

Renato Souza Santana Filho

Tecnologias para predição de quedas em idosos: Uma revisão de escopo

Uberlândia, MG

2025

Renato Souza Santana Filho

Tecnologias para predição de quedas em idosos: Uma revisão de escopo

Trabalho de Conclusão do Curso de Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia - UFU, como requisito para obtenção do título de Engenheiro biomédico.

Universidade Federal de Uberlândia - UFU
Faculdade de Engenharia Elétrica - FEELT

Orientador Prof. Dr. Eduardo Lázaro Martins Naves

Uberlândia, MG

2025

Agradecimentos

Agradeço a luz guia e onipresença daqueles que me trouxeram até aqui. Mãe, irmãos, sobrinhos, padrasto e avós. Em especial ao meu avô, que me deu motivos para seguir este caminho em sua busca rotineira por folêgo e cuja ausência é clara e inquietante. O amor e desejo de elevação de cada um de vocês formaram a estrela guia que me direcionou até o fim desta etapa tão esperada.

Aos meus colegas do Programa de Educação Tutorial - PET Engenharia Biomédica e Prof. Dr. Alcimar Barbosa Soares também devo incontáveis agradecimentos. A nossa vivência é pedra basilar na minha formação como ser humano.

Por fim, agradeço ao meu orientador Prof. Dr. Eduardo Lázaro Martins Naves pelo tema proposto e pela chance de estudá-lo com afinco.

Resumo

O estudo aborda o crescimento do envelhecimento populacional e a consequente elevação na incidência de quedas em idosos, destacando as graves repercussões físicas, sociais e econômicas desses eventos. Como resposta a esse cenário, o trabalho buscou mapear tecnologias voltadas à predição de quedas, sejam elas compostas de natureza eletrônica ou computacional.

A pesquisa foi conduzida como revisão de escopo, seguindo as diretrizes do PRISMA 2020 para garantir rigor metodológico e transparência na seleção dos estudos. Foram realizadas buscas em bases científicas relevantes, aplicando critérios definidos de inclusão e exclusão, resultando na análise de 17 artigos publicados nos últimos 10 anos.

Os resultados evidenciaram que sensores vestíveis e algoritmos de machine learning têm apresentado avanços significativos na detecção e predição de quedas, embora enfrentem limitações relacionadas à aceitação pelo usuário, à adaptação ao uso prolongado e ao custo de implementação. As plataformas de força mostraram-se opções acessíveis e confiáveis em ambientes clínicos para avaliação do equilíbrio, mas menos práticas para monitoramento contínuo.

O estudo conclui que prevenir e prever quedas é mais eficaz do que reagir após sua ocorrência, tanto no aspecto físico, ao preservar a autonomia do idoso, quanto econômico, ao reduzir custos associados a internações e reabilitações. Ressalta-se a necessidade de novas pesquisas com amostras maiores e validação clínica, visando tecnologias que sejam simultaneamente precisas, acessíveis e aceitáveis ao público idoso.

Palavras-chaves: Predição; Quedas; Idosos; PRISMA; Tecnologias em saúde.

Abstract

The study addresses the growth of population aging and the consequent increase in the incidence of falls among older adults, highlighting the severe physical, social, and economic repercussions of these events. In response to this scenario, the work aimed to map technologies focused on fall prediction, whether they consist of an electronic or computational nature.

The research was conducted as a scoping review, following the PRISMA 2020 guidelines to ensure methodological rigor and transparency in the selection of studies. Searches were performed in relevant scientific databases, applying predefined inclusion and exclusion criteria, resulting in the analysis of 17 published over the past decade.

The results showed that wearable sensors and machine learning algorithms have made significant advances in fall detection and prediction, although they face limitations related to user acceptance, adaptation to prolonged use, and implementation costs. Force platforms proved to be affordable and reliable options in clinical settings for balance assessment but less practical for continuous monitoring.

The study concludes that preventing and predicting falls is more effective than reacting after their occurrence, both in the physical aspect, by preserving older adults' autonomy, and economically by reducing costs associated with hospitalizations and rehabilitation. The need for further research with larger samples and clinical validation is emphasized, aiming for technologies that are simultaneously accurate, affordable, and acceptable to the elderly population.

Keywords: Prediction; Falls; Older adults; PRISMA; Health technologies.

Lista de ilustrações

Figura 1 – Termo de busca booleano para a revisão	14
Figura 2 – Diagrama de fluxo baseado no método PRISMA 2020.	16
Figura 3 – Disposição global dos trabalhos selecionados.	22
Figura 4 – Progressão anual de publicações.	23
Figura 5 – Distribuição do número de participantes entre os estudos. 8 estudos apresentaram até 100 participantes; 5 estudos registraram entre 100 e 1000 participantes; 4 estudos incluíram mais de 1000 participantes. . .	25
Figura 6 – Testes clínicos mais frequentes para coleta de dados.	26
Figura 7 – Tecnologias mais utilizadas para predição de quedas.	27

Lista de tabelas

Tabela 1	–	Características principais dos estudos.	17
Tabela 2	–	Estudos, ano, participantes e objetivo principal.	18
Tabela 3	–	Estudos, ano, participantes e objetivo principal.	19
Tabela 4	–	Estudos, tecnologia utilizada, testes clínicos e taxa de sucesso na predição.	20
Tabela 5	–	Estudos, tecnologia utilizada, testes clínicos e taxa de sucesso na predição.	21

Lista de abreviaturas e siglas

AAS	Accelerometer-based Activity Sensor
ABC	Activities-specific Balance Confidence
ADL	Activities of Daily Living
ATS	Avaliação de Tecnologias em Saúde
AUC	Area Under the Curve
BBS	Berg Balance Scale
BLSTM	Bidirectional Long Short-Term Memory
CI	Confidence Interval
CNN	Convolutional Neural Network
COVID	Coronavirus Disease
COX	Modelo de Regressão de Cox
DL	Deep Learning
DT	Decision Tree
ELSA	Ethical, Legal and Social Aspects
EMG	Electromyography
FLBP	Functional Lower Body Power
HAS	Hipertensão Arterial Sistêmica
HR	Hazard Ratio
ICC	Intraclass Correlation Coefficient
INCHIANTI	Invecchiare in Chianti
IP	Internet Protocol
KKT	Karush-Kuhn-Tucker
KNN	K-Nearest Neighbors

LR	Logistic Regression
LSTM	Long Short-Term Memory
ML	Machine Learning
MV	Movement Velocity
NB	Naive Bayes
ONU	Organização das Nações Unidas
OR	Odds Ratio
PASE	Physical e Activity Scale for the Elderly
PPA	Physical Performance Assessment
PPVs	Posture Predictive Values
PS	Postural Stability
PRISMA	Preferred Reporting Items for Systematic Reviews and Meta-Analyses
RF	Random Forest
ROC	Receiver Operating Characteristic
ROI	Region of Interest
STS	Sit-to-Stand
SVM	Support Vector Machine
TCP	Transmission Control Protocol
TIC	Tecnologias da Informação e Comunicação
TIPS	Technology Innovations for Preventing Falls
TRIL	Technology Research for Independent Living
TUG	Timed Up and Go
UK	United Kingdom

Sumário

1	INTRODUÇÃO	10
1.1	Justificativas	10
1.2	Objetivos	11
2	REFERENCIAIS TEÓRICOS	12
2.1	Metodologia PRISMA 2020	13
3	METODOLOGIA	14
3.1	Estratégia de busca	14
3.2	Crterios de inclusão	14
3.3	Seleção de estudos e extração de dados	15
4	RESULTADOS E DISCUSSÕES	16
4.1	Resultado das buscas	16
4.2	Dados Gerais	22
4.3	Dados Clínicos	25
4.3.1	Testes clínicos	25
4.3.2	Monitoramento contínuo	26
4.4	Tecnologias	27
4.4.1	Hardwares para predição	27
4.4.2	Softwares para predição	28
4.5	Taxa de sucesso na predição	30
5	CONCLUSÃO	32
	REFERÊNCIAS BIBLIOGRÁFICAS	34

1 Introdução

O envelhecimento populacional é um desafio que extrapola fronteiras nacionais. Segundo a Organização das Nações Unidas (ONU), o número de idosos, com 60 anos ou mais, irá duplicar até 2050 e mais do que triplicará até 2100, passando de 962 milhões em 2017 para 2,1 bilhões em 2050 e 3,1 bilhões em 2100 (UNRIC – Centro Regional de Informação da ONU para a Europa Ocidental, 2024). Segundo este órgão supranacional, o continente europeu já apresenta 25% da população com 60 anos ou mais enquanto que globalmente, as estimativas são que o número de pessoas com 80 anos ou mais deverá triplicar até 2050 passando de 137 milhões, em 2017, para 425 milhões em 2050. Em relação ao Brasil, o total de pessoas com 65 anos ou mais chegou a crescer 57,4% entre 2010 e 2022, alcançando a marca de 22 milhões de habitantes segundo o Censo Demográfico de 2022 (Governo Federal, 2023).

Entre os problemas mais relevantes associados ao envelhecimento, destacam-se as quedas acidentais. Estimativas da ONU revelam que adultos acima de 60 anos respondem pelo maior número de quedas fatais onde cerca de 20% dos idosos envolvidos nesses eventos traumáticos no ano de 2021 nos Estados Unidos sofreram feridas superficiais, fraturas no quadril e traumatismo craniano (World Health Organization, 2021). Além destas consequências físicas, as quedas afetam a esfera psicossocial, gerando medo, isolamento e dependência progressiva que podem reduzir drasticamente a qualidade de vida destes indivíduos além do grande custo de cuidados intensivos que são requeridos após um acidente neste contexto (HARTHOLT et al., 2011) .

1.1 Justificativas

Considerando a parcela idosa crescente da população mundial e as consequências físicas e sociais decorrentes de uma queda, é importante investir em iniciativas que tentem mitigar ou, na melhor das hipóteses, evitar que o trauma aconteça. Intervenções preventivas, como programas de exercícios, modificações ambientais e monitoramento com sensores, reduzem significativamente o número de quedas e suas complicações, preservando a mobilidade e retardando a necessidade de cuidados institucionais (HEKTOEN; AAS; LURÅS, 2009). Além disso, há evidências de que tais estratégias são custo-efetivas: o programa *Move With Balance* reduziu quedas em até 65% e apresentou retorno de investimento (ROI) de até 7,6:1 em um ano (MILLS et al., 2018), enquanto o programa hospitalar *Fall TIPS* gerou economia de US\$ 22 milhões em cinco anos (DYKES et al., 2023). Portanto, ao prevenir quedas, preserva-se não apenas a saúde física e emocional dos idosos, mas também reduz-se o ônus financeiro sobre sistemas de saúde e famílias.

1.2 Objetivos

Nesse sentido, a predição com antecedência da queda pode ser o fator chave que permite salvaguardar a saúde deste grande nicho populacional. Assim, este trabalho tem como objetivo principal buscar as principais tecnologias e procedimento utilizados para predição de quedas nos últimos 10 anos, de forma a relatar as metodologias mais eficazes e promissoras que permitam, no futuro, a concepção de uma tecnologia disponível e acessível para todos os brasileiros.

2 Referenciais Teóricos

A Avaliação de Tecnologias em Saúde (ATS) é um processo estruturado e multidimensional que investiga os impactos clínicos, econômicos, sociais e éticos associados ao uso de medicamentos, dispositivos, equipamentos, procedimentos e programas de saúde. Seu objetivo é subsidiar decisões informadas sobre incorporação, difusão e uso seguro e eficaz dessas tecnologias, garantindo que recursos limitados sejam aplicados de forma eficiente e equitativa (SAMPAIO; MANCINI, 2007; NITA et al., 2009).

As modalidades de ATS incluem:

- Avaliação de eficácia e efetividade clínica, que verifica se a tecnologia gera benefícios em condições ideais (ensaios clínicos controlados) ou reais (estudos observacionais);
- Avaliações econômicas, como análises de custo-minimização, custo-efetividade, custo-utilidade e custo-benefício, relacionando custos financeiros com desfechos clínicos ou de qualidade de vida (CHANDLER et al., 2019);
- Estudos de impacto orçamentário, que projetam o efeito financeiro da adoção de tecnologias sobre sistemas de saúde;
- Análises éticas, legais e sociais (ELSA), que avaliam equidade de acesso, aceitabilidade social e preferências dos pacientes;
- Revisões de literatura, essenciais para sintetizar criticamente a evidência disponível e identificar lacunas de conhecimento.

Entre essas abordagens, as revisões sistemáticas são consideradas o padrão-ouro, pois utilizam estratégias de busca transparentes, critérios claros de inclusão e exclusão, métodos padronizados de extração de dados e avaliação da qualidade metodológica dos estudos (MUNN; TUFANARU; AROMATARIS, 2014). Diferentemente das revisões narrativas, que são descritivas e suscetíveis a viés de seleção, as revisões sistemáticas aumentam a confiabilidade das conclusões e oferecem suporte sólido à formulação de políticas públicas e recomendações clínicas.

No campo da predição de quedas, diversos estudos têm empregado ATS para avaliar tecnologias como sensores inerciais vestíveis, plataformas de força, algoritmos de aprendizado de máquina e dispositivos inteligentes para monitoramento domiciliar. Revisões recentes mostram que sensores vestíveis apresentam alta acurácia na detecção e predição de quedas, mas enfrentam barreiras relacionadas à aceitação pelo usuário e ao custo (DELAHOZ; LABRADOR, 2014; BET; CASTRO; PONTI, 2019). Outras

revisões identificam que plataformas de força são ferramentas robustas para avaliação do equilíbrio em ambientes clínicos e de baixo custo relativo, sendo frequentemente utilizadas em programas de triagem de risco (PETRÓ; PAPACHATZOPOULOU; KISS, 2017).

2.1 Metodologia PRISMA 2020

Para garantir transparência, rigor metodológico e reprodutibilidade, recomenda-se que revisões sistemáticas sigam diretrizes internacionais como o PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). A atualização PRISMA 2020 aprimorou o checklist original e o fluxograma clássico, incorporando 27 itens essenciais que abrangem desde a justificativa da revisão até a apresentação dos resultados. O novo diagrama de fluxo documenta de forma clara todas as etapas de identificação, triagem, elegibilidade e inclusão de estudos, sendo adaptável a diferentes fontes de informação (PAGE et al., 2021).

No contexto desta revisão de escopo, voltada para tecnologias aplicadas à predição de quedas em idosos, a aplicação do PRISMA 2020 é particularmente relevante. Esse referencial assegura clareza metodológica sobre como as evidências foram selecionadas, quais critérios de qualidade foram aplicados e quais lacunas ainda precisam ser exploradas. Ao padronizar a busca, seleção e síntese de dados, o método contribui para que os resultados sejam comparáveis, úteis à tomada de decisão e aplicáveis à priorização de tecnologias seguras, eficazes e custo-efetivas.

3 Metodologia

3.1 Estratégia de busca

A construção desta revisão de escopo foi guiada pelas diretrizes do PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) (PAGE et al., 2021). Estes padrões garantem uma abordagem sistemática e transparente em todas as etapas do processo, desde a formulação da questão de pesquisa e a definição dos critérios de elegibilidade, passando pela busca abrangente em múltiplas bases de dados, a seleção criteriosa dos estudos, a extração de dados relevantes e, por fim, a síntese e apresentação dos achados.

A busca na literatura foi efetuada em junho de 2025 nas seguintes bases de dados: IEEE Xplore, Pubmed e ACM Digital Library. O termo de busca booleano utilizado está descrito na Tabela 1.

Figura 1 – Termo de busca booleano para a revisão

<i>Fall prediction</i>	("fall prediction")
<i>Elderly</i>	AND ("elderly" OR "older adults" OR "aged" OR "aging" OR "ageing" OR "geriatric" OR "senior citizens")
<i>Excluding factors: reviews</i>	NOT (review OR "meta-analysis" OR "systematic review")

Fonte: Autoria própria.

3.2 Critérios de inclusão

Os critérios de inclusão de artigos foram: (i) publicados nos últimos 10 anos (2015-2025), de forma a criar uma seleção de informações mais atuais; (ii) Língua inglesa; (iii) não serem revisões de qualquer tipo ou metanálises; (iv) testados em mais de um paciente alvo; (v) a intervenção para prevenção ou predição de quedas deve ser por forma de alguma tecnologia; (vi) idosos testados devem ser hígidos, ou seja, possuir um excelente estado de saúde funcional e cognitiva, sem doenças crônicas significativas ou com elas bem

controladas de forma que não comprometem sua independência e qualidade de vida; (vii) Texto completo disponível.

3.3 Seleção de estudos e extração de dados

Seguindo as diretrizes PRISMA 2020, primeiro foi conduzida a busca nas bases de dados mencionadas utilizando o termo de busca explicitado. Depois de ler o título e o abstract, artigos em potencial foram selecionados e foi feita a remoção de artigos duplicados utilizando uma ferramenta de gerenciamento de referências.


De cada artigo considerado na revisão foram extraídas as seguintes informações: autores, país de origem, conferência ou journal onde foi publicado, ano, número de participantes, objetivo principal do trabalho, tecnologia(s) utilizada(s) na predição, testes clínicos aplicados para a coleta de dados e a taxa de sucesso na predição.

4 Resultados e Discussões

4.1 Resultado das buscas

A busca inicial nas bases de dados mencionadas no capítulo 3 utilizando a combinação de termos booleanos descrita gerou um resultado total de 216 documentos. Após eliminar as duplicatas, restaram 207 artigos. Por fim, 17 estudos foram selecionados para serem analisados e revisados, de forma a retirar informações relevantes bem como os dados descritos anteriormente. A Figura 2 mostra em detalhes todo o processo de seleção de artigos e todas as fases selecionadas com base no método PRISMA 2020.

Figura 2 – Diagrama de fluxo baseado no método PRISMA 2020.



Fonte: Autoria própria.

As características primárias dos estudos selecionados estão dispostos nas Tabelas 1, 2, 3, 4 e 5.

Tabela 1 – Características principais dos estudos.

n	Estudo	País	Conferência ou Journal
1	Ogonowski et al.	Alemanha	Journal
2	Greene et al.	Irlanda	Journal
3	Razmara et al.	Irã	Journal
4	Vincenzo et al.	Estados Unidos	Journal
5	Wang et al.	Holanda, Reino Unido	Journal
6	Ye et al.	China, Estados Unidos	Journal
7	Forth et al.	Israel, Espanha, Taiwan	Journal
8	Makino et al.	Japão	Journal
9	Chan et al.	Austrália	Journal
10	Agrawal et al.	Tailândia	Journal
11	de Abreu et al.	Brasil	Journal
12	Maiora et al.	Espanha	Journal
13	Altunkaya et al.	Turquia	Journal
14	Mohan et al.	Nova Zelândia	Journal
15	Albites-Sanabria et al.	Itália	Journal
16	Kamienski et al.	Estados Unidos	Journal
17	Zuo et al.	China	Journal

Tabela 2 – Estudos, ano, participantes e objetivo principal.

n	Ano	Participantes	Objetivo principal
1	2016	12	Desenvolver um sistema de prevenção de quedas baseado em Tecnologia da Informação e Comunicação (TIC) que se integre de forma transparente na vida diária de idosos.
2	2017	22	Desenvolver um método estatístico para a avaliação do risco de queda e aprendê-lo através da combinação automática de fatores de risco clínicos, padrões simulados de sensores inerciais vestíveis.
3	2018	200	Prever o risco de quedas em idosos com base em uma abordagem de perfil fisiológico, utilizando uma rede neural artificial com algoritmo de aprendizado por retropropagação.
4	2018	98	Determinar a validade discriminatória da potência muscular funcional da parte inferior do corpo (FLBP) e da velocidade de movimento (MV) em idosos, com base no histórico de quedas.
5	2020	49	Determinar se dados de passos derivados de smartphones, sozinhos ou em conjunto com medidas clínicas comuns de risco de queda, poderiam prever quedas resultantes de escorregões e tropeços induzidos em laboratório.
6	2020	265225	Construir e validar uma ferramenta preditiva de risco de queda baseada em prontuários eletrônicos de saúde.
7	2020	209	Caracterizar o desempenho de um método comercial automatizado para avaliar o risco de queda em adultos mais velhos, utilizando machine learning.
8	2021	2520	Desenvolver um algoritmo simplificado de árvore de decisão para a predição de quedas em idosos que vivem na comunidade.
9	2023	32619	Determinar se os biomarcadores digitais da marcha, capturados por um dispositivo de pulso, podem prever quedas que causam lesões em pessoas idosas.

Tabela 3 – Estudos, ano, participantes e objetivo principal.

n	Ano	Participantes	Objetivo principal
10	2021	1101	Aplicar modelos de machine learning (ML) para prever o risco de queda de um indivíduo, utilizando dados de caminhada dinâmica coletados por palmilhas inteligentes com sensores de pressão sem fio.
11	2024	153	Determinar se Teste de Equilíbrio em Pé (Standing balance test) pode indicar a predição de quedas em idosos.
12	2024	106	Construir um modelo preditivo para estimar a probabilidade de um idoso sofrer uma queda no futuro próximo.
13	2024	71	Criar uma ferramenta prática que possa ser facilmente integrada à prática clínica, utilizando sinais de aceleração de um único sensor durante uma atividade de curta duração.
14	2024	21	Prever o risco de quedas em idosos monitorando continuamente seus sinais vitais com uma abordagem de lógica fuzzy para identificar anomalias.
15	2024	188	Demonstrar que as características de equilíbrio mensuradas em cenários de vida real têm uma capacidade preditiva superior para identificar pacientes com alto risco de queda do que as avaliações tradicionais feitas em laboratório.
16	2024	12	Desenvolver um sistema que possa prever quedas em tempo real e prevenir lesões por queda através de um mecanismo de andador rapidamente reconfigurável.
17	2024	8	Desenvolver um algoritmo de predição de quedas para movimentos de sentar-e-levantar (STS).

Tabela 4 – Estudos, tecnologia utilizada, testes clínicos e taxa de sucesso na predição.

n	Tecnologia utilizada	Dados clínicos	Taxa de sucesso na predição
1	iStopFalls System	Physiological Profile Assessment (PPA)	Resultados qualitativos.
2	Sensor inercial	Time Up and Go Test (TUG); Pelli–Robson contrast sensitivity scale; binocular logMAR; orthostatic hypotension	Acurácia geral: 76%; A avaliação baseada apenas em sensores teve uma acurácia de 73.6%, Os fatores de risco clínicos isoladamente tiveram uma acurácia de 68.8%.
3	Modelos de redes neurais	Características psicológicas e públicas	Acurácia utilizando apenas fatores psicológicos: 90% Acurácia utilizando apenas fatores públicos: 87.5%; Acurácia combinada: 91%.
4	Tendo Weighlifting Analyzer	FLBP e MV	Sensibilidade: (72% - 77%); Especificidade: 52%-59%.
5	Smartphone	Berg Balance Scale (BBS), Activities-Specific Balance Confidence Scale (ABC), Time Up and Go Test (TUG), Physical Activity Scale for the Elderly (PASE)	Idade + TUG + histórico de quedas = Sensibilidade: 94.3% e Especificidade: 58.3%; Acurácia geral: 85.1% e AUC: 0.831.
6	Algoritmo de Machine learning	Posture Predictive Values (PPVs)	C-statistic de 0.807.
7	Plataforma de força; Machine learning	Postural Stability (PS)	Alta confiabilidade da medição (ICC(2,1)[95%CI] = 0.78 [0.76 - 0.81]).
8	Decision-tree analysis (C5.0)	Histórico de queda, idade, sexo, medo de cair, uso de medicação, osteoartrite no joelho, dor nos membros inferiores, velocidade de marcha e timed up and go test (TUG)	Probabilidade de incidência de quedas, variando de 30.4%-71.9%.


Tabela 5 – Estudos, tecnologia utilizada, testes clínicos e taxa de sucesso na predição.

n	Tecnologia utilizada	Dados clínicos	Taxa de sucesso na predição
9	Sensor inercial	Dados de marcha e caminhada	$p < 0.05$.
10	Smart insole; Machine learning	TUG	Modelo Logistic Regression (LR) com superamostragem alcançou um AUC de 0.82, modelo Random Forest (RF) com superamostragem obteve uma acurácia de 0.81 e especificidade de 0.88.
11	Plataforma de força (EMG System do Brasil®)	Balanço e posturografia	$p < 0.05$.
12	Sensor inercial; deep learning convolutional neural network (CNN)	TUG	Melhor resultado = bidirecional long short-term memory (BLSTM), com acurácia de 0.83 e AUC de 0.73.
13	Sensor inercial; redes neurais	Um minuto de caminhada em linha reta	Acurácia: 82.2% Sensibilidade: 82.9% Especificidade: 81.6%.
14	Machine learning	Sinais vitais	Acurácia: 95.24%, Sensibilidade: 93.75% Especificidade: 100%.
15	Sensor inercial; Machine learning	Activities of Daily Living (ADL)	0.76 AUC para ambientes reais e 0.57 AUC para ambientes de laboratório.
16	Sensor inercial; redes neurais	Activities of Daily Living (ADL); Simulações de queda e tropeço	Acurácia de 97%.
17	Optitrack motion capture system (Natural-Point, USA); Algoritmo de otimização Karush-Kuhn-Tucker (KKT)	Análise do centro de massa durante sit-to-stand test	Acurácia de 94.9%.

4.2 Dados Gerais

Acerca da localização geográfica das publicações, notou-se uma quantidade maior em três países específicos: China, Espanha e Estados Unidos, com duas publicações para cada um. O restante dos estudos ficaram espalhados pelo globo nas seguintes localidades: Alemanha (1), Irlanda (1), Irã (1), Holanda (1), Reino Unido (1), Israel (1), Taiwan (1), Japão (1), Austrália (1), Tailândia (1), Brasil (1), Turquia (1), Nova Zelândia (1) e Itália (1). A distribuição completa também pode ser observada na Figura 3.


Figura 3 – Disposição global dos trabalhos selecionados.



Fonte: Autoria própria.

Em relação ao ano em que os trabalhos foram publicados, notou-se uma tendência crescente ao longo dos anos, com uma pequena queda notável entre 2020 e 2021, provavelmente provocada pela pandemia de COVID-19. Isso porque este fenômeno mundial foi responsável pela criação de medidas de diminuição de contágio tal como o distanciamento social para proteger os grupos de risco. Assim, os indivíduos idosos foram um dos grandes grupos a se manterem isolados nesse período (CARVALHO et al., 2020), fato que explica essa queda no período mencionado. Contudo, esse crescimento de produção de trabalhos voltados para predição de quedas nas últimas décadas revela a grande preocupação com o envelhecimento populacional acelerado não só no Brasil (NASRI, 2008) (WONG; CARVALHO, 2006) como também no mundo (BORGES et al., 2017).

Figura 4 – Progressão anual de publicações.




Fonte: Autoria própria.

A quantidade de participantes nos estudos escolhidos foi bastante variada (Figura 5). Enquanto os trabalhos de (RAZMARA; ZABOLI; HASSANKHANI, 2018), (YE et al., 2020), (FORTH et al., 2020), (MAKINO et al., 2021), (CHAN et al., 2023), (AGRAWAL et al., 2023), (ABREU et al., 2024), (MAIORA et al., 2024), (ALBITES-SANABRIA et al., 2024) apresentam centenas ou até milhares de participantes, o restante dos artigos escolhidos apresenta não mais que poucas dezenas. Isso se deve principalmente ao desenho de estudo e limitações implícitas a testes clínicos envolvendo quedas de idosos, uma vez que é um evento um tanto traumático e muitas vezes irreversível na vida de um cidadão septuagenário. (OGONOWSKI et al., 2016) explicita essa dificuldade de realizar testes com essa classe de indivíduos envolvidos nesse contexto específico e uma solução possível citada pelos autores seria o chamado "Living labs", no qual o ambiente de testes é um ambiente mais próximo da vida cotidiana para emular situações reais. Assim, as residências dos indivíduos foram utilizadas para os testes, o que demandou infraestrutura como internet, televisores e energia confiáveis. Considerando a dificuldade nesse tipo de abordagem de testes com indivíduos mais velhos, além da existência de variáveis estruturais que muitas pessoas podem não ser capazes de garantir, muitos autores optaram por criar seu sistema de predição baseando-se em bancos de dados públicos ou cedidos ao trabalho dos autores por uma instituição de saúde específica. Entre eles, pode-se citar:

- (CHAN et al., 2023) utilizou do UK Biobank study (SUDLOW et al., 2015), uma grande coorte populacional, para analisar biomarcadores da marcha em idosos e prever quedas com lesões;
- (YE et al., 2020) utilizou um subset de um grande banco de dados eletrônicos de Maine (EUA), autorizado pela rede de troca de informações de saúde promovida pela HealthInfoNet Organization (HealthInfoNet, 2025);
- (ALBITES-SANABRIA et al., 2024) utilizou do ADAPT (BOURKE et al., 2017), um estudo que descreve um sistema personalizado de análise de risco de queda para pessoas idosas que vivem sozinhas e do INCHANTI Study (National Institute on Aging, 2023), um estudo epidemiológico longitudinal iniciado na região de Chianti, na Itália, com o objetivo de investigar os fatores biológicos, ambientais e sociais que influenciam a mobilidade e a saúde funcional em idosos;
- (ALTUNKAYA, 2024) e (MOHAN et al., 2024) utilizaram o Physionet (GOLDBERGER et al., 2000), que é uma plataforma online de acesso aberto que disponibiliza um vasto repositório de dados fisiológicos e ferramentas computacionais voltadas para a pesquisa em fisiologia, biomedicina e saúde digital;
- (GREENE; REDMOND; CAULFIELD, 2017) utilizou dados do TRIL Project, um conjunto não público de informações sobre envelhecimento onde foi mensurada a mobilidade de idosos utilizando sensores inerciais na Clínica TRIL, no hospital St. James (SJH) localizado em Dublin, Irlanda.

Portanto, estudos longitudinais/coorte foram bastante comuns entre as estratégias de desenho de estudo, observando a diversidade de bancos de dados públicos disponíveis para a elaboração de ferramentas de predição. Além disso, alguns autores como (GREENE; REDMOND; CAULFIELD, 2017) e (ALBITES-SANABRIA et al., 2024) se propuseram a testar os dados de um dataset externo com seu próprio dataset reduzido, aumentando a confiabilidade de seus experimentos para a predição de quedas.

Figura 5 – Distribuição do número de participantes entre os estudos. 8 estudos apresentaram até 100 participantes; 5 estudos registraram entre 100 e 1000 participantes; 4 estudos incluíram mais de 1000 participantes.



Fonte: Autoria própria.

4.3 Dados Clínicos

As obras selecionadas apresentaram dois tipos de estratégias para obter dados que possam ser utilizados para determinar o risco de queda dos indivíduos testados: Aplicar testes clínicos esporadicamente ou monitorar continuamente em busca de uma variável fisiológica que possa indicar o risco de queda.

4.3.1 Testes clínicos

Quanto aos testes clínicos (Figura 6), os mais utilizados foram Timed-up-and-Go (TUG), citado cinco vezes, Activities of Daily Living (ADL), citado 3 vezes, seguidos da análise de marcha, Sit - to - Stand test, análise postural e Physiological Profile Assessment (PPA), cada um citado duas vezes, e por fim Physical Activity Scale for the Elderly (PASE), Berg Balance Scale (BBS) e Activities-specific Balance Confidence Scale (ABC), cada um citado uma única vez. Nesse contexto, TUG se consagrou como uma das melhores métricas para elencar o risco de queda de um cidadão idoso. Porém, apesar de em menor número, os outros testes apresentaram suma importância para prever quedas, não os tornando, portanto, menos importantes. Além disso, não há impedimento de associar mais de um teste, uma vez que (WANG et al., 2020) aplicou em conjunto os testes Berg Balance Scale


(BBS), Activities-specific Balance Confidence scale(ABC), Timed Up-and Go test (TUG), Physical e Activity Scale for the Elderly (PASE) para determinar com maior acurácia quais idosos eram mais propensos a queda accidental.

4.3.2 Monitoramento contínuo

Já em relação ao monitoramento contínuo, os autores demonstraram certa incerteza em indicar uma variável mais favorável. (MOHAN et al., 2024) tentou correlacionar a influência de dados vitais tais como pressão sanguínea, batimentos cardíacos e saturação sanguínea com a possibilidade de quedas e obteve resultados bastante relevantes, dado que seu algoritmo demonstrou Acurácia de 95.24%, Sensibilidade de 93.75% e Especificidade de 100%. Por outro lado, (WANG et al., 2020), com a hipótese de dados de passos obtidos de smartphones estarem relacionados com quedas em idosos, não obteve tanto sucesso.

Por fim, é importante ressaltar que os dados além daqueles obtidos de testes clínicos, que podem ou não ser monitorados continuamente caso se aplique, tais como idade, histórico de quedas, medo de cair, dores nos membros inferiores e uso de medicação controlada podem exercer bastante influência no risco de quedas. (RAZMARA; ZABOLI; HASSANKHANI, 2018) e (MAKINO et al., 2021) trataram desses fatores isolados e em conjunto com fatores fisiológicos que podem ser obtidos através dos testes citados e, como inferência, os autores obtiveram maior acurácia na predição quando esses fatores foram levados em consideração ao mesmo tempo.

Figura 6 – Testes clínicos mais frequentes para coleta de dados.




Fonte: Autoria própria.

4.4 Tecnologias

As tecnologias utilizadas para a predição (Figura 7) se diferem em dois tipos básicos: Hardware, que envolve coleta ativa de dados e software, que diz respeito a análise destes dados.

Figura 7 – Tecnologias mais utilizadas para predição de quedas.



Fonte: Autoria própria.

4.4.1 Hardwares para predição

Em relação às tecnologias de hardware, o uso de sensores inerciais estava presente nos trabalhos de (GREENE; REDMOND; CAULFIELD, 2017), (CHAN et al., 2023), (MAIORA et al., 2024), (ALTUNKAYA, 2024), (ALBITES-SANABRIA et al., 2024) e (KAMIENSKI; BONATO; ASADA, 2024). Isso demonstra que o uso deste sensor é bastante comum neste tipo de intervenção, pois é útil em mensuração de marcha (YANG; LI, 2012), além de gerar dados que podem ser utilizados tanto em doenças complexas como Parkinson (SICA et al., 2021) quanto em situações mais rotineiras como quedas acidentais de pessoas mais velhas.

O restante das tecnologias foi utilizado em contextos pontuais, com intuito de avaliar outros métodos além dos dados inerciais que já tem seu uso e eficácia comprovados. Nesse sentido, (ABREU et al., 2024) e (FORTH et al., 2020) verificaram que o uso da

plataforma de força focado na análise postural também é uma boa alternativa para a abordagem inercial. Sistemas de vídeo, abordados por (OGONOWSKI et al., 2016) e (ZUO et al., 2024), foram bastante promissores. Porém, o jogo sério descrito por (OGONOWSKI et al., 2016), apesar de positivamente prevenir as quedas no período analisado, pressupõe uma infraestrutura de tempo, energia elétrica e televisores que não se pode garantir para todo usuário. Da mesma forma, o trabalho de (ZUO et al., 2024) também relata uma excelente e inovadora forma de predição e prevenção de quedas, porém o intuito de inserir este sistema em um robô assistente é um ponto negativo a ser levado em consideração, observada a dificuldade de acesso dessas tecnologias com base em indicadores como alto preço e manutenção delicada (NOURY et al., 2021).

Os artigos de (VINCENZO; GRAY; GLENN, 2018), (WANG et al., 2020) e (AGRAWAL et al., 2023) tratam de um uso ainda mais inovador de uma tecnologia para predição de quedas. (VINCENZO; GRAY; GLENN, 2018) investigou o uso do Tendo Power Analyzer (TENDO Sports Machines, 2025), equipamento originalmente criado para um ambiente esportivo, e foi capaz de avaliar as funções motoras de membros inferiores e diferenciar pessoas com históricos de queda daquelas que não possuíam. (WANG et al., 2020) teorizou se os dados de passos inseridos em um smartphone seriam capazes de indicar o risco de queda de um indivíduo idoso, hipótese que não foi comprovada. Porém, os dados inerciais no smartphone juntamente com a idade, histórico de quedas e o teste TUG apresentaram 94.3 % de sensibilidade, revelando um uso bastante promissor dessa tecnologia móvel. (AGRAWAL et al., 2023) utilizou de Surasole (Suratec Co., Ltd., 2025), uma palmilha inteligente comercial, a qual permitiu a aquisição contínua de dados de pressão plantar e padrões de caminhada, auxiliando na detecção de alterações posturais relacionadas ao risco de quedas e gerou dados promissores para predição.

4.4.2 Softwares para predição

Notou-se um grande uso de intervenções voltadas para abordagens computacionais tais como machine learning (ML), deep learning (DL) e redes neurais (RN) de forma associada a um tipo de hardware ou aplicativos individualmente em um conjunto de dados.

Quanto a via independente de hardware específico (YE et al., 2020) detalhou o uso de um algoritmo de machine learning de forma não associada a um hardware específico denominado XGBoost (Extreme Gradient Boosting) (CHEN; GUESTRIN, 2016), que é um método baseado em árvores de decisão que otimiza o gradiente para obter alto desempenho preditivo com objetivo de analisar prontuários eletrônicos e identificar os indivíduos que sofreram quedas de forma retrospectiva, validando uma ferramenta para o uso na rede de saúde, por exemplo. (MAKINO et al., 2021) também utilizou uma estratégia parecida, um algoritmo de machine learning baseado em árvore de decisão com dados que podem ser obtidos em prontuários médicos tais como idade, sexo, histórico de quedas, uso de

medicamentos prescritos, osteoartrite no joelho, dor em membros inferiores e velocidade de marcha juntamente com o TUG de forma prospectiva, reforçando a possibilidade deste uso de ferramenta na prática clínica. Da mesma forma, (MOHAN et al., 2024) utilizou uma lógica fuzzy em dados vitais dispostos no Physionet (GOLDBERGER et al., 2000) com o mesmo objetivo de auxiliar a prática clínica, uma vez que a automatização gerou uma boa confiabilidade na identificação do risco de queda com Acurácia de 95.24%, Sensibilidade de 93.75% e Especificidade de 100%.

Porém, foi mais comum observar o uso de técnicas avançadas de software quando associados a um hardware específico. (FORTH et al., 2020) aplicou um algoritmo de machine learning juntamente com a análise postural proporcionada pelo uso de uma plataforma de força e demonstrou que o método se mostrou altamente confiável já que foi capaz de prever quedas com um ano de antecedência além de indicar que o uso de um algoritmo automatizado remove a subjetividade das avaliações clínicas tradicionais. (AGRAWAL et al., 2023) investigou dados de caminhada dinâmica coletados usando palmilhas inteligentes com sensores de pressão sem fio em associação com seis modelos de Machine Learning: Support Vector Machine (SVM), Random Forest (RF), Regressão Logística (LR), Naive Bayes (NB), Árvore de Decisão (DT) e K-Nearest Neighbor (kNN) e concluiu que os modelos de ML combinados com as palmilhas inteligentes são capazes de prever o risco de queda, o que apoia o uso de medidas preventivas para reduzir o risco de quedas e os danos resultantes. Por fim, (ALBITES-SANABRIA et al., 2024) coletou e analisou dados de equilíbrio em cenários de vida real usando sensores inerciais vestíveis e a aplicação de algoritmos de machine learning para predição além de utilizar uma plataforma de força para a coleta de dados de laboratório e a Regressão Lasso como modelo preditivo e concluiu que as medidas de equilíbrio em condições de vida real diferem consideravelmente das avaliações de laboratório e têm uma capacidade preditiva superior para identificar pacientes com alto risco de queda. Isso destaca a necessidade de ir além das medidas de equilíbrio tradicionais e desenvolver métodos mais sensíveis e precisos para a predição de quedas.

A aplicação de redes neurais implementada por (RAZMARA; ZABOLI; HAS-SANKHANI, 2018) se baseou em dados fisiológicos obtidos por meio de um questionário que continha fatores de risco como habilidades de visão, força muscular e outras atividades diárias, divididos pelos autores em fatores psicológicos e fatores públicos. O modelo de predição foi construído usando uma rede neural multicamadas com um algoritmo de aprendizado por retropropagação e ofereceu medidas válidas e confiáveis de forma que a proteção das pessoas idosas em risco de queda pode ser maximizada pelo uso de ferramentas de predição inteligentes. (MAIORA et al., 2024) por sua vez associou os dados inerciais com algoritmos de deep learning, como redes neurais convolucionais em que o melhor resultado foi através de uma rede neural Long Short-Term Memory (BLSTM) bidirecional em que um grande volume de dados de 106 participantes foram interpretados e foi possível elencar

o risco de quedas com clareza. (ALTUNKAYA, 2024) criou uma ferramenta prática e facilmente integrável à prática clínica em que a interpretação dos dados de um único sensor inercial a partir de uma rede neural artificial com base no algoritmo K-Nearest Neighbors (KNN), provando que o modelo pode ser aplicado em cenários com um único sensor inercial, tal como um smartphone. (KAMIENSKI; BONATO; ASADA, 2024) teve um objetivo mais emergencial, em que o sistema deveria ser capaz de prever quedas em tempo real e prevenir lesões ativamente. Assim, dados inerciais foram analisados por múltiplas redes neurais de Long Short-Term Memory (LSTM) e, com auxílio do quociente de Lipschitz para analisar casos de desequilíbrio e refinar o preditor, criou um andador que era capaz de prever quedas e se reconfigurar em até 400 ms de forma a mudar sua conformação para uma configuração que previne esta lesão. De forma análoga a (KAMIENSKI; BONATO; ASADA, 2024), porém tendo como fundamento um algoritmo de otimização Karush-Kuhn-Tucker (KKT) (KUHN; TUCKER, 1951), a iniciativa de (ZUO et al., 2024) utilizou de um sistema de vídeo embarcado em um robô assistente para prever quedas em tempo real com acurácia geral de 93.49%.

4.5 Taxa de sucesso na predição

A abordagem mais comum para avaliar o desempenho dos modelos de predição de quedas utiliza um conjunto de métricas de classificação binária. A acurácia é frequentemente citada, representando a proporção geral de previsões corretas (quedas e não quedas) (GREENE; REDMOND; CAULFIELD, 2017), (RAZMARA; ZABOLI; HASSANKHANI, 2018), (MAIORA et al., 2024), (ALTUNKAYA, 2024), (MOHAN et al., 2024). No entanto, como as quedas são eventos relativamente raros, a acurácia sozinha pode ser enganosa. Por isso, muitos estudos também utilizam a sensibilidade, que mede a capacidade do modelo de identificar corretamente os idosos que de fato sofrerão uma queda, sendo crucial para não deixar indivíduos de alto risco passarem despercebidos (WANG et al., 2020), (MAKINO et al., 2021). Em contrapartida, a especificidade avalia a capacidade de identificar corretamente aqueles que não sofrerão quedas, o que é importante para evitar intervenções e ansiedade desnecessárias. Para unificar essas duas medidas, a Área Sob a Curva ROC (AUC ou C-statistic) é amplamente empregada, fornecendo um valor único que resume a capacidade discriminativa geral do modelo em diferentes limiares de decisão (YE et al., 2020), (AGRAWAL et al., 2023). Em alguns casos, métricas como o F1-score e a média geométrica são calculadas para oferecer uma avaliação mais equilibrada, especialmente em conjuntos de dados desbalanceados (ALBITES-SANABRIA et al., 2024).

Outro grupo de estudos avalia o sucesso não apenas pela classificação, mas pela quantificação da força da associação entre um fator de risco e a ocorrência de quedas. Em estudos longitudinais que acompanham os participantes ao longo do tempo, como o de (CHAN et al., 2023) com um seguimento de até 9 anos, o Hazard Ratio (HR), derivado

de modelos de regressão de Cox (COX, 1972), é usado para medir como uma variável (por exemplo, um biomarcador de marcha) afeta a taxa de ocorrência de quedas ao longo do tempo. Em estudos que utilizam regressão logística, o Odds Ratio (OR) é calculado para determinar o quanto a presença de um fator aumenta as chances de um indivíduo ser classificado como "caidor" (MAKINO et al., 2021), (ABREU et al., 2024). Além disso, o estudo de (FORTH et al., 2020) empregou razões de verossimilhança (Likelihood Ratios) para definir categorias de risco (alto, moderado e baixo) com base em sua pontuação de estabilidade postural e utilizou análise de sobrevivência para visualizar o tempo até a primeira queda para cada grupo de risco.

Para sistemas projetados para intervenção em tempo real, como robôs assistivos ou dispositivos de proteção, as métricas de sucesso são ainda mais específicas e críticas em relação ao tempo. O estudo de (KAMIENSKI; BONATO; ASADA, 2024), por exemplo, foca no "lead time" (tempo de avanço), que é o tempo disponível entre a predição da queda e o momento em que ela se torna irrecuperável, um fator essencial para que um mecanismo de proteção, como um andador reconfigurável, tenha tempo de ser ativado. Nesse contexto, a taxa de quedas identificadas com uma taxa de falsos positivos extremamente baixa (por exemplo, inferior a 1%) torna-se uma medida de sucesso mais prática do que a sensibilidade geral. Da mesma forma, o trabalho de (ZUO et al., 2024) mede o sucesso não apenas pela acurácia da predição (93,49%), mas também pelo tempo de execução do algoritmo (runtime), que deve ser de milissegundos para ser viável em um sistema de monitoramento online.

Finalmente, alguns estudos avaliam o sucesso de uma abordagem de forma mais qualitativa ou focada na validação de um instrumento específico. O estudo de (VINCENZO; GRAY; GLENN, 2018), por exemplo, utiliza sensibilidade e especificidade não para validar um modelo preditivo complexo, mas para determinar a capacidade de uma nova medida de potência funcional de discriminar entre idosos com e sem histórico de quedas. Por outro lado, a pesquisa de (OGONOWSKI et al., 2016) é um estudo qualitativo de longo prazo que não utiliza métricas quantitativas de predição. Em vez disso, avalia o "sucesso" de um sistema de prevenção de quedas baseado em Tecnologias de Informação e Comunicação (TIC) através da adesão ao uso, da integração nas rotinas diárias e dos efeitos percebidos pelos participantes em sua autoconfiança, consciência sobre o risco de quedas e qualidade de vida. Essa abordagem oferece uma perspectiva mais holística do impacto de uma intervenção, para além da simples acurácia de um algoritmo.

Essa variedade de métricas, que incluem acurácia, sensibilidade, especificidade, AUC, e até mesmo a capacidade de uma medida em identificar uma associação estatística, reflete a natureza multifacetada do problema de predição de quedas e as diferentes abordagens que a comunidade científica adota para validar suas soluções.

5 Conclusão

A análise dos trabalhos selecionados nessa revisão demonstrou que não há uma única solução para predição de quedas em idosos, visto a grande gama de instrumentos e testes que podem ser aplicados para predizer quedas a longo e curto prazo.

O processo de realização de testes com vistas a extrair dados clínicos destinados a construção de um sistema de predição depende diretamente do tipo de análise pretendida. Para sensores inerciais, o Timed Up and Go Test (TUG) é o padrão ouro, vastamente utilizado em contextos de análise de marcha do indivíduo. Em se tratando de equilíbrio e estabilidade, testes como Berg Balance Scale (BBS) ou Sit-to-Stand Test (STS) se tornam mais apropriados, pois se aplicam melhor a hipótese pretendida. Contudo, essa metodologia não é necessariamente engessada, uma vez que foi demonstrado que a associação de mais de um tipo de teste pode acarretar em uma acurácia maior no intuito de predizer quedas acidentais de idosos. Além disso, o uso de testes clínicos em conjunto com informações extras tais como o histórico e medo de quedas, idade, uso de medicações prescritas e dores em membros inferiores pode oferecer uma predição ainda mais confiável.

Do ponto de vista do monitoramento contínuo, os sensores inerciais vestíveis tem larga utilização e se mantêm como opção viável por seu baixo custo e facilidade de implementação. Contudo, abordagens como esta são propensas a problemas de usabilidade, visto que existe uma grande preocupação com a aparência do objeto, preocupação com imagem pessoal e sensações de desconforto físico. A análise de dados vitais como a frequência cardíaca permite o monitoramento em largos períodos de tempo, onde a solução via smartwatch pode apresentar maior adaptação ao uso, apesar do custo não ser tão atrativo quanto um sensor inercial vestível.

Quanto a prática clínica, as tecnologias tratadas pelos artigos selecionados podem ser amplamente integradas de forma a auxiliar a análise médica. Nesse contexto, a plataforma de força se destaca pois se provou como uma tecnologia que pode ser utilizada em ambientes laboratoriais de forma confiável para prever quedas, além de também ser reconhecida pelo seu uso em reabilitação em diversos contextos.

Em relação às tecnologias de software, notou-se que seu uso pode ser direcionado com sucesso à dados públicos, em que as informações de um sistema de saúde podem servir para monitorar idosos e auxiliar a equipe médica que os supervisiona. Além disso, foi bastante comum associar técnicas computacionais com hardwares para predição, de forma a aumentar a confiabilidade e precisão de um sistema de predição de quedas. Para isso, os autores se lançaram de diversos algoritmos de machine learning, que podem ser imbuídos em qualquer tipo de hardware. Em casos que envolvem conjuntos de dados

grandes, complexos e gerados rapidamente de forma que não podem ser processados de maneira eficiente pelos métodos tradicionais de armazenamento e análise, comumente denominados de *Big Data*, as redes neurais e Deep Learning se mostraram eficientes, reduzindo o custo computacional ao mesmo tempo que mantém um sistema de predição coeso.

Apesar de não ter sido bastante tratado neste trabalho, o uso de smartphone e similares pode demonstrar uma maior significância no futuro. Com seus sensores inerciais embutidos de fábrica e, considerando que grande parte da população já os possui, integrá-lo à lógica do monitoramento contínuo ou de auxílio às equipes médicas pode trazer resultados impactantes para saúde pública de forma análoga como foi demonstrado na pandemia de COVID-19 na China, onde o *Mobile Health* foi essencial para o monitoramento de saúde da população. Assim, um sistema integrado com dados de saúde e tecnologias de software pode significar uma evolução drástica no cuidado dos idosos que vão além da predição de quedas.

Referências Bibliográficas

ABREU, D. C. C. de et al. Standing balance test for fall prediction in older adults: a 6-month longitudinal study. *BMC Geriatrics*, BioMed Central Ltd, v. 24, 12 2024. ISSN 14712318.

AGRAWAL, D. K. et al. Fall risk prediction using wireless sensor insoles with machine learning. *IEEE Access*, v. 11, p. 23119–23126, 7 2023. ISSN 2169-3536.

ALBITES-SANABRIA, J. et al. Real-world balance assessment while standing for fall prediction in older adults. *IEEE Transactions on Biomedical Engineering*, v. 71, p. 1076–1083, 3 2024. ISSN 1558-2531.

ALTUNKAYA, S. Leveraging feature selection for enhanced fall risk prediction in elderly using gait analysis. *Medical & biological engineering & computing*, Springer Science and Business Media Deutschland GmbH, v. 62, p. 3887–3897, 12 2024. ISSN 1741-0444. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/39126561><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC11568989>>.

BET, P.; CASTRO, P. C.; PONTI, M. A. Fall detection and fall risk assessment in older person using wearable sensors: A systematic review. *International journal of medical informatics*, Elsevier, v. 130, p. 103946, 2019.

BORGES, E. et al. O envelhecimento populacional: um fenômeno mundial. *O envelhecimento populacional um fenômeno*, v. 17, 2017.

BOURKE, A. K. et al. A physical activity reference data-set recorded from older adults using body-worn inertial sensors and video technology—the adapt study data-set. *Sensors*, MDPI, v. 17, n. 3, p. 559, 2017.

CARVALHO, L. de S. et al. O impacto do isolamento social na vida das pessoas no período da pandemia da covid-19. *Research, Society and Development*, v. 9, n. 7, p. e998975273–e998975273, 2020.

CHAN, L. L. et al. Prediction of injurious falls in older adults using digital gait biomarkers extracted from large-scale wrist sensor data. *Age and Ageing*, Oxford University Press, v. 52, 9 2023. ISSN 14682834.

CHANDLER, J. et al. *Cochrane handbook for systematic reviews of interventions*. [S.l.: s.n.], 2019. v. 4. 14651858 p.

CHEN, T.; GUESTIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 785–794.

COX, D. R. Regression models and life-tables. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 34, n. 2, p. 187–202, 1972. Disponível em: <<https://www.jstor.org/stable/2985181>>.

DELAHOZ, Y. S.; LABRADOR, M. A. Survey on fall detection and fall prevention using wearable and external sensors. *Sensors*, MDPI, v. 14, n. 10, p. 19806–19842, 2014.

DYKES, P. C. et al. Cost of inpatient falls and cost-benefit analysis of implementation of an evidence-based fall prevention program. In: AMERICAN MEDICAL ASSOCIATION. *JAMA Health Forum*. [S.l.], 2023. v. 4, n. 1, p. e225125–e225125.

FORTH, K. E. et al. A postural assessment utilizing machine learning prospectively identifies older adults at a high risk of falling. *Frontiers in medicine*, Frontiers Media S.A., v. 7, p. 591517, 12 2020. ISSN 2296-858X. Plataforma de força. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/33392218><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC7772994>>.

GOLDBERGER, A. L. et al. *PhysioNet: An NIH Research Resource for Complex Physiologic Signals*. 2000. e215–e220 p. Acessado em: 2025-08-08. Disponível em: <<https://physionet.org/>>.

Governo Federal. *Censo 2022: número de idosos na população do país cresceu 57,4% em 12 anos*. 2023. Disponível em: <<https://www.gov.br/secom/pt-br/assuntos/noticias/2023/10/censo-2022-numero-de-idosos-na-populacao-do-pais-cresceu-57-4-em-12-anos>>. Acessado em: 27 ago. 2025.

GREENE, B. R.; REDMOND, S. J.; CAULFIELD, B. Fall risk assessment through automatic combination of clinical fall risk factors and body-worn sensor data. *IEEE Journal of Biomedical and Health Informatics*, v. 21, p. 725–731, 5 2017. ISSN 2168-2208.

HARTHOLT, K. A. et al. Societal consequences of falls in the older population: injuries, healthcare costs, and long-term reduced quality of life. *Journal of Trauma and Acute Care Surgery*, LWW, v. 71, n. 3, p. 748–753, 2011.

HealthInfoNet. *HealthInfoNet: Maine's Statewide Health Information Exchange*. 2025. <<https://hinfonet.org/>>. Acessado em: 2025-08-08.

HEKTOEN, L. F.; AAS, E.; LURÅS, H. Cost-effectiveness in fall prevention for older women. *Scandinavian journal of public health*, Sage Publications Sage UK: London, England, v. 37, n. 6, p. 584–589, 2009.

KAMIENSKI, E. A.; BONATO, P.; ASADA, H. H. Time-critical fall prediction based on lipschitz data analysis and design of a reconfigurable walker for preventing fall injuries. *IEEE Access*, v. 12, p. 1822–1838, 7 2024. ISSN 2169-3536.

KUHN, H. W.; TUCKER, A. W. Nonlinear programming. In: *Proceedings of the Second Berkeley Symposium on Mathematical Statistics and Probability*. University of California Press, 1951. p. 481–492. Disponível em: <<https://projecteuclid.org/euclid.bsmsp/1200500249>>.

MAIORA, J. et al. Older adult fall risk prediction with deep learning and timed up and go (tug) test data. *Bioengineering (Basel, Switzerland)*, Multidisciplinary Digital Publishing Institute (MDPI), v. 11, 10 2024. ISSN 2306-5354. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/39451376><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC11504430>>.

MAKINO, K. et al. Simplified decision-tree algorithm to predict falls for community-dwelling older adults. *Journal of clinical medicine*, MDPI, v. 10, 11 2021. ISSN 2077-0383. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/34768703><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC8585075>>.

- MILLS, K. M. et al. An economic evaluation of preventing falls using a new exercise program in institutionalized elderly. *Journal of physical activity and health*, Human Kinetics, v. 15, n. 6, p. 397–402, 2018.
- MOHAN, D. et al. Fall prediction in elderly through vital signs monitoring—a fuzzy-based approach. *IEEE Internet of Things Journal*, v. 11, p. 33439–33449, 10 2024. ISSN 2327-4662.
- MUNN, Z.; TUFANARU, C.; AROMATARIS, E. *JBIs systematic reviews: data extraction and synthesis*. [S.l.]: LWW, 2014. v. 114. 49–54 p.
- NASRI, F. O envelhecimento populacional no brasil. *einstein*, São Paulo, v. 6, n. Supl 1, p. S4–S6, 2008.
- National Institute on Aging. *InCHIANTI Study (Invecchiare in Chianti)*. 2023. <<https://www.nia.nih.gov/inchianti-study>>. Acessado em: 2025-08-08.
- NITA, M. E. et al. Métodos de pesquisa em avaliação de tecnologia em saúde. *Arquivos de Gastroenterologia*, SciELO Brasil, v. 46, p. 252–255, 2009.
- NOURY, G. A. et al. The barriers of the assistive robotics market—what inhibits health innovation? *Sensors*, MDPI, v. 21, n. 9, p. 3111, 2021.
- OGONOWSKI, C. et al. Ict-based fall prevention system for older adults: Qualitative results from a long-term field study. *ACM Trans. Comput.-Hum. Interact.*, Association for Computing Machinery, v. 23, 10 2016. ISSN 1073-0516. Disponível em: <<https://doi.org/10.1145/2967102>>.
- PAGE, M. J. et al. The prisma 2020 statement: an updated guideline for reporting systematic reviews. *bmj*, British Medical Journal Publishing Group, v. 372, 2021.
- PETRÓ, B.; PAPACHATZOPOULOU, A.; KISS, R. M. Devices and tasks involved in the objective assessment of standing dynamic balancing—a systematic literature review. *PLoS one*, Public Library of Science San Francisco, CA USA, v. 12, n. 9, p. e0185188, 2017.
- RAZMARA, J.; ZABOLI, M. H.; HASSANKHANI, H. Elderly fall risk prediction based on a physiological profile approach using artificial neural networks. *Health Informatics Journal*, SAGE Publications Ltd, v. 24, p. 410–418, 12 2018. ISSN 17412811.
- SAMPAIO, R. F.; MANCINI, M. C. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. *Brazilian journal of physical therapy*, SciELO Brasil, v. 11, p. 83–89, 2007.
- SICA, M. et al. Continuous home monitoring of parkinson’s disease using inertial sensors: A systematic review. *PloS one*, Public Library of Science San Francisco, CA USA, v. 16, n. 2, p. e0246528, 2021.
- SUDLOW, C. et al. Uk biobank: an open access resource for identifying the causes of a wide range of complex diseases of middle and old age. *PLoS medicine*, Public Library of Science, v. 12, n. 3, p. e1001779, 2015.
- Suratec Co., Ltd. *Smart insole “SuraSole” (smart insole developed by Suratec Co., Ltd., Nakhon Ratchasima, Thailand)*. 2025. <<http://suratec.co.th/>>. Acessado em: 2025-08-12.

TENDO Sports Machines. *TENDO Sports Machines Official Website*. 2025. <<https://www.tendosport.com/>>. Acessado em: 2025-08-12.

UNRIC – Centro Regional de Informação da ONU para a Europa Ocidental. *Envelhecimento*. 2024. <<https://unric.org/pt/envelhecimento/>>. Acessado em: 27 ago. 2025.

VINCENZO, J. L.; GRAY, M.; GLENN, J. M. Validity of a novel, clinically relevant measure to differentiate functional power and movement velocity and discriminate fall history among older adults: A pilot investigation. *Innovation in Aging*, Oxford University Press, v. 2, 9 2018. ISSN 23995300.

WANG, Y. et al. Can smartphone-derived step data predict laboratory-induced real-life like fall-risk in community- dwelling older adults? *Frontiers in sports and active living*, Frontiers Media SA, v. 2, p. 73, 7 2020. ISSN 2624-9367. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/33345064><http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC7739785>>.

WONG, L. L. R.; CARVALHO, J. A. O rápido processo de envelhecimento populacional do brasil: sérios desafios para as políticas públicas. *Revista Brasileira de Estudos de população*, SciELO Brasil, v. 23, p. 5–26, 2006.

World Health Organization. *Falls: Key facts*. 2021. <<https://www.who.int/news-room/fact-sheets/detail/falls>>. Acessado em: 27 ago. 2025.

YANG, S.; LI, Q. Inertial sensor-based methods in walking speed estimation: A systematic review. *Sensors*, Molecular Diversity Preservation International (MDPI), v. 12, n. 5, p. 6102–6116, 2012.

YE, C. et al. Identification of elders at higher risk for fall with statewide electronic health records and a machine learning algorithm. *International Journal of Medical Informatics*, Elsevier Ireland Ltd, v. 137, 5 2020. ISSN 18728243.

ZUO, J. et al. Online monitoring for human sit-to-stand movement based on karush–kuhn–tucker optimized zonotope set-membership filter. *IEEE Transactions on Biomedical Engineering*, v. 71, p. 758–771, 3 2024. ISSN 1558-2531.