



**Politécnico
Castelo Branco**

Escola Superior
de Tecnologia

Análise e Avaliação de Algoritmos para Reconhecimento de Posturas com base em Matrizes de Pressão

André Carvalho Serra

20161198

Orientadores

Professor Doutor Fernando Reinaldo Silva Garcia Ribeiro

Professor Doutor José Carlos Meireles Monteiro Metrôlho

Dissertação apresentada à Escola Superior de Tecnologia do Instituto Politécnico de Castelo Branco para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Informática - Área de Especialização em Desenvolvimento de Software e Sistemas Interativos, realizada sob a orientação científica do Professor Adjunto, Doutor Fernando Reinaldo Silva Garcia Ribeiro e do Professor Coordenador, Doutor José Carlos Meireles Monteiro Metrôlho, do Instituto Politécnico de Castelo Branco.

Janeiro, 2025

Composição do júri

Presidente do júri

Doutor, Alexandre José Pereira da Fonte

Prof. Adjunto, Escola Superior de Tecnologia do Instituto Politécnico Castelo Branco

Vogais

Doutor, Carlos Cambra Baseca

Prof. Associado, Escuela Politécnica Superior da Universidade de Burgos - Espanha

Doutor, Eduardo Sabina dos Santos Valente

Prof. Adjunto, Escola Superior de Tecnologia do Instituto Politécnico Castelo Branco

Doutor, Fernando Reinaldo da Silva Garcia Ribeiro

Prof. Adjunto, Escola Superior de Tecnologia do Instituto Politécnico Castelo Branco

Agradecimentos

Ao longo do desenvolvimento desta dissertação, houve o envolvimento de diferentes pessoas, quer diretamente ou indiretamente.

Gostaria de agradecer à minha mãe e aos meus irmãos pelo apoio e esforço que constantemente me dão. E por toda a ajuda que oferecem, tanto em situações boas quanto em más. Igualmente agradecer, aos meus amigos que se preocupam com o meu bem-estar e que me suportam nos bons e maus momentos.

Quero agradecer aos meus orientados, Prof. Dr. Fernando Reinaldo Ribeiro e o Prof. Dr. José Carlos Metrôlho, pelo incentivo e por toda a ajuda que me deram deste o início não só desta dissertação, mas também durante os anos letivos em que tive oportunidade de os ter como meus professores de curso. E agradecer a Luís Fonseca, pelo seu apoio e conhecimento que forneceu um melhor entendimento de determinados tópicos no desenvolvimento desta dissertação.

Gostaria de agradecer também a todos os meus colegas, professores e ao Instituto Politécnico de Castelo Branco, que de certa forma me forneceram o apoio e oportunidades para conseguir chegar a este momento.

Resumo

O processo de controlar e monitorizar o estado do paciente durante as suas horas de sono tem vindo a ajudar no estudo de diminuição de riscos de saúde, nomeadamente em situações nas quais os maus hábitos noturnos ou mau posicionamento do corpo causam diferentes tipos de problemas no seu respetivo bem-estar. Vários estudos têm sido feitos neste âmbito, nomeadamente para a classificação de posturas das pessoas que se encontram acamadas, cada um deles seguindo diferentes abordagens. Por exemplo, técnicas que utilizam matrizes de pressão obtidas de sensores posicionados sobre o colchão, juntamente com algoritmos de *machine learning* (ML), têm alcançado precisões de até 99% (e.g., [1]) na classificação das posturas principais (virado para cima, virado para baixo, lateral esquerdo e lateral direito).

Este trabalho centra-se na utilização de algoritmos de ML aplicados a dados obtidos por uma matriz de sensores de pressão posicionada por baixo do colchão, de forma a minimizar o desconforto para o paciente monitorado. Usando este conjunto de dados, são aplicados e avaliados algoritmos para a classificação das posturas principais e as suas variações, com o objetivo de desenvolver uma solução eficaz e menos invasiva para monitorização da postura.

Os experimentos incluíram 10 algoritmos de ML, que alcançaram uma *accuracy* média entre 79,14% e 98,93% com validação *Group K-Fold* e entre 80,03% e 97,14% com a técnica *Leave-One-Group-Out* (LOGO) para classificar as quatro posturas principais. O estudo também expandiu a classificação para 28 variações de postura (7 variações para cada postura principal), com o algoritmo SVM alcançando uma *accuracy* de 65,18% na validação *Group K-Fold*. Isso representa uma melhoria significativa em relação a estudos anteriores, especialmente ao considerar o maior número de posturas. Comparações com outras abordagens que utilizam sensores de pressão mostram que esta solução, com sensores posicionados por baixo do colchão, oferece uma *accuracy* comparável e, em alguns casos, superior. Esses resultados sugerem que o uso de sensores por baixo do colchão é uma alternativa eficaz e menos intrusiva para a classificação de posturas.

Palavras-chave

Matrizes de pressão, algoritmos de reconhecimento, mantas de sensores, posturas na cama, *machine learning*.

Abstract

The process of controlling and monitoring a patient's condition during their sleeping hours has been helping to reduce health risks, particularly in situations where poor nighttime habits or poor body positioning cause different types of problems to their well-being. Several studies have been carried out in this area, particularly for the classification of postures of people who are bedridden, each of them following different approaches. For example, techniques that use pressure matrices obtained from sensors positioned on the mattress, together with machine learning (ML) algorithms, have achieved accuracies of up to 99% (e.g., [1]) in the classification of the main postures (face up, face down, left side and right side).

This work focuses on the use of ML algorithms applied to data obtained by a matrix of pressure sensors positioned under the mattress, to minimize discomfort for the monitored patient. Using this dataset, algorithms for classifying the main postures and their variations are applied and evaluated, with the aim of developing an effective and less invasive solution for posture monitoring.

The experiments included 10 ML algorithms, which achieved an average accuracy between 79.14% and 98.93% with Group K-Fold validation and between 80.03% and 97.14% with the Leave-One-Group-Out (LOGO) technique to classify the four main postures. The study also expanded the classification to 28 posture variations (7 variations for each main posture), with the SVM algorithm achieving an accuracy of 65.18% in Group K-Fold validation. This represents a significant improvement over previous studies, especially when considering the larger number of postures. Comparisons with other approaches using pressure sensors show that this solution, with sensors positioned under the mattress, offers comparable and, in some cases, superior accuracy. These results suggest that the use of sensors under the mattress is an effective and less intrusive alternative for posture classification.

Keywords

Pressure matrices, recognition algorithms, sensor blankets, bed postures, machine learning.

Índice geral

1.	Introdução.....	1
1.1.	Objetivos	2
1.2.	Cronograma	2
1.3.	Estrutura da Dissertação	3
2.	Trabalhos Relacionados.....	4
2.1.	Questões de Pesquisa.....	4
2.2.	Fontes e Pesquisa	4
2.3.	Critérios de Inclusão.....	5
2.4.	Critérios de Exclusão.....	5
2.5.	Resultados	5
2.6.	Análise dos Estudos Incluídos	7
2.7.	Discussão	10
3.	Metodologia.....	12
3.1.	Fases de Processamento e Validação de Algoritmos	12
3.2.	<i>Dataset PoPu</i>	13
3.3.	Seleção dos Algoritmos	14
4.	Resultados.....	15
4.1.	Experimentos para a Classificação das 4 Posturas Principais	15
4.1.1.	<i>K-Nearest Neighbors</i>	16
4.1.2.	<i>Support Vector Machine</i>	20
4.1.3.	<i>Decision Trees</i>	22
4.1.4.	<i>Random Forest</i>	25
4.1.5.	<i>Gradient Boosting</i>	28
4.1.6.	<i>Naive Bayes</i>	31
4.1.7.	<i>Feed Forward Artificial Neural Network</i>	34
4.1.8.	<i>Temporal Convolutional Network</i>	36
4.1.9.	<i>Convolutional Neural Network</i>	39
4.1.10.	<i>ResNet-18</i>	42
4.2.	Experimentos para a Classificação de 28 Posturas	44
5.	Discussão	46
6.	Conclusão.....	51

Referências 52

Índice de figuras

Figura 1 - Processo de seleção de estudos com base na pesquisa e critérios de inclusão e exclusão.....	6
Figura 2 - Matriz de confusão de KNN.....	17
Figura 3 - Distribuição de participantes no Group K-Fold.....	18
Figura 4 - Frequência de melhores parâmetros.	19
Figura 5 - Gráfico de performance de participantes.	19
Figura 6 - Matriz de confusão de SVM.	21
Figura 7 - Frequência de melhores parâmetros de SVM.	22
Figura 8 - Gráfico de performance de participantes.	22
Figura 9 - Matriz de confusão de DT.	24
Figura 10 - Frequência de melhores parâmetros de DT.....	25
Figura 11 - Gráfico de performance de participantes.....	25
Figura 12 - Matriz de confusão de RF.	27
Figura 13 - Frequência de melhores parâmetros de RF.	28
Figura 14 - Gráfico de performance de participantes.....	28
Figura 15 - Matriz de confusão de GB.....	30
Figura 16 - Frequência de melhores parâmetros de GB.....	31
Figura 17 - Gráfico de performance de participantes.....	31
Figura 18 - Matriz de confusão de NB.....	32
Figura 19 - Frequência de melhores parâmetros de NB.....	33
Figura 20 - Gráfico de performance de participantes.....	34
Figura 21 - Matriz de confusão de FFANN.	35
Figura 22 - Frequência de melhores parâmetros de FFANN.	36
Figura 23 - Gráfico de performance de participantes.....	36
Figura 24 - Matriz de confusão de TCN.	37
Figura 25 - Frequência de melhores parâmetros de TCN.....	38
Figura 26 - Gráfico de performance de participantes.....	39
Figura 27 - Matriz de confusão de CNN.....	40
Figura 28 - Frequência de melhores parâmetros de CNN.....	41
Figura 29 - Gráfico de performance de participantes.....	41
Figura 30 - Matriz de confusão de ResNet-18.	43
Figura 31 - Frequência de melhores parâmetros de ResNet-18.	44
Figura 32 - Gráfico de performance de participantes.....	44
Figura 33 - Matrizes de confusão de FFANN e SVM.	45
Figura 34 - Comparação dos valores médios de accuracy de todos os algoritmos.	47

Lista de tabelas

Tabela 1 - Calendarização de etapas.....	3
Tabela 2 - Resumo da informação dos estudos selecionados na revisão sistemática.	7
Tabela 3 - Resultados da avaliação inicial de KNN.....	16
Tabela 4 - Resultados do relatório de classificação de KNN.....	16
Tabela 5 - Resultados de avaliação cruzada K=5.	18
Tabela 6 - Resultados iniciais de SVM.....	20
Tabela 7 - Resultados do relatório de classificação de SVM.....	20
Tabela 8 - Resultados de validação cruzada de SVM.....	21
Tabela 9 - Resultados iniciais de DT.	23
Tabela 10 - Resultados do relatório de classificação de DT.	23
Tabela 11 - Resultados de validação cruzada de DT.	24
Tabela 12 - Resultados iniciais de RF.....	26
Tabela 13 - Resultados do relatório de classificação de RF.	26
Tabela 14 - Resultados de validação cruzada de RF.....	27
Tabela 15 - Resultados iniciais de RF.....	29
Tabela 16 - Resultados do relatório de classificação de GB.....	29
Tabela 17 - Resultados de validação cruzada de GB.....	30
Tabela 18 - Resultados iniciais de NB.	32
Tabela 19 - Resultados do relatório de classificação de NB.	32
Tabela 20 - Resultados de validação cruzada de GB.....	33
Tabela 21 - Resultados iniciais de FFANN.....	34
Tabela 22 - Resultados do relatório de classificação de FFANN.....	35
Tabela 23 - Resultados de validação cruzada de FFANN.....	35
Tabela 24 - Resultados iniciais de TCN.....	37
Tabela 25 - Resultados do relatório de classificação de TCN.....	37
Tabela 26 - Resultados de validação cruzada de TCN.....	38
Tabela 27 - Resultados iniciais de CNN.	39
Tabela 28 - Resultados do relatório de classificação de CNN.	40
Tabela 29 - Resultados de validação cruzada de CNN.	40
Tabela 30 - Resultados iniciais de ResNet-18.....	42
Tabela 31 - Resultados do relatório de classificação de ResNet-18.....	42
Tabela 32 - Resultados de validação cruzada de ResNet-18.....	43
Tabela 33 - Resultados de classificação de 28 posturas.	45
Tabela 34 - Resultados dos algoritmos analisados.	46
Tabela 35 - Resultados obtidos por outros estudos (amostra de dados da Tabela 2).	48
Tabela 36 - Estudos com dados obtidos por baixo ou por cima do colchão.....	48
Tabela 37 - Comparação com o estudo [13], com matriz de 64x27 e 4 posturas..	49
Tabela 38 - Comparação com o estudo [13], com matriz de 16x7 e 4 posturas.....	49
Tabela 39 - Comparação com o estudo [13], com 28 posturas.....	50

Lista de abreviaturas, siglas e acrónimos

API - *Application Programming Interface*

CNN - *Convolutional Neural Network*

DNN - *Deep Neural Network*

DT - *Decision Trees*

FFANN - *Feedforward Artificial Neural Network*

GB - *Gradient Boosting*

JSON - *JavaScript Object Notation*

KNN - *k-Nearest Neighbours*

LOGO - *Leave-One-Group-Out*

LOSO - *Leave-One-Subject-Out*

ML - *Machine Learning*

NB - *Naive Bayes*

NN - *Neural Network*

PRISMA - *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*

ResNet - *Residual Neural Network*

RF - *Random Forest*

SVM - *Support Vector Machine*

TCN - *Temporal Convolutional Networks*

1. Introdução

A postura em que um paciente dorme é um fator que tem vindo a ser estudado, por esta ser uma causa que proporciona o aumento do risco de saúde [2]. Estes riscos de saúde abrangem diversas doenças ou perturbações de sono que são influenciadas pelos maus hábitos noturnos ou pela postura corporal em que um paciente permanece durante o período em que está acamado. Exemplos de doenças ou perturbações deste tipo são “apneia”, insónia, distúrbios de sono [3], problemas de coluna [4] e úlceras de pressão [5][6].

Alguns estudos, por exemplo [7][8], têm vindo a comprovar que existe uma relação entre a postura em que os pacientes se posicionam durante as horas de sono e as respetivas perturbações de sono. Isso tem realçado a importância de uma monitorização constante das pessoas acamadas por parte dos profissionais de saúde que os acompanham. No entanto, a monitorização das condições dos pacientes pode ser uma tarefa que exige bastante tempo e dedicação por parte destes profissionais e isso tem levado ao desenvolvimento de soluções para, de certa forma, ajudar a monitorizar os pacientes durante o período em que estão acamados [9]. Tecnologias como polissonografia, pulseiras, sensores *ou* câmaras de vídeo [10], [11], ajudam na recolha de dados determinantes para conseguir identificar as posturas que o paciente mais frequentemente assume enquanto está acamado.

Para serem menos intrusivos para os pacientes, alguns métodos utilizam mapas de pressão obtidos a partir de sensores colocados em cima do colchão e, em seguida, aplicam técnicas de aprendizagem de máquina (*machine learning* (ML)) para classificar as posturas dos pacientes. Estes métodos são menos intrusivos do que aqueles que envolvem dispositivos ou sensores colocados diretamente no paciente. Normalmente, conseguem uma elevada precisão de classificação, acima dos 95% e até 99% em alguns casos, quando se consideram as quatro posturas principais (deitado para cima (supino), deitado para baixo (prone), lateral esquerda e lateral direita) (ex., [12], [13], [14], [15])

Nas abordagens que utilizam sensores de pressão, é comum a utilização de mantas de sensores colocadas sobre o colchão, que geram mapas de pressão representando as posturas dos indivíduos acamados. Embora estes métodos permitam uma boa precisão na classificação de posturas, não estão completamente isentos de desvantagens. A utilização de mantas de sensores colocadas entre o colchão e o corpo da pessoa pode introduzir algum desconforto, como fricção ou deslocamento da manta de sensores devido ao movimento da pessoa acamada. Essas soluções podem ser intrusivas e desconfortáveis, uma vez que consistem em mantas de sensores colocadas em contacto com o paciente. Neste contexto, a procura de soluções menos intrusivas para a classificação de posturas levou à exploração de matrizes de sensores de pressão colocadas por baixo do colchão.

1.1. Objetivos

O objetivo deste trabalho é estudar soluções para a classificação de posturas de pessoas acamadas utilizando algoritmos de ML, com base em mapas de pressão obtidos a partir de sensores colocados por baixo do colchão. O trabalho tem como base o dataset *PoPu-Data: A Multilayered, Simultaneously Collected Lying Position Dataset* [16] que é um dos *datasets* com informação de mapas de pressão de pessoas acamadas mais completos e que se encontra disponível para ser utilizado. Este *dataset* inclui dados de 60 indivíduos, e inclui informação como sexo, peso, altura e mapas de pressão correspondentes a 28 posturas diferentes, correspondendo a 7 variações para cada uma das 4 posturas principais. Neste *dataset* os dados foram recolhidos simultaneamente usando duas matrizes de sensores diferentes, uma colocada por cima do colchão e outra colocada por baixo do mesmo colchão. No caso deste trabalho, serão utilizados os dados da matriz de sensores colocada por baixo do colchão.

Este trabalho difere de outras abordagens, uma vez que utiliza dados de pressão recolhidos a partir de uma matriz de sensores colocada por baixo do colchão, sendo que a abordagem mais comum noutros estudos tem sido a colocação da matriz de sensores por cima do colchão.

Pretende-se também validar se a informação constante no *dataset* permite a classificação de posturas com um nível de *accuracy* suficiente para este tipo de aplicações pois, tanto quanto é do nosso conhecimento, nesta data ainda não foram realizados estudos com a componente do *dataset* correspondente à matriz de sensores colocada por baixo do colchão.

1.2. Cronograma

Para a execução do trabalho e para alcançar os objetivos propostos, foram previstas as seguintes etapas e calendarização:

1. Estudo e análise de trabalhos relacionados nomeadamente os que abordam modelos/algoritmos para reconhecimento de posturas em pessoas acamadas com base em matrizes de pressão obtidas por sensores colocados por baixo do colchão;
2. Análise e pré-processamento dos dados contidos no *dataset*;
3. Seleção e implementação de algoritmos de reconhecimento de posturas;
4. Avaliação dos resultados e comparação com resultados de abordagens incluídas no estado da arte;
5. Escrita do relatório.

Tabela 1 - Calendarização de etapas.

	Nov. 2023	Dez. 2023	Jan. 2024	Fev. 2024	Mar. 2024	Abr. 2024	Mai. 2024	Jun. 2024	Jul. 2024	Ago. 2024	Set. 2024	Out. 2024
1												
2												
3												
4												
5												

1.3. Estrutura da Dissertação

Esta dissertação está organizada em 6 capítulos:

- Capítulo 1: Introdução ao âmbito do estudo, apresentando o contexto, a motivação e os objetivos deste trabalho. É também apresentado o cronograma do trabalho realizado.
- Capítulo 2: Revisão de trabalhos relacionados e análise de estudos e algoritmos existentes para o reconhecimento de posturas de pessoas acamadas, com base em dados obtidos por sensores de pressão colocados sob o colchão.
- Capítulo 3: Descreve a metodologia aplicada neste estudo, detalhando as etapas de processamento e validação de dados, a descrição do *dataset PoPu* e a seleção de algoritmos.
- Capítulo 4: Apresentação dos resultados das experiências realizadas para a classificação de posturas usando os algoritmos selecionados no capítulo 3. Os experimentos foram divididos em duas partes: classificação das 4 posturas principais e classificação das 28 variações.
- Capítulo 5: Análise e discussão dos resultados obtidos no Capítulo 4, comparando-os com abordagens e resultados de estudos mencionados no Capítulo 2. A discussão destaca os pontos fortes e as limitações dos métodos utilizados, bem como possíveis melhorias.
- Capítulo 6: Apresenta as conclusões do estudo, sintetizando as principais descobertas e implicações das mesmas. São discutidas as contribuições do trabalho e sugestões para trabalho futuro.

2. Trabalhos Relacionados

Este capítulo apresenta uma revisão de literatura, com o objetivo de explorar estudos sobre reconhecimento de posturas com base em matrizes de pressão, obtidas por sensores colocados sob o colchão. São discutidos os algoritmos utilizados para o reconhecimento e as *accuracies* de classificação alcançadas.

Para a realização da revisão foi utilizada a metodologia de revisão sistemática *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) [17] com o objetivo de selecionar os estudos mais relevantes, com base em critérios de inclusão e exclusão.

O processo de pesquisa e seleção de artigos foi efetuado seguindo as seguintes 6 etapas:

1. Questões de pesquisa: identificação das questões de pesquisa que se pretendem responder de forma a responder aos objetivos propostos;
2. Fontes: identificação das bases de dados e recursos em que foram feitas as pesquisas e retirados os estudos;
3. Critérios de inclusão: definição de critérios que definem os termos que um determinado estudo cumpre para ser incluído na análise;
4. Critérios de exclusão: definição de critérios que excluem estudos que não estejam em conformidade com o propósito do presente trabalho.
5. Extração e análise de dados: extração da informação de cada estudo e análise do seu conteúdo;
6. Discussão: conclusões após a análise dos dados extraídos.

2.1. Questões de Pesquisa

Foram identificadas as seguintes 4 questões de pesquisa para dar resposta aos objetivos inicialmente definidos:

1. Que soluções para reconhecimento de posturas, baseadas em dados captados por sensores colocados por baixo do colchão, existem?
2. Que *datasets* com dados obtidos por sensores colocados por baixo do colchão existem e quais as suas características?
3. Quais as posturas que são mais identificadas?
4. Que algoritmos/modelos são utilizados para a classificação de posturas e que valores de *accuracy* permitem obter?

2.2. Fontes e Pesquisa

No processo de pesquisa foram utilizadas as bases de dados *Scopus* e *Web of Science*. Para fazer a pesquisa foram selecionados termos consistentes com os objetivos iniciais e focados no tema de classificação de posturas utilizando sensores de pressão por baixo

do colchão. Assim, a *string* de pesquisa utilizada foi a seguinte: “(lying OR bed*) AND (posture OR position) AND classification AND pressure”.

A pesquisa foi feita em novembro de 2023 e retornou 298 artigos nas bases de dados mencionadas. Dos artigos retornados, 122 artigos foram excluídos: 88 eram estudos com data de publicação anterior a 2013 e 34 artigos foram excluídos por serem duplicados, ou seja, o mesmo estudo estava presente simultaneamente nas bases de dados selecionadas. Resultando em 176 estudos na primeira fase de análise.

2.3. Critérios de Inclusão

Nesta fase foi analisado o título e resumo dos artigos selecionados para filtrar quais deles se enquadraram nos critérios de inclusão e devem ser analisados posteriormente e quais os que devem ser excluídos. Foram incluídos os estudos que cumpriram os seguintes critérios:

1. Estudos que usaram sensores de pressão;
2. Estudos que usaram sensores por baixo do colchão;
3. Estudos que definem a *accuracy* dos resultados;
4. Estudos que exemplificam os algoritmos/modelos utilizados.

Todos os estudos que atenderam a esses critérios foram incluídos para análise posterior. Após esta etapa foram excluídos 137 artigos, dos quais o seu contexto ou objetivos não coincidem com as questões dos critérios de inclusão. Ficando a restar 39 artigos.

2.4. Critérios de Exclusão

Os 39 artigos foram analisados para avaliar se poderiam ser incluídos na análise aprofundada. Para esta etapa, cada artigo foi lido para extrair as respostas às questões de investigação identificadas. Foram excluídos artigos sem informações suficientes sobre os modelos/algoritmos que foram utilizados para a extração e classificação das posturas e também aqueles que não continham informações sobre os resultados obtidos. Excluíram-se estudos com acesso limitado e em que o contexto se desviava do objetivo principal, ou seja, o uso de sensores de pressão posicionados por baixo do colchão. Nesta etapa foram excluídos 36 artigos restando assim 3 artigos para serem analisados.

2.5. Resultados

O diagrama apresentado na Figura 1 ilustra o processo de pesquisa, inclusão e exclusão dos estudos originalmente encontrados nas bases de dados selecionadas. Inicialmente foram encontrados 298 artigos. Após serem identificados permaneceram 176. Dos 122 excluídos, nesta etapa, 88 estudos foram publicados previamente ao ano

de 2013 e 34 foram estudos que se encontravam em ambas as bases de dados, eram estudos duplicados.

Na etapa de inclusão de artigos, analisaram-se os 176 estudos pelo seu título e resumo, com o objetivo de verificar se o seu contexto era aplicável às questões de pesquisa inicialmente determinadas. Desses 176, 116 estudos foram removidos logo de partida pelo seu título não corresponder ao tema abordado neste trabalho. E 21 estudos foram excluídos pelo seu resumo conter informação que contrariava os objetivos e questões propostas.

Na etapa de exclusão, foram excluídos no total 36 estudos dos 39 restantes após a última triagem. 31 estudos desviavam-se do contexto principal, ou seja, da utilização de sensores posicionados por baixo do colchão. 3 estudos foram excluídos por serem sobre o mesmo trabalho, sendo escritos pelos mesmos autores e contendo os mesmos métodos de execução. E 2 estudos foram excluídos pelo simples facto de serem de acesso restrito. Os restantes 3 estudos foram incluídos para análise.

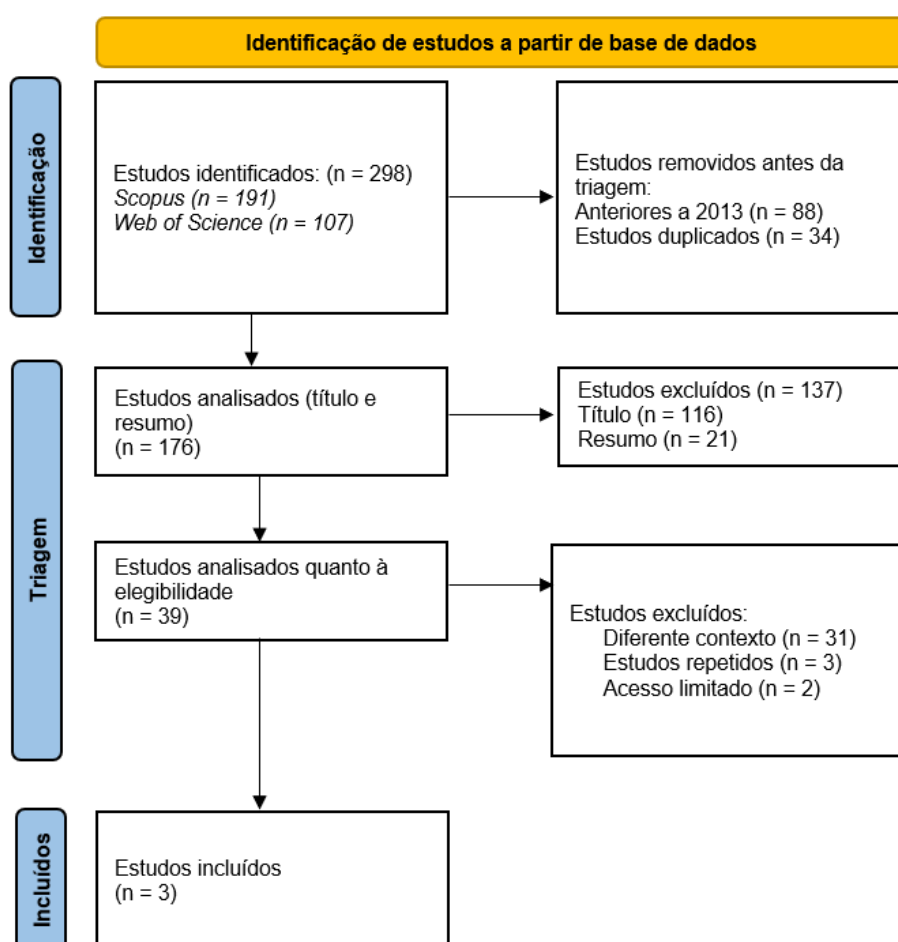


Figura 1 - Processo de seleção de estudos com base na pesquisa e critérios de inclusão e exclusão.

2.6. Análise dos Estudos Incluídos

Identificados os artigos a incluir na revisão, nesta seção foi feita uma análise mais aprofundada sobre o contexto e conteúdo desses estudos. A análise teve como objetivo e foco responder às perguntas de pesquisa previamente mencionadas. A Tabela 2 corresponde às informações extraídas de cada um dos artigos selecionados e que foram selecionadas de forma a permitir responder a cada uma das questões de pesquisa. Cada linha representa um estudo analisado.

Na extração de informação de cada artigo, foram identificadas várias propriedades relevantes:

- “Ref” significa a referência do artigo analisado.
- “#Amostras” representa o número de amostras do dataset que foi utilizado.
- “Participantes” representa o número de indivíduos representados no dataset de cada artigo.
- “#Posturas” significa o número de posturas que foram consideradas.
- “Sensores” representa o número e as características dos sensores que foram utilizados na recolha de informação para o dataset.
- “Algoritmos” representam os algoritmos ou modelos que foram utilizados em cada estudo.
- “Accuracy %” representa a *accuracy*, em percentagem, obtida na classificação de posturas pelos algoritmos utilizados.

A tabela 2 apresenta a informação extraída a partir de cada um dos artigos.

Tabela 2 - Resumo da informação dos estudos selecionados na revisão sistemática.

Ref.	#Amostras	Participantes	#Posturas	Sensores	Algoritmos	Accuracy%
[18]	300 000	3	5 fora da cama, sentado, deitado no centro, deitado à esquerda e deitado à direita.	4 Painel de sensores, 60x18 cm; 2 sensores piezoelétricos; 2 sensores de pressão.	Redes Neurais (NN) + Rede <i>Bayesian</i>	5 Posturas: 91.50% 3 Posturas: 89.9%
[19]	-	58	4 Deitado virado para cima (supino), deitado virado para baixo (prono), lateral direita e lateral esquerda.	4 Sensores hidráulico; 4 tubos de água cada um com um sensor de pressão.	Rede Neuronal Feedforward (FFNN) K-Fold e LOSO	K-Fold: 99% LOSO: 93%
[20]	-	84	3 Deitado (supino +	72 Tapetes de sensores de	TCN	Body-Position: 95.8%

			prone), lateral direita, lateral esquerda	pressão com 3 linhas de 8 sensores de pressão		
--	--	--	---	---	--	--

De seguida apresenta-se um resumo de cada um dos artigos selecionados. O objetivo do resumo foi encontrar os dados utilizados em cada estudo e quais as suas características, que tipos de sensores foram utilizados, quais os modelos ou algoritmos que foram utilizados e quais os resultados, com foco na *accuracy* em que o algoritmo consegue prever a postura ou posição de um participante deitado na cama.

Os autores do estudo *Bed Posture Classification using Noninvasive Bed Sensors for Elderly Care* [18], propõem uma classificação de posições na cama para cuidados de idosos, com o objetivo de prevenir que caiam das suas camas. Os dados foram recolhidos através de um painel de sensores, de tamanho 60x18 cm, equipado com 2 pares de tipos de sensores, 2 sensores piezoelétricos e 2 sensores de pressão. O painel foi posicionado por baixo do colchão na área do torácico permitindo assim saber quando a pessoa está deitada ou sentada. Os autores consideraram 5 posições para a recolha de dados, fora da cama, sentado, deitado no centro, deitado à esquerda e deitado à direita. A posição de sentado, não é uma escolha comum que seja considerada em outros estudos, mas neste os autores mencionam que a posição de sentado é muito importante para detetar a entrada e saída da cama. A recolha de dados foi feita com 3 participantes idosos, com idades entre 60 e 85 anos. Para avaliar o efeito do ambiente, a recolha de dados foi feita em dois quartos diferentes com conjuntos de sensores diferentes. Na avaliação do dataset foram definidas 5 categorias: participante A, participante B, participante C, combinação dos participantes no mesmo quarto, A e B, e a combinação dos dados dos diferentes quartos, participantes A, B e C. O dataset do participante A consistia em 2000 amostras (5 posições x 400 amostras) e o mesmo para o participante B, ambos os participantes fizeram as amostras no mesmo quarto. O dataset do participante C, em que as amostras foram recolhidas num quarto diferente, consistia em 1 335 amostras (5 posições x 267 amostras). No total foram recolhidas 5 335 amostras (5 posições x 1067 amostras). Na deteção de posições, foi utilizado o modelo de redes neuronais em que utilizaram como parâmetros de entrada o sinal esquerdo do piezoelétrico, o sinal direito piezoelétrico, o sinal de pressão esquerdo e o sinal de pressão da direita. Como os valores dos dois tipos de sensores são diferentes, os valores foram normalizados em vez de utilizar os valores brutos para eliminar os preconceitos do peso de diferentes pessoas. Em termos de resultados, numa performance geral o modelo baseado em entradas normalizadas consegue atingir melhores resultados, tendo o parâmetro de 120 entradas com sinal normalizado tido uma percentagem de *accuracy* de 100%. Também foi feito um teste em que se combinaram as redes neuronais com o modelo de rede *Bayesiana* para se conseguir estimar as próximas posições de transição possíveis. Para este efeito, da junção das redes neuronais e da rede *Bayesiana*, os autores estenderam o dataset do participante

A de 2000 para aproximadamente 300000 amostras, mencionando que este dataset não foi limpo, ou seja, contém ruído ao contrário do anterior. Os autores concluem, que é possível melhorar a performance da rede neuronal aplicando a probabilidade da rede *Bayesiana* e identificando a melhor proporção adequada para a combinação do peso. A *accuracy* final, utilizando 5 posições e as duas redes, foi de 91.50%. Neste estudo, também foi feito um teste com só 3 posições que obteve um resultado de 89.9%. Embora considere 5 posições, estas consideram mais o posicionamento do paciente na cama e a sua posição sentado ou deitado do que efetivamente as diferentes posturas que uma pessoa acamada pode assumir.

Em *Sleep Classification Using Bed Sensor Data and Neural Networks* [19], os respectivos autores apresentam uma classificação de posturas através de uma rede neuronal simples e o estudo de diferentes combinações de parâmetros para determinar qual a melhor configuração. Neste estudo foram usados sensores hidráulicos posicionados por baixo do colchão. Estes eram compostos por um conjunto de 4 tubos de água, cada um equipado com um sensor de pressão. Na extração de dados, foram incluídos 58 participantes jovens de boa saúde. Cada participante deitou-se na cama posicionando-se em 4 posturas predefinidas: deitado virado para cima (supino), deitado virado para baixo (prono), lateral direita e lateral esquerda. Para o processamento de classificação, os autores utilizaram a rede neuronal *feedforward* juntamente com a *API* do *Matlab* que permitiu definir manualmente os parâmetros desta rede, tais como o número de camadas, o número de nós por camada, a função de ativação e a quantidade de regularização. Os autores também utilizaram métodos de avaliação de classificação, o *K-Fold* (10 *folds*) e o *Leave-One-Subject-Out* (*LOSO*) para verificar qual as melhores configurações para cada problema de classificação. Com um resultado médio de 99% para o *K-Fold* e 93% para o *LOSO*.

O trabalho intitulado *Sleep-Wake and Body Position Classification with Deep Learning using Pressure Sensor Mat Measurements* [20] teve como objetivo a classificação de posturas e diferenciar o estado de acordado e a dormir em participantes com problemas de sono. Foram utilizados sensores de pressão colocados por baixo do colchão juntamente com *polysomnography*. *Polysomnography* é um teste que monitoriza o sono da pessoa para ajudar a diagnosticar problemas de sono. Somente 3 posturas foram consideradas, deitado virado para cima, lateral direita e lateral esquerda. Neste estudo foram utilizados tapetes de sensores de pressão, posicionados por baixo do colchão que usam fibra ótica para determinar a pressão aplicada. Cada um destes tapetes tem 3 linhas de 8 sensores de pressão separados por 10cm em que preenchem uma área de 80x25cm. O estudo foi feito em dois quartos diferentes contendo 6 tapetes de sensor de pressão. A recolha de dados foi feita com 84 participantes com possíveis problemas de sono. Para o teste de classificação de posturas foram utilizados os 84 participantes e no teste de diferenciar o estado de acordado e a dormir foram utilizados 70 participantes. Os autores utilizaram os modelos *Temporal Convolutional Network* (*TCN*) para a classificação da diferenciação do estado acordado e a dormir. Utilizaram um modelo do *TCN* que inclui 4 blocos de

TCN com 64 filtros de tamanho 15, 5% taxa de abandono e a entrada de dados são os dados dos tapetes de sensores de pressão que foram combinados num único canal com o algoritmo *SNR-Max*. Para a classificação das posturas dos indivíduos foi utilizado um modelo *TCN* que consiste em 1 bloco de *TCN* com 128 filtros de tamanho 15 e 5% de taxa de abandono. Os dados de entrada foram os dados dos tapetes de sensores de pressão sem filtragem, brutos. No final, os autores obtiveram uma *accuracy* geral de 0.958 (95.8%) para a classificação da postura dos participantes na cama e na classificação na diferenciação de estado acordado e a dormir obtiveram 91.3% e 66.6% respetivamente.

2.7. Discussão

Na revisão de literatura realizada sobre a classificação de posturas com base em sensores de pressão, a pesquisa centralizou-se principalmente em soluções de reconhecimento de posturas para indivíduos acamados, destacando que a maioria dos métodos de classificação de posturas baseados em sensores de pressão utiliza dados provenientes de sensores posicionados sobre o colchão, alcançando uma *accuracy* de pelo menos 95% para as quatro principais posturas (ex. [12], [21]). No entanto, soluções que utilizam dados de sensores colocados por baixo do colchão são limitadas.

Com base na revisão de literatura, três artigos foram selecionados para a revisão, pois descreviam o uso de sensores posicionados por baixo do colchão, os algoritmos/métodos utilizados e resultados obtidos.

O estudo [18] propõe uma solução para reconhecimento de posturas de idosos na cama, utilizando um painel de sensores colocado por baixo do colchão, equipado com dois sensores piezoelétricos e dois sensores de pressão. Os dados foram recolhidos de três participantes idosos, em dois quartos diferentes, com cinco posições consideradas: fora da cama, sentado, deitado no centro, à esquerda e à direita. No total, foram recolhidas 5335 amostras. A combinação de redes neuronais com redes Bayesianas melhorou a performance, alcançando 91,5% de *accuracy* para as cinco posições. A posição "sentado" destacou-se por ser relevante para detetar a entrada e saída da cama.

Os autores de [19] descrevem a utilização de diferentes configurações de parâmetros para a classificação de posturas usando a rede neuronal *feedforward*. Os dados foram recolhidos de 58 participantes jovens e saudáveis, que se posicionaram em quatro posturas: supino, prono, lateral direita e lateral esquerda. Sensores hidráulicos, compostos por quatro tubos de água com sensores de pressão, foram posicionados por baixo do colchão para recolha de dados. A avaliação foi feita, utilizando diferentes parâmetros de entrada, com o K-Fold (10 *folds*), que alcançou 99% de *accuracy* média, e *Leave-One-Subject-Out (LOSO)* com 93% de *accuracy*.

O estudo [20] propõe a classificação de posturas e a diferenciação entre os estados de acordado e a dormir em participantes com problemas de sono. Foram utilizados tapetes de sensores de pressão com fibra ótica, posicionados por baixo do colchão, e

polysomnography, uma técnica de monitorização de sono. Cada sensor tapete 3 linhas de 8 sensores, cobrindo uma área de 80x25cm. O estudo incluiu 84 participantes para a classificação de posturas e 70 para a diferenciação entre acordado e a dormir. Para a classificação de estados, foi utilizado o algoritmo Temporal Convolutional Network (TCN), alcançando 91,3% e 66,6% de *accuracy* para os dois estados, respetivamente. Na classificação de posturas, foi usado o TCN com a classificação cruzada *LOSO* usando as 3 posturas (deitado virado para cima, lateral direita, lateral esquerda), atingindo uma *accuracy* de 95,8%.

A análise dos estudos revelou as seguintes perceções sobre as questões de pesquisa identificadas:

- Q1. A falta de estudos que utilizam sensores posicionados por baixo do colchão é destacada, em comparação com a maior prevalência de soluções que utilizam sensores por cima do colchão. Os estudos analisados usaram sensores de pressão com diferentes configurações de *hardware*, variando no número e organização dos sensores.
- Q2. Embora alguns *datasets* tenham um número razoável de participantes, não ficou claro como foram construídos, especialmente em relação à posição dos participantes ou ao número de réplicas medidas.
- Q3. Os estudos classificaram um número limitado de posturas, geralmente menos de quatro. Um estudo classificou com base na posição da pessoa na cama, e não na postura (deitado ou sentado) [18], outro estudo fez a distinção entre posturas laterais e não laterais, combinando posturas deitado (prono e supino) e deitado de lado (direita e esquerda) [19], enquanto o último estudo [20], considerou apenas três posturas, agrupando as posturas de deitado virado para baixo e deitado virado para cima.
- Q4. Redes neurais foram usadas em todos os estudos para a classificação de posturas.

3. Metodologia

Este capítulo detalha as etapas de processamento e validação dos algoritmos selecionados para a classificação de posturas de pessoas acamadas, utilizando dados capturados por sensores de pressão. A metodologia foi organizada em três fases principais: preparação dos dados, construção e treino do modelo, e avaliação de desempenho. Apresenta também o *dataset* utilizado e descreve o processo de seleção dos algoritmos a utilizar.

3.1. Fases de Processamento e Validação de Algoritmos

Numa primeira fase, os dados foram analisados e pré-processados para garantir a sua consistência e adequabilidade em termos de formato para cada algoritmo implementado. Na preparação de dados, foram ajustados e normalizados os formatos dos dados adequando-os para os modelos e foi realizada a divisão do *dataset* em grupos de treino e teste. Para evitar que dados de um determinado participante possam estar presentes nos dois grupos (teste e treino), os dados foram primeiro agrupados pelo número identificador de participante e seguidamente uma randomização e distribuição dos dados para cada grupo.

Na segunda fase, para cada algoritmo foi feito um treino e criado o modelo para a realização de um teste inicial usando as métricas *accuracy*, *f1-score* e *recall*. Durante o treino, os algoritmos foram sujeitos a métodos de procura dos melhores parâmetros. Na maioria dos casos foi utilizado o *GridSearchCV*, que consiste numa técnica de otimização de parâmetros que utiliza a validação cruzada, com o objetivo de encontrar a melhor combinação de parâmetros para otimizar a *accuracy* do modelo. Em determinados casos houve a necessidade de implementar outras técnicas de otimização como *Keras Tuner* nomeadamente para algoritmos de *Keras* ou *TensorFlow*.

Na última fase, após a avaliação inicial com a aplicação do *GridSearchCV* e outras técnicas de otimização de parâmetros, foram feitas validações cruzadas para uma avaliação mais robusta e precisa dos modelos. A validação cruzada permitiu avaliar a capacidade de generalização dos algoritmos de forma mais confiável ao utilizar diferentes repartições do conjunto de dados. Foram utilizados dois tipos de validação cruzada, o *Group K-Fold Cross-Validation* e o *Leave-One-Group-Out (LOGO)*. No *Group K-Fold* o *dataset* foi dividido em 5 subconjuntos, não permitindo a sobreposição de grupos e não permitindo que o mesmo participante esteja presente em mais que um grupo. Em cada iteração de validação, um dos subconjuntos é utilizado como conjunto de teste e os restantes como conjuntos de treino. O *LOGO*, é uma variação do *K-Fold*, só que nesta técnica os subconjuntos estão divididos pelo número de observações, neste caso pelo número de participantes. Cada iteração deixa um participante de fora como o conjunto de teste e os restantes utiliza como um conjunto de treino, este processo é repetido dependendo o número total de participantes.

Os resultados foram apresentados através de matrizes de confusão e relatórios de classificação.

Este procedimento foi executado para cada um dos algoritmos/modelos executados.

3.2. Dataset PoPu

No estudo feito para a criação do *dataset PoPu* [16] foram recolhidos diversos dados a partir dos sensores com base em diferentes posturas. O *dataset* inclui 60 participantes, com registo dos seus dados sobre o peso, altura e sexo. O peso dos participantes variou de 45kg a 127kg (média de 74.25kg, com desvio padrão de 17.6), a altura variou de 145cm a 195cm (média de 171.9cm, com desvio padrão de 10.3) e a distribuição do sexo foi de 24 mulheres (40%) e 36 homens (60%).

Os participantes posicionaram-se em 28 diferentes posturas divididas em 7 variações das 4 posturas principais (supino, prone, lateral esquerda e lateral direita). As variações de posturas baseavam-se no posicionamento de todo o corpo, ou seja, existem posturas em que o indivíduo tinha as pernas esticadas, uma sobre a outra ou se estavam dobradas, se tinha almofada sobre a cabeça, debaixo do corpo ou entre as pernas. A recolha de dados resultou em 50400 amostras de dados de pressão.

O *dataset* utiliza o formato de *JavaScript Object Notation (JSON)* e está organizado em 3 pastas que representam cada camada. Cada pasta de camada contém uma pasta para cada um dos 60 participantes. As 3 pastas, representam os dados de pressão dos sensores por baixo do colchão ("*sensomatt_data*"), dos sensores por cima do colchão ("*tactilus_data*") e a segmentação das imagens ("*segmentation_data*"). Nas pastas com os dados dos sensores, para cada pasta de indivíduo existem 3 ficheiros para cada postura com o nome dessa postura e com uma indicação da variação (ex. "*supine1_1*"). Existem também outras pastas, tal como uma pasta ("*empty1*") que contém dados obtidos pelas matrizes de sensores quando não havia participantes na cama. Na pasta de "*segmentation_data*" existe um ficheiro para cada postura nomeada da mesma forma que as pastas com os dados dos sensores, sendo que só existe um ficheiro por postura então neste caso a designação fica só "*supine1*". E existe uma pasta com imagens obtidas dos ficheiros de segmentação, uma para cada postura.

Em termos de equipamentos, foram utilizadas duas matrizes de sensores diferentes. Uma colocada por cima do colchão, que se identifica como uma manta de sensores *Tactilus* com 1729 sensores piezoelétrico distribuídos por uma matriz de 27x64 sensores. Outra por baixo do colchão, em que foi utilizada uma manta de sensores *SensoMatt* que contém 72 sensores para detetar pressão através do contacto omnidirecional. As células foram posicionadas num matiz de 12x6 distribuída por 170cm x 84cm da superfície da manta. Também foram utilizadas almofadas de tamanhos de 50x70cm e de 30x50cm.

Neste trabalho, para a classificação de posturas de pessoas acamadas serão utilizados os dados da manta de sensores *SensoMatt*, que representa os dados obtidos com sensores colocados por baixo do colchão. Tanto quanto é do nosso conhecimento, até esta data, ainda nenhum trabalho utilizou esta componente do *dataset* para classificação de posturas de pessoas acamadas.

3.3. Seleção dos Algoritmos

A seleção de algoritmos para a classificação das posturas consideradas no *dataset* é uma fase importante, pois o desempenho dos resultados depende significativamente do algoritmo escolhido. Nesta seção, será discutida a escolha dos algoritmos selecionados para este estudo e as suas razões.

Numa primeira fase, a escolha de algoritmos baseou-se na revisão sistemática apresentada no capítulo 2. Os estudos [18], [19] e [20] levaram à seleção de algoritmos de redes neuronais. O estudo apresentado em [19] usou o modelo *FeedForward Neural Network (FFNN)*, que é um modelo capaz de capturar relações complexas entre dados de entrada e saída e eficaz em problemas de classificação que envolvem muitas características. O estudo apresentado em [20], utilizou o algoritmo *TCN* que é adequado para dados sequenciais, pois é capaz de capturar dependências temporais de longo prazo e utiliza convoluções casuais que forçam o modelo a utilizar apenas dados passados para fazer previsões em vez de utilizar dados futuros.

Uma vez que a quantidade de estudos analisados no capítulo 2, que se focam em sensores de pressão por baixo do colchão, é bastante reduzida, decidiu-se analisar estudos que utilizaram matrizes de sensores colocadas por cima do colchão para incluir também alguns dos algoritmos mais usados nestes estudos. Neste caso, a seleção dos algoritmos baseou-se na revisão sistemática apresentada em [22] a qual destacou a eficácia e performance de diferentes algoritmos baseados em dados de sensores de pressão. De acordo com a revisão, os algoritmos baseados em redes neuronais convolucionais (*Convolutional Neural Network (CNN)*) e redes neuronais profundas (*Deep Neural Network (DNN)*) apresentaram uma boa performance e *accuracy* na classificação de posturas. Esse estudo refere também que o modelo *KNN* continua a ser utilizado e implementado, mas mais para um aspeto de comparação. Apesar de as performances mais altas serem de redes neuronais, o algoritmo *SVM* foi uma exceção pois obteve uma *accuracy* superior a 99% e por isso será também incluído.

Com base nesta análise, os algoritmos selecionados para este estudo foram: *k-nearest neighbors (KNN)*, *support vector machine (SVM)*, *decision trees (DT)*, *gradient boosting (GB)*, *random forest (RF)*, *naive bayes (NB)*, *temporal convolutional network (TCN)*, *feed forward artificial neural network (FFANN)*, *CNN* e *Resnet-18*.

4. Resultados

Nesta secção são apresentados os experimentos realizados para desenvolver os modelos mais precisos para a classificação de posturas de pessoas acamadas. A escolha dos algoritmos baseou-se em revisões de literatura e na eficácia demonstrada em estudos anteriores, conforme discutido no Capítulo 3.

Como referido previamente, os dados foram divididos em conjuntos de treino e teste, garantindo que nenhum dado do mesmo participante aparecia em ambos os conjuntos simultaneamente, o que ajuda a manter a capacidade do algoritmo de generalizar para novos dados. Várias etapas de pré-processamento, incluindo normalização e codificação de variáveis categóricas, foram realizadas para preparar os dados para o treino do modelo.

Para a implementação dos algoritmos, foram utilizadas bibliotecas como *TensorFlow*, *Keras* e *PyTorch* para os modelos baseados em redes neuronais (*TCN*, *CNN*, *RESNET18*, *FFANN*) e *Scikit-Learn* para algoritmos mais simples como *SVM*, *RF*, *GB*, *DT*, *KNN* e *NB*. No caso de redes neuronais, utilizou-se *keras_tuner* para otimização de hiperparâmetros e *EarlyStopping* para prevenir o *overfitting*. Além disso, modelos pré-treinados da biblioteca *torchvision* foram ajustados no caso do algoritmo *ResNet-18*. Bibliotecas como *Pandas*, *NumPy* e *Pillow* auxiliaram na manipulação e preparação dos dados, enquanto as visualizações foram feitas com *Matplotlib* e *Seaborn*.

Para avaliar de forma abrangente o desempenho dos modelos, foram calculadas as métricas de *accuracy*, *recall* e *f1-score*:

- *Accuracy* reflete a *accuracy* global do modelo.
- *Recall* mede a capacidade do modelo para identificar corretamente as instâncias positivas.
- *F1-Score* equilibra a *accuracy* e a recordação, oferecendo uma métrica única que tem em conta os falsos positivos e os falsos negativos.

Nas secções seguintes são descritos os experimentos e os resultados da aplicação de cada um dos 10 algoritmos selecionados para a classificação das 4 posturas principais, juntamente com um experimento adicional para a classificação de 28 posturas. Para cada experimento é apresentada a otimização dos parâmetros e os resultados das métricas *Accuracy*, *Recall* e *F1-Score*, utilizando o *Group K-Fold Cross-Validation* e *LOGO*.

4.1. Experimentos para a Classificação das 4 Posturas Principais

Nas seções seguintes, são descritos os experimentos realizados e os resultados obtidos com a aplicação de cada algoritmo selecionado para a classificação das quatro posturas principais. Cada subsecção aborda os detalhes de implementação, os parâmetros utilizados e a análise de desempenho de cada modelo.

4.1.1. K-Nearest Neighbors

O *KNN* é um algoritmo de aprendizagem supervisionado que classifica um conjunto de dados com base nos pontos mais próximos em determinado espaço de características.

No processo de treino, foi utilizada a biblioteca *GridSearchCV* para permitir encontrar a melhor combinação de parâmetros, obter os melhores resultados possíveis e aumentar *accuracy* do modelo. Para o *KNN*, os parâmetros adaptados foram o número de vizinhos (*n_neighbors*) e a métrica de distância (*metric*). Após uma procura inicial, concluiu-se que os melhores parâmetros foram *n_neighbors=6* e *metric='manhattan'* que alcançou uma *accuracy* de 97.38%. Na avaliação do modelo foram consideradas as métricas *accuracy*, *recall* e *f1-score*.

Com estes parâmetros foram obtidos os resultados apresentados na Tabela 3.

Tabela 3 - Resultados da avaliação inicial de *KNN*.

Accuracy	93.66%
Recall	93.66%
F1-Score	93.65%
Parâmetros	<i>n_neighbors =6;</i> <i>metric='manhattan';</i>

Foi também produzido, e analisado, o relatório de classificação que permite fornecer uma visão da capacidade do modelo em classificar as posturas corretamente. Na Tabela 4, pode-se observar que o modelo obteve um bom desempenho para a classificação das posturas, com uma *accuracy* média de 93.66%. Estes resultados indicam que o modelo é capaz de classificar corretamente a maioria das instâncias conseguindo obter valores de *accuracy* entre 91.99% para a postura virado para baixo e 95.84% para a postura lateral esquerda.

Tabela 4 - Resultados do relatório de classificação de *KNN*.

Postura	Relatório de Classificação		
	Accuracy	Recall	F1-Score
Lateral esquerda	95.84%	90.82%	93.26%
Virado para baixo	91.99%	93.89%	92.93%
Lateral direita	94.69%	92.88%	93.78%
Virado para cima	92.37%	97.06%	94.66%
Accuracy Média	93.66%		

Nos resultados de *recall*, pode-se observar que as posturas classificadas com maior *accuracy* são as que menor *recall* têm. lateral esquerda e lateral direita foram

classificadas com uma *accuracy* de 95.84% e 94.69%, respetivamente, mas os seus valores de *recall* são de 90.82% e 92.88%. Isso mostra que, apesar de alta *accuracy*, o modelo teve dificuldades em classificar estas posturas, ao contrário das posturas de virado para baixo e virado para cima, que apesar de classificadas com menores valores de *accuracy*, 91.99% e 92.37%, obtiveram um *recall* mais alto, 93.89% e 97.06%, respetivamente. Sendo que o modelo teve maior facilidade em classificar estas duas posturas. Em termos dos valores de *f1-score*, estes variam entre 93.3% e 94.8% que indica que existe um equilíbrio entre os valores de *accuracy* e *recall*.

A matriz de confusão, apresentada na Figura 2, permite fazer uma análise com maior detalhe sobre os “verdadeiros positivos”, “verdadeiros negativos”, “falsos positivos” e “falsos negativos”, comparativamente a cada uma das posturas.




Figura 2 - Matriz de confusão de KNN.

Após a implementação do algoritmo e o treino e validação do modelo, foi feita uma validação cruzada com o método de *Group K-Fold*. O objetivo era a verificação da consistência da *accuracy* do modelo. A Figura 3 mostra a distribuição dos participantes durante o processo de validação cruzada. Os dados foram divididos em 5 subconjuntos, em que cada iteração um deles é usado como conjunto de teste e os restantes são considerados conjuntos de treino.




Figura 3 - Distribuição de participantes no Group K-Fold.

Como mostra a Tabela 5, a média de *accuracy* da validação cruzada foi de 92.02%, com valores de *accuracy* compreendidos entre 87.59% a 96.06%.

Tabela 5 - Resultados de avaliação cruzada K=5.

Fold	Accuracy	Recall	F1-Score
1	96.06%	96.06%	96.06%
2	87.59%	87.59%	87.54%
3	92.03%	92.03%	92.06%
4	93.71%	93.71%	93.70%
5	90.70%	90.70%	90.74%
Média	92.02%	92.02%	92.02%

A Figura 4 mostra a frequência dos melhores parâmetros que foram utilizados durante a validação cruzada. Com a métrica sendo sempre o valor de *manhattan* e o número de vizinhos entre o valor 6 e o valor 8.

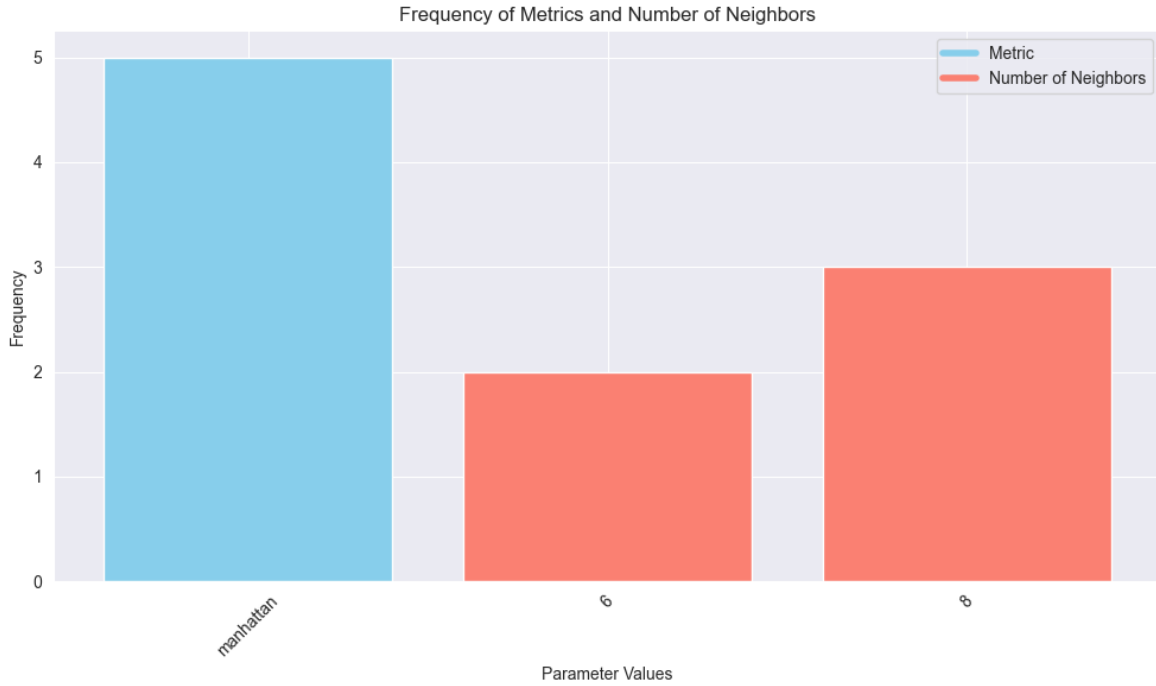


Figura 4 - Frequência de melhores parâmetros.

Foi também feita uma validação cruzada usando LOGO, garantindo que os dados de cada participante não aparecem simultaneamente nos conjuntos de treino e teste. Para cada iteração do LOGO, o algoritmo *KNN* foi treinado e avaliado garantindo sempre que utiliza os melhores parâmetros. Os resultados da validação do LOGO alcançaram uma média de *accuracy* de 93.28%, um *recall* de 93.19%, e um *f1-score* de 93.28%, como mostrado na figura 5. O valor de *recall* não é visível no gráfico devido à sua proximidade com o valor de *accuracy*, pelo que as linhas se encontram sobrepostas.




Figura 5 - Gráfico de performance de participantes.

4.1.2. Support Vector Machine

No processo de treino de *SVM*, foram considerados os parâmetros de regularização *C*, o *kernel* e a *gamma*. Após a procura inicial, a melhor combinação de parâmetros foi de $C=1$, $gamma=scale$ e $kernel=rbf$ que permitiu obter valores de *accuracy* de 97.16% na fase de treino. Na avaliação do modelo, usando a combinação com melhor *accuracy* adquirida durante o treino, os resultados do teste são apresentados na Tabela 6.

Tabela 6 - Resultados iniciais de SVM.

Accuracy	98.54%
Recall	98.54%
F1-Score	98.54%
Parâmetros	$C=1$; $Gamma=scale$; $Kernel=rbf$

Na avaliação inicial foram produzidos e analisados o relatório de classificação e a matriz de confusão que se podem observar na Tabela 7 e na Figura 6. O modelo obteve um desempenho para a classificação das posturas com uma *accuracy* média de 98.54%. Nos resultados da Tabela 7, pode-se observar que houve um equilíbrio entre todos os valores, não havendo uma grande discrepância, mostrando que o modelo classifica as posturas de uma forma equilibrada.

Tabela 7 - Resultados do relatório de classificação de SVM.

Postura	Relatório de Classificação		
	Accuracy	Recall	F1-Score
Lateral esquerda	98.52%	97.17%	97.84%
Virado para baixo	97.90%	99.79%	98.83%
Lateral direita	98.86%	98.65%	98.76%
Virado para cima	98.91%	98.57%	98.74%
Accuracy Média	98.54%		

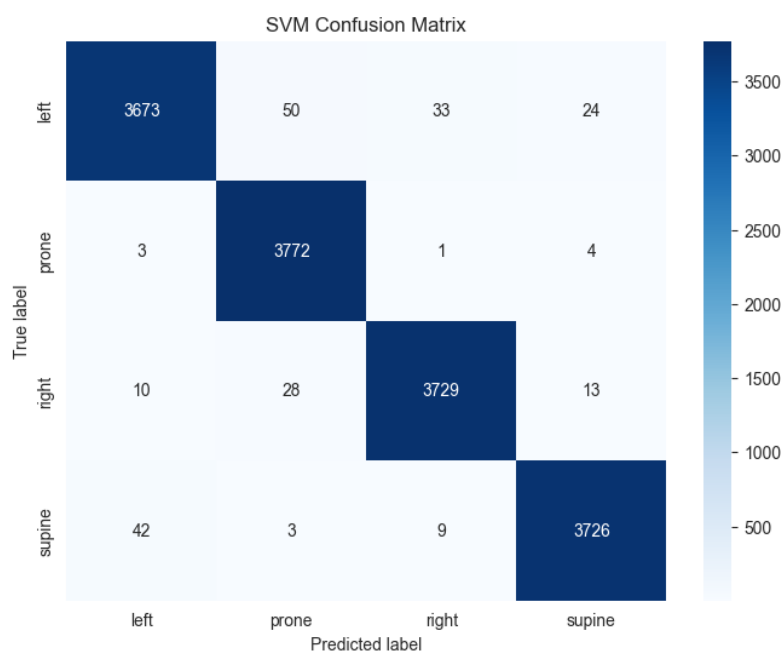


Figura 6 - Matriz de confusão de SVM.

Na validação cruzada do *SVM* os resultados são apresentados na Tabela 8. Pode-se observar que são obtidos valores de *accuracy* entre 94.70% e 98.5%, sendo a média de 96.55%.

Tabela 8 - Resultados de validação cruzada de SVM.

Fold	Accuracy	Recall	F1-Score
1	98.65%	98.65%	98.65%
2	94.70%	94.70%	94.69%
3	95.98%	95.98%	95.99%
4	96.31%	96.31%	96.31%
5	97.10%	97.10%	97.11%
Média	96.55%	96.55%	96.55%

A Figura 7 mostra a frequência dos melhores parâmetros. Observando que para *C* os valores são de 10 ou 1, para *gamma* é sempre o *scale* e para o *kernel* é o *rbf*.




Figura 7 - Frequência de melhores parâmetros de SVM.

Na validação cruzada, usando *LOGO*, o algoritmo *SVM* obteve uma *accuracy* média de 97.14%, um *recall* de 97.07% e um *f1-score* de 97.14%.

Na Figura 8 pode-se observar a performance dos participantes durante a validação cruzada.




Figura 8 - Gráfico de performance de participantes.

4.1.3. Decision Trees

No processo de treino de *DT*, foram considerados os parâmetros de *criterion*, *splitter*, *max_depth*, *min_samples_split*, *min_samples_leaf*, *max_features* e *max_leaf_nodes*. Com o treino inicial, a melhor combinação de parâmetros obtida foi de *criterion=gini*, *max_depth=None*, *max_features=None*, *max_leaf_nodes=None*,

$min_samples_leaf=4$, $min_samples_split=2$, $splitter=random$, que obteve uma *accuracy* de 83.21%.

Na fase de teste, o modelo conseguiu obter uma *accuracy* de 77.08%, como se observa na Tabela 9.

Tabela 9 - Resultados iniciais de DT.

Accuracy	77.08%
Recall	77.08%
F1-Score	77.05%
Parâmetros	<i>criterion = gini;</i> <i>max_depth = None;</i> <i>max_features = None;</i> <i>max_leaf_nodes = None;</i> <i>min_samples_leaf = 4;</i> <i>min_samples_split = 2;</i> <i>splitter = random.</i>

Com o treino e teste iniciais foram produzidos o relatório de classificação e a matriz de confusão, os quais estão apresentados na Tabela 10 e na Figura 9. Neste caso, o modelo não obteve o melhor desempenho para a classificação das posturas, comparado com modelos anteriores. Pela análise da Tabela 10 pode-se observar que, apesar de obter valores mais baixos, as posturas de virado para cima e lateral direita foram as que obtiveram uma *accuracy* mais alta com 80.21% e 81.14% respetivamente. Mas com um *recall* menor, o que indica que o modelo teve dificuldades em classificar estas posturas. Verifica-se o contrário nas posturas de lateral esquerda e virado para baixo, com valores de *accuracy* de 73.80% e 74.33%, mas com valores de *recall* de 84.37% e 76.46%. A postura de lateral esquerda, foi a que mais facilmente o modelo conseguiu classificar. O valor de *f1-score* manteve-se equilibrado entre os valores de 75.38% e 78.73%.

Tabela 10 - Resultados do relatório de classificação de DT.

Postura	Relatório de Classificação		
	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
Lateral esquerda	73.80%	84.37%	78.73%
Virado para baixo	74.33%	76.46%	75.38%
Lateral direita	81.14%	75.24%	78.08%
Virado para cima	80.21%	72.28%	76.04%
Accuracy Média	77.08%		




Figura 9 - Matriz de confusão de DT.

Na Tabela 11 são apresentados os resultados da validação cruzada de DT. Como se pode observar os valores de *accuracy* encontram-se entre 76.23% e 83.23%, sendo que a primeira iteração foi a que apresentou melhor *accuracy* e os valores das iterações seguintes apresentaram uma *accuracy* mais reduzida. A média de *accuracy* da avaliação cruzada foi de 79.14%.

Tabela 11 - Resultados de validação cruzada de DT.

Fold	Accuracy	Recall	F1-Score
1	83.23%	83.23%	83.19%
2	76.11%	76.11%	76.14%
3	78.80%	78.80%	78.87%
4	77.66%	77.66%	77.61%
5	79.88%	79.88%	79.87%
Média	79.14%	79.14%	79.14%

A Figura 9 mostra a frequência dos melhores parâmetros usados em cada iteração, sendo que os parâmetros de *min_sample_leaf* e *max_depth* são os que mais se alteram.




Figura 10 - Frequência de melhores parâmetros de DT.

Na última validação cruzada, no *LOGO*, o algoritmo *DT* obteve uma média de *accuracy* de 80.03%, um *recall* de 79.60% e um *f1-score* de 80.00%, como apresentado na Figura 11, que mostra a performance de cada participante na avaliação cruzada. Observa-se que, apesar de os valores serem mais baixos que outros modelos, ainda assim consegue classificar as posturas, e em determinados participantes os valores de *accuracy* são relativamente altos.




Figura 11 - Gráfico de performance de participantes.

4.1.4. Random Forest

No processo de treino do RF, foram considerados os parâmetros *n_estimators*, *max_features*, *min_samples_split*, *min_samples_leaf* e *criterion*. Com o treino inicial do modelo, foi obtida uma *accuracy* de 95.95% com a combinação de parâmetros de *n_estimators*=300, *max_features*=log2, *min_samples_split*=2, *min_samples_leaf*=1 e *criterion*=gini.

Na fase de teste, o modelo obteve uma *accuracy* de 93.79%, como apresentado na Tabela 12.

Tabela 12 - Resultados iniciais de RF.

Accuracy	93.79%
Recall	93.79%
F1-Score	93.82%
Parâmetros	<i>n_estimators = 300; max_features = 'log2'; min_samples_split = 2; min_samples_leaf = 1; criterion = 'gini';</i>

O relatório de classificação está representado na Tabela 13 e a Figura 12 representa a matriz de confusão, elementos produzidos através do teste inicial do modelo. Conforme apresentado na Tabela 13, o modelo obteve um desempenho para a classificação das posturas com uma *accuracy* média de 93.80%. Sendo que a classificação das posturas lateral esquerda, lateral direita e virado para cima são as que obtiveram maior *accuracy*. Mas as duas primeiras tiveram um *recall* mais baixo, o que significa que o modelo teve maior dificuldade em classificar estas posturas. A postura virado para cima, apesar de obter uma *accuracy* alta, também obteve um *recall* alto, com um valor de 97.14%, ao contrário das duas anteriores. A postura virado para baixo, foi a que obteve menor *accuracy*, com um valor de 85.47%, mas com um *recall* de 98.65%.

Tabela 13 - Resultados do relatório de classificação de RF.

Postura	Relatório de Classificação		
	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
Lateral esquerda	97.09%	90.03%	93.42%
Virado para baixo	85.47%	98.65%	91.59%
Lateral direita	97.66%	89.37%	93.33%
Virado para cima	96.81%	97.14%	96.98%
Accuracy Média	93.80%		




Figura 12 - Matriz de confusão de RF.

Os resultados da validação cruzada do *RF* estão apresentados na Tabela 14. O valor de *accuracy* mantém-se entre 92.09% e 96.37%, e sendo a *accuracy* média da avaliação cruzada de 94.19%.

Tabela 14 - Resultados de validação cruzada de RF.

<i>Fold</i>	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
1	96.37%	96.37%	96.37%
2	92.09%	92.09%	92.15%
3	93.56%	93.56%	93.57%
4	94.53%	94.53%	94.53%
5	94.40%	94.40%	94.41%
Média	94.19%	94.19%	94.21%

A Figura 13 apresenta a frequência dos parâmetros utilizados na validação cruzada. Sendo que o parâmetro de *min_samples_split* foi o que mais se alterou.

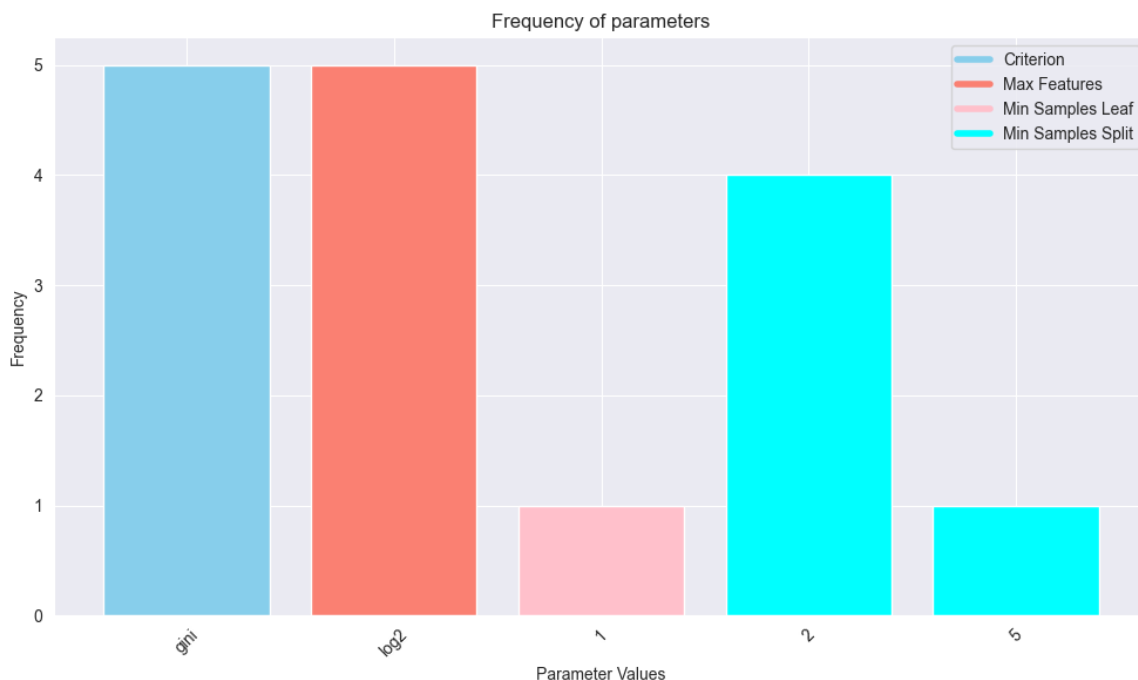


Figura 13 - Frequência de melhores parâmetros de RF.

Na última validação cruzada, no LOGO, o algoritmo *RF* obteve uma média de *accuracy* de 94.70%, um *recall* de 94.52% e um *f1-score* de 94.70%. A Figura 14 representa a performance dos participantes na validação cruzada e mostra que o *RF* obteve um bom desempenho na classificação de posturas durante as iterações da validação.




Figura 14 - Gráfico de performance de participantes.

4.1.5. Gradient Boosting

No processo de treino do *GB* foram considerados os parâmetros *n_estimators* e *learning_rate*. No treino inicial, o modelo obteve uma *accuracy* de 96.52% com a combinação de parâmetros de *n_estimators*=300 e *learning_rate*=0.5.

Na fase de teste, o modelo obteve uma *accuracy* de 94.61%, como apresentado na Tabela 15.

Tabela 15 - Resultados iniciais de RF.

Accuracy	94.61%
Recall	94.61%
F1-Score	94.61%
Parâmetros	<i>n_estimators</i> = 300; <i>learning_rate</i> = 0.5;

O relatório de classificação está representado na Tabela 16 e a Figura 15 representa a matriz de confusão, ambos produzidos pelo teste do modelo de GB. Observando a Tabela 16, o modelo obteve um bom desempenho para a classificação das posturas com uma média de *accuracy* de 94.62%. A postura de lateral esquerda é a que obteve uma *accuracy* mais elevada, com 99.04%, mas o seu valor de *recall* foi o mais baixo, com 87.41%. Verifica-se que o modelo teve mais dificuldade em classificar esta postura. Enquanto a postura virado para baixo foi a que obteve uma *accuracy* mais baixa, de 87.17%, mas o modelo facilmente a conseguiu classificar notando que o seu valor de *recall* é o mais alto verificando uma percentagem de 99.58%.

Tabela 16 - Resultados do relatório de classificação de GB.

Postura	Relatório de Classificação		
	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
Lateral esquerda	99.04%	87.41%	92.86%
Virado para baixo	87.17%	99.58%	92.96%
Lateral direita	97.98%	92.41%	95.11%
Virado para cima	96.00%	99.07%	97.51%
Accuracy Média	94.62%		




Figura 15 - Matriz de confusão de GB.

Os resultados da validação cruzada do GB são apresentados na Tabela 17. Os valores de *accuracy* mantêm-se entre os valores de 94.43% e 97.90%. Sendo a *accuracy* média da validação cruzada de 95.77%.

Tabela 17 - Resultados de validação cruzada de GB.

<i>Fold</i>	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
1	97.90%	97.90%	97.90%
2	94.43%	94.43%	94.44%
3	94.56%	94.56%	94.56%
4	95.45%	95.45%	95.45%
5	96.52%	96.52%	96.52%
Média	95.77%	95.77%	95.77%

A Figura 16 apresenta a frequência dos parâmetros utilizados na validação cruzada, sendo que ambos os parâmetros usados mantiveram sempre o valor em cada iteração.




Figura 16 - Frequência de melhores parâmetros de GB.

Na última validação cruzada, no LOGO, o algoritmo GB obteve uma média de *accuracy* de 96.63%, um *recall* de 96.54% e um *f1-score* de 96.63%, demonstrando na Figura 17, e que o GB obteve um bom desempenho na classificação de posturas durante as iterações da validação. A Figura 17 apresenta a performance de cada participante durante a avaliação cruzada de LOGO.




Figura 17 - Gráfico de performance de participantes

4.1.6. Naive Bayes

No processo de treino do NB, foi considerado o parâmetro *var_smoothing*. No treino inicial, o modelo obteve uma *accuracy* de 83.22% com a combinação de parâmetros de *var_smoothing*= 0.04329. Na fase de teste, o modelo obteve uma *accuracy* de 84.58%, como pode ver-se na Tabela 18.

Tabela 18 - Resultados iniciais de NB.

Accuracy	84.58%
Recall	84.58%
F1-Score	84.66%
Parâmetros	<i>var_smoothing</i> = 0.04329

O relatório de classificação apresentado na Tabela 19 e a matriz de confusão apresentada na Figura 18 foram produzidos pelo teste do modelo de NB. Observando a Tabela 19, verifica-se que o desempenho do modelo na classificação das posturas obteve valores bastante díspares. A postura virado para cima foi a que obteve uma *accuracy* com maior valor, de 94.32%. Por outro lado, a postura lateral direita foi a que obteve a menor *accuracy* com um valor de 76.92%. As posturas lateral esquerda e virado para baixo obtiveram uma *accuracy* de 83.74% e 84.92%.

Tabela 19 - Resultados do relatório de classificação de NB.

Postura	Relatório de Classificação		
	Accuracy	Recall	F1-Score
Lateral esquerda	83.74%	85.82%	84.77%
Virado para baixo	84.92%	88.81%	86.82%
Lateral direita	76.92%	80.74%	78.78%
Virado para cima	94.32%	82.96%	88.28%
Accuracy Média	84.58%		




Figura 18 - Matriz de confusão de NB.

Os resultados da validação cruzada do *NB* são apresentados na Tabela 20. O valor de *accuracy* mantém-se entre os valores de 80.64% e 91.61%, sendo a *accuracy* média da validação cruzada de 84.87%.

Tabela 20 - Resultados de validação cruzada de *GB*.

<i>Fold</i>	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
1	91.61%	91.61%	91.61%
2	80.64%	80.64%	80.64%
3	84.63%	84.63%	84.63%
4	86.12%	86.12%	86.12%
5	81.33%	81.33%	81.33%
Média	84.87%	84.87%	84.87%

A Figura 19 mostra a frequência dos parâmetros utilizados na validação cruzada. Em cada iteração foi utilizado um valor diferente para o parâmetro de *var_smoothing*.

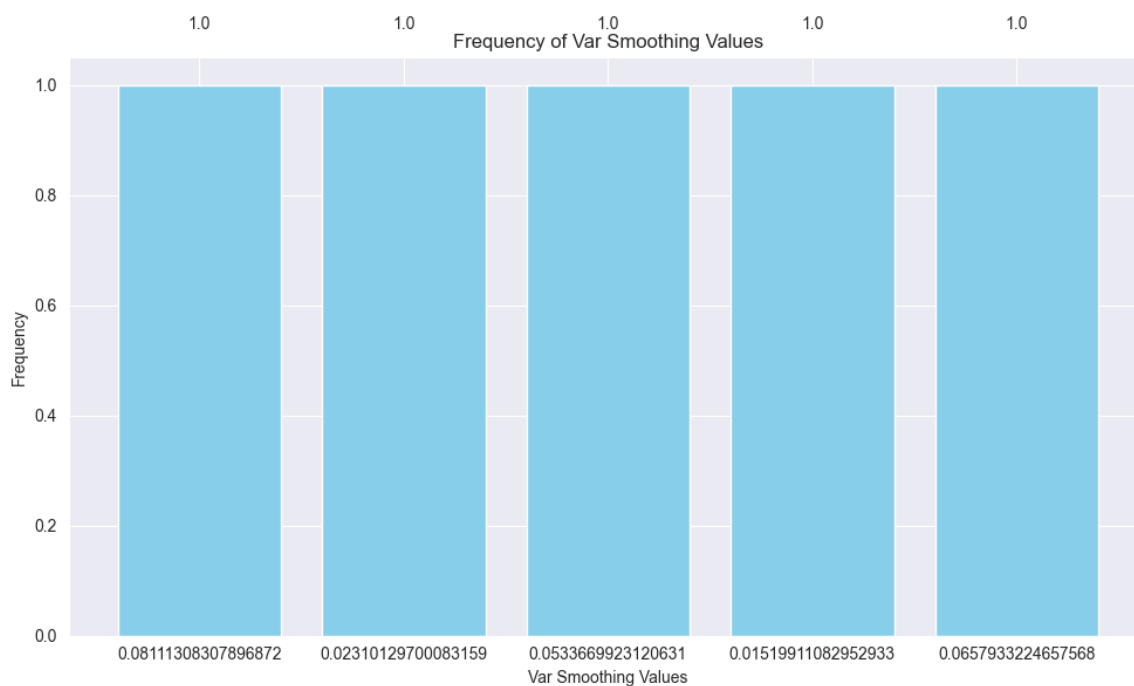


Figura 19 - Frequência de melhores parâmetros de *NB*.

Na última validação cruzada, no *LOGO*, o algoritmo *NB* obteve uma *accuracy* média de 85.00%, um *recall* de 84.30% e um *f1-score* de 85.00%, conforme pode ser observado na Figura 20, tendo valores de *accuracy* menores que os conseguidos por outros modelos avaliados anteriormente.




Figura 20 - Gráfico de performance de participantes.

4.1.7. Feed Forward Artificial Neural Network

No processo de treino de *FFANN*, foram considerados os parâmetros *activation*, *learning_rate*, *hidden_layer_size*, *alpha*, *learning_rate_init*, *batch_size*. No treino inicial, o modelo obteve uma *accuracy* de 97.19% com a combinação de parâmetros de *activation=relu*, *learning_rate=adaptive*, *hidden_layer_size=(100,)*, *alpha=0.0001*, *learning_rate_init=0.001*, *batch_size=128*. Na fase de teste, o modelo obteve uma *accuracy* de 96.48%, como apresentado na Tabela 21.

Tabela 21 - Resultados iniciais de *FFANN*.

Accuracy	96.48%
Recall	96.48%
F1-Score	96.50%
Parâmetros	<i>Activation = relu; learning_rate = adaptive; hidden_layer_size = (100,); alpha = 0.0001; learning_rate_init = 0.001; batch_size = 128;</i>

O relatório de classificação representado na Tabela 22 e a matriz de confusão apresentada na Figura 21 foram produzidos pelo teste do algoritmo de *FFANN*. Observando a Tabela 22, pode-se afirmar que houve valores mais elevados de *accuracy* na classificação das posturas de lateral esquerda, lateral direita e virado para cima com valores de 97.93%, 99.37% e 97.93%, respetivamente. A postura virado para baixo, apesar de não ter um valor de *accuracy* tão elevado como as outras, 91.33%, apresenta o seu valor de *recall* mais elevado, 98.60%, seguida da postura virado para cima com *recall* de 98.25%, indicando que, apesar da baixa *accuracy*, o modelo conseguiu mais facilmente identificar estas posturas. A média da *accuracy* das classificações das posturas foi de 96.49%.

Tabela 22 – Resultados do relatório de classificação de FFANN.

Postura	Relatório de Classificação		
	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
Lateral esquerda	97.93%	93.70%	95.77%
Virado para baixo	91.33%	98.60%	94.82%
Lateral direita	99.37%	95.40%	97.34%
Virado para cima	97.92%	98.25%	98.09%
Accuracy Média	96.49%		




Figura 21 - Matriz de confusão de FFANN.

Os resultados da validação cruzada do FFANN são apresentados na Tabela 23. Observando a Tabela 23, pode-se afirmar que este modelo obteve uma boa performance em todas as iterações da validação, tendo uma média de *accuracy* de 98.93%.

Tabela 23 - Resultados de validação cruzada de FFANN.

Fold	Accuracy	Recall	F1-Score
1	98.92%	98.92%	98.92%
2	97.60%	97.60%	97.62%
3	99.36%	99.36%	99.36%
4	99.47%	99.47%	99.47%
5	99.33%	99.33%	99.33%

Média	98.93%	98.93%	98.94%
-------	--------	--------	--------

A Figura 22 apresenta a frequência dos parâmetros utilizados na validação cruzada, sendo que em cada iteração foi utilizado o mesmo valor para cada parâmetro.




Figura 22 - Frequência de melhores parâmetros de FFANN.

Na última validação cruzada, no LOGO, o algoritmo FFANN obteve uma média de accuracy de 96.69%, um recall de 96.60% e um f1-score de 96.69%, tal como se pode observar na Figura 23, que apresenta a performance de cada participante durante a avaliação cruzada de LOGO.




Figura 23 - Gráfico de performance de participantes.

4.1.8. Temporal Convolutional Network

No processo de treino de TCN, foram considerados os parâmetros *dense_unit*, *filters*. No treino inicial, o modelo obteve uma accuracy de 94.97% com a combinação de parâmetros de *dense_unit=512* e *filters=512*. Na fase de teste, o modelo obteve uma accuracy de 91.01%, como demonstrado na Tabela 24.

Tabela 24 - Resultados iniciais de TCN.

Accuracy	91.01%
Recall	91.01%
F1-Score	91.11%
Parâmetros	'dense_unit'=512; 'filters'=512;

O relatório de classificação representado na Tabela 25 e a matriz de confusão apresentada na Figura 24 foram produzidos pelo teste do algoritmo de TCN. Observando a Tabela 25, verifica-se que a postura virado para cima obteve valores de *accuracy* mais elevados com 97.36%. A postura virado para baixo foi a que obteve um valor de *accuracy* significativamente mais baixo que as outras, tendo uma *accuracy* de 79.84%. Mas apesar de ser a *accuracy* com valor mais baixo, é a que foi mais facilmente classificada pelo modelo, com um valor de *recall* de 98.68%. O valor médio de *accuracy* foi de 91.01%.

Tabela 25 - Resultados do relatório de classificação de TCN.

Postura	Relatório de Classificação		
	Accuracy	Recall	F1-Score
Lateral esquerda	95.89%	90.77%	93.26%
Virado para baixo	79.84%	98.68%	88.26%
Lateral direita	94.85%	88.62%	91.63%
Virado para cima	97.36%	85.98%	91.32%
Accuracy Média	91.01%		




Figura 24 - Matriz de confusão de TCN.

Os resultados da validação cruzada do *TCN* são apresentados na Tabela 26. Observando os dados da referida tabela, pode-se afirmar que o modelo, apesar de não ter obtido resultados tão elevados como modelos anteriores, conseguiu valores de *accuracy* superiores a 89.22%, tendo uma média de *accuracy* de 90.98%.

Tabela 26 - Resultados de validação cruzada de *TCN*.

Fold	Accuracy	Recall	F1-Score
1	91.32%	91.32%	91.10%
2	89.22%	89.22%	88.92%
3	90.66%	90.66%	90.57%
4	91.64%	91.64%	91.33%
5	92.06%	92.06%	91.96%
Média	90.98%	90.98%	90.78%

A Figura 25 apresenta a frequência dos parâmetros utilizados na validação cruzada, sendo que houve alguma variação nas iterações para ambos os parâmetros.

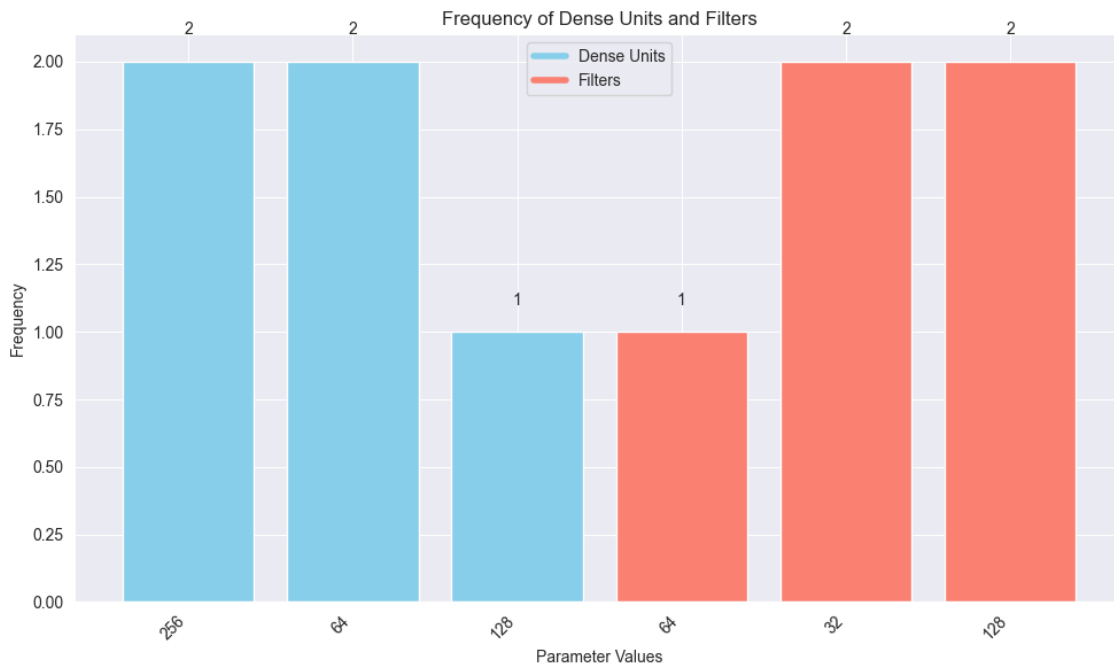


Figura 25 - Frequência de melhores parâmetros de *TCN*.

Na última validação cruzada, no *LOGO*, o algoritmo *TCN* obteve uma *accuracy* média de 93.00%, um *recall* de 92.78% e um *f1-score* de 93.00%, conforme se observa na Figura 26, que mostra a performance de cada participante durante a validação cruzada de *LOGO*.




Figura 26 - Gráfico de performance de participantes.

4.1.9. Convolutional Neural Network

No processo de treino de *CNN*, foram considerados os parâmetros *conv1 filters*, *conv1 kernel*, *conv2 filters*, *conv2 kernel*, *conv3 filters*, *conv3 kernel*, *dense units* e *dropout rate*. No treino inicial, o modelo obteve uma *accuracy* de 99.55% com a combinação de parâmetros de *Conv1 Filters=112*, *Conv1 Kernel=3*, *Conv2 Filters=80*, *Conv2 Kernel=3*, *Conv3 Filters=112*, *Conv3 Kernel=3*, *Dense Units=512* e *Dropout Rate=0.0*. Na fase de teste, o modelo obteve uma *accuracy* de 93.08%, como se observa na Tabela 27.

Tabela 27 - Resultados iniciais de CNN.

Accuracy	93.08%
Recall	93.08%
F1-Score	93.06%
Parâmetros	<i>Conv1 Filters=112;</i> <i>Conv1 Kernel=3;</i> <i>Conv2 Filters=80;</i> <i>Conv2 Kernel=3;</i> <i>Conv3 Filters=112;</i> <i>Conv3 Kernel=3;</i> <i>Dense Units=512;</i> <i>Dropout Rate=0.0.</i>

O relatório de classificação apresentado na Tabela 28 e a matriz de confusão apresentada na Figura 27 foram produzidos pelo teste do modelo de *CNN*. Na Tabela 28, pode-se observar que o modelo conseguiu uma *accuracy* média de 93.08%. Os valores de *accuracy* mantiveram-se entre 90.68% e 94.52%. O valor mais baixo foi obtido pela postura virado para cima, mas o seu valor de *recall* foi mais alto, de 94.26%, comparado com a postura lateral esquerda que teve a *accuracy* de 94.52% e o menor

recall de todas com 88.52%. A postura lateral direita foi a que foi mais facilmente classificada pelo modelo, com um valor de *recall* de 97.38%.

Tabela 28 – Resultados do relatório de classificação de CNN.

Postura	Relatório de Classificação		
	Accuracy	Recall	F1-Score
Lateral esquerda	94.52%	88.52%	91.42%
Virado para baixo	94.11%	92.17%	93.13%
Lateral direita	93.21%	97.38%	95.25%
Virado para cima	90.68%	94.26%	92.44%
Accuracy Média	93.08%		




Figura 27 - Matriz de confusão de CNN.

Os resultados da validação cruzada do CNN são apresentados na Tabela 29. O modelo, apesar de utilizar um formato de imagens em vez de matrizes para treinar e testar, conseguiu obter valores de *accuracy* altos, com uma média de *accuracy* de 94.91%.

Tabela 29 - Resultados de validação cruzada de CNN.

Fold	Accuracy	Recall	F1-Score
1	95.60%	95.60%	95.61%
2	94.11%	94.11%	94.12%
3	94.74%	94.74%	94.72%
4	95.76%	95.76%	95.75%
5	94.34%	94.34%	94.35%
Média	94.91%	94.91%	94.91%

A Figura 28 mostra a frequência dos parâmetros utilizados na validação cruzada, sendo que não houve variação de parâmetros nas iterações.




Figura 28 - Frequência de melhores parâmetros de CNN.

Na última validação cruzada, no *LOGO*, o algoritmo *CNN* obteve uma *accuracy* média de 91.99%, um *recall* de 91.73% e um *f1-score* de 91.99%, tal como se pode observar na figura 29, que mostra a performance de cada participante durante a avaliação cruzada de *LOGO*. Mesmo com valores que se dispersam um pouco, o modelo consegue obter bons resultados na classificação de posturas dos vários participantes, utilizando um tipo de formato de dados diferente.




Figura 29 - Gráfico de performance de participantes.

4.1.10. ResNet-18

No processo de treino do *ResNet-18*, foram considerados os parâmetros *lr* e *batch_size*. No treino inicial, o modelo obteve uma *accuracy* de 96.04% com a combinação de parâmetros de *lr*=0.0001 e *batch_size*=32. Na fase de teste, o modelo obteve uma *accuracy* de 95.99%, como pode observar-se na Tabela 30.

Tabela 30 - Resultados iniciais de ResNet-18.

Accuracy	95.99%
Recall	95.99%
F1-Score	95.99%
Parâmetros	<i>lr</i> = 0.0001; <i>batch_size</i> = 32;

O relatório de classificação que está apresentado na Tabela 31 e a matriz de confusão apresentada na Figura 30 foram produzidos pelo teste do modelo de *ResNet-18*. Observando a Tabela 31, pode-se observar que os valores de *accuracy* da classificação das posturas foram altos, mantendo-se entre as percentagens de 98.99% e 94.85%, numa média de 95.99%. A postura de lateral esquerda foi a que obteve o maior valor de *accuracy* com 98.99%. Mas a postura de lateral direita obteve um *recall* de 97.70%, significando que esta postura foi facilmente classificada pelo modelo.

Tabela 31 – Resultados do relatório de classificação de ResNet-18.

Postura	Relatório de Classificação		
	<i>Accuracy</i>	<i>Recall</i>	<i>F1-Score</i>
Lateral esquerda	98.99%	93.81%	96.33%
Virado para baixo	95.04%	97.35%	96.18%
Lateral direita	95.28%	97.70%	96.47%
Virado para cima	94.85%	95.11%	94.98%
Accuracy Média	95.99%		




Figura 30 - Matriz de confusão de ResNet-18.

Os resultados da validação cruzada do *ResNet-18* são apresentados na Tabela 32. O modelo obteve valores de *accuracy* elevados, indicando que o modelo é eficiente em classificar as posturas. A *accuracy* média da validação cruzada foi de 95.76%, obtendo uma média superior ao modelo *CNN*, 93.91%, que também utiliza o formato de imagem para a avaliação do modelo.

Tabela 32 - Resultados de validação cruzada de ResNet-18.

Fold	Accuracy	Recall	F1-Score
1	97.31%	97.31%	97.31%
2	96.04%	96.04%	96.04%
3	95.75%	95.75%	95.75%
4	95.18%	95.18%	95.16%
5	94.54%	94.54%	94.56%
Média	95.76%	95.76%	95.76%

A Figura 31 mostra a frequência dos parâmetros utilizados na validação cruzada, sendo que houve alguma variação nas iterações para ambos os parâmetros.




Figura 31 - Frequência de melhores parâmetros de ResNet-18.

Na última validação cruzada, no LOGO, o algoritmo *ResNet-18* obteve uma *accuracy* média de 95.71%, um *recall* de 95.72% e um *f1-score* de 95.71%, o que se pode observar na figura 32, que demonstra a performance de cada participante durante a avaliação cruzada de LOGO. Pode-se verificar que o valor de *accuracy* de cada participante se manteve acima dos 94%, demonstrando que o modelo é eficiente e consistente em diferentes cenários individuais.




Figura 32 - Gráfico de performance de participantes.

4.2. Experimentos para a Classificação de 28 Posturas

Esta secção descreve os experimentos e os resultados alcançados na classificação de 28 variantes de postura (7 variantes para cada uma das posturas principais). São utilizados os algoritmos *FFANN* e *SVM*, uma vez são os que obtiveram os melhores

resultados médios de *accuracy* na classificação das 4 posturas, com 98,93% e 96,55%, respectivamente, conforme apresentado nas secções anteriores. A Tabela 33 apresenta os resultados da classificação para as 28 posturas usando os algoritmos *FFANN* e *SVM*.

Tabela 33 - Resultados de classificação de 28 posturas.

Algoritmo	Inicial	Group K-Fold	LOGO
SVM	Accuracy: 66.72%	Accuracy: 65.18%	Accuracy: 67.17%
	Recall: 66.72%	Recall: 65.18%	Accuracy: 64.16%
	F1-Score: 66.42%	F1-Score: 65.23%	F1-Score: 67.17%
FFANN	Accuracy: 62.01%	Accuracy: 62.82%	Accuracy: 63.90%
	Recall: 62.01%	Recall: 62.82%	Recall: 60.49%
	F1-Score: 61.50%	F1-Score: 62.94%	F1-Score: 63.90%

Conforme seria de esperar, analisando a Tabela 33 na validação do *Group K-Fold*, observa-se que os resultados da classificação das 28 posturas são mais baixos, com os valores médios de *accuracy* mais altos de 65.18% alcançados pelo algoritmo do *SVM*. A Figura 33, mostra as matrizes de confusão de ambos os modelos de *FFANN* e *SVM*. As linhas representam o resultado esperado e as colunas o resultado previsto. As posturas estão representadas pela sua letra inicial, *P* – *Prone*, *S* – *Supine*, *L* – *Left* and *R* – *Right* e as variação estão representadas de 1 a 7. Por exemplo, *P1* representa a postura *Prone* na variação 1. Pode-se observar, que apesar da diminuição de *accuracy* na classificação das 28 posturas, comparado com os resultados com as 4 posturas, ainda assim ambos os modelos conseguem classificar bem a maior parte das posturas.

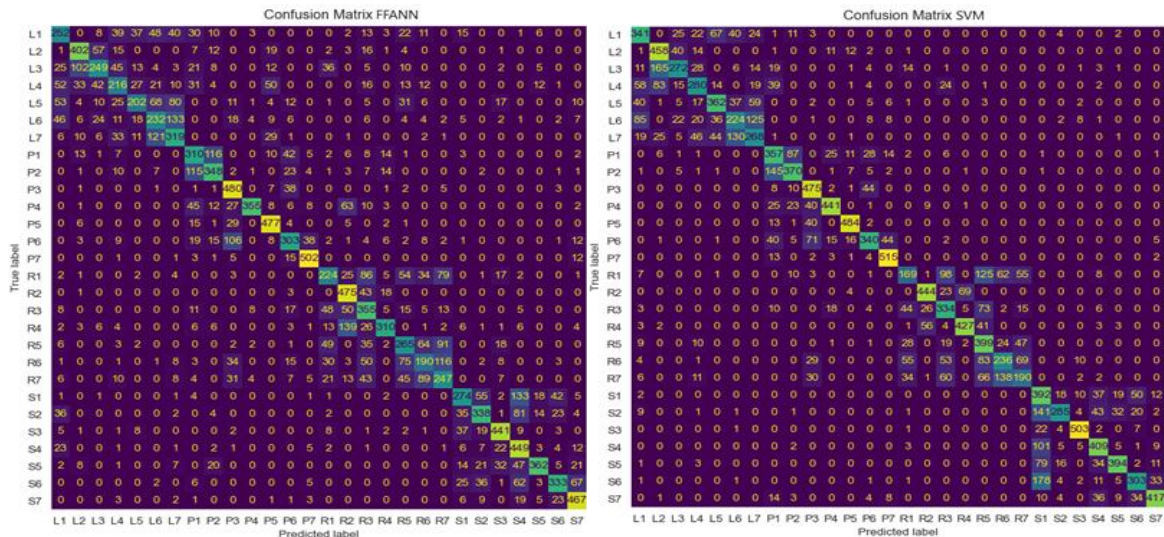


Figura 33 - Matrizes de confusão de FFANN e SVM.

5. Discussão

Nesta secção são discutidos os resultados apresentados no capítulo 4. Os resultados são contextualizados em relação aos objetivos iniciais do estudo e com os resultados de estudos analisados.

A Tabela 34 resume os resultados obtidos em cada etapa analisada, treino e teste inicial, *Group K-Fold* e *LOGO*, para cada um dos algoritmos.

Tabela 34 - Resultados dos algoritmos analisados.

Algoritmo	Accuracy Inicial	Group K-Fold	LOGO
<i>KNN</i>	93.66%	Maior: 96.06% Menor: 87.59% Média: 92.02%	Maior: 100% Menor: 64.76% Média: 93.28%
<i>SVM</i>	98.54%	Maior: 98.65% Menor: 94.70% Média: 96.55%	Maior: 100% Menor: 76.19% Média: 97.14%
<i>DT</i>	77.08%	Maior: 83.23% Menor: 76.11% Média: 79.14%	Maior: 97.26% Menor: 53.09% Média: 80.03%
<i>RF</i>	93.79%	Maior: 96.37% Menor: 92.09% Média: 94.19%	Maior: 100% Menor: 72.38% Média: 94.70%
<i>GB</i>	94.61%	Maior: 97.90% Menor: 94.43% Média: 95.77%	Maior: 100% Menor: 72.61% Média: 96.63%
<i>NB</i>	84.58%	Maior: 91.61% Menor: 80.64% Média: 84.87%	Maior: 99.40% Menor: 35.11% Média: 85.00%
<i>FFANN</i>	96.48%	Maior: 99.47% Menor: 97.60% Média: 98.93%	Maior: 100% Menor: 74.64% Média: 96.69%
<i>TCN</i>	91.01%	Maior: 92.06% Menor: 89.22% Média: 90.98%	Maior: 99.88% Menor: 67.85% Média: 93.00%
<i>CNN</i>	93.08%	Maior: 95.76% Menor: 94.11% Média: 94.91%	Maior: 99.40% Menor: 71.30% Média: 91.99%
<i>ResNet-18</i>	95.99%	Maior: 97.31% Menor: 94.56%	Maior: 97.16% Menor: 94.54%

		Média: 95.76%	Média: 95.71%
--	--	---------------	---------------

Oito dos dez algoritmos alcançaram valores médios de *accuracy* acima dos 90% tanto na validação cruzada *Group K-Fold* como no *LOGO*, tendo os algoritmos *SVM* e *FFANN* atingido os valores médios de *accuracy* mais elevados. A Figura 34 apresenta uma comparação dos valores médios de *accuracy* de todos os algoritmos.




Figura 34 - Comparação dos valores médios de *accuracy* de todos os algoritmos.

Como mencionado no estudo [22], que apresentou uma revisão sistemática sobre métodos e algoritmos para classificação de posturas com base em matrizes de pressão, os algoritmos com melhores resultados são normalmente algoritmos de redes neurais, com a exceção do *SVM*, que apresenta resultados de *accuracy* bastante positivos. Observando a Tabela 34 no parâmetro da média do *Group K-Fold*, pode-se concluir que há uma variação nos resultados ao comparar os algoritmos de *ML* com as redes neurais. Na maioria dos casos, as redes neurais continuam a obter melhores resultados que os outros algoritmos, com a exceção do *TCN* que, neste caso, obteve uma *accuracy* média com menor desempenho. O algoritmo *FFANN* foi o que obteve a melhor média de *accuracy* com 98.93%. O *SVM*, como dito em [22], continua a ser uma exceção em obter bons resultados e a acompanhar as redes neurais nesse aspecto. Os algoritmos *RF* e *GB* também se mostram competitivos alcançando valores de *accuracy* próximos das redes neurais, porém, ligeiramente inferiores.

Nos casos de classificação pelo formato de imagem, os algoritmos *CNN* e *ResNet-18* alcançaram bons desempenhos, com o *CNN* a apresentar o 5º melhor desempenho e o *ResNet-18* a apresentar o 4º melhor desempenho, quando considerados o valor médio da *accuracy Group K-Fold*, confirmando que estes algoritmos conseguem analisar e classificar a postura corretamente, na maioria dos casos.

A Tabela 35 mostra uma comparação com os resultados de outros estudos para o reconhecimento de posturas através de matrizes de sensores de pressão, por cima ou por baixo do colchão. Verifica-se que têm sido mais utilizados os algoritmos de redes neuronais, como visto na revisão sistemática em [22] e nos estudos analisados [18][19][14], o que mostra a eficácia destes algoritmos em problemas de classificação.

Analisando os resultados pode-se concluir que os desempenhos dos algoritmos não diferem muito. A análise dos estudos [19] e [20] indica que a utilização de matrizes de sensores de pressão posicionados por baixo do colchão é uma abordagem viável, eficiente e menos intrusiva, capaz de obter bons resultados. Embora o estudo [18] tenha utilizado uma combinação de algoritmos e um número maior de posturas, a comparação direta com os resultados deste estudo é limitada, pois no estudo [18] o objetivo foi identificar a postura da pessoa em relação à cama, mas não especificamente a sua postura quando está deitada. No entanto, os resultados dos estudos [19] e [20] mostram que matrizes de sensores de pressão podem ser utilizadas e podem permitir alcançar valores de *accuracy* elevados no reconhecimento de posturas de pessoas acamadas, destacando a eficácia desta abordagem. Isso é corroborado pelos resultados apresentados neste estudo que mostram que é possível alcançar valores de *accuracy* na classificação das 4 posturas principais usando validação cruzada, próximos, ou mesmo superiores a 97%.

Tabela 35 – Resultados obtidos por outros estudos (amostra de dados da Tabela 2).

Ref.	Nº Posturas	Algoritmo	Accuracy %
[18]	5*	Redes Neuronais (NN) + Rede Bayesian	5 Posições: 91.50% 3 Posições: 89.9%
[19]	4	FFNN	K-Fold: 99% LOSO: 93%
[20]	3	TCN	Body-Position: 95.8%

* Identifica a posição da pessoa em relação à cama, mas não especificamente a sua postura quando está deitada.

A Tabela 36 apresenta os estudos incluídos na discussão dos resultados.

Tabela 36 - Estudos com dados obtidos por baixo ou por cima do colchão.

Estudos com sensores por baixo do colchão	[18], [19], [20]
Estudos com sensores por cima do colchão	[22], [13]

No que respeita a estudos com sensores por cima do colchão, o estudo [13] investigou como o número de classes e a resolução do mapa de pressões afetam a classificação das posturas dos indivíduos acamados. Foram utilizados cinco algoritmos: *KNN*, *SVM*, *DT*, *RF* e *MLP*. Analisaram a *accuracy* destes algoritmos em diferentes

combinações e número de posturas (4 e 28) e resoluções de dados de entrada, variando a resolução da matriz. Os resultados mostraram que os algoritmos baseados em *NN*, particularmente o *MLP*, tendem a alcançar uma maior *accuracy*, atingindo os 99% em alguns cenários quando se consideram 4 posturas, enquanto os outros algoritmos foram utilizados principalmente para comparação. No entanto, neste caso foram considerados dados de pressão obtidos por sensores colocados por cima do colchão.

As Tabelas 37 e 38 apresentam os resultados do estudo [13] utilizando o método de validação cruzada de 5 vezes com 4 posturas. A Tabela 37 mostra os resultados utilizando uma manta de sensores com 64x27 sensores, enquanto a Tabela 38 apresenta os resultados com uma manta de sensores com 16x7 sensores. Pode-se observar que a redução da resolução da matriz de 64x27 para 16x7 diminui os valores de *accuracy* embora não de forma significativa. No entanto, o estudo mostra também que para resoluções de mapas de sensores inferiores a 16x7 sensores, a diminuição do resultado torna-se mais significativa.

Tabela 37 – Comparação com o estudo [13], com matriz de 64x27 e 4 posturas.

Algoritmo	K-Fold 5 - Accuracy média	
	Este estudo	Estudo [13]
KNN	92.02%	92.07%
SVM	96.55%	91.25%
DT	79.14%	80.05%
RF	94.19%	95.37%

Tabela 38 - Comparação com o estudo [13], com matriz de 16x7 e 4 posturas.

Algoritmo	K-Fold 5 - Accuracy média	
	Este estudo	Estudo [13]
KNN	92.02%	91.34%
SVM	96.55%	91.16%
DT	79.14%	79.07%
RF	94.19%	95.29%

Comparando os resultados obtidos nestes experimentos, os valores de *accuracy* em ambos os estudos não diferem muito. Com a matriz 64x27, o estudo [13] conseguiu melhores resultados, exceto para o *SVM*, que apresentou menor *accuracy*. No entanto, com a matriz 16x7, as precisões no estudo [13] diminuíram ligeiramente. Neste caso, os valores médios de *accuracy* deste estudo, que utiliza uma matriz 12x6, são superiores em alguns casos, mesmo considerando que a manta de sensores foi colocada por baixo do colchão, ao contrário de [13], onde a manta de sensores foi colocada por cima do colchão. Com efeito, o valor médio de *accuracy* de 96,55%, alcançado através

do algoritmo *SVM*, é o mais elevado quando se consideram os algoritmos utilizados em ambos os estudos.

No experimento das 28 posturas, tanto no estudo [13] como neste estudo os resultados de valores de *accuracy* foram inferiores em comparação com o experimento com as 4 posturas principais. A Tabela 39 apresenta uma comparação dos resultados deste estudo e do estudo [13] relativamente à classificação de 28 posturas. Como os algoritmos usados para o experimento das 28 posturas são diferentes nos dois estudos, a comparação direta dos resultados só é possível para o algoritmo *SVM*. Os resultados de ambos os experimentos mostram que o desempenho do *SVM* neste estudo (65.18%) foi superior ao do estudo [13] (58.25%). O maior desempenho do *SVM* neste estudo pode ser atribuído aos métodos aplicados no treino dos modelos e à utilização de técnicas de otimização para encontrar os melhores parâmetros. Neste estudo foi utilizado o *GridSearchCV* para ajudar a identificar a configuração mais adequada para o modelo *SVM*. Esta técnica permitiu, possivelmente, que o modelo se adaptasse melhor à complexidade de classificação de 28 posturas, resultando numa maior *accuracy*. Em contraste, o estudo [13] pode não ter utilizado o mesmo grau de otimização dos parâmetros, o que poderá explicar o menor desempenho observado.

Embora os resultados de *accuracy* sejam inferiores em comparação com o experimento de 4 posturas, é importante notar que a classificação de 28 posturas é inerentemente mais complexa devido ao aumento do número de classes. Estes resultados estão de acordo com as expectativas, uma vez que a adição de mais classes resulta, normalmente, em uma redução dos valores de *accuracy* devido à maior complexidade da classificação.

Tabela 39 – Comparação com o estudo [13], com 28 posturas.

Algoritmo	Accuracy	
	Este estudo	Estudo [13]
SVM	65.18%	58.25%
RF		63.06%
MLP		59.10%
FFANN	62.82%	

6. Conclusão

A monitorização das posturas de pessoas acamadas é crucial para reduzir os riscos para a saúde associados ao posicionamento corporal inadequado. Este trabalho focou-se na avaliação da viabilidade da utilização de algoritmos de *ML* para classificar posturas com base em matrizes de pressão obtidos a partir de mantas de sensores colocadas por baixo do colchão. A análise envolveu a comparação de vários algoritmos de *ML* utilizando dados de sensores do *dataset PoPu*. Os resultados indicam que esta abordagem não só é menos intrusiva, como também eficaz, com valores médios *accuracy* a atingirem até 98,93% utilizando a validação cruzada *K-Fold* e 97,14% utilizando o *LOGO*. Os algoritmos *FFANN* e *SVM* alcançaram os maiores valores de *accuracy*.

Ao considerar 28 posturas, este estudo mostra uma melhoria significativa em relação aos estudos anteriores, tanto no número de posturas consideradas como na *accuracy* alcançada. Embora os valores da *accuracy* tenha sido menor do que quando apenas foram consideradas as 4 posturas principais, neste caso, com o *SVM* a atingir os 65,18% na validação *Group K-Fold*, demonstra que a abordagem proposta se mantém eficaz mesmo com tarefas mais complexas.

Este estudo também comparou os resultados com pesquisas anteriores que utilizaram dados de sensores de pressão colocados por baixo do colchão para classificar as posturas, referindo que mesmo com menos posturas, os valores de *accuracy* alcançados foram maiores. As comparações com outros estudos que utilizaram mantas de sensores colocadas em cima do colchão mostram que os resultados são muito semelhantes e, em alguns casos, superam-nos quando se considera um número semelhante de sensores e posturas.

Trabalho de pesquisa futuro poderá explorar abordagens utilizando mantas de sensores com diferentes números de sensores e considerar um maior número de posturas ou variações das quatro posturas principais para avaliar a viabilidade desta abordagem sob diferentes condições.

Deste trabalho resultaram duas publicações científicas:

- Serra, A., Ribeiro, F., & Metrôlho, J. (2024a). In-Bed Posture Classification Using Pressure Data from a Sensor Sheet Under the Mattress. Information.
- Serra, A., Ribeiro, F., & Metrôlho, J. (2024b). In-Bed Posture Classification Using Pressure Data Measured Under the Mattress In-Bed Posture Classification Using Pressure Data Measured Under the Mattress. 19th Iberian Conference on Information Systems and Technologies.

Referências

- [1] H. H. Nguyen, B. L. Dang, H. P. Dam, Q. H. Dang, D. M. Nguyen, and V. A. Vo, "A novel implementation of sleeping posture classification using RANC ecosystem," in *2022 International Conference on Advanced Technologies for Communications (ATC)*, 2022, pp. 369–374. doi: 10.1109/ATC55345.2022.9942964.
- [2] O. Ozeke *et al.*, "Influence of the right- versus left-sided sleeping position on the apnea-hypopnea index in patients with sleep apnea," *Sleep Breath*, vol. 16, pp. 617–620, Jul. 2011, doi: 10.1007/s11325-011-0547-4.
- [3] O. Ozeke *et al.*, "Influence of the right-versus left-sided sleeping position on the apnea-hypopnea index in patients with sleep apnea," *Sleep and Breathing*, vol. 16, no. 3, pp. 617–620, Sep. 2012, doi: 10.1007/s11325-011-0547-4.
- [4] D. Cary, K. Briffa, and L. McKenna, "Identifying relationships between sleep posture and non-specific spinal symptoms in adults: A scoping review," *BMJ Open*, vol. 9, no. 6, p. e027633, Jun. 2019, doi: 10.1136/bmjopen-2018-027633.
- [5] M. Mohammad Amini *et al.*, "A Novel Elastic Sensor Sheet for Pressure Injury Monitoring: Design, Integration, and Performance Analysis," *Electronics (Basel)*, vol. 12, no. 17, p. 3655, Aug. 2023, doi: 10.3390/electronics12173655.
- [6] L. Fonseca *et al.*, "Integrated System for Pressure Ulcers Monitoring and Prevention," 2023, pp. 58–68. doi: 10.1007/978-3-031-26852-6_5.
- [7] A. Menon and M. Kumar, "Influence of Body Position on Severity of Obstructive Sleep Apnea: A Systematic Review," *ISRN Otolaryngol*, vol. 2013, p. 670381, Jul. 2013, doi: 10.1155/2013/670381.
- [8] N. B. Kavey, A. Blitzer, S. Gidro-Frank, and K. Korstanje, "Sleeping position and sleep apnea syndrome," *Am J Otolaryngol*, vol. 6, no. 5, pp. 373–377, 1985, doi: [https://doi.org/10.1016/S0196-0709\(85\)80015-6](https://doi.org/10.1016/S0196-0709(85)80015-6).
- [9] J. Yin, J. Xu, and T.-L. Ren, "Recent Progress in Long-Term Sleep Monitoring Technology," *Biosensors (Basel)*, vol. 13, no. 3, 2023, doi: 10.3390/bios13030395.
- [10] R. M. Kwasnicki *et al.*, "A lightweight sensing platform for monitoring sleep quality and posture: a simulated validation study," *Eur J Med Res*, vol. 23, no. 1, p. 28, Dec. 2018, doi: 10.1186/s40001-018-0326-9.
- [11] P.-Y. Jeng, L.-C. Wang, C.-J. Hu, and D. Wu, "A Wrist Sensor Sleep Posture Monitoring System: An Automatic Labeling Approach," *Sensors*, vol. 21, no. 1, p. 258, Jan. 2021, doi: 10.3390/s21010258.
- [12] E. V., . W., and . M., "Design and Implementation of an Intelligent System for Controlling a Robotic Hospital Bed for Patient Care Assistance," *Computación y Sistemas*, vol. 19, pp. 467–474, 2015, [Online]. Available: <https://www.redalyc.org/articulo.oa?id=61541546005>
- [13] L. Fonseca, F. Ribeiro, and J. Metrôlho, "Effects of the Number of Classes and Pressure Map Resolution on Fine-Grained In-Bed Posture Classification," *Computation*, vol. 11, no. 12, p. 239, Dec. 2023, doi: 10.3390/computation11120239.
- [14] L. Stern and A. Roshan Fekr, "In-Bed Posture Classification Using Deep Neural Network," *Sensors*, vol. 23, no. 5, p. 2430, Feb. 2023, doi: 10.3390/s23052430.

- [15] R. Hudec, S. Matúška, P. Kamencay, and M. Benco, "A Smart IoT System for Detecting the Position of a Lying Person Using a Novel Textile Pressure Sensor," *Sensors*, vol. 21, no. 1, p. 206, Dec. 2020, doi: 10.3390/s21010206.
- [16] L. Fonseca *et al.*, "PoPu-Data: A Multilayered, Simultaneously Collected Lying Position Dataset," *Data (Basel)*, vol. 8, no. 7, p. 120, Jul. 2023, doi: 10.3390/data8070120.
- [17] M. J. Page *et al.*, "PRISMA 2020 explanation and elaboration: updated guidance and exemplars for reporting systematic reviews," *BMJ*, vol. 372, 2021, doi: 10.1136/bmj.n160.
- [18] W. Viriyavit, V. Sornlertlamvanich, W. Kongprawechnon, and P. Pongpaibool, "Bed Posture Classification Using Noninvasive Bed Sensors for Elderly Care," in *European-Japanese Conference on Information Modelling and Knowledge Bases*, 2017. [Online]. Available: <https://api.semanticscholar.org/CorpusID:5754620>
- [19] M. Enayati, M. Skubic, J. M. Keller, M. Popescu, and N. Z. Farahani, "Sleep Posture Classification Using Bed Sensor Data and Neural Networks," in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018, pp. 461–465. doi: 10.1109/EMBC.2018.8512436.
- [20] C. Green *et al.*, "Sleep-Wake and Body Position Classification with Deep Learning using Pressure Sensor Mat Measurements," Jul. 2023, pp. 1–6. doi: 10.1109/MeMeA57477.2023.10171884.
- [21] E. Elsharif, N. Drawil, and S. Kanoun, "Automatic Posture and Limb Detection for Pressure Ulcer Risk Assessment," in *2021 IEEE 1st International Maghreb Meeting of the Conference on Sciences and Techniques of Automatic Control and Computer Engineering MI-STA*, IEEE, May 2021, pp. 142–149. doi: 10.1109/MI-STA52233.2021.9464360.
- [22] L. Fonseca, F. Ribeiro, and J. Metrôlho, "Pressure-Based Posture Classification Methods and Algorithms: A Systematic Review," *Computers*, vol. 12, no. 5, 2023, doi: 10.3390/computers12050104.