



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
MESTRADO ACADÊMICO EM CIÊNCIA DA COMPUTAÇÃO

CHRISTIANO DE ARAÚJO PEREIRA RODRIGUES

**INFORM - UMA ABORDAGEM PARA DETECÇÃO DE QUEDAS BASEADA EM
SENSORES DE MOVIMENTO INFRAVERMELHOS E ACELERÔMETROS**

FORTALEZA

2016

CHRISTIANO DE ARAÚJO PEREIRA RODRIGUES

INFORM - UMA ABORDAGEM PARA DETECÇÃO DE QUEDAS BASEADA EM
SENSORES DE MOVIMENTO INFRAVERMELHOS E ACELERÔMETROS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Ciência da Computação. Área de Concentração: Sistemas de Informação

Orientador: Prof. Dr. Miguel Franklin de Castro

Co-Orientador: Prof. Dr. Paulo Armando Cavalcante Aguilar

FORTALEZA

2016

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

R612i Rodrigues, Christiano de Araújo Pereira.

INFORM - Uma Abordagem para Detecção de Quedas Baseada em Sensores de Movimento Infravermelhos e Acelerômetros / Christiano de Araújo Pereira Rodrigues. – 2016.
83 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2016.

Orientação: Prof. Dr. Miguel Franklin de Castro.

Coorientação: Prof. Dr. Paulo Armando Cavalcante Aguilár.

1. Detecção de quedas. 2. Sensores Infravermelhos. 3. Acelerômetro. I. Título.

CDD 005

CHRISTIANO DE ARAÚJO PEREIRA RODRIGUES

INFORM - UMA ABORDAGEM PARA DETECÇÃO DE QUEDAS BASEADA EM
SENSORES DE MOVIMENTO INFRAVERMELHOS E ACELERÔMETROS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Ciência da Computação. Área de Concentração: Sistemas de Informação

Aprovada em: 29 de Novembro de 2016

BANCA EXAMINADORA

Prof. Dr. Miguel Franklin de Castro (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Paulo Armando Cavalcante
Aguilar (Co-Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. José Neuman de Souza
Universidade Federal do Ceará (UFC)

Prof. Dr. Rodrigo Varejão Andreão
Instituto Federal de Educação, Ciência e Tecnologia
do Espírito Santo (IFES)

Dedico este trabalho aos meus pais, Carlos Emílio e Maria de Guadalupe, e à minha namorada, Jaminny Benício.

AGRADECIMENTOS

Agradeço primeiramente e principalmente aos meus pais, pois foram eles que me apoiaram durante todo o processo e foram os responsáveis pela minha permanência em fortaleza para que eu chegasse ao fim dessa caminhada.

À minha namorada, Jaminny Benício, por ficar me cobrando quando era necessário, por ser paciente quando existiam outras prioridades, por me incentivar, por ficar ao meu lado escutando minhas reclamações e dificuldades enfrentadas, por pagar minha conta de luz, por ficar ouvindo um monte de coisas que não fazem o menor sentido para ela, só para me ajudar a colocar a cabeça no lugar e ter novas ideias. São muitas razões para agradecer, então para resumir, obrigado por me aturar.

Aos meus sogros, James e Mary por me receberem como um filho, pelos conselhos e pela orações para que eu finalizasse meu mestrado com sucesso.

Ao meu co-orientador, professor Paulo Armando, por me instigar e ajudar tanto nessa empreitada de trabalhar com algo tão diferente, pelas discussões, ideias e pela cerveja artesanal compartilhada.

Ao meu orientador, professor Miguel, por ter me orientado duas vezes, e ter me dado a oportunidade de chegar até o fim, mesmo depois de falhar. Agradeço os puxões de orelha, as poucas conversas que sempre eram bastante produtivas, a liberdade e as cobranças.

Ao meu amigo Caio Magno, por ser um dos responsáveis pelo meu interesse na área de e-health, pelos projetos realizados em conjunto, por me ajudar na realização do meu trabalho e pelas longas discussões filosóficas.

Aos meus irmãos, Cássio e Cláudio, por me cobrarem terminar logo meu mestrado e me fazerem companhia quando jogávamos.

Ao meu amigo Laurismar e sua família, por me abrigar durante o início dessa jornada e por me ajudarem a me adaptar a vida longe da família.

Aos voluntários, Jaminny, Belmondo, Rodrigo e Cássio, pelo tempo dedicado e principalmente pelas quedas. Desculpem as dores de cabeça e muito obrigado.

Aos amigos da pós-graduação, em especial Rainara, Ítalo, Thalisson, Andressa, Ismayle, Deborah, Adyson, Paulo, Lana, Rodrigo, Ticianne, Jefferson e Belmondo. Obrigado pelos momentos de distração e de seriedade, pelo incentivo nas horas difíceis e por terem tornado tudo esse processo mais divertido.

Aos professores do MDCC que participaram da minha formação e que me ajudaram quando solicitados.

A todos que compõe o GREat, professores, alunos, desenvolvedores, pessoal do financeiro, Rh, suporte, que a me ajudaram a finalizar meu trabalho.

A CAPES e FCPC pelas bolsas que foram extremamente vitais para que eu concluísse meu trabalho.

Por fim, a qualquer um, que de alguma forma colaborou, mesmo que minimamente para que eu pudesse finalmente concluir esta etapa.

Muito obrigado.

"Home is behind, the world ahead
And there are many paths to tread
Through shadow, to the edge of night
Until the stars are all alight"

(J.R.R. Tolkien)

RESUMO

O aumento da expectativa de vida das pessoas e maior qualidade de vida, tem provocado o envelhecimento da população mundial. Um problema bastante comum aos idosos são as quedas, que podem ser fatais em alguns casos. Em cenários como este, a tecnologia deve oferecer o suporte para a melhoria do acompanhamento desta faixa etária. Com a Internet das Coisas (IoT), qualquer coisa pode ser acessada a qualquer momento e em qualquer lugar. Por meio das informações dessas coisas um Sistema de Ambient Assisted Living (AAL) pode auxiliar pessoas a manter sua independência e viver melhor. Uma das funcionalidades deste tipo de sistema é detectar quedas. Este trabalho de dissertação de mestrado apresenta o INFOrM (INdoor Fall detectiOn Method), um método para detecção de quedas que utiliza aprendizagem de máquina para geração de um modelo de classificação baseado em informações de alto e baixo nível, provenientes de acelerômetros e sensores infravermelhos passivos. O classificador utiliza tecnologia de fácil aceitação pelo usuário e possui informações redundantes e complementares que podem melhorar a detecção do sistema analisadas em conjunto, mas que também podem ser usadas de forma independente, evitando a parada total do sistema. Os resultados obtidos a partir de experimentos demonstram que a utilização conjunta de sensores que respeitam a privacidade de seus usuários, como sensores de movimento e acelerômetro, pode atingir altos índices de acurácia na detecção de quedas, incluindo quedas lentas e em cenários de risco, como o banheiro.

Palavras-chave: Detecção de quedas. Sensores Infravermelhos. Acelerômetro.

ABSTRACT

The increase of life expectancy and higher quality of life has caused the aging of the world population. A fairly common problem for the elderly are falls, which can be fatal in some cases. In such scenarios, technology should offer support for better monitoring of this age group. With the Internet of Things (IoT), anything can be accessed anytime, anywhere. Through the information of these things an Ambient Assisted Living (AAL) System can help people maintain their independence and live better. One of the functionalities of this type of system is to detect falls. This master dissertation paper presents INFOrM (INdoor Fall detection Method), a method for fall detection that uses machine learning to generate a classification model based on high and low level information, from accelerometers and passive infrared sensors. The classifier uses technology that is easy to accept by the user and has redundant and complementary information that can improve system detection when analyzed together, but can also be used independently, avoiding system shutdown. The results obtained from experiments show that the combined use of sensors that respect the privacy of their users, such as motion sensors and accelerometer, can achieve high accuracy rates in fall detection, including slow falls and risk scenarios, such as the bathroom.

Keywords: Fall detection. Infrared Sensors. Accelerometer.

LISTA DE ILUSTRAÇÕES

Figura 1 – Gráfico que apresenta a expectativa de vida mundial, no Brasil, Austrália, Estados Unidos, França e Japão ao longo dos anos.	17
Figura 2 – Gráfico que ilustra o percentual de pessoas com mais de 65 anos de idade no Brasil, Austrália, Estados Unidos, França, Japão e no mundo ao longo dos anos.	18
Figura 3 – Gráfico representando a taxa de natalidade mundial, do Brasil, Austrália, Estados Unidos, França e Japão ao longo dos anos.	18
Figura 4 – Gráfico ilustrativo do percentual de pessoas com mais de 15 e menos de 64 anos de idade no Brasil, Austrália, Estados Unidos, França, Japão e no mundo ao longo dos anos.	19
Figura 5 – Número de mortes atribuídas a quedas não intencionais, em indivíduos com mais de 65 anos ao longo dos anos, a cada 100000, nos Estados Unidos. . .	20
Figura 6 – Aspectos tecnológicos e sociais que estão relacionados à Internet das Coisas	26
Figura 7 – Aplicações de IoT.	29
Figura 8 – Melhor descrição de <i>Ambiente Assisted Living</i>	31
Figura 9 – Classificação de dados de um acelerômetro: a)Gráfico de como geralmente é percebido um evento de queda; b)Grupos de dados não classificados; c)Classificação correta dos dados em b)	35
Figura 10 – A imagem mais a esquerda mostra um Kinect instalado em um apartamento. A imagem do meio são exemplos de quadros de imagem em profundidade e extração do primeiro plano do apartamento. A imagem da direita representa o objeto tridimensional formado a partir da extração do primeiro plano. . . .	37
Figura 11 – Fluxograma ilustrando a como ocorre a classificação de postura em (ZHANG <i>et al.</i> , 2013). O algoritmo lê dados da aceleração dos eixos x,y e z (A_x, A_y e A_z respectivamente), dos ângulos de inclinação em relação a cada eixo (θ_x, θ_y e θ_z) e o <i>timestamp</i> para diferenciar posturas com movimento e sem movimento	38
Figura 12 – Fluxograma do algoritmo de detecção de quedas implementado em (ZHANG <i>et al.</i> , 2013). Se o usuário está deitado ou sentado de forma inclinada, então é verificada a postura anterior do mesmo, caso o algoritmo entenda como uma queda lenta ele solicita a confirmação do usuário da ocorrência do evento. . .	38
Figura 13 – a) <i>Smartphone</i> utilizado em (ALBERT <i>et al.</i> , 2012) e a localização do mesmo nas costas do indivíduo. b) Eixos do acelerômetro das figuras à esquerda. . .	39

Figura 14 – Rede de evidências que fusiona informações do RFPAT e GARDIEN para detectar quedas. Na figura v representa o sensor que observa todo o ambiente e h o sensor posicionado a 1m de altura do chão. O triângulo R_I representa o <i>actigraphy</i> inerte	41
Figura 15 – Rede de evidência proposta em (CAVALCANTE <i>et al.</i> , 2014).	43
Figura 16 – Equipamentos utilizados em (GJORESKI <i>et al.</i> , 2014). Os círculos não preenchidos representam os acelerômetros, enquanto os preenchidos são os sensores de localização.	43
Figura 17 – Arquitetura do sistema proposto em (GJORESKI <i>et al.</i> , 2014).	44
Figura 18 – Arquitetura do sistema de detecção de quedas proposto em (LUSTREK <i>et al.</i> , 2015). A linha pontilhada indica que o acelerômetro pode ser usado para corrigir o reconhecimento de atividade e contexto. A linha tracejada indica como o sistema se pode ser adaptado para uso personalizado.	46
Figura 19 – Gráfico da aceleração resultante durante uma queda rápida	52
Figura 20 – Gráfico da aceleração resultante durante uma queda lenta	53
Figura 21 – Gráficos que representam a aceleração resultante durante diferentes atividades: a) Andar; b) Pular; c) Deitar; d) Cair	53
Figura 22 – Sensores infravermelhos implantados no cenário: a) Visão superior de um cômodo ; b) Área de cobertura do infravermelho do cômodo; c) Área de cobertura do infravermelho da parede, colocado à altura da cama; d) Área de cobertura dos dois sensores infravermelhos de um cômodo. IRP - Infravermelho da parede; IRC - Infravermelho do cômodo.	55
Figura 23 – Diagrama de fluxo representando o algoritmo de detecção de quedas baseado em limiares	58
Figura 24 – Diagrama representando como são gerados os arquivos da base de dados. Os sensores estão em azul, as aplicações em cinza e os dados escritos no arquivo csv em um cinza mais claro. O acelerômetro gera dados brutos que são derivados em novos atributos, postura e utilizados para detecção de queda e tudo isso é gravado no arquivo csv.	59
Figura 25 – Aplicação Android desenvolvida para centralizar as informações dos sensores utilizados, inferir posturas, detectar quedas e gravar todas as informações da base. À esquerda a visão inicial da aplicação e à direita os cômodos utilizados.	60

Figura 26 – Diagrama ilustrando o processo de extração de um modelo para detectar quedas	60
Figura 27 – Diagrama ilustrando todo processo para geração do classificador e sua utilização em um software capaz de detectar quedas, que utilize acelerômetro e sensores infravermelhos	61
Figura 28 – Inclinação (<i>pitch</i>), rotação (<i>roll</i>) e desvio (<i>yaw</i>) no <i>smartphone</i> utilizado. . .	65
Figura 29 – Usuário utilizando uma faixa com o Nexus 5 preso ao corpo para coletar todas as informações do cenário.	65
Figura 30 – Sensor PIR da marca Legrand	66
Figura 31 – Ambiente residencial simulado. As regiões marcadas por 1 são consideradas perigosas, enquanto as demarcadas por 0 são locais onde as pessoas costumam deitar. IRP - Infravermelho da parede; IRC - Infravermelho do cômodo. . .	67
Figura 32 – Interface da Weka - ferramenta utilizada para treinar os algoritmos de aprendizagem automática	69

LISTA DE TABELAS

Tabela 2 – Áreas de aplicação de AAL	32
Tabela 3 – Resultados obtidos em (ZHANG <i>et al.</i> , 2013)	39
Tabela 4 – Trabalhos relacionados - Tipos de quedas e de classificador	47
Tabela 5 – Trabalhos relacionados - Abordagem e categoria utilizadas	48
Tabela 6 – Trabalhos relacionados - Usos e restrições	48
Tabela 7 – Trabalhos relacionados e INFORM - Tipos de quedas e de classificador	62
Tabela 8 – Trabalhos relacionados e INFORM - Abordagem e categoria utilizadas	63
Tabela 9 – Trabalhos relacionados e INFORM - Usos e restrições	63
Tabela 10 – Eventos de queda, não queda, que parecem queda e os cômodos nos quais foram realizados	67
Tabela 11 – Índice de instâncias classificadas corretamente - Treino individual e total - Validação cruzada	71
Tabela 12 – Índice de instâncias classificadas corretamente - Validação por meio de uma base não usada no treino	72
Tabela 13 – Índice de instâncias classificadas corretamente - Não quedas e Quedas - Validação por meio de uma base não usada no treino	72
Tabela 14 – Índice de instâncias classificadas corretamente - Quedas sem acelerômetro e Quedas lentas - Validação por meio de uma base não usada no treino	73

LISTA DE ABREVIATURAS E SIGLAS

AA	Aprendizagem Automática
AAL	Ambient Assisted Living
CDC	Centers for Disease Control and Prevention
IEEE	Institute of Electrical and Electronics Engineers
IERC	European Research Cluster on the Internet of Things
INFORM	INdoor Fall detectiOn Method
IoT	Internet of Things
IR	Infrared Sensor
IRC	Infravermelho do Cômodo
IRP	Infravermelho da Parede
ISO	International Organization for Standardization
ITU-T	ITU Telecommunication Standardization Sector
ML	Machine Learning
Nq	Não queda
PIR	Passive Infrared Sensor
Q	Queda
QL	Queda Lenta
SAcc	Sem Acelerômetro
SMLR	Sparse Multinomial Logistic Regression
SVM	Support Vector Machines
U1	Usuário 1
U2	Usuário 2
U3	Usuário 3
U4	Usuário 4
U5	Usuário 5

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Contextualização	17
1.2	Motivação	20
1.3	Objetivo e contribuição	21
1.4	Metodologia	22
1.5	Organização da Dissertação	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Internet das Coisas	25
<i>2.1.1</i>	<i>Desafios</i>	26
<i>2.1.2</i>	<i>Aplicações</i>	28
<i>2.1.2.1</i>	<i>Transporte e logística</i>	28
<i>2.1.2.2</i>	<i>Ambientes inteligentes</i>	29
<i>2.1.2.3</i>	<i>Cuidados com a saúde</i>	29
2.2	Ambient Assisted Living (AAL)	30
<i>2.2.1</i>	<i>Aplicações</i>	32
<i>2.2.2</i>	<i>Desafios</i>	32
2.3	Aprendizagem automática	33
<i>2.3.1</i>	<i>Tipos de aprendizagem automática</i>	33
<i>2.3.2</i>	<i>Classificação</i>	34
3	TRABALHOS RELACIONADOS	36
3.1	Detecção de quedas utilizando somente uma modalidade de sensor	36
<i>3.1.1</i>	<i>Fall Detection in Homes of Older Adults Using the Microsoft Kinect</i>	36
<i>3.1.2</i>	<i>A real-time falls detection system for elderly</i>	37
<i>3.1.3</i>	<i>Fall classification by machine learning using mobile phones</i>	38
<i>3.1.4</i>	<i>Conclusões</i>	40
3.2	Detecção de quedas utilizando localização	40
<i>3.2.1</i>	<i>First steps in adaptation of an Evidential Network for data fusion in the framework of medical remote monitoring</i>	40
<i>3.2.2</i>	<i>A Dynamic Evidential Network for Fall Detection</i>	42

3.2.3	<i>Context-based fall detection and activity recognition using inertial and location sensors</i>	43
3.2.4	<i>Fall detection using location sensors and accelerometers</i>	45
3.3	Conclusões	46
4	UMA NOVA ABORDAGEM PARA DETECÇÃO DE QUEDAS	50
4.1	Modalidades de aquisição da informação	51
4.1.1	<i>Acelerômetros</i>	51
4.1.2	<i>Sensores Infravermelhos</i>	54
4.2	Fusão dos dados por meio de aprendizagem automática	55
4.3	INFORM	56
4.4	Conclusão	61
5	EXPERIMENTOS E RESULTADOS	64
5.1	Base de dados	64
5.1.1	<i>Equipamentos</i>	64
5.1.2	<i>Cenário</i>	66
5.1.3	<i>Eventos</i>	67
5.2	Treinamento dos algoritmos de aprendizagem automática	68
5.3	Resultados	70
6	CONCLUSÃO	75
6.1	Discussões Gerais	75
6.2	Produção Bibliográfica	76
6.3	Limitações	77
6.3.1	<i>Sensores</i>	77
6.3.2	<i>Experimentos</i>	78
6.4	Trabalhos Futuros	78
	REFERÊNCIAS	80

1 INTRODUÇÃO

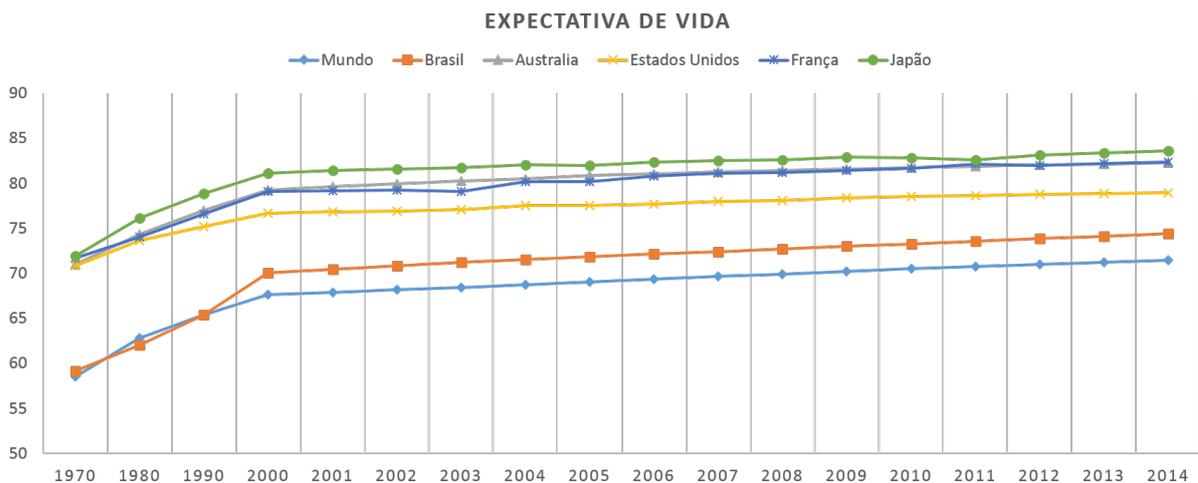
Esta dissertação de mestrado apresenta uma nova abordagem para detecção de quedas em ambientes inteligentes, tais como residências, hospitais, casas de repouso, entre outros. Tais ambientes vão estar equipados de forma que a utilização de sensores seja capaz de melhorar a detecção de quedas dos usuários e/ou residentes daquele local.

Este capítulo está dividido da seguinte forma: a Seção 1.1 descreve o contexto e descreve o problema abordado neste trabalho; a Seção 1.2 explica a razão pela qual o desenvolvimento desse trabalho é relevante; a Seção 1.3 apresenta os objetivos e contribuições que deste trabalho de mestrado; na Seção 1.4 foi descrito a metodologia utilizada para execução desse trabalho; por fim a Seção 1.5 descreve a organização do restante deste documento.

1.1 Contextualização

Os avanços na área da saúde têm favorecido o aumento da expectativa de vida da população em geral. A Figura 1, apresenta um gráfico com a expectativa de vida mundial e de alguns países. Abaixo, o gráfico da Figura 2, fica visível o aumento do número de pessoas com mais de 65 anos de idade em todos os países representados.

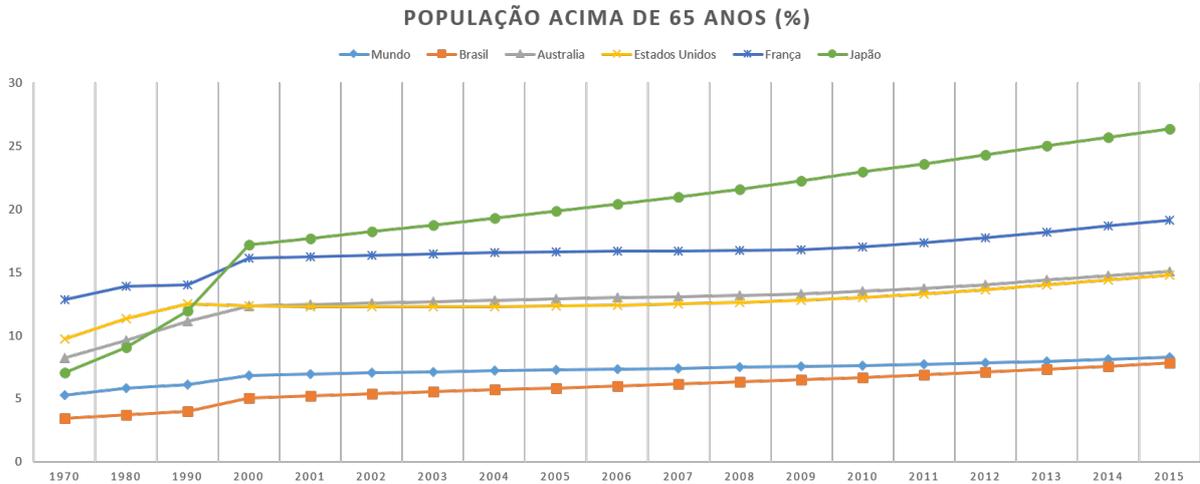
Figura 1 – Gráfico que apresenta a expectativa de vida mundial, no Brasil, Austrália, Estados Unidos, França e Japão ao longo dos anos.



Fonte: Adaptado de (The World Bank, 2014)

Segundo (United Nations, Department of Economic and Social Affairs, Population Division, 2015) em 2050, cerca de 44% da população mundial irá residir em países onde pelo menos 20% dos habitantes terá mais de 60 anos e que um em cada quatro pessoas irá viver em

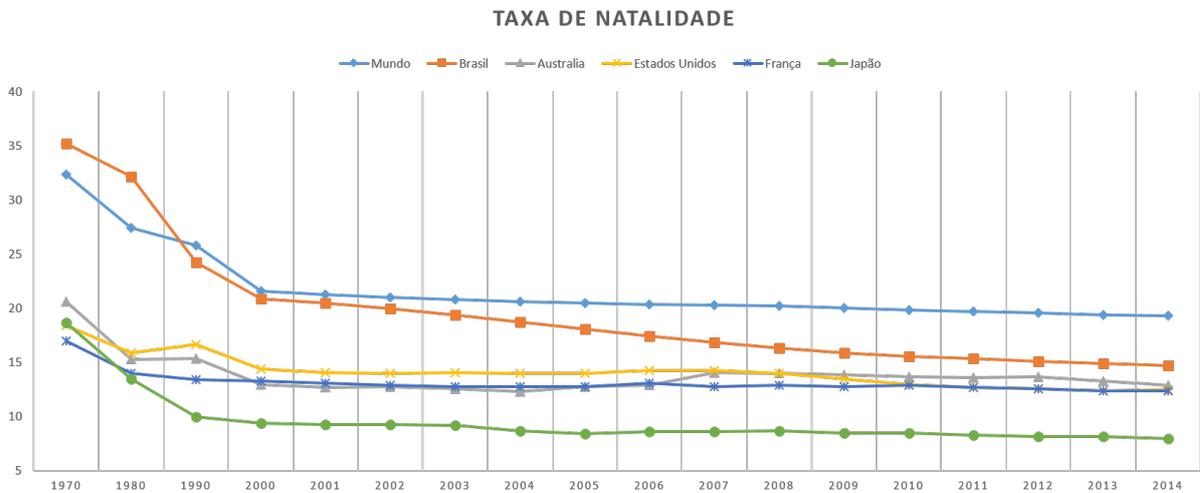
Figura 2 – Gráfico que ilustra o percentual de pessoas com mais de 65 anos de idade no Brasil, Austrália, Estados Unidos, França, Japão e no mundo ao longo dos anos.



Fonte: Adaptado de (The World Bank, 2014)

um país no qual pelo menos 30% dos seus residentes terá acima de 60. A Figura 3 mostra que a taxa de natalidade do mundo e dos países representados no gráfico está caindo com o passar dos anos, o que reforça a previsão das Nações Unidas. Outro índice que comprova o envelhecimento da população mundial é o ilustrado no gráfico da Figura 4, onde é possível notar que o número de jovens e adultos continua a cair com o passar dos anos. O Brasil apresenta um crescimento no número de jovens, porém com a queda da natalidade, esse número tende a cair com o passar dos anos.

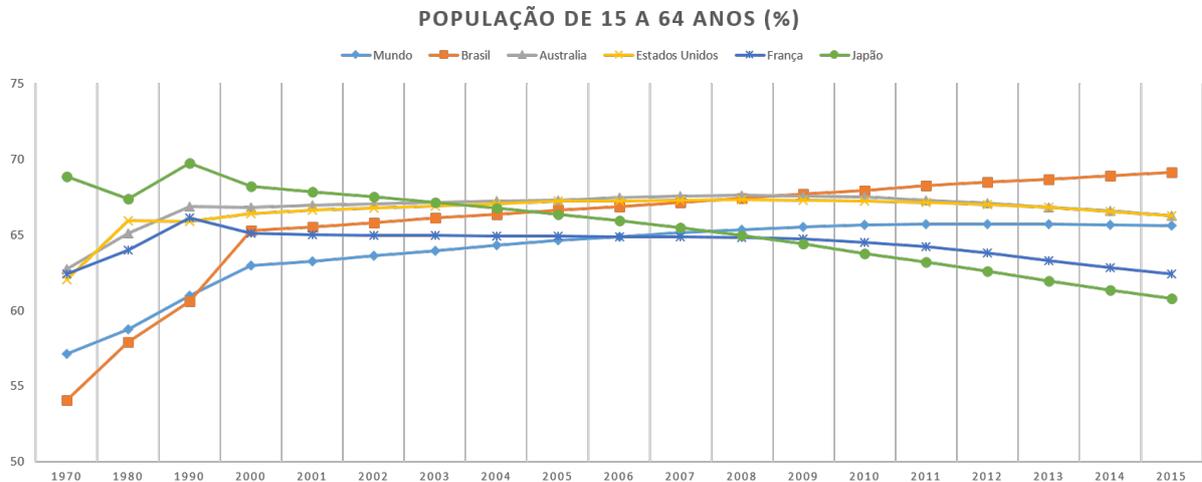
Figura 3 – Gráfico representando a taxa de natalidade mundial, do Brasil, Austrália, Estados Unidos, França e Japão ao longo dos anos.



Fonte: Adaptado de (The World Bank, 2014)

Juntamente com o aumento do número de idosos, cresce também o número de

Figura 4 – Gráfico ilustrativo do percentual de pessoas com mais de 15 e menos de 64 anos de idade no Brasil, Austrália, Estados Unidos, França, Japão e no mundo ao longo dos anos.



Fonte: Adaptado de (The World Bank, 2014)

dispositivos com poder de computação, comunicação e capacidade sensorial que estão presentes no dia a dia, principalmente os dispositivos dotados de tecnologias de comunicação sem fio. A grande proliferação destes tem ajudado a coletar uma maior quantidade de informações de diversos cenários nos quais estão presentes. No campo das telecomunicações, um paradigma que se tornou bastante importante é conhecido por Internet das Coisas (*Internet of Things* ou IoT).

A ideia básica deste conceito consiste na presença generalizada de uma variedade de coisas ou objetos no cotidiano, como sensores, atuadores e dispositivos com diferentes tecnologias. Através de esquemas de endereçamento único, estes são capazes de interagir uns com os outros e cooperar com seus vizinhos para alcançar objetivos comuns (ATZORI *et al.*, 2010), como por exemplo, gerenciar informações de usuários a fim de compor serviços, aplicações, sistemas, entre outros.

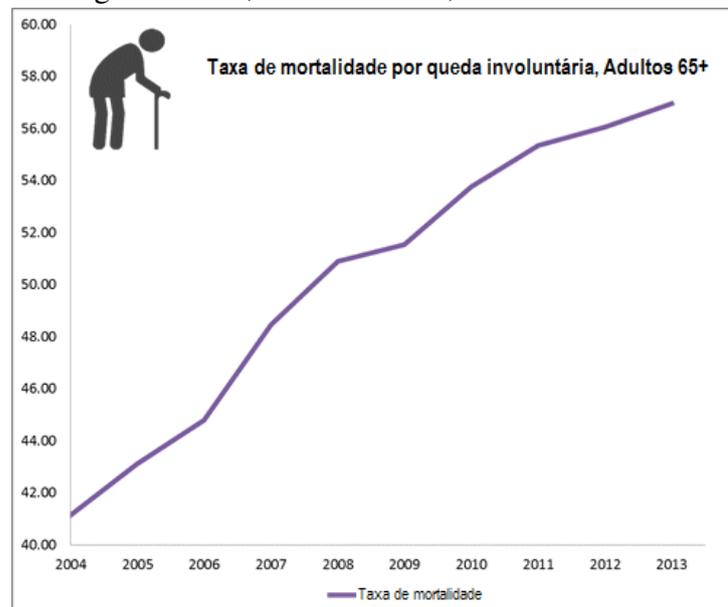
Segundo (TAN; WANG, 2010), o objetivo principal da IoT é conectar qualquer coisa, a qualquer momento, em qualquer lugar. Nesse cenário as coisas devem se comunicar umas com as outras e com o ambiente na qual estão localizadas, a fim de extrair informações. A Internet das Coisas abre um leque de oportunidades para aplicações e cenários que visam melhorar a qualidade de vida como, por exemplo, casas inteligentes, cidades inteligentes ou *Ambient Assisted Living* (AAL) que será explanado mais a frente. A Seção seguinte apresenta um problema comum aos idosos e como o uso de dispositivos capazes de sentir e atuar no meio pode ajudar a lidar com este problema.

1.2 Motivação

Envelhecer por si só já é um desafio para todos, devido às limitações que vão surgindo com o tempo. Por esse motivo, alguns necessitam de cuidadores, sejam eles profissionais ou parentes e amigos, que vão lhes auxiliar em atividades diárias. Uma questão importante é a redução das taxas de natalidade em todo o planeta, que foi mostrada anteriormente na Figura 3, o que provavelmente implicará em uma redução no número de cuidadores com o passar dos anos (RASHIDI; MIHAILIDIS, 2013a). Essa redução tornará ainda mais desafiador viver bem com uma idade avançada.

Dentre os problemas enfrentados pelos idosos, as quedas são bastante comuns. Pelo menos um terço dos idosos cai ao longo do ano (Centers for Disease Control and Prevention, 2013b). Cair em uma idade avançada pode ser bem perigoso, tendo em vista que esse tipo de evento é o maior responsável por hospitalização por traumas (BAKER; HARVEY, 1985)(Centers for Disease Control and Prevention, 2013a) e por morte devido às lesões da queda (MINIÑO *et al.*, 2007)(Centers for Disease Control and Prevention, 2013a) nessa faixa etária. A Figura 5 ilustra como o número de mortes associadas a quedas vem aumentando ao longo dos anos.

Figura 5 – Número de mortes atribuídas a quedas não intencionais, em indivíduos com mais de 65 anos ao longo dos anos, a cada 100000, nos Estados Unidos.



Fonte: Adaptado de (Centers for Disease Control and Prevention, 2013a)

Esse problema só tende a se agravar devido ao fato da maioria dos idosos, cerca de 64%, preferir ficar morando na sua própria residência, mesmo que morando só (Centers for

Disease Control and Prevention, 2013b). Eles preferem viver só do que morar em casas de repouso ou mesmo com familiares que podem auxiliá-los em suas necessidades e atividades diárias.

Uma das sugestões oferecidas pelo *Centers for Disease Control and Prevention* (CDC) norte americano é tornar o ambiente residencial mais seguro e contratar cuidadores para auxiliar no que for necessário. Mas isso pode ser um problema por causa dos elevados custos dos cuidadores e da visível redução da população jovem, o que provavelmente vai tornar cuidadores ainda mais caros e escassos. Além disso, um idoso que vive sozinho pode se encontrar incapacitado de pedir ajuda em um eventual acidente, mesmo que sua residência seja considerada segura.

Devido aos elevados custos de se manter um cuidador e a necessidade de monitorar idosos e pessoas com necessidade que moram sós, é imperativa a criação de sistemas que possam ajudar esses indivíduos a manter sua independência e segurança, além de tranquilizar os familiares. Mesmo em ambientes preparados para lidar com esse tipo de morador, o custo com empregados deve ser reduzido e a eficiência dos cuidadores maximizada. Logo, é de suma importância que tal ambiente seja preparado para monitorar seus residentes de forma eficiente, reforçando, assim, a necessidade de sistemas de monitoramento para idosos e pessoas com deficiências.

Os *Ambient Assisted Living* são ambientes que se utilizam de sistemas para que idosos e pessoas com necessidades especiais consigam realizar suas atividades do dia a dia de forma independente e segura. AAL está intimamente ligada à ambientes inteligentes, que, por sua vez, estão intimamente ligados à Internet das Coisas. Logo, é possível afirmar que em um ALL as coisas vão interagir com o objetivo de manter a segurança e independência do seu usuário. Em um caso mais específico, pode-se de detectar quedas e solicitar ajuda em eventuais emergências.

A detecção de quedas já vem sendo estudada há algum tempo na literatura, mas ainda é um grande desafio determinar com precisão quando uma queda realmente ocorre, evitando falsos positivos e falsos negativos.

1.3 Objetivo e contribuição

De acordo com a literatura, um desafio para os sistemas de detecção de quedas está na aceitação da tecnologia pelo usuário (MUBASHIR *et al.*, 2013), ou seja, se ele sente sua

privacidade comprometida ao utilizar uma dada tecnologia, logo esta provavelmente não é viável em cenários reais.

Outro problema é como lidar com falhas, pois em um ambiente como o AAL, uma falha pode significar a morte do residente. Por exemplo, um residente sofre uma queda e essa não é detectada, isso é uma falha do sistema e pode resultar em óbito. Por esse motivo faz-se necessária a utilização de mecanismos de redundância, como por exemplo, a utilização de sensores de diferentes tipos e independentes, onde a falha de um tipo não implica na falha do sistema como um todo.

Por fim, também existe a fragilidade de confiar apenas a um especialista a elaboração de classificadores para determinar quando um grupo de dados coletados significa uma queda. Dependendo de um especialista para atualizar o classificador de um ambiente pode ser um processo lento e custoso. Enquanto que utilizar algoritmos de aprendizagem para extração de modelos pode ser feito de forma mais rápida e tornar tal sistema mais robusto, podendo até ser personalizado para cada usuário, como em (LUSTREK *et al.*, 2015). A utilização das duas abordagens, regras e algoritmos de aprendizagem, pode trazer ganhos para um AAL capaz de detectar esse tipo de evento.

Este trabalho de dissertação de mestrado tem como objetivo atacar esses três problemas, propondo um método para detecção de quedas que utiliza aprendizagem de máquina para extração de um modelo baseado em informações de alto e baixo nível, provenientes de acelerômetros e sensores infravermelhos passivos. O classificador utiliza tecnologia de fácil aceitação pelo usuário e possui informações redundantes e complementares que podem melhorar a detecção do sistema quando somadas, mas que também podem ser usadas de forma independente, evitando a parada total do sistema.

1.4 Metodologia

Foi utilizada a seguinte metodologia para a realização deste trabalho de mestrado:

- Revisão bibliográfica - Foi realizada uma revisão da literatura com foco em Internet das Coisas, *Ambient Assisted Living*, Detecção de Quedas, Fusão de Dados e Aprendizagem de Máquina. Trabalhos que relacionassem tais temas foram considerados pontos importantes durante a revisão.
- Definição de características desejadas - Ainda durante a etapa de revisão da literatura, algumas características foram assinaladas nos sistemas e/ou mecanismos

de detecção de quedas apontados pela bibliografia. Dentre elas, algumas foram consideradas mais relevantes e desejáveis para o sistema desenvolvido neste trabalho.

- Desenvolvimento do método proposto - O desenvolvimento do método se deu através da união de dois tipos de sensores, acelerômetros internos de *smartphones*, capazes de detectar quedas e posturas, e sensores infravermelhos, com a finalidade de detectar localização *indoor* do usuário de um ambiente monitorado, juntamente com informação sobre a postura.
- Realização de experimentos - Para realização dos experimentos foram utilizados sensores infravermelhos e acelerômetros em um cenário controlado, todos disponibilizados pelo Grupo de Redes de Computadores, Engenharia de Software e Sistemas (GREat). Uma base de dados foi criada por meio do uso de voluntários que simularam diversas situações de quedas rápidas e lentas, bem como situações de não queda.
- Validação do sistema - A base criada na etapa de experimentação foi dividida em treino e teste e após a fase de treinamento do sistema, o mesmo foi avaliado.

1.5 Organização da Dissertação

Este documento de dissertação de mestrado está organizado em seis capítulos. O primeiro capítulo é a Introdução onde foi contextualizado o problema em foco, a motivação e o objetivo desta dissertação, assim como a metodologia utilizada e a organização do manuscrito. O restante se divide da seguinte forma:

Capítulo 2 - Fundamentação teórica: Aborda conceitos fundamentais para o bom entendimento de todo trabalho realizado. Eles são: Internet das Coisas (do inglês, *Internet of Things*), *Ambient Assisted Living* e Aprendizagem de Máquina.

Capítulo 3 - Trabalhos relacionados: Nesse capítulo, são apresentados trabalhos encontrados na literatura que trabalham com detecção de quedas, mais especificamente com detecção de quedas lentas e que utilizam localizam como uma das informações fusionadas.

Capítulo 4 - Uma nova abordagem para detecção de quedas: Encontra-se nesse capítulo a abordagem proposta para extrair modelos capazes de detectar quedas, baseado em acelerômetros e sensores infravermelhos passivos.

Capítulo 5 - Experimentos e resultados: Descreve os experimentos realizados

para validar o que foi proposto durante a execução deste trabalho de mestrado e os resultados encontrados.

Capítulo 6 - Conclusão: Os resultados encontrados, assim como as conclusões são apresentadas nesse último capítulo deste documento. Além disso, também são expostas algumas ideias de possíveis melhorias e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo serão apresentados conceitos que estão ligados ao problema da detecção de quedas e ao trabalho desenvolvido. Os conceitos mais importantes são Internet das Coisas, *Ambient Assisted Living* e Aprendizagem Automática, retratados, respectivamente, nas Seções 2.1, 2.2 e 2.3.

2.1 Internet das Coisas

Não existe consenso na literatura para a definição de Internet das Coisas. Dentre as definições existentes, algumas são mais aceitas e divulgadas. Dentre elas, algumas são apresentadas a seguir.

Segundo (TAN; WANG, 2010), o objetivo da Internet das Coisas é conectar qualquer coisa, a qualquer momento, em qualquer lugar, sem que se faça necessária a intervenção humana.

Em um relatório especial sobre Internet das Coisas, a IEEE descreve IoT como uma rede de itens equipados com sensores que estão conectados à Internet. Porém, esta não é uma definição oficial e trata somente do aspecto físico da IoT (IEEE Internet Initiative, 2015).

Segundo (European Research Cluster on the Internet of Things, 2015), duas definições de IoT são aceitas pela IERC - *European Research Cluster on the Internet of Things*. A primeira, proposta pela *ITU Telecommunication Standardization Sector (ITU-T)* (ITU Telecommunication Standardization Sector, 2012) afirma: "Internet das Coisas é uma infraestrutura global para a sociedade da informação, permitindo que serviços avançados por meio da interconexão de coisas (físicas e virtuais) com base em tecnologias de informação e comunicação existentes e em evolução. Através da exploração de identificação, captura de dados, capacidade de processamento e de comunicação, a Internet das coisas faz pleno uso das coisas para oferecer serviços a todos os tipos de aplicações, garantindo que os requisitos de segurança e privacidade são cumpridas. Nota 1 - Através da exploração de identificação, captura de dados, capacidade de processamento e de comunicação, a Internet das Coisas faz pleno uso das coisas para oferecer serviços a todos os tipos de aplicações, garantindo que os requisitos de segurança e privacidade são cumpridas. Nota 2 - A partir de uma perspectiva mais ampla, a Internet das Coisas pode ser percebida como uma visão com implicações tecnológicas e sociais".

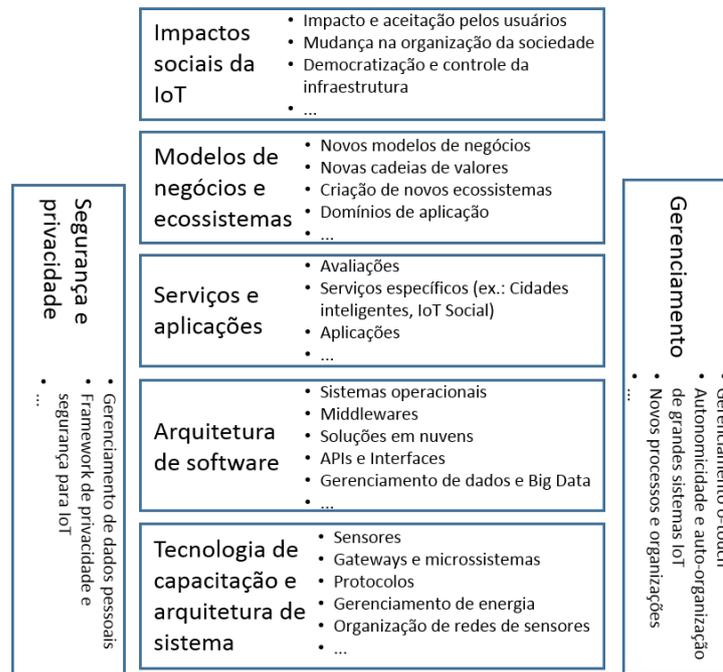
A segunda é proposta por membros da própria IERC, e afirma que IoT é uma infraestrutura dinâmica e global com capacidade de se autoconfigurar, baseada em padrões e

protocolos interoperáveis onde “coisas” físicas ou virtuais possuem identidades, atributos físicos e personalidades virtuais, utilizam interfaces inteligentes e estão integrados em uma rede de informações (VERMESAN; FRIESS, 2011).

Pode-se citar também a definição aceita pela ISO: "É uma infraestrutura de objetos, pessoas, sistemas e recursos de informação interligados juntamente com serviços inteligentes, que lhes permitam processar informações do mundo físico e virtual e reagir"(ISO/IEC JTC 1, 2014).

IoT é um domínio de aplicação que incorpora diferentes áreas tecnológicas e sociais, alguns desses podem ser observados na Figura 6, a saber: impactos sociais IoT, modelos de negócios e ecossistemas, serviços e aplicações, arquitetura de software, tecnologia de capacitação e arquitetura de sistema, gerenciamento e segurança e privacidade. É exatamente por essa composição tão abrangente que, apesar de ser um tópico tão explorado pela literatura ainda existem diversos desafios a serem abordados.

Figura 6 – Aspectos tecnológicos e sociais que estão relacionados à Internet das Coisas



Fonte: Adaptado de (IEEE Internet Initiative, 2015)

2.1.1 Desafios

Atualmente existem vários problemas para serem resolvidos em um cenário de Internet das Coisas. Tais problemas podem ser resumidos em três categorias: padronização;

endereçamento e problemas de rede; e segurança e privacidade.

Por se tratar de um cenário bastante heterogêneo, existem esforços que buscam padronizar a forma como esses dispositivos, aplicações e ambiente vão se comunicar. Algumas das iniciativas existentes podem ser encontradas em (ATZORI *et al.*, 2010), (IEEE Internet Initiative, 2015), (IEEE Internet Initiative, 2015), (ISO/IEC JTC 1, 2014), (AL-FUQAHA *et al.*, 2015), (RAMPARANY *et al.*, 2014) e (INDRA, 2017).

A IoT possui um número inacreditavelmente grande de nós, cada um capaz de produzir conteúdo e que deve permitir acesso a usuários autorizados, independentemente da sua localização naquele instante. Por esse motivo, existem diversos problemas que devem ser tratados. Esses desafios pertencem a diversas categorias (ATZORI *et al.*, 2010):

- **Arquitetura:** Não existe uma padronização que diga quais tecnologias, protocolos e arquiteturas devem ser empregados quando se trata de Internet das Coisas. Essa falta de padronização está muito relacionada ao fato de não existir uma única definição;
- **Disponibilidade:** A disponibilidade da IoT deve ser pensada tanto no hardware quanto no software, com objetivo de prover serviços em qualquer lugar e a qualquer momento. Aplicações devem ser capazes de prover serviços para qualquer um em qualquer lugar simultaneamente. Da mesma forma, os dispositivos devem ser compatíveis com protocolos e funcionalidades da IoT;
- **Confiabilidade:** É necessário entregar o sistema proposto de forma que este atenda às suas especificações e funcione corretamente. É uma característica crítica para aplicações no campo da emergência e está intimamente relacionada à disponibilidade;
- **Mobilidade:** Como foi citado anteriormente, a IoT visa entregar serviços para qualquer um, em qualquer lugar e a qualquer momento, caracterizando a disponibilidade dos serviços para usuário de dispositivos móveis, ou seja, é necessário disponibilizar serviços enquanto o usuário se move;
- **Desempenho:** Avaliar o desempenho de serviços para Internet das Coisas depende de vários fatores, como o desempenho dos componentes e das tecnologias empregadas. É necessário estar sempre melhorando e desenvolvendo novas formas de atender aos requisitos dos usuários;
- **Gerenciamento:** Gerenciar as conexões de bilhões de dispositivos inteligentes

é uma tarefa assustadora. É necessário, então, protocolos leves capazes de lidar com gerenciamento de falha, configuração, accountability, desempenho e segurança de todos os dispositivos da Internet das Coisas;

- Escalabilidade: É importante permitir a adição de novos dispositivos e serviços de forma simples e que não afete negativamente a qualidade dos já oferecidos. Porém, essa não é uma tarefa fácil, pois a heterogeneidade é uma característica marcante da IoT;
- Interoperabilidade: Outro desafio proveniente da heterogeneidade da IoT é a interoperabilidade. Como fazer com que essa diversidade de dispositivos, serviços, tecnologias e plataformas conversem entre si, sem que existam falhas no diálogo;
- Segurança e privacidade: Por fim, um dos principais desafios é o de segurança, principalmente pela falta de uma arquitetura única e padronização da Internet das Coisas. Não é uma tarefa simples garantir segurança e privacidade da informação trocada por bilhões de dispositivos e serviços heterogêneos.

Em (ATZORI *et al.*, 2010) e (AL-FUQAHA *et al.*, 2015), é possível encontrar discussões sobre esses desafios e referências a outros trabalhos que procuram solucionar alguns dos problemas apresentados acima.

2.1.2 Aplicações

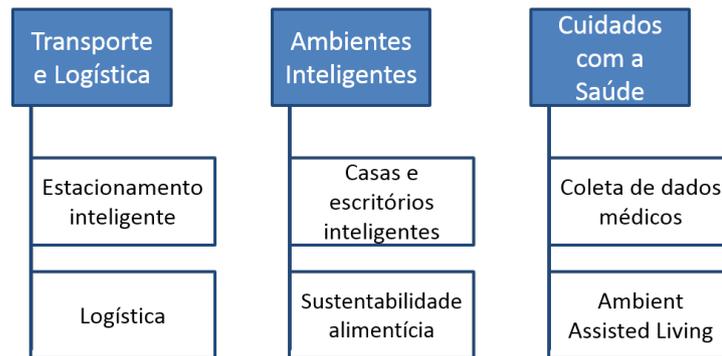
Diversas aplicações já fazem uso do conceito de Internet das Coisas e a tendência é que esse número aumente. Com o passar do tempo, mais dispositivos farão uso de tecnologias de computação e comunicação, possibilitando assim o surgimento de mais cenários onde IoT se faz presente. A Figura 7 ilustra algumas das possíveis aplicações que utilizam esse conceito e que são descritas a seguir.

2.1.2.1 Transporte e logística

Dentre as possíveis aplicações, sensores presentes nas vagas de estacionamento podem fornecer informações sobre entrada e saída de veículos. Esse tipo de informação pode ajudar os motoristas a poupar tempo e combustível fornecendo informações sobre onde está a vaga de estacionamento mais próxima.

Outra aplicação consiste em monitorar estoques. Dessa forma, é possível ter com-

Figura 7 – Aplicações de IoT.



Fonte: Adaptado de (AGRAWAL; VIEIRA, 2013)

pleto controle sobre entrada e saída de produtos e garantir que sempre exista estoque e que seja recarregado no momento certo, evitando desperdício e a falta de produtos (ATZORI *et al.*, 2010).

2.1.2.2 *Ambientes inteligentes*

Um cenário bastante conhecido são as casas e escritórios, onde o usuário está cercado de dispositivos eletroeletrônicos, como ar condicionado, luzes, ventilador, geladeira e outros. Sensores e atuadores presentes nesses dispositivos podem ajudar a controlar o ambiente e também o consumo de energia, tornando, assim, o ambiente mais agradável e poupando energia.

Outra aplicação consiste da produção e distribuição de alimentos. Sensores podem estar presentes no plantio, coletando informações e melhorando o rendimento da safra, na colheita, no transporte e na distribuição desses alimentos, evitando possíveis perdas (ATZORI *et al.*, 2010).

2.1.2.3 *Cuidados com a saúde*

Na área da saúde, diversas aplicações se tornam possíveis. Monitorar pacientes a distância por meio de sensores presentes nas roupas ou no corpo do paciente pode ajudar a detectar possíveis emergências e salvar vidas. Além disso, a massa de dados adquirida por meio dos sensores utilizados para monitorar os pacientes pode ser usada em estudos, proporcionando assim dados mais precisos para pesquisas nessa área (ATZORI *et al.*, 2010).

Um paradigma recente que está intimamente relacionado com IoT nas área de cuidados com a saúde e de ambientes inteligentes é o *Ambient Assisted Living*, que será explanado a seguir.

2.2 *Ambient Assisted Living* (AAL)

O constante avanço da medicina tem proporcionado melhor qualidade de vida e, com isso, maior longevidade. O aumento da população de idosos e de pessoas com necessidades requer soluções eficazes e de baixo custo que consigam entregar a essa população métodos de superar as dificuldades encontradas no dia a dia. *Ambient Assisted Living* fomenta o uso de tecnologias de informação e comunicação (TIC) para auxiliar pessoas idosas ou com algum tipo de necessidade especial a manter sua independência.

Ambient Assisted Living surgiu como uma iniciativa da União Europeia que encorajava o uso de TIC para atender às necessidades dos idosos, ao passo que também chamava atenção para o envelhecimento da população europeia e a necessidade de baratear os custos com a previdência social (IPIÑA *et al.*, 2009).

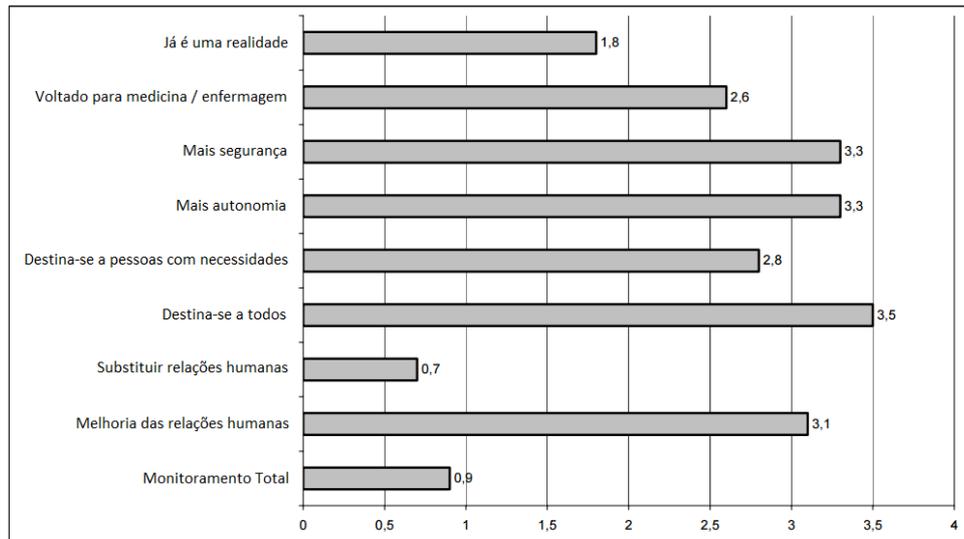
Segundo (GEORGIEFF, 2008) e (PIEPER *et al.*, 2011), AAL engloba conceitos, produtos e serviços que combinam TIC e ambientes sociais com o objetivo de proteger e melhorar a qualidade de vida, em qualquer idade. AAL também pode ser entendida como sistemas de assistência baseado na idade, que auxiliam nas diferentes necessidades dos usuários, para uma vida saudável e independente.

A Figura 8 ilustra a opinião de especialistas sobre o foco principal da AAL. Do ponto de vista deles, esse tipo de sistema tem como alvo um grupo muito grande de usuários e tem por objetivo proporcionar mais segurança e autonomia, melhorar as relações sociais, atender pessoas com necessidades e, principalmente, fornecer serviços médicos e/ou de enfermagem. Tais sistemas não representam uma forma de vigilância, nem buscam descartar o auxílio de cuidadores. Sistemas AAL podem ser utilizados para prevenir, ajudar na recuperação e melhorar o bem-estar ou condições de saúde de pessoas dependentes que necessitam de ajuda, ou que estão temporariamente dependentes de ajuda (RASHIDI; MIHAILIDIS, 2013b).

O uso de diferentes tecnologias se faz necessário para que AAL se torne uma realidade. Um exemplo seria a utilização de tecnologias assistivas e sensores móveis e vestíveis em um ambiente inteligente (*Smart Environment*)(RASHIDI; MIHAILIDIS, 2013b), as quais são definidas a seguir:

- Ambientes inteligentes são cenários, residenciais ou não, equipados com diversos sensores e atuadores. Os dados coletados podem ser analisados e utilizados para monitorar o estado de saúde seus usuários e também oferecer serviços adaptados aos mesmos, proporcionando assim mais conforto e bem-estar. Vale ressaltar

Figura 8 – Melhor descrição de *Ambiente Assisted Living*



Fonte: Adaptado de (GEORGIEFF, 2008)

novamente que este ambiente foi descrito como uma das possíveis aplicações da IoT, tornando evidente que este paradigma é capaz de dar suporte à implantação da AAL;

- Sensores móveis e vestíveis, como próprio nome diz, são sensores que podem se mover ao longo do tempo e/ou serem vestidos por usuários, como é o caso de GPS, acelerômetro, magnetômetro, giroscópio, sensores de movimento infravermelho, que podem ser usados para localizar e monitorar o movimento dos usuários, ou ainda sensores médicos de glicose, pressão, pulso, oxigênio, entre outros, podem medir o estado de saúde do usuário. Além disso, existem pesquisas em tecidos eletrônicos, para tornar imperceptível o uso desses sensores;
- As tecnologias assistivas fazem uso de diversos tipos de equipamentos, serviços, estratégias e práticas destinado a superar dificuldades físicas, cognitivas e facilitar tarefas do dia a dia bem como locomoção, comunicação, medicação, alimentação, de pessoas dependentes.

Todas essas tecnologias são utilizadas visando coletar o máximo de informação dos usuários e, com isso, tornar o sistema capaz de detectar padrões de atividades, modelar contexto, localizar pacientes, planejar atividades e detectar anomalias. Podem ser citados alguns exemplos como em (CAVALCANTE *et al.*, 2014), que lida com detecção de quedas, (MAGHERINI *et al.*, 2013) que trabalha com reconhecimento de atividades, rastreamento da posição de usuários em (NAZEMZADEH *et al.*, 2013) e modelagem de contexto em (HRISTOVA *et al.*, 2008). Em

(RASHIDI; MIHAILIDIS, 2013b), são listados outros algoritmos para cada uma das funções listadas anteriormente.

2.2.1 Aplicações

Ambient Assistent Living pode ser aplicada a diversas áreas, como monitoramento da saúde, detecção de emergências, bem-estar emocional, aplicações persuasivas e órteses cognitivas. A Tabela 2 ilustra alguns exemplos de aplicações em cada área.

Tabela 2 – Áreas de aplicação de AAL

Área de aplicação	Exemplos
Órteses cognitivas	Lembretes diários, Lembretes de medicação, Ferramentas de prevenção de perambulação
Monitoramento contínuo de saúde	Monitoramento de sinais vitais, Monitoramento de sono, Monitoramento de atividades diárias
Terapia	Sistemas de tele saúde, Sistemas de tele reabilitação
Detecção de emergência	Detecção de quedas, Detecção de emergências médicas, Detecção de perigo
Bem-estar emocional	Conectividade social, Comunicação facilitada (SUN <i>et al.</i> , 2008)
Aplicações persuasivas	Incentivo ao bem-estar, Cumprimento das recomendações médicas

Fonte: Autor

2.2.2 Desafios

Ambient Assisted Living é uma área relativamente recente e, mesmo tendo iniciado na Europa, vem ganhando bastante atenção, pois como foi visto no primeiro capítulo, a população de todos os continentes está envelhecendo. Assim como a Internet das Coisas, a AAL também está repleta de desafios. Alguns desses podem ser resumidos em categorias como:

- Design: o sistema não pode requisitar esforço do usuário, sendo necessário o uso de tecnologias que permitam a autogestão e se adequem às necessidades do usuário sem nenhum esforço do mesmo, ou com o mínimo possível;
- Tecnologia sensorial: sensores mais confortáveis de serem vestidos e com baterias melhores;
- Robótica assistiva: atualmente os robôs são construídos geralmente para um fim bem específico, o que limita seu uso em diversas atividades;
- Segurança e privacidade: é necessário garantir a segurança dos dados coletados

pelos sensores para garantir a privacidade dos usuários;

- Fatores humanos: usabilidade e experiência do usuário são extremamente importantes, dado que pessoas mais velhas normalmente não se interessam por tecnologias que consideram complexas;
- Algoritmos: ainda é preciso melhorar os algoritmos utilizados, a confiabilidade, a precisão, entre outros pontos para que seja possível a implantação de AAL no mundo real;
- Ético e legal: é preciso garantir os direitos dos usuários desse tipo de sistema.

Este trabalho tem como foco melhorar a detecção de quedas de sistemas AAL, por meio da fusão de dados coletados pelos sensores presentes em um cenário de IoT. Entretanto, o foco desta dissertação de mestrado não é apresentar um novo modelo para fusão dos dados, visto que algoritmos de aprendizagem de máquina foram utilizados nesta etapa da abordagem proposta. A Seção seguinte discute o que é aprendizagem automática e como a utilização de algoritmos dessa categoria funciona.

2.3 Aprendizagem automática

Com o aumento de dispositivos presentes no dia a dia com capacidade de coletar dados e se conectar à Internet, é necessária a utilização de mecanismos que acelerem a forma como os dados são avaliados, pois se atualmente o trabalho de analisar essas informações já é algo demorado e custoso, em alguns anos, será impossível. Aprendizagem automática (AA) (do inglês *Machine Learning*, ML) e mineração de dados (do inglês *Data Mining*) surgiram para suprir essa necessidade (THRUN; PRATT, 2012)(MURPHY, 2012).

Aprendizagem automática pode ser definida como um conjunto de métodos capazes de detectar padrões nos dados e, a partir desses, realizar previsões sobre novas informações ou tomar decisões (MURPHY, 2012). Em outras palavras, esses algoritmos são capazes de aprender a realizar tarefas após uma etapa de treino, onde observam e extraem informações necessárias para completar com sucesso a atividade (THRUN; PRATT, 2012).

2.3.1 Tipos de aprendizagem automática

Geralmente, AA é classificada em três abordagens principais: aprendizagem supervisionada ou preditiva, não supervisionada ou descritiva e aprendizagem por reforço.

Na aprendizagem preditiva, o objetivo do algoritmo é aprender a partir do mapeamento de entradas x e saídas y , dado um conjunto de pares de entradas e saídas $D = \{(x_i, y_i)\}_{i=1}^N$. D é a série de treino e N o número de exemplos. De maneira simplificada, cada entrada x_i é um vetor de dimensão D , composto por atributos ou características. Porém, x_i pode representar uma imagem, um gráfico, um texto, etc. Da mesma forma, a saída y_i , mas geralmente são variáveis categóricas ou nominais de um conjunto finito, por exemplo $y_i \in \{n, q\}$ (não queda e queda), ou pertencente a uma escala de valores reais. Quando y_i for categórico, tem-se um problema de classificação ou reconhecimento de padrões, enquanto que problema de regressão são aqueles onde y_i pertence a uma escala de valores reais.

A segunda abordagem é a aprendizagem descritiva ou não supervisionada. Nesse caso, os algoritmos recebem somente um conjunto de entradas $D = \{(x_i)\}_{i=1}^N$ e tem como objetivo encontrar padrões ou realizar agrupamento de dados. Esse é um tipo de problema não tão bem definido, pois não são informados padrões desejáveis nem métricas simples para avaliar os resultados (não existe um valor de saída y_i para um valor de entrada x_i).

A última das três classificações principais é a aprendizagem por reforço. Esta abordagem parte do princípio de aprender por meio de recompensas ou punições, ou seja, o algoritmo tem como objetivo maximizar a recompensa obtida durante a fase de aprendizagem.

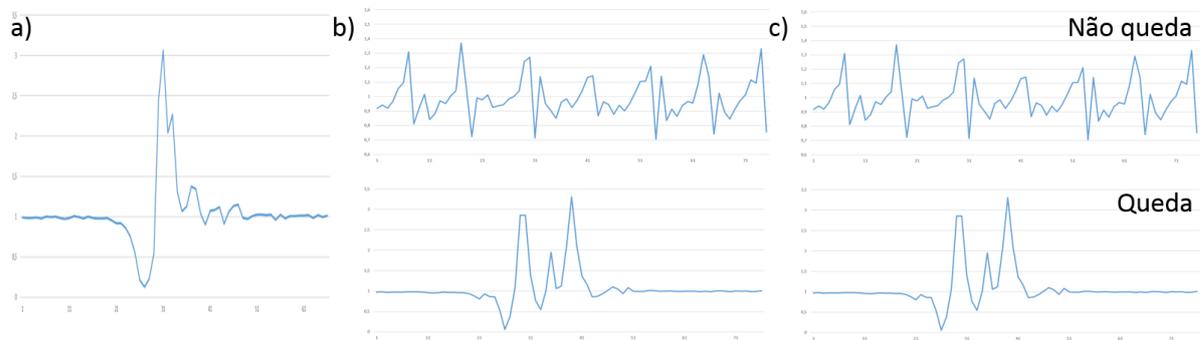
Este trabalho de dissertação lida com a detecção de quedas por meio de informações coletadas de sensores, de forma que é necessário classificar um determinado grupo de dados como queda ou não queda para determinar a ocorrência de tal evento. Logo, é possível inferir que se trata de um problema de classificação, baseada em aprendizagem supervisionada.

2.3.2 Classificação

O objetivo da classificação é aprender a mapear a partir de um conjunto de entradas x e saídas y , onde $y_i \in 1, \dots, C$ e C representa o número de classes, que no caso deste trabalho são duas ($\{n, q\}$). Problemas onde existem somente duas classes são conhecidos por classificação binária.

A formalização do problema pode ser feita utilizando uma função de aproximação. Por exemplo, $y = f(x)$, onde y é a saída, x a entrada e f uma função não conhecida. O algoritmo tem como objetivo estimar essa função a partir de um conjunto de treino rotulado e então realizar previsões utilizando $\hat{y} = \hat{f}(x)$. Fazer previsões no set de treino é algo simples. Por isso, o objetivo é utilizar \hat{f} em entradas não conhecidas pelo algoritmo.

Figura 9 – Classificação de dados de um acelerômetro: a)Gráfico de como geralmente é percebido um evento de queda; b)Grupos de dados não classificados; c)Classificação correta dos dados em b)



Fonte: Autor

A Figura 9a ilustra o gráfico do sinal gerado por um acelerômetro durante uma queda. Já 9b mostra 2 grupos de dados que devem ser classificados. A Figura 9c apresenta a classe de cada um dos dados. Fica visível que temos duas situações diferentes, onde um conjunto se assemelha ao que é considerado uma queda, enquanto o outro não.

A função de classificação pode ser determinada tanto utilizando conhecimento de um especialista, onde um humano cria regras que determinam como essa função se comporta, como pela utilização de algoritmos de AA. Cada uma das duas maneiras tem aspectos positivos e negativos.

Na literatura é possível encontrar as duas formas de classificação de quedas: por regras ou utilizando AA. O capítulo seguinte apresenta trabalhos relacionados ao que foi desenvolvido por esta dissertação.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta alguns trabalhos encontrados na literatura que tratam de detecção de quedas. Foram encontrados trabalhos que utilizam somente um tipo de sensor e trabalhos que coletam informações de dois ou mais. Existem publicações que consideram apenas quedas rápidas, enquanto outras também se preocupam com as quedas lentas, consideradas relevantes por poucos autores devido a dificuldade de detectar tais eventos.

Na Seção 3.1 são apresentados trabalhos sobre detecção de quedas que utilizam somente um tipo de sensor para coletar informações. Nessa seção, um trabalho lida com queda lenta enquanto os outros não tratam esse problema ou não informam. Na Seção 3.2, são apresentados trabalhos mais próximos da proposta desse trabalho de dissertação, onde são utilizados dois ou mais tipos de sensores (um deles para localização interna) e suas informações são fusionadas visando melhorar a detecção de quedas rápidas e lentas.

3.1 Detecção de quedas utilizando somente uma modalidade de sensor

Nesta seção, são apresentados três trabalhos que utilizam somente um tipo de sensor. Algumas características são discutidas com intuito de avaliar a abordagem proposta.

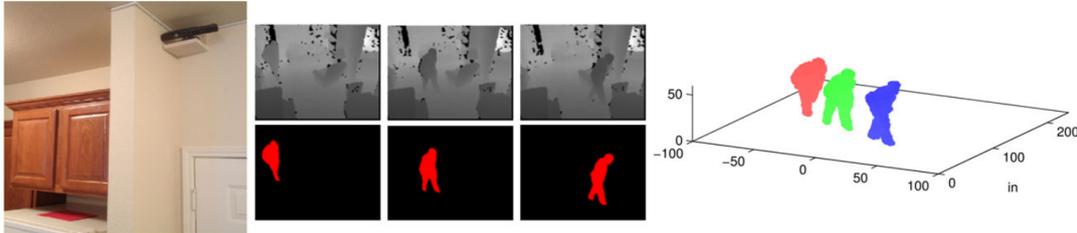
3.1.1 *Fall Detection in Homes of Older Adults Using the Microsoft Kinect*

Neste trabalho, é apresentada uma forma de detectar quedas em residências de idosos utilizando um Microsoft Kinect (MICROSOFT, 2010). Para isso, o mesmo foi implantando nas residências que faziam parte do estudo juntamente com um computador, responsável por avaliar as imagens coletadas.

Um sistema de dois estágios é utilizado. O primeiro estágio é encarregado de detectar a pessoa na vertical a partir de quadros de imagem em profundidade e criar uma sequência de quadros até a posição final, a pessoa no chão. O segundo estágio consiste em classificar como um evento ou não por meio de árvores de decisão. A Figura 10 ilustra o processo de separação em quadros e a utilização do Microsoft Kinect.

O equipamento utilizado é equipado com câmera, sensor de profundidade e microfone, além de ser capaz de perceber 48 pontos de articulação do corpo humano. Porém, a implantação de um Microsoft Kinect para cobrir cada cômodo além de ser caro, vai de encontro à privacidade do usuário, principalmente em relação ao banheiro, já que utiliza recursos

Figura 10 – A imagem mais a esquerda mostra um Kinect instalado em um apartamento. A imagem do meio são exemplos de quadros de imagem em profundidade e extração do primeiro plano do apartamento. A imagem da direita representa o objeto tridimensional formado a partir da extração do primeiro plano.



Fonte:(STONE; SKUBIC, 2015)

audiovisuais para monitorar o residente.

A avaliação do trabalho foi feita por meio de validação cruzada, onde a abordagem proposta foi capaz de detectar corretamente 98% das quedas onde o usuário estava em pé, 70% das que ele estava sentado e 71% das que ele estava deitado. Este trabalho não avalia quedas lentas.

3.1.2 *A real-time falls detection system for elderly*

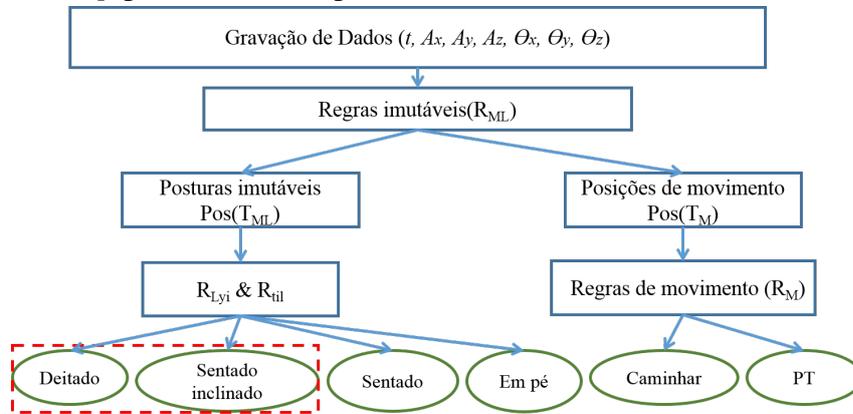
Em (ZHANG *et al.*, 2013), é apresentado um sistema de detecção de quedas que é composto por duas etapas e se baseia na ideia de detectar quedas a partir da transição entre posturas e atividades. Primeiramente, um algoritmo é utilizado para classificar as posturas com movimento e posturas sem movimento, como por exemplo, andar é uma postura com movimento, enquanto ficar em pé é uma postura sem movimento. A Figura 11 ilustra este primeiro passo do sistema.

Em uma segunda etapa, o algoritmo julga se a postura deitado ou sentado foi atingida a partir de uma sequência natural ou anormal. Se for considerada anormal, ele dispara um alarme. Em caso de dúvidas, um som de alerta é utilizado para que o usuário determine se houve ou não queda. A Figura 12 ilustra a segunda etapa do sistema proposto.

O trabalho classifica movimento e postura por meio do acelerômetro interno de um *smartphone*. A utilização de aceleração para inferir essas informações é algo bem explorado pela literatura e se mostra eficiente. Porém, a dependência do usuário é muito alta, pois necessita que este vista o equipamento e confirme a ocorrência de quedas lentas. Assim, fica claro que o momento do banho se torna um cenário não coberto pelo sistema de (ZHANG *et al.*, 2013).

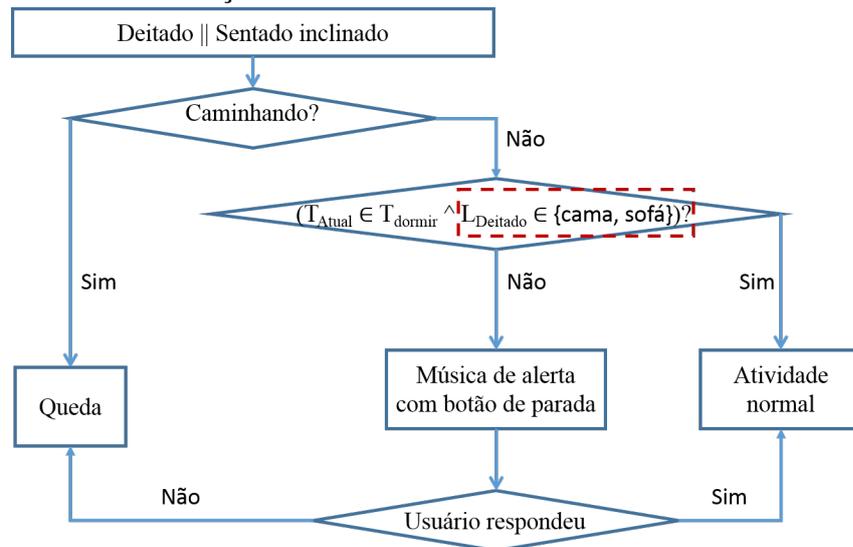
Este trabalho se mostra capaz de detectar quedas lentas e compara seus resultados

Figura 11 – Fluxograma ilustrando a como ocorre a classificação de postura em (ZHANG *et al.*, 2013). O algoritmo lê dados da aceleração dos eixos x,y e z (A_x, A_y e A_z respectivamente), dos ângulos de inclinação em relação a cada eixo (θ_x, θ_y e θ_z) e o *timestamp* para diferenciar posturas com movimento e sem movimento



Fonte: Adaptado de (ZHANG *et al.*, 2013)

Figura 12 – Fluxograma do algoritmo de detecção de quedas implementado em (ZHANG *et al.*, 2013). Se o usuário está deitado ou sentado de forma inclinada, então é verificada a postura anterior do mesmo, caso o algoritmo entenda como uma queda lenta ele solicita a confirmação do usuário da ocorrência do evento.



Fonte: Adaptado de (ZHANG *et al.*, 2013)

com um algoritmo baseado em limiares. O algoritmo proposto obteve 91,30% de detecções corretas enquanto que o baseado em limiares apenas 39%.

3.1.3 Fall classification by machine learning using mobile phones

Esse trabalho utiliza o acelerômetro de um celular para constatar quedas. Todos os dados coletados foram utilizados para treinar diferentes classificadores baseados em aprendizagem automática. A ideia principal é mostrar que é possível gerar classificadores de forma

automática e esses são capazes de detectar quedas de forma eficiente.

Figura 13 – a) *Smartphone* utilizado em (ALBERT *et al.*, 2012) e a localização do mesmo nas costas do indivíduo. b) Eixos do acelerômetro das figuras à esquerda.



Fonte: Adaptado de (ZHANG *et al.*, 2013)

Foram avaliados cinco algoritmos de AA: *support vector machines* (SVM), *sparse multinomial logistic regression* (SMLR), *naive Bayes*, *decision trees* e *k-nearest neighbors*. Com exceção do *naive Bayes*, todos apresentam bons resultados.

Um grande problema desse trabalho é a utilização de apenas uma modalidade para detectar quedas. Assim como no anterior, o equipamento é responsabilidade do usuário, logo se o mesmo não o equipar, é impossível determinar quando ocorreu uma queda.

Assim como a utilização de vários sensores visa aumentar a confiabilidade da informação, a utilização de um classificador que utiliza regras e algoritmos de AA pode melhorar a habilidade do sistema de classificar corretamente.

Os resultados apresentados na Tabela 3 foram obtidos por meio de validação cruzada utilizando a base completa com todos os usuários e bases individuais. Vale ressaltar que não foram avaliadas quedas lentas.

Tabela 3 – Resultados obtidos em (ZHANG *et al.*, 2013)

Validação \ Classificador	SVM	SMLR	Naive Bayes	Decision Trees	kNN
Detecção de queda utilizando a base completa	98.2%	98.0%	66.3%	95.9%	97.9%
Detecção de queda utilizando bases individuais	97.2%	96.6%	62.8%	93.8%	96.8%

Fonte: (ZHANG *et al.*, 2013)

3.1.4 Conclusões

Todos os trabalhos apresentados nesta seção utilizam apenas uma modalidade de sensor. Isso torna o sistema suscetível a falhas, pois se o dispositivo responsável por sentir o usuário falhar, todo o ambiente falha. Outra motivação para utilizar diferentes tipos de sensores é coletar um número maior de informações que podem reforçar a percepção de eventos.

A seguir serão apresentados trabalhos que lidam com mais de uma modalidade de sensor. Por motivos de proximidade ao trabalho desenvolvido nesta dissertação de mestrado, foram considerados trabalhos que utilizam localização como uma das informações coletadas.

3.2 Detecção de quedas utilizando localização

Esta seção lista trabalhos que se utilizam da informação de localização *indoor* do usuário. Na literatura, utilizar a localização do usuário para auxiliar na detecção de quedas não é algo comum, já que a maior parte da literatura não considera a percepção de quedas lentas. A seguir, são discutidas quatro abordagens utilizadas por outros autores.

3.2.1 *First steps in adaptation of an Evidential Network for data fusion in the framework of medical remote monitoring*

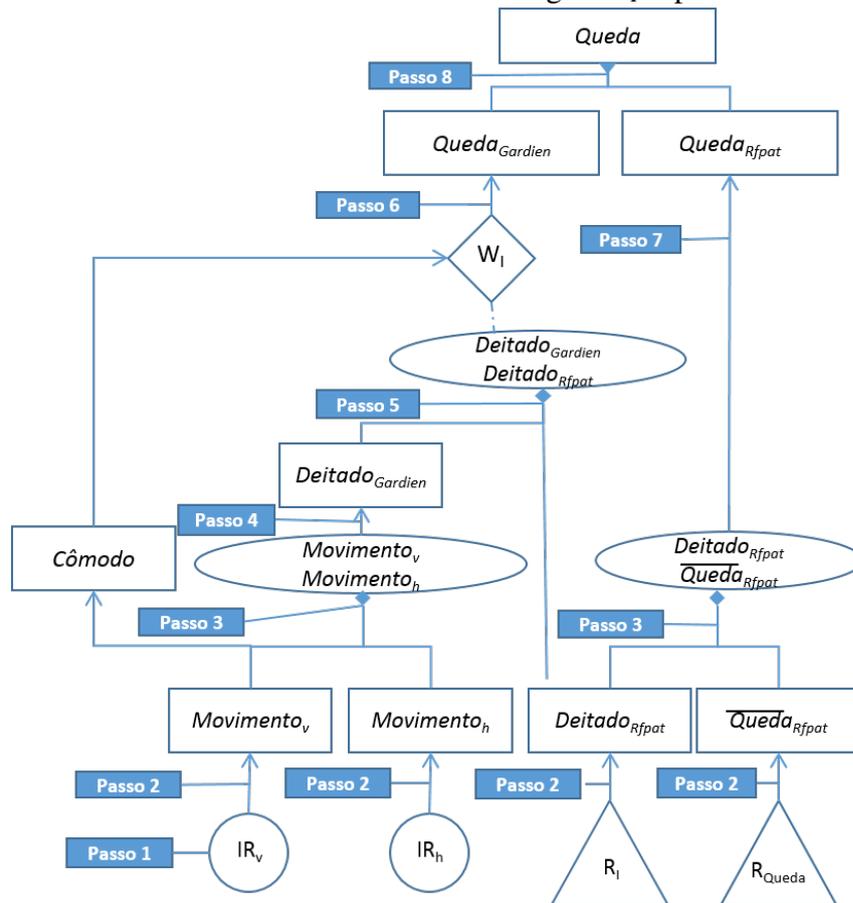
Esse trabalho apresenta uma aplicação para monitoramento remoto que visa detectar quedas. Tal aplicação se baseia em informações derivadas de três outros trabalhos, RFPAT (BALDINGER *et al.*, 2004), GARDIEN (STEENKESTE *et al.*, 1999) e ANASON (ISTRATE *et al.*, 2006), que utilizam quatro tipos de sensores, *actigraphy* (sensor que detecta movimentação, similar à um pedômetro) e frequencímetro, infravermelhos e microfones, respectivamente.

O RFPAT é capaz de monitorar os batimentos cardíacos e o comportamento da pessoa (movimentação e postura) por meio de um dispositivo vestível que incorpora *actigraphy* e frequencímetro. Tal aplicação é capaz de identificar situações de risco. Já o GARDIEN é composto por uma rede de sensores infravermelhos implantados no ambiente que é capaz de detectar a localização e postura por meio da utilização de um sensor implantado a um metro do solo. E o último é o ANASON, capaz de reconhecer padrões na fala do usuário e assim identificar eventos de risco.

Para detecção de eventos de queda, (CAVALCANTE *et al.*, 2012) utiliza uma rede de evidências (*Evidential Network* ou EN) que fusiona os dados obtidos pelo RFPAT e GARDIEN

de forma hierárquica, com intuito de garantir maior confiança e robustez da detecção. Além disso, as informações do ANASON são adicionadas posteriormente para melhorar o desempenho do sistema. A Figura 14 apresenta a rede de evidências utilizada neste trabalho.

Figura 14 – Rede de evidências que fusiona informações do RFPAT e GARDIEN para detectar quedas. Na figura v representa o sensor que observa todo o ambiente e h o sensor posicionado a 1m de altura do chão. O triângulo R_I representa o *actigraphy* inerte



Fonte: Adaptado de (CAVALCANTE *et al.*, 2012)

Esse trabalho também utiliza uma abordagem para adaptar regras de uma rede de evidências. Para isso, utiliza um algoritmo não supervisionado.

A utilização de sensores infravermelhos é um ponto forte do trabalho. Porém, fica visível na Figura 14 que as informações dos dois tipos de sensores estão atreladas. Logo, a falha ou não utilização de uma destas modalidades pode afetar o funcionamento da aplicação como um todo. Por se tratar de um ambiente onde um acidente pode ser fatal, é importante existir alguma forma de superar falhas.

Outro ponto importante é a utilização de um *actigraphy*, um sensor capaz de medir movimentação do usuário, que pode ser comparado a um pedômetro. Quando comparado a um

acelerômetro, esse tipo de sensor deixa muito a desejar, pois as informações provenientes do acelerômetro são muito mais ricas.

Vale citar também o uso de microfones. Primeiramente, porque mesmo que esses possam detectar eventos onde o paciente solicita ajuda, é importante notar que sua utilização não está atrelada à rede de evidências. E segundo porque é necessário levar em conta a privacidade do usuário, o que pode tornar a eficiência de tal mecanismo questionável.

Por fim, é importante ressaltar que este trabalho apresenta um índice de detecção de 93,94% e que abordagem utilizada permite detecção de quedas lentas, que é um ponto muito importante quando se lida com detecção de quedas. Porém o sistema depende unicamente do usuário já que os sensores infravermelhos não funcionam de forma independente.

3.2.2 A Dynamic Evidential Network for Fall Detection

Nesse trabalho, foi desenvolvido um mecanismo para detecção de quedas que utiliza *Dempster-Shafer theory* (DST) como mecanismo de fusão dos dados. Os dados são provenientes do RFPAT e GARDIEN, como no trabalho descrito anteriormente.

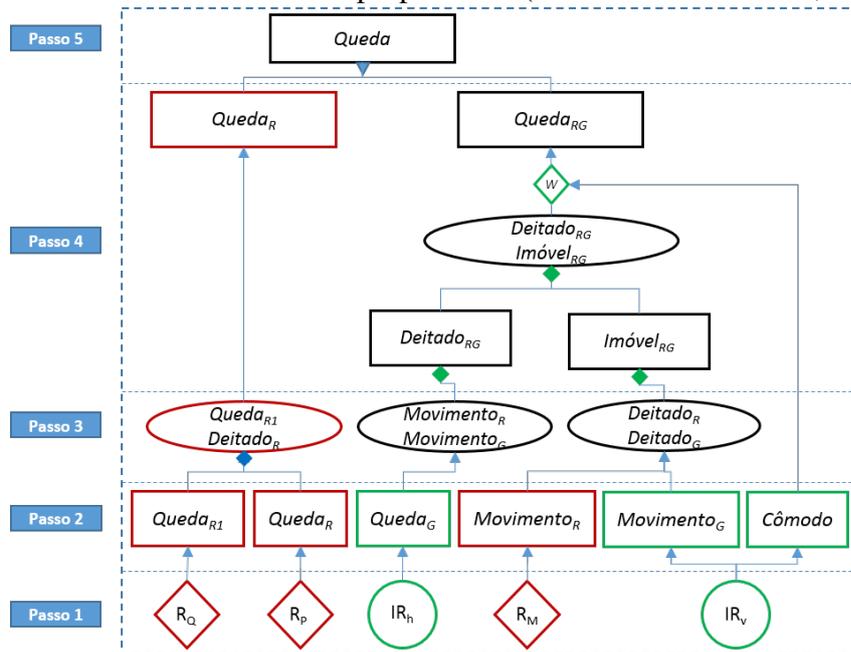
Diferente do trabalho anterior, esse não utiliza microfones e se diferencia também por utilizar notações de matrizes ao invés de algoritmos não supervisionados. Outra característica importante desse trabalho é a utilização de uma rede de evidências dinâmica para superar alguns problemas como degradação do sistema de detecção de quedas.

Um ponto forte é a capacidade de detectar quedas somente com os dados fornecidos pelo GARDIEN, como mostra a Figura 15, onde a rede de evidências utilizada torna independente a análise de queda por parte dos sensores infravermelhos. Por se tratar de uma evolução do trabalho anterior, esse também se caracteriza pela detecção de quedas lentas.

O trabalho avalia 33 quedas, 16 rápidas e 17 lentas. São testados dois classificadores, um utiliza informações do RFPAT e GARDIEN fusionadas por meio de uma rede de evidências estática, que obteve um percentual de acerto de 93,94%. Já o segundo usa somente o GARDIEN e uma rede de evidências dinâmica, e obteve uma acurácia de 96,97%.

Alguns pontos negativos devem ser ressaltados, o número de quedas avaliadas, o uso de um *actigraphy* e um classificador de que depende somente da expertise do especialista, já que uma adaptação para diferentes usuários requer um custo maior quando comparado à algoritmos de AA.

Figura 15 – Rede de evidência proposta em (CAVALCANTE *et al.*, 2014).



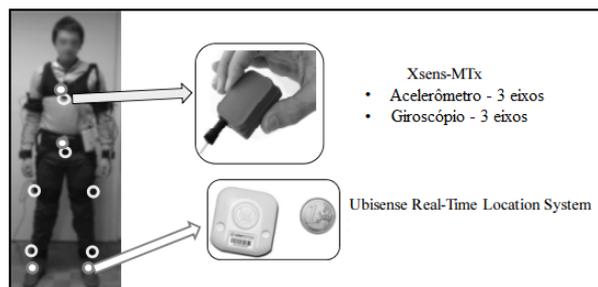
Fonte: Adaptado de (CAVALCANTE *et al.*, 2014)

3.2.3 Context-based fall detection and activity recognition using inertial and location sensors

Em (GJORESKI *et al.*, 2014), é desenvolvido um sistema para detecção de quedas baseados em um acelerômetro de seis eixos (acelerômetro e giroscópio) e sensores para localização *indoor*, ambos vestíveis. O método utilizado se baseia na informação de contexto, de algumas atividades básicas e da localização do usuário para detectar quedas.

A Figura 16 ilustra os sensores utilizados e os possíveis locais para utilização. Foram testadas combinações com seis acelerômetros (Xsens-MTx) e quatro sensores de localização (*Ubisense Real-Time Location System*).

Figura 16 – Equipamentos utilizados em (GJORESKI *et al.*, 2014). Os círculos não preenchidos representam os acelerômetros, enquanto os preenchidos são os sensores de localização.



Fonte: Adaptado de (GJORESKI *et al.*, 2014)

Os dados dos acelerômetros, giroscópios e dos sensores de localização foram utilizados para treinar um classificador responsável por reconhecimento de atividades. Esses mesmos dados foram utilizados por um algoritmo baseado em limiares para identificação de quedas e para identificar se o usuário está se movimentando.

Informações de localização, atividade, movimentação e queda são então utilizadas para decidir se foi detectado que o residente caiu involuntariamente. Utilizando dados de contexto esse trabalho consegue detectar quedas rápidas e lentas. O processo descrito é ilustrado na Figura 17. O acelerômetro de 6 eixos e os sensores de localização fornecem dados que são utilizados para gerar um modelo de classificação de atividades. Os dados dos sensores e do classificador são então avaliados e é detectada uma queda ou não.

Figura 17 – Arquitetura do sistema proposto em (GJORESKI *et al.*, 2014).



Fonte: Adaptado de (GJORESKI *et al.*, 2014)

Alguns pontos podem ser enfatizados, como a utilização de informações de contexto, localização e atividades, para ajudar a detecção de quedas lentas. Ambas são informações importantes. Porém, para conseguir classificar atividades é geralmente necessário um conjunto maior de sensores, o que aumenta a dependência do sistema em relação ao usuário e pode diminuir a aceitação pelo usuário, pela quantidade de equipamentos necessários.

Os sensores de localização utilizados também desfavorecem o funcionamento deste trabalho, por se tratar de sensores vestíveis. É importante frisar que o cômodo mais perigoso da casa é o banheiro (Centers for Disease Control and Prevention, 2011)(FERRETTI *et al.*, 2013) e que é possível que o residente não esteja utilizando os sensores nesse cenário. Nesse caso, o sistema se tornaria inoperante.

São avaliados diferentes atividades e quedas, incluindo quedas lentas. Utilizando somente os acelerômetros, o trabalho obteve um percentual de acerto de 67,9%. Utilizando os

sensores de localização, que também informam atividade, o resultado foi de 87,7% de acerto. Quando combinadas as modalidades o resultado de 96,6%. Vale ressaltar que a abordagem utiliza um total de 10 sensores presos ao corpo do usuário.

3.2.4 *Fall detection using location sensors and accelerometers*

Esse trabalho apresenta o *Confidence*, um sistema que pode utilizar qualquer método de localização com precisão suficiente para detectar posturas e atividades, por exemplo o *Ubisense Real-Time Location System*. Esse sistema pre-processa as informações dos sensores de localização para reconhecimento de atividades, assim é possível reconhecer situações anormais, por exemplo, deitar no banheiro. E juntamente com as informações de contexto, é capaz de detectar quedas. Ele também pode utilizar informações de um acelerômetro para corrigir o reconhecimento de atividades e contexto, além de ser capaz de personalizar o funcionamento para cada usuário.

O reconhecimento de atividades é feito tanto por algoritmos de aprendizagem automática quanto por algoritmos baseados em regras determinadas por especialistas, utilizando somente as informações do sistema de localização. O acelerômetro pode ser utilizado para corrigir ou confirmar que o usuário está deitado.

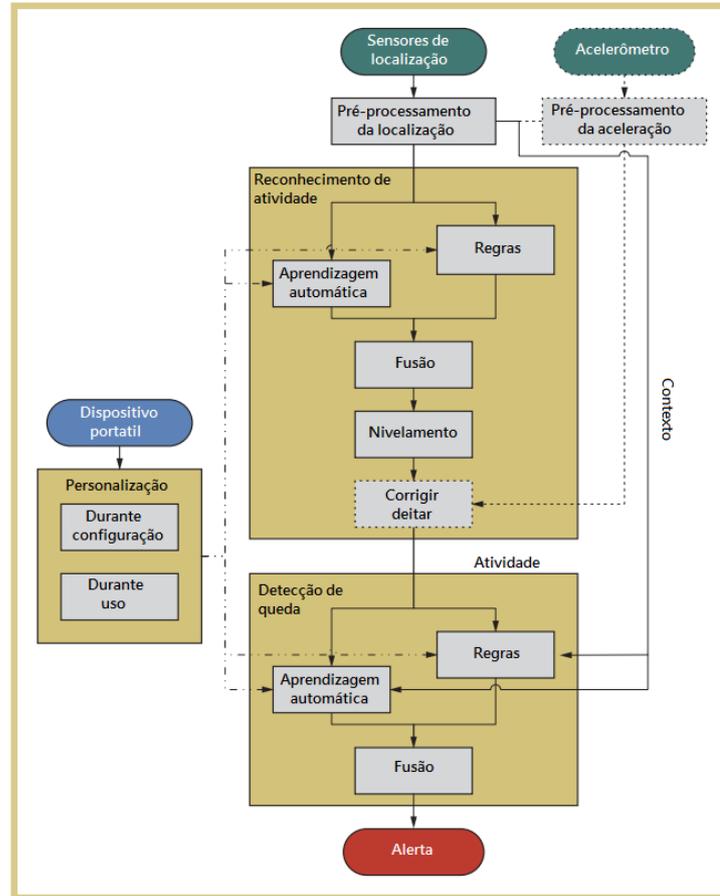
A detecção de quedas também se dá por meio de algoritmos de AA e baseados em regras que utilizam as informações de contexto e de atividade e opcionalmente dados personalizados do usuário. Esse processo é ilustrado na Figura 18.

Sobre esse trabalho, pode-se afirmar que a utilização de algoritmos de AA juntamente com algoritmos baseados em regras é um ponto forte, assim como a capacidade de personalizar o sistema para cada usuário e a não obrigatoriedade do uso do acelerômetro.

Porém, ao mesmo tempo em que torna o acelerômetro opcional, a abordagem confia em sensores vestíveis para determinar localização e inferir atividades. Novamente, surge o problema de todo o sistema depender do usuário para funcionamento correto, e novamente pode-se afirmar que o banheiro será um grande problema para tal sistema.

O resultado da avaliação do sistema proposta sem o uso do acelerômetro com apenas um sensor de localização foi de 94,2%, enquanto que com o uso do acelerômetro o acerto foi de 96,4%. Já com a utilização de 4 sensores de localização presos ao corpo, o sistema foi capaz de detectar corretamente 95,3% dos eventos sem utilizar acelerômetro e 98,6% quando estes estavam equipados.

Figura 18 – Arquitetura do sistema de detecção de quedas proposto em (LUSTREK *et al.*, 2015). A linha pontilhada indica que o acelerômetro pode ser usado para corrigir o reconhecimento de atividade e contexto. A linha tracejada indica como o sistema se pode ser adaptado para uso personalizado.



Fonte: Adaptado de (LUSTREK *et al.*, 2015)

A Seção 3.3 resume e discute os trabalhos relacionados apresentados nas Seções 3.1 e 3.2.

3.3 Conclusões

Dentre os trabalhos citados, alguns dispositivos podem ser considerados indesejáveis pelos usuários, como câmeras e microfones, por questões de privacidade. Logo, um sistema de detecção de quedas deve evitar a utilização de tais tecnologias.

Outro ponto que vale citar é a utilização de tecnologias que dependem do usuário para que o ambiente projetado funcione corretamente. A forma mais precisa de monitorar o residente é por meio de tecnologias vestíveis. Porém, em se tratando de idosos que podem esquecer de equipar os dispositivos necessários o funcionamento de um sistema que confia unicamente no usuário fica comprometido. E mesmo considerando que o usuário nunca esqueça,

monitorar algumas situações no banheiro é inviável, que é considerado o local mais perigoso de uma residência (Centers for Disease Control and Prevention, 2011)(FERRETTI *et al.*, 2013).

A utilização de vários sensores visa aumentar a confiabilidade da informação, seja por meio de dados redundantes seja por meio de dados complementares. Partindo dessa premissa, a utilização de um classificador que utiliza regras e algoritmos de AA pode melhorar a habilidade do sistema de classificar corretamente. Essa combinação é vista em (LUSTREK *et al.*, 2015).

Nenhum dos trabalhos apresentados consegue suprir todos os seguintes pontos levantados:

- O tipo de tecnologia empregada deve ser de fácil aceitação pelo usuário;
- A abordagem não pode depender somente do usuário e deve implementar mecanismos de redundância a fim de suprir uma possível falha de uma das modalidades fusionadas e complementares no intuito de produzir informações mais precisas;
- Algoritmos de aprendizagem automática são capazes de gerar um classificador de forma rápida e assim facilitar a adaptação do sistema. Porém, a experiência do especialista é muito importante e, somada aos algoritmos de AA, pode melhorar a eficiência do sistema.

A Tabela 4 compara os trabalhos relacionados descritos neste capítulo em relação à detecção de quedas rápidas e lentas e o tipo de classificador utilizado. É possível notar que somente os trabalhos que utilizaram localização se preocuparam em detectar quedas lentas, pois foi exatamente pensado em detectar esse tipo de evento, desconsiderado por boa parte da literatura, que surgiu a ideia de usar essa informação de contexto.

Tabela 4 – Trabalhos relacionados - Tipos de quedas e de classificador

Abordagem	Tipo de Queda		Classificador	
	Queda rápida	Queda lenta	Regras	AA
(STONE; SKUBIC, 2015)	X		X	
(ZHANG <i>et al.</i> , 2013)	X	X	X	
(ALBERT <i>et al.</i> , 2012)	X			X
(CAVALCANTE <i>et al.</i> , 2012)	X	X	X	
(CAVALCANTE <i>et al.</i> , 2014)	X	X	X	
(GJORESKI <i>et al.</i> , 2014)	X	X	X	
(LUSTREK <i>et al.</i> , 2015)	X	X	X	X

Fonte: Autor

Por sua vez, a Tabela 5 mostra que utilizar aceleração como uma forma de identificar situações de queda é algo bastante explorado pela literatura. Ao mesmo tempo, tecnologias vestíveis em geral estão sendo exploradas como possíveis meios de detectar quedas. Ainda na

tabela, fica visível que equipar o ambiente com dispositivos para monitorar o residente é outra forma de detectar quedas. Por esse motivo, o crescimento da Internet das Coisas pode colaborar de forma imprescindível para melhoria da qualidade de vida de usuários de AAL.

Tabela 5 – Trabalhos relacionados - Abordagem e categoria utilizadas

Abordagem	Vestível		Ambiente		Visão Computacional
	Aceleração	Outro	Áudio/Vídeo	Infra Vermelho	
(STONE; SKUBIC, 2015)					X
(ZHANG <i>et al.</i> , 2013)	X				
(ALBERT <i>et al.</i> , 2012)	X				
(CAVALCANTE <i>et al.</i> , 2012)	X		X	X	
(CAVALCANTE <i>et al.</i> , 2014)	X	X		X	
(GJORESKI <i>et al.</i> , 2014)	X	X			
(LUSTREK <i>et al.</i> , 2015)	X	X			

Fonte: Autor

As tecnologias utilizadas na Tabela 5 refletem na Tabela 6, onde ficam visíveis os possíveis cenários e a relação de dependência do usuário. Dessa forma, é possível ver que, apesar de ser algo bem comum, sensores vestíveis dependem do usuário para equipá-los e desta forma sem auxílio do mesmo, o sistema fica inoperante. Utilizar sensores que os usuários não aprovam em suas residências, ou em cômodos específicos, como câmeras e microfones também compromete o funcionamento de um sistema de detecção de queda.

O banheiro é o cenário com maior risco de acidentes domésticos em uma residência (Centers for Disease Control and Prevention, 2011)(FERRETTI *et al.*, 2013), ao mesmo tempo é o cenário onde a maior parte dos trabalhos desenvolvidos não pode ser utilizado ou se torna inoperante, como mostra a Tabela 6.

Tabela 6 – Trabalhos relacionados - Usos e restrições

Abordagem	Cômodo		Usuário	
	Banheiro	Outro	Dependente	Independente
(STONE; SKUBIC, 2015)		X		X
(ZHANG <i>et al.</i> , 2013)		X	X	
(ALBERT <i>et al.</i> , 2012)		X	X	
(CAVALCANTE <i>et al.</i> , 2012)		X	X	
(CAVALCANTE <i>et al.</i> , 2014)	X	X	X	X
(GJORESKI <i>et al.</i> , 2014)		X	X	
(LUSTREK <i>et al.</i> , 2015)		X	X	

Fonte: Autor

A abordagem proposta neste trabalho de dissertação de mestrado visa detectar quedas rápidas e lentas por meio de tecnologias de fácil aceitação pelo usuário, que forneçam informações complementares e redundantes e que utilize a expertise de um especialista, e ao

mesmo tempo, classifique quedas por meio de algoritmos de aprendizagem automática. O capítulo seguinte apresenta essa abordagem.

4 UMA NOVA ABORDAGEM PARA DETECÇÃO DE QUEDAS

Foi mostrado anteriormente que a população de idosos vem crescendo com o passar dos anos e que cair involuntariamente é algo que ocorre a um em cada três idosos. Tais quedas podem ser fatais em alguns casos, e por esse motivo é importante detectar de forma adequada a ocorrência de tais eventos. As quedas podem ser classificadas em dois tipos: a) quedas rápidas, que ocorrem quando a pessoa monitorada cai de forma abrupta, normalmente seguida de impacto, o que facilita sua detecção; b) quedas lentas, que se caracterizam pela ausência de impacto, onde o indivíduo cai de forma lenta, normalmente se apoiando em algo e o sistema geralmente entende que ele está sentando ou deitando.

Este trabalho acredita que, com a proliferação de dispositivos capazes de perceber características do meio no qual os indivíduos estão localizados, é possível melhorar a qualidade de vida de pessoas com algum tipo de debilidade, que é o que caracteriza um AAL. Neste intuito, alguns pontos foram levantados considerando um método para detecção de quedas:

- A tecnologia empregada deve ser facilmente aceita pelo usuário, haja vista que, alguns dispositivos ferem sua privacidade, como é o caso de câmeras e microfones;
- Informações redundantes e complementares são vitais para evitar falhas na detecção, como falsos alarmes e situações de risco não identificadas. Além disso, como o usuário não vai estar com os devidos dispositivos equipados a todo o momento, é importante que o sistema não fique inoperante nesses intervalos de tempo. Dessa forma, a utilização de mais de um tipo de sensor é vital;
- Classificadores baseados em aprendizagem automática podem se ajustar a diferentes cenários a partir da informação coletada em uma fase de treino, enquanto que classificadores baseados em limiares se baseiam nas informações de um especialista capaz de ajustar tais classificadores aos diferentes cenários. A utilização das duas técnicas pode melhorar o desempenho geral do mesmo.

Neste capítulo, é apresentado a INFOrM - *INdoor Fall detectiOn Method*, que é uma nova abordagem para detecção de quedas que utiliza duas modalidades de sensores e fusiona suas informações, de baixo e alto nível, por meio de algoritmos de aprendizagem automática para gerar um classificador capaz de detectar quedas rápidas (com impacto) e quedas lentas (sem ou com pouco impacto). Na Seção 4.1, são especificadas as duas modalidades de sensores utilizados para aquisição de informações sobre o usuário. As subseções 4.1.1 e 4.1.2 dissertam

sobre os acelerômetros e sensores infravermelhos respectivamente. Em seguida, a Seção 4.2 fala como os algoritmos de aprendizagem automática foram utilizados neste trabalho para geração do classificador. A Seção 4.3 apresenta a INFOrM . Por fim, a Seção 4.4 discute de forma geral as conclusões desse capítulo.

4.1 Modalidades de aquisição da informação

Estudando a literatura, observou-se que a utilização de diferentes tipos de sensores pode trazer muitos benefícios para um sistema capaz de detectar quedas, pois podem agregar um maior número de informações sobre o usuário do ambiente.

Esses dados podem ser complementares, de maneira que a soma deles pode gerar mais conhecimento a respeito da situação do residente. Sendo assim, o método desenvolvido neste trabalho utiliza sensores de presença infravermelhos, que podem ser usados para informar a localização *indoor* de uma pessoa e, ao mesmo tempo, o acelerômetro interno de *smartphones* pode ser usado para informar postura e detectar quedas. A soma dos dados coletados produz informações ricas capazes de aperfeiçoar a habilidade de detectar quando o usuário cair.

Os sensores podem ser redundantes e dessa forma prover informações semelhantes, o que pode melhorar a confiança da informação adquirida, ou em alguns casos, suprir a eventual falha em tipo de sensor. Novamente, tomando como exemplo o trabalho desenvolvido, é possível receber informações de postura do acelerômetro e dos sensores infravermelhos, mesmo que seja de forma limitada. A combinação desses dados garante uma maior confiança do que foi coletado e supre a eventual falha de um dos dois sensores.

A abordagem INFOrM, como dito acima, se utiliza de informações complementares e redundantes, visto que coleta informações de acelerômetros e sensores infravermelhos. Cada uma dessas duas modalidades de sensor é descrita a seguir.

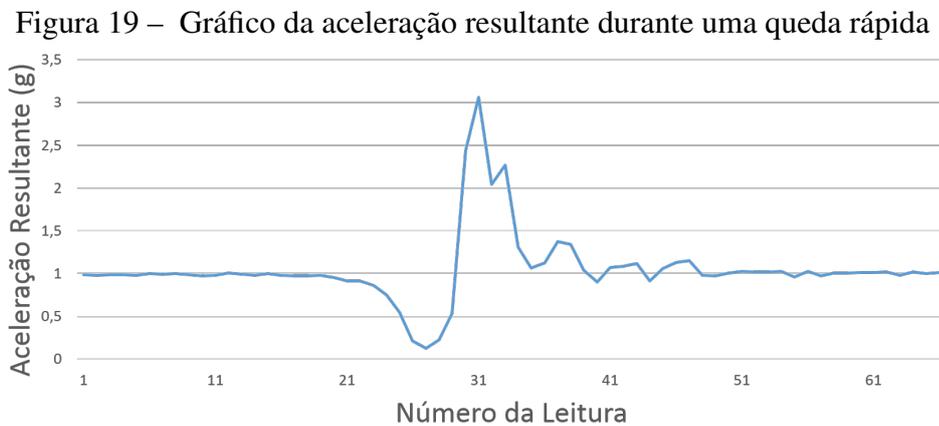
4.1.1 Acelerômetros

Acelerômetros são amplamente utilizados para detecção de quedas na literatura. Sua utilização já foi comprovada como uma forma eficiente de detectar esse tipo de evento em diversos trabalhos, alguns deles são descritos no Capítulo 3.

São dispositivos capazes de fornecer informações inclinação (*pitch*), rotação (*roll*) e desvio (*yaw*) do corpo em observação e, dessa forma, registrar seu comportamento. Por exemplo,

um conjunto de dados coletados pode representar que a pessoa está andando, sentada, deitada, ou mesmo que caiu.

Primeiramente, para entender melhor como detectar uma queda, é necessário diferenciar os dois tipos de quedas consideradas neste trabalho. Quedas rápidas ocorrem quando a pessoa cai e o acelerômetro percebe um momento de queda livre seguido de impacto. Classificadores baseados em limiares são comumente utilizados para perceber esse tipo de evento, pois são definidos dois limiares, um para detectar quando ocorre a queda livre e outro para detectar o momento do impacto, e caso os dois sejam detectados em um intervalo de tempo pequeno entende-se que o usuário caiu. A Figura 19 ilustra o gráfico de uma queda rápida, onde é possível notar que há uma desaceleração seguida de um impacto no intervalo de 1,5 segundos.



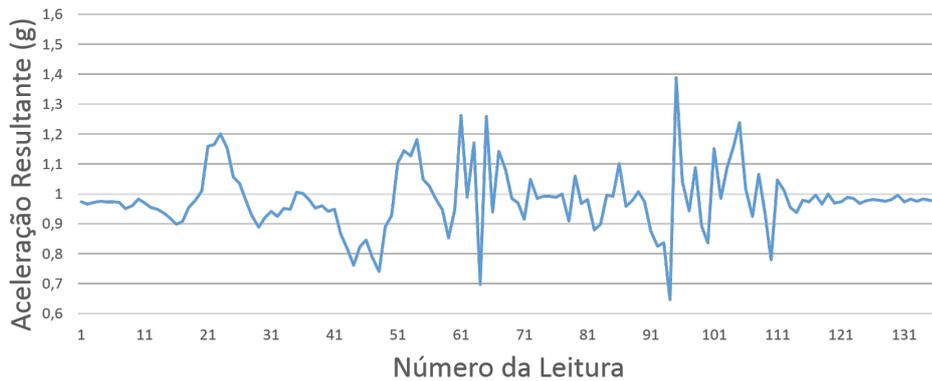
Fonte: Autor

Por outro lado, quedas lentas são aquelas onde geralmente o residente passa mal e consegue evitar uma queda brusca, mas termina no chão incapacitado. Ou seja, ele se apoia em algo para evitar impacto, mas ainda assim não é capaz de se recuperar. Nesse caso, é difícil detectar a ocorrência de impacto, como na queda rápida. Um algoritmo baseado em limiares provavelmente entenderia esse evento como uma ocorrência normal e não dispararia alarmes. Poderia ser até mesmo interpretado como deitar. A Figura 20 ilustra como uma queda lenta é percebida pelo acelerômetro de um *smartphone*.

Além de detectar quedas, acelerômetros também são usados para inferir a postura do usuário, que pode ser utilizada para aprimorar a detecção desse tipo de evento. Neste trabalho a postura foi definida por meio de limiares. Esses limiares serão apresentados posteriormente.

Por fim, os dados do acelerômetro também são utilizados na literatura para detectar várias outras atividades. A Figura 21 mostra exemplos de gráficos da aceleração resultante em

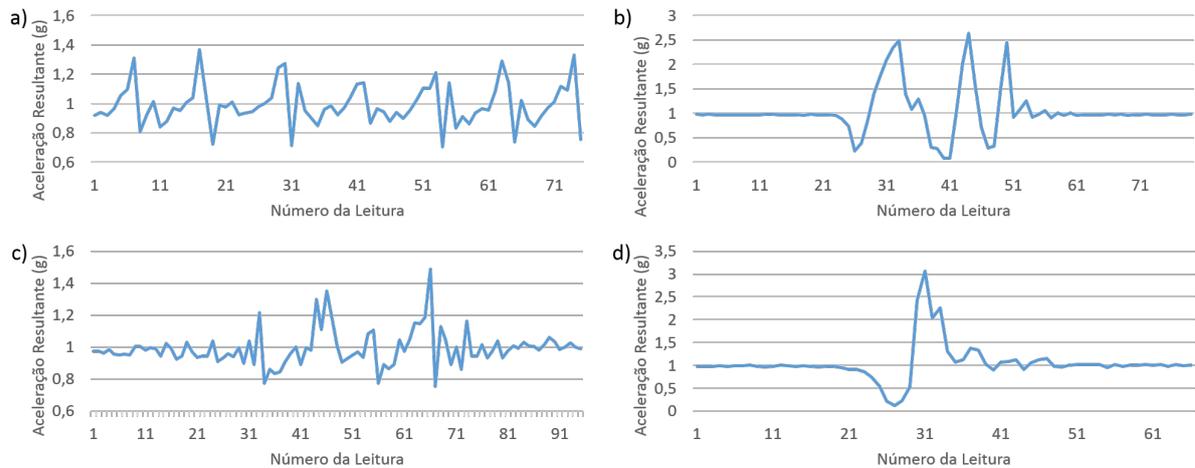
Figura 20 – Gráfico da aceleração resultante durante uma queda lenta



Fonte: Autor

quatro atividades diferentes: andar, pular, deitar e cair. Entretanto, como este trabalho não tem o objetivo de classificar atividades, eventos diferentes de quedas foram consideradas iguais pelo classificador.

Figura 21 – Gráficos que representam a aceleração resultante durante diferentes atividades: a) Andar; b) Pular; c) Deitar; d) Cair



Fonte: Autor

Uma característica comum ao evento de queda consiste de o residente chegar ao chão e permanecer deitado. Logo, uma forma possível de detectar quando algo está errado é utilizar informações de localização e com isso perceber se aquele é um local comum para se deitar ou não. Além disso, existem momentos que o usuário não estará vestindo esse sensor, seja por esquecimento, ou por ter removido para tomar banho, por exemplo. Visando detectar a localização do usuário e coletar informações de postura do usuário a partir de uma segunda fonte, foram utilizados sensores infravermelhos, que serão discutidos a seguir.

4.1.2 Sensores Infravermelhos

Um sensor amplamente conhecido e facilmente encontrado em diversos ambientes é o sensor infravermelho do tipo piroelétrico (do inglês *Passive Infrared Sensor* ou PIR ou somente IR), comumente chamado de sensor de presença. Diferente do que muitos acreditam, tais sensores não emitem sinal infravermelho. Na verdade eles captam e identificam esse sinal, proveniente do calor do corpo humano em sua área de cobertura, por isso a nomenclatura passivo.

Tais sensores só conseguem coletar informações binárias, ou seja, eles só possuem a habilidade de informar que existe alguém no alcance de detecção ou que não existe. Mesmo assim, podem ser utilizados com o objetivo de informar localização *indoor* do usuário monitorado, como em (CARVALHO *et al.*, 2015).

Uma grande vantagem da utilização desse tipo de equipamento se deve à sua fácil aceitação por parte do residente, visto que é um equipamento que não interfere na privacidade do mesmo. Além disso, é um equipamento de baixo custo, como apresentado em (MUBASHIR *et al.*, 2013).

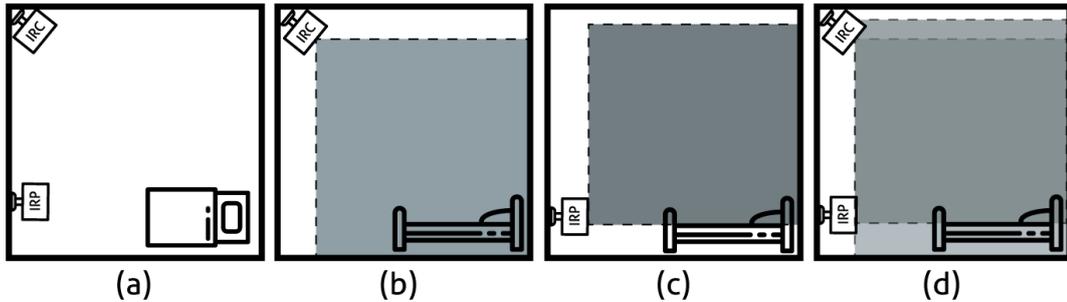
Os sensores infravermelhos também podem informar postura quando utilizados de maneira correta, capacidade desconsiderada pela literatura encontrada. Considerando que, geralmente, uma queda termina com a pessoa deitada no chão, é possível implantar sensores PIR a certa altura do chão, fazendo com que eles percebam somente a partir daquela altura. Assim, se a pessoa está deitada no chão, não é possível detectar a presença da mesma naquele momento e pode-se inferir que ela está deitada. Neste trabalho, foram utilizados dois sensores para cada cômodo, um com o objetivo de monitorar toda a área do mesmo e informar a localização, e outro a uma determinada altura do chão para detectar se a pessoa está deitada ou não.

Outra grande vantagem de sensores IR é a possibilidade de utilizá-los em banheiros. Segundo (Centers for Disease Control and Prevention, 2011) e (FERRETTI *et al.*, 2013), a maior parte dos acidentes domésticos ocorre no banheiro. Por isso, este ambiente pode ser considerado um local perigoso, especialmente para pessoas com idade avançada. É nesse mesmo local que os sensores mais conhecidos são incapazes de monitorar, seja por questões de privacidade ou mesmo quando o residente remove os sensores para tomar banho, por exemplo.

Neste trabalho, os sensores descritos foram utilizados para informar a localização *indoor* do residente, bem como a postura do mesmo (como descrito acima). A Figura 22 mostra como os sensores foram colocados, um no canto superior do cômodo (IRC), com intuito de determinar a localização interna e outro a alguns centímetros do chão, preso na parede (IRP),

visando determinar quando o usuário está deitado no chão.

Figura 22 – Sensores infravermelhos implantados no cenário: a) Visão superior de um cômodo ; b) Área de cobertura do infravermelho do cômodo; c) Área de cobertura do infravermelho da parede, colocado à altura da cama; d) Área de cobertura dos dois sensores infravermelhos de um cômodo. IRP - Infravermelho da parede; IRC - Infravermelho do cômodo.



Fonte: Autor

A partir dessas informações e de trabalhos como (STEENKESTE *et al.*, 1999), (CAVALCANTE *et al.*, 2012) e (CAVALCANTE *et al.*, 2014), o uso dos sensores infravermelhos se mostra eficaz para detectar um evento de queda, se tornando uma ótima ferramenta quando associados ao acelerômetro, visto que é possível coletar dados redundantes e complementares.

Após uma breve discussão de quais sensores foram utilizados e como eles podem ser utilizados, será apresentado a seguir como as informações são fusionadas para criação de um modelo capaz de detectar quedas rápidas e quedas lentas.

4.2 Fusão dos dados por meio de aprendizagem automática

Os dados coletados dos sensores, como dito anteriormente, são complementares e redundantes. Complementares porque a localização pode ser utilizada juntamente com informações do acelerômetro para identificar uma queda lenta, já que somente o último geralmente não é capaz. E redundantes porque a postura pode ser detectada por ambos os sensores, infravermelhos e acelerômetro. Mas é importante que essas informações sejam fusionadas.

Aprendizagem automática (AA), do inglês *Machine Learning* (ML), é uma área da inteligência artificial que evoluiu a partir de reconhecimento de padrões e se dedica a desenvolver algoritmos capazes de aprender a partir de conjuntos de dados, ou de realizar previsões a partir dos mesmos. Ou seja, esses algoritmos são capazes de extrair um modelo que vai guiá-los para tomar decisões, ao invés de seguir instruções pré-programadas.

Sendo assim, a fusão dos dados coletados é realizada por meio de algoritmos de

ML. Logo, a fusão ocorre por meio de um algoritmo, sem influência direta do especialista em como esses dados vão ser relacionados. Os algoritmos utilizados são responsáveis por extrair um modelo de como os dados passados como entrada podem ser agrupados, modelo esse que será utilizado para classificar novas entradas.

Os dados de entrada foram classificados em quedas e não quedas, tratando-se de aprendizagem supervisionada, onde os algoritmos utilizados se valem de diversos atributos de uma determinada coleta e da informação que aquele conjunto de dados representa ou não uma queda.

Na próxima seção, é explicado como a fusão dos dados dos sensores por meio de algoritmos de AA pode melhorar o desempenho de um sistema responsável por detectar quedas. Os algoritmos que foram utilizados são abordados no Capítulo 5, onde é descrita toda parte da validação do método proposto.

4.3 INFOrM

Nesta seção, será descrito de forma detalhada o funcionamento do método desenvolvido e avaliado. *Indoor Fall detectiOn Method* ou INFOrM é uma abordagem para detecção de quedas em ambientes internos, que utiliza informações de sensores infravermelhos e acelerômetro, fusionadas por meio de aprendizagem automática. Os dados fusionados são de baixo e alto nível, ou seja, são coletadas tanto informações brutas (aceleração dos eixos x,y e z) quanto pós-processadas (dados derivados das acelerações, como a resultante, ângulo de inclinação e outros, bem como provenientes de algoritmos de regras, como detecção de queda e de postura). Este novo método tem por objetivo tornar um AAL capaz de perceber quedas rápidas e quedas lentas.

Como foi citado anteriormente, os dois tipos de sensores utilizados são responsáveis por informar postura, logo tem-se redundância nesse tipo de informação. Além disso, os infravermelhos repassam a localização do usuário e o acelerômetro acompanha o comportamento da pessoa monitorada. Assim, tem-se informações diferentes que podem se completar e ajudar a perceber melhor o estado do residente desse ambiente.

Foi desenvolvido um aplicativo Android para centralizar todas as informações coletadas dos sensores. No aplicativo, foram implementados algoritmos baseados em limiares, assim as informações coletadas seriam dados brutos e de alto nível. Foram definidos limiares para inferir a postura do usuário, pois é comum que a postura final seja deitada. Os ângulos utilizados

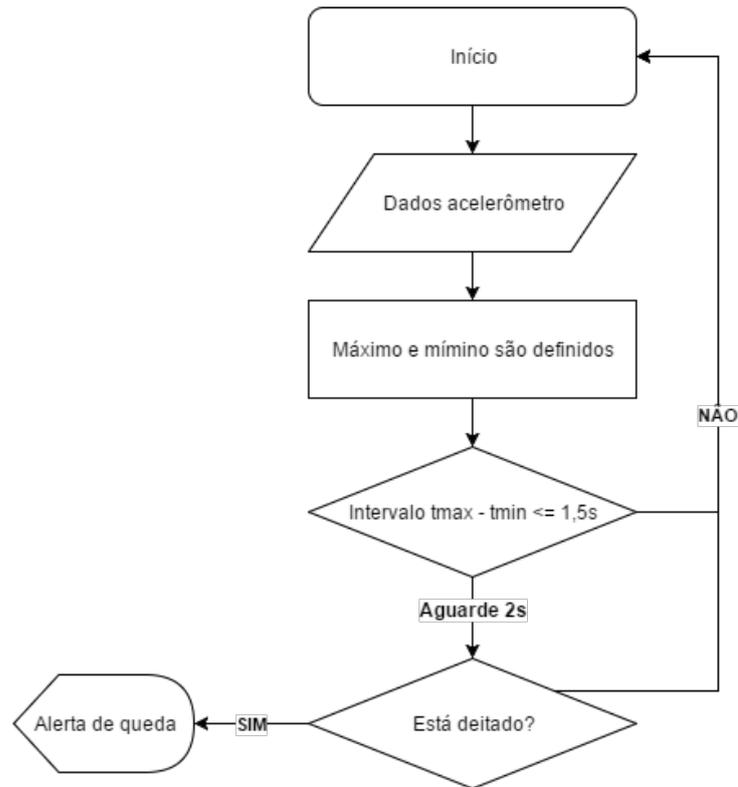
para detectar postura foram definidos baseados na análise de um especialista. Caso o ângulo detectado seja $\geq 45^\circ$, o algoritmo considera que a pessoa está em pé ou sentada. Caso o ângulo seja $< 45^\circ$ é registrado que a pessoa está deitada. O ângulo utilizado é referente ao percebido pelo dispositivo em relação a o plano XZ, ou seja, em relação ao solo.

No mesmo aplicativo também foi implementado um algoritmo capaz de detectar quedas baseado em limiares fixos e na postura final do residente. Os limiares utilizados no algoritmo implementado foram definidos com base em um conjunto de testes preliminares, na literatura e na experiência do especialista. Um grupo teste foi utilizado para validar os limiares utilizados com o objetivo de maximizar a detecção do algoritmo utilizado no aplicativo. Esta forma de identificar esse tipo de evento é bastante conhecida pela literatura. O algoritmo implementado é descrito a seguir e apresentado na Figura 23.

Ao ser iniciada, a aplicação passa a receber os dados dos acelerômetros e armazena o tempo de entrada do último mínimo e máximo detectados. Se o intervalo de tempo entre os dois for menor que 1,5 segundos, o algoritmo aguarda 2 segundos para confirmar a postura do usuário naquele instante e finalmente disparar um alarme de queda caso o mesmo esteja deitado após o tempo decorrido. Se o intervalo de tempo entre o máximo e mínimo for maior que 1,5 segundos, o algoritmo volta a coletar dados dos acelerômetros. Mesmo que o intervalo seja menor que o definido, se após aguardar 2 segundos a postura da pessoa monitorada for diferente de deitada, o alarme não é disparado e o aplicativo volta a coletar informações do acelerômetro. Os intervalos de tempo utilizados tiveram por base a literatura estudada (CHEN *et al.*, 2005)(KANGAS *et al.*, 2007)(PIVA *et al.*, 2014), bem como o conhecimento do especialista (CAVALCANTE *et al.*, 2014).

Uma característica importante desta abordagem é que somente os infravermelhos são capazes de detectar uma queda, caso o *smartphone* não esteja preso ao corpo do usuário. Para realizar esse tipo de detecção, foi utilizado um limiar de tempo. Em uma situação onde o celular está coletando informações, mas foi removido do corpo, o mesmo vai receber informações de um corpo estático, mas continua a receber a posição do usuário e se ele está no chão ou não. Para determinar uma situação de risco, foram utilizadas as seguintes regras: caso o usuário não seja detectado por nenhum sensor infravermelho em um intervalo maior que 12 segundos, é considerado que ele está em perigo. E se ele for localizado em um determinado cômodo, mas ele estiver no chão por mais de 12 segundos, também se considera que ele está caído. O intervalo adotado de 12 segundos, corresponde à 2 ativações dos sensores de presença utilizado, ou seja,

Figura 23 – Diagrama de fluxo representando o algoritmo de detecção de quedas baseado em limiares



Fonte: Autor

se o usuário não ativar o sensor em 12 segundos significa que ele não ativou o sensor por 2 vezes seguidas.

Desta forma, se o usuário desaparecer do raio de detecção de todos os infravermelhos por 12 segundos, considera-se um evento de risco, assim como ele estar ao alcance de um sensor responsável por um cômodo, mas estar deitado no chão por mais de 12 segundos de um local considerado de risco.

Para tornar o aparelho celular capaz de receber os dados referentes aos infravermelhos, foi desenvolvido um programa para registrar os dados dos sensores e um *web service*. O primeiro era utilizado para uma etapa de configuração dos sensores, sendo necessário registrar todos os sensores que iriam ser utilizados para monitorar o ambiente. Por exemplo, se o espaço em questão consiste de quatro cômodos, seriam utilizados dois sensores para cada cômodo: um para monitorar toda a área do cômodo e outro para verificar se a pessoa está deitada no chão ou não. Esses oito sensores seriam previamente cadastrados em um software com as suas respectivas áreas de observação.

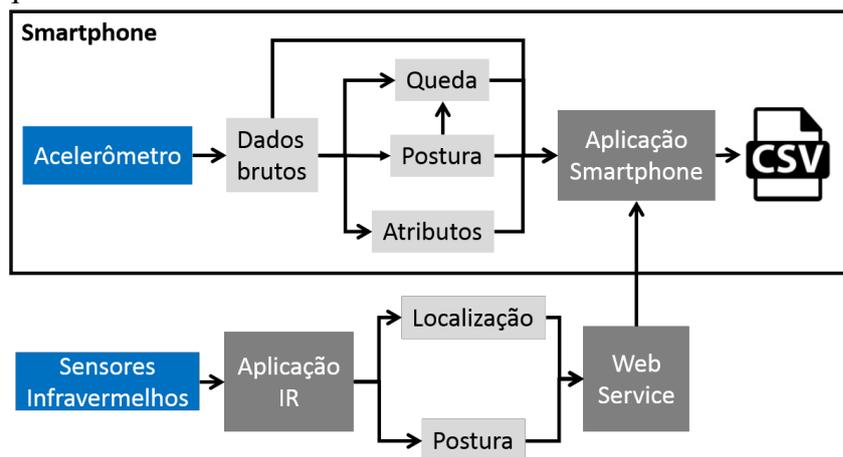
Após cadastro de todos os sensores, cada ativação é associada a uma respectiva área de observação e ambos eram anotados em um *web service*, para que o aplicativo no celular seja

capaz de coletá-los e, assim, registrar tanto os dados do acelerômetro quanto dos infravermelhos em um arquivo csv, que seriam utilizados posteriormente para gerar o classificador.

Por fim, juntamente com a postura, localização e registro ou não de queda, eram escritos no arquivo csv os dados brutos colhidos do acelerômetro e vários outros atributos gerados a partir desses dados.

A Figura 24 ilustra todo o processo descrito acima. O acelerômetro gera dados brutos que são utilizados para gerar novos atributos, inferir postura e verificar queda. Esses são registrados no arquivo juntamente com os dados coletados pelo celular do *web service*, que correspondem à localização e postura detectada pelos infravermelhos.

Figura 24 – Diagrama representando como são gerados os arquivos da base de dados. Os sensores estão em azul, as aplicações em cinza e os dados escritos no arquivo csv em um cinza mais claro. O acelerômetro gera dados brutos que são derivados em novos atributos, postura e utilizados para detecção de queda e tudo isso é gravado no arquivo csv.

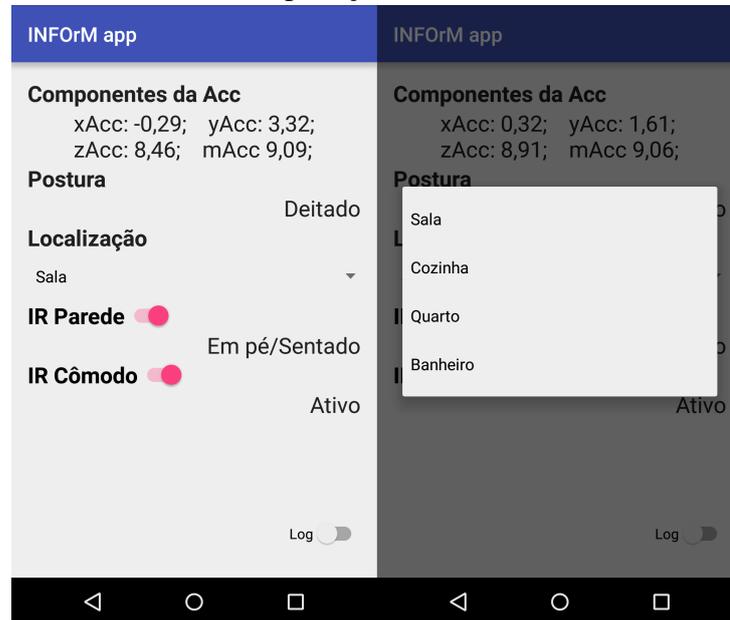


Fonte: Autor

A interface do aplicativo Android desenvolvido pode ser vista na Figura 25. O campo das componentes lista as acelerações detectadas nos eixos x, y e z. Em seguida, o campo da postura mostra a postura detectada a partir do ângulo em relação ao solo. As informações dos sensores infravermelhos são recebidas via *web service* e são responsáveis por informar a postura e conforto do usuário. E logo abaixo existe uma chave para determinar quando iniciar e finalizar a gravação em um arquivo csv. Algumas modificações foram feitas na versão final do aplicativo. Por esse motivo, existem chaves associadas aos sensores da parede e do cômodo. Essas alterações são explicadas no capítulo seguinte.

Os dados coletados pelo celular foram classificados por um especialista como sendo ou não um registro de queda. A base gerada é utilizada por algoritmos de aprendizagem

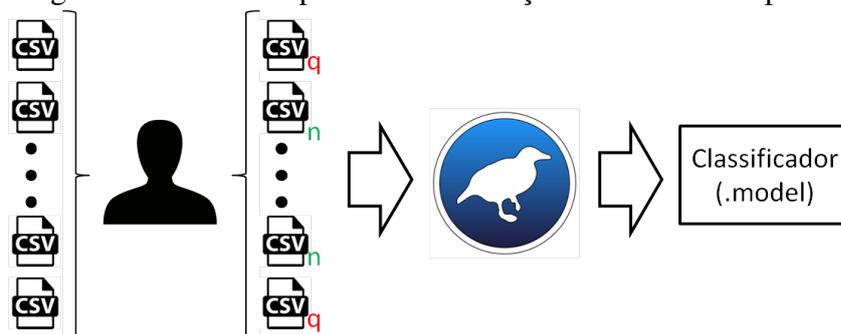
Figura 25 – Aplicação Android desenvolvida para centralizar as informações dos sensores utilizados, inferir posturas, detectar quedas e gravar todas as informações da base. À esquerda a visão inicial da aplicação e à direita os cômodos utilizados.



Fonte: Autor

automática para a construção de um classificador capaz de detectar de forma eficiente esse tipo de evento, seja ela uma queda rápida ou lenta. A Figura 26 ilustra esse processo, quando um especialista rotula os arquivos da base como queda ('q' na cor vermelho) e não quedas (n na cor verde) e utiliza, por exemplo, os algoritmos do Weka 3.8 (HALL *et al.*, 2009) para extrair um modelo que pode ser utilizado como classificador por um sistema qualquer.

Figura 26 – Diagrama ilustrando o processo de extração de um modelo para detectar quedas

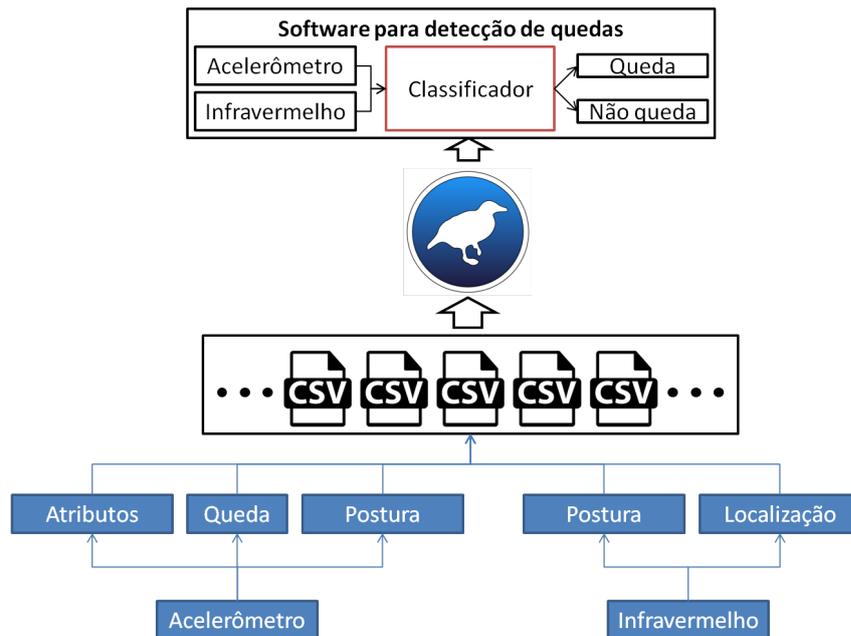


Fonte: Autor

Por fim, de forma resumida, o método proposto utiliza dados de um acelerômetro para inferir postura, detectar queda e calcular um conjunto de atributos, onde estes juntamente com dados de localização e postura produzidos por um conjunto de sensores infravermelhos passivos são fusionados por meio de algoritmos de aprendizagem automática com a finalidade

de extrair-se um modelo capaz de detectar de forma efetiva uma queda, seja ela rápida ou lenta. Esse modelo pode ser utilizado como classificador em um software para detecção de quedas, por exemplo. A Figura 27 ilustra todo este processo.

Figura 27 – Diagrama ilustrando todo processo para geração do classificador e sua utilização em um software capaz de detectar quedas, que utilize acelerômetro e sensores infravermelhos



Fonte: Autor

A seção seguinte compara o INFOrM com os trabalhos descritos no Capítulo 3, em relação a aspectos de aceitação pelo usuário, forma de classificação dos dados e possíveis situações de uso para cada abordagem.

4.4 Conclusão

Apesar de o trabalho desenvolvido ser semelhante a outras obras da literatura em alguns aspectos, ele se destaca em alguns pontos importantes. As abordagens discutidas no Capítulo 3 e a INFOrM foram comparadas com intuito de mostrar em que se assemelham e em que o trabalho desenvolvido se sobressai.

A Tabela 7 compara os trabalhos apresentados anteriormente juntamente com a INFOrM. É possível notar a semelhança com o trabalho desenvolvido em (LUSTREK *et al.*, 2015), pois ambos são capazes de detectar quedas rápidas e lentas e utilizam regras e aprendizagem automática para detectar quedas.

Tabela 7 – Trabalhos relacionados e INFOrM - Tipos de quedas e de classificador

Abordagem	Tipo de Queda		Classificador	
	Queda rápida	Queda lenta	Regras	AA
(STONE; SKUBIC, 2015)	X		X	
(ZHANG <i>et al.</i> , 2013)	X	X	X	
(ALBERT <i>et al.</i> , 2012)	X			X
(CAVALCANTE <i>et al.</i> , 2012)	X	X	X	
(CAVALCANTE <i>et al.</i> , 2014)	X	X	X	
(GJORESKI <i>et al.</i> , 2014)	X	X	X	
(LUSTREK <i>et al.</i> , 2015)	X	X	X	X
INFOrM	X	X	X	X

Fonte: Autor

Porém, nas Tabelas 8 e 9 ficam visíveis as diferenças em relação às outras abordagens. É possível observar diferenças tanto em relação às tecnologias envolvidas como nos possíveis cenários e a relação de dependência do usuário.

Apesar de ser considerada invasiva por (MUBASHIR *et al.*, 2013), a utilização de acelerômetros não compromete a privacidade do residente do ambiente observado. Além disso, é preciso levar em consideração a evolução de roupas equipadas com diferentes tecnologias, que irão facilitar ainda mais a aceitação desta modalidade. A utilização desse tipo de sensor é comum, como mostra a Tabela 8.

A outra forma de aquisição de dados ocorre por meio de um conjunto de sensores infravermelhos, que foram implantados no cenário observado. Diferentemente da outra modalidade de aquisição, essa não é comum em trabalhos que lidam com detecção de quedas, vide Tabela 8, apesar de também não interferir na privacidade do usuário.

Outra característica importante da utilização de PIR's, que já foi ressaltada, é a sua independência do usuário, ou seja, como estão equipados no ambiente, não dependem do mesmo para equipá-los ou não. Logo, em momentos que o acelerômetro não está equipado, ainda é possível inferir se a pessoa monitorada necessita de ajuda.

A INFOrM é capaz de detectar quedas no cômodo mais perigoso de uma casa, o banheiro. A Tabela 9 mostra que este cenário é comumente esquecido pela literatura, visto que utilizar câmeras e microfones é ferir a privacidade do residente, e que sensores que devem estar equipados ao corpo não vão estar equipados durante o banho, com algumas poucas exceções.

Por fim, o modelo proposto se utiliza de tecnologias de fácil aceitação. É capaz de operar mesmo durante uma eventual falha de uma das modalidades de aquisição dos dados. Além disso, utiliza-se de regras para gerar informações de alto nível e de algoritmos de aprendizagem automática para fusão dos dados e criação de um classificador capaz de detectar quedas lentas e

Tabela 8 – Trabalhos relacionados e INFOrM - Abordagem e categoria utilizadas

Abordagem	Vestível		Ambiente		Visão Computacional
	Aceleração	Outro	Áudio/Vídeo	Infra Vermelho	
(STONE; SKUBIC, 2015)					X
(ZHANG <i>et al.</i> , 2013)	X				
(WANG <i>et al.</i> , 2016)	X				
(CAVALCANTE <i>et al.</i> , 2012)	X		X	X	
(CAVALCANTE <i>et al.</i> , 2014)	X	X		X	
(GJORESKI <i>et al.</i> , 2014)	X	X			
(LUSTREK <i>et al.</i> , 2015)	X	X			
INFOrM	X			X	

Fonte: Autor

rápidas.

Tabela 9 – Trabalhos relacionados e INFOrM - Usos e restrições

Abordagem	Cômodo		Usuário	
	Banheiro	Outro	Dependente	Independente
(STONE; SKUBIC, 2015)		X		X
(ZHANG <i>et al.</i> , 2013)		X	X	
(WANG <i>et al.</i> , 2016)		X	X	
(CAVALCANTE <i>et al.</i> , 2012)		X	X	X
(CAVALCANTE <i>et al.</i> , 2014)	X	X	X	X
(GJORESKI <i>et al.</i> , 2014)		X	X	
(LUSTREK <i>et al.</i> , 2015)		X	X	
INFOrM	X	X	X	X

Fonte: Autor

O Capítulo 5 descreve o processo de validação da INFOrM, os equipamentos, os cenários e a metodologia utilizada, assim como os resultados encontrados.

5 EXPERIMENTOS E RESULTADOS

Ao longo deste Capítulo será apresentado todo o processo de validação da abordagem INFORM. Primeiramente será descrito como foram realizados os experimentos para criação da base de dados que foi utilizada para treinar os algoritmos de aprendizagem de máquina e gerar os classificadores responsáveis por detectar quedas. Em seguida, é apresentada como foi realizado o processo de treinamento. Por fim, os resultados obtidos na avaliação do método proposto são discutidos.

5.1 Base de dados

No capítulo 2 foi dito que um algoritmo de aprendizagem de máquina é capaz de extrair padrões de um conjunto de dados e dessa forma, aprender a classificar novas entradas. Assim sendo, faz-se necessária uma base de dados de onde os algoritmos possam aprender. Esse aprendizado resulta em um classificador capaz de julgar entradas como quedas ou não. A base criada com a finalidade de treinar algoritmos de AA é composta de dados de dois tipos de sensores, acelerômetro interno de um celular e um conjunto de sensores passivos infravermelhos, um cenário residencial e um grupo de voluntários que efetuou um conjunto predeterminado de eventos. Os experimentos foram realizados por 2 mulheres e 3 homens cuja altura variava de 156 à 180 centímetros e peso de 63 à 100 quilogramas. As subseções 5.1.1, 5.1.2 e 5.1.3 descrevem os equipamentos, o cenário e os eventos respectivamente.

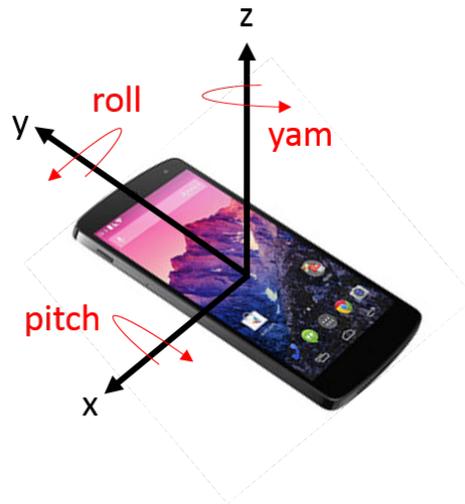
5.1.1 Equipamentos

Foi utilizado um *smartphone* LG Nexus 5 que possui um acelerômetro de seis eixos (acelerômetro e giroscópio) embutido. Com as informações coletadas é possível calcular inclinação (*pitch*), rotação (*roll*) e desvio (*yaw*) do aparelho que está preso ao corpo do usuário. A Figura 28 ilustra os três eixos em relação ao aparelho.

O aparelho foi fixado ao tórax do usuário porque, segundo a literatura, é um dos melhores locais para detectar o comportamento do mesmo (GJORESKI *et al.*, 2011). O celular foi preso por meio de uma faixa, assim como ilustra a Figura 29. Utilizando as informações coletadas pelo *smartphone*, é possível inferir a postura do usuário, que é algo importante para a detecção de uma queda.

Neste trabalho, só são reconhecidas duas posturas, sentado/em pé e deitado por dois

Figura 28 – Inclinação (*pitch*), rotação (*roll*) e desvio (*yam*) no *smartphone* utilizado.



Fonte: Autor

Figura 29 – Usuário utilizando uma faixa com o Nexus 5 preso ao corpo para coletar todas as informações do cenário.



Fonte: Autor

motivos: a) para diferenciar as duas primeiras de forma eficiente seria necessário reconhecer a orientação das pernas, possivelmente utilizando outro acelerômetro; b) geralmente a postura final de uma queda é deitada. Logo, é importante diferenciá-la das outras.

Outro tipo de informação possível de ser produzida a partir das acelerações coletadas do aparelho celular é a informação de queda. O algoritmo responsável pela detecção de tal evento foi apresentado no Capítulo 4.

Seriam utilizados sensores infravermelhos passivos da marca Legrand (LEGRAND, 2010). Cada sensor envia sua informação por meio de uma rede sem fio para uma base PLC (do inglês *Power Line Communication*) fixa. Essa base receberia sinais dos IRs por meio de

rádio frequência e enviaria por meio da corrente elétrica para outro equipamento responsável por receber, decodificar e transmitir para o computador via conexão USB. A Figura 30 apresenta o sensor descrito e seu funcionamento.

Figura 30 – Sensor PIR da marca Legrand



Fonte: Legrand

Devido a uma falha elétrica na base, não foi possível utilizar os sensores reais. Por esse motivo o aplicativo desenvolvido para coletar os dados foi alterado para receber uma entrada manual da localização do usuário e informar quando o usuário estava abaixo do nível do sensor responsável por detectar postura (sentado/em pé ou deitado). A entrada manual respeita o funcionamento original dos sensores. Sendo assim, acredita-se que não existem divergências nas informações que seriam adquiridas pelos sensores reais e no que foi informado manualmente.

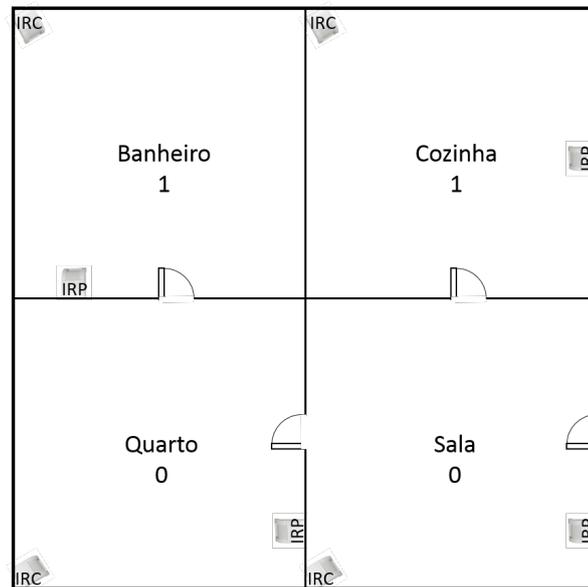
O Capítulo 4 explica como os sensores foram implantados e como estes seriam utilizados para detectar os usuários dentro de um ambiente monitorado e como é possível utilizá-los para inferir postura.

5.1.2 Cenário

Foi montado um ambiente para realização de eventos previamente definidos por diferentes voluntários. Este cenário é composto de quatro cômodos: uma sala, um quarto, um banheiro e uma cozinha. A Figura 31 apresenta o ambiente descrito e as possíveis transições entre os cômodos.

Baseado na literatura que afirma que banheiro e cozinha são os dois cômodos mais perigosos da casa (Centers for Disease Control and Prevention, 2011)(FERRETTI *et al.*, 2013), e em conhecimento comum que as pessoas não costumam deitar no banheiro e na cozinha, essas duas regiões foram consideradas como áreas de risco, por isso foram desconsiderados eventos onde o usuário deita nesses cômodos. O número 1 na Figura 31 representa as áreas perigosas, enquanto o 0 representa as regiões consideradas seguras.

Figura 31 – Ambiente residencial simulado. As regiões marcadas por 1 são consideradas perigosas, enquanto as demarcadas por 0 são locais onde as pessoas costumam deitar. IRP - Infravermelho da parede; IRC - Infravermelho do cômodo.



Fonte: Autor

5.1.3 Eventos

Para treinar um algoritmo de aprendizagem automática, é necessário fornecer informações das quais ele será capaz de extrair padrões que irá utilizar para classificar novas entradas. Com essa finalidade, foram estabelecidas atividades que seriam realizadas pelos voluntários, visando treinar um classificador de quedas.

Foi então determinado um conjunto de eventos que cobriram episódios de queda, de não queda (normais) e semelhantes a quedas. A Tabela 10 lista os eventos realizados pelos voluntários e os locais onde eles foram realizados.

Tabela 10 – Eventos de queda, não queda, que parecem queda e os cômodos nos quais foram realizados

Evento	Queda	Não queda	Parece queda	Cômodos
Andar		X		Todos
Pular		X		Todos
Sentar		X		Todos
Deitar		X		Não perigosos (0)
Deitar Rápido			X	Não perigosos (0)
Sentar Rápido			X	Todos
Queda deitado	X			Não perigosos (0)
Queda rápida	X			Todos
Queda lenta	X			Todos

Fonte: Autor

Cada evento listado na Tabela 10 foi realizado por cada voluntário quatro vezes, e nos cômodos listados na tabela. Por exemplo, o usuário deveria realizar quatro quedas lentas em cada aposento, totalizando dezesseis quedas lentas, já que esta atividade foi realizada em todos os compartimentos do cenário. Para ocorrências onde o usuário deveria estar deitado ou deitar-se, totaliza-se um total de oito coletas, visto que deitar nos locais considerados perigosos não foi considerada para criação do banco. Assim, foram totalizadas cento e vinte ações para cada voluntário.

5.2 Treinamento dos algoritmos de aprendizagem automática

Todo o processo de treinar algoritmos para que estes pudessem aprender a detectar quedas de forma eficiente foi feita utilizando a ferramenta Weka, versão 3.8.

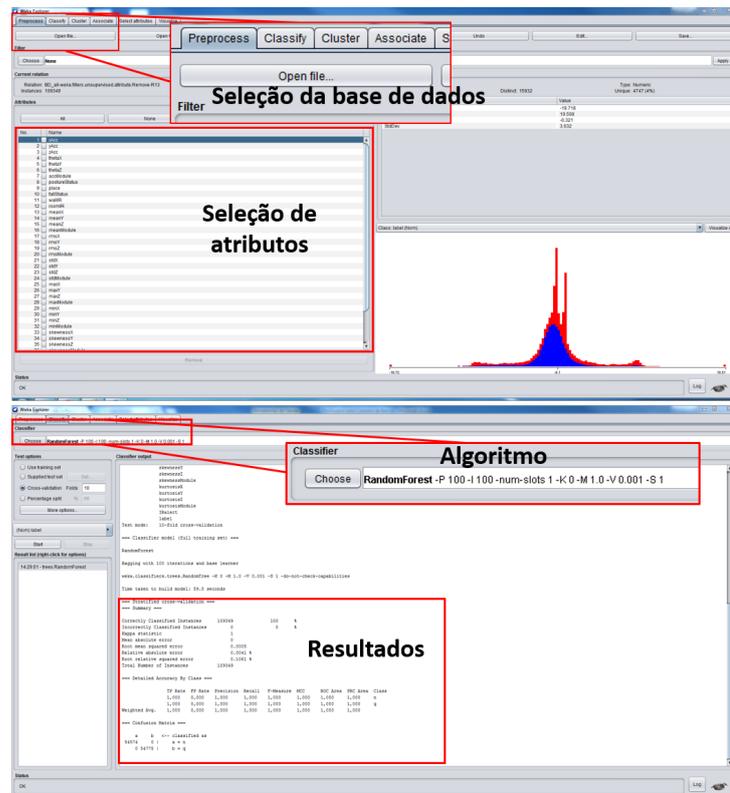
Essa ferramenta implementa todos os algoritmos de aprendizagem automática que foram utilizados, além de muitos outros, dessa forma não foi necessário implementar tais algoritmos. Além disso, é uma ferramenta com uma interface gráfica fácil de ser utilizada, sendo possível gerar um modelo de classificação com poucas interações. Com Weka também é possível utilizar algoritmos de aprendizagem automática em outros softwares, como por exemplo, é possível utilizar classificadores dentro do aplicativo do celular para que as leituras fossem classificadas em tempo real.

A figura 32 ilustra a interface da ferramenta. A parte superior da figura apresenta a interface inicial, onde é possível selecionar a base de dados a ser utilizada e os atributos dessa base que serão avaliados durante o treinamento. A parte inferior mostra uma das funcionalidades da ferramenta, a classificação. Nesta função é possível selecionar o algoritmo que será treinado, a forma de validação e coletar os resultados de forma simples.

A ferramenta utilizada implementa uma diversidade de algoritmos de AA. Porém, para avaliar a funcionalidade do método proposto, foram utilizados aqueles considerados mais eficientes em detectar quedas (LUŠTREK; KALUŽA, 2009)(ALBERT *et al.*, 2012)(GJORESKI *et al.*, 2011). Os algoritmos utilizados operam no modo operacional padrão do Weka 3.8 e são listados a seguir:

- Random Forest (BREIMAN, 2001);
- Support Vector Machines (SVM) (HEARST *et al.*, 1998);
- Bagging (BREIMAN, 1996);
- Adaboost M1 (FRIEDMAN *et al.*, 2000).

Figura 32 – Interface da Weka - ferramenta utilizada para treinar os algoritmos de aprendizagem automática



Fonte: Autor

Foram utilizados 41 atributos diferentes durante o treino de cada um dos algoritmos. Esses atributos são tanto informações brutas dos sensores, quanto informações derivadas desses dados de baixo nível. As informações foram coletadas à uma taxa de 30 coletas por segundo. O uso de alguns deles pode ser observado em trabalhos como (LUŠTREK; KALUŽA, 2009)(ALBERT *et al.*, 2012)(GJORESKI *et al.*, 2011). Os atributos utilizados são listados a seguir:

- Aceleração: x, y, z e módulo;
- Theta: x, y e z;
- Postura: baseado no ângulo de inclinação em relação ao solo;
- Localização: 0 para cômodo perigoso e 1 para seguro;
- Status de queda: detectado queda pelo algoritmo baseado em limiares;
- Infravermelhos: referente ao cômodo e à parede;
- Média: x, y, z e módulo;
- *Root mean square*: x, y, z e módulo;
- Desvio padrão: x, y, z e módulo;
- Máximo: x, y, z e módulo;

- Mínimo: x , y , z e módulo;
- Obliquidade (*skewness*): x , y , z e módulo;
- Curtose (*kurtosis*): x , y , z e módulo;
- Status de inatividade: ativa após 12 segundos sem nenhuma detecção dos infravermelhos;
- Rótulo: queda ou não queda.

Os resultados obtidos após treinamento de tais algoritmos e utilizando as informações que compõem a base elaborada são apresentados a seguir.

5.3 Resultados

Esta seção discute os resultados encontrados por cada algoritmo listado anteriormente. Todos os algoritmos foram utilizados nas configurações padrões da ferramenta. São realizadas dois tipos de validação nesta seção. A primeira forma de validar os resultados foi por meio de validação cruzada, descrita a seguir. A segunda forma consiste de utilizar o conjunto de todas as bases de usuários menos uma durante o treino e a base que não foi utilizada na fase de treino foi usada como teste.

Validação cruzada, do inglês *cross validation*, é uma técnica de validação de modelos, cujo objetivo é verificar a capacidade de generalização de um modelo, dado um conjunto de dados. Utilizando o Weka, dada uma validação cruzada com dez conjuntos e uma base com 100 dados rotulados, tem-se o seguinte:

- Weka seleciona os 100 dados rotulados;
- São produzidos 10 conjuntos de mesmo tamanho;
- Cada conjunto é dividido em dois grupos, um grupo com 90 dados rotulados para treinamento e um grupo com 10 para teste;
- A ferramenta gera um classificador para o primeiro conjunto utilizando 90 dados rotulados e testa com os outros 10;
- O mesmo é realizado para os grupos de 2 a 10;
- A média do resultado dos 10 conjuntos é calculada.

A Tabela 11 apresenta os resultados encontrados utilizando validação cruzada com dez conjuntos. As bases de todos os usuários foram avaliadas separadamente em uma primeira fase. Em seguida, uma base composta por todas as informações de todos os usuários foi utilizada.

A maior parte dos resultados encontrados durante a avaliação dos resultados na

validação cruzada mostra que os algoritmos detectaram corretamente todas as instâncias. Esses resultados se devem ao fato de cada base individual conter padrões de um único usuário, o que torna a tarefa de classificar em uma atividade simples. Quando avaliada a base que contém informações de todos os usuários é possível observar um decaimento no nível de classificações corretas.

Tabela 11 – Índice de instâncias classificadas corretamente - Treino individual e total - Validação cruzada

Base	U1	U2	U3	U4	U5	Todos
Random Forest	100%	100%	100%	100%	100%	100%
SVM	100%	100%	100%	100%	100%	98,21%
Bagging	100%	100%	100%	100%	100%	100%
Adaboost M1	99,45%	100%	100%	100%	99,04%	96,53%

Fonte: Autor

Utilizando a base composta por dados dos cinco voluntários, todos os algoritmos apresentam bom desempenho nessa primeira etapa de validação, sendo o Adaboost M1 que obteve o pior desempenho, com 96,53%. Porém, como foi citado, esta etapa de validação foi realizada por meio de validação cruzada, onde o conjunto de dados utilizado para teste é uma generalização do que foi utilizado para treino.

A segunda forma de avaliar o funcionamento do método proposto foi utilizar uma base de teste diferente da utilizada para treinar o algoritmo, garantindo que os dados de treino e de teste são completamente diferentes e não apenas uma generalização. Assim sendo, os dados de quatro usuários foram compilados em uma única base e as informações do quinto foram usadas como teste. Os resultados dessa avaliação são apresentados a seguir.

A Tabela 12 mostra os resultados encontrados quando utilizada essa segunda forma de avaliação. Para cada usuário utilizado como teste, foram utilizadas as informações dos outros quatro como treino. Assim sendo, a tabela apresenta o percentual de eventos detectados corretamente (quedas e não quedas) para cada usuário. Por exemplo, tomando o usuário 1 (U1), como base de teste, os dados dos usuários de 2 a 4 (Todos-U1) foram utilizados como base de treino para todos os algoritmos já citados, e os resultados são apresentados.

A partir dos resultados da Tabela 12 é possível ver que o algoritmo Bagging apresenta os piores resultados, independente de qual base foi avaliada. Assim, ele não é o mais indicado para ser utilizado juntamente com o método proposto por esse trabalho de mestrado. Outro ponto importante é que a base U4 apresenta resultados bem abaixo do restante, independente do algoritmo utilizado.

Tabela 12 – Índice de instâncias classificadas corretamente - Validação por meio de uma base não usada no treino

Bases de treino	Todos-U1	Todos-U2	Todos-U3	Todos-U4	Todos-U5
Base de teste	U1	U2	U3	U4	U5
Random Forest	91,37%	97,03%	97,41%	84,25%	96,52%
SVM	95,50%	95,32%	97,33%	86,63%	96,69%
Bagging	89,71%	92,63%	89,23%	78,90%	88,21%
Adaboost M1	92,85%	96,42%	97,38%	81,1%	91,96%

Fonte: Autor

Para entender melhor porque isso acontece, os resultados foram separados em quedas e não quedas. Na Tabela 13 os eventos de não queda e queda são representados por Nq e Q respectivamente. Novamente, utilizando a segunda forma de avaliação, a tabela apresenta o percentual de eventos de quedas e não quedas detectados corretamente para cada usuário. Por exemplo, tomando U1, como base de teste, U2, U3, U4 e U5 foram utilizados como base de treino para todos os algoritmos já citados, e os resultados são apresentados separadamente para situações de queda e não queda.

Tabela 13 – Índice de instâncias classificadas corretamente - Não quedas e Quedas - Validação por meio de uma base não usada no treino

Bases de treino	Todos-U1		Todos-U2		Todos-U3		Todos-U4		Todos-U5	
	U1		U2		U3		U4		U5	
	Nq	Q								
Random Forest	94,14%	89,99%	96,64%	97,23%	92,22%	100%	89,04%	81,86%	90,69%	99,43%
SVM	95,36%	95,57%	99,11%	93,42%	92,28%	99,85%	96,06%	81,92%	92,78%	98,65%
Bagging	94,48%	87,33%	92,29%	92,81%	88,6%	89,54%	91,67%	72,51%	92,65%	85,99%
Adaboost M1	94,14%	92,20%	95,75%	96,75%	92,14%	100%	87,62%	77,84%	91,94%	91,98%

Fonte: Autor

Dos testes realizados, somente dois casos apresentaram resultados abaixo de 80%, quando os algoritmos Bagging e Adaboost M1 foram treinados com informações dos voluntários de 1, 2, 3 e 5 e os dados do usuário 4 foram utilizados de teste. Uma forma de explicar tais resultados, como foi dito acima, é que além do algoritmo Bagging, o Adaboost M1 também não é uma boa opção para detecção de quedas utilizando o método INForM. Porém os algoritmos Random Forest e SVM também apresentaram resultados bem próximos de 80%, logo é pouco provável que este seja a razão.

Uma outra possível explicação, que não envolve os algoritmos, pode ser a uma diferença grande deste voluntário para os restantes, ou seja, suas características físicas e/ou comportamentais não se assemelham à dos outros. Dessa forma, os algoritmos avaliados não conseguiram extrair informações da base de treino para gerar um modelo capaz de classificar corretamente informações desse usuário. Uma possível solução para tal problema seria uma

classificação dos usuários em grupos, de forma que usuários semelhantes pertencessem a um mesmo grupo.

Analisando as Tabelas 12 e 13, é possível ver que resultados encontrados comprovam a eficácia do método utilizado para detectar quedas. Porém, é preciso avaliar também dois pontos que foram considerados cruciais e apontados anteriormente: a capacidade do mesmo em detectar quedas sem uso do acelerômetro e sua eficácia em identificar quedas lentas. Para avaliar esses dois pontos, foi utilizado o mesmo esquema de avaliação apresentado anteriormente, quatro bases conjuntas foram utilizadas como treino e uma diferente para teste.

A Tabela 14 apresenta o índice de detecção de quedas encontrado quando avaliadas somente quedas lentas, representadas por QL, e aquelas onde o acelerômetro não estava equipado, representadas por SAcc. Ao observar os resultados, fica visível que os sensores infravermelhos representam uma forma viável de evidenciar quedas em cenários onde o usuário não está sendo observado pelo acelerômetro, um cenário bastante esquecido pela literatura.

Tabela 14 – Índice de instâncias classificadas corretamente - Quedas sem acelerômetro e Quedas lentas - Validação por meio de uma base não usada no treino

Bases de treino	Todos-U1		Todos-U2		Todos-U3		Todos-U4		Todos-U5	
	U1		U2		U3		U4		U5	
	SAcc	QL								
Random Forest	100%	66,85%	100%	91,36%	100%	100%	100%	66,13%	100%	100%
SVM	100%	86,67%	100%	80,11%	100%	100%	100%	67,37%	100%	96,87%
Bagging	100%	58,06%	100%	79,67%	100%	81,35%	100%	66,13%	100%	94,05%
Adaboost M1	100%	74,18%	100%	87,28%	100%	100%	100%	56,69%	100%	95,56%

Fonte: Autor

O alto índice de acerto encontrado em quedas onde o acelerômetro não está equipado se deve ao fato de existir uma variável que não está presente em outros cenários. Esta variável é gravada no arquivo csv somente quando o residente não é encontrado em nenhum lugar do ambiente observado após 12 segundos, o que representa duas leituras negativas consecutivas do sensor de presença infravermelho.

Enquanto que as quedas lentas de alguns usuários são facilmente percebidas, a de outros apresenta índices muito baixos. Por se tratar de um grupo de voluntários com perfis físicos e comportamentais diferentes, alguns apresentam padrões que não são encontrados no restante do banco (outros voluntários). Tal fato é observado com os voluntários 1 e 4, por esse motivo os algoritmos se mostraram ineficazes na detecção de quedas lentas desses usuários. Enquanto isso, os resultados dos voluntários 3 e 5 apresentam ótimos resultados porque eles apresentam padrões semelhantes aos dos extraídos pelos algoritmos.

A partir dos resultados obtidos, apresentados nas Tabelas 12, 13 e 14, é possível fazer duas afirmações. Um grupo de usuários diversificado tanto em características físicas como comportamentais, apresentadas em 5.1, torna o classificador gerado pelos algoritmos de AA mais capaz de detectar quedas, sejam elas rápidas ou lentas. Logo é possível que com o crescimento da IoT e de ambientes inteligentes muito mais pessoas sejam avaliadas e isso melhore a eficiência dos sistemas AAL capazes de detectar quedas.

A outra afirmação diz respeito à criação de perfis de usuários, pois alguns usuários apresentam padrões que são bem diferentes de outros. Desta forma, um sistema de detecção de quedas pode se tornar muito mais eficiente se usuários com padrões semelhantes utilizarem classificadores correspondente ao seu perfil. Ou seja, olhando para Tabela 14, caso o voluntário 4 utilizasse um classificador que foi treinado com dados de outras pessoas cujo perfil físico e comportamental fosse semelhante ao dele, os resultados encontrados seriam bem melhores. Conseqüentemente, é necessária uma diversidade de padrões para que o classificador aprenda uma gama de variações possíveis e funcione melhor.

Observando os resultados obtidos, apresentados nas Tabelas 13 e 14, é possível supor que uma base extensa contendo mais informações de diversos indivíduos deve ser capaz de melhorar os padrões detectados pelos algoritmos de AA e assim melhorar a classificação de eventos de queda dos usuários que o método não foi tão eficiente.

Porém uma outra opção viável é a classificação dos usuários em classes. Por exemplo, usuários com perfis semelhantes poderiam ser utilizados para treinar os algoritmos e dessa forma o método seria capaz de melhorar sua percepção de quedas, pois usuários semelhantes devem apresentar padrões semelhantes.

Os resultados apresentados neste Capítulo mostram que é possível utilizar a INFORM em sistemas AAL que implementam detecção de quedas. O Capítulo 6 vai apresentar as conclusões deste trabalho de dissertação de mestrado, os trabalhos publicados durante o desenvolvimento do mesmo, as limitações da abordagem INFORM e por fim os trabalhos futuros provenientes desta dissertação.

6 CONCLUSÃO

Este Capítulo encerra este trabalho de dissertação de mestrado e se divide da seguinte maneira: 6.1 apresenta algumas reflexões sobre o trabalho desenvolvido e os resultados encontrados; 6.2 vai mostrar outros trabalhos desenvolvidos durante o mestrado que estiveram relacionados com o tema aqui abordado; 6.3 mostra as limitações presente no mesmo, tanto do ponto de vista da INFORM quanto dos experimentos; E por fim 6.4 lista algumas alternativas para continuação e melhoria deste trabalho.

6.1 Discussões Gerais

Esta dissertação apresentou o método INFORM. Uma abordagem para detectar quedas em sistemas AAL que se utiliza de informações de baixo e alto nível, extraídas de sensores infravermelhos e acelerômetro, e fusionadas por meio de algoritmos de aprendizagem automática. A INFORM visa atacar três pontos principais:

- O tipo de tecnologia empregada deve ser de fácil aceitação pelo usuário;
- A abordagem não pode depender somente do usuário e deve implementar mecanismos de redundância a fim de suprir uma possível falha de uma das modalidades fusionadas e complementares no intuito de produzir informações mais precisas;
- Algoritmos de aprendizagem automática são capazes de gerar um classificador de forma rápida e assim facilitar a adaptação do sistema, porém a experiência do especialista é muito importante e somada aos algoritmos de AA pode melhorar a eficiência do sistema.

Todos os pontos listados foram levantados a partir do estudo da literatura existente e observou-se que nenhum trabalho lida com os três ao mesmo tempo. O método INFORM trata esses pontos da seguinte maneira:

- Foram empregados sensores infravermelhos (os dados destes sensores foram coletados manualmente, explicado em 5.1.1) que além de possuírem um custo relativamente reduzido (MUBASHIR *et al.*, 2013) não ferem a privacidade do residente do ambiente monitorado. O método também se utiliza de um acelerômetro preso ao tórax do usuário, que pode ser considerado invasivo, porém é possível que em alguns anos existam roupas capazes de detectar a aceleração do usuário, o que remove este empecilho;

- A INFOrM utiliza informações do acelerômetro, que depende do usuário para equipá-lo e tem limite de bateria por se tratar de um dispositivo móvel como o caso de um celular por exemplo. Porém também utiliza sensores infravermelhos que podem estar ligados à rede elétrica e que são independentes do usuário;
- O método proposto utiliza algoritmos baseados na expertise de um especialista para gerar informações de alto nível que são utilizadas posteriormente em conjunto com as informações brutas dos sensores para treinar algoritmos de aprendizagem automática. Estes são capazes de extrair um modelo que pode ser utilizado por um sistema de detecção de quedas de um AAL.

Ainda sobre a INFOrM o Capítulo 5 apresenta os resultados obtidos e por meio destes é possível fazer algumas afirmações:

- O método INFOrM se mostrou eficiente em realizar detecção de quedas rápidas e lentas por meio de informações do acelerômetro e dos sensores infravermelhos;
- O método utilizado é capaz de detectar quedas em cenários que o uso de acelerômetro não se faz possível, ou quando o usuário esquece de equipá-lo. O banheiro é o cômodo mais perigoso da casa e mesmo assim a literatura se preocupa pouco com este cenário;
- Uma base de dados maior, com maior diversidade pode tornar o método ainda mais eficiente. Isto deve acontecer com o aumento do número de dispositivos capazes de sentir o ambiente e trocar informações;
- Uma possível classificação dos usuários em diferentes perfis pode facilitar o trabalho de um sistema de detecção de quedas, pois um classificador gerado a partir de usuários semelhantes provavelmente irá obter melhores resultados.

6.2 Produção Bibliográfica

Durante o desenvolvimento deste trabalho, o aluno trabalhou em projetos de pesquisa e desenvolvimento onde adquiriu maior expertise em aprendizagem automática e realizou atividades que estavam relacionadas a um sistema baseado em sensores infravermelhos. Ao longo destes dois projetos foram obtidas as seguintes publicações:

- Alisson S. C. Alencar, Wesley L. Caldas, João P. P. Gomes, Amauri H. de Souza Junior, Paulo A. C. Aguiar, Christiano A. P. Rodrigues, Wellington Franco, Miguel F. de Castro e Rossana M. C. Andrade, *MLM-Rank: A Ranking algorithm*

based on the Minimal Learning Machine. The 4th Brazilian Conference on Intelligent Systems (BRACIS), November 4-7, 2015, at the Federal University of Rio Grande do Norte (UFRN), in Natal, RN, Brazil;

- Caio M. A. Carvalho, Christiano A. P. Rodrigues, Paulo A. C. Aguilár, Miguel Franklin, Rossana M. C. Andrade, Dan Istrate, Jerome Boudy, *Adaptative Tracking Model in the Framework of Medical Nursing Home using Infrared Sensors*. International Workshop on Internet of Things for Ambient Assisted Living (Io-TAAL) in conjunction with IEEE GLOBECOM 2015, 6-10 December 2015, San Diego (CA), USA.

6.3 Limitações

Ao longo de todo o texto é possível notar que existem alguns pontos que o método proposto não cobre. Essas limitações se devem tanto a limitações dos sensores quanto dos experimentos realizados para validar a INForM e são listadas a seguir.

6.3.1 Sensores

Em se tratando do uso de sensores, sempre existem limitações associadas aos mesmos. De forma geral, a maior limitação do uso de acelerômetro é justamente quando eles não estão equipados ou quando estão sem bateria. Como os infravermelhos cobrem essa limitação, mesmo que de forma limitada, não há motivos para crer que seja importante apontar como uma limitação do método como um todo.

Porém o método desenvolvido se utiliza de sensores infravermelhos passivos, que são passíveis de falha. É comum ao utilizar uma lâmpada monitorada por um PIR que em algum momento ele não ative, ou demore a ativar. Por isso, movimentos pequenos podem não ser o suficiente para ativar o sensor, e dessa forma, a INForM acusaria uma queda por não conseguir localizar o usuário no cenário. Dormir poderia ser entendido como uma queda caso o usuário não se mova o suficiente para ativar os sensores.

Outra limitação deste tipo de sensor é a utilização de um box de vidro ou plástico no banheiro. Segundo alguns estudos, não é possível afirmar que esse tipo de material bloqueia a radiação infravermelha. Mas é possível que um chuveiro com box comprometa a capacidade do ambiente em detectar uma queda no banheiro, mais especificamente na área interna do box.

Esta limitação poderia ser superada com o uso do sensor na parte interna do box, porém sua integridade poderia ser posta em risco.

Por fim, sensores infravermelhos geralmente tem um tempo mínimo de ativação. Por exemplo, considerando este tempo como seis segundos, se o usuário ativa o sensor, ele só reconhecerá movimento depois de decorridos seis segundos. Ou seja, se o usuário não se mover, ou realizar movimentos curtos, é provável que o sensor não o reconheça, mesmo que durante os cinco segundos anteriores ele tenha se movido bastante. Por esse motivo, foi utilizado o tempo de doze segundos sem que haja nenhuma ativação para inferir que o usuário sofreu uma queda.

6.3.2 Experimentos

Os experimentos também podem ser responsáveis por limitar a avaliação da INFOrM. Uma das limitações se deve ao número de voluntários que foi utilizado para realizar a avaliação da abordagem, como já foi dito anteriormente, o desempenho poderia ter sido melhor com um número maior de usuários, seja porque o classificador seria capaz de extrair um padrão que funciona para todos, ou porque seria possível dividi-los em grupos baseando-se em seus perfis.

Outro ponto limitante se deve à não utilização dos sensores infravermelhos reais para efetuar os experimentos. Como foi dito, por questões de falha mecânica da base PLC, foram utilizadas entradas manuais para cadastrar localização e postura do usuário. Estas entradas respeitavam o funcionamento original dos sensores, mas ainda sim, é uma limitação registrada do experimento.

Por fim, durante os experimentos foram realizadas diversas atividades com intuito de treinar os algoritmos de aprendizagem automática. Um ponto que pode ser apontado como limitação é quando o usuário cai sentado, pois este evento não foi coberto. Assim, não é possível saber como a INFOrM se comportaria neste caso, pois os algoritmos não foram treinados para detectar este cenário, e porque pode ser possível que ao cair sentado o usuário ainda esteja ativando o sensor infravermelho responsável por detectar postura.

6.4 Trabalhos Futuros

O método INFOrM se mostrou eficiente em detectar quedas rápidas e lentas por meio do uso de informações de sensores infravermelhos passivos e acelerômetro, porém muito ainda pode ser feito para melhorar a performance do mesmo. Algumas dessas possibilidades já foram

levantadas no Capítulo 5, mas aqui são apresentadas outras possíveis melhorias do trabalho:

- Com o aumento do número de sensores e atuadores presentes no cotidiano é possível adaptar o método para utilizar novas modalidades de aquisição de informações. Por exemplo, sensores capacitivos presentes em camas, cadeiras, sofás, etc. podem ajudar a prover maiores informações sobre a localização do residente. Roupas com sensores que monitoram a saúde do paciente podem ser utilizadas para agregar esse tipo de informação à base e ajudar os classificadores.
- Outro trabalho possível, proveniente da análise dos dados, diz respeito a criação de uma etapa de classificação dos usuários para que abordagens de detecção de quedas em geral possam se tornar mais eficientes e precisas. Pois como foi mostrado, é possível que utilizando um perfil adequado para aquele residente sejam obtidos melhores resultados.
- A expertise do especialista está sendo usada neste trabalho na aplicação do celular, e na aplicação que monitora os sensores infravermelhos. Uma possível melhoria seria utilizar a experiência do mesmo também durante a classificação, como é feito em (LUSTREK *et al.*, 2015).
- Por fim, o método proposto pode ser modificado para utilizar informações de um relógio inteligente. Tais dispositivos podem ser utilizados durante o banho e seriam capazes de auxiliar os sensores infravermelhos na cobertura deste cenário tão esquecido pela literatura.

REFERÊNCIAS

- AGRAWAL, S.; VIEIRA, D. A survey on internet of things-[doi 10.5752/p. 2316-9451.2013 v1n2p78](https://doi.org/10.5752/p.2316-9451.2013v1n2p78). **Abakós**, v. 1, n. 2, p. 78–95, 2013.
- AL-FUQAHA, A.; GUIZANI, M.; MOHAMMADI, M.; ALEDHARI, M.; AYYASH, M. Internet of things: A survey on enabling technologies, protocols, and applications. **IEEE Communications Surveys Tutorials**, v. 17, n. 4, p. 2347–2376, Fourthquarter 2015. ISSN 1553-877X.
- ALBERT, M. V.; KORDING, K.; HERRMANN, M.; JAYARAMAN, A. Fall classification by machine learning using mobile phones. **PloS one**, Public Library of Science, v. 7, n. 5, p. e36556, 2012.
- ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. **Comput. Netw.**, Elsevier North-Holland, Inc., New York, NY, USA, v. 54, n. 15, p. 2787–2805, out. 2010. ISSN 1389-1286. Disponível em: <<http://dx.doi.org/10.1016/j.comnet.2010.05.010>>.
- BAKER, S. P.; HARVEY, A. Fall injuries in the elderly. **Clinics in geriatric medicine**, v. 1, n. 3, p. 501–512, 1985.
- BALDINGER, J.-L.; BOUDY, J.; DORIZZI, B.; LEVREY, J.-P.; ANDREA, R.; PERPÈRE, C.; DELAVAU, F.; ROCARIES, F.; DIETRICH, C.; LACOMBE, A. Tele-surveillance system for patient at home: the mediville system. In: SPRINGER. **International Conference on Computers for Handicapped Persons**. [S.l.], 2004. p. 400–407.
- BREIMAN, L. Bagging predictors. **Machine learning**, Springer, v. 24, n. 2, p. 123–140, 1996.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001.
- CARVALHO, C. M. A.; RODRIGUES, C. A. P.; AGUILAR, P. A. C.; CASTRO, M. F. de; ANDRADE, R. M. C.; BOUDY, J.; ISTRATE, D. Adaptive tracking model in the framework of medical nursing home using infrared sensors. In: **2015 IEEE Globecom Workshops (GC Wkshps)**. [S.l.: s.n.], 2015. p. 1–6.
- CAVALCANTE, P.; BOUDY, J.; ISTRATE, D.; DORIZZI, B.; MOTA, J. M. A dynamic evidential network for fall detection. **Biomedical and Health Informatics, IEEE Journal of**, v. 18, n. 4, p. 1103–1113, July 2014. ISSN 2168-2194.
- CAVALCANTE, P.; SEHILI, M.; HERBIN, M.; ISTRATE, D.; BLANCHARD, F.; BOUDY, J.; DORIZZI, B. First steps in adaptation of an evidential network for data fusion in the framework of medical remote monitoring. In: **Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE**. [S.l.: s.n.], 2012. p. 2044–2047. ISSN 1557-170X.
- Centers for Disease Control and Prevention. **Nonfatal Bathroom Injuries Among Persons Aged 15 Years — United States, 2008**. 2011. <<http://www.cdc.gov/mmwr/preview/mmwrhtml/mm6022a1.htm>>. Acessado em 10-Outubro-2016.
- Centers for Disease Control and Prevention. **Falls among older adults: an overview**. Centers for Disease Control and Prevention, Home and Recreational Safety Web site, 2013. Acessado em 05-Setembro-2016. Disponível em: <<http://www.cdc.gov/HomeandRecreationalSafety/Falls/adultfalls.html>>.

- Centers for Disease Control and Prevention. The state of aging and health in america 2013. Centers for Disease Control and Prevention, US Dept of Health and Human Services, 2013. Acessado em 30-Agosto-2016. Disponível em: <<https://www.cdc.gov/aging/pdf/state-aging-health-in-america-2013.pdf>>.
- CHEN, J.; KWONG, K.; CHANG, D.; LUK, J.; BAJCSY, R. Wearable sensors for reliable fall detection. In: **Engineering in Medicine and Biology Society**. [S.l.: s.n.], 2005. p. 3551–3554.
- European Research Cluster on the Internet of Things. **Position Paper on Standardization for IoT technologies**. 2015. <<http://www.internet-of-things-research.eu/documents.htm>>. Acessado em 20-Outubro-2016.
- FERRETTI, F.; LUNARDI, D.; BRUSCHI, L. Causas e consequências de quedas de idosos em domicílio. **Fisioter Mov**, v. 26, n. 4, p. 753–62, 2013.
- FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. *et al.* Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). **The annals of statistics**, Institute of Mathematical Statistics, v. 28, n. 2, p. 337–407, 2000.
- GEORGIEFF, P. Ambient assisted living. **Marktpotenziale IT-unterstützter Pflege für ein selbstbestimmtes Altern, FAZIT Forschungsbericht**, v. 17, p. 9–10, 2008.
- GJORESKI, H.; GAMS, M.; LUŠTREK, M. Context-based fall detection and activity recognition using inertial and location sensors. **Journal of Ambient Intelligence and Smart Environments (JAISE)**, v. 6, n. 4, p. 419–433, 2014.
- GJORESKI, H.; LUSTREK, M.; GAMS, M. Accelerometer placement for posture recognition and fall detection. In: IEEE. **Intelligent environments (IE), 2011 7th international conference on**. [S.l.], 2011. p. 47–54.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009.
- HEARST, M. A.; DUMAIS, S. T.; OSMAN, E.; PLATT, J.; SCHOLKOPF, B. Support vector machines. **IEEE Intelligent Systems and their Applications**, IEEE, v. 13, n. 4, p. 18–28, 1998.
- HRISTOVA, A.; BERNARDOS, A.; CASAR, J. Context-aware services for ambient assisted living: A case-study. In: **Applied Sciences on Biomedical and Communication Technologies, 2008. ISABEL '08. First International Symposium on**. [S.l.: s.n.], 2008. p. 1–5.
- IEEE Internet Initiative. **Towards a Definition of the Internet of Things (IoT)**. 2015. <<http://iot.ieee.org/definition.html>>. Acessado em 20-Outubro-2016.
- INDRA. **Sofia2**. 2017. <http://sofia2.com/home_en.html>. Acessado em 10-Janeiro-2017.
- IPIÑA, D. López-de; LAISECA, X.; BARBIER, A.; AGUILERA, U.; ALMEIDA, A.; ORDUÑA, P.; VAZQUEZ, J. I. Infrastructural support for ambient assisted living. In: SPRINGER. **3rd Symposium of Ubiquitous Computing and Ambient Intelligence 2008**. [S.l.], 2009. p. 66–75.
- ISO/IEC JTC 1. **Internet of Things. Preliminary Report 2014**. 2014. <http://www.iso.org/iso/publication_item.html?pid=PUB100362>. Acessado em 20-Outubro-2016.

ISTRATE, D.; CASTELLI, E.; VACHER, M.; BESACIER, L.; SERIGNAT, J.-F. Information extraction from sound for medical telemonitoring. **IEEE transactions on information technology in biomedicine**, IEEE, v. 10, n. 2, p. 264–274, 2006.

ITU Telecommunication Standardization Sector. **Internet of Things Global Standards Initiative**. 2012. <<http://www.itu.int/en/ITU-T/gsi/iot/Pages/default.aspx>>. Acessado em 20-Outubro-2016.

KANGAS, M.; KONTTILA, A.; WINBLAD, I.; JAMSA, T. Determination of simple thresholds for accelerometry-based parameters for fall detection. In: IEEE. **2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.], 2007. p. 1367–1370.

LEGRAND. **Legrand Catalogue 2010**. 2010. <http://media.klinkmann.fi/legrand/pdf/ex29001_644_ex29001_693.pdf>. Acessado em 10-Outubro-2016.

LUSTREK, M.; GJORESKI, H.; VEGA, N. G.; KOZINA, S.; CVETKOVIC, B.; MIRCHEVSKA, V.; GAMS, M. Fall detection using location sensors and accelerometers. **IEEE Pervasive Computing**, IEEE, v. 14, n. 4, p. 72–79, 2015.

LUŠTREK, M.; KALUŽA, B. Fall detection and activity recognition with machine learning. **Informatica**, v. 33, n. 2, 2009.

MAGHERINI, T.; FANTECHI, A.; NUGENT, C.; VICARIO, E. Using temporal logic and model checking in automated recognition of human activities for ambient-assisted living. **Human-Machine Systems, IEEE Transactions on**, v. 43, n. 6, p. 509–521, Nov 2013. ISSN 2168-2291.

MICROSOFT. **Kinect for Windows Sensor Components and Specifications**. 2010. <<https://msdn.microsoft.com/en-us/library/jj131033.aspx>>. Acessado em 10-Outubro-2016.

MINIÑO, A. M.; (US), N. C. for H. S. *et al.* **Deaths: final data for 2004**. [S.l.]: Department of Health and Human Services, Centers for Disease Control and Prevention, National Center for Health Statistics, 2007.

MUBASHIR, M.; SHAO, L.; SEED, L. A survey on fall detection: Principles and approaches. **Neurocomputing**, Elsevier, v. 100, p. 144–152, 2013.

MURPHY, K. P. **Machine Learning: A Probabilistic Perspective**. [S.l.]: The MIT Press, 2012. ISBN 0262018020, 9780262018029.

NAZEMZADEH, P.; FONTANELLI, D.; MACII, D. An indoor position tracking technique based on data fusion for ambient assisted living. In: **Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA), 2013 IEEE International Conference on**. [S.l.: s.n.], 2013. p. 7–12.

PIEPER, M.; ANTONA, M.; CORTÉS, U. Ambient assisted living. **Ercim News**, n. 87, 2011.

PIVA, L. S.; BRAGA, R. B.; FERREIRA, A. B.; ANDRADE, R. M. de C. falert: Um sistema android para monitoramento de quedas em pessoas com cuidados especiais. 2014.

RAMPARANY, F.; MARQUEZ, F. G.; SORIANO, J.; ELSALEH, T. Handling smart environment devices, data and services at the semantic level with the fi-ware core platform. In: IEEE. **Big Data (Big Data), 2014 IEEE International Conference on**. [S.l.], 2014. p. 14–20.

- RASHIDI, P.; MIHAILIDIS, A. A survey on ambient-assisted living tools for older adults. **IEEE journal of biomedical and health informatics**, IEEE, v. 17, n. 3, p. 579–590, 2013.
- RASHIDI, P.; MIHAILIDIS, A. A survey on ambient-assisted living tools for older adults. **IEEE journal of biomedical and health informatics**, Institute of Electrical and Electronics Engineers, Inc., 3 Park Avenue, 17 th Fl New York NY 10016-5997 United States, v. 17, n. 3, p. 579–590, 2013.
- STEENKESTE, F.; BOCQUET, H.; CHAN, M.; VELLAS, B. Remote monitoring system for elders in a geriatric hospital. In: **Promoting Independence & Quality of Life for older persons: an international conference on aging Arlington**. [S.l.: s.n.], 1999. p. 2–4.
- STONE, E. E.; SKUBIC, M. Fall detection in homes of older adults using the microsoft kinect. **IEEE journal of biomedical and health informatics**, IEEE, v. 19, n. 1, p. 290–301, 2015.
- SUN, H.; FLORIO, V. D.; GUI, N.; BLONDIA, C. Towards building virtual community for ambient assisted living. In: **Parallel, Distributed and Network-Based Processing, 2008. PDP 2008. 16th Euromicro Conference on**. [S.l.: s.n.], 2008. p. 556–561. ISSN 1066-6192.
- TAN, L.; WANG, N. Future internet: The internet of things. In: **Advanced Computer Theory and Engineering (ICACTE), 2010 3rd International Conference on**. [S.l.: s.n.], 2010. v. 5, p. V5–376–V5–380. ISSN 2154-7491.
- The World Bank. **Life expectancy**. 2014. Data retrieved from World Development Indicators, <<http://data.worldbank.org/indicator/SP.DYN.LE00.IN>>.
- THRUN, S.; PRATT, L. **Learning to Learn**. Springer US, 2012. ISBN 978-1-4615-5529-2. Disponível em: <http://dx.doi.org/10.1007/978-1-4615-5529-2_1>.
- United Nations, Department of Economic and Social Affairs, Population Division. **World Population Ageing 2015 - Highlights (ST/ESA/SER.A/368)**. United Nations, 2015. Acessado em 25-Agosto-2016. Disponível em: <http://www.un.org/en/development/desa/population/publications/pdf/ageing/WPA2015_Highlights.pdf>.
- VERMESAN, O.; FRIESS, P. **Internet of things-global technological and societal trends from smart environments and spaces to green ICT**. [S.l.]: River Publishers, 2011.
- WANG, H.; LI, M.; LI, J.; CAO, J.; WANG, Z. An improved fall detection approach for elderly people based on feature weight and bayesian classification. In: **2016 IEEE International Conference on Mechatronics and Automation**. [S.l.: s.n.], 2016. p. 471–476.
- ZHANG, S.; LI, H.; MCCULLAGH, P.; NUGENT, C.; ZHENG, H. A real-time falls detection system for elderly. In: IEEE. **Computer Science and Electronic Engineering Conference (CEEC), 2013 5th**. [S.l.], 2013. p. 51–56.