

# Um Sistema baseado em IoT para Monitoramento da Saúde de Idosos e Detecção de Quedas

Giseli Nunes Siqueira  
giseli.nunes1@gmail.com

Instituto Federal do Espírito Santo  
Serra, ES, Brasil

Leandro Resendo Colombi  
leandro@ifes.edu.br

Instituto Federal do Espírito Santo - Programa de  
Pós-Graduação em Computação Aplicada  
Serra, ES, Brasil

Eduardo Max Amaro Amaral  
eduardomax@ifes.edu.br

Instituto Federal do Espírito Santo  
Serra, ES, Brasil

Filipe Mutz  
filipe.mutz@ufes.br

Instituto Federal do Espírito Santo - Programa de  
Pós-Graduação em Computação Aplicada  
Universidade Federal do Espírito Santo  
Vitória, ES, Brasil

## ABSTRACT

The advancement of the internet to the paradigm of the Internet of Things (IoT) has brought to society new ways of generating, sharing and using information. The evolution of computing capacity and energy savings in IoT equipment combined with better software can enabled several new applications, among which we can highlight the monitoring of people's health through pervasive devices connected to the body. In view of this, this work proposes an algorithm to detect atypical situations such as falls in the elderly and other groups that need health care using accelerometers contained in wearable devices, particularly smartwatches. For the experimental evaluation of the proposed algorithm, a database that contains data from wearable sensors, environmental sensors, and visual devices was employed. The metrics used in the evaluation were accuracy, precision, recall and f1-score, with recall being the most relevant metric in the context. Results show that the best configuration of the algorithm is able to identify falls with 96% recall and F1-score of 90%.

## KEYWORDS

Internet of Things. Pervasive Computing. Health Computing. Elderly. Robotics. Fall Detection.

## 1 INTRODUÇÃO

O crescente acesso à internet pela maioria das pessoas tem trazido a nossa realidade novos conceitos e até novas formas de viver, tendo a internet e seu constante avanço como um item não mais supérfluo, mas como algo cada vez mais necessário, tornando a realização de atividades do cotidiano mais rápida, prática e cômoda através de uma conexão com internet. Em vista disso, pode-se destacar o avanço da internet para que esta possa acompanhar e suprir todas as necessidades demandadas pelos que a utilizam. Dentro desse avanço pode-se destacar a IoT - Internet of Things, que traduzida para o português, refere à Internet das Coisas, onde, segundo Chianese et al. [1], não somente as pessoas e seus dispositivos estarão conectados em rede, mas todos os objetos a sua volta, tornando-os cada vez mais pervasivos e trazendo ao mundo atual um conceito de abertura, onde diz-se que o mundo se torna mais aberto.

“Coisas Inteligentes” é o termo que se dá as coisas que passarão a estar conectadas em rede, onde cada uma delas e as pessoas que as utilizam produzem e consomem informações, geram conhecimento e interagem uns com os outros, aumentando a conexão de coisas e usuários, promovendo uma maior comodidade e facilitando a vida das pessoas em sociedade [2].

Conforme Atzori et al. [2], para que a IoT possa alcançar seu objetivo são necessários recursos que forneçam aplicações que promovam a interação entre os objetos e que sejam completamente possíveis de se integrar ao conceito de internet das coisas. Ainda segundo ele, esses recursos são sensores, leitores de etiquetas RFID - Radio Frequency Identification, ou em português, Identificação por Radiofrequência, e dispositivos que proporcionem a comunicação entre os objetos e que permitam o rastreamento de coisas e pessoas fornecendo serviços cada vez mais precisos e adequados as suas necessidades.

Atzori et al. [2] citam como exemplo de tarefas realizadas com IoT o monitoramento de áreas para plantação, monitoramento de saúde de pessoas através de dispositivos pervasivos conectados ao corpo, gerenciamento de condição física de produtos, casas com seus ambientes inteligentes, dentre outros. Dessa forma, o sensoria-mento de ambientes e de pessoas através da IoT vem sendo aplicado nas mais diversas áreas, entre elas o cuidado com a saúde, sendo utilizados em clínicas, monitoramento físico de pacientes através de dispositivos móveis carregados junto ao seu corpo, unidades de internação de pessoas com estado de saúde grave, e nas mais diversas aplicações onde o ser humano necessite de cuidados especiais e em tempo real [3], promovendo a melhoria dos procedimentos de socorro bem como de condição de vida dessas pessoas.

Tem se observado em todo o mundo uma tendência ao envelhecimento da população que mostram que o número de idosos irá dobrar em 2050, conforme dados da Organização Mundial da Saúde (OMS)[4]. No Brasil, a população idosa, segundo senso do Instituto Brasileiro de Geografia e Estatística (IBGE) em 2017, é de 30,2 milhões, apresentando crescimento de 18% em um período de 4 anos[5].

Idosos têm suas condições de saúde fragilizadas, sendo geralmente acometidos por doenças crônicas. Possuem também dificuldades de mobilidade e até mortalidade causadas por esses fatores

crônicos e por fatores externos. Alguns possuem ainda limitações físicas que impedem a realização de muitas de suas atividades. Obter, acompanhar e interpretar sua condição de saúde tem sido determinante para prover melhora na condição de vida dessas pessoas, já que são acometidas de várias doenças e tem sua qualidade de vida muitas vezes reduzida.

Uma das causas de redução da qualidade de vida dos idosos são quedas, que podem ser causadas por fatores inerentes a própria pessoa ou por fatores externos como características do ambiente [6]. Além das várias doenças crônicas a que são acometidas, essas pessoas têm maior tendência a cair, o que pode desencadear sérios danos, tanto físicos como fraturas, quanto psicológicos como a perda da confiança e o medo de que um novo episódio de queda ocorra. Diante desse quadro, a aplicação de IoT e o monitoramento de saúde através da utilização de sensores tem papel de aliado na identificação de situações de queda dessas pessoas através dos dados coletados.

Esses sistemas geralmente utilizam câmeras para coleta de dados, que são tratados, e as devidas ações são tomadas com base em seu resultado. Porém apresentam controvérsias quanto a sua utilização por comprometerem tanto a privacidade das pessoas que também residem no ambiente monitorado, quanto em situações íntimas das próprias pessoas monitoradas. O ideal é tornar o monitoramento das condições de saúde de uma pessoa e o seu ambiente de convivência cada vez mais confortável, silencioso e menos invasivo possível [7].

Diante disso, dispositivos vestíveis vêm sendo utilizados como alternativa, já que a maioria consegue obter dados relevantes acerca da condição de saúde de uma pessoa, captando movimentos, batimentos cardíacos, pressão arterial, localização via GPS - *Global Positioning System*, ou em português, Sistema de posicionamento Global, e ainda podendo se conectar diretamente à internet.

Smartwatches são relógios inteligentes que além de mostrar as horas conseguem, por meio de vários sensores embarcados, obter dados como localização, aceleração, frequência cardíaca, pressão arterial, entre outras, com a vantagem de serem vestíveis, proporcionam maior comodidade a quem os utiliza se tornando, no decorrer da sua constante utilização, praticamente invisíveis [8]. Atualmente é possível, utilizando-se dados obtidos por um smartwatch, capturar movimentos residuais e detectar situações de movimentos que indiquem uma queda de uma pessoa, bem como sua localização e registrar uma situação de emergência [9].

Neste trabalho será desenvolvido um algoritmo para detecção de quedas em pessoas idosas utilizando-se dados de dispositivos vestíveis instalados no pulso como smartwatches e realizada a medição da performance preditiva do mesmo. Para avaliação do sistema desenvolvido foi realizado o cálculo de métricas como acurácia, precisão, revocação e f1-score. Os resultados mostram que o sistema é capaz de identificar situações de queda com boa performance, alcançando no melhor caso revocação de 96% e F1-score de 90%. Experimentos adicionais mostram que o sistema obteve performance satisfatória quando em comparação com outros utilizando dados de dispositivos em outras partes do corpo como tornozelo, cintura, pescoço e bolso.

Esse trabalho encontra-se organizado em seções, a saber: a seção 2 é feita a fundamentação teórica e a descrição de trabalhos relacionados ao tema de detecção automática de quedas; Na seção 3, o desenvolvimento é descrito, com apresentação da base de dados

e o tratamento dos dados dos sensores, a descrição do processo de pré-processamento da base e do sistema proposto; na seção 4 é feita a apresentação dos experimentos, com a descrição dos dados levantados através do sistema de monitoramento de quedas e as métricas alcançadas; por fim, A conclusão e trabalhos futuros são dados na seção 5.

## 2 DETECÇÃO AUTOMÁTICA DE QUEDAS

A população idosa tem crescido ultimamente em todo o mundo. De acordo com a OMS, o número de pessoas idosas irá dobrar em 2050 [4]. No contexto do Brasil, segundo senso realizado pelo IBGE em 2017, o número de pessoas idosas é de 30,2 milhões, tendo apresentado, até então, crescimento de 18% em um período de quatro anos, sendo o idoso caracterizado como uma pessoa que tenham idade maior ou igual a 60 anos [5].

Com vista a esse aumento e nas necessidades demandadas por essas pessoas, sistemas têm sido desenvolvidos para auxiliar na promoção de melhor qualidade de vida e em suas atividades diárias. Por possuírem condições de saúde fragilizadas, serem acometidos por doenças crônicas como diabetes, hipertensão e, terem sua capacidade de mobilidade reduzidas em decorrência de fatores externos ou crônicos, essas pessoas podem ter dificuldade na realização de suas atividades cotidianas.

Segundo a Pesquisa Nacional de Saúde realizada pelo IBGE [10], cerca de 17,3% da população idosa apresenta dificuldades na realização de atividades de vida diária como fazer compras, tomar medicação, realizar atividades domésticas, etc., por possuírem limitações funcionais, aumentando para 39,2% quando avaliados idosos com idade maior ou igual a 75 anos ou mais.

Nota-se também o aumento da população idosa que reside sozinha, o que aumenta os riscos de acidentes e pode causar maiores transtornos devido à demora na prestação de socorro. De acordo com a Pesquisa Nacional por Amostra de Domicílios Contínua do IBGE, o número de pessoas com 60 anos ou mais que residem sozinhas no Brasil é de 14,6% dessa população.

Diante do aumento da população idosa e do estabelecimento do paradigma da Internet das Coisas, tecnologias AAL - *Ambient Assisted Living*, ou Ambiente de Vida Assistido, vem ganhando importância e sendo desenvolvidas a fim de auxiliar na realização de atividades de rotinas diárias com auxílio de tecnologias assistivas [11]. Em Mainetti et al. [12], um sistema AAL foi desenvolvido para monitorar de forma contínua o estado de saúde de um idoso através de dados de múltiplos sensores e dar a localização do idoso em tempo real, gerando alertas quando necessário.

Utilizando-se IoT e os sistemas AAL, ambientes inteligentes têm sido criados, tornando-os mais seguros, oferecendo mecanismos de emergência cada vez mais ágeis, soluções de detecção de quedas e sistemas de vídeo vigilância, por exemplo, além de serem ferramentas de suporte no cotidiano, sendo possível monitorar a realização de atividades diárias [13]. Em seu trabalho mostram uma arquitetura de sensoriamento de ambiente, capturando mudanças comportamentais de pessoas idosas através de dados de posicionamento e mobilidade de maneira discreta, com baixo custo e consumo de energia utilizando tecnologias de IoT.

Em Stutzel et al. [14], é mostrado um sistema móvel que monitora idosos com doenças crônicas, objetivando tornar a comunicação

com cuidadores ágil e reduzir seu estresse e fornecer a condição do paciente com maior frequência e organização utilizando smartphones e tablets.

Sensores contidos em dispositivos vestíveis também são utilizados para a detecção de quedas de idosos. Ocorrência de quedas é uma das principais causas de redução da qualidade de vida de pessoas idosas, sendo causadas por fatores inerentes a própria pessoa ou fatores externos relacionados ao ambiente em que esta pessoa vive ou frequenta. Podem ainda desencadear sérios danos, tanto físicos como fraturas por exemplo, quanto psicológicos como a perda da confiança e o medo de que um novo episódio de queda ocorra.

Por possuir fatores multidimensionais e ocorrerem com uma frequência considerável, e ainda, serem um importante fator que gera problemas relacionados a saúde da pessoa idosa ou a fatores inerentes ao ambiente, as quedas demandam atenção especial em relação a criação de ações para prevenir sua ocorrência. Nesse sentido, segundo [13], detectar os riscos precocemente pode auxiliar na realização de intervenções apropriadas e precisas, que venham a auxiliar no não aumento do risco da condição e melhorar a qualidade de vida e redução dos custos em tratamentos.

Sistemas embarcados, redes de sensores e IoT têm sido amplamente utilizados na área de saúde como ferramentas poderosas no monitoramento de ambientes e de pessoas presentes nesse ambiente com vistas a garantir melhores condições de vida para os idosos, bem como monitorar suas condições de saúde [13] e, com isso, melhorar o provimento de auxílio em casos em que sejam necessários maiores ou mais específicos cuidados médicos.

Em Galvão et al. [15], um sistema foi construído utilizando IoT, sensores e câmeras de vídeo, processamento digital de imagens e visão computacional para monitorar um ambiente e detectar situações de ocorrência de quedas de idosos. Em Ozcan and Velipasalar [16], um sistema foi desenvolvido utilizando dispositivos vestíveis como smartphone e tablet equipados com acelerômetro e câmera de vídeo para detectar a ocorrência de quedas de idosos, diferenciando-as de outras atividades diárias como andar, sentar, descer ou subir escadas, etc. Em De Araujo et al. [8], um sistema utilizando dados coletados pelo acelerômetro contido em um smartwatch foi desenvolvido para detectar quedas.

Nesse sentido, tendo os idosos como sendo pessoas que necessitam de monitoração na maioria dos casos, e com base na ainda existência de resistência desse grupo em relação a utilização de tecnologias quando essas apresentam grande número de recursos [17], terem sua privacidade invadida ou até mesmo não aceitarem cuidados, a utilização de dispositivos móveis e vestíveis tem auxiliado no sucesso de sistemas de monitoramento para essas pessoas por não realizarem intromissões em suas vidas [13] e não terem restrições de obtenção de dados devido aos ambientes onde são instalados para não invadirem questões de privacidade [8].

O suporte à saúde de pessoas idosas tem crescido a fim de atender suas necessidades, visto que possuem riscos de saúde aumentados por diversos fatores, promovendo a possibilidade de se manterem seguros e com a devida assistência através da utilização de Smartwatches tanto no ambiente residencial quanto fora dele. Esses dispositivos analisam taxas de batimentos cardíacos, movimento e localização dessas pessoas por meio de sensores e sendo capaz

de promover comunicação com médicos e/ou familiares em situações de risco, sendo imperceptíveis na maioria das vezes e não interferindo na vida cotidiana do usuário [18].

### 3 DESENVOLVIMENTO

Nesta seção serão descritas as etapas de desenvolvimento deste trabalho, estando dividido em subseções, sendo que a 3.1 descreve a metodologia de pesquisa aplicada, a 3.2 descreve a base de dados utilizada, a 3.3 aborda o pré-processamento dos dados e a 3.4 traz a descrição do sistema proposto.

#### 3.1 METODOLOGIA

Esta pesquisa tem natureza aplicada, tendo em vista a aplicação de conhecimentos para apresentar solução à problemas de cunho específico por meio da realização de atividade particular de forma prática [19]. Quanto a abordagem, esta pesquisa é determinada como sendo quantitativa. De acordo com Lakatos and Marconi [20], o método quantitativo baseia-se em dados medidos numericamente e analisados de forma estatística para levantar informações que provem as hipóteses levantadas.

Quanto aos objetivos desta pesquisa, a sua classificação é de natureza exploratória, descritiva e explicativa. Segundo Gil et al. [21], o principal objetivo da pesquisa exploratória é levar ao aperfeiçoamento de ideias através da familiaridade com o problema, a fim de também levar ao levantamento de hipóteses, através da realização de levantamento bibliográfico. Ainda de acordo com o autor, a pesquisa descritiva trata da descrição das características dos envolvidos no experimento, de fenômenos ocorridos ou a relação entre variáveis e a pesquisa explicativa busca identificar nos fenômenos seus agentes determinantes e contributivos.

Foi empregado ainda o método experimental de pesquisa, que segundo Gil et al. [21], consiste em estabelecer um objeto, realizar a seleção de variáveis que possam exercer influência sobre este e a definição de formas de controle e observação dos efeitos produzidos.

Na produção desta pesquisa, realizou-se revisão bibliográfica buscando tratar os pontos na bibliografia já publicada sobre a utilização de IoT e de dispositivos vestíveis na identificação de episódios de quedas acometendo pessoas idosas. O levantamento bibliográfico proporciona conhecer o que já foi publicado e o que já foi abordado a respeito do tema, para que a proposta seja justificada e evitar a repetição de estudos anteriores [22].

Após o levantamento bibliográfico, foi realizada pesquisa de bases de dados de dispositivos vestíveis, mais especificamente smartwatch, a fim de se ter dados semelhantes aos coletados nos trabalhos base dessa pesquisa. A coleta de dados na pesquisa experimental utiliza-se de recursos que envolvam algum tipo de processamento, como por exemplo, recursos mecânicos, elétricos ou eletrônicos para, a partir da manipulação de determinadas condições se observar os efeitos produzidos.

Para a detecção de quedas, o modelo deste sistema baseou-se no algoritmo descrito em [23] onde utiliza-se um smartwatch baseado no sistema Android para dispositivos móveis. O algoritmo de detecção de quedas em questão foi implementado como um serviço em segundo plano, onde ao se detectar uma queda o serviço informa a aplicação principal que notifica os cuidadores da pessoa idosa.

**Tabela 1: Atividades realizadas pelos sujeitos. Fonte: Martínez-Villaseñor (2019).**

ID	DESCRIÇÃO	DURAÇÃO (s)
1	Caindo para frente usando as mãos	10
2	Caindo para frente usando os joelhos	10
3	Caindo para trás	10
4	Caindo para o lado	10
5	Caindo sentado em uma cadeira vazia	10
6	Andando	60
7	De pé	60
8	Sentado	60
9	Pegando um objeto	10
10	Pulando	30
11	Deitado	60

Desenvolveu-se então um algoritmo para tratamento dos dados obtidos e sua interpretação, a fim de tornar conhecidos os parâmetros de acurácia, precisão, revocação e f1-score ao se detectar quedas a partir da estratégia de adaptação dos dados utilizada neste trabalho.

### 3.2 BASE DE DADOS

Os dados utilizados nesta pesquisa foram coletados no trabalho de Martínez-Villaseñor et al. [24], que é um conjunto de dados multimodal para detecção de quedas coletado através de experimento utilizando 17 pessoas jovens e saudáveis utilizando diversos sensores dos tipos vestíveis, ambientais e dispositivos visuais. Para tanto, os usuários realizaram atividades diárias selecionadas com base em pesquisa na literatura, conforme mencionado pelo autor. As atividades diárias simuladas foram: andar, ficar de pé, ficar sentado, pegar um objeto, pular e deitar. Também foram simulados 5 tipos de quedas, sendo elas: caindo para frente usando as mãos, caindo para frente usando os joelhos, caindo para trás, caindo para o lado e caindo sentado em uma cadeira vazia, utilizando-se de 3 tentativas para cada uma das atividades com ID e duração de cada uma descrita na Tabela 1.

Os sensores utilizados para coleta dos dados foram 5 sensores vestíveis para obter dados de acelerômetro, giroscópio e luz ambiente. Além destes, foram coletados dados de eletroencefalografia através de um fone de ouvido, dados de seis sensores infravermelhos e ainda 2 câmeras, resultando em um *dataset* com mais de 850 GB de informações sensoriais.

Nesta pesquisa, utilizamos essa base de dados por ela possuir o objetivo de auxiliar no reconhecimento de atividade humana voltada para a comparação de soluções de detecção de quedas, e ainda por não ser o foco dessa pesquisa a realização de experimentos com pessoas reais, tendo em vista o seu escopo. Para tanto, utilizou-se dados de sensores semelhantes aos contidos em um smartwatch para obter-se dados de acelerômetro. Com base em De Araujo et al. [8], os limiares utilizados na detecção de quedas são identificados quando o dado desse sensor excede um valor pré-definido.

A definição dos sujeitos é parte importante para realização desta pesquisa, visto que é a partir dos resultados obtidos através desse

**Tabela 2: Estatísticas dos sujeitos.**

ID	IDADE	ALT. (m)	PESO(kg)	GÊNERO	LADO
1	18	1.70	99	Masculino	Destro
2	20	1.70	58	Masculino	Destro
3	19	1.57	54	Feminino	Canhoto
4	20	1.62	71	Feminino	Destro
5	21	1.71	69	Masculino	Destro
6	22	1.62	68	Masculino	Destro
7	24	1.74	70	Masculino	Destro
8	23	1.75	88	Masculino	Destro
9	23	1.68	70	Feminino	Destro
10	19	1.69	63	Masculino	Destro
11	20	1.65	73	Feminino	Destro
12	19	1.60	53	Feminino	Destro
13	20	1.64	55	Masculino	Destro
14	19	1.70	73	Feminino	Destro
15	21	1.57	56	Feminino	Destro
16	20	1.70	62	Masculino	Destro
17	20	1.66	54	Feminino	Destro

grupo que se pode generalizar para a população na qual estes pertencem. É de grande importância que a população que participará da pesquisa seja determinada com precisão.

Os dados utilizados foram coletados em experimento que utilizou 17 pessoas jovens, saudáveis e não portadoras de deficiências, sendo 9 homens e 8 mulheres com idade entre 18 e 24 anos de idade, com suas características principais listadas na Tabela 2, utilizando sensores vestíveis, que realizaram atividades diárias e a simulação de 5 tipos de quedas cada uma em 3 tentativas.

Sabe-se que os resultados obtidos através de simulação com pessoas jovens podem conter diferenças quando comparadas com a ocorrência dos mesmos eventos com pessoas idosas, mas conforme Martínez-Villaseñor et al. [24], o conjunto de dados em questão pode ser utilizado para experimentos que utilizem aprendizado de máquina para previsão também em idosos.

Ainda em relação a utilização de dados de grupos de pessoas jovens e de idosos, pode-se destacar que os parâmetros de configuração e os valores dos limites para os picos de aceleração definidos no sistema proposto mudam em relação a esses grupos, porém a variação da aceleração não apresenta alterações, assim como em relação a alterações nas características físicas das pessoas em questão como altura, peso, etc., não influenciando assim na análise realizada neste trabalho.

### 3.3 PRÉ-PROCESSAMENTO

O pré-processamento é etapa importante para padronizar os dados com que se quer trabalhar e extrair conhecimento a partir destes. Para se obter o resultado esperado e evitar a perda do desempenho de um sistema, são aplicadas diversas estratégias de tratamento de dados a depender da base de dados e sua composição.

Neste trabalho, o pré-processamento dos dados foi realizado buscando tratar dados de acelerômetro que estavam fora do padrão, filtrar apenas dados relevantes para o objetivo principal, conhecer as características dos dados e realizar algumas operações de alteração

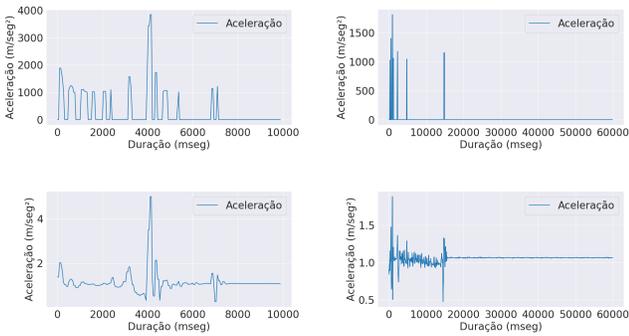


Figura 1: Gráficos de aceleração antes (primeira linha) e após (segunda linha) o pré-processamento dos dados.

de tipagem, tendo em vista o grande número de dados disponíveis na base de dados selecionada.

Para tratamento dos dados algumas operações realizadas em código utilizando linguagem Python foram realizadas. A base em formato .csv foi convertida para arquivo no formato .xlsx do aplicativo de criação de planilhas Excel para facilitação do entendimento, contendo 47 colunas com dados de acelerômetros colocados em tornozelo, acelerômetro em dispositivos no bolso, acelerômetro no pulso, infravermelho, etc., coletados a uma frequência de 100 Hz, o que difere do utilizado em [23], por medir em seu trabalho os valores de acelerômetro a uma frequência de 40 Hz.

Para esta pesquisa, os dados considerados foram os tempos no formato de data e hora, os valores de acelerômetro com eixo x, eixo y e eixo z, além das colunas indicando o ID dos sujeitos, atividades e tentativas. As colunas também foram renomeadas para facilitar a utilização do dataset, e a coluna com os tempos foi tratada, sendo convertida para o tipo datetime e posteriormente numérico da linguagem Python.

Ao gerar visualizações por meio de gráficos da aceleração utilizando-se os valores dos três eixos, notou-se que esses dados estavam despadronizados, alguns não possuindo divisão decimal ocasionando assim o cálculo errado da aceleração, conforme exibido na Figura 1 (primeira linha), onde o eixo Y do gráfico estava com escala com 7 casas decimais. A fim de ajustar esses valores, realizou-se um tratamento de conversão do tipo dos dados e o cálculo do valor absoluto, onde casos em que este fosse maior que 30 então foi realizada divisão por 1000, conseguindo-se assim ajustar a escala do eixo Y referente à aceleração conforme exibido na Figura 1.

### 3.4 SISTEMA PROPOSTO

O algoritmo desenvolvido nesse trabalho tomou como base o trabalho de Kostopoulos et al. [23], onde o módulo de detecção de quedas do sistema utiliza um algoritmo baseado em limiares para detectar a ocorrência de quedas. Para tanto, são levados em consideração o momento da queda livre, os movimentos do usuário pós-queda e a localização.

Em seu trabalho, atividades de rotina diária são identificadas por padrões e distinguidas de quedas, para tanto é calculada a aceleração para cada caso com base no cálculo abaixo.

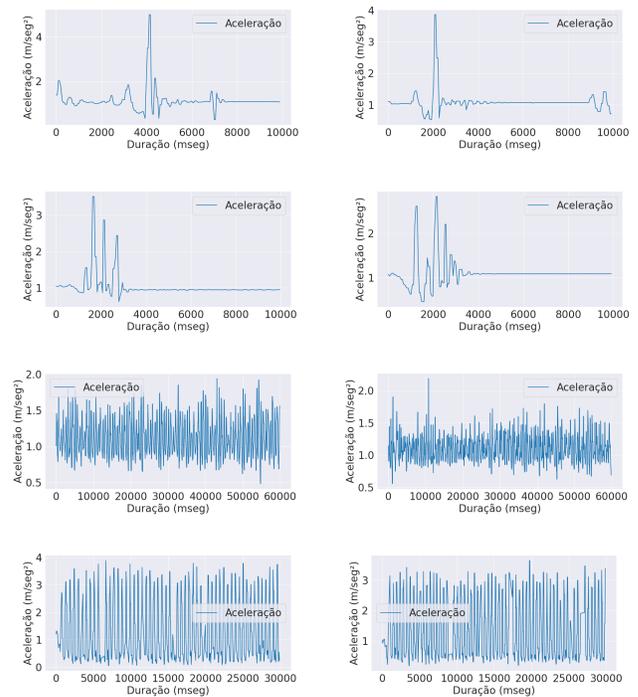


Figura 2: Ilustração do comportamento da aceleração em diferentes movimentos. As quatro linhas representam, respectivamente, as ações de queda para frente usando as mãos, queda para frente sobre os joelhos, caminhada e saltos. As colunas são amostras diferentes destas atividades.

$$aceleracao = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

Neste trabalho foi realizado o cálculo da aceleração sobre os dados tratados e em seguida gerados gráficos para análise do comportamento para cada sujeito, atividade e tentativa. A Figura 2 ilustra o comportamento da aceleração em diferentes movimentos. As quatro linhas representam, respectivamente, as ações de queda para frente usando as mãos, queda para frente sobre os joelhos, caminhada e saltos. As colunas são amostras diferentes destas atividades.

Ainda conforme Kostopoulos et al. [23], são três movimentos principais que caracterizam um episódio de queda em seu trabalho, a saber: a alteração da aceleração no instante exato da queda, chamada por eles de rebote, o movimento seguinte à queda chamado de movimento residual e a localização da pessoa no instante da queda.

Os limiares, sendo definidos como valor mínimo e máximo obtidos com base em atividades diárias da pessoa, são utilizados como pontos de observação da alteração da aceleração durante um episódio de queda. Quando uma queda ocorre, o pico da aceleração é maior que o valor máximo do limiar, em sequência o padrão da queda é identificado quando há um segundo pico, menor que o primeiro, e que ultrapassa o limiar inferior usado para identificar o rebote da queda. Por último, a aceleração retorna aos valores normais.

Definida uma janela de tempo entre 5 e 6 segundos, se os valores da aceleração excedem os limiares estando dentro do padrão de existência de dois picos com tempo de no máximo 0,5 segundos entre eles, então uma possível queda é identificada e um módulo de decisão define se a queda é real. Nesse módulo, um contador é incrementado sempre que situações de quedas são identificadas. Seu valor é então comparado com dois valores pré-definidos que registram número de picos de aceleração de outras atividades como, por exemplo corrida (contador  $\geq Y$ ) ou apenas movimentos bruscos com o pulso onde está o sensor (contador  $< X$ ). Neste caso, para validar a ocorrência de uma queda o contador deve estar entre os valores de  $X$  e  $Y$  ( $X \leq \text{contador} \leq Y$ ), sendo  $Y$ , segundo os autores, definido entre 5 e 10 para idosos e  $X$  igual a 1. Quando o contador estiver no intervalo, uma queda é detectada.

#### 4 EXPERIMENTOS

Para os experimentos foram utilizados dados de uma base de dados contendo informações de acelerômetro coletados através de simulações de atividades diárias consideradas normais e atividades de queda utilizando dispositivos em várias partes do corpo. Para atender a finalidade desse trabalho em relação a detectar quedas utilizando smartwach, foram lidos, tratados e interpretados os dados referentes ao acelerômetro de três eixos instalado no pulso dos sujeitos.

A primeira estratégia de interpretação dos dados foi estabelecida através da leitura dos gráficos da aceleração em relação ao tempo medidos para cada sujeito, atividade e tentativa, onde definiu-se, conforme método utilizado como base e descrito na seção 3, o valor máximo para o limite superior da aceleração. Observou-se então que dentro do conjunto de dados analisado, o limite superior poderia ser estabelecido com valor de aceleração igual a  $2m/sec^2$ , pois, nas atividades onde realmente houve queda a aceleração teve pico elevado ultrapassando esse valor.

Ao definir o limite superior como sendo igual a  $2m/sec^2$ , divergiu-se do proposto por Kostopoulos et al. [23], que estabelece um limite superior entre 10 a  $18m/sec^2$  dependendo do perfil do usuário. Isso deve-se ao fato de que os valores de acelerômetro mudaram na forma de coleta em relação ao dispositivo utilizado e à frequência de captura nos dois trabalhos, além de talvez a aceleração da gravidade não ter sido removida na base de dados utilizada para testes, impactando diretamente nos valores da aceleração.

A partir da definição do limite superior o algoritmo desenvolvido calculou as métricas de performance para conhecer a capacidade de acertar nas previsões utilizando apenas este critério. As métricas foram construídas a partir da matriz de confusão que é uma estrutura em linhas e colunas, onde as linhas se referem a classe verdadeira e as colunas são referentes ao que foi predito pelo modelo e são preenchidas pelo valor de comparação [25]. Foram utilizadas como métricas acurácia, precisão, revocação e f1-score.

A acurácia (ACC) é a métrica que indica quanto o modelo teve índice de acerto dentro das previsões possíveis, ou seja, a quantidade de acertos dentro do total de previsões realizadas. O seu valor é a razão entre a soma das previsões corretas pela quantidade de previsões, e é calculada conforme abaixo:

$$Acuracia = \frac{VP + VN}{VP + VN + FN + FP} \quad (2)$$

**Tabela 3: Métricas de performance utilizando apenas limite superior para aceleração.**

	Precisão	Revocação	F1-score	Suporte
Falso	96%	85%	90%	304
Verdadeiro	84%	96%	90%	255
Acurácia			90%	559
Média macro	90%	90%	90%	559
Média ponderada	91%	90%	90%	559

A precisão (PRC) é o resultado da proporção dos modelos positivos que foram corretamente identificados, ou seja, quantas amostras preditas como positivas de fato eram. Seu valor é dado pela divisão dos verdadeiros positivos pela soma dos verdadeiros positivos com os falsos positivos, conforme abaixo:

$$Precisao = \frac{VP}{VP + FP} \quad (3)$$

A revocação (RVC) mede a proporção de positivos que foram corretamente identificados, ou seja, quão bom de detectar positivos o meu modelo é. Seu valor é definido pela razão entre os verdadeiros positivos pela soma de verdadeiros positivos com falsos negativos, conforme abaixo:

$$Recall = \frac{VP}{VP + FN} \quad (4)$$

O F1-score (F1) é a medida que mostra a média entre precisão e revocação do modelo de predição. Seu cálculo é dado conforme abaixo:

$$F_1 = 2 * \frac{Recall * Precision}{Recall + Precision} \quad (5)$$

A Tabela 3 mostra os valores obtidos com este experimento. Nesta avaliação, o algoritmo conseguiu um índice de acurácia de 90%, indicando que utilizando apenas o limite superior consegue detectar corretamente uma queda em aproximadamente 503 simulações do total de 559 analisadas no *dataset*. Quando comparado com o índice de acurácia alcançado em [23], o algoritmo deixou de prever corretamente apenas 6.01% das situações de queda, sendo 96.01% o índice de acurácia obtido por ele. Já em relação a revocação, métrica relevante neste trabalho devido ao seu contexto, o algoritmo conseguiu índice de 96% na previsão correta de casos de queda classificados como verdadeiros.

Adicionou-se então à implementação do algoritmo de detecção os conceitos de limite inferior, janela de tempo e contador, para que na ocorrência do pico de aceleração maior que o limite superior a queda seja identificada após a ocorrência de um segundo pico, menor que o primeiro e que ultrapasse esse limite inferior em uma janela de tempo de medição definida em 5 segundos e com tempo de 0.5 segundos entre eles. Após satisfeitos os critérios um contador é incrementado sendo definido com valor entre 5 e 10 para eliminação de falsos positivos em atividades que possuem muitos picos de aceleração.

Nesse caso, o limite inferior foi definido em  $1.5m/sec^2$ , e o contador foi definido em 5 picos. O algoritmo então calculou as métricas

**Tabela 4: Métricas de performance utilizando todos os critérios para avaliação.**

	Precisão	Revocação	F1-score	Suporte
Falso	94%	89%	91%	304
Verdadeiro	87%	93%	90%	255
Acurácia			91%	559
Média macro	91%	91%	91%	559
Média ponderada	91%	91%	91%	559

**Tabela 5: Métricas de performance com segundo pico entre os limites superior e inferior.**

	Precisão	Revocação	F1-score	Suporte
Falso	76%	92%	83%	304
Verdadeiro	88%	65%	74%	255
Acurácia			80%	559
Média macro	82%	79%	79%	559
Média ponderada	81%	80%	79%	559

de performance para conhecer a capacidade de acertar nas predições utilizando todos os critérios também utilizados em [23]. A Tabela 4 mostra os valores obtidos com este experimento.

Nesta avaliação, o algoritmo conseguiu um índice de acurácia de 91%, mostrando-se melhor em 1% em relação a medição utilizando apenas o limite superior como critério de definição. Quando comparada com a acurácia alcançada em [23], essa abordagem aplicada na base de dados utilizada neste trabalho obteve diminuição de 5.01%. Observou-se também o aumento de 3% na precisão na detecção de casos verdadeiros de 84% para 87% e diminuição de 3% na revocação em relação aos verdadeiros, ou seja, diminuição na capacidade do modelo de prever casos de queda corretamente.

Ainda se utilizando o método que envolve os parâmetros definidos em [23], sendo: a definição de um limite superior e um limite inferior, uma janela de tempo definida em 5 segundos e um tempo entre os picos de 0.5 segundos, foi definido um critério extra objetivando a análise do desempenho do algoritmo para os casos onde o segundo pico de aceleração for maior que o limite inferior, mas seja sempre menor que o limite superior, ficando assim entre os limiares. A Tabela 5 mostra os valores obtidos com este experimento.

O algoritmo conseguiu obter acurácia de 80%, piorando seu desempenho em 10% quando comparado a medição com apenas o limite superior definido e de 11% em relação a utilização de todos os critérios para detecção de uma queda com base em [23], não sendo assim, bom em prever corretamente em relação aos demais métodos apresentados. A precisão, neste caso, ao analisar os verdadeiros aumentou em 1%, de 87% utilizando todos os critérios de detecção de queda para 88%. A revocação decresceu em 28% em relação a utilização de todos os critérios para detecção de queda, de 93% para 65% nesta medição, o que mostra que esta abordagem é pior em relação a previsão correta das quedas, onde o algoritmo pode deixar de prever uma situação real de sua ocorrência.

Mediu-se ainda o desempenho do algoritmo utilizando a abordagem de apenas o limite superior definido e a abordagem utilizando

**Tabela 6: Métricas de performance para demais acelerômetros vestíveis.**

Modelo	Acurácia	Precisão	Revocação	F1-score
Apenas limite superior definido				
pulso	90%	84%	96%	90%
tornozelo	81%	77%	84%	80%
bolso	93%	98%	86%	92%
cintura	<b>98%</b>	<b>98%</b>	<b>98%</b>	<b>98%</b>
pescoço	97%	99%	95%	97%
Todos os critérios definidos				
pulso	91%	87%	93%	90%
tornozelo	87%	91%	80%	85%
bolso	91%	98%	82%	89%
cintura	<b>96%</b>	<b>98%</b>	<b>94%</b>	<b>96%</b>
pescoço	<b>96%</b>	<b>99%</b>	<b>93%</b>	<b>96%</b>

todos os critérios de definição de queda conforme Kostopoulos et al. [23], em relação aos dados de outros acelerômetros que não o de pulso disponíveis na base de dados utilizada neste trabalho, sendo estes localizados em outras regiões do corpo dos sujeitos, sendo: tornozelo, bolso, cintura e pescoço. A Tabela 6 mostra os valores obtidos com este experimento.

Como pode-se observar o algoritmo apresenta bom desempenho na detecção de quedas também com dados de dispositivos em outras regiões do corpo, podendo-se destacar os índices para o acelerômetro na cintura utilizando apenas o critério do limite superior e o todos os critérios definidos no trabalho base, e também o acelerômetro no pescoço se utilizando todos os critérios definidos também no trabalho base.

Em relação a métrica de revocação como sendo métrica relevante neste trabalho, o algoritmo mostrou-se bom em classificar situações de queda com índice satisfatório para todos os acelerômetros, destacando-se nos casos de acelerômetro instalado na cintura e levando-se em consideração apenas o limite superior como indicativo de ocorrência de queda. Em relação ao f1-score, o algoritmo mostrou-se com melhor desempenho em dispositivos instalados em regiões com menor mobilidade como cintura e pescoço nas duas abordagens de detecção aplicadas, já que segundo Mighali et al. [13], os sensores colocados em locais que recebem movimentos mais complexos, têm maior complexidade na detecção de atividades.

## 5 CONCLUSÃO

Este trabalho levantou métricas de desempenho de um algoritmo implementado com o objetivo de identificar situações de quedas em pessoas idosas. Foi desenvolvido algoritmo que, a partir de uma base de dados de teste, identifica se uma determinada atividade é classificada como queda ou não dentro de um conjunto contendo atividades de rotina diária e eventos de queda.

O resultado mostrou que considerando os critérios definidos para detectar quedas mostrados em trabalho correlato, a utilização apenas do limite superior para o pico da aceleração durante o evento de queda é relevante para caracterizar um evento como queda real, tendo um desempenho de acurácia de 90%, precisão de 84%, revocação de 96% e f1-score de 90%. Levando-se em consideração

a utilização de limite superior, limite inferior, quantidade de picos e janela de tempo, o algoritmo mostrou-se levemente melhor em relação a abordagem com apenas limite superior definido, tendo um desempenho de acurácia de 91%, 87% de precisão, revocação de 93% e f1-score de 90%.

Foi possível observar ainda que ao definir o critério dos picos de aceleração dentro da janela de tempo de indicação de quedas e o segundo pico for maior que o limite inferior e menor que o limite superior, o desempenho foi reduzido em relação aos demais métodos, resultando em uma acurácia de 80%, precisão de 88%, a revocação em 65% e o f1-score em 74% para casos verdadeiros. Observou-se ainda que a aplicação do algoritmo em dados de acelerômetro de dispositivos em outras partes do corpo diferentes do pulso obteve desempenho satisfatório, destacando-se os valores obtidos para os dispositivos localizados em regiões menos móveis como cintura e pescoço.

Tendo em vista o objetivo a que esse trabalho se propõe, foi possível também observar que a revocação, tida como métrica relevante dentro do contexto, foi melhor na abordagem de definição apenas do limite superior com 96% e pior na abordagem com todos os critérios e adicionando o pico de aceleração entre os dois limites, com 65% apenas. Conforme esclarecido em [23], esses valores podem mudar a depender do perfil do usuário que é determinante na característica dos dados coletados.

Como recomendação de trabalhos futuros propõe-se a construção de uma base de dados com informações de sensores utilizados por pessoas idosas para melhor avaliação de desempenho do algoritmo com dados dessa população em específico. Para tanto, propõe-se o registro de casos de ocorrências naturais de quedas sofridas por idosos visando não os submeter a situações que possam comprometer sua saúde como por exemplo, a simulação de quedas.

Propõe-se ainda a aplicação de métodos de aprendizado de máquina sobre a base de dados para uma avaliação da medição da acurácia para as abordagens aplicadas neste trabalho. Pode-se ainda desenvolver módulos voltados a avaliação do estado de saúde de pessoas idosas, utilizando dados de outros sensores disponíveis em dispositivos móveis como sensores cardíacos, para verificação da ocorrência de alterações no momento de uma queda detectada para uma completa assistência de vida à essas pessoas.

## AGRADECIMENTOS

Este estudo foi financiado em parte pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, Brasil); e pela Fundação de Amparo à Pesquisa do Espírito Santo (FAPES, Brasil) - processo 2021-07KJ2; Os autores agradecem ainda ao apoio da FAPES e da CAPES (processo 2021-2S6CD, nºFAPES 132/2021) por meio do PDPG (Programa de Desenvolvimento da Pós-Graduação, Parcerias Estratégicas nos Estados).

## REFERÊNCIAS

- [1] Angelo Chianese, Francesco Picciulli, and Giuseppe Riccio. Smune: A smart multisensor network based on embedded systems in iot environment. In *2015 11th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, pages 841–848. IEEE, 2015.
- [2] Luigi Atzori, Antonio Iera, and Giacomo Morabito. From "smart objects" to "social objects": The next evolutionary step of the internet of things. *IEEE Communications Magazine*, 52(1):97–105, 2014.
- [3] Arnaud SRM Ahouandjinou, Kokou Assogba, and Cina Motamed. Smart and pervasive icu based-iot for improving intensive health care. In *2016 International Conference on Bio-engineering for Smart Technologies (BioSMART)*, pages 1–4. IEEE, 2016.
- [4] Ageing and health. <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>. Accessed: 2022-10-30.
- [5] Número de idosos cresce 18 em 5 anos e ultrapassa 30 milhões em 2017. <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2012-agencia-de-noticias/noticias/20980-numero-de-idosos-cresce-18-em-5-anos-e-ultrapassa-30-milhoes-em-2017.html>. Accessed: 2022-10-30.
- [6] Quedas em idosos: Um problema de saúde pública. <http://www.blog.saude.gov.br/index.php/promocao-da-saude/53685-quedas-em-idosos-um-problema-de-saude-publica>. Accessed: 2022-10-30.
- [7] Atika Arshad, Sheraz Khan, AHM Zahirul Alam, Ahmad Fadzil Ismail, and Ruman Tasnim. Capacitive proximity floor sensing system for elderly tracking and fall detection. In *2017 IEEE 4th International Conference on Smart Instrumentation, Measurement and Application (ICSIMA)*, pages 1–5. IEEE, 2017.
- [8] Italo Linhares De Araujo, Lucas Dourado, Leticia Fernandes, Rossana Maria De C Andrade, and Paulo Armando C Aguiar. An algorithm for fall detection using data from smartwatch. In *2018 13th Annual Conference on System of Systems Engineering (SoSE)*, pages 124–131. IEEE, 2018.
- [9] Thomas Vilarinho, Babak Farshchian, Daniel Gloppstad Bajer, Ole Halvor Dahl, Iver Egge, Sondre Steinsland Hegdal, Andreas Lønes, Johan N Slettevold, and Sam Mathias Weggelsen. A combined smartphone and smartwatch fall detection system. In *2015 IEEE international conference on computer and information technology; ubiquitous computing and communications; dependable, autonomic and secure computing; pervasive intelligence and computing*, pages 1443–1448. IEEE, 2015.
- [10] Brasil. Envelhecimento e saúde da pessoa idosa/ministério da saúde, secretaria de atenção à saúde, departamento de atenção básica, 2007.
- [11] Paulo AS Duarte, Felipe M Barreto, Paulo AC Aguiar, Jérôme Boudy, Rossana MC Andrade, and Windson Viana. Aal platforms challenges in iot era: a tertiary study. In *2018 13th Annual Conference on System of Systems Engineering (SoSE)*, pages 106–113. IEEE, 2018.
- [12] Luca Mainetti, Luigi Patrono, Andrea Secco, and Ilaria Sergi. An iot-aware aal system for elderly people. In *2016 International multidisciplinary conference on computer and energy science (SpliTech)*, pages 1–6. IEEE, 2016.
- [13] Vincenzo Mighali, Luigi Patrono, Maria Laura Stefanizzi, Joel JPC Rodrigues, and Petar Solic. A smart remote elderly monitoring system based on iot technologies. In *2017 Ninth International Conference on Ubiquitous and Future Networks (ICUFN)*, pages 43–48. IEEE, 2017.
- [14] Matheus Costa Stutzel, Michel Fillipo, Alexandre Sztajnberg, André Brittes, and Luciana Branco da Motta. Smai-mobile system for elderly monitoring. In *2016 IEEE International Conference on Serious Games and Applications for Health (SeGAH)*, pages 1–8. IEEE, 2016.
- [15] Yves M Galvão, Vinicius A Albuquerque, Bruno JT Fernandes, and Mèuser JS Valença. Anomaly detection in smart houses: Monitoring elderly daily behavior for fall detecting. In *2017 IEEE Latin American Conference on Computational Intelligence (LA-CCL)*, pages 1–6. IEEE, 2017.
- [16] Koray Ozcan and Senem Velipasalar. Wearable camera-and accelerometer-based fall detection on portable devices. *IEEE Embedded Systems Letters*, 8(1):6–9, 2015.
- [17] Taiuani Marquine Raymundo and Carla da Silva Santana. Factors influencing the acceptance of technology by older people: How the elderly in brazil feel about using electronics. *IEEE Consumer Electronics Magazine*, 3(4):63–68, 2014.
- [18] Rainer Lutze and Klemens Waldhör. A smartwatch software architecture for health hazard handling for elderly people. In *2015 International conference on healthcare informatics*, pages 356–361. IEEE, 2015.
- [19] Francisco Paulo do NASCIMENTO. Classificação da pesquisa. natureza, método ou abordagem metodológica, objetivos e procedimentos. *Metodologia da Pesquisa Científica: teoria e prática—como elaborar TCC. Brasília: Thesaurus*, 2016.
- [20] Eva Maria Lakatos and Marina de Andrade Marconi. Metodologia científica. In *Metodologia científica*, pages 231–231. 1986.
- [21] Antonio Carlos Gil et al. *Como elaborar projetos de pesquisa*, volume 4. Atlas São Paulo, 2002.
- [22] Mauro José Fontelles, Marilda Garcia Simões, Samantha Hasegawa Farias, and Renata Garcia Simões Fontelles. Metodologia da pesquisa científica: diretrizes para a elaboração de um protocolo de pesquisa. *Revista paraense de medicina*, 23(3):1–8, 2009.
- [23] Panagiotis Kostopoulos, Tiago Nunes, Kevin Salvi, Michel Deriaz, and Julien Torrent. F2d: A fall detection system tested with real data from daily life of elderly people. In *2015 17th International Conference on E-health Networking, Application & Services (HealthCom)*, pages 397–403. IEEE, 2015.
- [24] Lourdes Martínez-Villaseñor, Hiram Ponce, Jorge Brievea, Ernesto Moya-Albor, José Núñez-Martínez, and Carlos Peñafor-Asturiano. Up-fall detection dataset: A multimodal approach. *Sensors*, 19(9):1988, 2019.
- [25] Kevin P Murphy. *Machine learning: a probabilistic perspective*. MIT press, 2012.