



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS QUIXADÁ**  
**CURSO DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**BRENA RODRIGUES MACHADO**

**UTILIZAÇÃO DE TÉCNICAS DE AUTOML PARA A DETECÇÃO DO  
CONGELAMENTO DA MARCHA EM PACIENTES COM DOENÇA DE PARKINSON**

**QUIXADÁ**

**2023**

BRENA RODRIGUES MACHADO

UTILIZAÇÃO DE TÉCNICAS DE AUTOML PARA A DETECÇÃO DO CONGELAMENTO  
DA MARCHA EM PACIENTES COM DOENÇA DE PARKINSON

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação do Campus Quixadá da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Ciência da Computação.

Orientador: Prof. Dr. Régis Pires Magalhães.

QUIXADÁ

2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

M129u Machado, Brena Rodrigues.

Utilização de técnicas de AutoML para a detecção do congelamento da marcha em pacientes com doença de Parkinson / Brena Rodrigues Machado. – 2023.  
42 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá, Curso de Ciência da Computação, Quixadá, 2023.

Orientação: Prof. Dr. Régis Pires Magalhães.

1. Aprendizado de máquina. 2. Máquinas de suporte de vetores. 3. Doença de Parkinson. 4. Acelerômetro. I. Título.

CDD 004

---

BRENA RODRIGUES MACHADO

UTILIZAÇÃO DE TÉCNICAS DE AUTOML PARA A DETECÇÃO DO CONGELAMENTO  
DA MARCHA EM PACIENTES COM DOENÇA DE PARKINSON

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Ciência da Computação  
do Campus Quixadá da Universidade Federal  
do Ceará, como requisito parcial à obtenção do  
grau de bacharel em Ciência da Computação.

Aprovada em: \_\_\_\_/\_\_\_\_/\_\_\_\_.

BANCA EXAMINADORA

---

Prof. Dr. Régis Pires Magalhães (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dra. Lívia Almada Cruz  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Criston Pereira de Souza  
Universidade Federal do Ceará (UFC)

A Deus.

À minha família.

À ciência.

## AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por conceder-me força, coragem, oportunidades e fé. Sem Ele, eu não seria ninguém. Ele é meu porto seguro, atendendo às minhas orações em meio às tribulações dos últimos quatro anos. Sua presença é evidente em cada passo desta jornada, iluminando meu raciocínio e facilitando a compreensão dos conhecimentos adquiridos na universidade.

Expresso minha gratidão à minha mãe, Marcelina, ao meu pai, José Almir, e ao meu irmão, Paulo Henrique, que são minha base e meus maiores amigos. Eles estiveram sempre presentes, apoiando-me em todas as escolhas feitas ao longo dessa jornada. Agradeço também ao meu namorado, Maxwell, pelo incentivo, companhia e carinho durante esse desafiador último ano de curso. Amo vocês do fundo do meu coração.

Ao meu orientador, o Prof. Dr. Régis Pires Magalhães, profissional pelo qual tenho enorme admiração, por sua competência, notável atuação na ciência e por ser uma fonte valiosa de conhecimento. Expresso minha gratidão pela excelente orientação durante o trabalho, pela compreensão e pelo apoio do início ao fim.

Manifesto minha gratidão ao *Insight Data Science Lab* pela oportunidade de participar como bolsista nos projetos Plataforma Big Data para Acelerar a Transformação Digital do Estado do Ceará e Samsung AI4Wellness. A contribuição da equipe foi fundamental para minha formação profissional, proporcionando a chance de estudar e aplicar meus conhecimentos. Agradeço também à Samsung Eletrônica da Amazônia Ltda, porque parte dos resultados apresentados neste trabalho foi realizada no âmbito do projeto "CENTRO DE EXCELÊNCIA EM INTELIGÊNCIA ARTIFICIAL - AI4WELLNESS", financiado pela mesma. Agradeço a contribuição da equipe de pesquisa que deu feedback sobre este estudo e apoiou este trabalho.

Agradeço aos professores Dra. Lívia Almada Cruz e Dr. Criston Pereira de Souza por aceitarem participar da banca examinadora deste trabalho.

Por fim, agradeço aos meus amigos da universidade pela parceria ao longo do curso. Sem vocês, a jornada teria sido muito mais desafiadora.

"Nada a fazer senão esquecer o medo." (Milton Nascimento)

## RESUMO

Este estudo teve como objetivo identificar e classificar episódios de congelamento de marcha (FOG) em diferentes fases da caminhada utilizando técnicas de aprendizado de máquina automatizado (AutoML). Foram utilizados dados de acelerômetro de pacientes com doença de Parkinson (DP) e exploradas diferentes técnicas de classificação utilizando o AutoGluon, uma biblioteca de AutoML. Foram treinados 4 modelos com os mesmos dados, diferindo apenas no tamanho de janelas temporais para cada treinamento, sendo elas de tamanho 1, 2, 3 e 6. Os resultados mostraram que a abordagem escolhida não ofereceu bom desempenho na classificação de eventos FOG, mas a métrica *Mean Average Precision* (mAP) do melhor modelo superou o resultado do 5º lugar na competição Kaggle. Trabalhos futuros incluem avaliar a contribuição do uso de janelas de tempo maiores e engenharia de atributos avançada. O estudo contribui para avanços na detecção e tratamento do congelamento da marcha em pacientes com DP.

**Palavras-chave:** aprendizado de máquina; aprendizado supervisionado; aprendizado de máquina automatizado; doença de parkinson; acelerômetro.

## ABSTRACT

This study aimed to identify and classify episodes of FOG in different phases of walking using AutoML (Automated Machine Learning) techniques. Accelerometer data from patients with DP were utilized, and various classification techniques were explored using *AutoGluon*, an AutoML library. Four models were trained with the same data, differing only in the size of temporal windows for each training, which were of sizes 1, 2, 3, and 6. The results indicated that the chosen approach did not exhibit good performance in classifying FOG events. However, the Mean Average Precision (mAP) metric of the best model surpassed the result of the 5th place in the Kaggle competition. Future work includes evaluating the contribution of larger time windows and advanced feature engineering. The study contributes to advancements in the detection and treatment of Freezing of Gait in patients with DP.

**Keywords:** machine learning; supervised learning; automated machine learning; parkinson's disease; accelerometer.

## LISTA DE FIGURAS

Figura 1 – Sintomas clínicos associados à doença de Parkinson progressão . . . . .	17
Figura 2 – Técnicas de classificação de aprendizado supervisionado . . . . .	19
Figura 3 – Exemplo de classificação com algoritmo DecisionTree utilizando o conjunto de dados íris . . . . .	20
Figura 4 – Matriz de confusão . . . . .	21
Figura 5 – Fluxo da realização dos procedimentos metodológicos . . . . .	28
Figura 6 – Eixos anatômicos perpendiculares ao centro de gravidade . . . . .	32
Figura 7 – Gráfico 3D dos eixos do acelerômetro - DeFOG . . . . .	33
Figura 8 – Gráfico 3D dos eixos do acelerômetro - tDCSFOG . . . . .	33
Figura 9 – Gráfico temporal dos eixos do acelerômetro - DeFOG . . . . .	34
Figura 10 – Gráfico temporal dos eixos do acelerômetro - tDCSFOG . . . . .	34

## LISTA DE TABELAS

Tabela 1 – Classificação dos modelos no treinamento de janela igual a 1 . . . . .	36
Tabela 2 – Resultados dos melhores modelos treinados para cada tamanho de janela . .	37
Tabela 3 – Resultados da competição <i>Parkinson's Freezing of Gait Prediction</i> . . . . .	37

## LISTA DE QUADROS

Quadro 1 – Quadro comparativo de trabalhos relacionados . . . . .	27
Quadro 2 – Atributos do conjunto de dados <i>Freezing of Gait Prediction</i> . . . . .	32

## LISTA DE ABREVIATURAS E SIGLAS

AP	<i>Average Precision</i>
AutoML	aprendizado de máquina automatizado
DP	doença de Parkinson
EAR	Estimulação Auditiva Rítmica
FN	falso negativo
FOG	congelamento de marcha
FP	falso positivo
mAP	<i>Mean Average Precision</i>
VN	verdadeiro negativo
VP	verdadeiro positivo

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Objetivos</b>	<b>15</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>16</b>
<b>2.1</b>	<b>Doença de Parkinson</b>	<b>16</b>
<b>2.1.1</b>	<i>Congelamento de marcha FOG</i>	<b>17</b>
<b>2.2</b>	<b>Dispositivos vestíveis</b>	<b>18</b>
<b>2.3</b>	<b>Aprendizado de máquina</b>	<b>18</b>
<b>2.3.1</b>	<i>Aprendizado supervisionado</i>	<b>19</b>
<b>2.3.1.1</b>	<i>Classificação</i>	<b>19</b>
<b>2.3.2</b>	<i>AutoML</i>	<b>20</b>
<b>2.4</b>	<b>Métricas de avaliação</b>	<b>21</b>
<b>2.4.1</b>	<i>Sensibilidade</i>	<b>22</b>
<b>2.4.2</b>	<i>Especificidade</i>	<b>22</b>
<b>2.4.3</b>	<i>Precisão</i>	<b>22</b>
<b>2.4.4</b>	<i>F1-Score</i>	<b>22</b>
<b>2.4.5</b>	<i>Average Precision (Average Precision (AP))</i>	<b>22</b>
<b>2.4.6</b>	<i>Mean Average Precision (mAP)</i>	<b>23</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>24</b>
<b>3.1</b>	<b>Engenharia de conjunto de recursos para detecção de congelamento da marcha na doença de Parkinson usando Redes Neurais Recorrentes Profundas (MASIALA <i>et al.</i>, 2019)</b>	<b>24</b>
<b>3.2</b>	<b>Melhoria do desempenho na detecção do congelamento da marcha na doença de Parkinson usando Redes <i>Transformers</i> e um único acelerômetro triaxial usado na cintura (SIGCHA <i>et al.</i>, 2022)</b>	<b>24</b>
<b>3.3</b>	<b>Rumo a um sistema vestível para prever o congelamento da marcha em pessoas afetadas pela doença de Parkinson (DEMROZI <i>et al.</i>, 2020)</b>	<b>25</b>
<b>3.4</b>	<b>Análise comparativa</b>	<b>26</b>
<b>4</b>	<b>PROCEDIMENTOS METODOLÓGICOS</b>	<b>28</b>
<b>4.1</b>	<b>Seleção do conjunto de dados</b>	<b>28</b>
<b>4.2</b>	<b>Análise exploratória dos dados</b>	<b>28</b>

4.3	<b>Pré-processamento dos dados</b> . . . . .	29
4.4	<b>Seleção da ferramenta de AutoML</b> . . . . .	29
4.5	<b>Execução dos experimentos</b> . . . . .	29
4.5.1	<i>Seleção do preditor do AutoGluon</i> . . . . .	29
4.5.2	<i>Treinamento dos preditores</i> . . . . .	30
4.5.3	<i>Teste de classificação</i> . . . . .	30
4.5.4	<i>Coleta dos resultados</i> . . . . .	30
4.6	<b>Análise dos resultados</b> . . . . .	30
5	<b>EXPERIMENTOS E RESULTADOS</b> . . . . .	31
5.1	<b>Análise do conjunto de dados</b> . . . . .	31
5.2	<b>Pré-processamento dos dados</b> . . . . .	32
5.3	<b>Engenharia de atributos</b> . . . . .	34
5.4	<b>Treinamento dos modelos</b> . . . . .	34
5.5	<b>Avaliação dos modelos</b> . . . . .	35
5.5.1	<i>Classificação dos modelos</i> . . . . .	35
5.5.2	<i>Avaliação dos resultados</i> . . . . .	35
5.5.3	<i>Considerações finais</i> . . . . .	36
6	<b>CONCLUSÕES E TRABALHOS FUTUROS</b> . . . . .	38
	<b>REFERÊNCIAS</b> . . . . .	39

## 1 INTRODUÇÃO

A doença de Parkinson (DP) é a segunda doença neurológica degenerativa mais comum no mundo. Os sintomas característicos desta doença é rigidez, bradicinesia, instabilidade postural e tremor (GÁLVEZ *et al.*, 2018). De acordo com Demrozi *et al.* (2020), com a evolução da doença, pode ocorrer um sintoma ainda mais preocupante que é o congelamento de marcha, do inglês, *freezing of gait* (FOG), que impede a caminhada principalmente ao iniciar a marcha, ao se virar e quando se executa duas tarefas ao mesmo tempo, essa manifestação aumenta o risco de quedas e diminui a qualidade de vida.

Com isso, é importante que os médicos consigam diagnosticar e acompanhar a evolução da doença e do tratamento a partir dos eventos de FOG durante o cotidiano do paciente. Conforme Park *et al.* (2021), atualmente utiliza-se a avaliação de vídeos feitas por profissionais especializados em classificação de movimentos, esta técnica é considerada padrão ouro na área por conseguir detectar os eventos de FOG com precisão. Apesar de ser uma abordagem com bons resultados, não soluciona o problema do monitoramento do FOG no cotidiano do paciente, por ser aplicada apenas em laboratórios assistidamente usando aparelhos de alto custo e induzindo os pacientes a situações de gatilho para o FOG, impedindo que o evento ocorra como ocorreria na realidade.

Portanto, é essencial explorar a alternativa de utilizar dispositivos vestíveis que possuam acelerômetro para prever o FOG. Essa abordagem tem o potencial de fornecer compreensão valiosa sobre os padrões de movimento relacionados a esse problema de saúde, permitindo um conhecimento mais aprofundado dos gatilhos e da evolução da doença. Além disso, segundo Mughal *et al.* (2022), o método proposto é mais acessível em termos de custo se comparado ao método padrão consolidado, além de permitir o monitoramento contínuo do paciente. Isso viabiliza o registro dos eventos de FOG durante as atividades diárias.

Para processar o grande conjunto de dados resultante da coleta de sensores vestíveis, faz-se necessário a utilização de aprendizado de máquina para classificação e análise dos padrões dos dados de forma rápida e eficiente. Entretanto, para construir modelos de aprendizado de máquina, o usuário deve ter um amplo conhecimento na área de ciência de dados, além disso, até mesmo para cientistas de dados experientes, é necessário utilizar abordagens que agilizem o processo de busca de modelos que se encaixem melhor em cada tipo de problema. Para isso, é importante analisar a viabilidade do uso de aprendizado de máquina automatizado (AutoML) com o intuito de otimizar a tarefa de construção de modelos de aprendizado de máquina. Sendo

assim, este trabalho visa utilizar técnicas de AutoML, para predição de FOG utilizando dados coletados durante uma semana de vários pacientes com Parkinson através de um acelerômetro vestível. Será discutido se essa abordagem é viável para solucionar o problema do monitoramento contínuo do sintoma de FOG fazendo uma comparação entre os resultados obtidos e os resultados dos trabalhos relacionados a esta área.

## 1.1 Objetivos

Dessa forma, o objetivo geral deste trabalho é identificar e classificar os episódios de FOG de indivíduos em geral durante diferentes fases da caminhada, abrangendo o início da caminhada, o período durante a caminhada e os momentos de mudança de direção, utilizando a técnica de AutoML. Como objetivos específicos estão:

- a) Escolher um conjunto de dados com quantidade significativa de amostras de diferentes indivíduos acometidos pela doença de Parkinson.
- b) Treinar modelos de aprendizado utilizando AutoML para predição dos eventos de início de caminhada, caminhada e mudança de direção.
- c) Avaliar o resultado das métricas de avaliação de modelos de classificação.

A estrutura do trabalho está organizada da seguinte maneira: o Capítulo 2 apresenta a fundamentação teórica que abrange os principais conceitos estudados nesta pesquisa. São discutidos a doença de Parkinson, incluindo um de seus sintomas, o congelamento de marcha, além de abordar os dispositivos vestíveis utilizados para monitoramento e coleta de dados nesse contexto. Também é apresentada a técnica proposta para a detecção do congelamento de marcha, baseada no uso de aprendizado de máquina automatizado aplicado a dados tabulares, juntamente com as formas de avaliação do desempenho dessa abordagem; no Capítulo 3, são apresentados três trabalhos relacionados que tratam da predição do congelamento de marcha; no Capítulo 4, é detalhada a metodologia proposta para a realização deste trabalho; por fim, no Capítulo 5, são apresentados os resultados preliminares obtidos até o momento.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo descreve os principais fundamentos necessários para desenvolver o presente trabalho, como: a doença de Parkinson, exposta na Seção 2.1, elencando um dos sintomas debilitantes desta doença conhecido como congelamento de marcha; os dispositivos vestíveis definidos na Seção 2.2, onde se destaca sua importância no monitoramento contínuo de movimento a partir de sensores; o aprendizado de máquina, apresentado na Seção 2.3 abordando o aprendizado supervisionado, bem como a técnica de classificação; e as métricas de avaliação expostas na Seção 2.4, estas utilizadas para avaliar o desempenho de modelos de aprendizado de máquina.

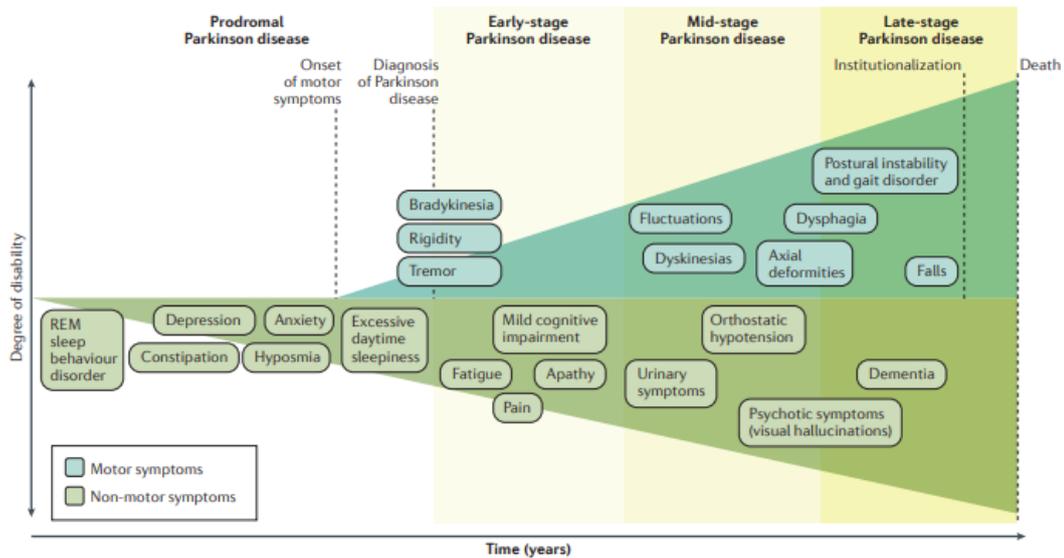
### 2.1 Doença de Parkinson

Segundo Poewe *et al.* (2017), a doença de Parkinson (DP) é um distúrbio neurodegenerativo que aflije cerca de 3% da população idosa. Em concordância com Balestrino e Schapira (2020), a DP afeta o cérebro mais precisamente pela perda de neurônios dopaminérgicos na substância negra pars compacta e pela presença de inclusões de alfa-sinucleína mal dobradas chamadas corpos de Lewy. Como consequência disso, são apresentados alguns sintomas que afetam tanto o sistema motor: tremor, bradicinesia, rigidez, quanto o cognitivo: depressão, distúrbios do sono e até o mau funcionamento do sistema autônomo responsável pelo movimento involuntário dos órgãos.

Balestrino e Schapira (2020) informa que a causa da DP não é conhecida, mas há alguns fatores que a maioria das pessoas com o mal de Parkinson têm em comum, como pertencer ao sexo masculino, ter idade avançada ou até problemas genéticos.

De acordo com Poewe *et al.* (2017), a DP é uma doença incurável, podendo apenas remediar para retardar a evolução do distúrbio e diminuir os sintomas. Além da medicação, existem terapias experimentais que buscam estimular a atividade cerebral visando restaurar suas funções. Por ser uma doença degenerativa, como mostra a Figura 1, com o passar do tempo a doença evolui intensificando os sintomas e surgindo novos sintomas ainda mais incapacitantes, como o congelamento de marcha. A seção a seguir descreve este sintoma.

Figura 1 – Sintomas clínicos associados à doença de Parkinson progressão



Fonte: Poewe *et al.* (2017)

### 2.1.1 Congelamento de marcha FOG

O congelamento de marcha FOG, do inglês, *freezing of gait*, é um sintoma da DP, caracterizado pela perda temporária de movimento ao caminhar, que ocorre em cerca de 47% dos pacientes com DP (JANKOVIC, 2008). Como mostra a Figura 1, este sintoma aparece em um estágio avançado da DP diminuindo drasticamente a qualidade de vida do paciente por ser debilitante e promover o risco de quedas.

Segundo Jankovic (2008), existem cinco atividades conhecidas por provocar o FOG, como ao iniciar a caminhada, virar-se, andar por uma passagem estreita, ao chegar no destino ou ao andar em espaço aberto.

Diagnosticar o FOG em um paciente não é uma tarefa fácil, por ser necessária a análise do paciente por profissionais especializados em classificação de movimento, além de necessitar a provocação deste sintoma, reproduzindo atividades do cotidiano. Por isso, esta técnica não é totalmente eficaz, porque o resultado dependerá da experiência que o profissional possui. Além disso, a provocação do FOG não reproduz o congelamento fielmente como aconteceria no cotidiano do paciente. De acordo com Demrozi *et al.* (2020), dispositivos vestíveis com sensores de movimento como acelerômetro e giroscópio podem auxiliar no diagnóstico e monitoramento contínuo do tratamento da DP.

## 2.2 Dispositivos vestíveis

Dado que o monitoramento contínuo do tratamento é de grande valor para entender a evolução da doença de cada paciente, o uso de dispositivos vestíveis torna-se crucial nesta tarefa. Segundo Mughal *et al.* (2022), dispositivos vestíveis são apropriados para monitoramento de condições de saúde, por terem baixo custo, serem precisos e por poderem acompanhar o paciente durante as mais diversas tarefas diariamente. Mughal *et al.* (2022) elenca alguns tipos de dispositivos vestíveis com sensores integrados como acelerômetro e giroscópio que permitem a coleta dos dados de movimentação dos pacientes, além possuir acesso à internet para a comunicação entre dispositivos e permitir a implantação de modelos de aprendizado de máquina para detectar distúrbios na movimentação.

O acelerômetro é um sensor que detecta a mudança de aceleração, podendo coletar dados em três dimensões (TROIANO *et al.*, 2014). Esse sensor é adequado para usar em monitoramento de movimentação de indivíduos por ser acessível, consumir pouca energia e coletar em alta frequência de amostragem. Por serem compactos, podem ser fixados em diversas partes do corpo como pernas, pés, cintura, costas, braços, entre outros. Quando combinado com outros sensores pode-se revelar informações completas sobre a trajetória da movimentação do usuário, possibilitando a detecção de distúrbios na movimentação como o FOG em pacientes com Parkinson (BORZÌ *et al.*, 2021). Segundo Borzì *et al.* (2021), a utilização de aprendizado de máquina e o acelerômetro mostra-se eficaz para predição de eventos de FOG permitindo o monitoramento em tempo real.

## 2.3 Aprendizado de máquina

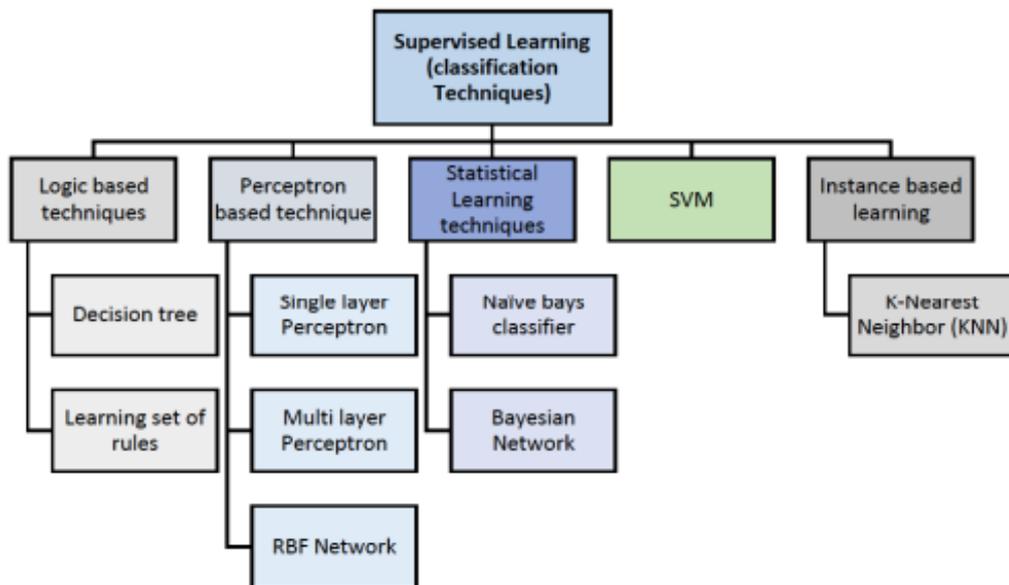
O aprendizado de máquina é uma subárea da inteligência artificial e se dedica ao aprendizado a partir de dados de diversos tipos. Essa tecnologia está presente nos mais diversos ambientes da vida humana, como na saúde, entretenimento e mercado financeiro. Com o aprendizado, a máquina pode tomar decisões, reconhecer imagens e textos, recomendar produtos, entre outras aplicações, sem ter sido necessariamente programada para isso. Isso é possível através do processamento de dados, algoritmos e modelos estatísticos (MAHESH, 2020). No aprendizado de máquina existem diferentes tipos de técnicas de aprendizado, como o aprendizado supervisionado, não supervisionado, por reforço, redes neurais, entre outras (JANIESCH *et al.*, 2021). Neste trabalho será abordado somente o aprendizado supervisionado descrito na seção

abaixo.

### 2.3.1 Aprendizado supervisionado

Segundo Janiesch *et al.* (2021), o aprendizado supervisionado se caracteriza por possuir um conjunto de dados de treino rotulado, ou seja, para cada amostra, há um rótulo respectivo. Com isso, o modelo de aprendizado de máquina consegue aprender através dos padrões encontrados nos dados para cada rótulo e o resultado do modelo será o rótulo associado a cada amostra do conjunto de treino. Ainda no aprendizado supervisionado existem duas técnicas para realizar a predição, sendo classificação e regressão.

Figura 2 – Técnicas de classificação de aprendizado supervisionado



Fonte: Soofi e Awan (2017)

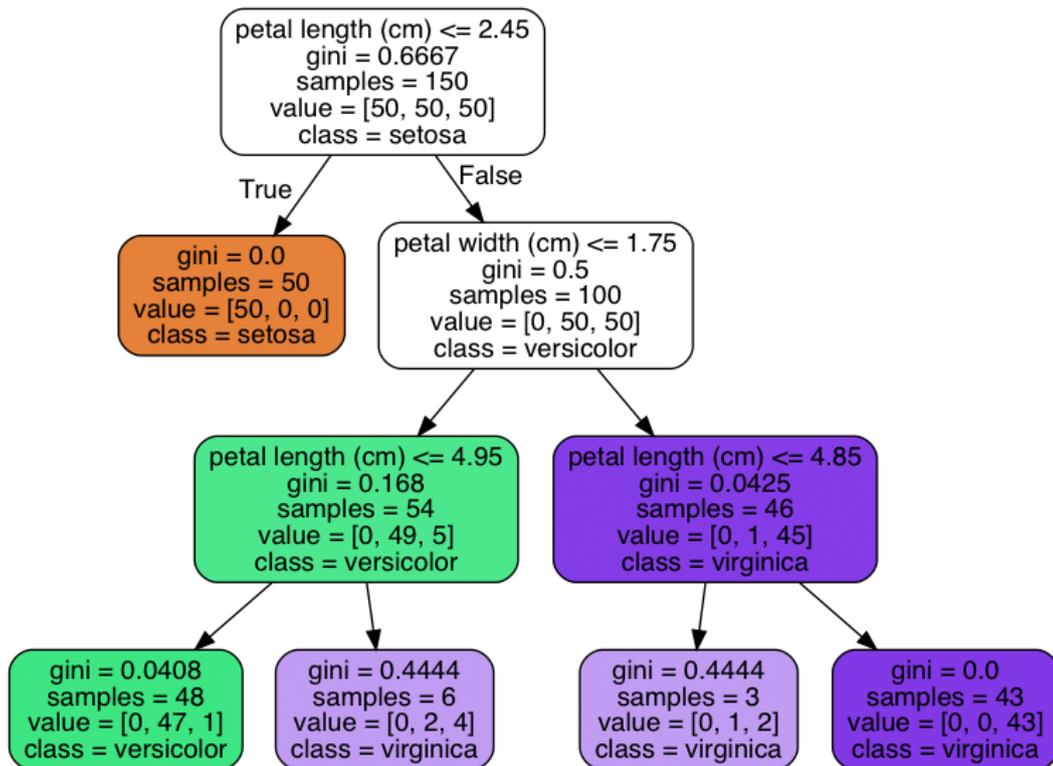
#### 2.3.1.1 Classificação

A classificação é uma tarefa do aprendizado supervisionado na qual se dedica a identificar padrões em classes do conjunto de dados para prever a associação de um grupo a uma instância dos dados (SOOFI; AWAN, 2017). A Figura 2 mostra algumas técnicas de classificação mais conhecidas no aprendizado supervisionado.

Um exemplo de aplicação da tarefa de classificação é o problema de classificação de flores íris, neste caso o rótulo assumirá os valores das espécies de flores, que representarão as classes pertencentes de cada amostra. Já o restante do conjunto de dados possuirá os atributos

relacionados a largura e comprimento das pétalas e sépalas, entre outras características. A Figura 3 mostra como ocorre o processo de classificação para o algoritmo *DecisionTree*, o qual tenta dividir o conjunto de dados da melhor forma tomando como base um atributo mais representativo e dividindo em forma de árvore, nota-se que nas folhas da árvore gerada estão as instâncias em suas respectivas classes.

Figura 3 – Exemplo de classificação com algoritmo *DecisionTree* utilizando o conjunto de dados íris



Fonte: Heemann *et al.* (2017)

### 2.3.2 AutoML

*AutoML* significa aprendizado de máquina automatizado, ou seja, é uma técnica de aprendizado de máquina onde vários processos serão realizados automaticamente utilizando pouco código. Dessa forma, pessoas que têm pouco conhecimento na área podem construir modelos rapidamente. De acordo com He *et al.* (2021), ferramentas de AutoML podem realizar todas as etapas do *pipeline* de aprendizado de máquina do início ao fim, como pré-processamento dos dados, treinamento, ajuste de hiperparâmetros, otimização e avaliação dos modelos sem precisar de configurações adicionais. Além disso, essa técnica inclui vários tipos de modelos, possuindo modelos básicos e até redes neurais.

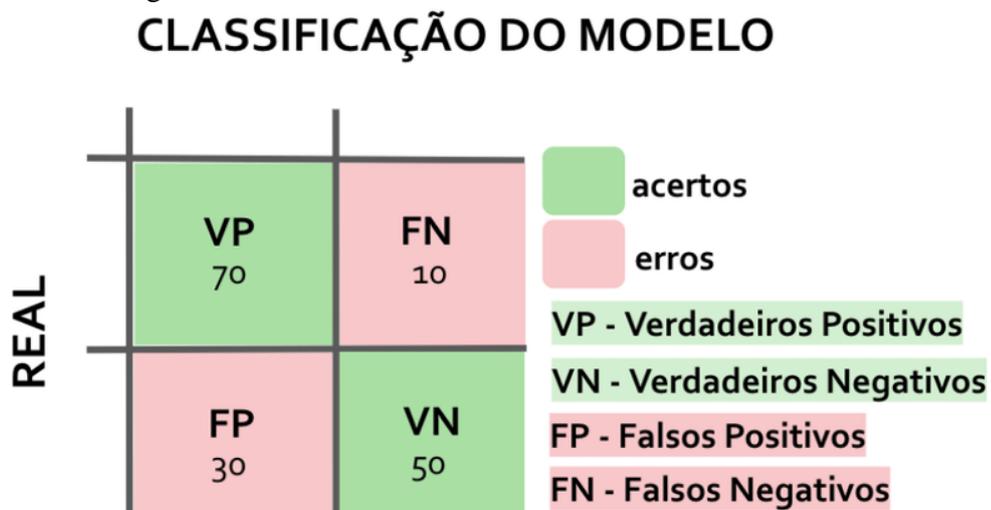
O AutoGluon é uma biblioteca do python desenvolvida para AutoML. Esta ferramenta se destaca dentre outras com o mesmo propósito, por ser fácil de utilizar, permitir o treinamento de diversos modelos de aprendizado de máquina com alta acurácia de forma rápida e otimizada (ERICKSON *et al.*, 2020). Como mencionado na Seção 2.3.2, por se tratar de AutoML, esta biblioteca possibilita que todo o pipeline de aprendizado de máquina seja executado, sem que o usuário precise conhecer a fundo os problemas dos dados, como desbalanceamento, e técnicas avançadas de aprendizado de máquina.

De acordo com Erickson *et al.* (2020), além de modelos tradicionais como KNN e *Random Forest*, essa ferramenta conta com modelos mais complexos como redes neurais e abordagens de agregação de modelos e combinações ponderadas.

## 2.4 Métricas de avaliação

Para avaliar a predição de um modelo de classificação é necessária a utilização de algumas métricas que relacionam as classes que o modelo conseguiu acertar ou errar. Algumas métricas bem utilizadas na literatura são: sensibilidade, especificidade, F1-score e precisão. Para entender o cálculo realizado em cada métrica, como mostra o Quadro ??, primeiro deve ser discutido sobre matriz de confusão, a Figura 4 mostra a relação do verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN). As métricas mencionadas estão definidas a seguir.

Figura 4 – Matriz de confusão



Fonte: Ruback *et al.* (2021)

### 2.4.1 Sensibilidade

A sensibilidade, também conhecida como *recall* indica quantas previsões corretas o modelo conseguiu acertar para amostras de uma classe (MONTEVECHI *et al.*, 2022).

$$R_i = \frac{VP_i}{VP_i + FN_i} \quad (2.1)$$

### 2.4.2 Especificidade

A métrica de especificidade indica a capacidade de um modelo de identificar corretamente as instâncias negativas.

$$S_i = \frac{VN_i}{FP_i + VN_i} \quad (2.2)$$

### 2.4.3 Precisão

Segundo Meerholz *et al.* (2023), a precisão indica a porcentagem de acerto das previsões positivas efetuadas pelo modelo.

$$P_i = \frac{VP_i}{VP_i + FP_i} \quad (2.3)$$

### 2.4.4 F1-Score

De acordo com Montevechi *et al.* (2022), a métrica do F1-score combina as métricas de precisão e sensibilidade, para identificar se há problema na predição relacionado a desbalanceamento de dados.

$$S_i = 2 \times \frac{P_i \times S_i}{P_i + S_i} \quad (2.4)$$

### 2.4.5 Average Precision (AP)

Segundo Pedregosa *et al.* (2011) a AP condensa uma curva de precisão e *recall* por meio da média ponderada das precisões obtidas em cada ponto de corte, utilizando o aumento

na revocação em relação ao ponto de corte anterior como fator de ponderação. A equação 2.5 descreve o cálculo desta métrica.

$$AP = \sum_n (R_n - R_{n-1}) P_n \quad (2.5)$$

#### **2.4.6 Mean Average Precision (mAP)**

Para Li *et al.* (2014) a mAP é uma métrica chave de desempenho em muitas tarefas de classificação multiclasse. Além disso, de acordo com Rutigliano *et al.* (2021), a mAP representa a “medida global de acurácia de classificação e localização”. Esta métrica é calculada utilizando a média dos valores de AP.

### 3 TRABALHOS RELACIONADOS

Neste capítulo são apresentados os trabalhos relacionados que descrevem abordagens de aprendizado de máquina para detecção do congelamento de marcha.

#### 3.1 Engenharia de conjunto de recursos para detecção de congelamento da marcha na doença de Parkinson usando Redes Neurais Recorrentes Profundas (MASIALA *et al.*, 2019)

Neste trabalho, Masiala *et al.* (2019) propõe a utilização de redes neurais de recorrência (RNN) profunda com LSTM para detecção de congelamento de marcha em pacientes com a doença de Parkinson.

O conjunto de dados utilizado foi o Daphnet (ROGGEN DANIEL; HAUSDORFF, 2013), o qual possui valores de sensores de acelerômetro 3D medidos em três regiões do corpo do paciente, sendo eles, no tornozelo, tronco e coxa. Os resultados mostraram que o sensor localizado no tronco é mais relevante para a classificação do congelamento de marcha. No geral, o método proposto conseguiu superar o estado da arte da época considerando os valores das métricas AUC, especificidade e sensibilidade.

Semelhantemente, neste trabalho será utilizado um conjunto de dados de sensor de acelerômetro 3D situado na região baixa das costas para treinar o modelo de aprendizado de máquina. Entretanto, além de classificar o evento de congelamento de marcha, o presente trabalho se propõe a classificar este evento em três fases conhecidas como indutoras da paralisação: início da caminhada, durante a caminhada e mudança de direção, e mais o evento não-FOG.

#### 3.2 Melhoria do desempenho na detecção do congelamento da marcha na doença de Parkinson usando Redes *Transformers* e um único acelerômetro triaxial usado na cintura (SIGCHA *et al.*, 2022)

A pesquisa de Sigcha *et al.* (2022) propõe a melhoria do desempenho na detecção do FOG em pacientes com doença de Parkinson usando redes *transformers* para classificação e CNN para extração de atributos. Neste trabalho, Sigcha *et al.* (2022) discute o potencial do uso de abordagens de aprendizado profundo (DL), especificamente redes *transformers*, que podem processar dados sequenciais com eficiência, para detecção de FOG. O objetivo é desenvolver sistemas precisos de detecção de FOG que possam ser usados para monitoramento de longo

prazo e desenvolvimento de tratamentos eficazes para a DP.

O conjunto de dados utilizado foi o REMPARK-FOG coletado no estudo de Rodríguez-Martín *et al.* (2017), que possui dados do uso diário de um único acelerômetro triaxial situado no lado esquerdo da cintura de 21 pacientes. O autor discute sobre a relevância da localização do sensor na região da cintura, pois além de facilitar o seu posicionamento em cintos ou outros adereços, a posição está próxima do centro de gravidade do corpo humano que está muito relacionado ao FOG e equilíbrio do paciente. Para a avaliação do método proposto, Sigcha *et al.* (2022) utilizou as métricas de sensibilidade, especificidade, AUC, EER e precisão.

Diferentemente do trabalho mencionado, o presente trabalho utilizará o conjunto de dados disponibilizado pela competição *Parkinson's Freezing of Gait Prediction* (FOUNDATION, 2023) <sup>1</sup> realizada pela plataforma Kaggle. Neste conjunto de dados, são reunidos dados de um único acelerômetro 3D situado na região baixa das costas de vários pacientes que possuem ou não o sintoma de FOG, além disso, existem três categorias de dados, sendo elas, uso diário durante uma semana, uso durante reprodução do protocolo de provocação de FOG em um ambiente supervisionado e uso durante reprodução do protocolo de provocação no ambiente domiciliar sem supervisão. Dessa forma, o presente trabalho pode classificar o FOG em diversos tipos de atividades por possuir um conjunto de dados mais abrangente.

### **3.3 Rumo a um sistema vestível para prever o congelamento da marcha em pessoas afetadas pela doença de Parkinson (DEMROZI *et al.*, 2020)**

Neste trabalho, Demrozi *et al.* (2020) propõe um sistema vestível baseado em aprendizado de máquina para prever e prevenir o congelamento da marcha (FOG) em pacientes com doença de Parkinson. O sistema usa três sensores acelerômetros triaxiais usados nas costas, quadril e tornozelo para monitorar a marcha. As características da marcha são extraídas por janela de dados e redução de dimensionalidade não linear, e um algoritmo k-NN é usado para classificar a marcha em três classes: pré-FOG, não-FOG e FOG.

O conjunto de dados utilizado foi o Daphnet (ROGGEN DANIEL; HAUSDORFF, 2013), o mesmo mencionado na Seção 3.1. E as métricas utilizadas para avaliação do método proposto foram: sensibilidade, especificidade e F1-Score.

Diferentemente dos trabalhos citados acima, o algoritmo proposto por Demrozi *et al.* (2020) consegue prever o momento pré-FOG. Essa predição é muito relevante no tratamento

<sup>1</sup> <https://www.kaggle.com/competitions/tlvmc-parkinsons-freezing-gait-prediction/data>

desse sintoma, pois a partir desta detecção, a duração e a gravidade do FOG podem ser reduzidos com o acionamento de um dispositivo de Estimulação Auditiva Rítmica (EAR)

O presente trabalho poderá utilizar a técnica de detecção pré-FOG para melhorar o reconhecimento de padrões e assim, aumentar a eficácia do algoritmo construído.

### **3.4 Análise comparativa**

O Quadro 1 a seguir apresenta a comparação de informações importantes de cada trabalho. Apesar dos trabalhos proporem soluções para um mesmo problema, há variedade na abordagem adotada pelos autores citados, mostrando maior predominância da aplicação de redes neurais para solucionar o problema da detecção de FOG. Assim como os trabalhos relacionados, planeja-se utilizar as métricas sensibilidade, F1-Score, precisão e mAP para avaliar o desempenho do modelo de aprendizado supervisionado a ser definido neste trabalho.

Dentre os trabalhos selecionados, todos utilizam bases de dados com quantidade pequena de amostras. O conjunto de dados utilizado por Masiala *et al.* (2019) e por Demrozi *et al.* (2020) possui apenas 17 registros de 10 pacientes, dentre esses 2 não apresentam o sintoma de FOG, enquanto o conjunto de dados utilizado por Sigcha *et al.* (2022) possui registros de 21 pacientes com o sintoma de FOG. Já o presente trabalho utilizará o conjunto de dados disponibilizado pela competição *Freezing of gait prediction* realizada pelo Kaggle que possui uma maior quantidade de amostras com registros diários durante uma semana de 65 pacientes.

Quadro 1 – Quadro comparativo de trabalhos relacionados

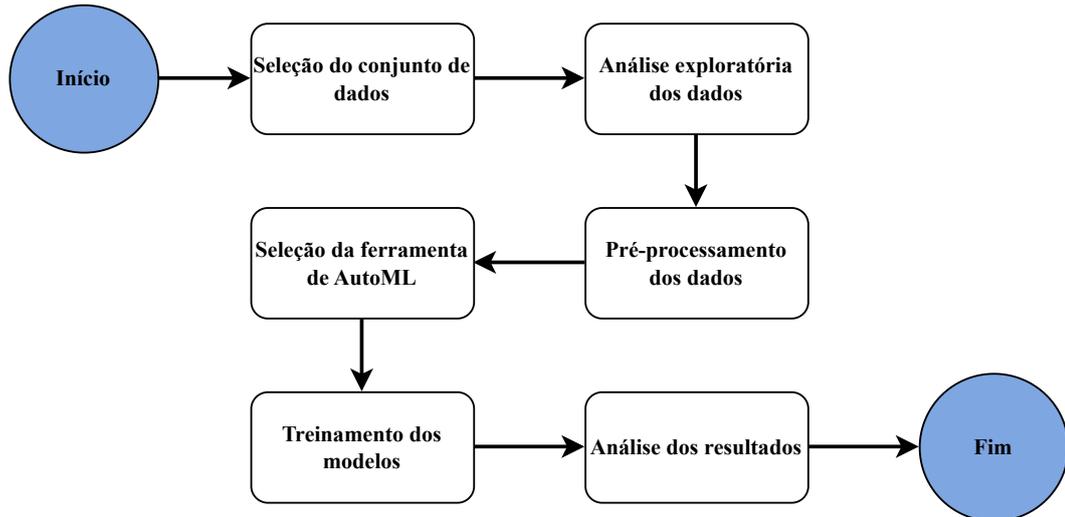
<b>Trabalho</b>	<b>Algoritmos</b>	<b>Conjunto de dados</b>	<b>Problema</b>	<b>Métricas</b>
Masiála <i>et al.</i> (2019)	RNN profunda com LSTM	Daphnet	Predição de FOG	AUC, especificidade e sensibilidade
Sigcha <i>et al.</i> (2022)	Redes transformers CNN	REMPARK-FOG	Predição de FOG	Sensibilidade, especificidade, AUC, EER e precisão
Demrozi <i>et al.</i> (2020)	KNN	Daphnet	Predição das três fases: pré-FOG, não-FOG e FOG	Sensibilidade, especificidade e F1-Score
Este trabalho	Autoglun Tabular	<i>Freezing of gait prediction</i>	Predição de FOG em quatro eventos: não-FOG, início da caminhada, durante a caminhada e ao virar-se	Sensibilidade, F1-Score, precisão e mean average precision

Fonte: Elaborado pela autora

## 4 PROCEDIMENTOS METODOLÓGICOS

A metodologia seguida neste trabalho está dividida em cinco etapas, são elas, seleção do conjunto de dados, análise exploratória dos dados, seleção da ferramenta de AutoML, execução dos experimentos e análise dos resultados. Cada etapa está descrita abaixo.

Figura 5 – Fluxo da realização dos procedimentos metodológicos



Fonte: Elaborado pela autora

### 4.1 Seleção do conjunto de dados

Seleciona-se o conjunto de dados disponibilizado pela competição *Parkinson's Freezing of Gait Prediction* que possui dados de sensores vestíveis situados na região lombar. Os conjunto de dados possui três divisões, sendo cada uma para um tipo de coleta de dados: 1) DeFOG: dados do uso do sensor assistidamente em clínica e execução de protocolos de indução de FOG; 2) tDCSFOG: dados do uso do sensor assistidamente no ambiente domiciliar do paciente e com execução de protocolos de indução de FOG; 3) *Daily Living*: dados do uso do sensor de forma não assistida durante o dia inteiro e por uma semana. Analisando os atributos de cada conjunto de dados, foram escolhidos o DeFOG e tDCSFOG por possuírem rótulos dos eventos estudados.

### 4.2 Análise exploratória dos dados

Após a seleção do conjunto de dados, os dados foram explorados para conhecer os valores assumidos por cada atributo, foram gerados gráficos para entender a correlação entre

estes atributos, verificada a necessidade de pré-processamento ou divisão dos dados.

### **4.3 Pré-processamento dos dados**

A etapa de pré-processamento dos dados é muito importante, por modificar a estrutura dos dados com o fim de torná-lo compreensível para os modelos de aprendizado de máquina. Neste trabalho, foi utilizado o conceito de janelas de tempo para transformar o problema de série temporal em um problema de aprendizado supervisionado.

### **4.4 Seleção da ferramenta de AutoML**

A ferramenta de AutoML facilita a etapa de execução dos experimentos, pois a ferramenta deve executar diversas etapas do processo de ciência de dados de forma automática, como pré-processamento, divisão dos dados, treinamento, validação e ajuste de hiperparâmetros. Portanto, foi selecionada a biblioteca de AutoML AutoGluon, que se encaixa nesses requisitos e se destaca pela variedade de tipos de preditores, rapidez e facilidade de uso.

### **4.5 Execução dos experimentos**

A execução dos experimentos se dividiu em quatro partes, sendo elas: seleção do preditor do AutoGluon, treinamento dos preditores, teste de classificação e coleta de resultados.

#### ***4.5.1 Seleção do preditor do AutoGluon***

A ferramenta AutoGluon possui três tipos de preditores, sendo eles, preditor em dados tabulares, preditor em dados temporais e preditor de dados diversos. Em seguida, ao avaliar as opções, o preditor para dados temporais, que seria o mais relacionado ao dado utilizado, não é adequado para resolver o problema, pois não possui classificação de séries temporais, apenas previsão. Então foi escolhido o preditor tabular da biblioteca AutoGluon que resolve especificamente problemas que utilizam dados tabulares, para isso, os dados tiveram que passar por modificações para que a série temporal se transformasse em problema de aprendizado supervisionado. Após isso, foram construídos os preditores definindo os parâmetros de configuração do treinamento, como tempo limite, quantidade de tentativas e tipo de busca por algoritmos.

#### **4.5.2 Treinamento dos preditores**

A etapa de treinamento consistiu em utilizar os dados pré-processados com janelas temporais no preditor tabular configurado. Para isso, cada dado no formato de *pandas dataframe* foi convertido em *TabularDataset*, uma estrutura de dados criada pelo AutoGluon específica para dados tabulares, e passado como parâmetro na função de treinamento do preditor.

#### **4.5.3 Teste de classificação**

Para cada preditor treinado, foi utilizado um dado pré-processado de vários pacientes diferentes dos utilizados no treinamento, foi retirada a coluna de rótulo e então foi passado para o modelo poder prever os eventos dos novos pacientes. Após a execução do teste, possui-se material suficiente para o cálculo das métricas.

#### **4.5.4 Coleta dos resultados**

As métricas foram coletadas utilizando dados de saída da etapa de teste, primeiro avaliando os acertos, comparando os rótulos preditos com o rótulo real e a partir disso, calculando as métricas selecionadas. Posteriormente, foi calculada a probabilidade de ocorrência de cada classe para que a métrica de mAP pudesse ser gerada.

### **4.6 Análise dos resultados**

Após a execução dos experimentos, os resultados das métricas, acurácia, sensibilidade, especificidade, precisão e mAP definidos na Seção 2.4 de todos os modelos treinados foram reunidos para comparação. Finalmente, os resultados do melhor modelo foram comparados aos resultados dos trabalhos submetidos à competição de predição de congelamento de marcha do *Kaggle*.

## 5 EXPERIMENTOS E RESULTADOS

Neste capítulo são apresentados os experimentos e resultados deste trabalho. Todos os experimentos foram realizados em uma máquina que possui 125GB de RAM e processador Intel(R) Core(TM) i7-10700 CPU @ 2.90GHz.

### 5.1 Análise do conjunto de dados

O conjunto de dados selecionado foi o disponibilizado pela competição *Parkinson's Freezing of Gait Prediction*<sup>1</sup> realizada pela plataforma Kaggle<sup>2</sup>. Este conjunto de dados possui valores de acelerômetro 3D posicionado na região lombar de vários pacientes com a DP, e está dividido em três partes, sendo elas: 1) tDCS FOG, que compreende os pacientes que reproduziram o protocolo de provocação de FOG de forma supervisionada em uma clínica. 2) DeFOG no qual os pacientes reproduziram o mesmo protocolo enquanto estavam tomando a medicação para a DP e em outro momento quando não estavam tomando a medicação para a DP, mas desta vez de forma supervisionada em ambiente domiciliar. 3) E *The Daily Living Dataset* no qual 65 pacientes utilizaram o acelerômetro na região lombar por uma semana realizando suas atividades diárias em suas casas, sem supervisão, destes, 45 apresentando DP e FOG, enquanto os 20 restantes apresentam a DP, mas não sofrem o FOG.

Os atributos que se referem à coleta do acelerômetro 3D estão dispostas no conjunto de dados como AccV, AccML e AccAP, que significam, respectivamente, o eixo vertical, mediolateral e anteroposterior. A Figura 6 ilustra o posicionamento dos eixos citados no corpo humano, onde é possível perceber que o local de posicionamento do acelerômetro se situa bem próximo do cruzamento destes três eixos que representam o centro de gravidade do corpo humano, portanto, altamente relacionado ao equilíbrio. Além dos valores do acelerômetro, o conjunto de dados possui outros atributos que auxiliam na classificação do FOG por informarem sobre a ocorrência desse sintoma durante o período de coleta. O Quadro 2 descreve todos os atributos que o conjunto de dados selecionado possui. Além disso, como parte do processo de análise foram gerados gráficos 3D, demonstrados nas Figuras 7 e 8, e gráficos temporais, demonstrados nas figuras 9 e 10, de um paciente de cada conjunto de dados.

<sup>1</sup> <https://www.kaggle.com/competitions/tlvmc-parkinsons-freezing-gait-prediction>

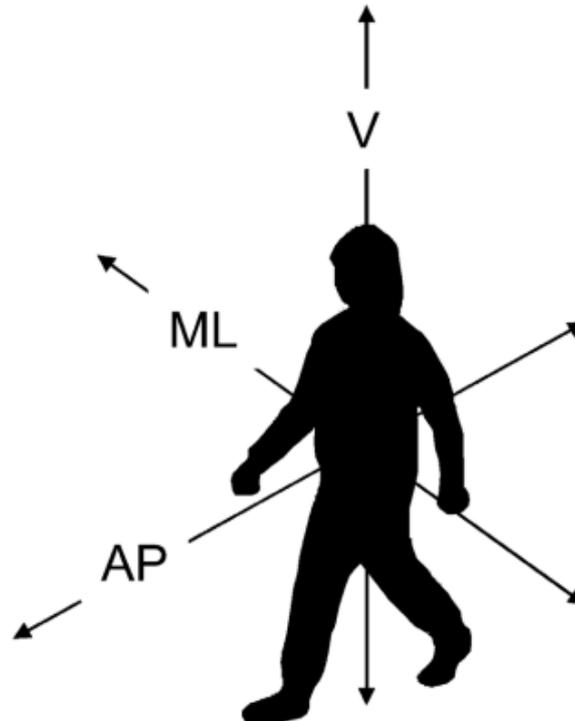
<sup>2</sup> <https://www.kaggle.com/>

Quadro 2 – Atributos do conjunto de dados *Freezing of Gait Prediction*

	Atributo	Descrição
1	Time	Valor inteiro representando o instante de tempo da coleta
2	AccV	Valor do acelerômetro no eixo vertical
3	AccML	Valor do acelerômetro no eixo mediolateral
4	AccAP	Valor do acelerômetro no eixo anteroposterior
5	<i>StartHesitation</i>	Ocorrência de FOG no início da caminhada naquele instante
6	<i>Turn</i>	Ocorrência de FOG na mudança de direção naquele instante
7	<i>Walking</i>	Ocorrência de FOG durante a caminhada naquele instante
8	<i>Event</i>	Ocorrência de FOG de qualquer tipo
9	<i>Valid</i>	Valor para afirmar que o evento foi rotulado sem ambiguidade
10	<i>Task</i>	Indica que o instante de tempo pertence a um movimento rotulado

Fonte: Elaborado pela autora

Figura 6 – Eixos anatômicos perpendiculares ao centro de gravidade

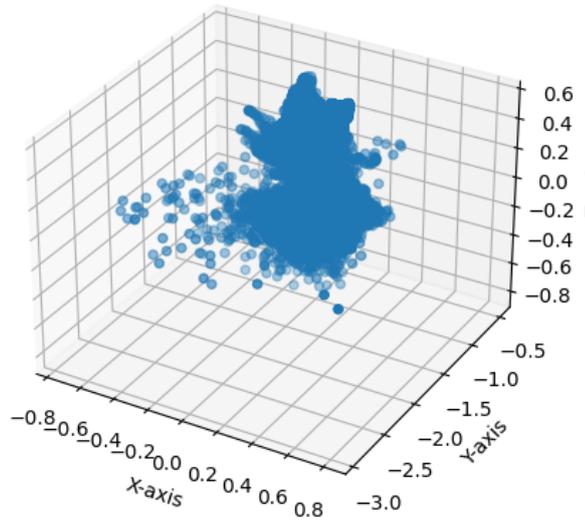


Fonte: Annegarn *et al.* (2012)

## 5.2 Pré-processamento dos dados

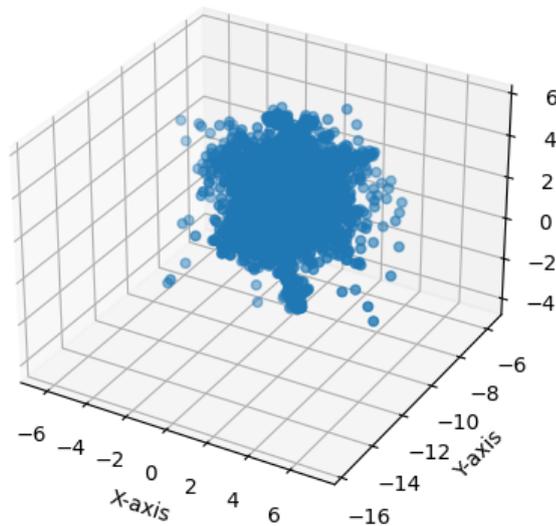
O conjunto de dados retirado da competição não possui dados faltantes ou inconsistências de valores, entretanto para que o modelo de classificação possa utilizá-lo, as colunas *StartHesitation*, *Turn* e *Walking* precisam ser unidas em apenas uma coluna representando os eventos como 1, 2 e 3, respectivamente. Além disso, foi adicionado um quarto evento, o *no-FOG*, representado pelo número 0 que indica quando não há ocorrência do congelamento de marcha. Esses valores serão entendidos pelos modelos de aprendizado de máquina como categorias e não

Figura 7 – Gráfico 3D dos eixos do acelerômetro - DeFOG



Fonte: Elaborada pela autora

Figura 8 – Gráfico 3D dos eixos do acelerômetro - tDCSFOG



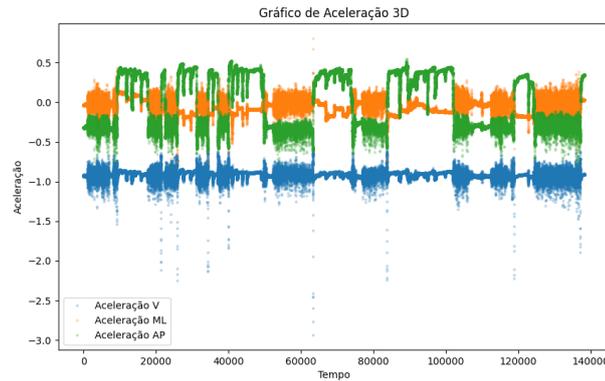
Fonte: Elaborada pela autora

valores numéricos comuns.

As colunas *Valid* e *Task* indicam quando a anotação do evento foi validado pelos profissionais de classificação de movimentos, com isso, o conjunto de dados utilizado no treinamento foi tratado para que não houvesse classes de eventos 1, 2 ou 3 onde *Valid* e *Task* fossem falsas.

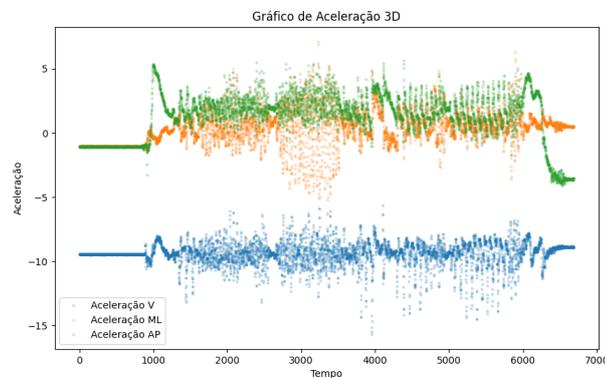
Após o pré-processamento, o *dataframe* final foi convertido em *TabularDataset*, uma estrutura de dados própria da biblioteca *AutoGluon* usada para representar dados tabulares. Essa conversão é necessária para o início do treinamento dos modelos.

Figura 9 – Gráfico temporal dos eixos do acelerômetro - DeFOG



Fonte: Elaborada pela autora

Figura 10 – Gráfico temporal dos eixos do acelerômetro - tDCSFOG



Fonte: Elaborada pela autora

### 5.3 Engenharia de atributos

Pela estrutura dos dados, com apenas três atributos, um para cada eixo do acelerômetro, o modelo tabular do AutoGluon não poderia aprender os padrões temporais e prever corretamente. Essa informação está apresentada na Tabela 2, onde o resultado do primeiro treinamento com dados brutos mostraram que a precisão, *recall* e *f1-score* estavam zerados para as classes *StartHesitation* e *Walking*. Então, a estrutura dos dados foi modificada para incluir janelas de tempo de tamanho 1, 2, 3 e 6, visando analisar a influência do tamanho de cada janela temporal nos resultados obtidos.

### 5.4 Treinamento dos modelos

O preditor utilizado foi o *TabularPredictor*, por ser específico para treinar modelos que tenham dados tabulares como entrada. Posteriormente, foram escolhidos os parâmetros de treinamento: tempo limite de treinamento igual a 28800 segundos, ou seja, 8 horas, para que o AutoGluon consiga testar várias abordagens e ainda não tome muito tempo. Já no

parâmetro “*hyperparameter\_tune\_kwargs*”, o número de tentativas de diferentes combinações de hiperparâmetros que cada modelo iria executar foi definido como 5, esse valor foi considerado moderado e suficiente para explorar uma gama razoável de configurações de hiperparâmetros sem comprometer excessivamente o tempo de treinamento. O agendador foi definido como execução local, pois os experimentos foram executados em apenas uma máquina. E o parâmetro de pesquisa pelos modelos foi definido como automática, com isso o AutoGluon executará uma pesquisa de otimização bayesiana nos modelos NN\_TORCH e FASTAI e uma pesquisa aleatória em outros modelos. Essa mesma configuração foi adotada para todos os preditores tabulares treinados para cada configuração de janela temporal.

Após o treinamento, foi coletado o resultado da classificação desses preditores focando nas métricas apresentadas na seção 2.4

## **5.5 Avaliação dos modelos**

O processo de avaliação dos modelos está definido em duas etapas: comparar o melhor modelo aos outros modelos treinados pelo AutoGluon, e avaliar os melhores modelos para cada janela temporal em relação às métricas selecionadas. Essa discussão está disposta na seção 5.5.1 e 5.5.2, respectivamente.

### **5.5.1 Classificação dos modelos**

A Tabela 1 mostra os modelos e estatísticas sobre pontuação de validação criados no treinamento do AutoGluon Tabular. O preditor tabular treinou 28 modelos e classificou em ordem decrescente em relação à pontuação de validação, sendo o melhor modelo treinando o WeightedEnsemble\_L2, tendo 0,9995 em sua pontuação de validação. Dada a escolha do melhor modelo, iniciou-se o processo de avaliação de desempenho por meio das métricas selecionadas neste trabalho.

### **5.5.2 Avaliação dos resultados**

A Tabela 2 mostra os resultados obtidos na fase de experimentos. O melhor modelo para todos os tamanhos de janela (TJ) foi o WeightedEnsemble\_L2 (WE\_L2). Nota-se que o modelo consegue inferir bem os eventos no-FOG, porém as demais classes ficaram com as métricas muito baixas. É possível perceber que pelo menos para a classe no-FOG, o aumento do

Tabela 1 – Classificação dos modelos no treinamento de janela igual a 1

	Modelo	Acurácia de validação
0	WeightedEnsemble_L2	0,9995
1	RandomForestEntr	0,9993
2	RandomForestGini	0,9992
3	ExtraTreesEntr	0,9977
4	ExtraTreesGini	0,9975
5	LightGBMLarge	0,9855
6	LightGBMXT/T5	0,9850
7	LightGBM/T5	0,9836
8	LightGBM/T2	0,9835
9	LightGBM/T3	0,9830
10	CatBoost/T2	0,9822
11	LightGBM/T1	0,9815
12	CatBoost/T3	0,9510
13	CatBoost/T4	0,9510
14	CatBoost/T5	0,9510
15	CatBoost/T1	0,9510
16	NeuralNetFastAI/77c583be	0,9499
17	NeuralNetFastAI/77c583c0	0,9456
18	NeuralNetFastAI/77c583c2	0,9456
19	NeuralNetFastAI/77c583bf	0,9359
20	LightGBMXT/T3	0,9321
21	LightGBMXT/T1	0,9321
22	LightGBM/T4	0,9321
23	LightGBMXT/T4	0,9321
24	LightGBMXT/T2	0,9321
25	NeuralNetFastAI/77c583c1	0,9321
26	KNeighborsUnif	0,8807
27	KNeighborsDist	0,8761

Fonte: Elaborado pela autora

tamanho da janela favoreceu a detecção, alcançando 0,96 no f1-score e precisão, 0,97 no *recall* e 0,93 na acurácia. Já a mAP chegou em 0,39, valor este maior que o resultado do 5º colocado na competição do Kaggle.

### 5.5.3 Considerações finais

Neste capítulo foram apresentados os resultados obtidos pelos experimentos com AutoGluon Tabular e dados da competição *Parkinson's Freezing of Gait Prediction*, possibilitando a reflexão sobre a abordagem escolhida.

O uso de AutoML, mais especificamente, AutoGluon, facilitou a escolha de um

Tabela 2 – Resultados dos melhores modelos treinados para cada tamanho de janela

TJ	Modelo	No-FOG			StartHesitation			Turn			Walking			Global	
		F1	R	P	F1	R	P	F1	R	P	F1	R	P	ACC	mAP
1	WE_L2	0,94	0,98	0,91	0,00	0,00	0,00	0,04	0,02	0,12	0,00	0,00	0,00	0,89	0,34
2	WE_L2	0,85	1,00	0,92	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,84	0,39
3	WE_L2	0,84	1,00	0,91	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,84	0,35
6	WE_L2	0,96	0,97	0,96	0,00	0,00	0,00	0,01	0,01	0,01	0,00	0,00	0,00	0,93	0,39

Fonte: Elaborado pela autora

Legenda:

TJ: Tamanho da janela temporal

F1: F1-score

R: Sensibilidade

P: Precisão

Tabela 3 – Resultados da competição *Parkinson's Freezing of Gait Prediction*

Posição	mAP
1°	0.5140
2°	0.4509
3°	0.4364
4°	0.4174
5°	0.3898
6°	0.3694
7°	0.3569
8°	0.3563
9°	0.3489
10°	0.3477
20°	0.3247
30°	0.3160
40°	0.3089
50°	0.3060

Fonte: Elaborada pela autora

modelo de aprendizado de máquina ao automatizar diversas etapas de transformação dos dados, ajuste de hiperparâmetros e tentativas de vários tipos de modelos de aprendizado de máquina para o dado trabalhado. Entretanto, a estrutura original do conjunto de dados selecionado dificulta o aprendizado de padrões, por possuir poucos atributos, levando à baixa capacidade de detectar o FOG.

Apesar de utilizar a técnica de janela temporal para dar um vislumbre da sequência de movimentos realizada pelo paciente, essa modificação não foi suficiente para melhorar a detecção dos eventos de FOG, provavelmente por utilizar janelas temporais pequenas.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

A detecção de FOG em pacientes com DP é um problema ainda muito estudado nesta área, tendo como principais abordagens o uso de aprendizado de máquina e dados de sensores. Com isso, o objetivo geral deste trabalho é utilizar técnicas de AutoML para desenvolver um modelo preditivo para identificar e classificar os episódios de FOG de indivíduos em geral durante diferentes fases da caminhada, abrangendo o início da caminhada, o período durante a caminhada e os momentos de mudança de direção. Dessa forma, foram treinados 4 modelos utilizando a ferramenta AutoGluon, utilizando os mesmos dados para cada treinamento, diferenciando somente o tamanho das janelas de tempo que foram 1, 2, 3 e 6.

Dentre as principais dificuldades encontradas na realização desse trabalho pode-se destacar o pouco poder de processamento da máquina utilizada, levando à necessidade de treinar os modelos com menos dados para que não custasse tanto tempo. Além disso, pode-se citar a dificuldade de utilizar modelos treinados com AutoGluon na competição *Parkinson's Freezing of Gait Prediction*, pois era necessário submeter o notebook em vez de um arquivo CSV com a resposta, com isso, a configuração do ambiente para carregar o modelo treinado de forma *offline* foi um grande obstáculo.

Sobre os resultados obtidos, o melhor modelo conseguiu detectar bem apenas uma das quatro classes analisadas, conseguindo para a classe no-FOG 0,96 no *f1-score* e precisão, 0,97 no *recall*, 0,93 na acurácia e 0,39 no mAP. Para a classe *Turn* o modelo obteve 0,01 no *f1-score*, *recall* e precisão. Já para as classes *StartHesitation* e *Walking* todas as métricas foram zeradas. Com isso, foi constatado que a abordagem escolhida não oferece bom desempenho na classificação dos eventos de FOG, tendo como possível explicação a pouca quantidade de atributos para representar uma sequência temporal de movimentos. Adicionalmente, a métrica mAP do melhor modelo, que foi 0,39, superou o resultado do 5º colocado na competição do Kaggle que foi 0,38.

Dessa forma, este trabalho mostrou que o uso de técnicas de AutoML podem contribuir com a escolha e treinamento de modelos de aprendizado de máquina de forma mais rápida ao automatizar o processo do início ao fim, entretanto, para o conjunto de dados selecionado no trabalho a abordagem não conseguiu detectar eventos de FOG eficientemente.

Como trabalhos futuros, faz-se necessário avaliar a contribuição do uso de janelas temporais maiores, além do uso de engenharia de atributos avançada.

## REFERÊNCIAS

- ANNEGARN, J.; SPRUIT, M.; SAVELBERG, H.; WILLEMS, P.; BOOL, C.; SCHOLS, A.; WOUTERS, E.; MEIJER, K. Differences in walking pattern during 6-min walk test between patients with copd and healthy subjects. **PloS one**, [S.I: s. n.], v. 7, p. e37329, 05 2012.
- BALESTRINO, R.; SCHAPIRA, A. Parkinson disease. **European Journal of Neurology**, [S.I: s. n.], v. 27, n. 1, p. 27–42, 2020.
- BORZÌ, L.; MAZZETTA, I.; ZAMPOGNA, A.; SUPPA, A.; OLMO, G.; IRRERA, F. Prediction of freezing of gait in parkinson's disease using wearables and machine learning. **Sensors**, MDPI, [S.I: s. n.], v. 21, n. 2, p. 614, 2021.
- DEMROZI, F.; BACCHIN, R.; TAMBURIN, S.; CRISTANI, M.; PRAVADELLI, G. Toward a wearable system for predicting freezing of gait in people affected by parkinson's disease. **IEEE Journal of Biomedical and Health Informatics**, [S.I: s. n.], v. 24, n. 9, p. 2444–2451, 2020.
- ERICKSON, N.; MUELLER, J.; SHIRKOV, A.; ZHANG, H.; LARROY, P.; LI, M.; SMOLA, A. **AutoGluon-Tabular**: Robust and accurate automl for structured data. [S.I: s. n.]: [S. n.], 2020.
- FOUNDATION, T. M. J. F. **Parkinson's Freezing of Gait Prediction**. [S.I: s. n.]: [S. n.], 2023. Kaggle competition.
- GÁLVEZ, G.; RECUERO, M.; CANUET, L.; DEL-POZO, F. Short-term effects of binaural beats on eeg power, functional connectivity, cognition, gait and anxiety in parkinson's disease. **International journal of neural systems**, World Scientific, [S.I: s. n.], v. 28, n. 05, p. 1750055, 2018.
- HE, X.; ZHAO, K.; CHU, X. Automl: A survey of the state-of-the-art. **Knowledge-Based Systems**, Elsevier, [S.I: s. n.], v. 212, p. 106622, 2021.
- HEEMANN, A.; VELINOVA, D.; GASTEGGER, M. **Textklassifikation - Decision Trees Random Forests**. [S.I: s. n.]: [S. n.], 2017.
- JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, Springer, [S.I: s. n.], v. 31, n. 3, p. 685–695, 2021.
- JANKOVIC, J. Parkinson's disease: clinical features and diagnosis. **Journal of Neurology, Neurosurgery & Psychiatry**, BMJ Publishing Group Ltd, [S.I: s. n.], v. 79, n. 4, p. 368–376, 2008. ISSN 0022-3050.
- LI, K.; HUANG, Z.; CHENG, Y.-C.; LEE, C.-H. A maximal figure-of-merit learning approach to maximizing mean average precision with deep neural network based classifiers. In: **IEEE 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.I: s. n.], 2014. p. 4503–4507.
- MAHESH, B. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**. [Internet], [S.I: s. n.], v. 9, n. 1, p. 381–386, 2020.
- MASIALA, S.; HUIJBERS, W.; ATZMUELLER, M. **Feature-Set-Engineering for Detecting Freezing of Gait in Parkinson's Disease using Deep Recurrent Neural Networks**. [S.I: s. n.]: [S. n.], 2019.

MEERHOLZ, P. V.; MATTOS, W. D. de; FREITAS, D. S. de; INACIO, E. C. Um estudo sobre o uso de modelos de machine learning para manutenção preditiva industrial. **Anais do Computer on the Beach**, [S.I: s. n.], v. 14, p. 311–318, 2023.

MONTEVECHI, A. A.; MIRANDA, R. de C.; MEDEIROS, A. L.; AMARAL, J. V. S. D. Machine learning na análise do risco de crédito: Uma aplicação da regressão logística e algoritmos de resampling. **Anais do Encontro Nacional de Engenharia de Produção**, [S.I: s. n.], 2022.

MUGHAL, H.; JAVED, A. R.; RIZWAN, M.; ALMADHOR, A. S.; KRYVINSKA, N. Parkinson's disease management via wearable sensors: a systematic review. **IEEE Access**, IEEE, [S.I: s. n.], v. 10, p. 35219–35237, 2022.

PARK, K. W.; LEE, E.-J.; LEE, J. S.; JEONG, J.; CHOI, N.; JO, S.; JUNG, M.; DO, J. Y.; KANG, D.-W.; LEE, J.-G.; CHUNG, S. J. Machine learning–based automatic rating for cardinal symptoms of parkinson disease. **Neurology**, Wolters Kluwer Health, Inc. on behalf of the American Academy of Neurology, [S.I: s. n.], v. 96, n. 13, p. e1761–e1769, 2021. ISSN 0028-3878.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, [S.I: s. n.], v. 12, p. 2825–2830, 2011.

POEWE, W.; SEPPI, K.; TANNER, C. M.; HALLIDAY, G. M.; BRUNDIN, P.; VOLKMANN, J.; SCHRAG, A.-E.; LANG, A. E. Parkinson disease. **Nature reviews Disease primers**, Nature Publishing Group, [S.I: s. n.], v. 3, n. 1, p. 1–21, 2017.

RODRÍGUEZ-MARTÍN, D.; SAMÀ, A.; PÉREZ-LÓPEZ, C.; CATALÀ, A.; AROSTEGUI, J. M. M.; CABESTANY, J.; BAYÉS, À.; ALCÁINE, S.; MESTRE, B.; PRATS, A. *et al.* Home detection of freezing of gait using support vector machines through a single waist-worn triaxial accelerometer. **PLoS one**, Public Library of Science San Francisco, CA USA, [S.I: s. n.], v. 12, n. 2, p. e0171764, 2017.

ROGGEN DANIEL, P. M.; HAUSDORFF, J. **Daphnet Freezing of Gait**. [S.I: s. n.]: [S. n.], 2013. UCI Machine Learning Repository. DOI: <https://doi.org/10.24432/C56K78>.

RUBACK, L.; AVILA, S.; CANTERO, L. Vieses no aprendizado de máquina e suas implicações sociais: Um estudo de caso no reconhecimento facial. In: SBC. **Anais do II Workshop sobre as Implicações da Computação na Sociedade**. [S.I: s. n.], 2021. p. 90–101.

RUTIGLIANO, D.; BORACCHI, G.; INVERNIZZI, P.; SOZIO, E.; ALIPPI, C.; BINETTI, S. Event-detection deep neural network for otdr trace analysis. In: SPRINGER. **International Conference on Engineering Applications of Neural Networks**. [S.I: s. n.], 2021. p. 190–201.

SIGCHA, L.; BORZÌ, L.; PAVÓN, I.; COSTA, N.; COSTA, S.; AREZES, P.; LÓPEZ, J. M.; De Arcas, G. Improvement of performance in freezing of gait detection in parkinson's disease using transformer networks and a single waist-worn triaxial accelerometer. **Engineering Applications of Artificial Intelligence**, [S.I: s. n.], v. 116, p. 105482, 2022. ISSN 0952-1976.

SOOFI, A. A.; AWAN, A. Classification techniques in machine learning: applications and issues. **Journal of Basic & Applied Sciences**, Set Publishers, [S.I: s. n.], v. 13, n. 1, p. 459–465, 2017.

TROIANO, R. P.; MCCLAIN, J. J.; BRYCHTA, R. J.; CHEN, K. Y. Evolution of accelerometer methods for physical activity research. **British Journal of Sports Medicine**, British Association of Sport and Exercise Medicine, [S.I: s. n.], v. 48, n. 13, p. 1019–1023, 2014. ISSN 0306-3674.