

# Um Modelo Sequencial para Identificação do Comprometimento Cognitivo Usando Dados de Acelerômetro

Vitória C. dos S. Camelo<sup>1</sup>, Claurton de A. Siebra<sup>1</sup>

<sup>1</sup>Centro de Informática, Universidade Federal da Paraíba  
João Pessoa – PB – Brasil

vitoria.cristhyna@academico.ufpb.br, claurton@ci.ufpb.br

**Abstract.** *The progression of certain cognitive impairments can be slowed when identified early. However, current diagnostic methods are costly and not widely accessible to the general population. This paper presents a sequence model that leverages accelerometer data to characterize behavioural routines, enabling the differentiation between cognitively impaired and mentally healthy individuals. The raw data, collected at 80 Hz, was consolidated into 24-hours time windows and represented by 13 features. The final dataset (N = 2934) with 429,912 hours of data was used to train a Conv1D-based sequence model, which achieved significantly higher AUC-ROC ( $0.90 \pm 0.01$ ) than cross-sectional models ( $0.59 \pm 0.02$ ).*

**Resumo.** *A identificação precoce é essencial para o retardo de certos comprometimentos cognitivos. Porém, métodos atuais para diagnóstico não estão amplamente acessíveis à população. Este artigo apresenta um modelo para análise de sequências que utiliza dados de acelerômetro para caracterizar rotinas comportamentais, permitindo a diferenciação entre indivíduos com e sem comprometimento cognitivo. Dados coletados a 80 Hz foram consolidados em janelas de tempo de 24 horas e representados por 13 atributos. O dataset final (N = 2934) com 429.912 horas foi usado para treinar um modelo Conv1D, o qual obteve um resultado melhor (AUC-ROC de  $0,90 \pm 0,01$ ) em comparação ao obtido com dados transversais ( $0,59 \pm 0,02$ ).*

## 1. Introdução

Pesquisas recentes evidenciam que intervenções clínicas destinadas ao tratamento de comprometimentos cognitivos podem atuar de forma eficaz na atenuação de sintomas, como déficits de memória e atenção, contribuindo para o retardamento do declínio neurofuncional e para a preservação da qualidade de vida dos pacientes, especialmente quando o diagnóstico é realizado precocemente [Marvi et al. 2024]. De fato, o diagnóstico em estágios iniciais, anterior à ocorrência de danos neuronais significativos, constitui uma janela crítica para a implementação de estratégias terapêuticas mais eficazes [Auso et al. 2020].

Os métodos diagnósticos convencionais baseiam-se, predominantemente, na análise de biomarcadores, como a concentração das proteínas beta-amiloide e tau no líquido cefalorraquidiano ou em amostras sanguíneas, além do uso de técnicas avançadas de neuroimagem, como a ressonância magnética funcional (fMRI) e a tomografia por emissão de pósitrons (PET). Apesar de sua elevada sensibilidade e especificidade, esses procedimentos são frequentemente invasivos, dispendiosos e de acesso restrito, o que limita sua aplicabilidade em estratégias populacionais de triagem ou monitoramento contínuo [Wittenberg et al. 2019].

Nesse contexto, torna-se importante o desenvolvimento de soluções diagnósticas que sejam não invasivas, economicamente viáveis e escaláveis. Dispositivos vestíveis emergem como uma tecnologia promissora ao possibilitar a coleta contínua de variáveis fisiológicas (e.g., frequência cardíaca, variabilidade da frequência cardíaca, temperatura corporal) e comportamentais (e.g., padrões de sono, mobilidade, rotinas diárias), fornecendo dados de alta resolução temporal que podem ser utilizados para inferência sobre o estado cognitivo do indivíduo [Gaur et al. 2024].

Nossa proposta se baseia na aplicação de técnicas de aprendizado de máquina aos dados sequenciais coletados por dispositivos vestíveis, em especial acelerômetros, o que pode permitir o desenvolvimento de modelos preditivos capazes de estimar o risco de comprometimento cognitivo em estágios iniciais. Tais modelos podem viabilizar intervenções mais precoces e centradas no paciente, contribuindo para uma abordagem preventiva e proativa em saúde cognitiva.

As próximas seções estão organizadas da seguinte maneira: em princípio, destacamos os trabalhos relacionados a este artigo, descrevendo posteriormente os materiais e métodos empregados. Em seguida, abordamos os resultados obtidos com os diferentes modelos e discutimos sobre as técnicas de explicabilidade utilizadas. Ao final, apontamos as limitações desta pesquisa e propomos estratégias para avanço na temática.

## **2. Trabalhos Relacionados**

Estudos recentes têm explorado diversas aplicações de dispositivos vestíveis. Por exemplo, Ardle et al. (2020) demonstraram o uso de dados de acelerômetros para derivar características da marcha e diferenciar subtipos de demência, embora a precisão alcançada tenha sido modesta. A revisão de Weizman et al. (2021) discute outros estudos primários focados na relação entre demência e características da marcha derivadas de vestíveis. Suas descobertas indicam que muitos estudos se concentram em detectar eventos relacionados à demência, como prognóstico de quedas ou parâmetros de atividade física que são preditores independentes do risco de queda. Outro atributo em investigação baseado em vestíveis é a variabilidade da frequência cardíaca (VFC) [Alharbi et al. 2020], proposta como um potencial marcador fisiológico para demência. No entanto, a detecção confiável de demência usando VFC requer um monitoramento contínuo de longo prazo para rastrear mudanças sutis ao longo do tempo, já que medições pontuais ou monitoramento de curto prazo podem não capturar as tendências ou padrões necessários para a detecção precisa do declínio cognitivo [Whelan et al. 2022].

O estudo recente de Addae et al. (2024) oferece uma revisão abrangente de tecnologias vestíveis e não vestíveis que podem ser usadas para detectar o declínio neurofuncional. No entanto, alguns desses métodos, como a utilização de câmeras, apresentam desafios para implementação, enquanto outros, como a análise de voz [Jahan et al. 2024], ainda estão em fase de avaliação. De fato, a análise de voz para detecção de comprometimento cognitivo é uma área emergente de pesquisa que utiliza técnicas de processamento de fala e linguagem para identificar sinais precoces de dano neuronal. Em contraste, nosso estudo foca em dados de acelerômetros devido à sua facilidade de uso, acessibilidade, ampla disponibilidade e natureza não intrusiva. Nossa hipótese é que a avaliação dos dados gerados dentro de uma janela de tempo contínua de 24 horas

é suficiente para diferenciar indivíduos com comprometimento cognitivo daqueles mentalmente saudáveis. Essa hipótese é avaliada utilizando um modelo sequencial, ao qual foram incorporadas técnicas de explicabilidade para melhorar a interpretabilidade dos resultados.

O declínio cognitivo frequentemente se manifesta em mudanças sutis no comportamento ao longo do dia, como interrupções nos ciclos de sono e vigília, aumento da inatividade durante o dia ou rotinas irregulares. Dados com resolução horária permitem detectar essas flutuações mais detalhadas que passariam despercebidas em resumos diários. Além disso, condições como o “sundowning”, aumento da confusão e agitação no final da tarde ou à noite, são específicas do tempo e ocorrem dentro do mesmo dia, e não apenas entre diferentes dias. A resolução horária favorece a identificação desses fenômenos clinicamente relevantes [Rykov et al. 2024, Moyle et al. 2021].

### 3. Materiais e Métodos

#### 3.1. Dataset

Nosso conjunto de dados foi derivado do programa *National Health and Nutrition Examination Survey* (NHANES), versão de 2011 a 2014 [Brody et al. 2019], e contém os seguintes atributos associados aos participantes (N=2934):

- Dados demográficos: idade e sexo biológico. Esses valores são usados apenas para análises estatísticas e não como entradas para os modelos;
- Acelerômetro: valor triaxial dado em MIMS (*Monitor-Independent Movement Summary*) por minuto. Esse valor foi avaliado ao longo de 9 dias contínuos. No entanto, apenas 7 dias, de domingo a sábado, foram considerados, já que o primeiro e o último dias estão incompletos. Isso resulta em um total de 429.912 horas ( $2934 \times 7 \times 24$ );
- Testes de funcionamento cognitivo: esses testes incluem os módulos de aprendizado e recordação de palavras do *Consortium to Establish a Registry for Alzheimer's Disease* (CERAD) [Morris et al. 1989], o teste de Fluência Verbal por Animais [Clark et al. 2009] e o teste de Substituição de Símbolos por Dígitos (DSST) [Wechsle 1997].

MIMS é uma medida padronizada de atividade física derivada de dados de acelerômetros, projetada especificamente para ser independente da marca ou tipo de acelerômetro utilizado [John et al. 2019]. Desta forma, embora o NHANES tenha usado o acelerômetro ActiGraph GT3X+ para coleta dos dados, o MIMS permite a comparação entre estudos que utilizam diferentes dispositivos.

#### 3.2. Pré-processamento

O modelo de sequência proposto é um classificador binário com 13 atributos de entrada e uma saída com duas possibilidades (com e sem comprometimento cognitivo). Os 13 atributos de entrada, que qualificam cada hora de avaliação dos dados, são: (1) soma de minutos dormindo, (2) soma de minutos em estado sedentário, (3) soma de minutos em atividade física leve, (4) soma de minutos em atividade física moderada, (5) soma de

minutos em atividade física vigorosa, (6) valor médio do sinal, (7) valor máximo do sinal, (8) valor mínimo do sinal, (9) desvio padrão do sinal, (10) entropia do sinal, (11) valor mediano do sinal, (12) valor de curtose do sinal e (13) dia da semana representado como um número de 1 a 7. As características estatísticas (média, máximo, mínimo, desvio padrão, entropia, mediana e curtose) são atributos clássicos usados para representar sinais de acelerômetros [Siebra and Wac 2025, Tsanousa et al. 2020]. A curtose, por exemplo, é uma medida da “cauda” de uma distribuição e pode indicar com que frequência ocorrem valores atípicos. A modelagem da atividade física usando os pontos de corte MIMS foi baseada em [Phillips et al. 2020] e descrita da seguinte forma:

- Sedentarismo:  $< 1.0$  MIMS;
- Atividade leve:  $1.0$  a  $< 5$  MIMS;
- Atividade moderada:  $5$  a  $< 30$  MIMS;
- Atividade intensa:  $\geq 30$  MIMS.

A consolidação dos testes cognitivos nas duas saídas (positivo e negativo para comprometimento cognitivo) foi baseada em dois estudos [Ma et al. 2023, Tao et al. 2022]. Cada teste cognitivo é analisado por meio do cálculo do z-score, que é então acumulado em um escore total de cognição [Ma et al. 2023]. O menor quartil do escore total de cognição é utilizado como ponto de corte. No nosso caso, esse valor foi  $-2,12$ . Os pacientes acima do ponto de corte foram atribuídos ao grupo de controle (0). Os demais foram atribuídos ao grupo com comprometimento cognitivo (1). Sugerimos o trabalho de Shi et al. (2023) para uma melhor compreensão sobre como combinar os escores de função cognitiva do NHANES.

### 3.3. Modelos

O classificador *Random Forest* (RF) foi utilizado como modelo de análise para os dados transversais. Nesse modelo, a unidade de processamento para organização dos dados de entrada foi “hora”, totalizando deste modo 429.912 instâncias, cada uma com 13 atributos. Assim, esse modelo analisa as “horas” dos participantes, o que certamente não é a melhor abordagem, mas funciona como uma espécie de *baseline*. Ou seja, os resultados desse primeiro experimento permitem comparações com análises baseadas em sequências de dados mais longas, enfatizando a importância desta última.

Em seguida, utilizamos uma arquitetura de rede neural convolucional 1D (Tabela 1) para gerar nosso modelo de sequência. Nesse caso, cada participante é responsável por gerar 7 sequências de 24 horas. A decisão por tais modelos (RF e Conv1D) foi baseada em experimentos anteriores encontrados na literatura [Siebra and Wac 2025] e em testes decorrentes de outros trabalhos do nosso grupo de pesquisa.

Os modelos foram compilados por meio do otimizador *Adam* e a função de perda de entropia cruzada binária. O treinamento foi realizado ao longo de 10 épocas, com um tamanho de lote (*batch*) de 64. Dado o desequilíbrio entre as classes dos grupos sem (75,4%) e com comprometimento cognitivo (24,6%), foi aplicada uma estratégia de ponderação de classes para ajustar a importância dos erros, atribuindo maior peso aos erros relacionados à classe minoritária. Os pesos são calculados automaticamente, sendo proporcionais à taxa de ocorrência de cada classe. Por fim, as métricas da área sob a

curva da característica de operação do receptor (*area under curve of receiver operating characteristic*, AUC-ROC), área sob a curva de precisão-revocação (*area under the precision-recall curve*, AUPRC), sensibilidade e especificidade foram utilizadas na avaliação dos modelos.

**Tabela 1. Arquitetura da rede neural (Conv1D) para classificação binária**

Layer (type)	Output Shape	Param #
input_layer_2 (InputLayer)	(None, 24, 13)	0
conv1d (Conv1D)	(None, 22, 64)	2.560
max_pooling1d (MaxPooling1D)	(None, 11, 64)	0
conv1d_1 (Conv1D)	(None, 9, 128)	24.704
max_pooling1d_1 (MaxPooling1D)	(None, 4, 128)	0
flatten (Flatten)	(None, 512)	0
dense_4 (Dense)	(None, 64)	32.832
dropout_4 (Dropout)	(None, 64)	0
dense_5 (Dense)	(None, 1)	65
Total de parâmetros: 60.161 (235,00 KB)		

**3.4. Explicabilidade**

Em concordância com as regulamentações recentes [Gornet and Maxwell 2024] sobre o uso de inteligência artificial em domínios críticos como a saúde, foi incorporado um módulo inicial de explicabilidade para facilitar a interpretação dos resultados das classificações. Esse módulo utiliza duas estratégias. Primeiramente, empregamos o método de Importância dos Atributos pela Redução na AUC (*Feature Importance by Decrease in AUC*), o qual determina a importância dos atributos em um modelo preditivo medindo o impacto na AUC-ROC do modelo quando um atributo específico é permutado ou removido. Em seguida, foi utilizado o método de Propagação de Relevância em Camadas (*Layer-Wise Relevance Propagation*), que funciona retropropagando as ativações da camada de saída da rede pelas suas camadas escondidas, redistribuindo a relevância da saída para as características de entrada com base em sua contribuição para a predição.

**4. Resultados**

**4.1. Análise Descritiva**

A estatística descritiva foi utilizada para se obter um melhor entendimento das principais características do conjunto de dados e garantir que as distribuições relevantes estivessem adequadamente representadas. Um exemplo é a distribuição entre participantes do sexo masculino (N=1317, 221.256 horas) e feminino (N=1242, 208.656 horas), a qual se mostrou bem similar. Uma distribuição particularmente importante, mostrada na Figura 1, destaca que, com exceção do grupo de participantes com 80 anos ou mais, a população com comprometimento cognitivo (CI) está distribuída de forma

equilibrada entre os grupos etários. Esse equilíbrio ajuda a mitigar o viés potencial ao prever comprometimentos cognitivos com base apenas na idade.

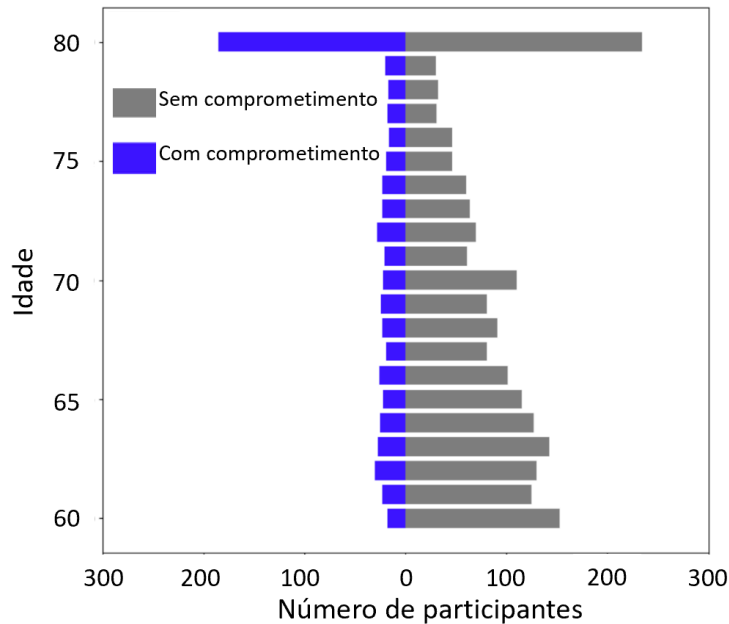


Figura 1. Pirâmide da idade vs. comprometimento cognitivo

4.2. Modelo Baseado em Dados Transversais

Os resultados na Tabela 2 mostram a média e o desvio padrão de quatro execuções utilizando o classificador *Random Forest*. Este experimento mostra, por exemplo, um AUC de 0,5995, indicando que a capacidade do modelo de distinguir entre as classes saudável e com comprometimento cognitivo é ligeiramente melhor do que o acaso (um AUC de 0,5 corresponde a um palpite aleatório). Portanto, tal resultado ainda está abaixo do limiar geralmente desejado de 0,8 para um modelo “bom” [Metz 1978], sugerindo que o desempenho do classificador é relativamente fraco.

Tabela 2. Resultados para o classificador *Random Forest*

Métrica	Média/Desvio Padrão	Intervalo de Confiança (IC)
AUC-ROC	0,5995/0,0206	95% IC: 0,5793 - 0,6197
AUPRC	0,3119/0,0427	95% IC: 0,2700 - 0,3537
Sensitividade	0,5956/0,0165	95% IC: 0,5794 - 0,6117
Especificidade	0,5473/0,0137	95% IC: 0,5339 - 0,5607


4.3. Modelo Baseado em Dados Sequenciais (Longitudinal)

Os resultados a seguir (Tabela 3) mostram a média de quatro execuções utilizando a abordagem convolucional 1D.

**Tabela 3. Resultados para o classificador baseado em convolução 1D**

Métrica	Média/Desvio Padrão	Intervalo de Confiança (IC)
AUC-ROC	0,9039/0,0056	95% IC: 0,8984 – 0,9095
AUPRC	0,7520/0,0118	95% IC: 0,7404 – 0,7636
Sensitividade	0,8670/0,0226	95% IC: 0,8449 – 0,8891
Especificidade	0,7735/0,0237	95% IC: 0,7503 – 0,7967

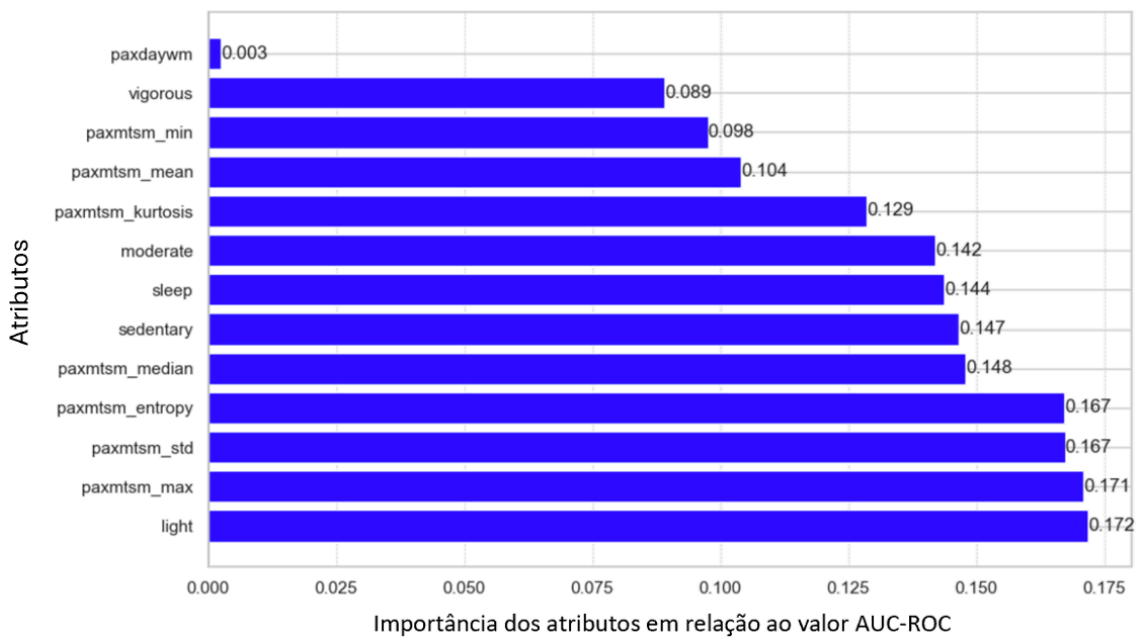
Esses resultados demonstram que o uso de uma janela de tempo de 24 horas melhora significativamente o desempenho nas métricas avaliadas. No entanto, a matriz de confusão (Figura 2) destaca um desafio importante do modelo: um número substancial de falsos positivos (64.680), no qual o comprometimento cognitivo é previsto quando o rótulo verdadeiro é “sem comprometimento cognitivo”. Esse desequilíbrio, com falsos positivos sendo mais de quatro vezes o número de falsos negativos, pode sugerir que o modelo ainda está apresentando *overfitting*.



**Figura 2. Matriz de confusão para o experimento utilizando dados longitudinais**


#### 4.4. Explicabilidade

O gráfico resultante da aplicação do método de importância dos atributos (Figura 3) categoriza cada entrada com base em sua influência na classificação. De acordo com o gráfico, o tempo gasto em atividade física leve, assinalado como “light” no diagrama, tem o maior impacto na métrica AUC-ROC, indicando que é o atributo mais relevante para a predição. Embora essa classificação forneça uma visão sobre a importância relativa dos atributos, ela não oferece uma interpretação mais profunda dos resultados. Por exemplo, ainda que possamos identificar os atributos mais impactantes, ainda são necessárias informações sobre a “direção” de seu efeito. Ou seja, se são direta ou inversamente proporcionais ao resultado positivo (comprometimento cognitivo).



**Figura 3. Diagrama da importância dos atributos para a classificação**

Portanto, o método de propagação de relevância em camadas, o qual origina o seguinte mapa de calor (Figura 4), foi utilizado para complementar a explicação anterior, indicando a direção (valores positivos ou negativos) da relevância e como ela é distribuída ao longo do tempo.



**Figura 4. Mapa de calor da relevância dos 13 atributos ao longo do tempo: atributos (eixo Y) possuem um valor de importância (representado por uma cor) para cada hora coletada (eixo X). As cores variam de vermelho escuro (relevância negativa) a verde escuro (relevância positiva), como exposto na escala do lado direito.**



Por exemplo, o mapa de calor mostra que os dados coletados entre 17h e 23h tendem a ter uma importância menor quando comparados a outros períodos do dia. Além disso, a atividade sedentária (e.g., atividades que não envolvem movimentação, como assistir TV) teve uma influência positiva significativa entre 9h e 11h. No entanto, tais métodos de explicabilidade ainda são insuficientes para suportar interpretações mais elaboradas. A investigação de novos métodos de explicabilidade, baseados em conhecimento do domínio, é uma das direções da nossa pesquisa.

## 5. Conclusão

Neste artigo, foram destacadas as vantagens do uso de modelos de análise sequencial para identificação de comprometimentos cognitivos por meio de dados de acelerômetro. A estratégia de análise sequencial, representada pela rede neural convolucional 1D, obteve resultado superior (AUC-ROC de  $0,90 \pm 0,01$ ) ao emprego de modelo com interpretação transversal dos dados (AUC-ROC de  $0,59 \pm 0,02$ ), correspondente ao classificador *Random Forest*. Os resultados indicam que a aplicação de técnicas de aprendizado de máquina em medições de dispositivos vestíveis pode servir como um método não invasivo e mais acessível para acompanhamento do comprometimento cognitivo, favorecendo um diagnóstico precoce. Ademais, os processos de explicabilidade apontaram que os tempos de atividade física leve e atividade sedentária influenciam a predição da presença de comprometimento neurofuncional. No entanto, várias questões ainda permanecem em aberto, apresentando oportunidades para pesquisas futuras. Por exemplo, embora tenhamos analisado sequências de 24 horas, períodos mais longos podem fornecer *insights* mais confiáveis sobre o comportamento humano e sua correlação com a saúde mental. O conjunto de atributos de entrada foi derivado de estudos anteriores, mas uma seleção diferente de tais atributos pode ser mais adequada para este domínio. Além disso, as técnicas de explicabilidade atualmente empregadas devem ser reavaliadas, pois não oferecem suporte adequado para a interpretabilidade dos resultados. Uma opção é incluir entradas que capturem de forma mais eficaz os comportamentos humanos, em vez de depender de atributos estatísticos com valor semântico limitado. Outra estratégia é aplicar explicabilidade baseada em conhecimento a priori, a qual incorpora informações simbólicas do domínio e pode elucidar melhor as relações entre entradas e resultados.

## Referências

- Addae, S. et al. (2024) “Smart Solutions for Detecting, Predicting, Monitoring, and Managing Dementia in the Elderly: A Survey”, *IEEE Access*, vol. 12, pp. 26-56.
- Alharbi, E., Alomainy, A. and Jones, J. M. (2020) “Detecting cognitive decline in early Alzheimer’s patients using wearable technologies”, *IEEE International Conference on Healthcare Informatics (ICHI)*, pp. 1-4.
- Ardle, R., Del Din, Galna, B., Thomas, A. and Rochester, L. (2020) “Differentiating dementia disease subtypes with gait analysis: feasibility of wearable sensors?”, *Gait & posture*, vol.76, pp. 372-376.
- Ausó, E., Gómez-Vicente, V. and Esquivia, G. (2020). “Biomarkers for Alzheimer’s disease early diagnosis”, *Journal of Personalized Medicine*, vol. 10, n. 3, pp. 114.

- Brody, D. J et al. (2019) "Cognitive performance in adults aged 60 and over: National Health and Nutrition Examination Survey, 2011–2014".
- Clark, L. et al. (2009) "Longitudinal verbal fluency in normal aging, preclinical and prevalent Alzheimer's disease", *American Journal of Alzheimer's Disease and Other Dementia*, vol. 24, pp. 461-468.
- Gaur, P., et al. (2024) "Continuous Monitoring of Heart Rate Variability in Free-Living Conditions Using Wearable Sensors: Exploratory Observational Study", *JMIR Formative Research*, vol. 8, e53977.
- Gornet, M. and Maxwell, W. (2024) "The European approach to regulating AI through technical standards", *Internet Policy Review*, vol. 13, n. 3, pp. 1-27.
- Jahan, Z., Khan, S. B. and Saraei, M. (2024) "Early dementia detection with speech analysis and machine learning techniques", *Discover Sustainability*, vol. 5, n. 1, pp. 1-18.
- John, D., Tang, Q., Albinali, F., and Intille, S. (2019) "An open-source monitor-independent movement summary for accelerometer data processing", *Journal for the Measurement of Physical Behaviour*, vol. 2, n.4, pp. 268-281.
- Ma, X. et al. (2023) "Developing and validating a nomogram for cognitive impairment in the older people based on the NHANES", *Front Neurosci*, vol. 17, n. 17, pp. 1195570.
- Marvi, F., Chen, Y. H. and Sawan, M. (2024) "Alzheimer's Disease Diagnosis in the Preclinical Stage: Normal Aging or Dementia", *IEEE Reviews in Biomedical Engineering*, pp. 1-18.
- Metz, C. (1978) "Basic principles of ROC analysis", *Seminars in Nuclear Medicine*, vol. 8, n. 4, pp. 283-298.
- Morris, J. C. et al. (1989) "The Consortium to Establish a Registry for Alzheimer's disease (CERAD). Part 1. Clinical and neuropsychological assessment of Alzheimer's disease", *Neurology*, vol. 39, pp. 1159-1165.
- Moyle, W., Jones, C., Murfield, J., Thalib, L., & Beattie, E. (2021) "Effect of a robotic pet on agitation and quality of life in individuals with dementia: a cluster-randomized controlled trial", *Journal of the American Medical Directors Association*, 22(5), 933–939.e1.
- Phillips, K. et al. (2020) "A theory-based model of cumulative activity," *Scientific reports*, vol. 12, n. 1, p. 15635.
- Rykov, Y.G., Patterson, M.D., Gangwar, B.A., et al. (2024) "Predicting cognitive scores from wearable-based digital physiological features using machine learning: data from a clinical trial in mild cognitive impairment", *BMC Medicine*, 22, 36.
- Shi, Y., Wang, H., Zhu, Z., Ye, Q., Lin, F. and Cai, G. (2023) "Association between exposure to phenols and parabens and cognitive function in older adults in the United States: a cross-sectional study", *Sci. Total Environ*, vol. 858, pp. 160129.

- Siebra, C. and Wac, K. (2025) "A correlation analysis between passively assessed gait initiation signal data and brain tumours progress", *Biomedical Signal Processing and Control*, vol. 99, pp. 106858.
- Tao, M., Liu, J. and Cervantes, D. (2022) "Association between magnesium intake and cognition in US older adults: National Health and Nutrition Examination Survey (NHANES) 2011 to 2014", *Alzheimers Dement (N Y)*, vol. 8, n. 1, pp. e12250.
- Tsanousa, A. et al. (2020) "A novel feature selection method based on comparison of correlations for human activity recognition problems", *Journal of Ambient Intelligence and Humanized Computing*, vol. 11, pp. 5961-5975, 2020.
- Wechsle, D. (1997) *WAIS Manual – 3<sup>rd</sup> Edition*. New York: Psychological Corporation.
- Weizman, Y. et al. (2021) "Gait assessment using wearable sensor-based devices in people living with dementia: a systematic review", *International Journal of Environmental Research and Public Health*, vol. 18, n. 23, pp. 12735.
- Whelan, R. et al. (2022) "Developments in scalable strategies for detecting early markers of cognitive decline", *Translational Psychiatry*, vol. 12, pp. 473.
- Wittenberg, R. et al. (2019) "Economic impacts of introducing diagnostics for mild cognitive impairment Alzheimer's disease patients", *Alzheimer's & Dementia: Translational Research & Clinical Interventions*, vol. 5, pp. 382-387.