

Classificação de Posturas de Pessoas Acamadas Usando Dados de Pressão Obtidos por Baixo do Colchão

In-Bed Posture Classification Using Pressure Data Measured Under the Mattress

André Serra¹, Fernando Ribeiro^{1,2}, José Metrôlho^{1,2}

¹Polytechnic Institute of Castelo Branco, Castelo Branco, Portugal

²CISeD-Research Centre in Digital Services, Viseu, Portugal

Resumo — O reconhecimento de posturas de pessoas acamadas pode ser muito útil para a diminuição de riscos de saúde. Neste estudo, é proposta a utilização de algoritmos de *machine learning* para a classificação de posturas de pessoas acamadas com base em mapas de pressão obtidos por sensores colocados por baixo do colchão. Esta abordagem é menos intrusiva em relação às abordagens mais comuns e que utilizam mapas de pressão obtidos a partir de sensores colocados por cima do colchão. Nesta abordagem foi usado o *dataset* PoPu, que inclui dados de posturas de 60 participantes. Para a classificação das posturas foi utilizado o algoritmo k-NN e foi realizada validação cruzada para a verificação da consistência e generalização dos resultados. A precisão média da classificação das posturas foi de 94.8%, com as posições “voltado para a esquerda” e “voltado para a direita” com os valores mais elevados de precisão, 95.3% e 98.1% respetivamente, mas com valores de recall menores. Nas posições de “voltado para cima” e “voltado para baixo”, verificou-se o inverso com valores de precisão menores, 93.3% e 92.8%, mas com valores de *recall* mais elevados. Na validação cruzada, foi possível verificar que o modelo consegue ser consistente na precisão, em diferentes divisões do conjunto de dados, com uma média de precisão de 93.03%.

Palavras-Chave - *classificação de posturas; machine learning; mapas de pressão; posturas de pessoas acamadas.*

Abstract — In-bed posture classification can be highly useful for reducing health risks. In this study, the use of machine learning algorithms is proposed for the classification of postures of bedridden individuals based on pressure maps obtained from sensors placed beneath the mattress. This approach is less intrusive compared to more common approaches that use pressure maps obtained from sensors placed on top of the mattress. The PoPu dataset, which includes posture data from 60 participants, was utilized in this approach. The k-NN algorithm was used to classify the postures, and cross-validation experiments were performed to check the consistency and generalization of the results. The average classification precision of the postures was 94.8%, with the “Left” and “Right” postures having the highest precision values, 95.3% and 98.1% respectively, but with lower values of recall. The opposite is achieved in the supine and prone postures, with lower values of precision, 93.3% and 92.8%, but with higher values of recall. In the cross-validation, it was possible to verify that the model can have a consistent precision, in different sets of the dataset, with an average precision of 93.03%.

Keywords - *in-bed posture; machine learning; posture classification; pressure maps.*

I. INTRODUÇÃO

A atividade de controlar e monitorizar o estado das pessoas durante os períodos em que permanecem acamadas pode contribuir para ajudar no estudo de diminuição de riscos de saúde, pois maus hábitos noturnos ou maus posicionamentos do corpo podem potenciar diferentes tipos de problemas no seu bem-estar. As posturas que uma pessoa assume enquanto dorme é um fator que tem vindo a ser estudado pelo facto de ser considerada uma causa potenciadora do aumento do risco de saúde [2]. Frequentemente, estes riscos são associados a diversas doenças, ou perturbações de sono, que são influenciadas pela postura em que uma pessoa se posiciona enquanto se encontra deitada, tais como apneia, insónia, qualidade de sono e perturbações do comportamento do sono e problemas de coluna [3][4]. Mas a monitorização das posturas de pessoas acamadas pode também ser útil no acompanhamento de pacientes que permanecem longos períodos na cama, ajudando, por exemplo, na prevenção e tratamento de úlceras por pressão. Têm sido exploradas várias abordagens, usando diferentes tecnologias, para monitorizar como a pessoa se posiciona durante o período em que permanece acamada, nomeadamente recorrendo a polissonógrafos, sensores, pulseiras ou câmaras de vídeo [5][6].

O trabalho aqui apresentado foca-se nas abordagens que utilizam matrizes de sensores que são posicionadas por cima ou por baixo, dos colchões de pessoas acamadas. A maioria dos estudos existentes utilizam algoritmos que se baseiam em matrizes de pressão obtidas a partir de mantas de sensores colocadas por cima do colchão e o seu objetivo tem vindo a concentrar-se na melhoria da precisão da classificação das posturas. Normalmente, recorrem a *datasets* existentes, variáveis no número e tipo de sensores, e classificam as quatro posturas principais (voltado para cima, para baixo, para a esquerda e para a direita) sendo que, em alguns casos (e.g., [7]), apenas classificam 3 posturas, não distinguindo entre voltado para cima e para baixo, e outros (e.g., [8][9]) incluem algumas variantes das 4 posturas principais. Quando consideradas apenas as 4 posturas principais, alguns estudos (e.g., [1]) conseguem obter resultados de precisão superior a 99% na identificação das posturas, embora esta precisão diminua quando considerado um número maior de posturas diferentes. O facto de estas soluções se basearem na utilização de matrizes de pressão obtidas a partir de mantas de sensores colocadas por cima do colchão, também

Identify applicable sponsor/s here. If no sponsors, delete this text box. (sponsors)

significa que, de alguma forma, se trata de uma solução algo intrusiva para as pessoas acamadas. A procura por modelos/algoritmos que permitam a identificação das posturas a partir de matrizes de pressão que sejam obtidos a partir de soluções instaladas por baixo do colchão, menos intrusivas, representam um desafio interessante e é a abordagem seguida no estudo do presente trabalho.

Assim, o objetivo principal deste trabalho é analisar e avaliar a viabilidade do uso de algoritmos de *Machine Learning* (ML) para classificação de posturas de pessoas acamadas, usando como base mapas de pressão obtidos a partir de matrizes de sensores colocadas por debaixo do colchão. Os resultados dos experimentos iniciais da abordagem descrita neste artigo, conseguidos utilizando o algoritmo *k-nearest neighbors* (k-NN) e o *dataset* PoPu [10], permitiram obter valores médios de precisão de 94.8% na classificação das 4 posturas principais (voltado para cima, voltado para baixo, voltado para a esquerda e voltado para a direita) levando a concluir que a classificação de posturas com base em matrizes de sensores colocadas por debaixo do colchão também será viável e com menores efeitos intrusivos para as pessoas acamadas.

Este artigo está organizado em 4 secções. Além do enquadramento, motivação e objetivos apresentados nesta secção inicial, na Secção II é apresentada uma análise de trabalhos relacionados desenvolvidos com objetivos semelhantes, nomeadamente aqueles que visaram o reconhecimento de posturas em pessoas acamadas com base em algum tipo de informação obtida a partir de sensores de pressão. Na Secção III é descrita a metodologia proposta, o que inclui o *dataset* usado, os experimentos e os resultados iniciais, em que foi utilizado o algoritmo k-NN para a classificação de posturas com base em mapas de pressão obtidos por sensores colocados debaixo do colchão. É também apresentada uma discussão dos resultados obtidos. Finalmente, na Secção IV são apresentadas algumas conclusões e notas finais e são também identificadas algumas linhas de trabalho futuro.

II. REVISÃO DE LITERATURA

Nesta secção apresenta-se uma análise de estudos que abordaram o reconhecimento de posturas de pessoas acamadas com base em sensores de pressão posicionados por baixo de colchões

A maioria das soluções para reconhecimento de posturas em pessoas acamadas que utilizam sensores de pressão, baseiam-se em dados de sensores que são colocados por cima do colchão. Isso pode ser confirmado numa revisão sistemática sobre de sistemas inteligentes baseados em sensores para prevenção de úlceras de pressão apresentada em [16] e também no estudo apresentado em [17], onde se pode concluir que a quase totalidade das soluções analisadas recorrem a sensores colocados na cama ou em cima do colchão, diretamente abaixo do participante. As soluções que utilizam dados adquiridos por sensores colocados por baixo do colchão são muito reduzidas.

Assim, para analisar os estudos existentes que recorrem a dados de sensores de pressão, posicionados sob o colchão, para classificação de posturas de pessoas acamadas, foi realizada uma revisão de literatura. Para a seleção e análise dos estudos foi adotada a metodologia de revisão sistemática *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA)

[15]. Este processo consistiu em 6 etapas: definição das questões de pesquisa de forma a responder aos objetivos propostos; identificação de fontes de pesquisa e termos de pesquisa; definição dos critérios de inclusão para determinar quais os estudos a considerar; definição dos critérios de exclusão, para eliminar estudos que não se adequassem aos objetivos; extração e análise dos dados dos estudos selecionados; e discussão e resposta às questões de investigação identificadas.

Para a seleção dos estudos a analisar foram identificadas 5 questões:

- Que soluções para reconhecimento de posturas existem baseadas em dados captados por sensores colocados por baixo do colchão?
- Que *datasets* obtidos por sensores colocados por baixo do colchão existem e quais as suas características?
- Quais as principais posições (posturas) que são mais identificadas?
- Que tipos de sensores de pressão são usados?
- Que algoritmos/modelos são utilizados para a classificação de posturas e que valores de precisão permitem obter?

A pesquisa de estudos foi realizada nas bases de dados *Scopus* e *Web of Science* usando a *string* de pesquisa “(lying OR bed*) AND (posture OR position) AND classification AND pressure”. O objetivo foi identificar estudos que tivessem abordado a identificação ou classificação (*classification*) de posturas ou posições (*posture OR position*) de pessoas deitadas ou acamadas (*lying OR bed**) e que tivessem usado sensores de pressão (*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 (foram considerados apenas os últimos 10 anos) e 34 artigos foram excluídos por serem duplicados, ou seja, o mesmo estudo estava presente simultaneamente nas bases de dados selecionadas.

Aos 176 estudos resultantes, analisados de forma a incluir apenas os que: usaram sensores de pressão; usaram sensores por baixo do colchão; apresentam a precisão dos resultados; e que exemplificam os algoritmos/modelos utilizados. Foram também excluídos os estudos que: não forneciam informação suficiente sobre os modelos ou algoritmos utilizados na extração e classificação das posturas; não apresentam informação sobre os resultados; e que divergiam do objetivo principal, que se foca no uso de sensores de pressão posicionados por baixo do colchão. Após estas fases foram excluídos 173 estudos, restando 3 estudos, que são a seguir descritos.

O estudo apresentado em [11] apresenta uma classificação de posições de pessoas na cama para cuidados de idosos, visando prevenir quedas. Os dados foram recolhidos usando um painel com uma dimensão de 60cm por 18cm, posicionado por baixo do colchão, equipado com 2 pares de tipos de sensores, 2 sensores piezoelétricos e 2 sensores de pressão. Para a classificação foram consideradas cinco posições: fora da cama, sentado, deitado no centro, deitado à esquerda e deitado à direita. A

posição sentada foi destacada por ser crucial para detecção de entrada e saída da cama. Os dados foram recolhidos através de três participantes idosos em dois quartos diferentes, cada um com conjuntos de sensores distintos. Foram utilizadas redes neurais, para detecção de posições, em conjunto com o modelo de rede *Bayesian*, para estimar as transições das posições. Foram obtidos resultados de precisão de 91.50% quando consideradas as 5 posições. Este trabalho foca-se em identificar a posição em que o idoso se encontra em relação à cama e não especificamente a sua postura quanto está deitado.

O estudo descrito em [12], recorreu a uma rede neural simples para fazer a classificação de posturas, explorando diversas combinações de parâmetros para determinar a configuração mais eficaz. Utilizaram sensores hidráulicos sob o colchão, compostos por 4 tubos de água equipados com sensores de pressão. O estudo envolveu 58 participantes jovens e saudáveis, cada um assumindo 4 posturas pré-definidas (deitado voltado para cima, deitado voltado para baixo, voltado para a direita e voltado para a esquerda). Para a classificação, implementaram uma rede neural avaliando o desempenho de diferentes conjuntos de parâmetros com os métodos de classificação *K-fold* (10 *fold*) e *Leave One Subject Out* (LOSO). Em termos de resultados, o algoritmo de *k-fold* obteve uma precisão de 99% e quando considerado o LOSO o valor de precisão foi de 93%.

No estudo [13] o objetivo foi classificar posturas e distinguir entre os estados de acordado e a dormir, em participantes com problemas de sono. Sensores de pressão foram colocados sob o colchão para monitorar o sono e diagnosticar problemas. Foi utilizado um polissonógrafo e sensores de pressão colocados por baixo do colchão. Os sensores consistiam em 6 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. 84 participantes foram incluídos no estudo para classificação de posturas, sendo que 70 foram utilizados para diferenciar os estados de sono. Utilizaram um modelo *Temporal Convolutional Network* (TCN) para ambas as tarefas, com diferentes configurações de parâmetros. O modelo 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. O desempenho do classificador de posturas foi avaliado usando LOSO com 84 participantes. Foram consideradas apenas 3 posturas: voltado para a direita, voltado para a esquerda e deitado direito. A precisão obtida foi de 95.8% para a classificação de posturas e de 91.3% e 66.6% para a diferenciação entre estados de acordado e a dormir, respetivamente.

A revisão destacou uma escassez de estudos que utilizam dados recolhidos por baixo do colchão, em comparação com aqueles que implementam sensores posicionados por cima do colchão. As posições mais comuns selecionadas para a classificação foram: lateral direita e lateral esquerda, sendo que um dos estudos também inclui voltado para cima e voltado para baixo e o outro considera estas duas posições numa única. Os estudos analisados utilizam sensores de pressão, usando diferente hardware, para a recolha de dados e para a classificação de posturas implementam, na maioria dos casos, redes neurais. Normalmente usam *datasets* próprios. Destacando o estudo

[12] que se focou na determinação da melhor configuração utilizando métodos e técnicas de validação cruzada e considerou as 4 posturas principais na classificação. Esta análise mostra também que existe muito pouca investigação que usa soluções com sensores colocados por baixo do colchão para classificação de posturas de pessoas deitadas, sendo que estas soluções são significativamente menos intrusivas para as pessoas que se encontram na cama.

III. METODOLOGIA

Nesta seção descreve-se os aspetos principais da abordagem utilizada. A secção está dividida em 3 subsecções: na primeira subsecção é feita uma descrição do *dataset* utilizado; na segunda são apresentados os experimentos realizados para a classificação de posturas; e na terceira subsecção são apresentados e discutidos os resultados obtidos.

A. Descrição do Dataset

O *dataset* PoPu [10] foi criado a partir de um estudo que incluiu 60 participantes, cujos dados de peso, altura, sexo, postura principal e variantes foram registados. Além destes dados foi também registado, para cada variante de postura o mapa de pressão, que corresponde à pressão que o corpo da pessoa acamada exerce, e que foi registado usando mantas com matrizes de sensores. Os participantes foram posicionados deitados em 28 variações das 4 principais posturas corporais (deitado para cima, deitado para baixo, voltado para a direita e voltado para a esquerda). Algumas das variações incluíram almofadas. Foram recolhidas várias amostras para cada uma das posições o que resultou num *dataset* com 50.400 amostras. Os dados foram recolhidos usando duas abordagens distintas. Uma usando uma manta de sensores *Tactilus* com 180cm por 78cm e com 1728 sensores piezoelétricos, distribuídos por uma matriz de 27 x 64, colocada sobre o colchão e outra com uma manta de sensores *SensoMatt* com 170cm por 84cm e com 72 (6 x 12) sensores de pressão, colocada por baixo do colchão. No *dataset* os dados obtidos por cada uma das abordagens foram organizados em pastas específicas.

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.

B. Algoritmo e experimentos

O processo de experimentos foi dividido em etapas previamente planeadas, desde a seleção e preparação dos dados até a implementação e avaliação dos modelos. Primeiro, os dados foram analisados e pré-processados para garantir a sua consistência e adequabilidade em termos de formato. Depois, foi preparado o modelo para efetuar a classificação das posturas. Finalmente, é analisado o desempenho do modelo, considerando várias métricas e implementada a validação cruzada para avaliar a generalização dos resultados.

Nestes experimentos foi apenas considerado o algoritmo *k-NN*. Embora a utilização de redes neurais tenha vindo a aumentar em abordagens para classificação de posturas o algoritmo *k-NN* ainda é bastante comum e usado principalmente

para comparação [18]. O treino do algoritmo k-NN é distinto do treino de outros algoritmos de ML. Ele armazena o *dataset* de treino no modelo e, quando é feita uma previsão para uma nova instância de dados, o algoritmo calcula a distância entre essa instância e todas as outras instâncias no *dataset*. Em seguida, seleciona as k instâncias mais próximas, ou seja, os “vizinhos mais próximos”, com base na medida de distância escolhida, que geralmente é a distância euclidiana. Finalmente, o algoritmo atribui a classe mais frequente entre os k vizinhos à nova instância de dados [14].

Para a implementação do algoritmo k-NN foi necessário efetuar o pré-processamento dos dados do *dataset*, uma vez que, os dados de leitura dos sensores estão num formato de *array*, que não é um formato aceite pelo algoritmo. Assim os dados de pressão no *dataset* foram transformados num *dataframe* em que cada input do *array*, com as leituras do sensor de pressão, foi convertido numa variável. Os dados do *dataframe* também passaram pelo processo de normalização, utilizando o método *StandardScaler* da biblioteca do *sklearn*.

Para a criação dos *datasets* de treino e de teste para o modelo k-NN, foram divididos os 60 participantes do *dataset* em 70% e 30%, respetivamente. Ou seja, os dados de 42 participantes (70%) compõem o conjunto de treino e os dados dos restantes 18 participantes (30%) compõem o conjunto de teste. Desta forma os dados de treino e os dados de teste são sempre diferentes e não existe a possibilidade de dados semelhantes do mesmo participante estarem presentes nos dois *datasets*. Para a seleção do valor de k , número de vizinhos mais próximos, foi utilizada a implementação da taxa de erro para diferentes valores de k , como se pode visualizar no exemplo da figura 1 (retirada dos experimentos iniciais feitos para o modelo k-NN). Desta forma foi possível saber qual o valor ótimo de k para o algoritmo baseando-se no menor valor da taxa de erro. Após a implementação inicial do algoritmo foi feita uma validação cruzada do algoritmo com o *k-fold* com $k = 5$.

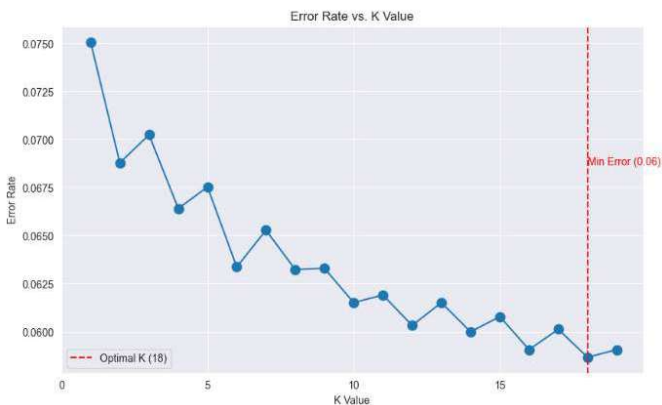


Figure 1. Taxa de erro dos valores de k .

C. Discussão dos Resultados

Para a avaliação do desempenho do algoritmo k-NN foram utilizadas as métricas: precisão, *f1-score* e *recall*. Foi também produzida e analisada a matriz de confusão. Estas métricas fornecem uma visão da capacidade do modelo em classificar as posturas corretamente.

Na tabela I, observa-se que o modelo obteve um bom desempenho para a classificação de todas as posturas, com uma média de precisão de 94.8%. Estes resultados indicam que o modelo é capaz de classificar corretamente a maioria das instâncias em todas as posturas obtendo valores de precisão sempre acima dos 92.8%.

TABLE I. RESULTADOS DA CLASSIFICAÇÃO.

Postura	Relatório de Classificação		
	Precisão	Recall	F1-Score
Voltado para a esquerda	95.3%	91.5%	93.3%
Voltado para baixo	92.8%	95.8%	94.3%
Voltado para a direita	98.1%	93.6%	95.8%
Voltado para cima	93.3%	98.3%	95.7%
Precisão Média	94.8%		

A posturas *left* (“voltado para a esquerda”) e *right* (“voltado para a direita”) foram as posturas que resultaram em precisões mais elevadas com 95.3% e 98.1%, respetivamente. Mas mesmo tendo uma precisão mais alta, a postura *left* obteve um valor de *recall* mais baixo, de 91.5%, o que indica que o modelo teve mais dificuldades em identificar as instâncias desta classe. O contrário aconteceu com as posturas que resultaram em precisões mais baixas de 92.8% e 93.3% para a postura de *prone* (“voltado para baixo”) e *supine* (“voltado para cima”). Estas posturas obtiveram um *recall* de 95.8% e 98.3%, respetivamente, o que indica que apesar da sua precisão ter um valor mais baixo o modelo teve menos dificuldades em identificar corretamente as suas instâncias. Os valores do *f1-score* variam entre os 93.3% e 95.8%, o que indica que existe um equilíbrio entre a precisão e o *recall* e que o modelo é capaz de classificar as diferentes posições com precisão.

A matriz de confusão, apresentada na Figura 2, permite uma análise mais detalhada sobre os “verdadeiros positivos”, “verdadeiros negativos”, “falsos positivos” e “falsos negativos”, relativamente a cada uma das posturas consideradas. A matriz apresenta a relação entre a classe de classificação real (*True label*) e a classe na qual foram classificados (*Predicted label*).

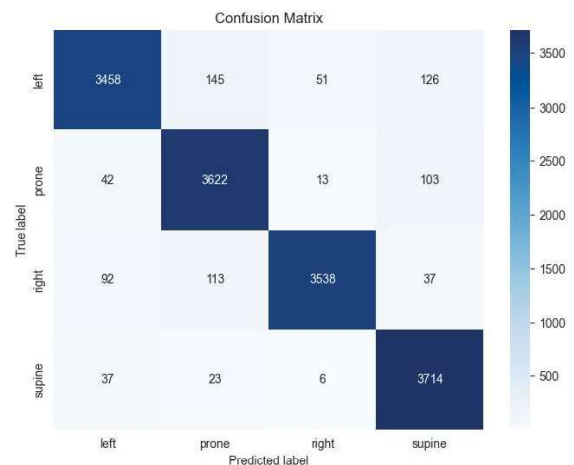


Figure 2. Matriz de Confusão.

Após a implementação e teste do algoritmo k-NN, foi efetuada uma avaliação cruzada com o método *k-fold* com $k=5$, com o objetivo de verificar a consistência de precisão do modelo. Como mostra a tabela II, a média de precisão da avaliação cruzada foi de 93.03%. O que indica que o modelo apresentou uma consistência de precisão em diferentes divisões do conjunto de dados, com algumas variações dos valores de precisão, mas compreendidos entre 91.2% e 94.7%.

É importante considerar que em todas as posturas consideradas havia variantes em que os participantes do *dataset* usaram almofadas e outras em que não as usaram e será importante estudar com maior detalhe qual a influência que isso terá tido nos resultados obtidos.

TABLE II. RESULTADOS DA VALIDAÇÃO CRUZADA $k=5$.

Fold	Precisão	Recall	f1-score
1	91.2%	91.2%	91.1%
2	93.2%	93.2%	93.2%
3	94.7%	94.7%	94.7%
4	94.03%	94.03%	94.9%
5	92.02%	92.02%	92.0%
Média	93.03%	93.03%	93.0%

Com os resultados obtidos através da avaliação do modelo k-NN para a classificação de posturas, pode-se afirmar que existem resultados promissores visto que a precisão média, usando validação cruzada, foi de 93.03%. Este desempenho sugere que o modelo é capaz de classificar corretamente a maioria das instâncias nas diferentes posturas, com valores iguais ou superiores a 91.2%.

IV. CONCLUSÃO E TRABALHO FUTURO

Este estudo teve como objetivo principal analisar e avaliar a viabilidade do uso de algoritmos de ML para a classificação de posturas de pessoas acamadas, utilizando como base mapas de pressão obtidos a partir de matrizes de sensores colocadas por debaixo do colchão. Os resultados das implementações iniciais, utilizando o algoritmo k-NN e o *dataset* PoPu, foram promissores, alcançando valores de precisão média de 94.8% na classificação das quatro posturas principais (voltado para cima, voltado para baixo, voltado para a esquerda e voltado para a direita).

Os resultados obtidos indicam que a classificação de posturas com base em matrizes de sensores colocadas por baixo do colchão é uma abordagem viável, oferecendo uma alternativa menos intrusiva para monitorização e identificação de posições de pessoas acamadas. Além disso, os resultados sugerem que as técnicas de ML podem ser eficazes na interpretação dos dados de matrizes de pressão.

No entanto, este estudo é apenas um primeiro passo na exploração da implementação de ML na interpretação de dados de matrizes de pressão com sensores colocados sob o colchão. Trabalhos futuros podem incluir a investigação de diferentes algoritmos de ML, técnicas de pré-processamento de dados e interpretação de modelos para o melhoramento da precisão e a eficácia da implementação apresentada. A exploração da diferença entre a

precisão e o *recall* nas diferentes posições e aumentar a diversificação de modelos de classificação para uma melhor comparação de resultados e aumento de possibilidades. É também importante estudar com maior detalhe os resultados obtidos, nomeadamente a precisão conseguida em cada uma das posturas, entender onde ocorre o maior número de falsos positivos e falsos negativos e porquê, e o porquê das diferenças de precisão em cada uma das posturas consideradas. O estudo [18], que apresentou uma revisão sistemática sobre métodos e algoritmos de classificação de posturas com base em mapas pressão, concluiu que a utilização de redes neurais, neste tipo de problemas, tem aumentado ao longo do tempo e têm apresentado bom desempenho. Embora esta conclusão resulte essencialmente da análise de estudos que utilizaram mapas de pressão obtidos com sensores colocados por cima do colchão, esta será também uma linha de trabalho futuro a explorar.

AGRADECIMENTOS

Este trabalho é financiado por Fundos Nacionais através da FCT – Fundação para a Ciência e a Tecnologia, I.P., no âmbito do projeto Ref.^a UIDB/05583/2020. Agradecemos adicionalmente ao Centro de Investigação em Serviços Digitais (CISeD) e ao Instituto Politécnico de Viseu pelo apoio prestado.

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] Ozeke, O., Erturk, O., Gungor, M. et al. Influence of the right- versus left-sided sleeping position on the apnea-hypopnea index in patients with sleep apnea. *Sleep Breath* 16, 617–620 (2012). doi: 10.1007/s11325-011-0547-4.
- [3] Cary, Doug et al. "Identifying relationships between sleep posture and non-specific spinal symptoms in adults: a scoping review." *BMJ OPEN* vol. 9,6 E027633. 28 jun. 2019, DOI:10.1136/BMJOPEN-2018-027633.
- [4] Cary, Doug et al. "Examining relationships between sleep posture, waking spinal symptoms and quality of sleep: A cross sectional study." *PLoS one* vol. 16,11 e0260582. 30 Nov. 2021, DOI: 10.1371/JOURNAL.PONE.0260582
- [5] Jeng, Po-Yuan et al. "A Wrist Sensor Sleep Posture Monitoring System: An Automatic Labeling Approach." *Sensors (Basel, Switzerland)* vol. 21,1 258. 2 Jan. 2021, doi:10.3390/s21010258.
- [6] Kwasnicki, Richard M et al. "A lightweight sensing platform for monitoring sleep quality and posture: a simulated validation study." *European journal of medical research* vol. 23,1 28. 30 May. 2018, doi:10.1186/s40001-018-0326-9.
- [7] Stern, L.; Roshan Fekr, A. In-Bed Posture Classification Using Deep Neural Network. *Sensors* 2023, 23, 2430. <https://doi.org/10.3390/S23052430>.
- [8] Nguyen, H.H.; Dang, B.L.; Dam, H.P.; Dang, Q.H.; Nguyen, D.M.; Vo, V.A. A novel implementation of sleeping posture classification using RANC ecosystem. In Proceedings of the 2022 International Conference on Advanced Technologies for Communications, Ha Noi, Vietnam, 20–22 October 2022; pp. 369–374. <https://doi.org/10.1109/ATC55345.2022.9942964>.
- [9] Fonseca, L., Ribeiro, F., & Metrólho, J. (2023). Effects of the Number of Classes and Pressure Map Resolution on Fine-Grained In-Bed Posture Classification. *Computation*, 11(12), 239. <https://doi.org/10.3390/computation11120239>.
- [10] Fonseca, L., Ribeiro, F., Metrólho, J., Santos, A., Dionísio, R., Amini, M. M., Silva, A. F., Heravi, A. R., Sheikholeslami, D. F., Fidalgo, F., Rodrigues, F. B., Santos, O., Coelho, P., & Aemmi, S. S. (2023). PoPu-Data: A Multilayered, Simultaneously Collected Lying Position Dataset. *Data*, 8(7). <https://doi.org/10.3390/data8070120>.
- [11] Viriyavit W., Sornlertlamvanich V., Kongprawechnon W., Pongpaibool P.; "Bed Posture Classification Using Noninvasive Bed Sensors for Elderly Care. ", In *Frontiers in Artificial Intelligence and Applications* (2018). <https://doi.org/10.3233/978-1-61499-834-1-383>.

- [12] Enayati M., Skubic M., Keller J.M., Popescu M., Farahani N.Z. "Sleep Posture Classification Using Bed Sensor Data and Neural Networks", In Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (2018-july). <https://doi.org/10.1109/EMBC.2018.8512436>.
- [13] Green C., Bouchard M., Goubran R., Robillard R., Higginson C., Lee E., Knoefel F. "Sleep-Wake and Body Position Classification With Deep Learning Using Pressure Sensor Mat Measurements", 2023, IEEE International Symposium on Medical Measurements and Applications. <https://doi.org/10.1109/MEMEA57477.2023.10171884>.
- [14] Müller, A. C., & Guido, S. "Introduction to Machine Learning with Python: A Guide for Data Scientists". O'Reilly Media, 2016.
- [15] Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E., Chou, R., Glanville, J., Grimshaw, J.M., Hróbjartsson, A., Lalu, M.M., Li, T., Loder, E.W., Mayo-Wilson, E., McDonald, S., McGuinness, L.A., Stewart, L.A., Thomas, J., Tricco, A.C., Welch, V.A., Whiting, P., Moher, D.: The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Syst Rev.* 10, 1–11 (2021). <https://doi.org/10.1186/S13643-021-01626-4/FIGURES/1>.
- [16] Silva, A., Metrólho, J., Ribeiro, F., Fidalgo, F., Santos, O., & Dionisio, R. (2021). A Review of Intelligent Sensor-Based Systems for Pressure Ulcer Prevention. *Computers*, 11(1), 6. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/computers11010006>.
- [17] Fonseca, L., Ribeiro, F., & Metrólho, J. (2023). Lying-People Pressure-Map Datasets: A Systematic Review. *Data*, 8(1). <https://doi.org/10.3390/data8010012>.
- [18] Fonseca, L., Ribeiro, F., & Metrólho, J. (2023). Pressure-Based Posture Classification Methods and Algorithms: A Systematic Review. *Computers*, 12(5), 104. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/computers12050104>.