.shape[2]', X_test.shape[2])
print()
print('y_test.shape[1]', y_test.shape[0])
print('y_test.shape[1]', y_test.shape[1])

model = Sequential()
model.add(LSTM(100, activation='relu', input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(2))
model.compile(optimizer='adam', loss='mse')

history = model.fit(X_train, y_train, epochs=epochs,
                    batch_size=batch_size, validation_split=validation_split)

plt.plot(history.history['loss'], label='train')
plt.plot(history.history['val_loss'], label='validation')
plt.legend()
plt.show()

train_predicted = model.predict(X_train.reshape(X_train.shape))
test_predicted = model.predict(X_test.reshape(X_test.shape))

train_predicted = scaler.inverse_transform(train_predicted)
test_predicted = scaler.inverse_transform(test_predicted)

train_actual = scaler.inverse_transform(y_train)
test_actual = scaler.inverse_transform(y_test)

mae = mean_absolute_error(test_actual, test_predicted)
mse = mean_squared_error(test_actual, test_predicted)
rmse = mean_squared_error(test_actual, test_predicted, squared=False)
r2 = r2_score(test_actual, test_predicted)
print('mae', mae)
print('mse', mse)
print('rmse', rmse)
print('r2', r2)

```

```
x1 = np.arange(0, len(train_actual))
x2 = np.arange(len(train_actual), len(train_actual)+len(test_actual))

plt.plot(x1,train_actual)
plt.plot(x1,train_predicted)
plt.legend(['train_actual','train_predicted'])

plt.plot(x2,test_actual[:,0])
plt.plot(x2,test_predicted[:,0])
plt.legend(['test_actual','test_predicted'])

plt.plot(x1,train_actual)
plt.plot(x1,train_predicted)
plt.plot(x2,test_actual[:,0])
plt.plot(x2,test_predicted[:,0])
plt.legend(['train_actual','train_predicted','test_actual','test_predicted'])
plt.vlines(x=int(len(train_actual)), color='r',linestyle='dashed', ymin = 0, ymax = max(test_actual))
plt.show()

future_data = df.iloc[len(df)-input_size-1:len(df)-1]
future_scaled = scaler.transform(future_data)
future_sequence = np.array([future_scaled])

future_predicted = model.predict(future_sequence)
future_predicted = scaler.inverse_transform(future_predicted)

print("Future predicted values:", future_predicted)
```

APÊNDICE C – CÓDIGO FONTE DO MODELO DE PREDIÇÃO DE DOIS CANAIS BASEADO NA ARQUITETURA LSTM

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_absolute_error
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
from keras.models import Sequential, load_model
from keras.layers import LSTM, Dense

from google.colab import drive
drive.mount('/content/drive')

file_name = '/content/drive/MyDrive/Colab Notebooks/Testes/all13-7.csv'
col_names = ['dim1', 'dim2', 'dim3', 'dim4', 'dim5', 'dim6', 'dim7', 'dim8', 'dim9', 'dim10', 'dim11',
'dim12', 'dim13']

df = pd.read_csv(file_name, usecols=[0,1,2,3,4,5,6,7,8,9,10,11,12], header=None,
names=col_names)
df

df = df[['dim1','dim13']]
df.head()

df_od = df[['dim1']]
df_od.head()

plt.plot(df['dim1'])

input_size = 10
epochs = 10
batch_size = 50
validation_split = 0.2
test_size = 300 + input_size

train_size = int(len(df) - test_size)
train_data = df.iloc[:train_size]
test_data = df.iloc[train_size:]

train_size_od = int(len(df_od) - test_size)
train_data_od = df_od.iloc[:train_size_od]
test_data_od = df_od.iloc[train_size_od:]

print("df",len(df))
print("train_data",len(train_data))
print("test_data",len(test_data))
print()
print("df_od",len(df_od))
print("train_data_od",len(train_data_od))

```

```

print("test_data_od",len(test_data_od))

scaler = StandardScaler()
train_scaled = scaler.fit_transform(train_data)
test_scaled = scaler.transform(test_data)

train_scaled_od = scaler.fit_transform(train_data_od)
test_scaled_od = scaler.transform(test_data_od)

def create_sequences(data, input_size):
    X, y = [], []
    for i in range(len(data) - input_size):
        X.append(data[i:i + input_size])
        y.append(data[i + input_size])
    return np.array(X), np.array(y)

X_train, y_train = create_sequences(train_scaled, input_size)
X_test, y_test = create_sequences(test_scaled, input_size)

X_train_od, y_train_od = create_sequences(train_scaled_od, input_size)
X_test_od, y_test_od = create_sequences(test_scaled_od, input_size)

print(X_train.shape)
print(X_test.shape)
print(X_train_od.shape)
print(X_test_od.shape)

print('X_train.shape', X_train.shape)
print()
print('y_train.shape', y_train.shape)
print()
print('X_test.shape', X_test.shape)
print()
print('y_test.shape', y_test.shape)

print('X_train.shape', X_train_od.shape)
print()
print('y_train.shape', y_train_od.shape)
print()
print('X_test.shape', X_test_od.shape)
print()
print('y_test.shape', y_test_od.shape)

model = Sequential()
model.add(LSTM(100, activation='relu',input_shape=(X_train.shape[1], X_train.shape[2])))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')

history = model.fit(X_train, y_train, epochs=epochs,
batch_size=batch_size,validation_split=validation_split)

plt.plot(history.history['loss'], label='train')
plt.plot(history.history['val_loss'], label='validation')
plt.legend()
plt.show()

```

```
train_predicted = model.predict(X_train.reshape(X_train.shape))
test_predicted = model.predict(X_test.reshape(X_test.shape))

train_predicted = scaler.inverse_transform(train_predicted)
test_predicted = scaler.inverse_transform(test_predicted)

train_actual = scaler.inverse_transform(y_train)
test_actual = scaler.inverse_transform(y_test)

train_actual = train_actual[:,0]
train_predicted = train_predicted[:,0]

test_actual = test_actual[:,0]
test_predicted = test_predicted[:,0]

print(train_actual)
print(train_predicted)
print(test_actual)
print(test_predicted)

mae = mean_absolute_error(test_actual, test_predicted)
mse = mean_squared_error(test_actual, test_predicted)
rmse = mean_squared_error(test_actual, test_predicted, squared=False)
r2 = r2_score(test_actual, test_predicted)

print('mae', mae)
print('mse', mse)
print('rmse', rmse)
print('r2', r2)

x1 = np.arange(0, len(train_actual))
x2 = np.arange(len(train_actual), len(train_actual)+len(test_actual))

plt.plot(x1,train_actual)
plt.plot(x1,train_predicted)
plt.legend(['train_actual','train_predicted'])

plt.plot(x2,test_actual)
plt.plot(x2,test_predicted)
plt.legend(['test_actual','test_predicted'])

plt.plot(x1,train_actual)
plt.plot(x1,train_predicted)
plt.plot(x2,test_actual)
plt.plot(x2,test_predicted)
plt.legend(['train_actual','train_predicted','test_actual','test_predicted'])
plt.vlines(x=int(len(train_actual)), color='r',linestyles='dashed', ymin = 0, ymax = max(test_actual))
plt.show()
```


APÊNDICE D – PROTOCOLO DE REVISÃO SISTEMÁTICA DE ACORDO COM O PRISMA-P

Título: Evaluation of Machine Learning and Deep Learning Techniques applied in SCI injury		
Identificação	1a	Revisão Sistemática
Atualização	1b	Não se aplica.
Registro	2	Não se aplica.
Autor:		Valério Junior Piana, Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento – Universidade Federal de Santa Catarina.
Contato	3a	E-mail: valeriojuniorpiana@gmail.com. Endereço: R. Deputado Antonio Edu Vieira, 523. Ap 402 - Pantanal, Florianópolis-SC, 88040-001.
Contribuições	3b	Pesquisador.
Alterações	4	Não se aplica.
Apoio:		
Fontes	5a	Apoio com a liberação de Carga Horária de trabalho (CLT) em até de 20% (8h semanais) para realização das atividades do Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento (PPGEGC), como disciplinas e atividades curriculares.
Financiador	5b	Federação das Indústrias do Estado de Santa Catarina (FIESC), Serviço Nacional de Aprendizagem Industrial de Santa Catarina (SENAI/SC) e Centro Universitário SENAI/SC (UniSENAI/SC).
Papel do Financiador	5c	Apoio com a Carga Horária de Trabalho em até 20%.
Justificativa	6	Frente a inversão da pirâmide populacional, cada vez mais pessoas chegarão aos estágios mais avançados de idade, podendo possuir fragilidades que tendem a aumentar a demanda por tratamentos de saúde (PARUCKER; IOCCA ASSUNÇÃO; DE OLIVEIRA, 2022). Não obstante, em contraste das informações que advém da avaliação do estilo de vida das pessoas, envolvendo por exemplo, a baixa prática de exercícios e sedentarismo (PEREIRA;

	<p>FRANCISCHI; LANCHA JR, 2003.), bem como hábitos nutricionais, surgem vetores catalisadores para compor uma nova cartela de elementos que exijam a dependência dos indivíduos aos serviços de saúde, com forte tendência ao aumento da demanda por terapias clínicas especializadas (MACEDO; FREITAS; SCHEICHER, 2014).</p> <p>Pela avaliação do estado da arte atual de soluções biomédicas e de engenharia, pode-se obter diversos tipos de mecanismos para aplicação em pacientes, especialmente quando se trata da reabilitação sensor-motora, promovendo diferentes desafios para incorporação de BMIs para feedback e aplicação nas atividades diárias, compondo obstáculos à serem superados (PISOTTA; PERRUCHOUD; IONTA, 2015). Conforme discutido por Popovic et al. (2000), ao examinar cenários onde BMIs podem ser integradas com a FES na fisioterapia, surge a possibilidade de sua aplicação em sistemas híbridos, especialmente benéficos na recuperação de movimentos complexos. Esta abordagem tem um potencial particular para ajudar aqueles que enfrentam paralisia total dos membros inferiores, visando a restauração de seus movimentos. Embora existam desafios na integração de um sistema de controle hierárquico híbrido para reflexos artificiais e FES, o objetivo de criar sistemas que possam ser incorporados ao cotidiano do paciente sem causar inconvenientes torna-se promissor.</p> <p>A tradução dos sinais cerebrais pelos profissionais, mesmo que amparada por diferentes dispositivos tecnológicos, nem sempre é uma tarefa fácil, tornando-se fundamental a aplicação de técnicas e algoritmos que auxiliem no processamento e síntese de conhecimento. Desta forma, o uso de ANNs tem potencial para apoiar a sincronização e a resposta dos sistemas usados junto aos pacientes, estimando com maior precisão a ação dos atuadores pela leitura dos sensores. Isso pode ser calibrado pela adaptação do próprio algoritmo pela retroalimentação e dinâmicas da leitura de</p>
--	-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

		<p>atividade neuronal, com trajetórias de ângulo de andar/marcha (gait-pattern), posição, força e torque, conduzindo à evidências sólidas da utilização da tecnologia para reabilitação através da neuroplasticidade (JEZERNIK et al., 2003; ROBINSON et al., 2021).</p> <p>Neste campo interdisciplinar da tecnologia, em especial no que tange as diferentes opções de terapias que podem ser escolhidas para o tratamento dos pacientes com SCI, os profissionais deparam-se em embates que podem ser contornados mediante aplicação da tecnologia em favor da maximização cognitiva, bem como de informações reais e fidedignas que possam ser processadas em tempo real pela máquina em prol de um tratamento mais assertivo. Com isso, torna-se notório que os profissionais da área da saúde possam apoiar sua tomada de decisão clínica com a análise de diagnóstico e predição fornecida por sistemas inteligentes, em especial àqueles que possuem sistemas de AI (KAHILE et al., 2021).</p>
Objetivos	7	<p>Avaliar:</p> <ol style="list-style-type: none"> 1. Quais pesquisas foram publicadas abordando os tópicos de AI para tratamento de SCI? 2. Quais são os impactos desses estudos na pesquisa e na prática de campo para o tratamento de pacientes com SCI? 3. Se os estudos levam em conta ou mencionam a ética, a regulamentação ou gestão do conhecimento no tratamento dos dados do paciente?
Critérios de elegibilidade	8	<p>P - População: Profissionais da Área da Saúde e/ou Pacientes com SCI I - Intervenção: Terapias para SCI C - Comparador: A partir do uso de tecnologias inovadoras O - Outcomes: Fator de impacto do tratamento. Seleção de todos os resultados/Estudos sem limite de data/período.</p>
Fontes de informação	9	<p>Science Direct®, ACM Digital Library®, IEEE®, SCIELO BR®, Web of Science®, PUBMED® e COCHRANE®.</p>

Estratégia de busca	10	(“Artificial Intelligence” OR “Machine Learning”) AND (“Spinal Cord Injury” OR “SCI” OR “Mioelectric”) AND (“physiotherapy”) AND (“System”)
Registro dos estudos:		
Gestão de dados	11a	Mendley para gestão dos trabalhos e Rayyan para a seleção em duplo cego.
Processo de seleção	11b	Dois revisores independentes, para promoção das seleções em duplo cego, de acordo com os critérios de revisão com a elegibilidade elencada para inclusão.
Processo de coleta de dados	11c	Dados extraídos a partir de seleção independente, para listagem das aplicações tecnológicas e seus ônus e bônus em cada terapia.
Itens de dados	12	As informações causais serão relacionadas com os métodos computacionais listados, sendo então descritos a partir de seus fluxos de funcionamento e também nomenclaturas técnicas da área, e a identificação da estrutura de aplicação. Cada ferramenta de tecnologia da informação e comunicação aplicada, deverá estar claramente descrita, em todas as suas entradas, ciclos de processamento e saídas, com o objetivo de clarificar os métodos de interação com os pacientes e o uso da tecnologia, visando a transparência do processo e a devida tradução da efetividade de aplicação das mesmas no processo de tratamento para SCI.
Desfecho e priorização	13	Não se aplica.
Risco de viés nos estudos individuais	14	Os métodos que serão utilizados para mitigar o risco de viés, bem como do grau de confiança, serão dados pela observação dos resultados e dos desfechos dos estudos, a partir da avaliação da tecnologia aplicada em relação a sua eficiência prática. Outrossim, será dada também a avaliação dos diagramas em UML (<i>Unified Modelling Language</i>), em observância a coerência de interfaces e suas correlações de arquitetura da informação. Ainda, serão avaliados os métodos estatísticos que foram aplicados em atenção a vislumbrar a aplicação junto destes sistemas na síntese dos dados.

Síntese de dados	15a	Todos os estudos selecionados servirão de instrumentos para avaliação quantitativa, exemplificando a quantidade de vezes aos quais cada tecnologia teve aparição, em relação a cada contexto.
	15b	As tecnologias serão classificadas por sua eficiência computacional e a tradução da eficiência em terapias para SCI. A ordenação será realizada sobre uma análise holística de cada estudo, frente a uma interrelação dos resultados clínicos, fazendo contraste, se possível, aos métodos tradicionais.
	15c	Se for detectada uma percepção de contingência nos resultados, uma meta-regressão poderá ser aplicada em busca da tradução dos efeitos e co-variáveis das pesquisas.
	15d	Todos as tecnologias listadas pelos estudos serão elencadas em sua eficiência, acurácia e performance de desempenho, de forma a trazer o contraste de ônus e bônus dos cenários aplicados.
Meta viés	16	Será avaliado o viés de publicação dos estudos em relação aos patrocinadores e motivações advindas do apoio a realização dos estudos.
Confiança na evidência acumulada	17	As evidências serão avaliadas em seu inteiro teor, em relação ao método de input, processamento e output dos dados de sistemas, bem como da efetividade das terapias e performance do sistema em relação a utilização do usuário.

APÊNDICE E – DIMENSIONAMENTO DOS 13 CANAIS (12 AGRUPAMENTOS MUSCULARES E CRANKSET)

