

Predição Automática de Escala de Avaliação de Equilíbrio Utilizando Estabilometria

Nathan H. C. Zebendo¹, Jonathan N. Gois¹, Diego R. G. Gonzalez¹,
Wesley L. Passos², Gabriel M. Araujo² e Amaro A. de Lima²

Resumo—O equilíbrio postural adequado é um aspecto fundamental para a saúde humana. Porém, com o avanço da idade ou na presença de doenças, é natural que a capacidade de se equilibrar em pé seja deteriorada, aumentando o risco de quedas, que podem até ser fatais. Um sistema de avaliação preciso e eficiente pode ser decisivo para mapear debilidades de equilíbrio e evitar acidentes. O modelo de avaliação MINI-BESTest tem por objetivo a construção desse diagnóstico. Com uma metodologia cientificamente comprovada e um profissional credenciado, é possível avaliar um paciente com acurácia. Este trabalho propõe uma versão automatizada do processo de avaliação, reduzindo subjetividades e a quantidade de informações necessárias. Com uma abordagem hierárquica, é possível estimar a nota do MINI-BESTest e seus subsistemas com uma precisão 17% maior do que o estado da arte.

Palavras-Chave—Equilíbrio Postural; Aprendizado de Máquina; Avaliação automática.

Abstract—Proper postural balance is a fundamental aspect of human health. However, with advancing age or the presence of diseases, it is natural for the ability to maintain an upright balance to deteriorate, increasing the risk of falls, which can even be fatal. A precise and efficient evaluation system can be decisive in mapping balance deficiencies and preventing accidents. The MINI-BESTest assessment model aims to construct this diagnosis. With a scientifically proven methodology and a certified professional, it is possible to accurately evaluate a patient. This study proposes an automated version of the assessment process, reducing subjectivity and the amount of necessary information. Using a hierarchical approach, it is possible to estimate the MINI-BESTest score and its subsystems with 17% greater accuracy than the current state of the art.

Keywords—Postural Balance; Machine Learning; Automatic Evaluation.

I. INTRODUÇÃO

A habilidade de manter-se e executar diferentes tarefas na postura ereta em pé é uma das principais habilidades em qualquer idade para um indivíduo com equilíbrio postural saudável [1]. O equilíbrio postural envolve a coordenação dos sistemas sensoriais e motor na estabilização do centro de massa do corpo diante de perturbações externas ou internas sem que haja quedas [2–4]. Entretanto, diferentes fatores podem afetar a capacidade de equilibrar-se de pé ou executar tarefas que demandem um movimento corporal adequado, como a idade, sedentarismo, doenças que afetem os sistemas visual, vestibular ou somatossensorial [1, 5] ou doenças neurológicas como a doença de Parkinson [6]. Mortes por queda

são frequentes em todo mundo, principalmente para indivíduos idosos. No Brasil, entre 2000 e 2019, foram registradas 135.209 mortes por queda em indivíduos com mais de 60 anos, com um tendência crescente no período analisado [7]. Por isso, o desenvolvimento de avaliações clínicas funcionais que auxiliem na predição do risco de queda [3] torna-se importante em uma população onde cresce o número de idosos.

Dois metodologias se destacam para a avaliação do equilíbrio postural: técnicas instrumentais e escalas de avaliação clínica [8–10]. A técnica instrumental mais utilizada é a estabilometria, que envolve a avaliação das oscilações da posição do centro de pressão (COP) de um indivíduo na posição ortostática medidas por plataforma de força [5, 11, 12]. Este método avalia como o corpo humano mantém sua postura e equilíbrio em resposta a diferentes estímulos sensoriais, normalmente em medições de até 60 s. Alterações nas oscilações do COP, tanto na área quanto na velocidade de oscilação, tem potencial de auxiliar na detecção e diagnóstico de deficiências nos sistemas envolvidos na manutenção do equilíbrio, como os sistemas nervoso central e periférico ou o sistema musculoesquelético, assim como na avaliação do risco de quedas [11, 13]. Entretanto, como as oscilações posturais envolvem estes diferentes sistemas fisiológicos, a interpretação destas medições necessita de outras informações sobre o indivíduo. Em virtude disso, frequentemente não há clareza sobre a causa de alterações no equilíbrio [3, 5].

Entre as escalas de avaliação, o *Balance Evaluation Systems Test* (BESTest) [14] é uma ferramenta abrangente que avalia o equilíbrio utilizando uma série de testes padronizados para medir a capacidade de um indivíduo de manter o equilíbrio sob diversas condições, podendo auxiliar assim na discriminação entre os diferentes tipos de desordens no equilíbrio [3]. A avaliação do BESTest consiste em um questionário com 27 tarefas, totalizando 108 pontos de nota em seis subsistemas envolvidos no equilíbrio postural: *Anticipatory Postural Adjustments* (APA), *Postural Responses* (RPC), *Sensory Orientation* (SO) e *Dynamic Gait* (DG), *Biomechanical Constraints* (BC) e *Stability Limits* (SL). Entre as suas principais limitações estão a necessidade de um profissional qualificado para avaliação e o tempo necessário para executar o teste [3]. Uma versão mais resumida desta avaliação, conhecida como *Mini-Balance Evaluation Systems Test* (MINI-BESTest) possui um tempo de execução menor pois avalia apenas quatro desses subsistemas (APA, RPC, SO e DG), possuindo 14 itens e apresentando nota em uma escala de 0 a 28 [15, 16]. O MINI-BESTest apresenta resultados semelhantes ao BESTest, podendo apresentar melhor desempenho na identificação de pacientes com doença de Parkinson [14]. Apesar de apresentar um resultado numérico, fatores como a experiência dos profissionais ou condições em

¹ Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Nova Friburgo-RJ, e-mails: nathan.zebendo@aluno.cefet-rj.br, {jonathan.gois, diego.gonzalez}@cefet-rj.br; ² Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Nova Iguaçu-RJ, e-mails: {wesley.passos, gabriel.araujo, amaro.lima}@cefet-rj.br.

que os testes foram realizados podem contribuir de forma subjetiva para este resultado.

Devido aos benefícios do MINI-BESTest na identificação de alterações no equilíbrio postural e seus subsistemas associados, uma alternativa proposta para contornar algumas de suas limitações é a predição automática da nota do MINI-BESTest a partir da estabilometria [17]. Ao inserir as variáveis de medições estabilométricas como entradas, um modelo de regressão poderia estimar a pontuação do MINI-BESTest assim como a pontuação de seus subtestes, APA, RPC, SO e DG. Entretanto, a escolha de quais variáveis estabilométricas podem ser utilizadas assim como a escolha de modelos de regressão com maior reprodutibilidade ainda são objeto de investigação.

O objetivo deste trabalho é a proposição de uma metodologia automatizada para o auxílio na avaliação postural por parte do profissional habilitado, através da predição da nota do MINI-BESTest e de seus subtestes a partir de dados estabilométricos. Contudo, além da avaliação postural, o trabalho propõe uma metodologia para a extração de características com a finalidade da predição mais acurada da avaliação.

As seguintes seções deste trabalho estão organizadas da seguinte forma: na Seção II são apresentados os trabalhos de avaliação estabilométrica utilizando técnicas de aprendizado de máquina; em seguida, na Seção III, é apresentada a metodologia proposta neste trabalho; os resultados obtidos pelo método proposto e a comparação com o estado da arte está disponível na Seção IV; por fim, as conclusões estão dispostas na Seção V.

II. TRABALHOS RELACIONADOS

O aumento da capacidade de avaliar o risco de quedas em indivíduos, especialmente aqueles com maior vulnerabilidade, como os idosos, é fundamental para prevenir lesões graves e melhorar a qualidade de vida. Estudos recentes têm explorado diversas abordagens tecnológicas, incluindo o uso de aprendizado de máquina e análise de trajetórias do COP, para aprimorar a precisão da avaliação do balanço postural e do risco de quedas.

Em [18], os autores exploraram a aplicação de seis algoritmos de aprendizado de máquina para prever quedas em um teste de equilíbrio, utilizando uma base de dados com 163 participantes. O estudo destacou que todos os modelos foram capazes de classificar com sucesso os participantes em grupos de risco de queda, demonstrando a eficácia dessas ferramentas na identificação precoce de indivíduos em risco.

Em [19] são fornecidas evidências numéricas da relação entre os subsistemas de controle de equilíbrio, pavimentando caminho para a utilização de aprendizado de máquina para analisar essas relações de forma mais detalhada.

Os autores de [20] utilizaram algoritmos de aprendizado de máquina para classificar o risco de quedas a partir de parâmetros posturográficos. O estudo, que incluiu 215 participantes, ressalta a relevância de abordagens baseadas em dados na melhoria das estratégias de prevenção de quedas.

O artigo [21] avançou no campo combinando técnicas de aprendizado de máquina com análises de variáveis no domínio do tempo e entropia, utilizando uma base de dados pública de COP. Os autores combinaram um classificador de análise discriminante por mínimos quadrados parciais com a

dinâmica não-linear das séries temporais de COP. Embora tenha se mostrado eficaz para classificar oscilações posturais relacionadas à idade, há a limitação de não explorar outras metodologias.

Os autores de [22] investigaram o ponto de corte do MINI-BESTest para prever o risco de quedas usando sinais do COP. O estudo revelou que a medição do COP é uma ferramenta promissora para estimar o risco de queda.

Em [23] as trajetórias do COP são modeladas matematicamente com o objetivo de classificar indivíduos idosos e com histórico de queda. Os parâmetros estimados demonstraram que as trajetórias do COP de indivíduos idosos são mais irregulares, fornecendo uma base potencial para intervenções preventivas.

O estudo em [24] demonstrou como redes neurais profundas podem ser usadas para prever riscos de queda com alta precisão, utilizando uma base de dados pública contendo sinais capturados a partir de uma plataforma de força, ressaltando a importância da simplicidade arquitetônica da rede e da mínima complexidade em tais modelos.

Os autores de [17] implementaram algoritmos de aprendizados de máquina para avaliar com precisão os subsistemas de controle de equilíbrio. Utilizando uma base de dados pública de avaliação de equilíbrio humano, o estudo introduziu novos parâmetros que demonstraram melhorar a precisão da avaliação do controle de equilíbrio.

Esses estudos demonstram a crescente tendência de aplicar métodos de aprendizado de máquina e análise de dados avançada para aprimorar a previsão de testes clínicos e a avaliação de riscos de quedas. Apesar dos avanços, as limitações como a dependência de bases de dados abertas e a necessidade de maior validação clínica indicam áreas para futuras investigações. A contínua exploração e integração de novas tecnologias, bem como o desenvolvimento de modelos mais robustos e acessíveis, são fundamentais para avançar no campo da prevenção de quedas e reabilitação.

III. METODOLOGIA

Nesta Seção será detalhada a base de dados utilizada neste trabalho, as características propostas para a avaliação automática e a metodologia empregada para tal fim.

A. Base de dados

Neste trabalho foi utilizada a BDS (do inglês, *Balance Data Set*) [25], uma base de dados pública na qual foram medidas as oscilações posturais de 163 voluntários (116 mulheres), com idade entre 18 e 85 anos, massas corporal entre 44,0 kg e 75,9 kg, altura entre 1,40 m e 1,89 m e índices de massa corpórea (IMC) variando entre 17,2 a 31,9 kg/m². Dentre os participantes do teste, 10% relataram uma ou mais limitação física, incluindo déficits auditivos, vestibulares, visuais, cognitivos ou musculoesqueléticos.

O protocolo experimental envolvia permanecer sobre uma plataforma de força na posição ortostática, com os pés orientados em um lugar fixo por 60 s. Ao todo, foram coletados dados em quatro condições experimentais: ficar em pé sobre uma superfície rígida ou de espuma, com os olhos abertos ou fechados. Cada disposição foi repetida três vezes, totalizando 12 medições por voluntário.

As forças de reação do solo, os momentos de força e o deslocamento do COP nas direções anterior-posterior (AP) e medial-lateral (ML) foram registrados com frequência de amostragem de 100 Hz utilizando uma plataforma de força (OPT400600-1000; AMTI, Watertown, MA, USA) e um módulo de aquisição (*Optima Signal Conditioner*, AMTI, Watertown, MA, USA). Posteriormente os sinais foram filtrados por um filtro passa-baixas de Butterworth de quarta ordem e frequência de corte 10 Hz sem deslocamento/atraso de fase, para minimizar ruídos e harmônicos indesejáveis [26]. A base de dados contém ainda questionários de identificação individual, medições antropométricas e resultados de testes clínicos de equilíbrio, como o MINI-BESTest.

Portanto, o banco de dados é composto pela identificação do teste realizado, identificação do sujeito (peso, altura, IMC, gênero, tamanho do pé, nacionalidade, cor da pele, anos de estudo, tipo de calçado preferencial, doenças, medicamentos usados e deficiências), número de quedas nos últimos 12 meses, respostas dos questionários orientados *Falls Efficacy Scale-International* (FES-I) [27] e *International Physical Activity Questionnaire Short Version* (IPAQ) [28], o tempo gasto na tentativa da realização do teste e as notas referente ao MINI-BESTest e seus subtestes (APA, RPC, SO e DG), além das 12 medições estabilométricas por voluntário.

Além disso, pelo fato da limitação no número de voluntários e pela quantidade de testes realizados, é importante salientar o desbalanceamento do conjunto de dados tendo vieses nos extremos das avaliações.

B. Extração de características

Foram extraídos parâmetros das medições do deslocamento do COP nas direções ML e AP, COP_x e COP_y respectivamente. Como a posição dos pés na plataforma varia entre os testes e os indivíduos, foi removida a tendência linear (*fitting linear*) dos dados em ambas as direções. A partir dos sinais de COP_x e COP_y , foram calculadas a variância, entropia, curtose (*kurtosis*), assimetria (*skewness*), RMS (*Root Mean Square*), amplitude, fator de crista, fator de impulso, fator de curtose, velocidade média e média da velocidade resultante (COP_{vel}). Outra característica selecionada a partir do padrão de deslocamento do centro de pressão foi a área elíptica [29] que envolve a maior parte do deslocamento do COP sobre a plataforma de força (COP_{area}). Além das características temporais, foram extraídas as parâmetros no domínio da frequência: frequência média (COP_{freq}) e máxima de potência, percentis de 50% e 95% da densidade espectral de potência (do inglês, *Power Spectral Density* – PSD).

C. Modelo Proposto

Seguindo similar estrutura experimental da adotada em [17], foi utilizado um extrato do conjunto de dados BDS, composto por 1896 medições de 158 voluntários, tendo sido suprimido todas as medições dos 5 voluntários cuja a coleta tinha sido incompleta. O objetivo de seguir o mesmo raciocínio experimental é permitir a comparação direta entre o estado da arte e a proposta apresentada no texto.

As variáveis COP_x e COP_y das 12 medições de cada voluntário foram concatenadas formando uma série temporal, de onde são extraídas as características apresentadas na subseção

III-B, sendo 12 temporais, 1 geométrica (área percorrida), 4 espectrais e 4 antropométricas, compondo um vetor de 12 características para cada usuário.

Para a predição das notas do MINI-BESTest foi utilizado um modelo de regressão [30] com método de aprendizagem estatística supervisionada, considerando como entradas as características extraídas e também os dados antropométricos correspondentes a cada indivíduo como idade, peso, altura e gênero. O regressor de aprendizagem supervisionada empregado foi o *Support Vector Regressor* (SVR) [31].

Observando que as menores notas no MINI-BESTest são de voluntários idosos e/ou que apresentam alguma limitação física, cognitiva ou doença, um modelo específico para a predição destas notas pode trazer uma confiabilidade maior ao modelo.

Então, a proposição deste trabalho é uma abordagem hierárquica de classificação baseada em duas etapas (Fig. 1):

- 1) Estratificação: com os dados de treino e um conjunto de características reduzido (características antropométricas, COP_{area} , COP_{vel} e COP_{freq}) uma separação em dois grupos é proposta através do método não-supervisionado *K-means*. Nesta etapa são gerados dois grupos de treino, Treino A e Treino B, e os centroides associados a cada um destes. A separação foi feita em apenas dois grupos para não comprometer a generalização do modelo encontrado, dado que ao dividir o conjunto de dados, se reduz o número de amostras no treinamento.
- 2) Classificação: na etapa de classificação, os dados segregados da etapa anterior são responsáveis pelo treinamento de dois modelos distintos: SVR A e SVR B. Esses modelos, por tratarem de um espaço amostral menor de indivíduos, foram propostos com o intuito de um melhor ajuste na regressão.

Como a quantidade de dados na etapa de treino é reduzida, este trabalho propõe a utilização do método de validação cruzada *K-fold* [32] para a redução de riscos de sobreajuste e garantir a generalização do modelo proposto.

Inicialmente os dados foram separados em K grupos distintos. A etapa de treinamento foi realizada com $K - 1$ grupos e a de teste com 1 destes grupos. Cada iteração rotaciona qual grupo está na etapa de teste e qual está na etapa de treinamento.

A figura de mérito utilizada neste trabalho foi o erro absoluto médio (MAE, do inglês *Mean Absolute Error*),

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

onde y_i é a saída real, \hat{y}_i é a saída estimada e n é o número de amostras. Ainda, utilizou-se *K-fold* com $K = 10$ e, portanto, os valores reportados são a média dos *folds*.

O estudo apresentado aplica SVR no vetor de características dos dados de 9 *folds* no intuito de treinar modelos que estimem os resultados do MINI-BESTest, APA, RPC, SO e DG. Uma vez treinados os modelos, o teste é realizado no *fold* restante. No entanto, técnicas de aprendizado de máquina requerem a otimização dos hiperparâmetros dos algoritmos utilizados. Desta forma, na busca ótima de hiperparâmetros usou-se o algoritmo do *Grid Search*, que testa todos os parâmetros pré-configurados, e retornar o conjunto que obteve melhor desempenho, assim como a rede treinada. Os hiperparâmetros

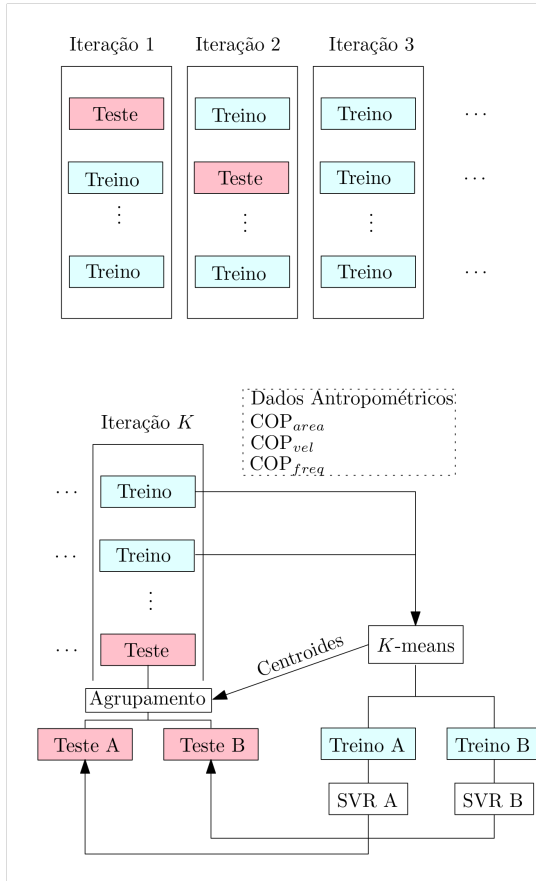


Fig. 1. Modelo de estratificação de dados aplicado ao treinamento.

avaliados foram $\epsilon=\{0,1;0,2;\dots;0,9\}$ e as funções de kernel linear, polinomial, RBF (do inglês, *radial basis function*) e sigmoideal.

O sistema proposto no trabalho consiste em avaliar a ideia da complexidade da representação dos dados para se utilizar um modelo único. Desta forma, os dados foram separados em $k=2$ agrupamentos utilizando um algoritmo não supervisionado de aprendizado de máquina, chamado *k-means*. Os dados foram divididos em agrupamentos A e B, cujos centróides (vetores que representam o centro dos agrupamentos) são utilizados para decidir a qual agrupamento pertence um dado teste (desconhecido). São gerados modelos SVR diferentes para cada agrupamento e o vetor de teste em análise é aplicado ao modelo no qual está associado.

IV. RESULTADOS

A Tabela I apresenta os resultados MAE para o MINI-BESTest, APA, RPC, SO e DG do método proposto separado por agrupamento, A e B, além de calcular média ponderada do desempenho para gerar um valor único e poder comparar com o SVR puro (sem utilizar o *k-means*) e com o Ren *et al.* [17]. Em uma análise preliminar dos dados, foi possível observar que dois grupos de amostras estavam separados pela mediana da nota de avaliação do sistema. Os agrupamentos resultantes do *k-means* não estão relacionados com a mediana, mas tendem relacionar as amostras de entrada espacialmente. Esse fato fica mais evidente, quando se observa que os agrupamentos dividiram os dados em aproximadamente 50%

em todas as ocorrências com variações de até 47,5% para o agrupamento A e 52,5% para o B. Numericamente o método proposto supera o estado da arte ao estimar os resultados do MINI-BESTest, AP, RPC e SO, atingindo MAE de 2,27, 0,71, 0,95 e 0,60, representando uma melhoria em desempenho de aproximadamente 17%, 14%, 2% e 6%, respectivamente. Já no caso de DO ocorreu uma piora de desempenho de aproximadamente 7%, pois o método proposto obteve MAE de 1,05 e o Ren *et al.* [17] obteve 0,98. Vale ressaltar que tanto para o caso do SVR puro quanto para os agrupamentos A e B, os hiperparâmetros ótimos foram kernel sigmoideal e $\epsilon = 0,9$.

TABELA I

RESULTADOS MAE DO MÉTODO PROPOSTO, AGRUPAMENTOS A (AGR. A), B (AGR. B) E MÉDIA PONDERADA (MP), COM SVR COMPARADO COM REN *et al.* [17] E SVR PURO PARA OS CASOS DE MINI-BESTest (M-B), APA, RPC, SO E DG.

Método	M-B	APA	RPC	SO	DG
Ren <i>et al.</i> [17]	2,66	0,83	0,97	0,64	0,98
SVR	3,48	1,16	0,97	0,72	1,39
Proposto (MP)	2,27	0,71	0,95	0,60	1,05
Agr. A	1,98	0,61	0,94	0,50	0,92
Agr. B	2,54	0,79	0,96	0,68	1,18

Os resultados corroboram para a ideia proposta na metodologia de não tratar os dados como se pertencessem a um grupo único, mostrando claramente superioridade numérica da técnica proposta, principalmente no caso do MINI-BESTest. Este conceito parece ser bem coerente uma vez que o conjunto de dados representa testes reais realizados com humanos de vários grupos etários e condições, que preenchem as mais variadas escalas nos testes de equilíbrio e um único grupo possivelmente não é capaz de explicar as sutilezas dos diferentes casos. Outro ponto a se ressaltar é que a metodologia, embora tenha utilizado somente 2 agrupamentos devido ao limitado conjunto de 158 voluntários, numa possível expansão do conjunto de dados, a metodologia seria extensível ao aumento dos agrupamentos.

V. CONCLUSÕES E TRABALHOS FUTUROS

Avaliação de equilíbrio postural requer um profissional especializado para analisar dados medidos em plataformas de força, o que demanda tempo. Esse artigo propôs um sistema automatizado de avaliação, que utiliza aprendizado de máquina para auxiliar o profissional com o objetivo de reduzir o tempo de avaliação, bem como mitigar possível viés do avaliador.

A ideia consistiu em capturar os dados medidos em plataformas de força, extrair características, separar os dados em 2 possíveis agrupamentos e treinar modelos SVR dependentes desses agrupamentos. Uma nova medição ao ser testada, terá primeiramente suas características extraídas, depois de acordo com sua proximidade ao centróide de cada agrupamento, será aplicada ao modelo correspondente gerando sua saída, que poderá estimar tanto o resultado do MINI-BESTest, quanto dos subsistemas APA, RPC, SO e DG. Todos associados a modelos/tarefas diferentes.

O desempenho do sistema proposto foi bastante encorajador, uma vez que foi capaz de superar em 17% o MAE do estado da

arte para o MINI-BESTest, obtendo também melhores MAE para os subsistemas APA, RPC e SO, perdendo somente para o DG. Porém, como os dados são limitados, faz-se necessária uma validação clínica para a real comprovação da eficácia do método.

A proposta de adotar agrupamentos no intuito de lidar com maior complexidade e possivelmente diferente natureza dos dados se mostrou bastante eficaz. No entanto, uma investigação quanto a importância das características utilizadas pode reduzir a dimensionalidade do vetor de entrada e aumentar a eficiência do regressor. Adicionalmente o estudo de outras técnicas de regressão e expansão artificial do conjunto de dados podem ser interessantes passos futuros.

REFERÊNCIAS

- [1] N. Van Humbeeck, R. Kliegl, and R. T. Krampe, “Lifespan changes in postural control,” *Scientific Reports*, vol. 13, no. 1, p. 541, 2023.
- [2] F. B. Horak, “Postural orientation and equilibrium: what do we need to know about neural control of balance to prevent falls?” *Age and ageing*, vol. 35, no. suppl_2, pp. ii7–ii11, 2006.
- [3] M. Mancini and F. B. Horak, “The relevance of clinical balance assessment tools to differentiate balance deficits,” *European journal of physical and rehabilitation medicine*, vol. 46, no. 2, p. 239, 2010.
- [4] A. S. Pollock, B. R. Durward, P. J. Rowe, and J. P. Paul, “What is balance?” *Clinical rehabilitation*, vol. 14, no. 4, pp. 402–406, 2000.
- [5] J. E. Visser, M. G. Carpenter, H. van der Kooij, and B. R. Bloem, “The clinical utility of posturography,” *Clinical Neurophysiology*, vol. 119, no. 11, pp. 2424–2436, 2008.
- [6] J.-H. Park, Y.-J. Kang, and F. B. Horak, “What is wrong with balance in parkinson’s disease?” *Journal of movement disorders*, vol. 8, no. 3, p. 109, 2015.
- [7] I. C. M. Gonçalves, “Análise da tendência de mortalidade por quedas em idosos, no brasil, no período de 2000-2019,” 2022.
- [8] S.-H. Park, “Tools for assessing fall risk in the elderly: A systematic review and meta-analysis,” *Aging Clinical and Experimental Research*, vol. 30, no. 1, pp. 1–16, Apr. 2017.
- [9] N. Banker, C. Gough, and S. Gordon, “Classification of balance assessment technology: A scoping review of systematic reviews,” *Studies in Health Technology and Informatics*, vol. 268, pp. 45–59, Mar. 2020.
- [10] L. Abou, J. Peters, E. Wong, R. Akers, M. S. Dossou, J. J. Sosnoff, and L. A. Rice, “Gait and balance assessments using smartphone applications in Parkinson’s disease: A systematic review,” *Journal of Medical Systems*, vol. 45, no. 9, p. 87, Aug. 2021.
- [11] F. Quijoux, A. Nicolai, I. Chairi, I. Bargiotas, D. Ricard, A. Yelnik, L. Oudre, F. Bertin-Hugault, P.-P. Vidal, N. Vayatis *et al.*, “A review of center of pressure (cop) variables to quantify standing balance in elderly people: Algorithms and open-access code,” *Physiological reports*, vol. 9, no. 22, p. e15067, 2021.
- [12] S. B. Richmond, B. W. Fling, H. Lee, and D. S. Peterson, “The assessment of center of mass and center of pressure during quiet stance: Current applications and future directions,” *Journal of biomechanics*, vol. 123, p. 110485, 2021.
- [13] F.-Y. Liao, C.-C. Wu, Y.-C. Wei, L.-W. Chou, K.-M. Chang *et al.*, “Analysis of center of pressure signals by using decision tree and empirical mode decomposition to predict falls among older adults,” *Journal of healthcare engineering*, vol. 2021, 2021.
- [14] F. B. Horak, D. M. Wrisley, and J. Frank, “The balance evaluation systems test (bestest) to differentiate balance deficits,” *Physical therapy*, vol. 89, no. 5, pp. 484–498, 2009.
- [15] F. Franchignoni, F. Horak, M. Godi, A. Nardone, and A. Giordano, “Using psychometric techniques to improve the balance evaluation system’s test: the mini-bestest,” *Journal of rehabilitation medicine: official journal of the UEMS European Board of Physical and Rehabilitation Medicine*, vol. 42, no. 4, p. 323, 2010.
- [16] L. King and F. Horak, “On the mini-BESTest: scoring and the reporting of total scores,” *Physical therapy*, vol. 93, no. 4, pp. 571–575, 2013.
- [17] P. Ren, S. Huang, Y. Feng, J. Chen, Q. Wang, Y. Guo, Q. Yuan, D. Yao, and D. Ma, “Assessment of balance control subsystems by artificial intelligence,” *IEEE transactions on neural systems and rehabilitation engineering*, vol. 28, no. 3, pp. 658–668, 2020.
- [18] J. Pennone, N. F. Agüero, D. M. Martini, L. Mochizuki, and A. A. do Passo, Suaide, “Fall prediction in a quiet standing balance test via machine learning: Is it possible?” *PLoS One*, vol. 19, no. 4, p. e0296355, 2024.
- [19] K. Wu, J. Zhang, A. W. A. Mohsen, Z. Wang, Y. Jin, W. Wang, X. Peng, D. Yao, P. A. Valdes-Sosa, and P. Ren, “Analysis of the relation between balance control subsystems: A structural equation modeling approach,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 32, pp. 625–637, 2024.
- [20] H.-W. Liang, R. Ameri, S. Band, H.-S. Chen, S.-Y. Ho, B. Zaidan, K.-C. Chang, and A. Chang, “Fall risk classification with posturographic parameters in community-dwelling older adults: a machine learning and explainable artificial intelligence approach,” *Journal of NeuroEngineering and Rehabilitation*, vol. 21, p. 15, 2024.
- [21] V. Alcan, “Enhancing age-related postural sway classification using partial least squares-discriminant analysis and hybrid feature set,” *Neural Computing and Applications*, vol. 36, pp. 5621–5643, 2024.
- [22] L. W.-Y., C. Y.-H., L. F.-Y., C. K.-M., and C. L.-W., “Cutoff point of mini-balance evaluation systems test scores for elderly estimated by center of pressure measurements by linear regression and decision tree classification,” *Life*, vol. 12, no. 12, p. 2133, 2022.
- [23] Y. Tawaki, T. Nishimura, and T. Murakami, “Classification of older and fall-experienced subjects by postural sway data using mass spring damper model,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 40–49, 2021.
- [24] M. Savadkoobi, T. Oladunni, and L. A. Thompson, “Deep neural networks for human’s fall-risk prediction using force-plate time series signal,” *Expert Systems with Applications*, vol. 182, no. 15, p. 115220, 2021.
- [25] D. A. Santos and M. Duarte, “A public data set of human balance evaluations,” *PeerJ*, vol. 4, p. e2648, 2016.
- [26] I. W. Selesnick and C. S. Burrus, “Generalized digital butterworth filter design,” *IEEE Transactions on signal processing*, vol. 46, no. 6, pp. 1688–1694, 1998.
- [27] G. I. Kempen, L. Yardley, J. C. Van Haastregt, G. R. Zijlstra, N. Beyer, K. Hauer, and C. Todd, “The short fes-i: a shortened version of the falls efficacy scale-international to assess fear of falling,” *Age and ageing*, vol. 37, no. 1, pp. 45–50, 2008.
- [28] C. L. Craig, A. L. Marshall, M. Sjöström, A. E. Bauman, M. L. Booth, B. E. Ainsworth, M. Pratt, U. Ekelund, A. Yngve, J. F. Sallis *et al.*, “International physical activity questionnaire: 12-country reliability and validity,” *Medicine & science in sports & exercise*, vol. 35, no. 8, pp. 1381–1395, 2003.
- [29] M. Duarte, “Comments on “ellipse area calculations and their applicability in posturography” (schubert and kirchner, vol. 39, pages 518–522, 2014),” *Gait Posture*, vol. 41, no. 1, pp. 44–45, 2015.
- [30] Y. S. Abu-Mostafa, M. Magdon-Ismail, and H.-T. Lin, *Learning from data*. AMLBook New York, 2012, vol. 4.
- [31] M. Awad, R. Khanna, M. Awad, and R. Khanna, “Support vector regression,” *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, pp. 67–80, 2015.
- [32] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An introduction to statistical learning*. Springer, 2013, vol. 112.