

UCS - Universidade de Caxias do Sul

Cesar Luiz Buzin Júnior

SDQI: Sistema de Detecção de Quedas de Idosos

Caxias do Sul

2016

UCS - Universidade de Caxias do Sul
Centro de Ciências Exatas e da Tecnologia – CCET

Cesar Luiz Buzin Júnior

SDQI: Sistema de Detecção de Quedas de Idosos

Trabalho de Conclusão do Curso de Bacharelado em Ciência da
Computação pela Universidade de Caxias do Sul.
Área de concentração: Computação.
Orientador: Prof. Dr. André Gustavo Adami

Caxias do Sul

2016

Cesar Luiz Buzin Júnior

SDQI: Sistema de Detecção de Quedas de Idosos

Trabalho de Conclusão do Curso de Bacharelado em Ciência da
Computação pela Universidade de Caxias do Sul.
Área de concentração: Computação.
Orientador: Prof. Dr. André Gustavo Adami.

Aprovado em __/__/__

Banca Examinadora

Prof. Dr. André Gustavo Adami
Universidade de Caxias do Sul-UCS

Prof. Dr. André Luiz Martinotto
Universidade de Caxias do Sul-UCS

Prof. Dr. André Zampieri
Universidade de Caxias do Sul-UCS

AGRADECIMENTOS

Perante a conclusão do meu trabalho de conclusão, gostaria de realizar os seguintes agradecimentos:

- Ao meu orientador, André Gustavo Adami, por ter dedicado horas do seu tempo prestando orientações e conselhos que se tornaram essenciais para realização desse trabalho;
- A minha namorada, pelo apoio, ajuda e compreensão perante as horas que dediquei a esse trabalho;
- A minha família, também pela compreensão e o apoio prestados.

RESUMO

As quedas sofridas por idosos tem sido um problema nos últimos tempos, principalmente para o estudo da geriatria. Um dos principais problemas dessas quedas é a falta de socorro posterior ao momento do acidente, no qual o idoso pode permanecer sem ajuda por minutos, horas ou mesmo dias. Esse tempo representa um grave risco para o indivíduo se ele não puder chamar socorro por si só, pelos mais diversos motivos (ficar inconsciente, perder a capacidade de movimentação e locomoção, etc).

Esse trabalho propõe uma solução que realiza o chamado automático por ajuda em situações de queda de idosos. A solução é um sistema para *smartphones*, que utiliza o acelerômetro presente na maioria dos *smartphones* que circulam no mercado. O sistema é responsável por detectar quedas ocorridas pelo indivíduo que estiver carregando um *smartphone* e, assim que essa situação ocorrer, emitir alertas para os destinatários desejados.

Para detecção automatizada das quedas, foi desenvolvido um detector de quedas baseado em quatro classificadores: de quedas por inatividade, por árvores de decisão, por limiares e por orientação do dispositivo. Adaptando esses classificadores em um único algoritmo, buscou-se obter uma boa precisão no processo de detecção. Para desenvolver esse algoritmo e avaliar os resultados obtidos, foram utilizadas três bases de dados: MobiFall, MobiFall2 e uma base própria desenvolvida por esse trabalho. Essas bases contém amostras de simulações de quedas e de AVDs. Assim, os resultados dos testes avaliaram a capacidade de diferenciar as amostras de quedas das amostras de AVDs. Os resultados finais apresentaram 87,65% de especificidade e 95,45% de sensibilidade, precisão próxima ou superior quando comparados aos trabalhos relacionados, demonstrando a eficiência da metodologia abordada.

Palavras-chave: Detecção de padrões. Quedas. Idosos. Acelerômetro. *Smartphone*.

LISTA DE GRÁFICOS

Gráfico 1 - Número de pessoas com 60 anos ou mais em escala mundial.....	17
Gráfico 2 - Percentual da população brasileira com 60 anos ou mais.....	18
Gráfico 3 - Média de filhos por mulher em âmbito nacional e internacional.	19
Gráfico 4 - Expectativa de vida da população em âmbitos nacional e internacional.....	20
Gráfico 5 - Taxa de atividade por idade entre os anos 2000 e 2010.....	21
Gráfico 6 - Comparativo dos idosos em atividade entre o Brasil e o Mundo. ...	23
Gráfico 7 - Taxas de analfabetismo no ano de 2010.....	24
Gráfico 8 - Densidade Espectral de Potência da aceleração linear.....	86
Gráfico 9 - Desempenho do Detector de Quedas.	89
Gráfico 11 – Desempenho do Classificador de Quedas baseado no Detector de Inatividades.	90
Gráfico 12 – Desempenho do Classificador de Quedas Baseado em Limiares.	91
Gráfico 13 – Desempenho do Classificador de Quedas por Orientação.	92
Gráfico 14 – Desempenho do Classificador de Quedas por Árvores de Decisão.	94

LISTA DE FIGURAS

Figura 1 - Processo básico dos detectores de quedas.....	33
Figura 2 - Padrão de classificação.	34
Figura 3 - As quatro fases do evento de queda.....	37
Figura 4 - A hierarquia de abordagens e classes de métodos de detecção de quedas para idosos e pacientes.	42
Figura 5 - Cenário para um detector de acidentes de queda com smartphone de bolso.....	44
Figura 6 - Um smartphone Android preso ao cinto.....	46
Figura 7 - A ilustração mostra a eficiência do acompanhamento durante a queda.	47
Figura 8 - Componentes do sistema Vigi'Fall.	48
Figura 9 - HomeSafe (Landline) da linha de produtos Lifeline, da Philips.	49
Figura 10 - Os dez melhores detectores de quedas de 2016.....	50
Figura 11 - Coordenadas do acelerômetro tri axial.	53
Figura 12 - Dados de aceleração reais (linhas coloridas) e filtrados (linhas pretas).	55
Figura 13 - Representação de estágios de queda sobre um exemplo representativo da magnitude do filtro passa-baixo de sinal de aceleração para um evento de queda.....	55
Figura 14 - Nomenclatura dos movimentos de troca de orientação.	57
Figura 15 - Segmentação dos dados em janelas de 128 amostras com 50% de sobreposição.....	58
Figura 16 - Padrão para detecção de queda utilizando os dados fornecidos pelo acelerômetro.	60
Figura 17 - Detalhe da detecção da queda.	60
Figura 18 - Exemplo de árvore de decisão para um processo de empréstimo.	70
Figura 19 - Fluxo de execução da detecção de quedas.	72
Figura 20 - Exemplo de janela de dados durante a execução.....	73
Figura 21 - Exemplo de detecção de inatividade.....	75
Figura 22 - Exemplo de árvore de decisão montada pelo algoritmo J48.....	77
Figura 23 - Árvore de decisão gerada pelo algoritmo J48 com todos os testes de todas as bases de dados utilizadas.....	78

Figura 24 - Exemplo de queda e marcação dos limites de aceleração linear para detecção de quedas.	79
Figura 25 - Valores de aceleração de cada eixo para diferentes posições.	81
Figura 26 - Exemplo de comportamento de <i>ayt</i> em situação de queda.....	82
Figura 27 - Exemplo de comportamento de <i>ayt</i> em situação de queda onde a posição resultante do dispositivo foi levemente inclinado na horizontal.....	83
Figura 28 - AVD com <i>ayt</i> semelhantes às de uma queda.....	84
Figura 29 - Exemplo de seleção de dados para base de treinamento da árvore de decisão para uma base.	93
Figura 30 - Exemplo de seleção de dados para base de treinamento da árvore de decisão para mais de uma base.....	94
Figura 31 - Estrutura básica da aplicação em dois projetos.....	97
Figura 32 - Dispositivo utilizado na captura de dados para montagem da base de dados SDQI adaptado a um cinto.	98
Figura 33 – Exemplo de notificação exibida em tela.	99
Figura 34 - Tela de queda detectada	100
Figura 35 - Fluxograma do processo de emissão de alertas.....	102
Figura 36 - Detalhamento do uso da bateria no <i>smartphone</i> com Android 6.0.	104

LISTA DE TABELAS

Tabela 1 - Matriz de Confusão.	39
Tabela 2 - Medidas de desempenho derivadas da matriz de confusão 2x2; P=TP+FN ; N=FP+TN.	40
Tabela 3 - Testes e resultados de trabalhos com detecção por limiares.....	62
Tabela 4 - Testes e resultados de trabalhos com detecção por aprendizado de máquina.....	66
Tabela 5 - Situações simuladas pela base de dados MobiFall.....	85
Tabela 6 - Situações simuladas pela base de dados própria.	87
Tabela 7 - Voluntários da base de dados própria.....	88
Tabela 8 – Acurácias de todos os classificadores de detecção de quedas por base de dados. A última coluna apresenta o desempenho do sistema utilizando todos os classificadores	90
Tabela 9 – Comparativo entre os resultados apresentados por Pediadtis et al. (2013) e pelo detector de quedas apresentado.....	95
Tabela 10 - Resultados apresentados por Figueiredo e Leal (2016).....	96

LISTA DE ABREVIATURAS E SIGLAS

SUS	Sistema Único de Saúde
IBGE	Instituto Brasileiro de Geografia e Estatística
IDC	<i>International Data Corporation</i>
AVD	Atividade de Vida Diária
IMC	Índice de Massa Corporal
mAh	Miliampere-hora
mV	Millivolt
g	Força-G
G	Aceleração da Gravidade
m/s ²	Metros por Segundo ao Quadrado
APP	Aplicativo
FP	Falso Positivo
GPS	Sistema de Posicionamento Global (<i>Global Positioning System</i>)
SMS	Serviço de Mensagens Curtas (<i>Short Message Service</i>)
3G	Terceira geração de padrões e tecnologias de telefonia móvel
4G	Quarta geração de padrões e tecnologias de telefonia móvel
IDE	Ambiente de Desenvolvimento Integrado (<i>Integrated Development Environment</i>)
JDK	Kit de Desenvolviemnto Java (<i>Java Development Kit</i>)
GHz	Gigahertz
RAM	Memória de Acesso Aleatório (<i>Random Access Memory</i>)

SUMÁRIO

1	Introdução.....	13
1.1	Estrutura.....	15
2	A População Idosa na Sociedade Atual.....	16
2.1	Evolução da População Idosa.....	16
2.2	Motivos do Rápido Envelhecimento Populacional.....	18
2.3	Alterações na Participação do Mercado de Trabalho.....	20
2.4	Taxas de Analfabetismo.....	23
2.5	Responsabilidade por Domicílios.....	24
2.6	Distribuição de Idosos nas Zonas Urbanas e Rurais.....	25
3	As Quedas Sofridas Pela População Idosa.....	26
3.1	Custos e Internações Decorrentes de Quedas.....	26
3.2	Consequências das Quedas.....	27
3.3	Causas das Quedas.....	29
3.3.1	Fatores Intrínsecos.....	30
3.3.2	Fatores Extrínsecos.....	31
4	Sistema de Detecção de Quedas para Idosos.....	33
4.1	Estrutura Básica dos Detectores de Quedas.....	33
4.2	Caracterização de Quedas.....	35
4.2.1	Tipos de Quedas.....	35
4.2.2	Fases do Evento de Queda.....	36
4.3	Medição de Qualidade.....	38
4.3.1	Aceitação do Dispositivo.....	41
4.4	Tipos de Detectores de Quedas.....	41
4.4.1	Dispositivos Vestíveis.....	42
4.4.2	Dispositivos Baseados em Câmeras.....	45

4.4.3	Dispositivos de Ambiente	47
4.5	Detectores Disponíveis no Mercado.....	48
5	Metodologia para Detecção de Quedas via Acelerômetro Tri Axial	52
5.1	O Sensor e os Dados Retornados.....	52
5.2	Seleção de Características	53
5.3	Classificadores.....	58
5.3.1	Limiares	58
5.3.2	Aprendizado de Máquina.....	65
6	Metodologia	71
6.1	Sistema de Detecção de Quedas.....	71
6.1.1	Seletor de Características	73
6.1.2	Detector de Inatividade.....	74
6.1.3	Classificador de Quedas por Árvore de Decisão	75
6.1.4	Classificador de Quedas Baseado em Limiares	79
6.1.5	Classificador por Orientação.....	80
6.2	Bases de Dados.....	84
6.2.1	MobiFall	84
6.2.2	MobiFall 2	86
6.2.3	Base própria	87
6.3	Experimentos e Resultados	88
6.3.1	Resultados do Classificador de Quedas por Inatividade	90
6.3.1	Resultados do Classificador de Quedas por Limiares	91
6.3.2	Resultados do Classificador de Quedas por Orientação	92
6.3.3	Resultados do Classificador de Quedas por Árvores de Decisão. 92	
6.3.4	Trabalhos relacionados com as bases de dados utilizadas	95
6.4	Aplicativo de Detecção de Quedas para Smartphone.....	96
6.4.1	Interface Gráfica e Configurações	98

6.4.2	Emissão de Alertas.....	101
6.4.3	Testes de consumo de bateria.....	103
7	Conclusões.....	105
	Referências.....	107

1 INTRODUÇÃO

Nos últimos anos, a população vem envelhecendo rapidamente, graças à diminuição da fecundidade e ao aumento da expectativa de vida que vem ocorrendo. Segundo dados do IBGE, nas décadas de 1950 e 1960, a taxa de fecundidade era de aproximadamente 6,20 filhos por mulher, taxa que passou para 1,77 filhos até 2013. Entre os anos de 1980 e 2009, a expectativa de vida dos brasileiros teve um acréscimo de 10,60 anos, sendo que no ano de 2009 estava em 73,17 anos. No ano de 2000, quase 15 milhões de pessoas estavam com 60 anos ou mais de idade (8,6% da população brasileira). Desses quase 15 milhões de idosos, 17,9% moravam sozinhos em suas residências. No censo demográfico de 2010, verificou-se que 20,6 milhões de pessoas (10,8% da população brasileira) estavam com 60 anos ou mais de idade. Ainda assim, a expectativa é de que até o ano de 2050, um quinto da população mundial seja de idosos.

Com o aumento da expectativa de vida, acidentes envolvendo idosos tornam-se cada vez mais recorrentes. Cerca de 30% dos idosos com 65 anos ou mais sofrem uma ou mais quedas ao ano, as quais representam dois terços das mortes acidentais sofridas por idosos (Almeida, Brites, & Takizawa, 2011). Isso é um índice considerável para saúde pública, logo que o SUS registra mais de 51 milhões de reais gastos com tratamentos de fraturas decorrentes de quedas por ano (Portal Brasil, 2012).

Com base nas informações descritas até agora, pode-se imaginar o seguinte cenário: grande parte da população com idade igual ou superior a 60 anos, vivendo sozinha em sua residência, correndo o risco de sofrer uma queda e não ser socorrida por um longo período, cujo qual pode ser crucial caso a vítima tenha sofrido alguma fratura ou traumatismo, permanecendo até mesmo desacordada por horas. Esse cenário faz parte de um tema que tem preocupado pesquisadores, além de ser muito valorizado pela gerontologia (Coelho Fabrício, Rodrigues, & Costa Junior, 2004). Com base neste cenário, nota-se a importância de um sistema de monitoramento em tempo real para pessoas que

se encaixam no cenário citado acima, que chame por socorro e/ou emita algum alerta para um responsável assim que identificada uma queda. A detecção automática representa a principal funcionalidade desse sistema, pois não seria necessária a tomada de ação do sujeito que estiver sendo monitorado, logo que esse pode não ser capaz de realizar uma determinada ação para informar que sofreu uma queda (como por exemplo apertar um botão de um dispositivo).

Existem diversas pesquisas que buscam encontrar meios para a detecção automática de quedas sofridas por idosos. Amiri, Pourazad et al. (2014) apresenta um projeto de casa inteligente, com monitoramento através de câmeras e o detector de movimentos Kinect da Microsoft para cada cômodo. O problema desse método é a necessidade de recursos em cada cômodo, o que o torna caro e limita o monitoramento em apenas alguns ambientes. Também existem soluções que propõem o uso de acelerômetros através de dispositivos desenvolvidos especificamente para detecção de queda (Barbosa, Ramíres, & Goroso, 2013), (Bloch, et al., 2011). Embora seja mais eficaz do que o monitoramento de ambiente proposto anteriormente, esse ainda necessita de desenvolvimento de hardware específico. Uma das soluções mais baratas e acessíveis, a qual será foco do trabalho aqui proposto, é a detecção de quedas utilizando o acelerômetro tri-axial presente em *smartphones*, conforme apresentado por Sabadini, Bezerra, et al. (2014).

Com base nos estudos já realizados e nas necessidades apresentadas pela atual e futura população, esse trabalho visa a criação de um sistema simples e acessível de detecção de quedas voltado para idosos. O sistema tem o propósito de identificar quedas sofridas pelo usuário em tempo real com a maior taxa de acerto possível, através de um *smartphone* portado pelo mesmo. Com isso, não é necessária a interação desse usuário com o dispositivo para que as quedas sejam identificadas.

A identificação das quedas é realizada através da análise dos sinais emitidos pelo acelerômetro tri-axial presente nos *smartphones*. Como esse sensor retorna pontos x, y e z com uma determinada periodicidade (que depende da precisão do acelerômetro), é possível calcular a aceleração linear do dispositivo assim que ele é movimentado. Dessa forma, analisando as alterações

da aceleração, é possível filtrar os pontos lidos de modo a identificar padrões nessas alterações, detectando quaisquer eventuais quedas sofridas pelos portadores do *smartphone* em que o sistema estará sendo executado. Ao detectar uma queda, o sistema emite alertas através dos meios de comunicação (e-mail, SMS...) disponibilizados pelo dispositivo. Através do uso desses alertas automatizados, responsáveis previamente cadastrados serão notificados.

O software foi desenvolvido para sistemas operacionais Android, atualmente o sistema predominante em 82,8% dos *smartphones* disponíveis no mercado (IDC - International Data Corporation, 2015). Apesar disso, o detector de quedas desenvolvido poderá ser utilizado em quaisquer outros sistemas operacionais, desde que o seja integrado a um sistema compatível.

1.1 ESTRUTURA

O trabalho está dividido em seis capítulos. O Capítulo 2 detalha os indicadores sobre a população para a qual a solução aqui apresentada será criada, a população idosa. No Capítulo 3, as quedas sofridas pelos idosos são analisadas e definidas. No Capítulo 4, sistemas relacionados à detecção de quedas são analisados e discriminados por categorias, seguindo para a metodologia utilizada pelos detectores de quedas baseados em acelerômetros no Capítulo 5. Por fim, o Capítulo 6 apresenta a proposta de solução definida por esse trabalho e o Capítulo 7 as considerações finais.

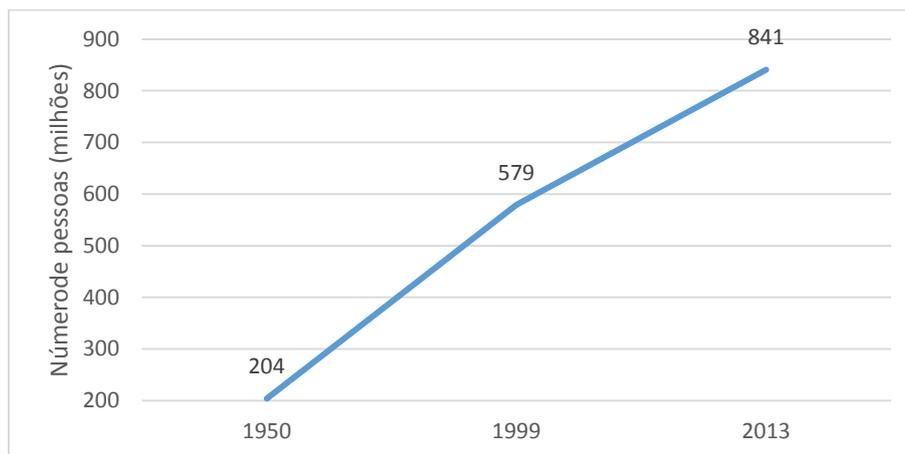
2 A POPULAÇÃO IDOSA NA SOCIEDADE ATUAL

Esse trabalho consiste em apresentar uma solução para detecção de quedas voltada para um público específico, a população idosa, de modo que é importante ter conhecimento sobre a sua atuação na sociedade. Esse capítulo irá caracterizar a população em seis seções. A Seção 2.1 mostra a evolução da população idosa no Brasil e no mundo. A Seção 2.2 trata dos motivos do rápido envelhecimento populacional. A Seção 2.3 descreve as alterações na participação dos idosos no mercado de trabalho. A Seção 2.4 mostra as taxas de analfabetismo nesta população. A Seção 2.5 mostra a parcela da população idosa responsável por manter domicílios. Finalmente, a Seção 2.6 mostra como está a distribuição dos idosos nas zonas urbanas e rurais. Todas as seções têm por objetivo demonstrar a atual realidade da população idosa, como ela atua e qual o seu papel na sociedade atual.

2.1 EVOLUÇÃO DA POPULAÇÃO IDOSA

Nos últimos anos, a quantidade de idosos no mundo vem crescendo rapidamente. Por cinco décadas, houve um crescimento de quase 8 milhões de anciãos por ano na população mundial. Em 1950 existiam aproximadamente 204 milhões de idosos, chegando aos 579 milhões no ano de 1998. Era estimada uma escala de um indivíduo com 60 anos ou mais para cada 10 no final da década de 90. Ainda no ano de 1999, eram 145.000 centenários presentes no mundo todo (IBGE - Instituto Brasileiro de Geografia e Estatística, 2002). Em levantamentos mais recentes, verificou-se que no ano de 2013, existiam cerca de 841 milhões de idosos no mundo (Department of Economic and Social Affairs, 2013). A evolução da população idosa (60 anos ou mais) é ilustrada no Gráfico 1.

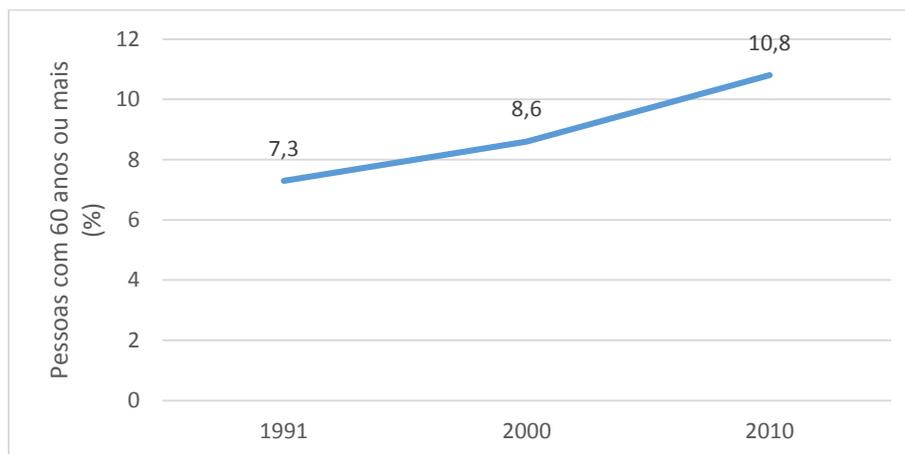
Gráfico 1 - Número de pessoas com 60 anos ou mais em escala mundial.



Fontes: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2002) e DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS (2013).

O Brasil ainda é uma nação onde a maioria da população é constituída por jovens, mas ao mesmo tempo tem seu envelhecimento populacional cada vez mais presente. Conforme o último censo demográfico realizado em 2010, a população brasileira com 60 anos ou mais chegou a 20,6 milhões de pessoas nesse mesmo ano, volume que representa 10,8% da população total do país. No ano de 1991, esse percentual estava em 7,3%, progredindo para 8,6% em 2000 e chegando a 10,8% em 2010, conforme demonstrado no Gráfico 2 (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014). Logo, entre os anos de 1991 e 2010, o país alcançou um aumento de 3,5% no percentual da população nessa faixa etária. No ano de 1991, o número de idosos com 100 ou mais anos era 13.865, passando para 24.576 no ano de 2000 (IBGE - Instituto Brasileiro de Geografia e Estatística, 2002).

Gráfico 2 - Percentual da população brasileira com 60 anos ou mais.

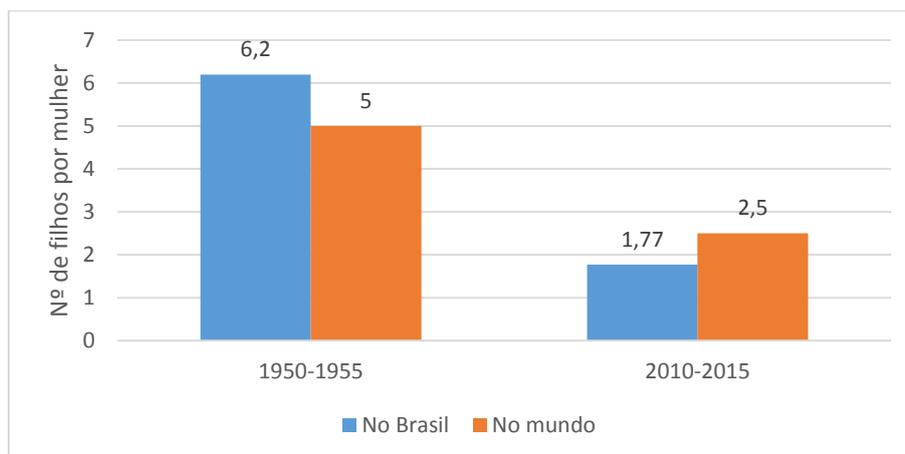


Fonte: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2014).

2.2 MOTIVOS DO RÁPIDO ENVELHECIMENTO POPULACIONAL

O aumento da população idosa mundial deve-se principalmente a dois fatores: queda do nível de fecundidade e aumento da expectativa de vida. Segundo mensurado pelo censo nacional, a média foi de 1,77 filhos por mulher no ano de 2013, quantidade muito inferior à de 6,20 filhos que estava presente entre os anos de 1950 e 1960. O número de mulheres com idade superior a 20 anos que possuíam ao menos um filho também decresceu entre os anos de 2000 e 2010. A proporção de crianças com idade inferior a 14 anos era de 34,7% no ano de 1991, baixando para 24,1% em 2010 (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014). Em menor escala, a fertilidade no mundo também diminuiu. Entre os anos de 1950 e 1955 a média era de 5 filhos por mulher, passando para estimativa de 2,5 filhos por mulher entre 2010 e 2015 (Department of Economic and Social Affairs, 2013). O Gráfico 3 mostra um comparativo entre o declínio de fecundidade nacional e internacional. Note que esses declínios são levantamentos de dados de todas as regiões onde as pesquisas foram realizadas. Deve-se observar que o nível de fertilidade varia entre diferentes regiões, dependendo do nível de desenvolvimento dessas.

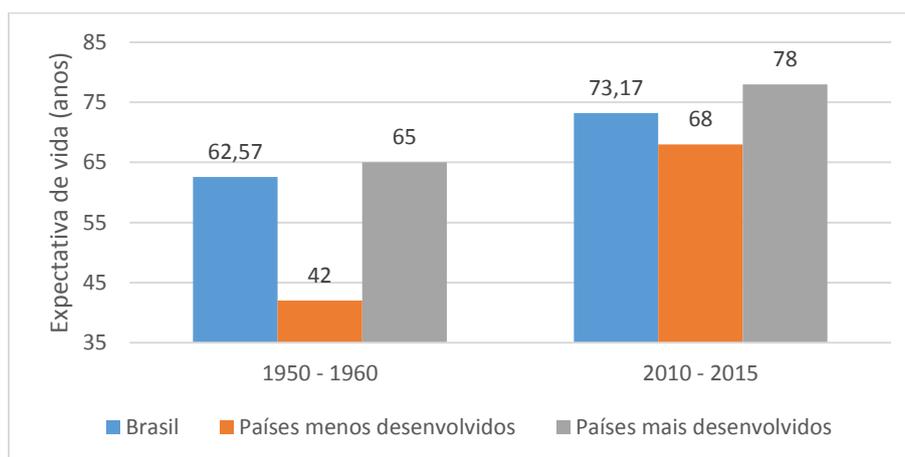
Gráfico 3 - Média de filhos por mulher em âmbito nacional e internacional.



Fontes: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2014) e DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS (2013).

Apesar da queda de fertilidade ser um dos principais fatores do aumento da população idosa, a expectativa de vida é outro fator de grande relevância. O Brasil teve um incremento anual de 4 meses e 12 dias na expectativa de vida durante 29 anos. Entre os anos de 1980 e 2009, a expectativa de vida dos brasileiros teve um acréscimo de 10,60 anos, sendo que no ano de 2009 estava em 73,17. Foi apenas a partir do ano de 2000 que a expectativa de vida do brasileiro passou a ser superior aos 70 anos de idade (IBGE – Instituto Brasileiro de Geografia e Estatística, 2010). Em nível mundial, a expectativa de vida para as regiões mais desenvolvidas, que era de 65 anos de vida em 1950, passou a ser estimada em 78 anos entre 2010 e 2015. Nas regiões menos desenvolvidas, essa melhoria consiste de 42 anos em 1950 para 68 entre 2010 e 2015 (Department of Economic and Social Affairs, 2013). O Gráfico 4 mostra o aumento de expectativa de vida no Brasil e países menos e mais desenvolvidos.

Gráfico 4 - Expectativa de vida da população em âmbitos nacional e internacional.



Fontes: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2010) e DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS (2013).

Com a finalidade de prever qual será a participação da parcela de idosos no futuro, projeções são realizadas baseadas do histórico de dados e valores já coletados. O aumento da expectativa de vida também ocasiona a elevação do número de idosos. Estima-se que, para o ano de 2050, a expectativa de vida do brasileiro seja de 81,29 anos (IBGE – Instituto Brasileiro de Geografia e Estatística, 2010). No mundo, estima-se que serão 392 milhões de pessoas com 80 anos ou mais em 2050 (Department of Economic and Social Affairs, 2013). No ano 2000, o IBGE relatou que a escala mundial era de um idoso para cada 10 habitantes, sendo que nos próximos 50 anos avançaria para um idoso para cada 5 habitantes. Para os locais mais desenvolvidos, essa escala poderia chegar em um idoso a cada três pessoas. É esperado ainda que o número de centenários chegue a 2,2 milhões no ano de 2050, sendo que evoluiu de 13.865 em 1991 para 24.576 nos anos 2000 (IBGE - Instituto Brasileiro de Geografia e Estatística, 2002).

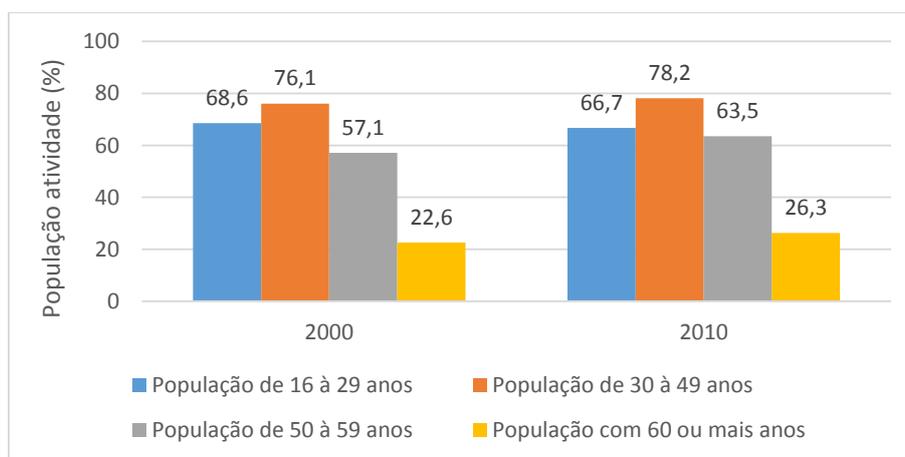
2.3 ALTERAÇÕES NA PARTICIPAÇÃO DO MERCADO DE TRABALHO

Em paralelo ao amadurecimento progressivo da população, ocorre a extensão do período produtivo dessa durante a sua vida. Desde o início do

século, existe um declínio do número de trabalhadores com idade inferior a 30 anos, enquanto as pessoas com idade superior a essa estão se tornando cada vez mais ativas.

Esta alteração demográfica no mercado de trabalho pode ser verificada no Gráfico 5, que traz dados sobre o Brasil. A taxa de atividade da população de 16 a 29 anos diminuiu de 68,6% nos anos 2000 para 66,7% em 2010. A partir dessa parcela da população, a taxa dos indivíduos de 30 a 49 anos subiu de 76,1% para 78,2% nos mesmos anos, a dos indivíduos com idade de 50 a 59, que representam o grupo com maior incremento na participação do mercado de trabalho, subiram de 57,1% para 63,5% e, de 22,6% para 26,3% a população com mais de 60 anos (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014).

Gráfico 5 - Taxa de atividade por idade entre os anos 2000 e 2010.



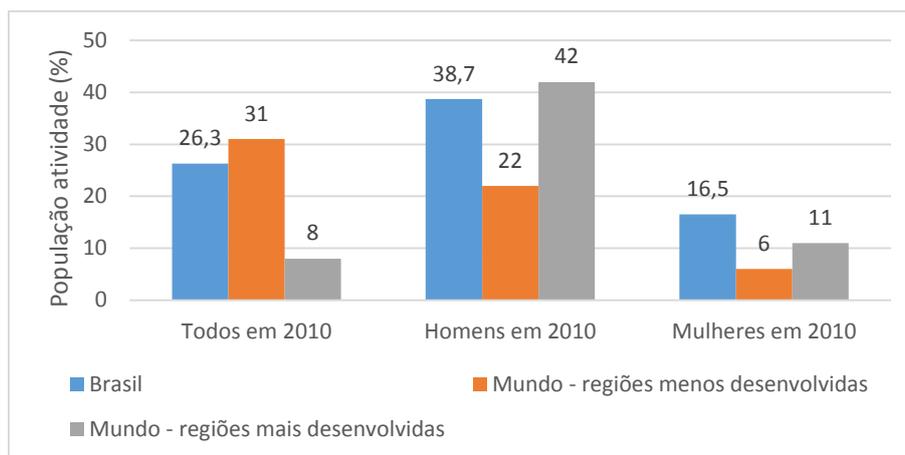
Fonte: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2010).

A necessidade de continuar no mercado de trabalho tem se consolidado, tanto em países desenvolvidos quanto em desenvolvimento. Em 2010, 31% dos idosos das regiões em desenvolvimento com 65 anos ou mais tinham alguma atividade. Nas regiões desenvolvidas esse índice é mais baixo, sendo apenas 8% dos idosos com participação no mercado de trabalho (Department of Economic and Social Affairs, 2013).

O percentual de idosos brasileiros sem rendimento algum ou com apenas um salário mínimo está em, respectivamente, 11,9% e 44,5%. Embora o número de idosos com apenas um salário mínimo seja elevado em comparação com as demais faixas etárias, que são em média 27,3%, esses representam a menor fatia da população sem rendimentos. Das pessoas com 16 a 24 anos, 46,2% não tem rendimento algum, seguidos de 20,8% entre 25 e 39 anos e 21,2% de 40 a 59 anos (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014).

É importante ressaltar a diferenciação entre os sexos na participação do mercado de trabalho. No Brasil, na comparação entre o passar dos anos, em 2000, 37,4% dos homens com 60 anos ou mais tinham participação, contra 10,6% das mulheres. Em 2010, 38,7% dos homens nessa mesma faixa etária tinham atividade, enquanto apenas 16,5% das mulheres tinham. Embora a prevalência de idosos empregados ainda seja masculina, houve uma notável redução no número de mulheres nessa faixa que não possuíam rendimentos. Essas diminuíram de um percentual de 28,7% das últimas décadas para 15,7% em 2010. Porém, mesmo com o aumento da participação da mulher idosa no mercado, elas ainda recebiam apenas 64% do rendimento dos homens. Essa desigualdade tende a ser maior na população mais rica (IBGE – Instituto Brasileiro de Geografia e Estatística, 2010). A diferenciação dos sexos dos idosos no mercado de trabalho também existe fora do Brasil, conforme ilustrado no Gráfico 6. Nas regiões mais desenvolvidas, 42% dos homens idosos trabalham, enquanto apenas 11% das idosas tem atividade remunerada. Nas regiões menos desenvolvidas, 22% dos homens trabalham e apenas 6% das mulheres estão ativas no mercado (Department of Economic and Social Affairs, 2013).

Gráfico 6 - Comparativo dos idosos em atividade entre o Brasil e o Mundo.

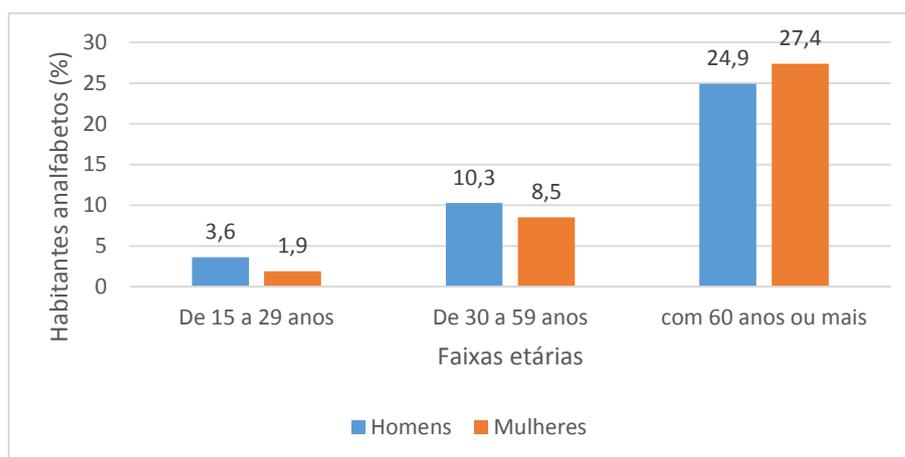


Fontes: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2010) e DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS (2013).

2.4 TAXAS DE ANALFABETISMO

O analfabetismo das pessoas idosas ainda se faz presente na população nacional atual, como mostra o Gráfico 7 (IBGE – Instituto Brasileiro de Geografia e Estatística, 2010). Em 2010, 27,4% das mulheres e 24,9% dos homens não sabiam ler nem escrever. Analisando as demais faixas etárias, pode-se perceber que a taxa de analfabetismo tende a diminuir com envelhecimento da população. A população entre 30 e 59 anos analfabeta é de 10,3% dos homens e de 8,5% das mulheres, seguido pela população de 15 a 29 anos, com 3,6% dos homens e 1,9% das mulheres. Com isso, nota-se também que as mulheres tendem a baixar o índice de analfabetismo mais rápido que os homens.

Gráfico 7 - Taxas de analfabetismo no ano de 2010.



Fonte: IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2014).

2.5 RESPONSABILIDADE POR DOMICÍLIOS

Com o passar dos anos, o número de idosos responsáveis por seus domicílios aumentou, do mesmo modo que os idosos que residiam sozinhos também tiveram um acréscimo. No ano de 2000, dos 44.795.101 domicílios brasileiros, os idosos eram responsáveis por 8.964.850. Com isso, 20% dos domicílios são administrados por eles, ou ainda podemos dizer que 62,4% dos idosos eram responsáveis por seus domicílios. Desses 20% dos domicílios, 17,9% possuíam apenas um morador. Em análises anteriores, no ano de 1991, 18,4% dos domicílios estavam sob responsabilidade de idosos. Nesse mesmo ano, 15,4% dos idosos responsáveis por suas residências moravam sozinhos (IBGE - Instituto Brasileiro de Geografia e Estatística, 2002).

Em nível mundial, os índices são superiores aos brasileiros. Aproximadamente 40% da população idosa vive sozinha, sem diferença significativa entre sexos. Nas regiões mais desenvolvidas, 3/4 dos idosos vivem sozinhos, enquanto apenas 10% das regiões menos desenvolvidas vivem sozinhos (Department of Economic and Social Affairs, 2013).

2.6 DISTRIBUIÇÃO DE IDOSOS NAS ZONAS URBANAS E RURAIS

Atualmente não há grande discrepância entre a distribuição da população brasileira idosa. Em 2010, 10,8% da população residente nas zonas urbanas era constituída por idosos, e 11,0% da população residente nas zonas rurais é constituída por idosos. Apesar da maioria dos idosos ainda residirem na zona rural, o nível de urbanização dessa faixa etária elevou-se de 75,6% em 1991 para 84,4% em 2010 (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014).

É importante notar que as faixas etárias que mais residem nas zonas rurais são de 0 a 14 anos e de 60 anos acima. A população de 15 a 59 anos, em sua maioria, ainda residem na zona urbana (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014).

3 AS QUEDAS SOFRIDAS PELA POPULAÇÃO IDOSA

O aumento da população idosa tem se tornado um assunto de importância considerável, logo que exige maior demanda de serviços voltados para essa parcela da população. São necessárias precauções para que o impacto causado por essa mudança não seja prejudicial para a população em geral, idosa ou não (Lima & Murai, 2005).

Acidentes envolvendo idosos tornam-se cada vez mais recorrentes. Cerca de 30% dos idosos com 65 anos ou mais sofrem uma ou mais quedas por ano, as quais representam dois terços das mortes acidentais sofridas por idosos (Almeida, Brites, & Takizawa, 2011). Prado et al. (2014) explica que não existe uma definição clara sobre queda na literatura, mas define como sendo uma alteração na altura da posição do indivíduo, resultando em um impacto do corpo com algo, podendo esse ser o solo ou mesmo algum objeto, como por exemplo uma cadeira ou poltrona. No próprio ato de sentar-se, uma queda pode ser identificada, dependendo da força que o indivíduo atingir o assento e do impacto causado no atrito. Assim como no ato de sentar, ao se deitar a mesma situação pode ocorrer.

As quedas são consequências naturais do envelhecimento humano. Entre 29% e 30% dos idosos, com 65 anos ou mais, sofrem ao menos uma queda por ano (Ferreira & Yoshitome, 2010) (Maia, Viana, Arantes, & Alencar, 2011). Ferreira e Yoshitome (2010) encontraram prevalência de quedas em 37,2% dos casos estudados.

Este capítulo apresenta as consequências das quedas, seguidas das causas e principais fatores de risco.

3.1 CUSTOS E INTERNAÇÕES DECORRENTES DE QUEDAS

As quedas entre idosos representam um dos principais problemas de saúde pública. Essas são responsáveis por altos custos, não só para atendimentos de quedas, como também para posteriores tratamentos das

consequências causadas (Carvalho & Coutinho, 2002). O Sistema Único de Saúde (SUS), anualmente, registra mais de 51 milhões de reais gastos com tratamentos de fraturas decorrentes de quedas (Portal Brasil, 2012).

As causas externas são traumatismos, lesões ou quaisquer outros agravos à saúde – intencionais ou não – de início súbito e como consequência imediata de violência ou outra causa exógena. Neste grupo, incluem-se as lesões provocadas por eventos no transporte, homicídios, agressões, quedas, afogamentos, envenenamentos, suicídios, queimaduras, lesões por deslizamento ou enchente, e outras ocorrências provocadas por circunstâncias ambientais (mecânica, química, térmica, energia elétrica e/ou radiação) (Gonsaga, et al., 2012).

No ano de 2006 ocorreram 281.324 internações hospitalares decorrentes de quedas, o que corresponde a 42,5% do total de internações (Brasil. Ministério da Saúde, 2009). Segundo Koizumi (2004), em 2000, as causas externas eram as responsáveis por 7,7% das internações do SUS. Nessas, o tempo médio de permanência era de 4,98 dias, tendo um custo médio de 503,70 reais. O custo diário dessas internações era de cerca de 101,23 reais. Conforme Carvalho e Coutinho (2002), o tempo médio de permanência de pacientes que receberam apenas tratamento clínico foi de 10,6 dias, enquanto o tempo para pacientes submetidos a cirurgias foi de 16,2 dias.

3.2 CONSEQUÊNCIAS DAS QUEDAS

As quedas acabam por ocasionar uma série de consequências para os sujeitos que as sofrem, podendo essas serem físicas e/ou psicológicas (Ferreira & Yoshitome, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Maia, Viana, Arantes, & Alencar, 2011) (Almeida, Brites, & Takizawa, 2011).

Ferreira e Yoshitome (2010) salientam que, entre os idosos analisados que sofreram alguma queda, 57,3% tiveram alguma consequência física. Além disso, foram registradas 81 lesões dentro de 66 casos de queda. Algumas consequências decorrentes das quedas incluem trauma de crânio e lesões na cabeça, contusões, subluxações articulares, hemorragias, entorses, cortes,

lacerações, abrasões, lesões neurilógicas, perda de mobilidade, doença sensoriais (visuais e auditivas), infecções, entre outros (Almeida, Brites, & Takizawa, 2011) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008).

Fratura é uma das lesões físicas mais ocasionadas pelas quedas em idosos. Gawryszewski, Mello Jorge e Koizumi (2004) destacam que as fraturas ocuparam 52,8% das consequências por acidentes de causas externas, esses em sua maioria quedas e acidentes de transporte. As fraturas mais comuns são as de colo de fêmur (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008). Coelho Fabrício e Costa Junior (2004) apresentaram em seu estudo, que as fraturas ocuparam 64% das consequências por quedas, sendo que 62% dessas foram no fêmur, seguidas por 12,5% no rádio, 6,25% na clavícula, além das demais menos ocorridas. No estudo realizado por Ribeiro et al. (2008), as fraturas foram consequências em apenas 24,3% das quedas. Ainda assim, dessas fraturas, 33% foram de fêmur.

As quedas podem ocasionar uma série de consequências psicológicas ao indivíduo. Entre essas, a mais referenciada é o medo de sofrer novas quedas (Ferreira & Yoshitome, 2010) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Fhon, et al., 2013). Esse medo de cair novamente acaba por minimizar, quando não erradicar, a confiança de realizar AVDs, principalmente a atividade que estava exercendo quando sofreu a última queda. Essa perda de confiança acaba por exigir mudanças nos hábitos e abandono de atividades, muitas vezes levando indivíduo à dependência de outras pessoas, ou mesmo levando à institucionalização e, conseqüentemente, ao isolamento social. Existe também a defesa da ideia de que o medo é um fator positivo, já que diminui a confiança do idoso, forçando esse a ser mais cauteloso (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008).

Uma das mais graves consequências das quedas é a falta do devido socorro prestado no pós-queda. Dependendo do dano sofrido pelo idoso ao cair, esse pode não ser capaz de chamar socorro por si só, de maneira que se estiver

sozinho pode passar por horas, senão dias sem ser socorrido. Almeida et al. (2011) salienta o fato dos idosos que sofrem quedas não conseguirem se levantar sem auxílio, e atenta que esses podem sofrer desidratação, pneumonia, úlceras de decúbito e rabdomiólise.

As mortes se fazem presentes em uma considerável parcela dos casos. Quando citadas as mortes, essas podem não ter ocorrido no momento da queda, mas posteriormente, em decorrência dos traumas ocasionados ao cair (Almeida, Brites, & Takizawa, 2011) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Gawryszewski, Mello Jorge, & Koizumi, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008). Apenas no estado de São Paulo, no ano de 2007, foram mais de 1.300 mortes decorrentes de quedas (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010). Segundo o estudo realizado por Coelho (2004), 28% dos casos de quedas terminaram levando as vítimas ao óbito. Gawryszewski et al. (2004) mostra que o índice de mortes hospitalares, decorrente às quedas sofridas por idosos, é de 5,2/100 casos.

3.3 CAUSAS DAS QUEDAS

Os fatores que ocasionam as quedas podem ser divididos em duas categorias: intrínsecos e extrínsecos. Os fatores intrínsecos são provenientes do envelhecimento natural, como fraqueza muscular, tontura, consequências do uso de medicamentos e vertigem. Os fatores extrínsecos tem origem exterior ao indivíduo, estão relacionados ao meio ambiente e às atividades praticadas nesse, tais como pisos mal conservados e calçados escorregadios (Almeida, Brites, & Takizawa, 2011) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008) (Maia, Viana, Arantes, & Alencar, 2011).

3.3.1 Fatores Intrínsecos

Uma das principais causas das quedas é a dependência parcial para realização das AVDs, ou seja, quando o idoso ainda consegue realizar sozinho algumas tarefas, mas não todas. Ao contrário da dependência total, a dependência parcial proporciona ao idoso a confiança para realização das atividades, o que representa risco ao não tomar as precauções necessárias (Ferreira & Yoshitome, 2010) (Fhon, et al., 2013) (Carvalho & Coutinho, 2002) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004). Esses dados condizem com a idade em que os indivíduos mais sofrem quedas, que é de aproximadamente 80 anos ou mais (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Fhon, et al., 2013) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Varas-Fabra, et al., 2006).

A presença de doenças provenientes da idade avançada também representa fator de risco, logo que essas doenças causam alguns distúrbios no organismo que podem ocasionar uma queda. Algumas destas doenças são osteoporose, pressão arterial, depressão, doenças cardiovasculares e osteomusculares (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008) (Carvalho & Coutinho, 2002). A presença de doenças também acaba levando ao uso de medicamentos para combater seus sintomas, os quais representam mais uma das causas de quedas (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Carvalho & Coutinho, 2002) (Varas-Fabra, et al., 2006) (Ferreira & Yoshitome, 2010) (Gawryszewski, Mello Jorge, & Koizumi, 2004) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008).

Obesidade, níveis muito baixos de IMC, perda de força, dificuldade de caminhar e demência são responsáveis por grande parte das quedas registradas. O sedentarismo também é um fator intrínseco, logo que a atividade física tem se mostrado eficaz para fortalecimento do corpo e, conseqüentemente, diminuição dos acidentes envolvendo quedas (Almeida, Brites, & Takizawa,

2011) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Fhon, et al., 2013) (Gawryszewski, Mello Jorge, & Koizumi, 2004) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Carvalho & Coutinho, 2002) (Varas-Fabra, et al., 2006) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008).

A diminuição das habilidades sensoriais, tais como visão, audição e equilíbrio se mostram responsáveis por dificultar as AVDs mais simples do dia-a-dia, tornando o idoso vulnerável a quedas (Almeida, Brites, & Takizawa, 2011) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Gawryszewski, Mello Jorge, & Koizumi, 2004) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008).

O sexo feminino tem se mostrado mais vulnerável à quedas, logo que apresenta algumas fragilidades quando comparado com o sexo masculino, tais como maior incidência de casos de osteoporose, menor força muscular e menor massa magra (Almeida, Brites, & Takizawa, 2011) (Lojudice, Laprega, Rodrigues, & Rodrigues Júnior, 2010) (Ferreira & Yoshitome, 2010) (Gawryszewski, Mello Jorge, & Koizumi, 2004) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Varas-Fabra, et al., 2006). Além disso, as mulheres têm expectativa de vida superior ao sexo masculino, logo que no ano de 2010 existiam 96 homens para cada 100 mulheres (IBGE - Instituto Brasileiro de Geografia e Estatística, 2014).

Concluindo, é constatado que o idoso que já sofreu quedas está mais propício a sofrer novas quedas, logo que essas se tornam um risco presente na sua rotina (Ferreira & Yoshitome, 2010) (Ricci, Gonçalves, Coimbra, & Coimbra, 2010) (Carvalho & Coutinho, 2002).

3.3.2 Fatores Extrínsecos

Dos fatores extrínsecos, o mais citado foi a situação dos pisos e os objetos que neles se encontram. Escorregões são comuns em pisos lisos, além de ocorrerem também por objetos soltos no piso, tais como tapetes e calçados. Esses escorregões também podem ser ocasionados pelo tipo do calçado,

geralmente chinelos ou pantufas, logo que idosos que utilizam calçados fechados ou bem presos tem menos probabilidade de cair. Pisos irregulares e degraus também são fatores de risco, logo que podem ocasionar tropiques. Devido a esses fatores, os locais onde mais ocorrem queda são nos dormitórios e nos banheiros, seguidos das ruas e calçadas (Fhon, et al., 2013) (Carvalho & Coutinho, 2002) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004) (Ribeiro, Souza, Atie, Souza, & Schilithz, 2008). A qualidade e a situação dos pisos serem responsáveis por quedas comprovam outra informação: a maioria dos tombos de idosos ocorre da sua própria altura e na realização de simples AVDs (Ferreira & Yoshitome, 2010) (Coelho Fabrício, Rodrigues, & Costa Junior, 2004).

Outro fato encontrado é que idosos institucionalizados (internados em alguma instituição para que recebam os auxílios necessários para realização de suas atividades) são mais vulneráveis a quedas. Isso ocorre porque eles passam pela troca de ambiente da sua residência para o da instituição, além de sofrer por mudanças psicológicas e de suas AVDs (Almeida, Brites, & Takizawa, 2011) (Ferreira & Yoshitome, 2010).

Quanto ao horário, a manhã é o horário quando mais ocorrem quedas. Seguido desse, os horários posteriores são a tarde e à noite. A madrugada é menos propícia a acidentes, logo que é o horário quando os idosos realizam menos, em sua maioria nenhuma, atividades (Ferreira & Yoshitome, 2010) (Carvalho & Coutinho, 2002).

4 SISTEMA DE DETECÇÃO DE QUEDAS PARA IDOSOS

Soluções para detecção automática de quedas vêm sendo desenvolvidas nos últimos tempos como alternativas para as consequências sofridas por esse tipo de acidente. Tais soluções ganham cada vez mais importância devido a situação em que a população se encontra: grande parte constituída por indivíduos idosos, ativos e independentes.

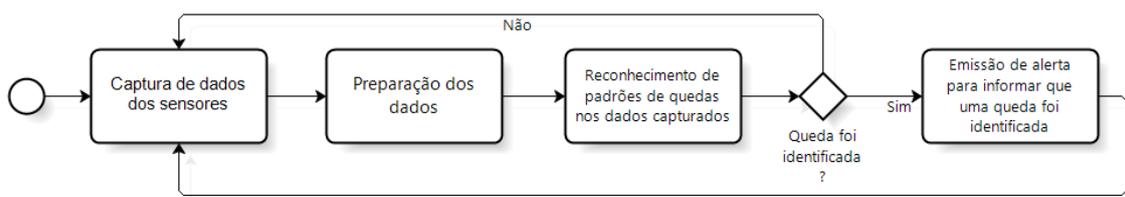
Nesse capítulo serão abordados os diferentes sistemas de detecção de quedas existentes. Para isso, a estrutura e as medições de qualidade desses sistemas serão apresentadas. Além disso, será apresentada a caracterização das quedas e os detectores disponíveis no mercado.

4.1 ESTRUTURA BÁSICA DOS DETECTORES DE QUEDAS

Existem diferentes propostas de soluções, mas todas compartilham algumas características semelhantes, conforme ilustrado na Figura 1:

- Captura de dados do ambiente ou do indivíduo monitorado através de sensores;
- Preparação dos dados para o reconhecimento de padrões;
- Reconhecimento de padrões de quedas nos dados capturados;
- Em caso de queda detectada, emissão de alertas para informar alguém de que o idoso sofreu uma queda.

Figura 1 - Processo básico dos detectores de quedas.

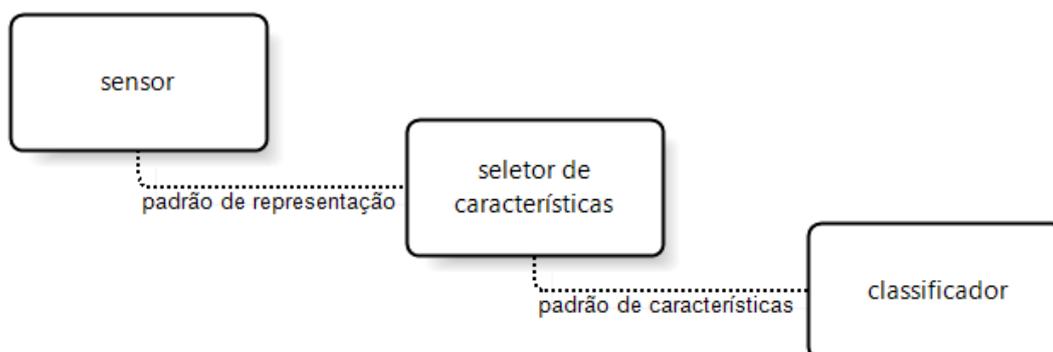


Fonte: Autor.

Pode-se dizer que as soluções de detecção de quedas apresentam apenas dois possíveis resultados em suas execuções: queda reconhecida ou queda não reconhecida. Esses resultados podem ser obtidos através de padrões de classificação, que classificam os dados de acordo com os padrões pré-estabelecidos e, como resultado do processo, decidem a que classe pertencem. É a partir desse princípio que Webb e Kopsey (2011) apresentam o esquema ilustrado na Figura 2: os dados coletados pelo sensor passam, organizados em um padrão de representação, para um seletor de características, que captura as características mais importantes para classificação e as envia para o classificador decidir a qual classe pertencem os sinais coletados. Os três principais agentes do padrão de classificação são:

- *Sensor*: responsável por capturar/coletar dados em formato digital;
- *Seletor de características*: responsável por processar os sinais do sensor, produzindo uma representação apropriada para posterior classificação. É esse seletor que dispõe os dados em forma de aceleração, velocidade, aplica filtros para extrair informações relevantes para a classificação, entre outros;
- *Classificador*: responsável por classificar os dados retornados pelo seletor de características entre as classes disponíveis, através de categorização por limiares ou por aprendizado de máquina. No caso da detecção de quedas, as duas possíveis classes são ocorrência de queda e não ocorrência de queda.

Figura 2 - Padrão de classificação.



4.2 CARACTERIZAÇÃO DE QUEDAS

Esta seção tem por objetivo caracterizar os tipos de quedas e as suas fases.

4.2.1 Tipos de Quedas

As quedas podem ocorrer das mais diversas formas, já que se tratam de movimentos involuntários ocorridos no decorrer do dia-a-dia. Essas quedas podem ocorrer quando realizadas tarefas mais comuns de rotina (deitar, sentar), ou mesmo nas mais distintas atividades onde possam ser encontrados fatores intrínsecos ou extrínsecos que ocasionem o acidente em questão. Baseado nas pesquisas e nos testes realizados, Noury et al. (2008), assim como Aguiar et al. (2014), citaram diversas situações de quedas, divididas por tipos:

- Queda para trás:
 - Ao final de sentar;
 - Ao final de deitar;
 - Terminando em posição lateral;
 - Com recuperação.
- Queda para frente:
 - Sobre os joelhos;
 - Com proteção frontal usando os braços;
 - Terminando de deitar;
 - Com rotação, terminando em posição lateral à esquerda ou à direita;
 - Com recuperação.
- Queda lateral para direita/esquerda:
 - Terminando de deitar;
 - Com recuperação.
- Síncope:
 - Deslize vertical em contato com algum objeto, por exemplo uma parede, terminando na posição sentada.

- Neutro (situações que não representam quedas, mas que apresentam características semelhantes):
 - Sentando em uma cadeira e levantando em seguida;
 - Deitando em uma cama e levantando em seguida;
 - Caminhando alguns metros;
 - Abaixar-se, pegando algo no chão e em seguida levantando;
 - Tossir ou espirrar.

No estudo de Yu (2008), foram apresentados quatro tipos de quedas, alguns detalhes das quedas e seus tempos médios de duração:

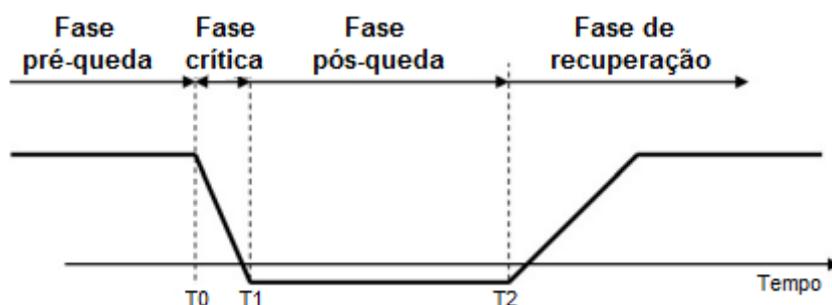
- *Queda ao dormir (na cama)*: a pessoa está deitada na cama no início da queda. Em seguida, o corpo reduz sua altura do nível do leito para o nível do solo, sofrendo nesse momento uma queda livre. Após o impacto com o solo, o corpo permanece deitado no chão, próximo ao leito. Esse processo tem duração média de 1 a 3 segundos;
- *Cair sentado (cadeira)*: o indivíduo está sentado na cadeira no início da queda. Durante a queda, a cabeça do indivíduo tem uma baixa de altura do nível de sentado para o nível do chão, representando uma queda livre da cabeça e resultando no impacto com o chão. O corpo tende a permanecer imóvel, próximo a cadeira, após o impacto. O evento da queda tem duração de 1 a 3 segundos;
- *Cair sobre o chão, estando originalmente em pé*: a pessoa está em pé no início da queda, sendo que sua cabeça tem uma redução drástica da altura onde estava, chocando com o chão ao final do evento. A duração desse evento de queda é de 1 a 2 segundos.
- *Cair sobre suportes, tais como escadas, estando originalmente em pé*: tipo de queda apenas citada, mas não detalhada pelo autor.

4.2.2 Fases do Evento de Queda

A queda é caracterizada por uma sequência de eventos, os quais permitem que sua detecção seja realizada. Noury et al. (2008) dividiram o evento de queda em quatro fases: fase pré-queda, fase crítica, fase pós queda e fase

de recuperação, conforme ilustrado na Figura 3. Na fase pré-queda, o indivíduo ainda não apresenta nenhum sinal de que uma queda irá ocorrer, em resumo, é a fase onde ocorrem as AVDs. A fase crítica se dá do início do evento de queda até que o impacto do idoso com algum objeto ou com o chão ocorra. A fase pós-queda ocorre após o ponto do impacto, quando o sujeito permanece imóvel por um tempo. Recomenda-se que essa fase dure menos de uma hora para reduzir as consequências da queda sofridas pelos idosos. A última fase, a de recuperação, é o momento quando o indivíduo apresenta reação à queda, levantando por conta própria ou por auxílio de alguém.

Figura 3 - As quatro fases do evento de queda.



Fonte: Adaptado de Noury et al. (2008).

Baseado nas fases do evento de queda exibidos na Figura 3, Noury et al. (2008) distinguiu a detecção de quedas em quatro tipos:

1. *Detecção prévia à fase crítica:* as velocidades horizontais e verticais são encontradas, e é verificado se essas ultrapassam alguns limiares pré-definidos para detecção da queda. A dificuldade é a definição desses limiares. Quando esses são muito baixos, o sistema frequentemente detecta uma queda quando não houve (Falso Positivo – FP), assim como quando são muito altos, eventos de quedas deixam de ser identificados;
2. *Detecção no final da fase crítica:* é analisada a inversão súbita da polaridade do vetor de aceleração da direção da trajetória da queda ocasionada pelo choque do impacto. Os problemas dessa abordagem

são a determinação da direção do movimento e, nos casos onde o sensor não está próximo ao ponto de impacto, o choque pode ser captado com força menor do que a ocorrida;

3. *Detecção indireta durante o período pós queda*: o posicionamento do indivíduo após sofrer uma queda tende a ser horizontal, de modo que essa posição pode ser captada por um sensor de inclinação. Verificar se o usuário encontra-se com os pés no chão vem sendo uma alternativa aos vários FPs retornados pela simples verificação da posição do indivíduo, mas isso requer instalações mais complexas;
4. *Detecção indireta da ausência de movimento durante o período pós-queda*: a falta de movimentação após sofrer uma queda é um padrão na maioria dessas situações. O uso dessa abordagem por si só retorna muitos FPs, mas pode ser usada como complemento para outras abordagens.

4.3 MEDIÇÃO DE QUALIDADE

Existem três pontos importantes para avaliação da qualidade dos detectores de quedas:

1. Desempenho do processo de identificação de quedas (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008);
2. Tempo de autonomia do hardware proposto sem recarga de baterias (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008) (Aguiar, Rocha, Silva, & Sousa, 2014) (Ozcan & Velipasalar, 2016);
3. Aceitação da solução proposta pelo público alvo (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008) (Jiangpeng, Xiaole, Zhimin, Zhaohui, & Dong, 2010) (Noury, Feury, Rumeau, & Bourke, 2007).

A qualidade do processo de identificação de quedas tem que demonstrar se as quedas ocorridas são identificadas e quantas AVDs são identificadas como quedas. Com isso, a mensuração da qualidade do processo de detecção de quedas pode ser realizada através do uso da matriz de confusão (Webb & Copsey, 2011), exibida na Tabela 1, com os seguintes parâmetros:

- *Verdadeiros positivos (TP)*: quando o dispositivo detecta uma queda que realmente ocorreu;
- *Falsos positivos (FP)*: quando o dispositivo detecta uma queda que não ocorreu;
- *Verdadeiros negativos (TN)*: quando o dispositivo não detecta quedas em AVDs;
- *Falsos negativos (FN)*: quando o dispositivo não detecta uma queda que ocorreu.

Tabela 1 - Matriz de Confusão.

		Classe positiva	
		Positivo	Negativo
Classe prevista	Positivo	Verdadeiro positivos (TP)	Falso positivos (FP)
	Negativo	Falso negativos (FN)	Verdadeiro negativos (TN)

Fonte: Adaptado de Webb e Kopsey (2011).

Com base na matriz de confusão, medidas de desempenho podem ser calculadas para mensurar a qualidade do resultado. Essas medidas são exibidas na Tabela 2 (WEBB e COPSEY, 2011).

Tabela 2 - Medidas de desempenho derivadas da matriz de confusão 2x2; $P=TP+FN$;
 $N=FP+TN$.

Nome	Variável Identificadora	Fórmula
Acurácia	Acc	$(TP + TN) / (P + N)$
Taxa de erro	E	$1 - Acc$
Taxa de falsos positivo	FPR	FP / N
Taxa de verdadeiros positivo / Taxa de falsos alarmes / Sensibilidade	TPR / Rec / Sens	TP / P
Precisão	Rec	$TP / (TP + FP)$
Especificidade	Spec	TN / N
Medida F	--	$2 / ((1/Prec) + (1/Rec))$

Fonte: Adaptado de Webb e Kopsey (2011).

Das medidas de desempenho apresentadas, as mais encontradas em artigos são as medidas de sensibilidade e de especificidade, conforme será demonstrado nos trabalhos relacionados listados no Capítulo 5. Dessas, a sensibilidade é a capacidade de classificar corretamente eventos de interesse ocorridos, os quais nesse trabalho são as quedas. Um sistema com uma sensibilidade alta raramente não detectará uma queda quando ela ocorrer. A especificidade é a capacidade de classificar corretamente o não acontecimento dos eventos de interesse (De Sá, 2001). Um sistema com uma especificidade alta terá uma baixa taxa de falso alarme, causado por detectar uma queda quando não ocorre.

Noury et al. (2008) ressaltam a importância da autonomia de dispositivos, sem necessidade de manutenção (por exemplo, recarga de baterias), na detecção de quedas. Kau e Chen (2015) realizaram uma medição do consumo de bateria do *smartphone* sem o uso do aplicativo detector de quedas e outra medição com o uso do aplicativo. Sem o aplicativo, o *smartphone* apresentou consumo de 80 mAh, com duração de carga de 32 horas, enquanto

com o aplicativo, o consumo foi de 542 mAh, com duração de carga de 4,76 horas. Aguiar et al. (2014) mediu 0,72% de descarregamento da bateria do *smartphone* sem a aplicação, enquanto com a aplicação, o consumo mínimo foi de 0,92% e máximo de 2,93% da carga da bateria por hora. Jiangpeng et al. (2010) apresentaram quatro medidas para redução do consumo de energia em *smartphones*:

- Execução do monitoramento do usuário em segundo plano;
- Frequência de amostragem de dados ajustada conforme necessidade;
- Serviços de telefonia e correspondência inicializados apenas quando necessário (quando detectada alguma queda);
- Exibição e interação com a tela do aplicativo apenas por requisição do usuário.

4.3.1 Aceitação do Dispositivo

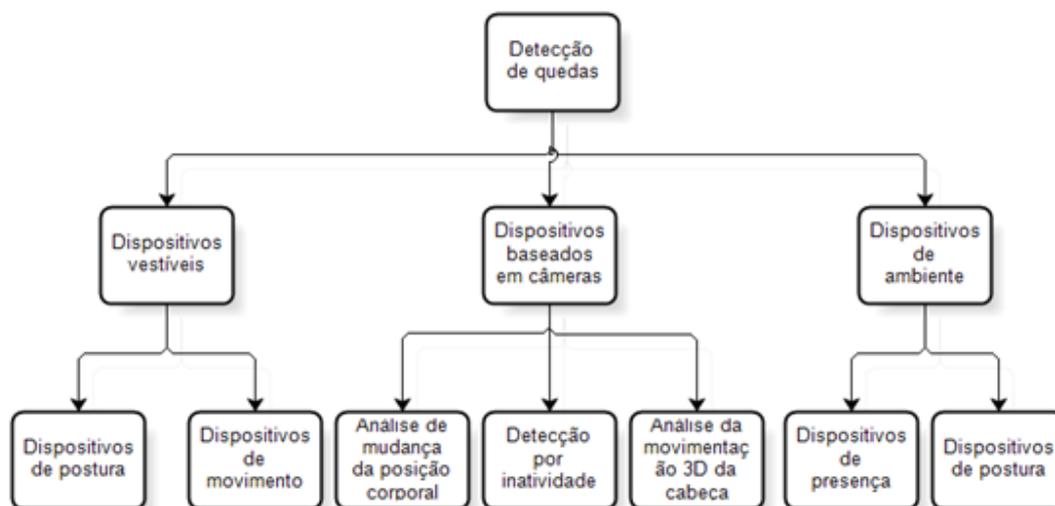
A aceitação pelo idoso do dispositivo de detecção de quedas é necessária para que ele se sinta confortável e seguro ao utilizá-lo. Um exemplo é a baixa aceitação do uso de câmeras, que acabam por invadir a privacidade do usuário (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008). Jiangpeng et al. (2010) citam que o uso de *smartphones* pelos idosos pode ter alguns problemas de aceitação, mas ponderam que esses problemas possam ser minimizados quando visto que carregar um *smartphone* consigo representa uma ação natural nos dias atuais, não chama atenção, ao contrário de ter que carregar um dispositivo dedicado para detecção de quedas, que poderia demonstrar dependência por parte do idoso.

4.4 TIPOS DE DETECTORES DE QUEDAS

Existem diversas abordagens utilizadas na detecção de quedas, as quais podem ser categorizadas conforme os tipos de sensores utilizados pelos

dispositivos propostos. Uma das classificações mais citadas divide os sistemas de detecção de quedas em três categorias, conforme ilustrado na Figura 4: dispositivos vestíveis, dispositivos baseados em câmeras e dispositivos de ambientes (Yu, 2008) (Koray, Anvith, Casares, & Valipasalar, 2013). Essas categorias serão melhor explicadas nas próximas seções.

Figura 4 - A hierarquia de abordagens e classes de métodos de detecção de quedas para idosos e pacientes.



Fonte: Adaptado de Yu (2008).

4.4.1 Dispositivos Vestíveis

A categoria de dispositivos vestíveis, também chamada de dispositivos sem visão por Koray et al. (2013), engloba os detectores de queda que são acoplados ao corpo do usuário através de cintas, suportes ou mesmo nos bolsos das roupas. São usados giroscópios para detecção da postura do usuário (Li, Stankovic, Hanson, Bartch, & Lach, 2009), acelerômetros para mesma finalidade dos giroscópios e para detecção da aceleração proveniente de movimentos do usuário (Noury, Feury, Rumeau, & Bourke, 2007) (Piva, Ferreira, Braga, & Andrade, 2014) (Ventura, Lopes, & Goroso, 2013) (Kau & Chen, 2015) (Aguiar,

Rocha, Silva, & Sousa, 2014), ou mesmo sensores de mercúrio para verificação da orientação espacial do dispositivo carregado pelo usuário (Yu, 2008).

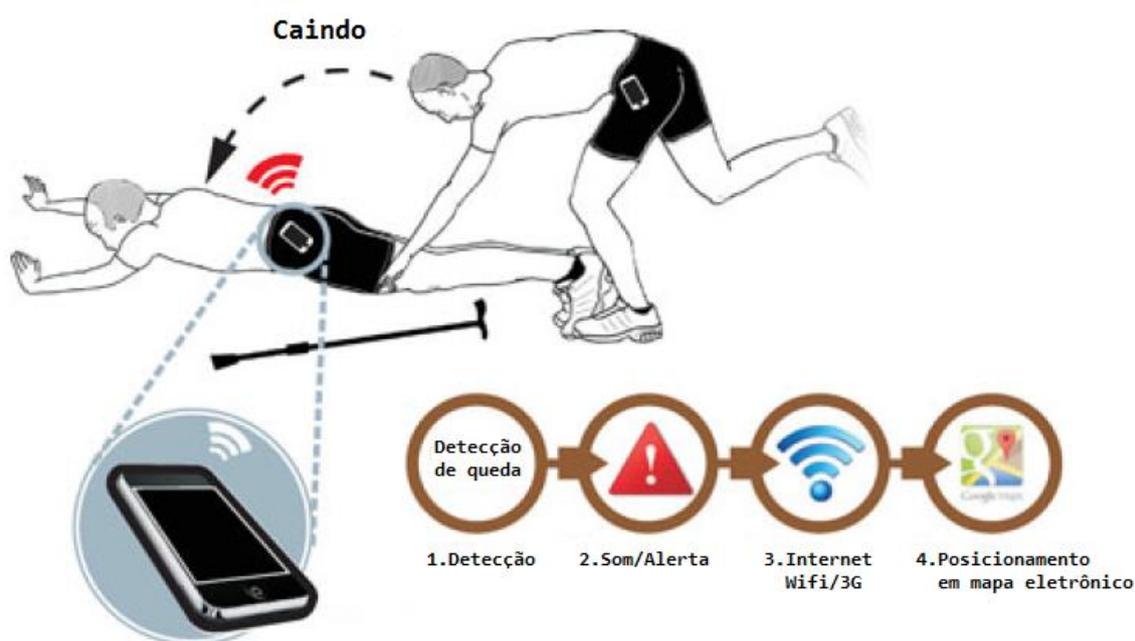
Dentro dessa categoria, os dispositivos de detecção podem ser classificados em duas subcategorias: os dispositivos de captura de postura e os de captura de movimentos (Yu, 2008). Embora os dispositivos vestíveis sejam divididos nessas duas subcategorias, geralmente é feito uso das duas em conjunto na detecção de quedas, ou apenas o uso da detecção de movimentos. Isso se dá pelo fato da análise da postura, por si só, ser insuficiente para detecção de uma queda, apresentando muitos falsos-positivos (Noury, Feury, Rumeau, & Bourke, 2007).

Diversas propostas utilizam hardware dedicado para detecção de quedas (Bloch, et al., 2011) (Ventura, Lopes, & Goroso, 2013), sendo nele instalados os sensores desejados. Doukas e Maglogiannis (2008) desenvolveram uma solução que faz uso de um acelerômetro e, ao mesmo tempo, um microfone preso ao pé do usuário. Nessa abordagem, além das verificações realizadas através dos pontos retornados pelo acelerômetro, identificações de padrões de sons também são processadas para descobrir quais ações estão sendo realizadas pelo usuário, ações que podem ser quedas. Almeida, Zhang e Liu (2007) apresentaram uma solução onde apenas um giroscópio é fixado em uma bengala, capturando a velocidade angular e a orientação espacial do objeto. Nessa solução, assume-se que se a bengala estiver “deitada”, o usuário também está, caracterizando uma queda. Essas soluções geralmente necessitam de toda uma estrutura física para serem funcionais, já que precisam emitir alertas através de algum meio de comunicação, seja esse acoplado no próprio dispositivo (por exemplo internet móvel) ou disposto através de uma conexão sem fio (por exemplo Bluetooth) com uma central.

Uma alternativa interessante é a utilização de *smartphones*, logo que, em sua maioria, possuem acelerômetros, sensores GPS, microfones, conexões com internet, serviços de telefonia, entre diversas outras funcionalidades acopladas ao próprio hardware e dispostas pelo sistema operacional. Aguiar et al. (2012) utiliza o acelerômetro tri axial do *smartphone* para detecção de quedas,

preso ao cinto ou acomodado no bolso das roupas do usuário. Assim que uma queda é detectada, o sistema captura o posicionamento GPS do dispositivo e o envia via e-mail por internet móvel para um destinatário pré-configurado, a fim de informar que o usuário sofreu uma queda e o local onde está. Kau e Chen (2015) fazem uso de uma estratégia semelhante, mas acrescentando o uso de uma bússola eletrônica (eCompass) na busca de dados para detecção das quedas. Essa solução foi desenvolvida para que o *smartphone* permaneça no bolso do usuário para a detecção das quedas, conforme o cenário ilustrado na Figura 5. Piva et al. (2014) também apresentam um detector de quedas baseado no acelerômetro tri-axial dos *smartphones*, o fAlert. Nessa proposta, o *smartphone* foi preso no tórax dos usuários. O diferencial do algoritmo proposto no fAlert é que ele foi programado para que, quando sofrida uma queda, o *smartphone* peça a confirmação da queda ocorrida via comando de voz, esperando uma resposta, também por voz, do usuário. Caso a pergunta não seja respondida ou o indivíduo confirme ter caído, então uma queda é identificada e o respectivo alerta é enviado via chamada telefônica.

Figura 5 - Cenário para um detector de acidentes de queda com smartphone de bolso.



Fonte: Adaptado de Kau e Chen (2015).

4.4.2 Dispositivos Baseados em Câmeras

Na categoria de dispositivos baseados em câmeras, existem ainda três subdivisões: análises de mudança da posição corporal, detecção por inatividade e análise da movimentação 3D da cabeça do usuário.

A mudança da posição corporal é a mais comumente utilizada nas abordagens com câmeras, onde uma sequência de imagens é analisada e um padrão de queda é buscado para identificar se ela ocorreu. Essa sequência de imagens pode ser gerada por câmeras fixadas no ambiente, conforme as abordagens mais citadas por artigos (Yu, 2008) (Noury, Feury, Rumeau, & Bourke, 2007), ou ainda podem ser utilizadas câmeras carregadas pelo próprio usuário (Ozcan & Velipasalar, 2016). Na proposta das câmeras carregadas pelo próprio usuário, também foi feito uso de um acelerômetro tri axial para aumentar a precisão das quedas detectadas, tudo através de um *smartphone* preso ao cinto do usuário, conforme ilustrado na Figura 6. Nessa proposta, foram realizados testes com 10 usuários, sendo que cada um simulou 10 quedas ocorridas enquanto estavam em pé (andando), 10 quedas ao sentar, 10 atividades de sentar sem sofrer quedas e mais 10 atividades de deitar também sem sofrer quedas. O sistema obteve uma sensibilidade de 65,66% de sensibilidade e um FP de 0% com apenas o uso de acelerômetros, enquanto o uso apenas da câmera apresentou 74,33% de sensibilidade e 0,16% de FP. O uso do acelerômetro em conjunto com a câmera apresentou 91% de sensibilidade e 0,026% de FP.

Figura 6 - Um smartphone Android preso ao cinto.



Fonte: Adaptado de Ozcan e Velipasalar (2016).

A detecção por inatividade tem como foco identificar se o indivíduo permanece imóvel em algum lugar incomum no ambiente analisado, como no chão ou em alguma escada. Jansen e Deklerek (2006) utilizaram esse tipo de detecção, na qual analisaram se o indivíduo capturado pelas câmeras estava em inatividade e, se permanecesse imóvel por algum tempo, avaliava o local para saber se uma queda havia ocorrido. Essa categoria de verificação tende a ser leve e rápida, porém pouco precisa (Yu, 2008).

A detecção 3D da cabeça do indivíduo se mostra eficaz, logo que a cabeça é um ponto fácil de identificar quando as câmeras estiverem localizadas em pontos altos, como nos cantos superiores de uma sala. Na detecção, identificam-se as velocidades horizontais e verticais dos movimentos da cabeça do usuário e, caso essas ultrapassem os limites pré-estabelecidos, uma queda é identificada. O problema dessa abordagem é que o processamento de imagens, ilustrado na Figura 7, é um processo pesado e lento, pois deve identificar o corpo em várias imagens, calcular as velocidades baseadas no intervalo de tempo entre as imagens e o deslocamento dos pontos reconhecidos, além de verificar os limites das velocidades encontradas (Rougier, Meunier, St-Arnaud, & Rousseau, 2006).

Figura 7 - A ilustração mostra a eficiência do acompanhamento durante a queda.



Fonte: Adaptado de Rougier, Meunier, et al. (2006).

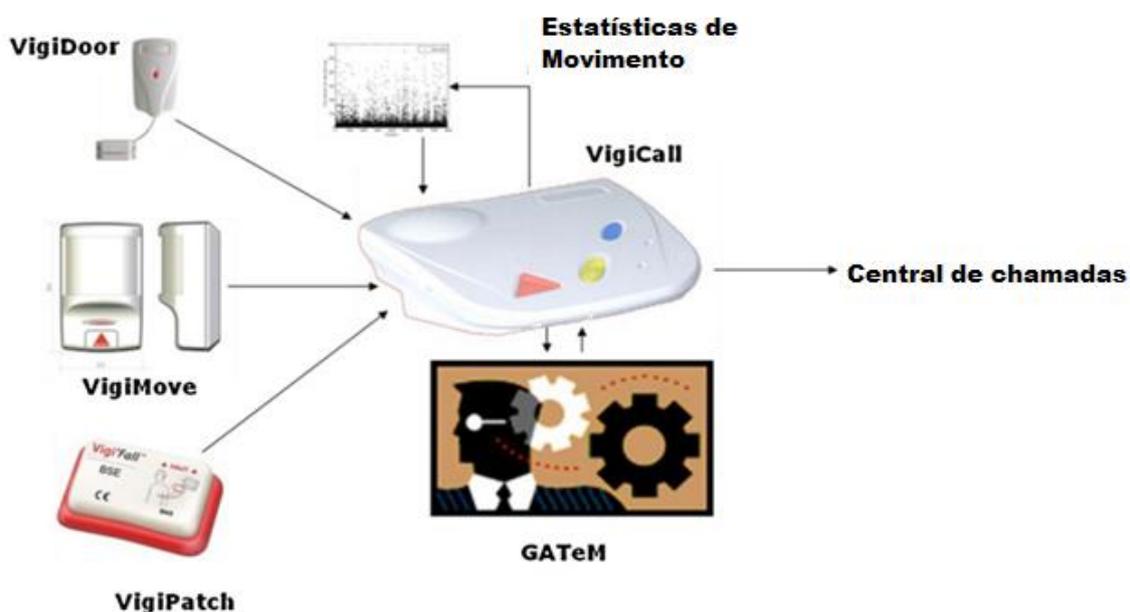
4.4.3 Dispositivos de Ambiente

A categoria de dispositivos de ambiente engloba soluções com sensores que são dispostos para monitoramento onde os indivíduos habitam, com exceção das soluções que fazem uso de câmeras, já que essas têm uma categoria específica. Nessa categoria, as soluções são divididas em dispositivos de detecção de presença e dispositivos de detecção de postura do usuário (Yu, 2008).

O Vigi'Fall, sistema apresentado por Blosch et al. (2011) e ilustrado na Figura 8, combina sensores infravermelhos e acelerômetro acoplado ao corpo para detectar quedas. Os sensores infravermelhos são instalados no ambiente para detecção de quedas, e o usuário utiliza um dispositivo vestível, fixado no tórax, que possui um acelerômetro para identificação de choques sofridos pelo usuário contra objetos ou contra o próprio solo. Nos testes dessa abordagem sem o uso do sensor vestível (acelerômetro) realizados com apenas dois usuários, nenhuma situação de queda ocorreu, porém nenhum FP foi detectado. Já nos testes realizados também com o sensor vestível, 8 indivíduos foram analisados e o sistema apresentou 62,5% de sensibilidade e 99,5% de especificidade. Alwan et al. (2006) apresentam uma abordagem que utiliza um

sensor piezoelétrico acoplado ao chão para detecção de vibrações. As vibrações podem ser diferenciadas entre as causadas por movimentos voluntários, por impacto de um objeto ou de uma pessoa que sofreu uma queda. Em seus testes, 70 quedas foram simuladas e 53 objetos derrubados sobre o piso onde os sensores foram instalados. Todas as quedas foram corretamente detectadas e nenhum dos objetos derrubados foi detectado como queda, apresentando 100% de sensibilidade e 100% de especificidade.

Figura 8 - Componentes do sistema Vigi'Fall.



Fonte: Blosch et al. (2011).

4.5 DETECTORES DISPONÍVEIS NO MERCADO

A detecção de quedas, ao mesmo tempo que desperta interesse à estudos, também desperta interesse de empresas para encontrar soluções e dispô-las no mercado. Os principais tipos de soluções presentes no mercado serão citados e detalhados nessa seção.

Em sistemas de detecção automática por dispositivo vestível, com central física e serviço de assistência, o usuário carrega consigo um dispositivo vestível, que detecta quedas automaticamente ou quando pressionado um botão de emergência. Esse dispositivo pode ser usado em forma de colar, de pulseira, ou mesmo prendendo à roupa, dependendo dos modelos dispostos pelo fabricante. Nessa categoria, os dispositivos vestíveis precisam estar próximos a uma central, que é responsável por receber o sinal do dispositivo e entrar em contato com centrais de atendimento para receber socorro. Um exemplo dessa categoria de produtos é exibido na Figura 9.

Figura 9 - HomeSafe (Landline) da linha de produtos Lifeline, da Philips.



Fonte: página web de produtos da linha Lifeline da Philips¹.

Nas soluções com detecção automática por dispositivo vestível, sem central física e com serviço de assistência, possuem um dispositivo vestível tal como o citado anteriormente, mas esse possui a comunicação embutida para chamada de socorro, não necessitando permanecer próxima a uma central física. Além das funcionalidades citadas, algumas das soluções dispõem também de localização via GPS^{1,2}. Dentre essas soluções, vale citar a autonomia da carga da bateria do dispositivo do Alert-1, que chega a durar dois anos sem recarga³.

¹ Disponível em: < <https://www.lifeline.philips.com/safety-solutions.html>>. Acesso em: abr. 2016.

² Disponível em: < <http://www.sense4care.com/en/products/angel4-whiteblack>>. Acesso em: abr. 2016.

³ Disponível em: < <https://www.alert-1.com/system/pax-mobile-fall-detection/4719>>. Acesso em: abr. 2016.

Existe também a detecção automática por dispositivo vestível, sem central física e sem serviço de assistência, mas com conexão Bluetooth para *smartphones*. Ao ativar o dispositivo vestível, o pareamento do dispositivo com o *smartphone* é realizado. Caso ocorra uma queda, ou mesmo um botão de alerta seja pressionado, o *smartphone* do idoso envia um alerta para o *smartphone* de um responsável. Nesse, outros serviços remotos também estão disponíveis, tais como emissões de avisos de necessidade de recarga de baterias².

Com a crescente procura por detectores de quedas, padrões de qualidade e confiança começaram a se tornar mais necessários, além da necessidade de serem financeiramente tangíveis pela população. Os valores dos 10 melhores detectores de quedas avaliados em 2016⁴ variam entre R\$ 85,72 e R\$ 1.071,44, como é mostrado na Figura 10.

Figura 10 - Os dez melhores detectores de quedas de 2016.



Fonte: Página web dos 10 melhores detectores de quedas de 2016⁴.

⁴ Disponível em: <<http://medical-alert-systems-review.toptenreviews.com/fall-detection/>>. Acesso em: mai. 2016.

A gama de produtos disposta atualmente para consumo é baixa, dispondo de pouca variedade dos tipos de abordagens utilizadas. Não se encontra soluções que façam uso de hardwares genéricos, como *smartphones*, para atividade fim de detecção de quedas nas melhores soluções oferecidas no mercado. Em questão de valores, pode-se chegar à conclusão de que, se o valor médio dos melhores detectores de queda do mercado é de R\$ 238,092 (Purch Corporation, 2016), detectores de quedas através do uso de *smartphones* podem sair mais em conta financeiramente, apresentando custo apenas do software de detecção e, talvez em uma solução mais completa, uma central de monitoramento/acompanhamento dos usuários.

5 METODOLOGIA PARA DETECÇÃO DE QUEDAS VIA ACELERÔMETRO TRI AXIAL

Nos dispositivos de ambiente, embora os índices de qualidade encontrados sejam próximos (quando não superiores) aos encontrados pelas demais categorias, toda a preparação do ambiente e o custo proveniente das adaptações necessárias acaba, muitas vezes, por inviabilizar a solução. Os detectores com uso de câmeras têm se tornado cada vez mais acessíveis e, com o surgimento das câmeras sem fio, a instalação delas também têm se tornado mais fácil e com menores custos de instalação. Apesar das facilidades fornecidas pelo uso de câmeras, a invasão da privacidade do usuário continua sendo um problema (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008). Conforme citado por Blosh et al. (2011), o uso de três acelerômetros pelo idoso permite maior precisão na identificação de quedas. Entretanto, conforme citado por Piva et al. (2014), o custo por eficiência pode se tornar alto, além do incômodo do usuário ter de carregar vários sensores espalhados pelo corpo. Analisando os resultados encontrados no uso dos diferentes tipos de detectores de quedas, seus problemas e a necessidade de aceitação do uso da solução proposta pelo usuário, uma das abordagens com melhores resultados, de mais fácil implementação, aceitação e mais barata é a de uso do acelerômetro tri axial presente nos *smartphones*, foco da solução apresentada por esse trabalho.

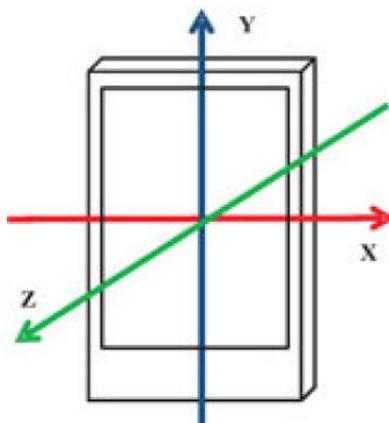
5.1 O SENSOR E OS DADOS RETORNADOS

Um acelerômetro é um dispositivo que mede a vibração ou a aceleração do movimento de uma estrutura. A força causada por vibração ou uma mudança no movimento (aceleração) faz com que a massa de "apertar" o material piezoelétrico, que produz uma carga elétrica que é proporcional à força exercida sobre ela. Uma vez que a carga é proporcional à força, e a massa é uma constante, então a carga também é proporcional à aceleração⁵.

⁵ Disponível em: <<http://www.omega.com/prodinfo/accelerometers.html>>. Acesso em: mai. 2016.

A primeira etapa da detecção de quedas é a captura dos dados retornados pelos sensores. O acelerômetro tri axial mede a aceleração individual de cada um dos três eixos do dispositivo, x, y e z, ilustrados na Figura 11 (Kau & Chen, 2015).

Figura 11 - Coordenadas do acelerômetro tri axial.



Fonte: Adaptado de Kau e Chen (2015).

O acelerômetro tri axial produz diferentes amostras de acordo com a posição onde for preso ao corpo do usuário. As opções de uso comumente usadas são: cintura, pulso, peito e coxa (Kulkarni & Basu, 2013). Para cada localização do sensor, uma abordagem de detecção de quedas diferente deve ser realizada, já que os resultados encontrados podem divergir de acordo com a orientação do sensor. Yi, Sarcar et al. (2014) apresentam divergência dos índices de sensibilidade encontrados nos resultados da aplicação para diferentes localizações do acelerômetro no usuário.

5.2 SELEÇÃO DE CARACTERÍSTICAS

A seleção de características consiste em manipular os dados, de maneira que fiquem dispostos para posterior classificação (Webb & Copsey, 2011). Nessa subseção, serão apresentadas as formas de representação das

características mais utilizadas pelos detectores de quedas, assim como as equações necessárias para obtenção dos valores a partir dos dados brutos retornados pelo acelerômetro.

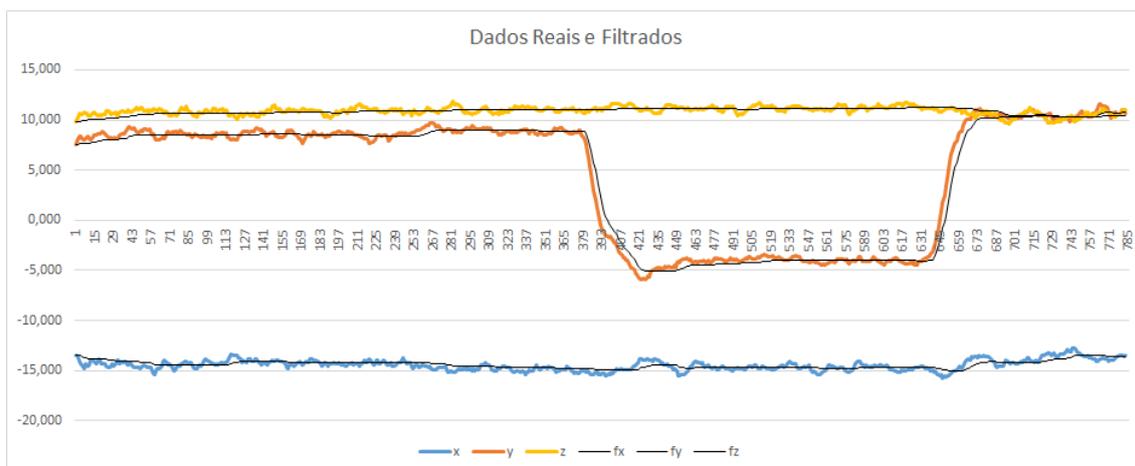
Filtros para eliminação de variações não necessárias para detecção podem ser aplicados nos dados retornados pelo acelerômetro. Silva (2013) utiliza um filtro passa-baixa sobre os dados, eliminando diversas variações de aceleração ocorridas. Liandana, Mustika e Selo (2014) utilizam as seguintes equações para aplicação do filtro:

$$ACCHPavg = ACCnew * 0.1 + ACCHPavg * 0.9$$

$$ACCHPFiltered = ACCNew - ACCHPavg$$

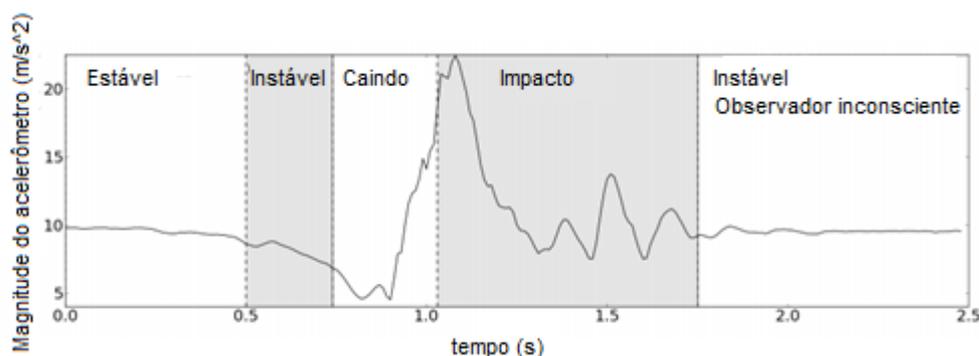
onde *ACCnew* é o retorno de cada eixo do acelerômetro, *ACCHPavg* é a aceleração isolada da força da gravidade e *ACCHPFiltered* é o resultado do filtro. Um exemplo dos dados obtidos após a aplicação do filtro é ilustrado na Figura 12, onde as linhas amarela, laranja e azul representam as acelerações dos eixos x, y e z, respectivamente, retornadas pelo acelerômetro, enquanto as pretas representam os dados após aplicado o filtro. Aguiar et al. (2014) apresentaram, aplicando filtro passa-baixa nos dados retornados pelo sensor, uma divisão da aceleração do evento de queda em cinco fases, mostradas na Figura 13: estável, instável, queda, impacto e instável observando inconscientemente.

Figura 12 - Dados de aceleração reais (linhas coloridas) e filtrados (linhas pretas).



Fonte: Discussão intitulada como “Filtrando dados dos sensores de aceleração e magnético no Android” em fórum web Stack Overflow⁶.

Figura 13 - Representação de estágios de queda sobre um exemplo representativo da magnitude do filtro passa-baixo de sinal de aceleração para um evento de queda.



Fonte: Adaptado de Aguiar et al. (2014).

Para verificação dos pontos retornados pelo acelerômetro tri axial, pode-se calcular a aceleração individual de cada um dos eixos, ou pode-se calcular a aceleração linear do dispositivo. A aceleração linear (a_t) pode ser calculada através de

$$a_t = \left| \sqrt{a_{x_t}^2 + a_{y_t}^2 + a_{z_t}^2} \right|$$

⁶ Disponível em: <<http://pt.stackoverflow.com/questions/68303/filtrando-dados-dos-sensores-de-acelera%C3%A7%C3%A3o-e-magn%C3%A9tico-no-android>>. Acesso em: mai. 2016.

onde a_x , a_y e a_z são as gravidades dos eixos x, y e z, respectivamente (Piva, Ferreira, Braga, & Andrade, 2014) (Jiangpeng, Xiaole, Zhimin, Zhaohui, & Dong, 2010).

O vetor de aceleração atual (A_t) pode ser estimado através de

$$A_t = a_t * fs \left(\frac{g}{LSB} \right) (g)$$

onde fs é o fator de escala atual (0.312g/LSB), g é a unidade de gravidade inicial e LSB é a abreviação para o bit menos significativo, *least significant bit* (Li, Chen, Shen, Zhu, & Cheng, 2012).

Koshmak e Liden (213) estimam a aceleração desenvolvida (Act_t) através de

$$Act_t = |a_t^2 - a_{t-1}^2|.$$

A soma da diferença total da aceleração ($SDif_t$), usada por Liandana, Mustika e Selo (2014) com o somatório das sete últimas medições, é calculada por

$$SDif_t = \sum_{i=0}^6 a_{t-i} - a_{t-i-1}.$$

A amplitude, que é a aceleração vertical absoluta (a_{vt}), pode ser calculada através de

$$a_{vt} = |a_{xt} \sin\theta_z + a_{yt} \sin\theta_y - a_{zt} \cos\theta_y \cos\theta_z|$$

onde, θ_x , θ_y e θ_z são as orientações do dispositivo em relação aos eixos x, y e z, respectivamente.

Perry, Kellog et. al. (2009) apresentam como parâmetro adicional para detecção de quedas a soma das velocidades frontal e sagital (s_{ht}), calculada por

$$s_{ht} = \sqrt{a_{xt}^2 + a_{zt}^2}.$$

Além da aceleração, a velocidade (v_t) também pode ser calculada através dos pontos retornados pelo acelerômetro tri axial (Perry, et al., 2009), conforme

$$v_t = \int (a_t - 9,81) dt.$$

Após detectada a possibilidade de queda através da aceleração, a alteração da orientação do dispositivo detector de quedas pode ser verificada (Koshmak & Liden, 2013). Essa orientação pode ser encontrada através dos ângulos de Euler, gerados a partir das alterações de orientação do dispositivo, ilustrados na Figura 14, são:

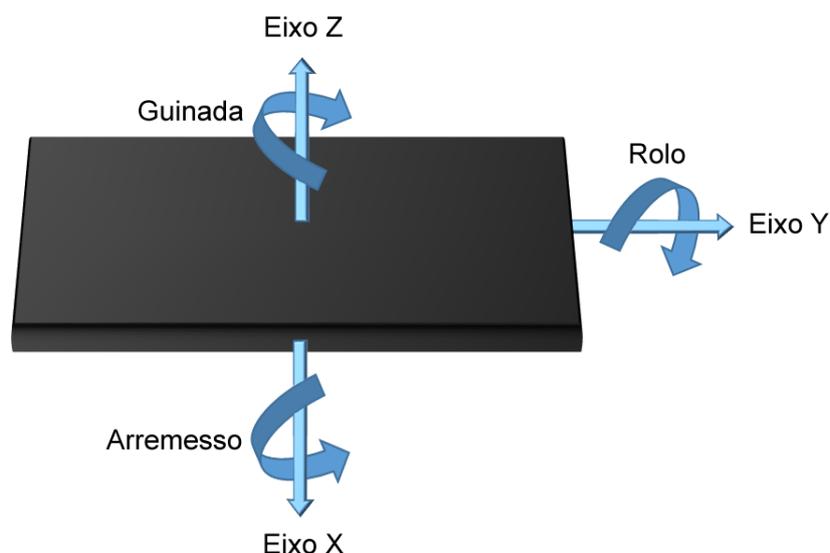
- Guinada: quando o dispositivo gira em torno do eixo Z;
- Rolo: quando o dispositivo gira em torno do eixo Y, estimado através de

$$rolo_t = \arcseno\left(\frac{a_{xt}}{9,81}\right).$$

- Arremesso: quando o dispositivo gira em torno do eixo X, estimado através de

$$arremesso_t = \arcseno\left(\frac{a_{zt}}{9,81}\right).$$

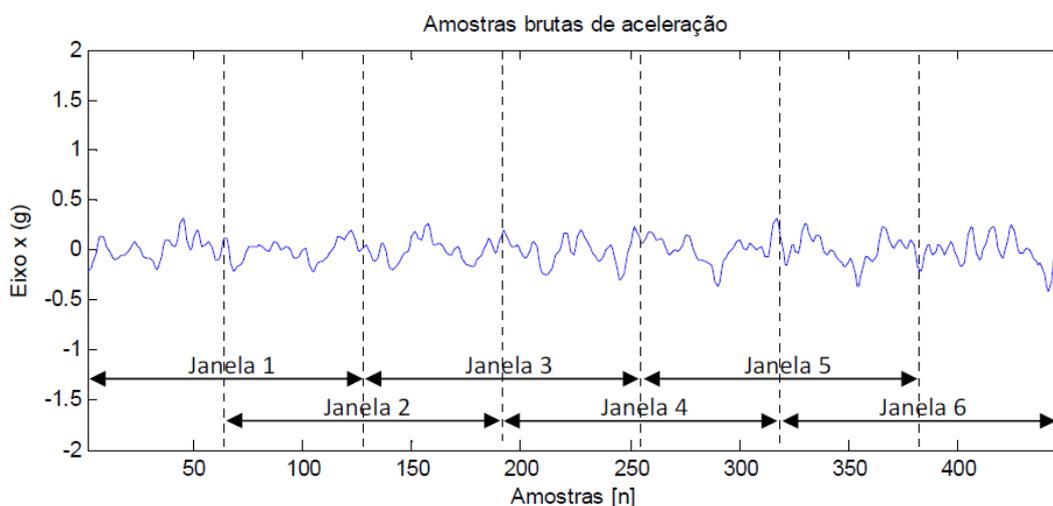
Figura 14 - Nomenclatura dos movimentos de troca de orientação.



Fonte: Autor.

Além da seleção de características, antes ou depois dessa, deve-se definir um intervalo de amostras para ser enviada ao classificador. Esse intervalo é chamado de janela (Duda, Hart, & Stork, 2001). Por exemplo, se houverem quinhentos pontos retornados pelo sensor, poderiam ser definidas janelas de 128 amostras para serem enviadas ao classificador, conforme ilustrado na Figura 16. Essas janelas podem ser definidas sobrepondo umas às outras, de modo que os mesmos dados possam ser processados em diferentes janelas (Silva, 2013).

Figura 15 - Segmentação dos dados em janelas de 128 amostras com 50% de sobreposição.



Fonte: Silva (2013).

5.3 CLASSIFICADORES

Com os dados capturados pelos sensores e com as suas características relevantes discriminadas, chega a fase de classificação. Essa classificação pode ser realizada de duas formas: por limiares e por aprendizado de máquina.

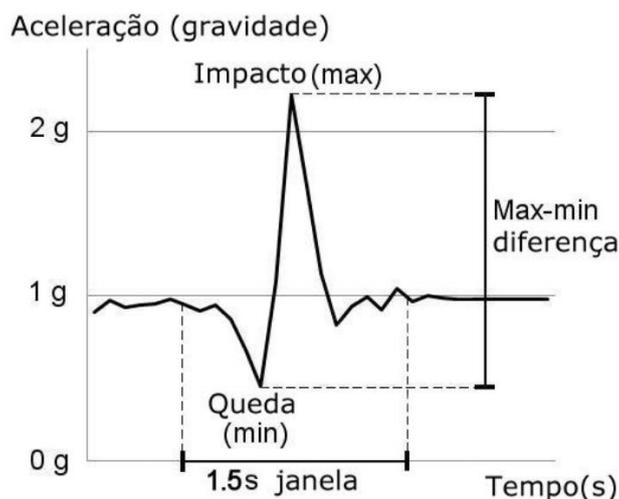
5.3.1 Limiares

A detecção de quedas por limites consiste em definir limites cujos quais os dados retornados pelo seletor de características devem ultrapassar para que

uma queda seja detectada. Nessa categoria de classificação, basta que os limites sejam atingidos para que uma queda seja detectada (Tamura, Yoshimura, Sekine, Ushida, & Tanaka, 2009) (Li, Chen, Shen, Zhu, & Cheng, 2012) (Koshmak & Liden, 2013) (Liandana, Mustika, & Selo, 2014) (Yi, Sarkar, Mathavan, & Jafar, 2014) (Pierleoni, et al., 2015) (Wang, Narayanan, Lord, Redmond, & Lovell, 2014) (Sannino, Falco, & PietroInstitute, 4) (Chen, Fend, Zhang, Li, & Wang, 2011) (Li, Stankovic, Hanson, Bartch, & Lach, 2009) (Bianchi, Redmond, Narayanan, Cerutti, & Lovell, 210) (Hwang, Kang, Jang, & Kim, 2004) (Piva, Ferreira, Braga, & Andrade, 2014) (Kostopoulos, Nunes, Salvi, Deriaz, & Torrent, 2015) (Chen, Kwong, Chang, Luk, & Bajcsy, 2006) ou estados podem ser definidos para cada limite alcançado, utilizando uma abordagem chamada de Máquina de Estados (Hsieh, Su, Liu, & Jiang, 2012) (Valcourt, Hoz, & Labrador, 2016). A abordagem por limiares e a abordagem por máquina de estados são muito semelhantes, apresentando aspectos de implementação praticamente idênticos. A única distinção são os estados predefinidos alcançados durante a detecção, os quais podem ser entendidos como etapas, que a máquina de estados faz uso.

Piva et al (2014) utilizam limiares mínimos e máximos para detectar se uma queda ocorreu. O sistema verifica se a aceleração linear ultrapassa os valores mínimo e máximo dentro de um período de tempo de 1,5 segundo, como ilustrado na Figura 16. Caso isto ocorra, o sistema verifica se o dispositivo se encontra em posição de até 45° em relação ao solo, para assim determinar se uma queda ocorreu.

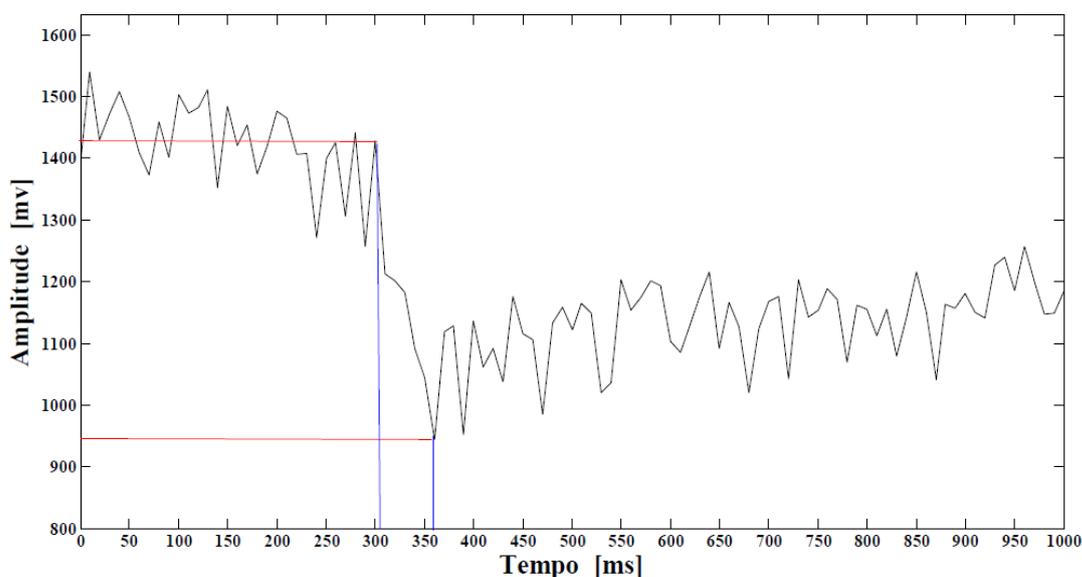
Figura 16 - Padrão para detecção de queda utilizando os dados fornecidos pelo acelerômetro.



Fonte: Adaptado de Piva et al. (2014).

Ventura, López e Goroso (2013) definiram como limiar uma queda brusca de, no mínimo, 530 mV em um período de 50 milissegundos para que um evento fosse identificado como queda. Conforme ilustrado pela Figura 17, houve uma queda brusca da amplitude de 1500 mV para 960 mV em 50 milissegundos, a qual representa uma queda de um indivíduo que estava em pé.

Figura 17 - Detalhe da detecção da queda.



Fonte: Adaptado de Vetura, López e Goroso (2013).

Semelhante ao método de Piva et al (2014), Kau e Chen (2015) aplicaram limites pré-definidos na velocidade linear coletada para detecção de quedas. Segundo eles, a aceleração durante a queda tende a ser menor do que 0,6G, passando para mais de 1,8G no ponto de impacto com o solo. Depois disso, sendo o momento onde a vítima da queda permanece parada, a aceleração permanece com alteração em torno de 1G. Para Perry, Kellog et al. (2009), a queda é representada pela aceleração linear passando de 6G durante a queda, baixando para menos de 2G no impacto.

A Tabela 3 cita os testes e os respectivos resultados retornados pelos trabalhos que realizam detecção por limiares.

Tabela 3 - Testes e resultados de trabalhos com detecção por limiares.

Trabalho	Localização dos sensores	Descrição dos testes	Resultados obtidos
TAMURA et al. (2009)	Nas costas	<ul style="list-style-type: none"> • 17 indivíduos; • Quedas para frente e para trás realizadas em laboratório. 	<ul style="list-style-type: none"> • Acurácia: 93%.
Koshmak, Linden et al. (2013)	Na cintura	<ul style="list-style-type: none"> • 7 indivíduos; • Simulação em laboratório de 50 quedas e 33 AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 90%; • Especificidade: 100%.
Liandana, Mustika e Selo (2014)	Na cintura	<ul style="list-style-type: none"> • 3 indivíduos; • Simulação em laboratório de 365 quedas e 125 AVDs 	<ul style="list-style-type: none"> • Sensibilidade: 90,41%; • Especificidade: 94,4%.
Hsieh et al. (2012)	No bolso da camisa e no bolso das calças	<ul style="list-style-type: none"> • 3 indivíduos; • Simulação em laboratório de quedas para frente, para trás e para as laterais, além de AVDs. 	<ul style="list-style-type: none"> • Sensibilidade para detecção de quedas para frente e para trás: <ul style="list-style-type: none"> ○ Com sensor no bolso da camisa: 100%; ○ Com sensor no bolso das calças: 100%. • Sensibilidade para detecção de quedas laterais: <ul style="list-style-type: none"> ○ Com o sensor no bolso da camisa: 93%; ○ Com sensor no bolso das calças: 93%. • Especificidade para detecção de AVDs: 100%.
Valcourt, Hoz e Labrador (2016)	Diversa	<ul style="list-style-type: none"> • 6 indivíduos; • Simulação em laboratório de 36 quedas e 108 AVDs. 	<ul style="list-style-type: none"> • Acurácia: 81,3%; • Precisão: 58,2%; • Especificidade: 79%.
Pierleoni et al. (2015) ⁷	No peito	<ul style="list-style-type: none"> • 10 indivíduos; • Simulação em laboratório de 540 situações (quedas, quedas com recuperação e AVDs). 	<ul style="list-style-type: none"> • Acurácia: 95,9%; • Sensibilidade: 96,7%; • Especificidade: 96,9%.
Wang et al. (2014)	Não especificado	<ul style="list-style-type: none"> • 3 indivíduos; 	<ul style="list-style-type: none"> • Acurácia: 95,9%; • Sensibilidade: 96,7%;

⁷ IEEE Sensors Journal, v. 15, p. 4544 - 4553, ago. 2015

Trabalho	Localização dos sensores	Descrição dos testes	Resultados obtidos
		<ul style="list-style-type: none"> • Simulação em laboratório de 114 quedas por cada indivíduo. 	<ul style="list-style-type: none"> • Especificidade: 96,9%.
Saninno, Falco e Pietro (2015)	No peito	<ul style="list-style-type: none"> • 3 indivíduos; • Simulação em laboratório de 2 vezes cada tipo de queda mais 16 AVDs por indivíduo; • Base de dados contendo 86 registros de queda. 	<ul style="list-style-type: none"> • Acurácia com simulações: 91,57%; • Sensibilidade com simulações: 85,71%; • Especificidade com simulações: 95,83%; • Acurácia com base de dados: 93,17%; • Sensibilidade com base de dados: 86,77%; • Especificidade com base de dados: 99,21%;
Chen et al. (2011)	Na cintura	<ul style="list-style-type: none"> • 5 indivíduos; • Simulação em laboratório de quedas para frente, para trás, para as laterais e AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 95%; • Especificidade: 100%; • Precisão da detecção de ADLs: 100%; • Precisão da detecção de quedas: <ul style="list-style-type: none"> ○ Para frente: 100%; ○ Para trás: 95,56%; ○ Para esquerda: 96,67%; ○ Para direita: 100%.
Li et al. (2009)	Acelerômetro no peito e giroscópio na coxa	<ul style="list-style-type: none"> • 3 indivíduos; • Simulações em laboratório de 70 quedas e 72 AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 91%; • Especificidade: 92%.
Bianchi et al. (2010)	Na cintura	<ul style="list-style-type: none"> • 20 indivíduos simulando em laboratório de 16 tipos de quedas; • 10 indivíduos realizando AVDs durante o dia. 	<ul style="list-style-type: none"> • Acurácia com verificação de: <ul style="list-style-type: none"> ○ Alteração de aceleração: 70%; ○ Alteração aceleração e imobilidade: 85,3%. • Sensibilidade com verificação de: <ul style="list-style-type: none"> ○ Alteração de aceleração: 75%; ○ Alteração de aceleração e imobilidade: 75%. • Especificidade com verificação de: <ul style="list-style-type: none"> ○ Alteração de aceleração: 67%; ○ Alteração de aceleração e imobilidade: 91,5%.
Piva et al. (2014)	No peito	<ul style="list-style-type: none"> • Simulação em laboratório de 30 quedas. 	<ul style="list-style-type: none"> • Efetividade: 93%.
Hwang et al. (2004)	No peito	<ul style="list-style-type: none"> • 3 indivíduos; 	<ul style="list-style-type: none"> • Acurácia: 96,7%.

Trabalho	Localização dos sensores	Descrição dos testes	Resultados obtidos
		<ul style="list-style-type: none"> • Simulação em laboratório de AVDs (uma vez) e de quedas (realizadas 10 vezes), resultando em 123 testes. 	
Kostopoulos et al. (2015)	No pulso	<ul style="list-style-type: none"> • 6 indivíduos; • Simulações em laboratório de quedas e AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 92,18%; • Especificidade: 87,29%; • Acurácia: 89,74%.
Kau e Chen (2015)	No bolso	<ul style="list-style-type: none"> • 450 ações envolvendo 9 tipos de atividades. 	<ul style="list-style-type: none"> • Sensibilidade: 92%; • Especificidade: 99,75%.
Aguiar et al.(2014)	No bolso e na cintura	<ul style="list-style-type: none"> • 28 indivíduos; • Simulações em laboratório de 1879 quedas e 1611 AVDs. 	<ul style="list-style-type: none"> • Sensibilidade com sensor: <ul style="list-style-type: none"> ○ No bolso: 96,6%; ○ Na cintura: 97%. • Especificidade com sensor: <ul style="list-style-type: none"> ○ No bolso: 98,6%; ○ Na cintura: 98,4%. • Precisão com sensor: <ul style="list-style-type: none"> ○ No bolso: 97,5%; ○ Na cintura: 97,6%.

Fonte: Autor.

5.3.2 Aprendizado de Máquina

O aprendizado de máquina consiste em duas fases: a fase de treinamento e a fase de reconhecimento. Na fase de treinamento, informam-se dados de execução e os respectivos estados, a fim de criar uma base de dados para futuras comparações. Na fase de reconhecimento, informam-se dados reais para um algoritmo de classificação e, conforme os percentuais de probabilidade retornados por esse, conclui-se qual é a classe mais provável que os dados se assemelham, de acordo com limiares de probabilidade pré-estabelecidos. No caso da detecção de quedas, simulações de quedas e de AVDs são realizadas para obtenção de dados de treinamento, assim os dados lidos pela aplicação de detecção de quedas poderão ser classificados entre duas classes: classe de queda ocorrida e classe de queda não ocorrida.

Existem diversos algoritmos de inteligência artificial utilizados para classificação de quedas/não quedas, entre eles: árvores de decisão (Ojetola, Gaura, & Brusey, 2011), lógica de Fuzzy (Surana, Hemalatha, Vaidehi, Palavesam, & Khan, 2013) (Putchana, Chivapreecha, & Limpiti, 2012), Cadeias Escondidas de Markov – *Hidden Markov Model* (HMM) (Tong, Song, Ge, & Liu, 2013) (Tra & Pham, 2013), *k-Nearest Neighbors* (k-NN) (Jian & Chen, 2015), redes neurais artificiais (Nuttaitanakul & Leauhatong, 2015) (Vallejo, Isaza, & López, 2013) (Sengto & Leauhatong, 2012), Máquinas de Vetor de Suporte – *Support Vector Machine* (SVM) (Ye, Li, Zhao, & Liu, 2014) (Shan & Yuan, 2010) (Pierleoni, et al., 2015).

A Tabela 4 apresenta os testes e os resultados obtidos por trabalhos com detecção de quedas cujos classificadores trabalham com aprendizado de máquina. Esses trabalhos estão divididos pelos algoritmos utilizados.

Tabela 4 - Testes e resultados de trabalhos com detecção por aprendizado de máquina.

	Trabalho	Localização dos sensores	Descrição dos testes	Resultados obtidos
Árvores de decisão C4.5	Ojetola, Gaura e Brusey (2011)	No peito	<ul style="list-style-type: none"> • 8 indivíduos; • Simulações em laboratório de AVDs e de quedas para as quatro direções. 	<ul style="list-style-type: none"> • Precisão média dos resultados: 81,82%; • Acurácia média dos resultados: 99,45%;
Lógica Fuzzy	Surana et al. (2013)	No peito	<ul style="list-style-type: none"> • 6 bases de dados. 	<ul style="list-style-type: none"> • Acurácia: 92,66%.
	Putchana et al. (2012)	Na cintura	<ul style="list-style-type: none"> • 5 indivíduos; • Simulação em laboratório de 50 testes envolvendo AVDs e quedas. 	<ul style="list-style-type: none"> • Sensibilidade: 86,6%; • Especificidade: 100%.
HMM	Tong et al. (2013)	Nas costas	<ul style="list-style-type: none"> • Simulação em laboratório de 64 quedas frontais e traseiras, 16 quedas laterais e 40 minutos de AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: <ul style="list-style-type: none"> ○ Sem verificação de orientação: 100%; ○ Com verificação de orientação: 100%. • Especificidade: <ul style="list-style-type: none"> ○ Sem verificação de orientação: 88,75%; ○ Com verificação de orientação: 100%.
Redes Neurais	Nuttaitanakul e Leauhatong (2015)	Na cintura	<ul style="list-style-type: none"> • 150 testes de 10 tipos de atividades, envolvendo quedas e AVDs. 	<ul style="list-style-type: none"> • Precisão média dos resultados: 98,73%.
	Vallejo, Isaza e López (2013)	Na cintura	<ul style="list-style-type: none"> • 381 situações de queda e 429 AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 98,4%; • Especificidade: 98,6%.
	Sengto e Leauhatong (2012)	No peito	<ul style="list-style-type: none"> • 4 indivíduos; • Simulações de quedas nas 4 direções e AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 96,25%; • Especificidade: 99,50%.

	Trabalho	Localização dos sensores	Descrição dos testes	Resultados obtidos
k-NN	Jian e Chen (2015)	Nas costas	<ul style="list-style-type: none"> • 10 indivíduos; • Simulações em laboratório de 170 situações, envolvendo quedas e AVDs. 	<ul style="list-style-type: none"> • Acurácia média dos resultados: 96%.
SVM	Ye et al. (2014)	Na cintura	<ul style="list-style-type: none"> • Monitoramento de 10 idosos para captura de AVDs; • Simulação em laboratório de quedas. 	<ul style="list-style-type: none"> • Acurácia média dos resultados: 97,67%.
	Shan e Yuang (2010)	Na cintura	<ul style="list-style-type: none"> • 5 indivíduos; • Simulações em laboratório de quedas nas 4 direções e AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 100%; • Especificidade: 100%.
	Pierleoni et al. (2015) ⁸	Diversa	<ul style="list-style-type: none"> • 5 indivíduos; • Simulações em laboratório de quedas e AVDs. 	<ul style="list-style-type: none"> • Sensibilidade: 99.3%; • Especificidade: 96%; • Acurácia: 97,7%.

Fonte: Autor.

⁸ Sensors Applications Symposium (SAS), 2015 IEEE, Zadar, p. 1-5, abr. 2015

Mohamed, Choi e Iraqi (2014) revisaram as seguintes abordagens para detecção de quedas através de dispositivos vestíveis:

- Captura de dados com giroscópio biaxial, representando as características através de velocidades guinadas, de rolo ou de arremesso. Nessa abordagem, o método de classificação utilizado é o método Fuzzy;
- Captura de dados com acelerômetro tri axial, representando as características através de vetores de aceleração. Nessa abordagem, os métodos de classificação que podem ser utilizados são o método SVM ou o método Fuzzy.

O método Fuzzy, embora utilizado em algumas abordagens, tem seu uso muito limitado quando utilizado em problemas complexos, de grande dimensão de dados. Quando utilizado puramente, caso o problema possua dezenas de recursos, esse método contribui pouco, quando nada (Duda, Hart, & Stork, 2001).

Delahoz e Labrador (2014) analisaram diversos trabalhos de detecção de quedas utilizando aprendizado de máquina. Entre os algoritmos utilizados, os que apresentaram melhores resultados, utilizados puramente, foram k-NN e árvores de decisão. Segundo citado, a abordagem utilizando árvores de decisão apresenta baixa complexidade, custo de energia e custo de processamento médios, além de ter sido utilizada com a captura de dados realizada através de um acelerômetro axial de um *smartphone*, foco do estudo desse trabalho.

5.3.2.1 Árvores de Decisão

Árvores de decisão são abordagens não paramétricas (não baseadas em suposições sobre distribuições populacionais, mas nos principais padrões encontrados em valores numéricos, descritivos ou booleanos) utilizadas na construção de modelos de classificação (Webb & Copsey, 2011). Elas trabalham com a abordagem de divisão e conquista, onde o problema original é dividido em diversos problemas menores, montando os níveis e nodos da árvore em questão (Witten & Frank, 2005). O modelo da árvore de decisão inicia com um nodo fonte,

do qual partem novas sub árvores, ampliando a gama dos possíveis resultados em forma de uma árvore do tipo *top-down*, ou seja, a árvore tende a crescer de cima para abaixo. Dentro desse contexto, a cada nó montado para árvore, o atributo que se mostrar mais eficiente é o utilizado para expandir novos nós no próximo nível, utilizando como critério o ganho de informação (Quinlan, 1993). Essa avaliação de ganho pode ser obtida através do cálculo da entropia, que segundo Mitchell (1997), caracteriza a impureza de uma coleção arbitrária de exemplos para definir precisamente os ganhos de informação. A entropia de um conjunto de valores S de um determinado atributo pode ser obtido através da fórmula

$$Entropia(S) \equiv -p_{\oplus} \log_2 p_{\oplus} - p_{\ominus} \log_2 p_{\ominus}$$

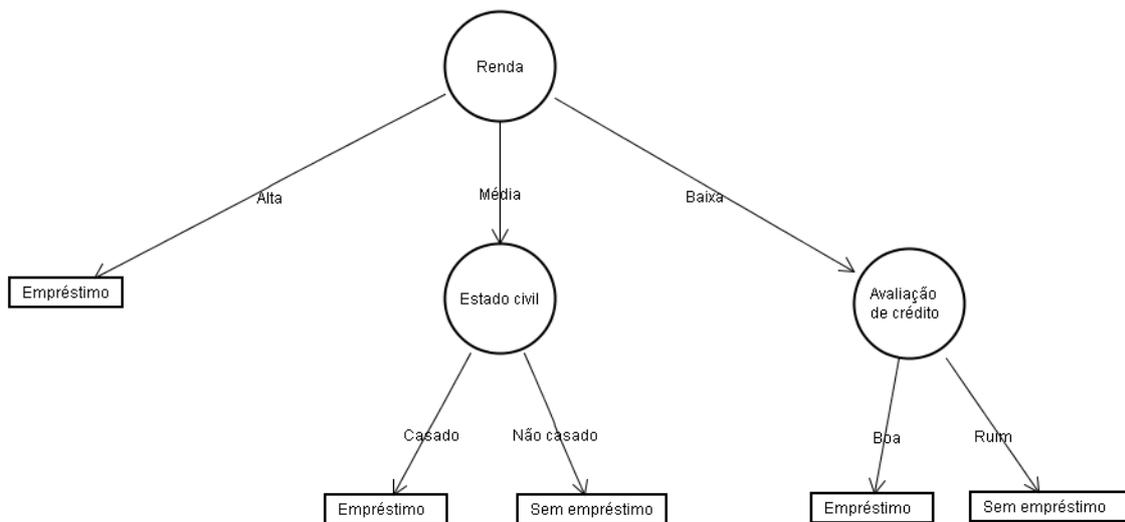
onde p_{\oplus} é o número de exemplos positivos e p_{\ominus} é o número de exemplos negativos do conceito avaliado. Mitchell (1997) também explica que, dada a entropia como o cálculo da impuridade em uma coleção de exemplos de treinos, a informação de ganho atrelada a um atributo na classificação dos dados de treinamento pode ser obtida através da fórmula

$$Ganho(S, A) \equiv Entropia(S) - \sum_{v \in Valores(A)} \frac{|S_v|}{|S|} Entropia(S_v)$$

onde A é o atributo em questão, S são os seus respectivos valores exemplos, $Valores(A)$ são todos os possíveis valores do atributo A e S_v é o subconjunto de S relativo a iteração v do somatório.

Na Figura 18 é exibida uma árvore de decisão para tomada de decisão para liberação de empréstimo, onde a renda, estado civil e avaliação de crédito são os atributos analisados pelo algoritmo, enquanto empréstimo e não empréstimo são as classes de decisão resultantes do reconhecimento realizado. Nesse exemplo, embora existam diversos nodos resultantes nos últimos níveis da árvore, apenas duas classes resultantes foram declaradas. De maneira semelhante, a detecção de quedas também resulta em apenas duas classes, além de também ser facilmente adaptável ao crescimento por níveis com o passar do tempo. A decisão de qual caminho seguir pelos nodos seria realizada de acordo com a aceleração linear encontrada com o decorrer do tempo.

Figura 18 - Exemplo de árvore de decisão para um processo de empréstimo.



Fonte: Adaptado de Webb e Copsey (2011).

Os atributos informados para o algoritmo de aprendizagem podem ser dos tipos quantitativos e qualitativos. Os dados métricos são os dados numéricos, enquanto os dados não métricos são propriedades atribuídas ao determinado atributo, tais como “verdadeiro e falso”, “sim e não”, “ser e não ser”, assim como outras propriedades mais variáveis, tal como o atributo “Estado civil”, que pode apresentar os valores “Casado” ou “Solteiro” (Duda, Hart, & Stork, 2001).

O algoritmo J48 é um dos que apresentam os melhores resultados na montagem de árvores de decisão (Quinlan, 1993). Ele é uma implementação do algoritmo C4.5, adaptado com a revisão 8 deste.

6 METODOLOGIA

Com o objetivo de auxiliar a população com 60 anos ou mais nos eventos de quedas, este capítulo apresenta uma proposta de software de detecção de quedas para *smartphones*. O sistema utiliza os dados retornados pelo acelerômetro tri-axial do *smartphone* para identificação de padrões de quedas, de modo a emitir alertas e pedidos de ajuda no momento em que uma dessas quedas ocorrer.

Este capítulo está organizado da seguinte forma: a Seção 6.1 apresenta o sistema de detecção de quedas, seguida da Seção 6.2 que detalha as bases de dados utilizadas, da Seção 6.3 que demonstra os resultados obtidos pelos testes e da seção 6.4, que explica sobre a aplicação final criada para *smartphones*.

6.1 SISTEMA DE DETECÇÃO DE QUEDAS

O sistema de detecção é responsável por identificar se ocorreu ou não uma queda através dos dados mensurados pelo acelerômetro, passando eles pelo seletor de características e pelos classificadores. O seletor de características recebe os dados do acelerômetro e seleciona as principais informações para posterior análise. Os classificadores recebem os dados do seletor de características, sendo responsáveis por retornar se houve ou não um evento de queda. Quatro classificadores foram desenvolvidos: classificador de inatividade, de quedas por árvores de decisão, por limiares e por orientação.

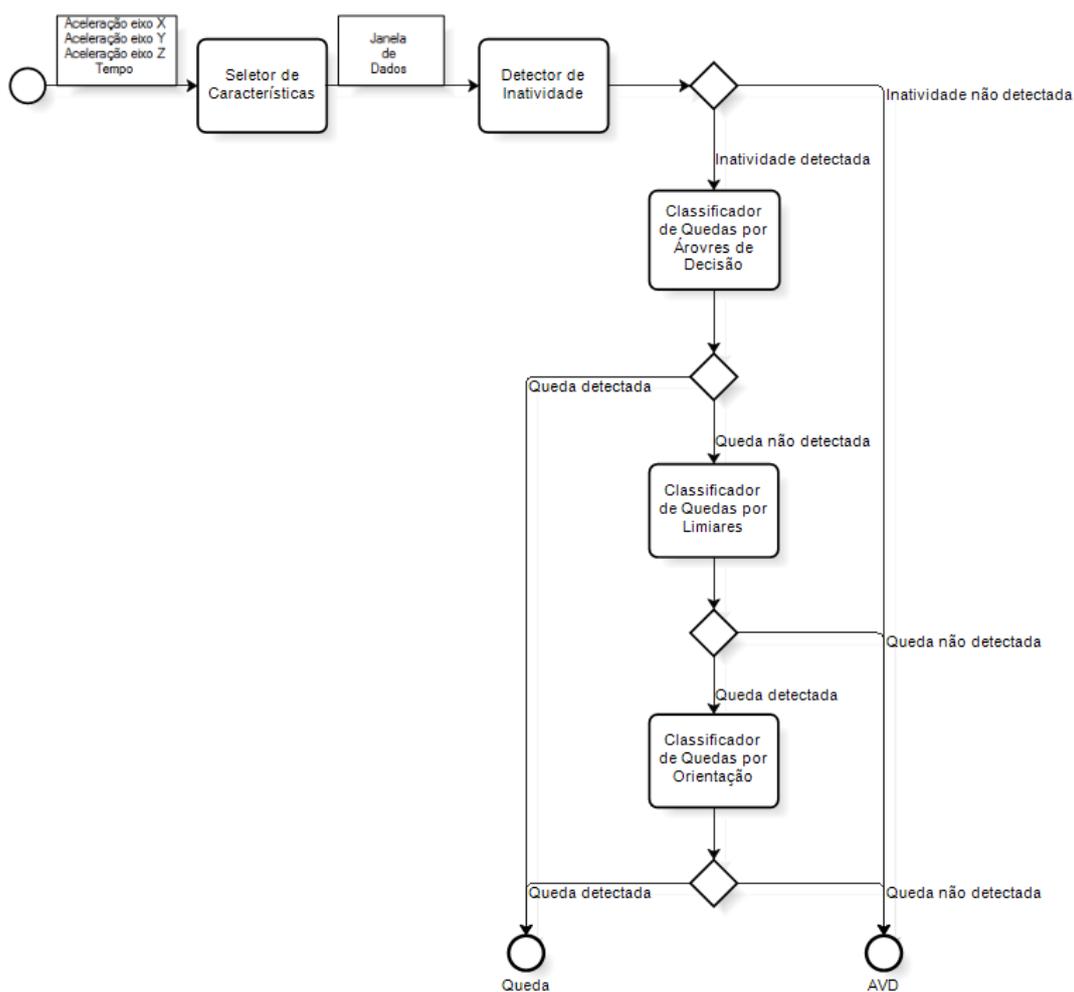
A execução conjunta do classificador de inatividade e dos três classificadores de quedas estudados por esse trabalho, cujo fluxo de execução é exibido na Figura 19, foi combinada para tirar proveito dos resultados individuais para melhora do resultado final. Essa execução consiste nos seguintes passos:

- Primeiramente, através do detector de inatividade, é analisada se a janela de dados possui algum período de inatividade. Se o período

de inatividade for detectado e esse não estiver perdurando por mais de 30 segundos, a execução dos demais classificadores é realizada;

- Tendo detectado um período de inatividade, é executado o classificador por árvores de decisão. Caso esse encontre um padrão de queda, a biblioteca de detecção retorna que uma queda foi detectada, caso contrário são executados os demais classificadores;
- Não tendo o classificador por árvores de decisão detectado uma queda, são executados os classificadores por limiares e por orientação. Caso os dois classificadores reconheçam que uma queda ocorreu, a biblioteca de detecção retorna essa informação, caso contrário retorna que nenhuma queda foi detectada.

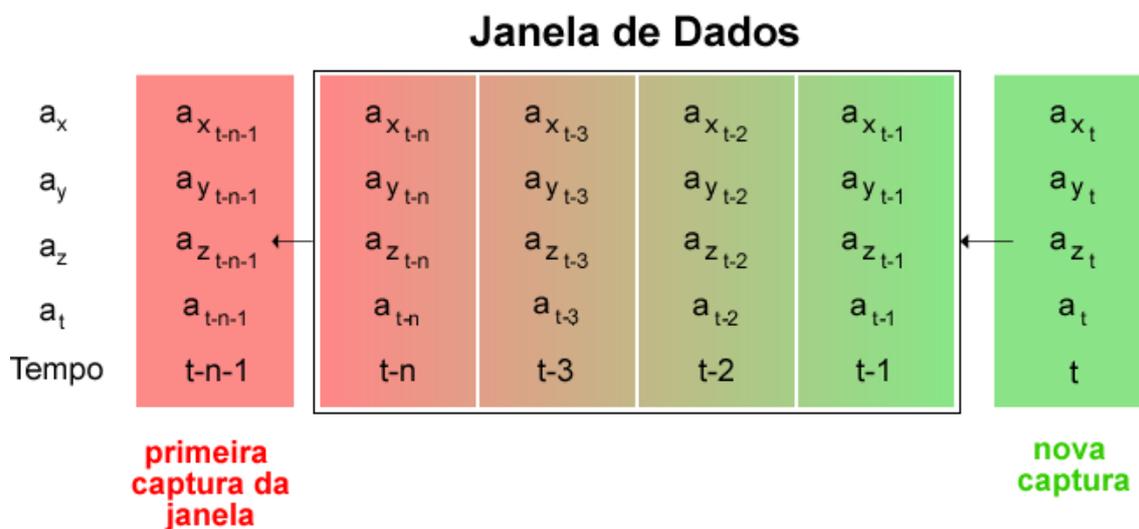
Figura 19 - Fluxo de execução da detecção de quedas.



6.1.1 Seletor de Características

O seletor de características é responsável por estimar as características a serem utilizadas e enviar essas aos classificadores. Nesta etapa, o seletor de características calcula a aceleração linear e a armazena em memória juntamente com as acelerações individuais de cada eixo e o momento exato da captura. A janela de dados a ser analisada foi definida em 10 segundos, em uma formação do tipo “*first in first out*”, ou seja, os dados novos vão substituindo os dados mais velhos que estão na lista, conforme demonstrado na Figura 20.

Figura 20 - Exemplo de janela de dados durante a execução.



Fonte: Autor.

A execução dos classificadores sobre os dados retornados pelo acelerômetro pode ser lenta, dependendo do hardware que estiver processando esses retornos. Por exemplo, a execução dos classificadores utilizados nesse trabalho pode demorar 200ms para ser executada em um hardware robusto, enquanto a mesma execução pode perdurar 750ms quando executados em um hardware mais simples. Para evitar atrasos no processo de detecção de quedas, foi desenvolvida uma regra para decidir a frequência de execução dos

classificadores. O número de amostras $p(f, t)$ entre as quais o sistema deve produzir um resultado pode ser definido por

$$p(f, t) = \begin{cases} 1 & \left(f * \frac{t}{1000}\right) < 1 \\ f * \frac{t}{1000} & 1 < \left(f * \frac{t}{1000}\right) < 13 \\ 13 & \left(f * \frac{t}{1000}\right) \geq 13 \end{cases}$$

onde f é a frequência da taxa de amostragem dos dados coletados e t é o tempo de uma execução de todos os classificadores no dispositivo. O valor máximo de $p(f, t)$ é 13, a fim de evitar que dados sejam perdidos devido a grandes tamanhos da janela de dados utilizada.

6.1.2 Detector de Inatividade

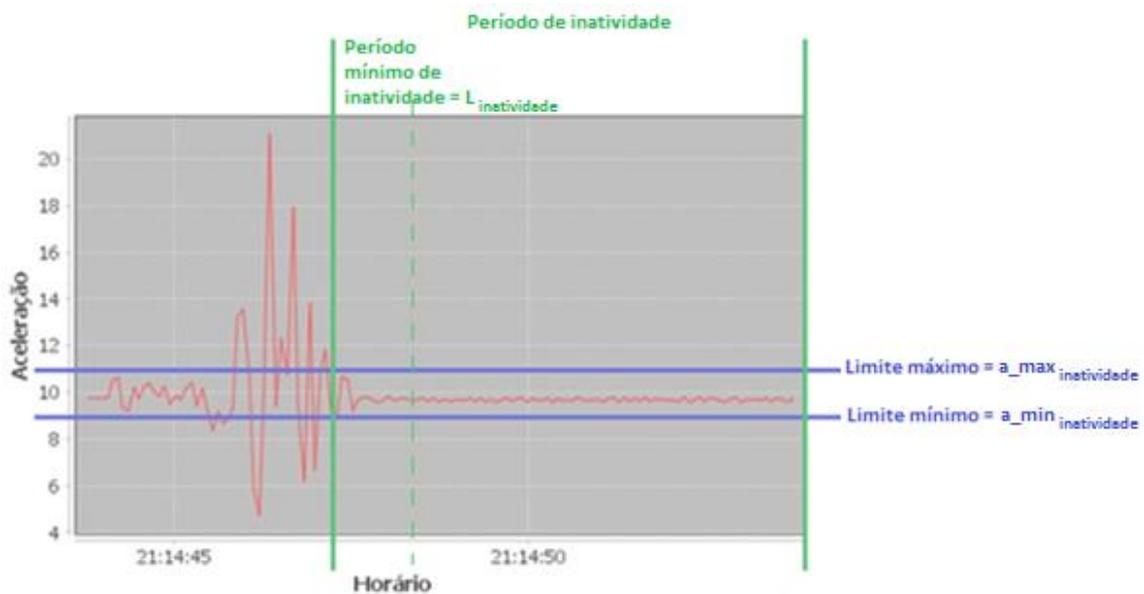
Um padrão das quedas é o período de inatividade presente na fase pós-queda. Seguindo esse padrão, a detecção de inatividade pode ser utilizada como gatilho para que, quando ocorrido um período de inatividade, sejam executados os demais classificadores para confirmar se ocorreu ou não uma queda.

A detecção de inatividade é realizada com base em limiares mínimo ($a_{min_{inatividade}}$) e máximo ($a_{max_{inatividade}}$) para a aceleração linear. A inatividade é detectada quando o sinal da aceleração linear não ultrapassa os limites no período mínimo de tempo ($L_{inatividade}$), conforme exibido na Figura 21. Esse processo de detecção de inatividade pode ser representado pela equação

$$I(t) = \begin{cases} 1 & a_{min_{inatividade}} < a_{t-L_{inatividade}}^t < a_{max_{inatividade}} \\ 0 & \text{caso contrário} \end{cases}$$

onde $a_{t-L_{inatividade}}^t$ corresponde a todas as amostras do intervalo de tempo $[t - L_{inatividade}; t]$. Baseado nos padrões encontrados nas três bases de dados utilizadas para testes, os limites $a_{min_{inatividade}}$ e $a_{max_{inatividade}}$ foram definidos, respectivamente, com 9,5 m/s² e 11,5 m/s² enquanto o limite mínimo de tempo $L_{inatividade}$ foi definido com 1 segundo.

Figura 21 - Exemplo de detecção de inatividade.



Fonte: Autor.

A fim de reduzir o processamento desnecessário de informações, o detector de inatividade é utilizado para definir se os demais classificadores devem ser executados. Quando o dispositivo permanecer em inatividade por um período maior do que 30 segundos, apenas o classificador de inatividade prossegue sendo executado, até que alguma movimentação seguida de inatividade seja detectada. Assim, os demais classificadores não precisarão ser executados quando o dispositivo estiver parado por longos períodos de tempo (por exemplo durante a noite).

6.1.3 Classificador de Quedas por Árvore de Decisão

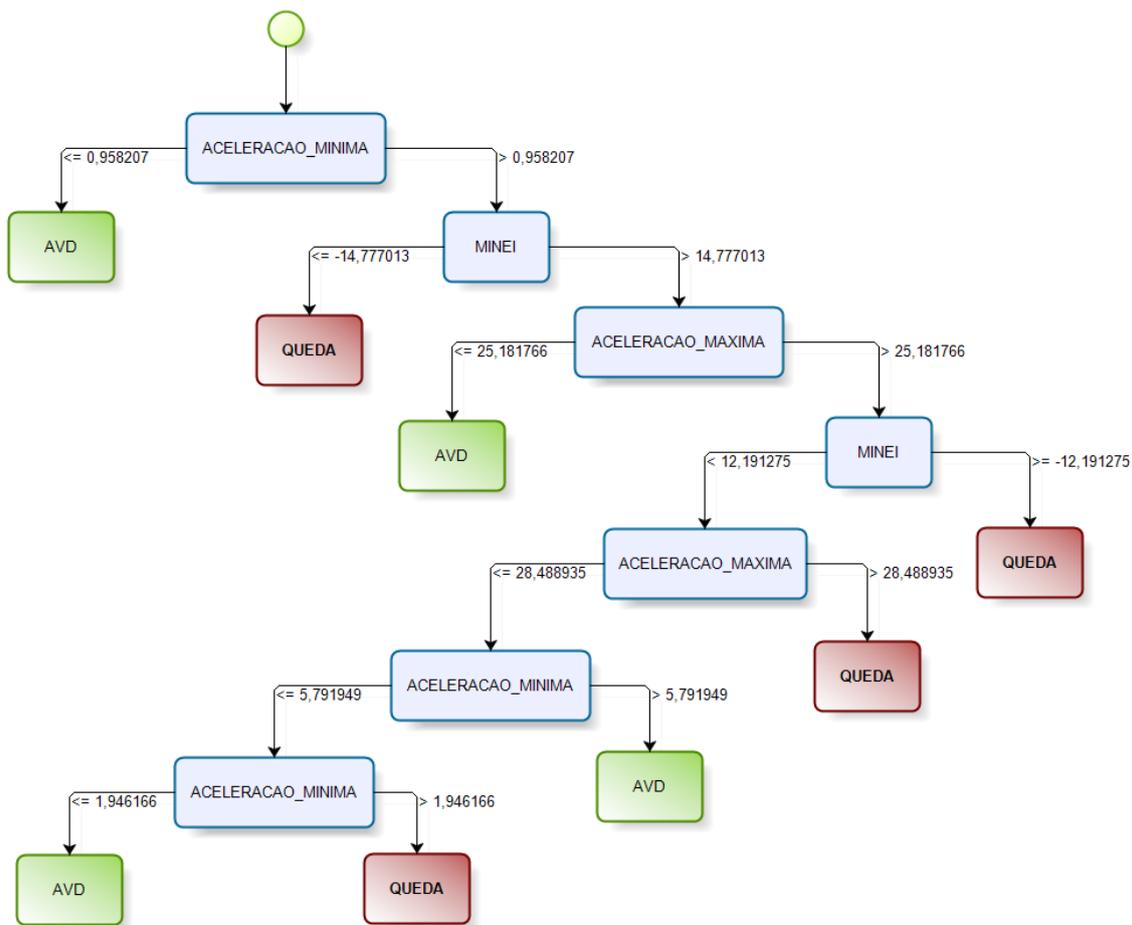
Para implementação do classificador por Árvore de Decisão, foi utilizada a biblioteca *Ambiente Para Análise do Conhecimento Waikato (WEKA)*⁹. Em sua implementação, deve-se informar o modelo de classificação desejado (Árvores de Decisão), o algoritmo (J48), uma base de dados de treinamento e os dados a serem classificados. Ao final do processamento, a probabilidade de ser uma

⁹ Disponível em: <<https://weka.wikispaces.com/>>. Acesso em: mai, 2016.

queda ou AVD é retornada. Como a biblioteca é compilada também em Java, foi facilmente adaptável ao código fonte do sistema de detecção de quedas.

As bases de dados de treinamento e de classificação da árvore de decisão são compostas por $\max a_0^t$ (aceleração máxima encontrada na janela de dados analisada), $\min a_{t-0}^t$ (aceleração mínima encontrada na janela de dados analisada), e $\min (\min a_{x_0}^t, \min a_{y_0}^t, \min a_{z_0}^t)$ (a aceleração individual mínima dos eixos x, y e z). Durante a fase de treinamento, o algoritmo J48 gera uma árvore de decisão, na qual cada nodo pode ser um dos possíveis resultados (“QUEDA” ou “AVD”) ou uma condição (regra) baseada em uma das entradas (atributos) que gera dois possíveis caminhos, conforme o exemplo de árvore de decisão da Figura 22. O conjunto de regras é utilizado para classificar uma entrada nunca antes analisada. Durante a fase de testes, o algoritmo aplica as regras em cada nova entrada a fim de determinar a sua classe.

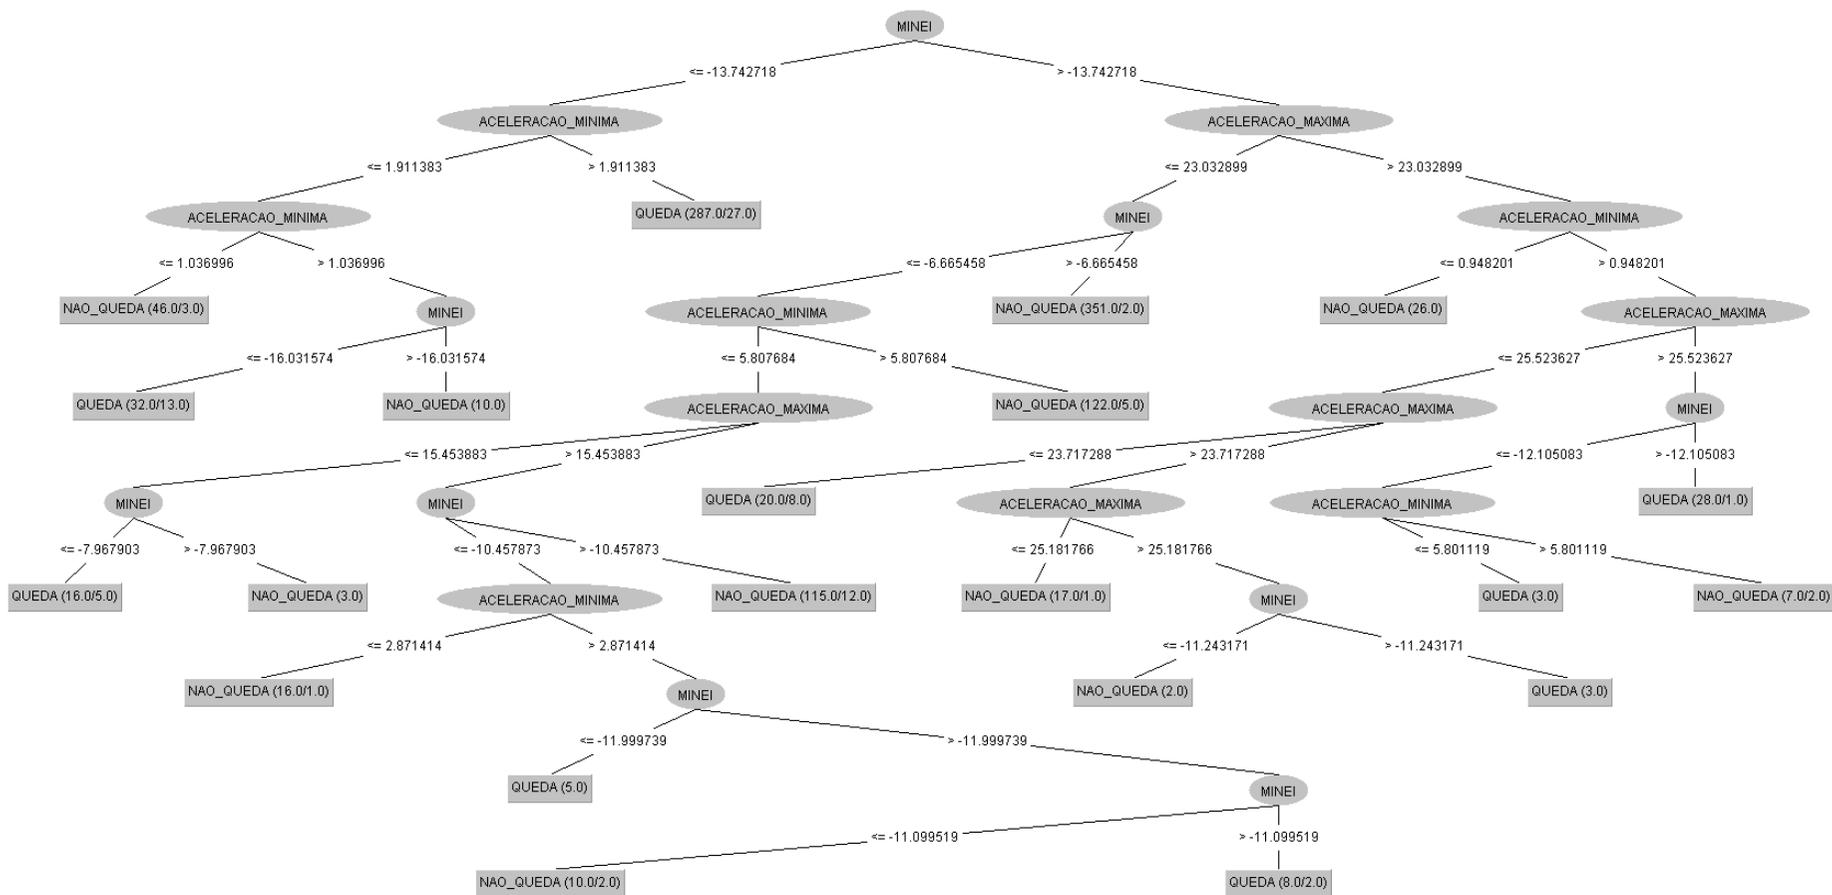
Figura 22 - Exemplo de árvore de decisão montada pelo algoritmo J48.



Fonte: Autor.

Utilizando todas as simulações das três bases de dados utilizadas nesse trabalho, foi montada uma base de treinamento para a versão final do sistema de detecção de quedas. A Figura 23 ilustra a árvore de decisão gerada por essa base de treinamento através da biblioteca WEKA.

Figura 23 - Árvore de decisão gerada pelo algoritmo J48 com todos os testes de todas as bases de dados utilizadas.



Fonte: Autor.

6.1.4 Classificador de Quedas Baseado em Limiares

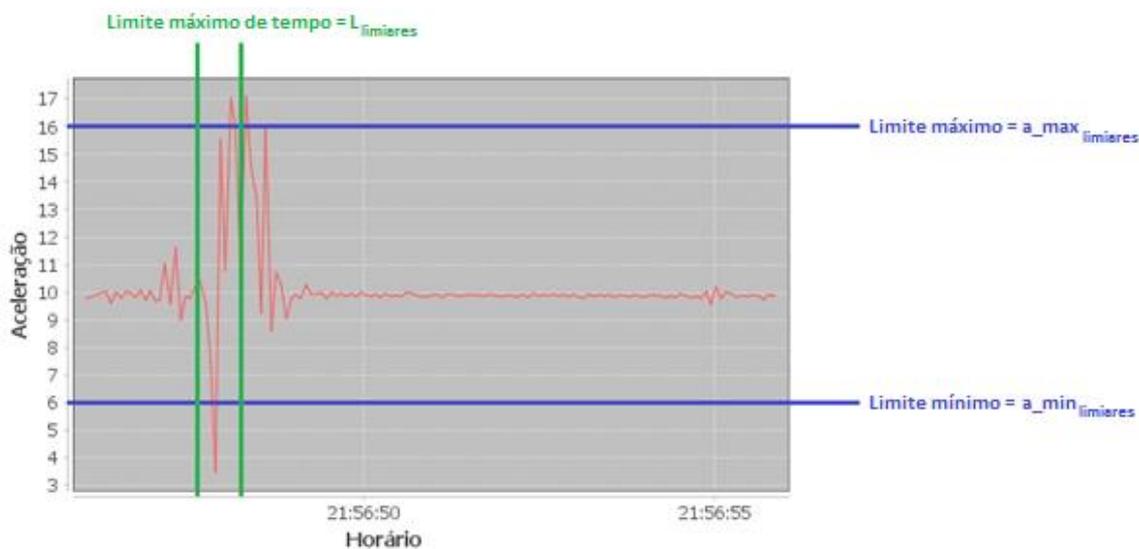
A classificação de quedas utilizando limiares, embora seja uma estratégia simplória, pode-se tornar eficaz para o processo de detecção. Ainda que o classificador por árvores de decisão se mostre bastante eficaz, a verificação de limiares fixos pode reconhecer quedas que as árvores de decisão não reconhecem.

A regra para detecção consiste em definir um limite mínimo ($a_{min_{limiares}}$) e um limite máximo ($a_{max_{limiares}}$) para aceleração linear. Dentro de uma janela de análise, caso esses limites sejam ultrapassados com diferença de tempo inferior a um limite ($L_{limiares}$) entre eles, o classificador retorna que uma queda foi reconhecida. O processo de detecção com essa regra pode ser representado pela seguinte equação

$$L(t) = \begin{cases} 1 & a_{min_{limiares}} < a_{t-L_{limiares}}^t < a_{max_{limiares}} \\ 0 & \text{caso contrário} \end{cases}$$

onde $a_{t-L_{limiares}}^t$ corresponde a todas as amostras no intervalo $[t - L_{limiares}; t]$. Baseado nos padrões encontrados nas três bases de dados utilizadas para testes, esses limites foram definidos com $a_{min_{limiares}}=6$ m/s², $a_{max_{limiares}}=16$ m/s² e $L_{limiares}=700$ ms, cujo uso é ilustrado na Figura 24.

Figura 24 - Exemplo de queda e marcação dos limites de aceleração linear para detecção de quedas.



Fonte: Autor.

6.1.5 Classificador por Orientação

Uma situação que pode ocorrer, embora não seja um padrão em todas as situações, é a alteração da orientação durante a queda. Para a detecção dessa orientação do dispositivo, pode-se analisar a aceleração individual do eixo Y, conforme visto na Figura 25. Pode-se verificar que quanto mais na horizontal o dispositivo estiver, a_{y_t} estará mais próximo de 0 m/s².

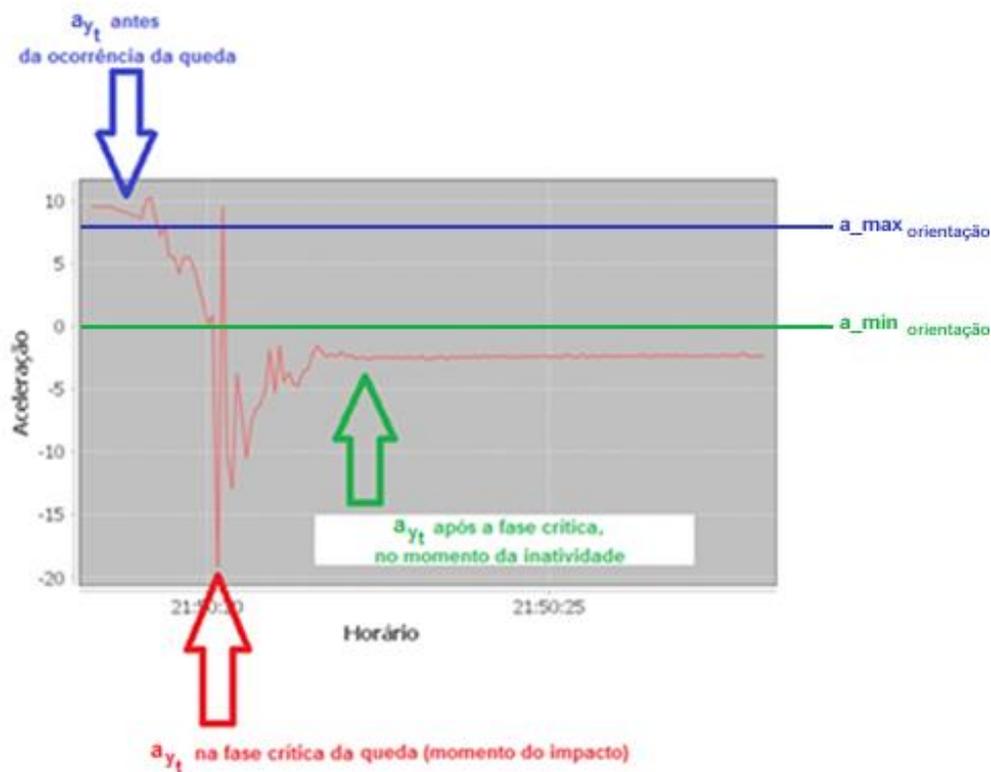
Figura 25 - Valores de aceleração de cada eixo para diferentes posições.

Posição	a_{x_t}	a_{y_t}	a_{z_t}
Para cima: 	0	9.81m/s^2	0
Para esquerda: 	9.81m/s^2	0	0
Para baixo: 	0	-9.81m/s^2	0
Para direita: 	-9.81m/s^2	0	0
Frente para cima: 	0	0	9.81m/s^2
Frente para baixo: 	0	0	-9.81m/s^2

Fonte: Adaptado de Chen (2011).

Na grande maioria das quedas, o dispositivo está na vertical no início da sua ocorrência, alterando para horizontal depois de ocorrência da queda, conforme exemplo ilustrado na Figura 26.

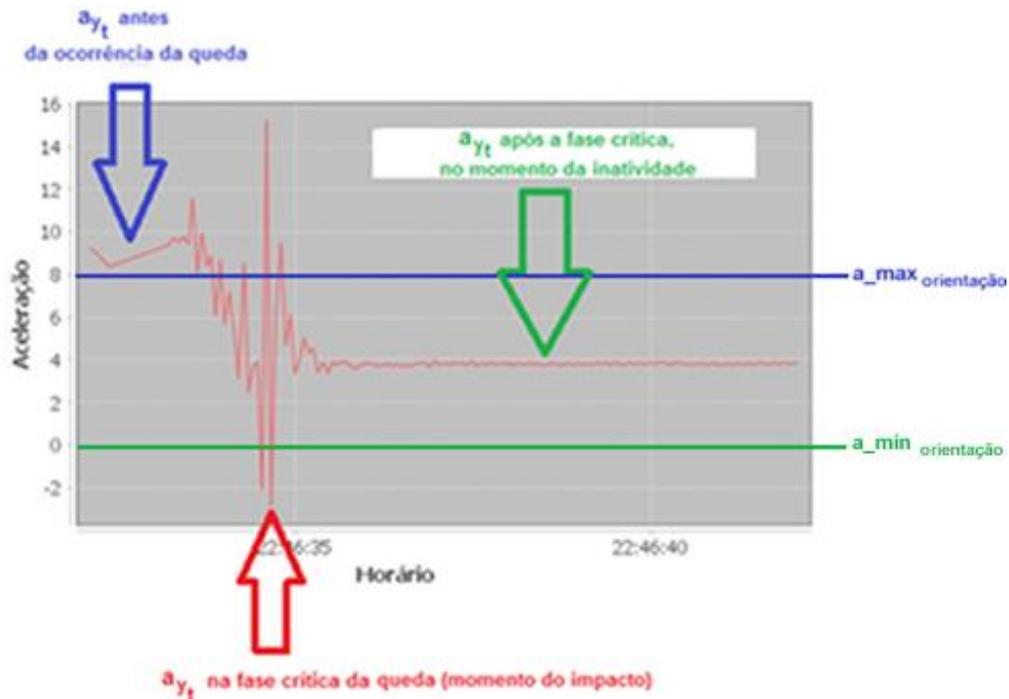
Figura 26 - Exemplo de comportamento de a_{y_t} em situação de queda.



Fonte: Autor.

Após o evento da queda, é possível que o dispositivo fique inclinado (entre horizontal e vertical). A Figura 27 mostra a trajetória de a_{y_t} durante o evento de uma queda. Durante o momento de inatividade, a_{y_t} possui valor em torno de 4. Apesar disso, nota-se que durante a fase crítica, a_{y_t} mínima é sempre inferior a 0 m/s².

Figura 27 - Exemplo de comportamento de a_{y_t} em situação de queda onde a posição resultante do dispositivo foi levemente inclinado na horizontal.



Fonte: Autor.

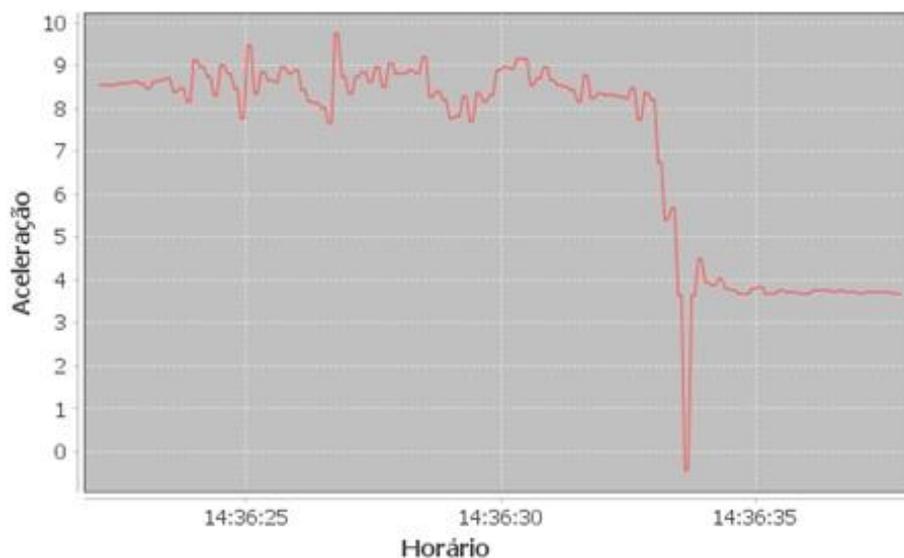
Buscando por um padrão de comportamento, nota-se que quando ocorre uma queda, a_{y_t} indica que o dispositivo está na vertical (maior que $a_{max_orientacao}$), passando para horizontal no momento da fase crítica (menor do que $a_{min_orientacao}$). Dessa forma, a detecção pode ser representada pela seguinte equação

$$O(k) = \begin{cases} 1 & a_{max_orientação} < a_{y_{t-Li_orientação}}^t \text{ e } a_{min_orientação} > a_{y_{t-Lf_orientação}}^t \\ 0 & \text{caso contrário} \end{cases}$$

onde $a_{t-Li_orientação}^t$ corresponde a todas as amostras no intervalo de tempo $[t - Li_orientação; t]$ e $a_{t-Lf_orientação}^t$ corresponde a todas as amostras no intervalo $[t - Lf_orientação; t]$. Com esse método, as únicas situações reconhecidas como falso-positivos foram as de sentar-se e deitar-se, onde a alteração da orientação do dispositivo também ocorreu. Um exemplo dessa situação pode ser visto na Figura 28, onde uma ação um pouco mais brusca do idoso ao sentar-se em uma cadeira teve um comportamento semelhante ao de uma queda. Baseado nessa

regra e em testes realizados com as bases de dados estudadas, os limites foram definidos com $a_{max_{orientacao}}=8 \text{ m/s}^2$ e $a_{min_{orientacao}}=0 \text{ m/s}^2$.

Figura 28 - AVD com a_{y_t} semelhantes às de uma queda.



Fonte: Autor.

6.2 BASES DE DADOS

O estudo dos padrões e a avaliação da qualidade da detecção de quedas e de AVDs do sistema proposto foi realizada utilizando duas bases de dados disponíveis na internet (MobiFall e MobiFall 2) e outra coletada para este trabalho (Base Própria).

6.2.1 MobiFall

A base de dados MobiFall (Vavoulas, Pediaditis, Spanakis, & Tsiknakis, 2013) consiste em uma série de AVDs e de simulações de quedas. Os dados foram extraídos do acelerômetro e do giroscópio de um *smartphone* Samsung Galaxy S3, localizado bolso das calças, com amostragem de 87Hz. Fizeram parte da extração de dados 11 voluntários com idade entre 22 e 32 anos, altura entre 1,69 e 1,89 metros e peso entre 50 e 90 quilogramas. Desses 11

voluntários, 9 simularam AVDs e quedas, enquanto 2 deles simularam apenas quedas.

A base possui dados de acelerometria de 132 quedas e 317 AVDs simuladas. Dentre todos os movimentos cujas acelerações foram coletadas, a base contempla 13 categorizações de quedas e AVDs, como mostra a Tabela 5.

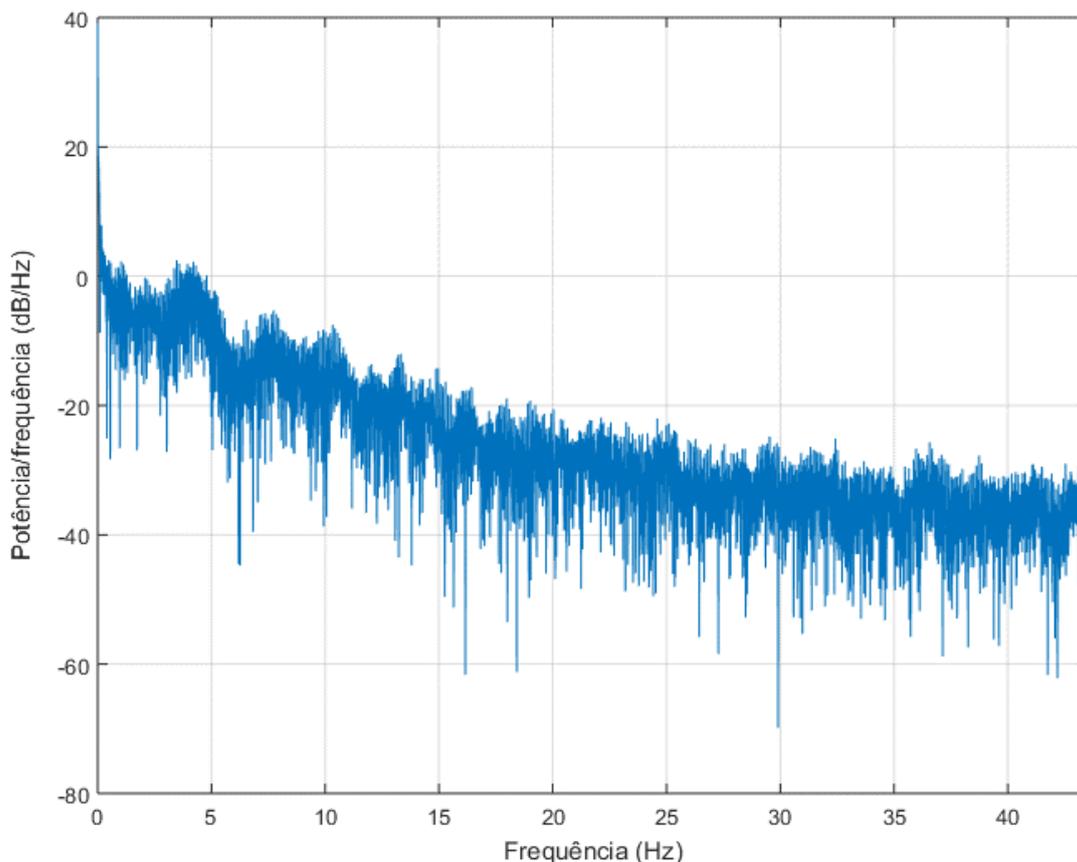
Tabela 5 - Situações simuladas pela base de dados MobiFall.

AVDs	Em pé (com movimentos sutis)
	Caminhada normal
	Movimentar-se
	Salto contínuo
	Subir escadas com 10 degraus
	Descer escadas com 10 degraus
	Sentar em uma cadeira
	Entrar em um carro
	Descer de um carro
Quedas	Para frente, amortecendo a queda com as mãos
	Para frente sobre os joelhos
	Para trás, ao tentar sentar em uma cadeira
	Lateral, dobrando as pernas

Fonte: Autor.

A fim de garantir as mesmas condições para todas as bases, a taxa de amostragem dos sinais dos acelerômetros foi reduzida para 15 Hz. Avaliando a distribuição das potências do sinal em cada frequência (ilustrada pela densidade espectral de potência no Gráfico 8), pode-se verificar que as frequências relevantes da aceleração linear se concentram abaixo de 5 Hz. Além disso, a redução da taxa de amostragem reduz o custo computacional no processamento do sinal coletado.

Gráfico 8 - Densidade Espectral de Potência da aceleração linear



Fonte: Autor.

6.2.2 MobiFall 2

A base de dados MobiFall 2 (Vavoulas, Pediaditis, Chatzaki, Spanakis, & Tsiknakis, 2016), assim como a sua primeira versão MobiFall, também consiste em uma série de AVDs e de simulações de quedas. O dispositivo, localização do dispositivo, sensores e taxa de amostragem são os mesmos da base de dados MobiFall. Os sujeitos cujas acelerações foram coletadas foram 31 voluntários com idade entre 22 e 47 anos, altura entre 1,60 e 1,89 metros e peso entre 50 e 103 quilogramas. Desses voluntários, 16 simularam AVDs e quedas, enquanto 15 deles simularam apenas quedas. Dentre todos os movimentos cujas acelerações foram coletadas, a base contempla as mesmas 13 categorizações descritas na base MobiFall.

Pelas mesmas razões pelas quais a base de dados MobiFall teve de ter sua taxa de amostragem reduzida, o mesmo ajuste foi realizado na fase MobiFall

2. Além desse ajuste, visando manter um padrão das bases de dados analisadas, foram removidas todas as capturas de quedas que não possuíam um período de inatividade após o impacto, restando 173 das 241 simulações de quedas originais da base. Além das simulações de quedas, a base conta também com 321 simulações de AVDs.

6.2.3 Base própria

Uma base de dados foi construída com os sinais do acelerômetro de um *smartphone* LG Optimus L5, preso na lateral da cintura, com taxa de amostragem de 15Hz. A coleta foi realizada dividindo as simulações exibidas na Tabela 6 em duas categorias: quedas e AVDs.

Tabela 6 - Situações simuladas pela base de dados própria.

AVDs	Sentar em uma cadeira
	Levantar de uma cadeira
	Deitar em uma cama
	Levantar de uma cama
	Subir um degrau
	Descer um degrau
	Subir uma escada com vários degraus
	Descer uma escada com vários degraus
	Caminhar
Quedas	De pé para frente
	De pé para trás
	De pé para direita
	De pé para esquerda
	Sentado para esquerda
	Sentado para direita

Fonte: Autor.

Para coleta de dados participaram quatro voluntários jovens para a simulação de quedas e de AVDs e quatro voluntários com idade superior a 60

anos para a simulação de AVDs. Os dados demográficos de cada sujeito estão descritos na Tabela 7.

Tabela 7 - Voluntários da base de dados própria.

Sujeito	Idade (anos)	Peso (quilogramas)
Sujeito 1	14	48
Sujeito 2	21	52
Sujeito 3	23	65
Sujeito 4	51	62
Sujeito 5	80	66
Sujeito 6	74	84
Sujeito 7	63	50
Sujeito 8	70	105

Fonte: Autor.

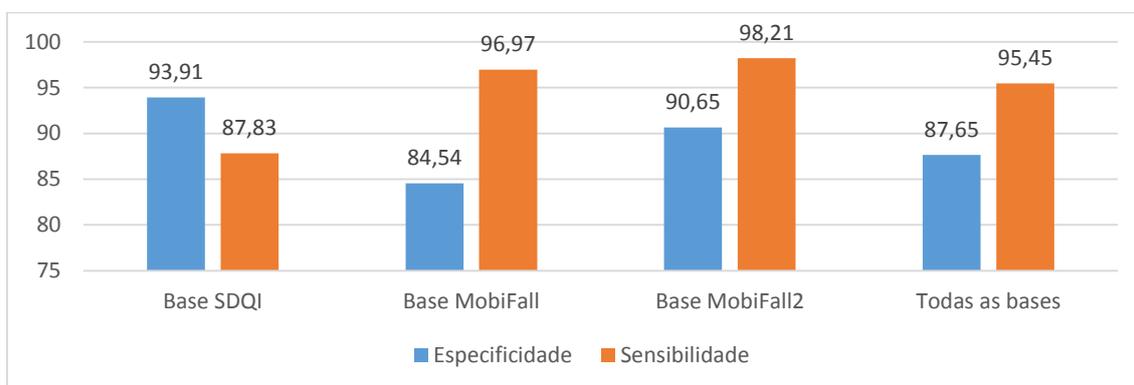
Um aplicativo para *smartphone* foi desenvolvido para a coleta dos sinais do acelerômetro. Esse aplicativo inicia a captura ao pressionar o botão presente nos fones de ouvido do *smartphone*. Ao pressionar novamente, a aplicação interrompe a captura e salva um arquivo com as acelerações mensuradas e o respectivo horário. Através dessa aplicação, cada tipo de simulação foi coletado três vezes. Essas coletas foram realizadas aleatoriamente, ou seja, a sequência de execução das atividades era intercalada, a fim de evitar vícios nas atividades. Além disso, após cada teste simulado, seja AVD ou queda, foram simulados 5 segundos de inatividade antes de interromper a captura pelo aplicativo. Em resumo, a base contém 74 simulações de quedas e 115 simulações de AVDs.

6.3 EXPERIMENTOS E RESULTADOS

A fim de demonstrar a eficiência do processo de detecção e de comprovar a meritocracia da abordagem utilizada, foram realizados testes com o método de detecção de quedas desenvolvido com base nas três bases de

dados citadas. Os testes do detector de quedas avaliaram todas as amostras das três bases de dados utilizadas, sequencialmente. Os testes foram realizados por base de dados, sendo que o treinamento da árvore de decisão utilizava os dados das bases que não estavam sendo testadas. Os resultados desses testes são exibidos na Gráfico 9, onde com todas as bases de dados juntas a detecção encontrou sensibilidade de 95,45% e especificidade de 87,65%.

Gráfico 9 - Desempenho do Detector de Quedas.



Fonte: Autor.

Além dos testes finais do sistema de detecção de quedas desenvolvido, foram realizados testes individuais com cada um dos classificadores de quedas: por inatividade, por árvores de decisão, por limiares e por orientação. A Tabela 8 apresenta os resultados de cada classificador por base de dados. O desempenho do sistema proposto é melhor dos desempenhos individuais, exceto na base de dados MobiFall. Nessa, o resultado que apresentou maior acurácia do classificador de quedas por árvores de decisão. A diferença de precisão dos sensores presentes nos dispositivos utilizados para captura de dados que constituíram cada uma das bases pode ser responsável pela diferença entre os resultados encontrada, de modo que o processo de detecção foi desenvolvido para ser capaz de detectar o padrão mais abrangente, que seja capaz de encontrar bons resultados para os mais diversos *smartphones* existentes.

Tabela 8 – Acurácias de todos os classificadores de detecção de quedas por base de dados. A última coluna apresenta o desempenho do sistema utilizando todos os classificadores.

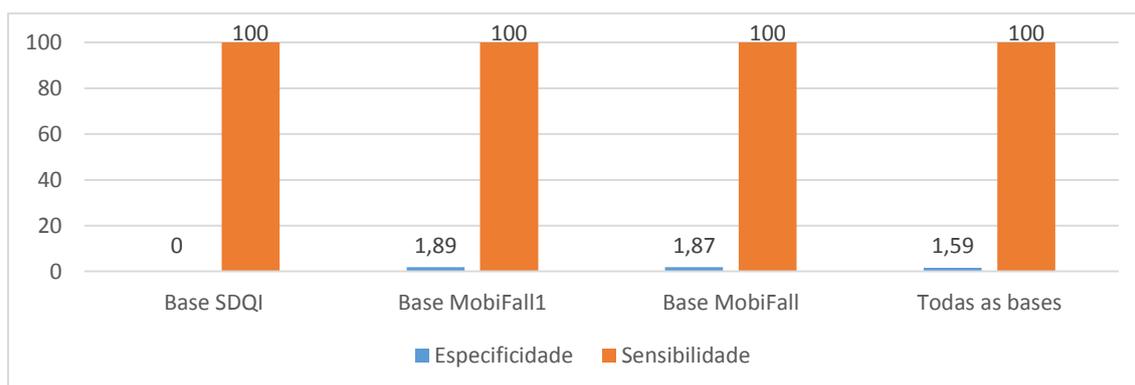
	Classificador de inatividade	Classificador por Árvores de Decisão	Classificador por Limiares	Classificador por Orientação	Todos os Classificadores
SDQI	0,34	85,27	28,22	72,67	90,24
MobiFall	39,15	95,77	67,72	87,30	91,53
MobiFall2	30,73	86,85	66,59	67,71	88,19
Todas	35,58	91,00	56,85	71,57	93,25

Fonte: Autor.

6.3.1 Resultados do Classificador de Quedas por Inatividade

Uma hipótese que foi avaliada é de que um período de inatividade ocorre após uma queda. Assim, analisamos a possibilidade de utilizar o detector de inatividade como um detector de queda. Isto é, o sistema retornaria que houve uma queda toda vez que um período de inatividade fosse detectado. O Gráfico 10 mostra o desempenho deste detector de quedas.

Gráfico 10 – Desempenho do Classificador de Quedas baseado no Detector de Inatividades.



Fonte: Autor.

Os resultados mostram que o detector de inatividade não é suficiente para estimar se houve uma queda. Como a inatividade está presente em quase

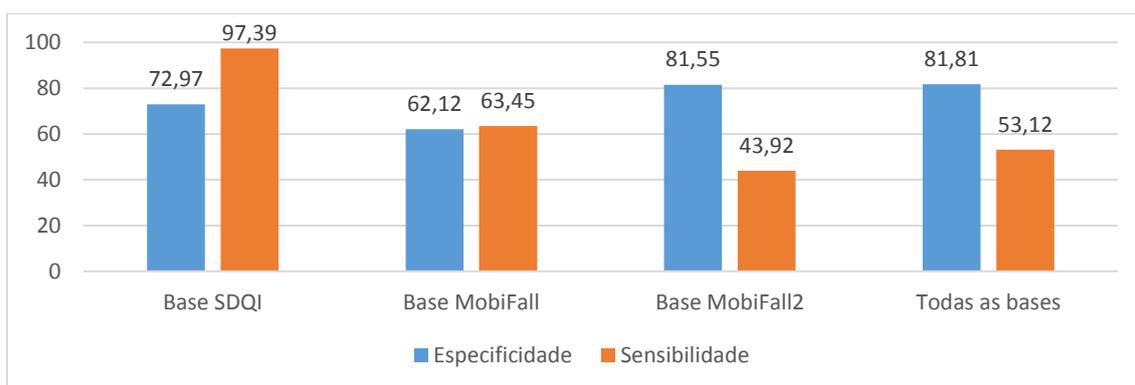
todas as simulações das bases de testes, por se tratarem de testes realizados em laboratório, a especificidade encontrada nos testes não passou de 2%.

Apesar da detecção de inatividade não ser suficiente para reconhecer se uma queda ocorreu, a sua execução pode ser utilizada para reduzir o processamento do sistema. Por exemplo, o sistema pode desabilitar o processamento dos demais classificadores quando o dispositivo se encontrar imóvel por mais do que um determinado intervalo de tempo, já que a execução dos mesmos representaria apenas processamento desnecessário.

6.3.1 Resultados do Classificador de Quedas por Limiares

O classificador de quedas por limiares apresentou maior discrepância entre a especificidade e a sensibilidade encontrada nos testes realizados em três das quatro bases utilizadas. De acordo com os resultados exibidos no Gráfico 11, o uso desse classificador, individualmente, não apresenta resultados tão precisos quanto aos do classificador por árvores de decisão. Por outro lado, esse classificador é uma alternativa para melhora da especificidade quando utilizado no fluxo de execução proposto pelo detector de quedas aqui apresentado.

Gráfico 11 – Desempenho do Classificador de Quedas Baseado em Limiares.

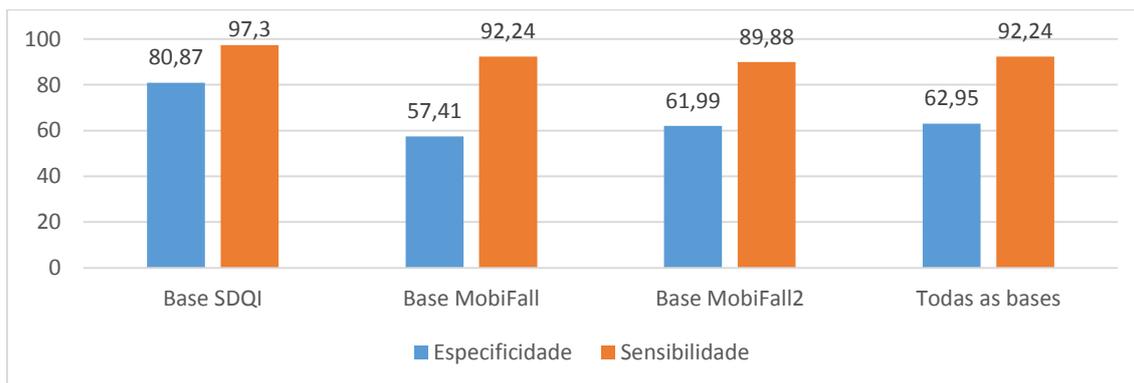


Fonte: Autor.

6.3.2 Resultados do Classificador de Quedas por Orientação

O classificador de quedas por orientação obteve altos níveis de sensibilidade nos testes executados, mas ao mesmo tempo também obteve baixos níveis de especificidade em algumas das bases de dados utilizadas, conforme os resultados mostrados no Gráfico 12. Da mesma forma como o classificador de quedas por limiares, o classificador por orientação não é suficiente para a detecção de quedas, mas pode apresentar melhora no resultado final do processo de detecção de quedas quando executado em conjunto com o classificador por limiares, de acordo com o fluxo proposto para o detector aqui apresentado.

Gráfico 12 – Desempenho do Classificador de Quedas por Orientação.



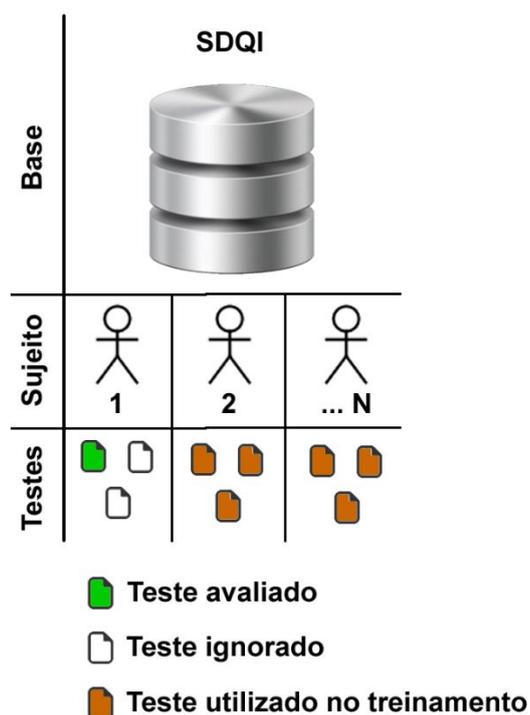
Fonte: Autor.

6.3.3 Resultados do Classificador de Quedas por Árvores de Decisão

Diferente dos classificadores de quedas por inatividade, por limiares e por orientação, o classificador de quedas por árvores de decisão necessita de treinamento com base em dados previamente coletados. Nos testes envolvendo apenas uma base, foram utilizados como base de treinamento dados (AVDs e quedas) de todos os sujeitos diferentes do que está sendo avaliado, descartando todos os dados do sujeito cujas simulações estão sendo avaliadas, conforme

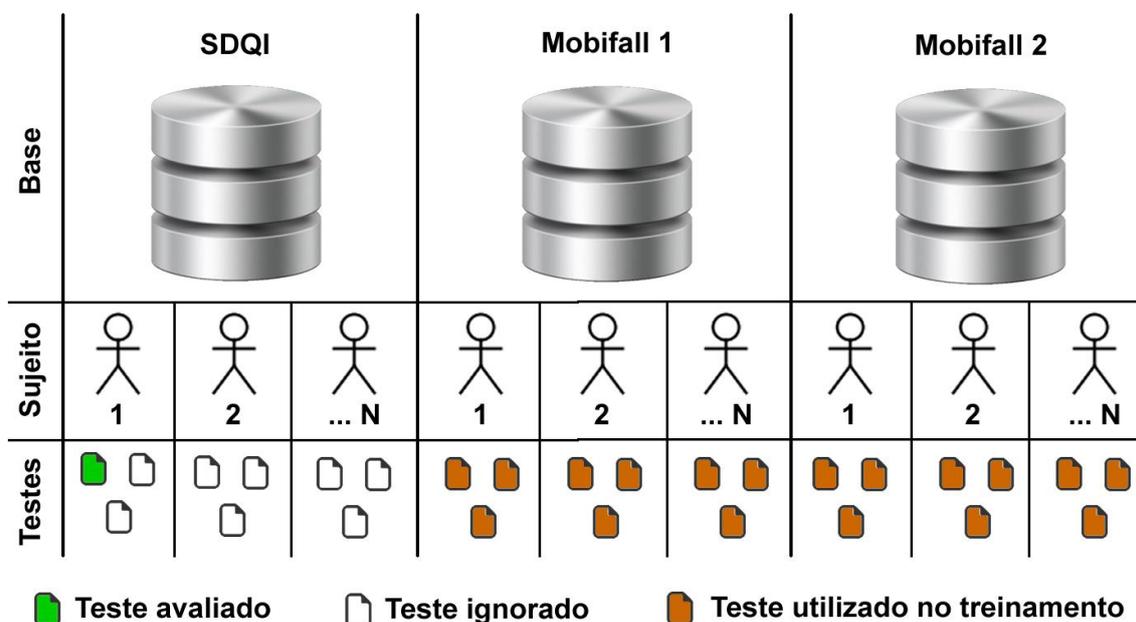
exibido na Figura 29. Já nos testes envolvendo todas as bases de dados, os dados de sujeitos de todas as outras bases diferentes da do sujeito que está sendo avaliado foram utilizadas para constituir a base de treinamento, descartando toda a base de dados do sujeito cujas ações estavam sendo avaliadas, conforme exibido na Figura 30.

Figura 29 - Exemplo de seleção de dados para base de treinamento da árvore de decisão para uma base.



Fonte: Autor.

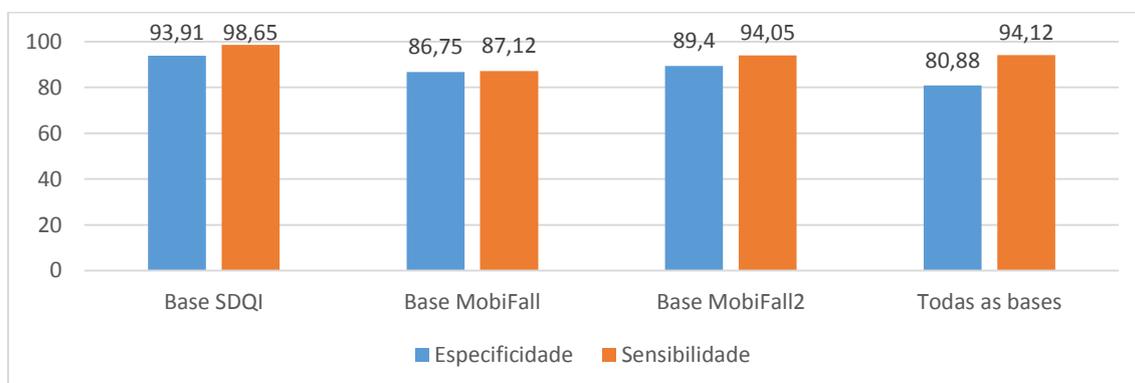
Figura 30 - Exemplo de seleção de dados para base de treinamento da árvore de decisão para mais de uma base.



Fonte: Autor.

O classificador de quedas por árvores de decisão apresentou os resultados ilustrados no Gráfico 13. Esse classificador apresentou altos níveis de especificidade e de sensibilidade. Se comparados aos resultados do detector de quedas final, percebe-se que existe como aperfeiçoar esses resultados através do uso dos demais classificadores propostos nesse trabalho.

Gráfico 13 – Desempenho do Classificador de Quedas por Árvores de Decisão.



Fonte: Autor.

6.3.4 Trabalhos relacionados com as bases de dados utilizadas

Os resultados encontrados podem ser comparados com outros estudos de detectores de quedas que utilizaram as mesmas bases de dados em suas avaliações.

Assim como nesse trabalho, diversos trabalhos utilizaram a base de dados MobiFall. A Tabela 9 mostra resultados encontrados por técnicas de detecção de quedas na MobiFall listados por Pediadtis et al. (2013). A especificidade obtida nos estudos listados foi próxima ou superior a especificidade do detector de quedas SDQI (84,54%). Apesar disso, o SDQI obteve uma sensibilidade maior (96,97%) do que todos os métodos listados. Isto é, os sistemas listados prezam a especificidade (proporção de AVDs reconhecidas corretamente como AVDs) em detrimento da sensibilidade (proporção de quedas reconhecidas corretamente como quedas). Entretanto, temos que levar em conta que o SDQI utiliza múltiplas informações para decidir a classe.

Tabela 9 – Comparativo entre os resultados apresentados por Pediadtis et al. (2013) e pelo detector de quedas apresentado.

Autores	Sensibilidade	Especificidade	Técnica
Sposaro and Tyson	55%	100%	Verificação da aceleração vertical
Dai et al.	39%	100%	Limiar de diferença de aceleração linear entre aceleração mínima e máxima
He et al.	71%	84%	Limiares mínimos e máximos de sinal de magnitude
SDQI	96,97%	84,54%	Limiares de aceleração linear, orientação e árvores de decisão.

Fonte: Autor.

Figueiredo e Leal (2016) apresentam níveis de sensibilidade e especificidade pouco superiores aos encontrados pelo nosso estudo, conforme mostra a Tabela 10. Rashidpour et al. (2016) também encontraram resultados superiores, com 100% de sensibilidade e de especificidade utilizando redes neurais artificiais e lógica Fuzzy, mas tiveram seus resultados baseados em uma

única base de dados, de modo que o detector foi adaptado apenas para a detecção de quedas nessa base. Deve-se levar em consideração que o SDQI teve seus limiares de aceleração e de orientação baseados em 3 bases de dados distintas, com objetivo de ser um sistema de detecção genérico, cuja execução funcione em diferentes hardwares.

Tabela 10 - Resultados apresentados por Figueiredo e Leal (2016).

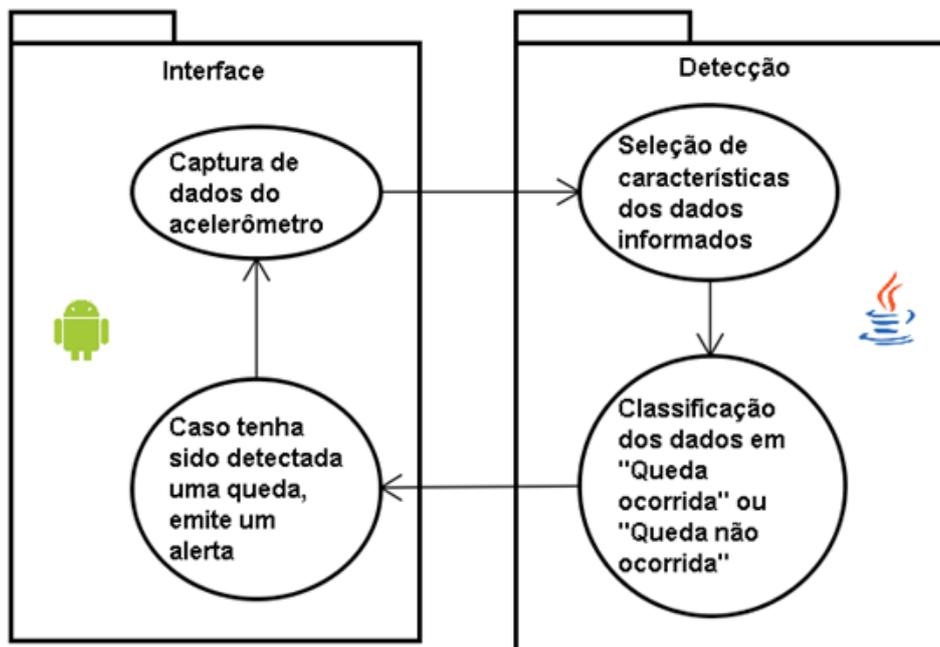
Características	Sensibilidade	Especificidade
Aceleração linear	100%	85,96%
Aceleração linear e ângulos de orientação	100%	86,26%
Aceleração linear e retornos do giroscópio	100%	87,72%

Fonte: Autor.

6.4 APLICATIVO DE DETECÇÃO DE QUEDAS PARA SMARTPHONE

A aplicação consiste em capturar os dados do acelerômetro, enviar para o detector de quedas e emitir um alerta caso o detector reconheça uma queda. A estrutura da aplicação e do detector de quedas em dois projetos, ilustrada na Figura 31, permite que o projeto de detecção seja utilizado em outros sistemas, desde que a linguagem de programação utilizada permita integração com aplicações Java. Desse modo, o desenvolvimento de uma nova aplicação para outro sistema operacional implicaria apenas em refazer o projeto Interface, necessitando apenas da reprogramação da captura de dados do acelerômetro e da emissão de alertas, funcionalidades específicas de cada sistema operacional.

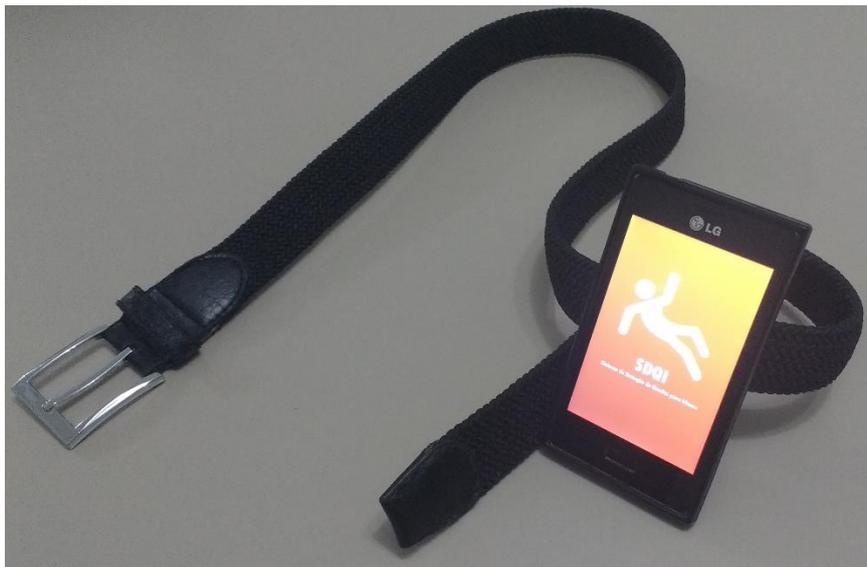
Figura 31 - Estrutura básica da aplicação em dois projetos.



Fonte: Autor.

Quanto ao posicionamento do sensor, o sistema foi desenvolvido para que o *smartphone* seja preso na cintura do usuário (conforme protótipo demonstrado na Figura 32), como na maioria dos trabalhos relacionados apresentados. Além disso, entende-se que os pontos do corpo que apresentam menor mobilidade durante AVDs e maior mobilidade durante quedas são o peito, costas e cintura. A escolha de utilizar o *smartphone* na cintura se dá pela praticidade quando comparado à utilização de uma cinta para prendê-lo nas costas ou no peito, o que exigiria maior flexibilidade do idoso, além de poder gerar incômodo.

Figura 32 - Dispositivo utilizado na captura de dados para montagem da base de dados SDQI adaptado a um cinto.



Fonte: Autor.

O sistema para demonstração do detector de quedas foi desenvolvido para sistemas operacionais Android, atualmente predominantes em 82,8% dos *smartphones* disponíveis no mercado (IDC - International Data Corporation, 2015). O sistema é voltado para versão 4.0 ou superior, que está em circulação em *smartphones* no mercado desde o final do ano de 2011 e início de 2012. Com o sistema operacional proposto, o hardware deve possuir um acelerômetro tri axial, e ao menos um meio de comunicação disponível para emissão de alertas, o qual pode ser:

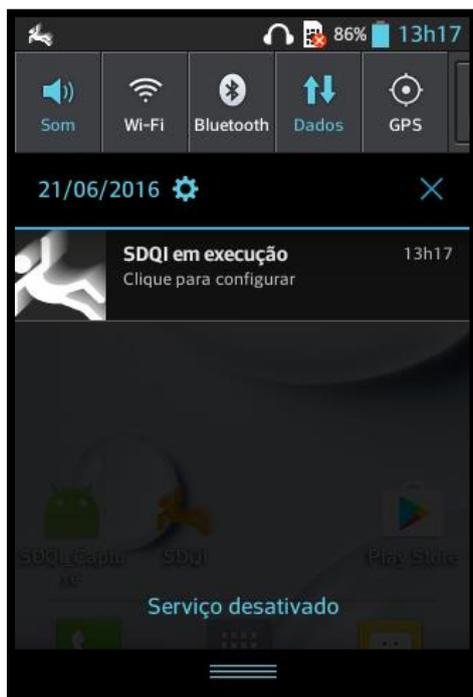
- Conexão de dados móveis com internet (3G, 4G, entre outros);
- Conexão com internet via wireless;
- Serviço de telefonia ativo com pacote de mensagens.

6.4.1 Interface Gráfica e Configurações

A captura de dados é simples, já que basta que a aplicação inicie a comunicação com o acelerômetro e receba esses dados. Com os dados em memória, esses são enviados para detector de quedas e, caso seja retornado

que uma queda ocorreu, inicia o processo de emissão de alerta. Até o momento em que um alerta é emitido, a execução da aplicação ocorre em segundo plano, exibindo apenas um item na lista de notificações do sistema, semelhante a notificação de mensagens recebidas, exibida na Figura 33.

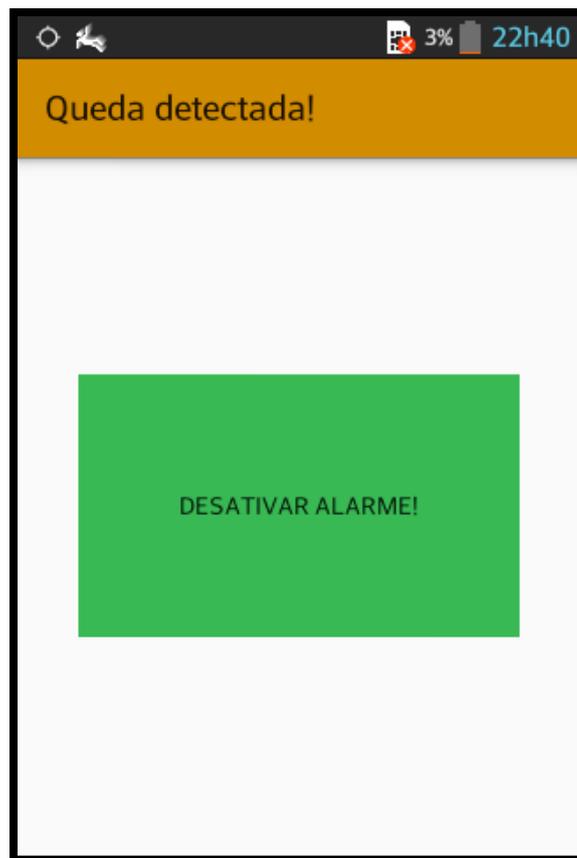
Figura 33 – Exemplo de notificação exibida em tela.



Fonte: Autor.

No momento que uma queda é detectada, uma tela de aviso é exibida, contendo apenas o título “Queda detectada!” e um botão grande com a descrição “Desativar alarme”, cuja tela é ilustrada na Figura 34. Essa tela permanece exibida por um minuto, emitindo um sinal sonoro no momento da sua abertura. Caso não seja pressionado o botão, o alerta é emitido e o sistema volta a capturar os dados em segundo plano.

Figura 34 - Tela de queda detectada



Fonte: Autor.

À parte do fluxo normal da aplicação, tem-se uma tela de configuração, com finalidade de selecionar as opções de execução desejadas. Essa tela será exibida quando selecionado o item na lista de notificações do sistema operacional e deverá constar os seguintes itens:

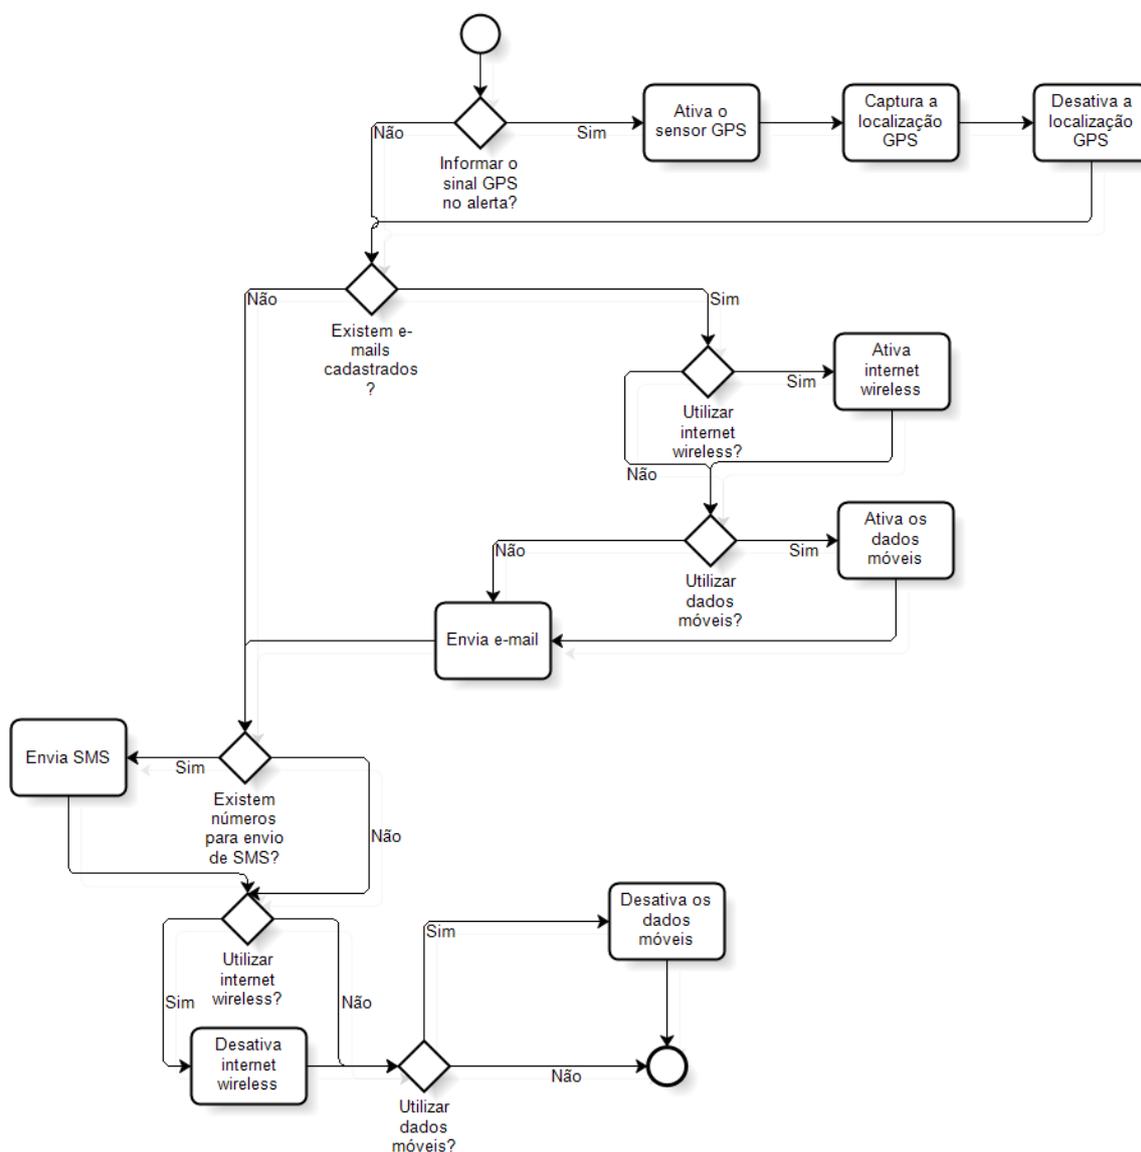
- E-mails para emissão de alerta: endereços de e-mail para que seja enviado o alerta. Caso não seja informado nenhum endereço, o serviço de envio via e-mail não será executado;
- Números SMS: números de telefones celulares para que seja enviado o alerta via SMS. Caso nenhum número de celular seja cadastrado, o serviço de envio via SMS não será executado;

- Ativar inicialização automática: quando essa opção for habilitada, a aplicação irá iniciar automaticamente, juntamente com o sistema operacional;
- Ativar localização GPS: caso seja habilitada essa opção, a localização GPS será enviada anexa ao alerta;
- Ativar internet sem fio: ativar a utilização da internet sem fio para emissão de alertas via e-mail, desativando ao final da ação;
- Ativar dados móveis: ativar a utilização da rede móvel (3G, 4G...) para emissão de alertas via e-mail, desativando ao final da ação.

6.4.2 Emissão de Alertas

No momento em que o projeto de detecção retorna que uma queda foi detectada, a captura de dados é interrompida e a tela de queda detectada, conforme citado anteriormente, é exibida. Passando os 10 segundos sem interromper o alerta, o sistema realiza o fluxo exibido na Figura 35. Nesse fluxo, a captura do sinal GPS, com respectiva ativação e desativação do sensor, é realizada caso esteja ativado o envio das coordenadas nas configurações do sistema. A partir disso, se houver algum e-mail configurado, ativa o serviço de internet sem fio e ativa o serviço de dados móveis caso esses estejam selecionados nas configurações, realiza o envio do alerta via e-mail, envia o alerta via SMS se houver algum número de telefone cadastrado nas configurações e, após isso, desativa a internet sem fio e os dados móveis, caso esses estejam ativos nas configurações. Todo esse processo de ativação e desativação dos serviços é realizado com objetivo de economizar a carga da bateria do aparelho, do mesmo modo com que a aplicação é executada em segundo plano, já que a autonomia sem recarga de baterias é um dos requisitos de qualidade dos detectores de queda.

Figura 35 - Fluxograma do processo de emissão de alertas.



Fonte: Autor.

Quanto a mensagem exibida no alerta de queda, ela pode ter duas formas: exibindo ou não o posicionamento GPS do dispositivo. Quando a utilização do GPS estiver desabilitada nas configurações do sistema, será emitido o alerta com a seguinte mensagem: “Uma queda foi detectada!”. Quando a utilização do GPS estiver habilitada, será emitido o alerta com a seguinte mensagem: “Uma queda foi detectada! Posicionamento GPS: <https://www.google.com.br/maps/dir//X,Y/@X,Y,17z>”, onde X e Y são as coordenadas do posicionamento GPS do dispositivo.

Além do alerta de queda detectada, também foi desenvolvido o alerta de baixo nível de bateria. Quando a carga da bateria do *smartphone* estiver menor ou igual a 10% da sua capacidade, serão ativados os serviços de internet e serão emitidos um SMS e um e-mail para os destinatários configurados. A mensagem enviada é: “Baixa carga de bateria! Restam apenas X% de carga.”, onde X é o percentual de carga restante.

6.4.3 Testes de consumo de bateria

Testes de duração da bateria foram realizados para mensurar o uso de energia aproximado por parte do sistema de detecção de quedas. Visando simular a situação de maior uso de energia, a aplicação foi adaptada para manter seu processamento máximo, independentemente de estar ou não em inatividade. Com essa adaptação, a aplicação foi executada em dois cenários: um primeiro com Android 6.0, para buscar analisar o gasto em mAh, e o segundo com o Android 4.0.3, para analisar o tempo de duração da bateria.

No primeiro teste, executado em um *smartphone* MotoG3, a aplicação apresentou o uso de energia calculado em 3 mAh durante um período de 96 horas, sem recarga da bateria, conforme demonstrado na Figura 36. Esse teste foi realizado em um aparelho ativo, com uso diário.

Figura 36 - Detalhamento do uso da bateria no *smartphone* com Android 6.0.

Fonte: Autor.

O segundo teste, executado em um *smartphone* LG L5, foi dividido em duas etapas: uma com a medição do tempo de duração da bateria do *smartphone* executando a aplicação e outra sem executar a aplicação (como referência). Ambos os testes iniciaram a partir de uma carga completa da bateria do aparelho, sendo que esse não esteve em uso (sem chip), executando apenas a aplicação SDQI adaptada. Executando a aplicação, a bateria teve duração de 223,5 horas, enquanto o mesmo teste sem executar a aplicação obteve duração de 225,4 horas, isto é, um consumo de bateria relativo de 0,8%.

7 CONCLUSÕES

A detecção de quedas envolve um reconhecimento complexo de padrões, que tende a variar de acordo com cada indivíduo que sofre uma queda. Para realização dessa tarefa, existem soluções disponíveis a venda, mas essas expressam uma imagem de dependência ao usuário, devido ao formato do dispositivo ou as limitações impostas por ele, tais como distância de um ponto base. Também existem diversos estudos de softwares de detecção de quedas para uso em *smartphones*, através de acelerômetros e câmeras, mas os resultados nem sempre são satisfatórios. Em resumo, hoje não existe um detector de quedas acessível à população que seja preciso e discreto. Esse assunto chama atenção na área da geriatria, além de ser citado em censos demográficos, tais como IBGE, já que a população idosa está se tornando cada vez mais presente e ativa na sociedade moderna.

Esse estudo tem por objetivo desenvolver um sistema de detecção de quedas voltado para idosos, o qual apresenta emissão de alertas automatizados em caso de quedas. Dessa forma, foi desenvolvido um detector de quedas que analisa padrões de comportamento de dados obtidos através de acelerômetros tri-axiais. Também foi desenvolvido um sistema de detecção de quedas para sistemas operacionais *Android* que faz uso desse detector. O sistema de detecção emite alertas via e-mail e SMS caso uma queda seja detectada. Para o desenvolvimento do detector, foram exploradas quatro diferentes metodologias para classificação de quedas (por inatividade, por árvores de decisão, por limiares e por orientação), analisando o comportamento em amostras de simulações de quedas e de AVDs de três bases de dados (MobiFall, MobiFall2 e uma base montada pelo estudo).

Os testes do sistema proposto apresentaram 87,65% de especificidade e 95,45% de sensibilidade no resultado final. Esses resultados apresentaram precisão próxima ou superior quando comparados aos trabalhos relacionados, demonstrando a eficiência da metodologia abordada.

Existem diversas possibilidades de melhorias, baseadas nos conceitos abordados neste trabalho, que podem ser avaliadas para sistemas de detecção

de quedas. Entre elas, estão a análise conjunta de giroscópios e acelerômetros e a avaliação de outros algoritmos de reconhecimento de padrões que permitam capturar padrões mais complexos dos sinais. Além disso, testes do detector de quedas em outros tipos de dispositivos (diferentes de *smartphones*) e testes de rotina realizados diretamente com idosos são algumas alternativas para melhor avaliação da metodologia aqui proposta.

REFERÊNCIAS

- AGUIAR, B. et al. Accelerometer-Based Fall Detection for Smartphones. **Medical Measurements and Applications (MeMeA), 2014 IEEE International Symposium on**, Lisboa, p. 1-6, 2014.
- ALMEIDA, O.; ZHANG, M.; LIU, J.-C. Dynamic Fall Detection and Pace Measurement in Walking Sticks. **High Confidence Medical Devices, Software, and Systems and Medical Device Plug-and-Play Interoperability, 2007. HCMDSS-MDPnP. Joint Workshop on**, Boston, p. 204-206, jan. 2007.
- ALMEIDA, L. P. D.; BRITES, M. D. F.; TAKIZAWA, M. D. G. M. H. Quedas em idosos: fatores de risco. **RBCEH**, v. 8, n. 3, p. 384-391, 2011.
- ALWAN, M. et al. A Smart and Passive Floor-Vibration Based Fall Detector for Elderly. **2006 2nd International Conference on Information & Communication Technologies**, Damasco, v. 1, p. 1003-1007, 2006.
- AMIRI, S. M. et al. Improved human action recognition in a smart home environment setting. **IRBM**, p. 321–328, 2014.
- BARBOSA, V.; RAMÍRES, L. J. L.; GOROSO, D. G. Aplicação de sistema multicanal na detecção de quedas para idosos. **Revista Brasileira de Inovação Tecnológica em Saúde**, v. 3, n. 2, p. 38-47, 2013.
- BIANCHI, F. et al. Barometric Pressure and Triaxial Accelerometry-Based Falls Event Detection. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 18, p. 619-627, dez. 2010.
- BLOCH, F. et al. Evaluation under real-life conditions of a stand-alone fall detector for the elderly subjects. **Annals of Physical and Rehabilitation Medicine**, p. 391-398, 2011.
- BRASIL. MINISTÉRIO DA SAÚDE. **Saúde Brasil 2008: 20 anos de Sistema Único de Saúde (SUS) no Brasil**. Brasília: Ministério da Saúde, Secretaria de Vigilância em Saúde, Departamento de Análise de Situação em Saúde, 2009.

CARVALHO, A. M.; COUTINHO, E. S. F. Demência como fator de risco para fraturas graves em idosos. **Revista Saúde Pública**, Rio de Janeiro, p. 448-454, 2002.

CHEN, D. et al. A Wearable Wireless Fall Detection System with Accelerators. **Robotics and Biomimetics (ROBIO), 2011 IEEE International Conference on**, Karon Beach, p. 2259 - 2263, dez. 2011.

CHEN, G. How to Convert 3-Axis Directions and Swap X-Y Axis of Accelerometer Data within Android™ Driver. **Site da Freescale Semiconductor, Inc**, 2011. Disponível em: <http://cache.freescale.com/files/sensors/doc/app_note/AN4317.pdf>. Acesso em: 11 maio 2016.

CHEN, J. et al. Wearable Sensors for Reliable Fall Detection. **2005 IEEE Engineering in Medicine and Biology 27th Annual Conference**, Shanghai, p. 3551-3554, jan. 2006.

COELHO FABRÍCIO, S. C.; RODRIGUES, R. A. P.; COSTA JUNIOR, M. L. Causas e consequências de quedas de idosos atendidos em hospital público. **RSP - Revista de Saúde Pública**, p. 93-99, 2004.

COLUNISTA PORTAL - EDUCAÇÃO. PORTAL EDUCAÇÃO - Cursos Online : Mais de 1000 cursos online com certificado. **Portal Educação**, 2013. Disponível em: <<http://www.portaleducacao.com.br/nutricao/artigos/32812/conceitos-de-sensibilidade-e-especificidade#ixzz4BYK9124N>>. Acesso em: 14 jun. 2016.

DE SÁ, J. M. **Reconhecimento de padrões**. 1. 2001.

DELAHOZ, Y. S.; LABRADOR, M. A. Survey on Fall Detection and Fall Prevention Using Wearable and External Sensors. **Sensors 2014**, v. 14, p. 19806-19842, 2014.

DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS, P. D. **World Population Ageing 2013**. United Nations. 2013.

DOUKAS, C.; MAGLOGIANNIS, I. Advanced Patient or Elder Fall Detection based on Movement and Sound Data. **2008 Second International Conference**

on **Pervasive Computing Technologies for Healthcare**, Tampere, p. 2153-1633, 2008.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2^a. ed.: Wiley, 2001.

FERREIRA, D. C. D. O.; YOSHITOME, A. Y. Prevalência e características das quedas de idosos institucionalizados. **Revista Brasileira de Enfermagem**, Brasília, p. 991-997, 2010.

FHON, J. R. S. et al. Prevalência de quedas de idosos em situação de fragilidade. **Revista Saúde pÚBLICA**, Ribeirão Preto, v. 47, n. 2, p. 266-273, 2013.

FIGUEIREDO, I. N. et al. Exploring smartphone sensors for fall. **mUX: The Journal of Mobile**, v. 5, n. 2, maio 2016.

GAWRYSZEWSKI, V. P.; MELLO JORGE, M. H. P. D.; KOIZUMI, M. S. Mortes e internações por causas externas entre os idosos no Brasil: o desafio de integrar a saúde coletiva e atenção individual. **Revista da Associação Médica Brasileira**, São Paulo, v. 50, n. 1, p. 97-103, 2004.

GONSAGA, R. A. T. et al. Avaliação da mortalidade por causas externas. **Revista do Colégio Brasileiro de Cirurgiões**, Rio de Janeiro, v. 39, n. 4, p. 263-267, 2012.

HSIEH, S.-L. et al. A Finite State Machine-Based Fall Detection Mechanism on Smartphones. **Ubiquitous Intelligence & Computing and 9th International Conference on Autonomic & Trusted Computing (UIC/ATC), 2012 9th International Conference on**, Fukuoka, p. 735 - 739, set. 2012.

HWANG, J. Y. et al. Development of novel algorithm and real-time monitoring ambulatory system using Bluetooth module for fall detection in the elderly. **Engineering in Medicine and Biology Society, 2004. IEMBS '04. 26th Annual International Conference of the IEEE**, São Francisco, v. 1, p. 2204-2207, set. 2004.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Perfil dos Idosos Responsáveis pelos Domicílios, 25 Julho 2002. Disponível em:

<<http://www.ibge.gov.br/home/presidencia/noticias/25072002pidoso.shtm>>.

Acesso em: 27 fev. 2016.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA.

Observações sobre a evolução da mortalidade no Brasil: o passado, o presente e perspectivas, Rio de Janeiro, 2010. Disponível em:

<<http://www.ibge.gov.br/home/estatistica/populacao/tabuadevida/2009/notastecnicas.pdf>>. Acesso em: 27 jan. 2016.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA.

Estatísticas de Gênero. Uma análise dos resultados do Censo

Demográfico 2010. Rio de Janeiro, 2014.

IDC - INTERNATIONAL DATA CORPORATION. Smartphone OS Market Share, 2015. Disponível em: <<http://www.idc.com/prodserv/smartphone-os-market-share.jsp>>. Acesso em: 27 fev. 2016.

JANSEN, B.; DEKLEREK, R. Context aware inactivity recognition. **2006 Pervasive Health Conference and Workshops**, Innsbruck, p. 1-4, 2006.

JIAN, H.; CHEN, H. A Portable Fall Detection and Alerting System Based on k-NN Algorithm and Remote Medicine. **China Communications**, v. 12, p. 23-31, jun. 2015.

JIANGPENG, D. et al. PerFallD: A pervasive fall detection system using mobile phones. **Pervasive Computing and Communications Workshops**, Manhattan, p. 292-297, mar. 2010.

KAU, L.-J.; CHEN, C.-S. A Smart Phone-Based Pocket Fall Accident Detection, Positioning, and Rescue System. **IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS**, v. 19, n. 1, p. 44-56, jan. 2015.

KOIZUMI, M. S. Gastos governamentais do SUS com internações hospitalares por causas externas: análise no estado de São Paulo, 2000. **Revista Bras. Epidemiol.**, São Paulo, v. 7, p. 228-238, 2004.

KORAY, O. et al. Automatic Fall Detection and Activity Classification by Wearable Embedded Smart Camera. **IEEE Journal on Emerging and Selected Topics in Circuits and Systems**, v. 3, n. 2, p. 125-136, jan. 2013.

- KOSHMAK, G.; LIDEN, M. Evaluation of the Android-Based Fall Detection System with Physiological Data Monitoring. **35th Annual International Conference of the IEEE EMBS**, Osaka, p. 1164 - 1168, jul. 2013.
- KOSTOPOULOS, P. et al. Increased Fall Detection Accuracy in an Accelerometer-Based Algorithm Considering Residual Movement. **Conference: 4th International Conference on Pattern Recognition Applications and Methods**, Lisbon, jan. 2015.
- KULKARNI, S.; BASU, M. A Review on Wearable Tri-Axial Accelerometer Based Fall Detectors. **Journal of Biomedical Engineering and Technology**, v. 1, n. 3, p. 36-39, 2013.
- LI, Q. et al. Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information. **2009 Sixth International Workshop on Wearable and Implantable Body Sensor Networks**, Berkeley, p. 138-143, jun. 2009.
- LI, Y. et al. Accelerometer-Based Fall Detection Sensor System for the Elderly. **2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems**, Hangzhou, v. 3, p. 1216 - 1220, nov. 2012.
- LIANDANA, M.; MUSTIKA, I. W.; SELO. Fall Detection System for Elderly Based on Android Smartphone. **Proceeding Conference on Applied Electromagnetic Technology (AEMT)**, Lombok, abr. 2014.
- LIMA, C. K. G.; MURAI, H. C. Percepção do idoso sobre o próprio processo de envelhecimento. **Revista de Enfermagem da UNISA**, v. 6, p. 15-22, 2005.
- LOJUDICE, D. C. et al. Quedas de idosos institucionalizados: ocorrência e fatores associados. **Revista Brasileira de Geriatria e Gerontologia**, Rio de Janeiro, v. 13, n. 3, p. 403-412, 2010.
- MAIA, B. C. et al. Consequências das Quedas em Idosos Vivendo na Comunidade. **Revista Brasileira de Geriatria e Gerontologia**, Rio de Janeiro, v. 14, n. 2, p. 381,393, 2011.
- MITCHELL, T. T. **Machine Learning**. Singapura: McGraw-Hill , 1997.

MOHAMED, O.; CHOI, H.-J.; IRAQI, Y. Fall Detection Systems for Elderly Care: A Survey. **2014 6th International Conference on New Technologies, Mobility and Security (NTMS)**, Dubai, p. 1-4, abr. 2014.

NOURY, N. et al. Fall detection - Principles and Methods. **2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, Lyon, p. 1663-1666, ago. 2007.

NOURY, N. et al. A proposal for the classification and evaluation of fall detectors. **IRBM**, v. 29, n. 6, p. 340-349, ago. 2008.

NUTTAITANAKUL, N.; LEAUHATONG, T. A Novel Algorithm for Detection Human Falling From Accelerometer Signal Using Wavelet Transform and Neural Network. **2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE)**, Chiang Mai, p. 215-220, out. 2015.

OJETOLA, O. **Detection of human falls using wearable sensors**. Tese de Doutorado. set. 2013.

OJETOLA, O.; GAURA, E. I.; BRUSEY, J. Fall Detection with Wearable Sensors—SAFE (SmArt Fall dEtecton). **Intelligent Environments (IE), 2011 7th International Conference on**, Nottingham, p. 318-321, jul. 2011.

OZCAN, K.; VELIPASALAR, S. Wearable Camera- and Acelerometer-Based Fall Detection on Portables Devices. **IEEE Embedded Systems Letters**, v. 8, p. 6-9, mar. 2016.

PEDIADITIS, ; EMMANOUIL, G. S.; TSIKNAKIS, M. The MobiFall Dataset: An Initial Evaluation of Fall Detection Algorithms Using Smartphones. **Conference: Bioinformatics and Bioengineering (BIBE)**, n. 13, 2013 11.

PERRY, J. T. et al. Survey and Evaluation of Real-Time Fall Detection Approaches. **2009 6th International Symposium on High Capacity Optical Networks and Enabling Technologies (HONET)**, Alexandria, p. 158-164, dez. 2009.

PIERLEONI, P. et al. A High Reliability Wearable Device for Elderly Fall Detection. **IEEE Sensors Journal**, v. 15, p. 4544 - 4553, ago. 2015.

PIERLEONI, P. et al. SVM-Based Fall Detection Method for Elderly People Using Android Low-Cost Smartphones. **Sensors Applications Symposium (SAS), 2015 IEEE**, Zadar, p. 1-5, abr. 2015.

PIVA, L. S. et al. fAlert: Um sistema android para monitoramento de quedas em pessoas com cuidados especiais. **Laboratório de Banco de Dados UFMG**, Nov 2014. Disponível em: <<http://www.lbd.dcc.ufmg.br/>>. Acesso em: 19 abr. 2016.

PORTAL BRASIL. Portal Brasil, 17 Abril 2012. Disponível em: <<http://www.brasil.gov.br/saude/2012/04/quedas#>>. Acesso em: 29 fev. 2016.

PRADO, A. R. D. A.; ET AL. **Geriatrics e Gerontologia**. 1. ed. Barueri: Manole, v. I, 2014.

PURCH CORPORATION. The Best Fall Detection Sensors Reviews. **TopTenReviews**, 2016. Disponível em: <<http://medical-alert-systems-review.toptenreviews.com/fall-detection/>>. Acesso em: 05 maio 2016.

PUTCHANA, W.; CHIVAPREECHA, S.; LIMPITI, T. Wireless Intelligent Fall Detection and Movement Classification using Fuzzy Logic. **Biomedical Engineering International Conference (BMEiCON), 2012**, Ubon Ratchathani, p. 1-5, dez. 2012.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. Sydney: Morgan Kaufmann Publishers, 1993.

RASHIDPOUR, M.; MOHAMMADI, F. A.; FATHI, A. Fall Detection Using Adaptive Neuro-Fuzzy Inference System. **International Journal of Multimedia and Ubiquitous Engineering**, v. 11, n. 4, p. 91-106, 2016.

RIBEIRO, A. P. et al. A influência das quedas na qualidade de vida de idosos. **Revista Ciência & Saúde Coletiva**, Rio de Janeiro, v. 13, n. 4, p. 1265-1273, 2008.

RICCI, N. A. et al. Fatores associados pelo histórico de quedas de idosos assistidos pelo Programa de Saúde da Família. **Revista Saúde e Sociedade**, São Paulo, v. 19, n. 4, p. 898-909, 2010.

- ROUGIER, C. et al. Monocular 3D Head Tracking to Detect Falls of Elderly People. **Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE**, Nova Iorque, p. 6384 - 6387, 2006.
- SABADINI, L. P. et al. **fAlert: Um sistema android para monitoramento de quedas em pessoas com cuidados especiais**. 2014.
- SANNINO, G.; FALCO, I. D.; PIETROINSTITUTE, G. D. A supervised approach to automatically extract a set of rules to support fall detection in an mHealth system. **Institute of High Performance Computing and Networking, National Research Council of Italy (ICAR-CNR)**, Nápoles, p. 205–216, 2015 4.
- SENGTO, A.; LEAUHATONG, T. Human falling detection algorithm using back propagation neural network. **Biomedical Engineering International Conference (BMEiCON), 2012**, Ubon Ratchathani, p. 1-5, dez. 2012.
- SHAN, S.; YUAN, T. A Wearable Pre-impact Fall Detector using Feature Selection and Support Vector Machine. **IEEE 10th INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING PROCEEDINGS**, Beijing, p. 1686-1689, out. 2010.
- SILVA, F. G. **Reconhecimento de movimentos humanos utilizando um acelerômetro e inteligência computacional**. São Paulo, 2013.
- SURANA, J. et al. Adaptive Learning based Human Activity and Fall Detection using Fuzzy Frequent Pattern Mining. **Recent Trends in Information Technology (ICRTIT), 2013 International Conference on**, Chennai, p. 744-749, jul. 2013.
- TAMURA, T. et al. A Wearable Airbag to Prevent Fall Injuries. **IEEE Transactions on Information Technology in Biomedicine** , v. 13, p. 910-914, nov. 2009.
- TONG, L. et al. HMM-Based Human Fall Detection and Prediction. **IEEE Sensors Journal** , v. 13, p. 1849-1856, abr. 2013.

TRA, K.; PHAM, T. V. Human Fall Detection Based On Adaptive Background Mixture Model and HMM. **Advanced Technologies for Communications (ATC), 2013 International Conference on**, Ho Chi Minh City, p. 95-100, out. 2013.

VALCOURT, L.; HOZ, Y. D. L.; LABRADOR, M. Smartphone-based Human Fall Detection System. **IEEE Latin America Transactions**, v. 14, p. 1011-1017, mar. 2016.

VALLEJO, M.; ISAZA, C. V.; LÓPEZ, J. D. Artificial Neural Networks as an Alternative to Traditional Fall Detection Methods. **2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**, Osaka, p. 1648-1651, jul. 2013.

VARAS-FABRA, F. et al. Caídas en ancianos de la comunidad: prevalencia, consecuencias y factores asociados. **Revista Aten Primaria**, Córdoba, v. 38, n. 8, p. 450-455, 2006.

VAVOULAS, G. et al. The MobiFall Dataset: An Initial Evaluation of Fall Detection Algorithms Using Smartphones. **6th IEEE International Symposium on Monitoring & Surveillance Research (ISMSR): Healthcare-Bioinformatics**, Chania, 2013.

VAVOULAS, G. et al. The MobiAct Dataset: Recognition of Activities of Daily Living using Smartphones. **The MobiAct Dataset: Recognition of Activities of Daily Living using Smartphones**, p. 143-151, jan. 2016.

VENTURA, J. B.; LOPES, L. J. R.; GOROSO, D. G. Aplicação de Sistema Multicanal na Detecção de Quedas Para Idosos. **Revista Brasileira de Inovação Tecnológica em Saúde**, v. 3, n. 2, p. 38-47, 2013.

WANG, C. et al. A Low-power Fall Detection Algorithm Based on Triaxial Acceleration and Barometric Pressure. **2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, Chicago, p. 570-573, ago. 2014.

WEBB, A. R.; COPSEY, K. D. **Statistical Pattern Recognition**. 3. ed. Malvern: John Wiley & Sons, Ltd, 2011.

WITTEN, I. H.; FRANK, E. **Data mining**: practical machine learning tools and techniques. 2. ed. São Francisco: Morgan Kaufmann Publishers, 2005.

YE, Z. et al. A Falling Detection System with wireless sensor for the Elderly People Based on Ergonomics. **International Journal of Smart Home**, Hebei, v. 8, p. 187-196, 2014.

YI, W.-J. et al. Wearable Sensor Data Fusion for Remote Health Assessment and Fall Detection. **IEEE International Conference on Electro/Information Technology**, Milwaukee, p. 303-307, jun. 2014.

YU, X. Approaches and Principles of Fall Detection for Elderly and Patient. **Institute for InfoComm Research**, Singapura, p. 42-47, jul. 2008.