

UNIVERSIDADE FEDERAL FLUMINENSE
INSTITUTO DE COMPUTAÇÃO
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO

Douglas Faria Moreira Mareli

Reconhecimento de Atividades em um Sistema
Computacional Pervasivo de Assistência Domiciliar à
Saúde

Niterói-RJ

2011

DOUGLAS FARIA MOREIRA MARELI

RECONHECIMENTO DE ATIVIDADES EM UM SISTEMA COMPUTACIONAL
PERVASIVO DE ASSISTÊNCIA DOMICILIAR À SAÚDE

Monografia apresentada ao Curso de Graduação em Ciência da Computação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Bacharel em Ciência da Computação.

Orientador: Prof. ORLANDO GOMES LOQUES FILHO, Ph.D

Niterói-RJ

2011

DOUGLAS FARIA MOREIRA MARELI

RECONHECIMENTO DE ATIVIDADES EM UM SISTEMA COMPUTACIONAL
PERVASIVO DE ASSISTÊNCIA DOMICILIAR À SAÚDE

Monografia apresentada ao Curso de
Graduação em Ciência da Computação
da Universidade Federal Fluminense,
como requisito parcial para obtenção do
Grau de Bacharel em Ciência da Com-
putação.

Aprovada em Julho de 2011.

BANCA EXAMINADORA

Prof. Dr. ORLANDO GOMES LOQUES FILHO - Orientador

UFF

Prof. Dr. JULIUS CESAR BARRETO LEITE

UFF

Prof. Me. SERGIO TEIXEIRA DE CARVALHO

UFG

Niterói-RJ

2011

Dedico este projeto de aplicação a todos meus familiares, amigos e professores, que no período de iniciação científica e desenvolvimento deste projeto me ajudaram com paciência, atenção e compreensão, demonstrando que o desenvolvimento é valioso, por estar ao lado de pessoas que se importam com o sucesso deste trabalho.

“O problema não é se as máquinas pensam, mas se os homens fazem.”

— Burrhus Frederic Skinner

“Os conceitos mais simples são os mais abstratos.”

— Friedrich Wilhelm Ostwald

“O conhecimento nos faz responsáveis.”

— Che Guevara

Agradecimentos

Agradeço aos Professores da UFF, que me forneceram o conhecimento necessário e motivaram o meu aprendizado.

Aos colegas do laboratório Tempo que me ajudaram quando as dificuldades apareceram.

Ao CNPq por incentivar a nossa pesquisa através da bolsa de iniciação científica.

Aos meus pais que me deram condições para concluir a faculdade e chegar onde estou.

Aos meus amigos que sempre confiaram e torceram pelo meu sucesso.

Lista de Figuras

3.1	Módulo de Reconhecimento de Atividade Conceitual	23
3.2	Detector de quedas	27
3.3	Treinamento do classificador C4.5	29
3.4	Treinamento do classificador SVM	31
3.5	Inferidor AF	35
4.1	Arquitetura utilizada para detecção de queda	44
4.2	Diagrama de classe do módulo de detecção de queda	46
4.3	Diagrama da sequência principal do módulo de detecção de queda	47
4.4	Arquitetura utilizada na inferência AF	50

Lista de Tabelas

6.1	Tabela de testes do detector de queda	59
6.2	Tabela de testes do inferidor AF	61

Sumário

Agradecimentos	vi
Lista de Figuras	vii
Lista de Tabelas	viii
Resumo	xi
1 Introdução	1
2 Trabalhos relacionados	6
2.1 Análise de estudos gerais sobre reconhecimento de atividades	9
2.2 Análise de técnicas voltadas à detecção de quedas	13
2.3 Análise de técnicas voltadas à inferência do nível de atividade física	16
2.4 Conclusão do capítulo	19
3 Metodologia proposta	20
3.1 Detecção de queda	24
3.2 Inferência do nível de atividade física	32
3.3 Conclusão do capítulo	36
4 Desenvolvimento de um Módulo de Reconhecimento de Atividades	37
4.1 Ferramentas de Desenvolvimento	38
4.1.1 Weka	39
4.1.2 Android	40
4.1.3 Kit de desenvolvimento do eZ430-Chronos	42
4.2 Detecção de quedas	43
4.3 Identificador do nível de intensidade da atividade física	49
4.4 Conclusão do capítulo	52

5	Integração e Teste	53
5.1	Testes do detector de quedas	54
5.2	Testes do identificador do nível de atividade física (AF)	56
5.3	Conclusão do capítulo	57
6	Resultados	58
6.1	Resultados do detector de quedas	59
6.2	Resultados do identificador do nível de atividade física	60
6.3	Conclusão do capítulo	61
7	Conclusão	63
7.1	Trabalhos futuros	67

Resumo

O aumento da população idosa vem se tornando uma preocupação crescente na área da saúde. Atualmente, os sistemas de telemonitoramento de pacientes são vistos como uma opção viável para aprimorar os serviços de atendimento à saúde. Neste contexto, estamos desenvolvendo um sistema computacional inteligente de assistência domiciliar a saúde (SCIADS), que incorpora conceitos de computação ubíqua. Neste tipo de aplicação, a identificação da atividade física realizada pelo paciente é uma informação essencial para a manutenção da saúde do paciente. Nosso trabalho visa investigar um arcabouço de técnicas voltadas para o reconhecimento de atividades de pacientes através de informações providas por sensores, que podem ser vestidos pelo paciente ou distribuídos no ambiente residencial. Inicialmente, implementamos um módulo que permite identificar as atividades básicas desenvolvidas por pacientes. Além disso, implementamos uma função de reconhecimento de quedas que complementa a funcionalidade de reconhecimento de atividades. Ao realizar testes com simulação de movimentos cotidianos observamos 87% de precisão na determinação do nível de atividade física e 93% de precisão na detecção de quedas. Os resultados obtidos serão integrados em um módulo de Reconhecimento de Atividades, componente do sistema SCIADS atualmente em desenvolvimento.

Palavras-chave: reconhecimento de atividades, computação ubíqua, telessaúde.

Capítulo 1

Introdução

Com a percepção do aumento da perspectiva de vida devido ao avanço da medicina é observado que a quantidade de pessoas idosas cresce substancialmente nos últimos anos. Neste cenário, aparecem problemas em diversas esferas da sociedade, sendo um deles o aumento da demanda por tratamento nos órgãos de saúde. Os principais tipos de tratamentos, cuja demanda vem aumentando, são os relacionados com doenças crônicas e condições críticas de saúde. Em sua maioria, esses tratamentos exigem longos períodos de internação, ou necessitam de acompanhamento periódico por um longo tempo. Essa demanda pode ser atendida por sistemas de telessaúde.

Sistemas de telessaúde podem ser construídos para o acompanhamento a distância de pacientes, permitindo que o tratamento seja realizado em suas residências. Atendendo ao crescente aumento de pessoas idosas vivendo sozinhas, os custos de internação podem ser reduzidos. Ao acompanhar um número relevante de pacientes, a telessaúde pode ocasionar na redução de profissionais dedicados e custos de internação.

Um dos grandes desafios da assistência domiciliar a saúde é conquistar a adesão do paciente ao tratamento. Há uma dificuldade em acompanhar à distância a sua rotina. Isso coloca em questão a situação do paciente em relação ao cumprimento das prescrições médicas, indicativo do nível de adesão ao tratamento. O sistema de telessaúde proposto em [2] e [1], denominado Sistema Computacional Inteligente de Assistência Domiciliar à Saúde (SCIADS), busca soluções a essas questões.

Como objetivo, o SCIADS estabelece um telemonitoramento à saúde utilizando tecnologias de computação ubíqua em ambiente residencial. A possibilidade de internação com os paciente permitida pela computação ubíqua, o SCIADS tem o potencial de prover maior adesão do paciente ao tratamento.

Em [2], foi apresentado um protótipo que ilustra a aplicação dessa ideia. Nesse protótipo há duas estações básicas, a central de supervisão médica (CSM), e a central de supervisão residencial (CSR). Na CSM é possível monitorar vários pacientes, observando dados e medidas realizadas. Cada paciente possui uma CSR em casa, através da qual suas medidas são enviadas para a CSM. Esse envio ocorre através de conexão com a internet. Além disso, a CSR provê uma interface com o paciente, contendo um plano de cuidados a serem seguidos. Os cuidados prescritos incluem pedidos para fazer medida de pressão, tomar remédios, fazer pesagem, entre outros. Um profissional de saúde é responsável por preencher remotamente os planos de cuidados.

Outro dado importante fornecido pelo sistema é a atividade. No protótipo, por exemplo, com o uso de um Sun SPOT foi possível visualizar a intensidade da atividade física. Essa informação é utilizada como auxílio a um modelo de decisão para a inferência da situação do paciente, proposto em [5], e composto de várias medidas. A obtenção de atividade é um foco de trabalho no desenvolvimento do SCIADS.

Neste projeto, atividade é tratada como um conjunto de ações relacionadas a situação física e comportamental de um indivíduo. As atividades mais simples possuem um conjunto menor de ações associadas. Alguns exemplos de atividades simples são deitar, levantar e sentar. As atividades de alto nível possuem um conjunto maior de ações e atividades simples associadas. Alguns exemplos de atividades mais gerais são comer, dormir e cozinhar. Este nível de atividade é mais complexo de ser reconhecido, porém sua informação tem valor alto valor representativo do estado do paciente.

Obter informações de atividade do paciente no SCIADS é fundamental, para reforçá-la, pois saber o que o paciente está fazendo possibilita analisar melhor sua adesão. Por exemplo, quando um remédio é prescrito, o sistema pode avisar caso o paciente não o tenha tomado. Isso poderia ser identificado com a verificação das atividades realizadas através de sensores infravermelhos e acelerômetros. Outro exemplo é a informação de atividade auxiliar, junto com outras medidas, na execução no módulo de decisão para inferir se o paciente está em situação de emergência. A informação de atividade auxiliar pode estar associada a sua situação física.

Dados esses exemplos é preciso verificar os problemas que estão associados à identificação dessas atividades. Esses problemas podem estar relacionados à falta de precisão e à alta demanda de interação do usuário. Essa demanda de interação torna o sistema demasiadamente intrusivo, e a falta de precisão torna o reconhecimento pouco confiável. Por exemplo, o identificador de intensidade presente no protótipo do SCIADS [2] apre-

senta informações momentâneas. Essas informações não representam a situação física a longo prazo, representando um problema quando estas medidas são utilizadas no módulo de decisão. As informações de longo prazo são mais representativas e são uns dos objetivos do módulo de reconhecimento de atividades (RA).

Tendo como motivação atender essa necessidade, foi estabelecido como objetivo deste trabalho, reconhecer atividades em um sistema computacional pervasivo de assistência domiciliar a saúde. Voltadas a esse objetivo, essa proposta investiga um arcabouço de técnicas, o qual permite o desenvolvimento do módulo RA. Esse módulo pretende identificar, com precisão, o comportamento do paciente. O módulo implementado neste trabalho também permite estabelecer uma integração com o SCIADS.

Este trabalho foi motivado pela existência da necessidade de estabelecer uma solução ubíqua para determinação de atividades, a ser utilizada no sistema SCIADS. Essa proposta é uma continuação das aplicações de identificação de atividade utilizadas no protótipo apresentado em [2]. O seu desenvolvimento foi aprimorado tendo em vista a necessidade de um módulo mais robusto e confiável.

É preciso definir as contribuições dessa integração. Uma delas é o reconhecimento de atividades que ajudem a identificar situações críticas à saúde do paciente. Atividades como cair, bater a cabeça e o alto desgaste físico representam algumas dessas atividades críticas. Outro exemplo de situação crítica é a ocorrência de pressão alta e baixa. Há ocasiões em que só a medida de pressão não é suficiente para determinar situações críticas. Neste caso, a informação de níveis de atividade física pode auxiliar na avaliação dessa situação. A associação entre pressão e atividade pode ser encontrada no protótipo apresentado em [2]. Porém é pretendido gerar uma informação mais representativa e confiável do que a encontrada nesse protótipo.

No intuito de abordar nossa proposta de implementação de um módulo RA, foi estabelecida uma organização. Primeiramente, são abordadas técnicas relacionadas ao reconhecimento de atividade. A seguir é feita nossa proposta de abordagem e sua implementação. Foram implementados um detector de queda e um identificador de atividade física. As implementações foram testadas considerando-se a integração com o SCIADS. Os resultados são apresentados e discutidos de acordo com os critérios de avaliação de confiabilidade definidos. Para fechar este trabalho é apresentada sua conclusão junto com uma visão de possíveis soluções futuras.

Descrevendo melhor essa organização, o capítulo definido para propostas relacionadas, capítulo 2, é apresentado. Neste capítulo é estabelecido um escopo bem definido

de técnicas que podem ser utilizadas no telemonitoramento residencial pervasivo. Para direcionar a pesquisa de técnicas, foi utilizado um trabalho que revisa análises da atividade humana. Esta revisão é proposta em [3]. Em seguida, devido à necessidade de obter informações de um paciente, é feita uma análise de propostas mais gerais de soluções ao reconhecimento de atividade. Esse tipo de informação é útil para que profissionais da saúde entendam o comportamento do indivíduo. Ainda nesse capítulo, são avaliadas as propostas de cunho mais específico, listando e analisando técnicas, tanto para detecção de quedas quanto para identificação do nível de esforço físico. Estas duas propostas são usadas para auxiliar a indicação da situação emergencial de um paciente. A identificação do nível de atividade pode ser também uma forma de acompanhar se a rotina do paciente não está sendo muito sedentária.

Avaliadas as propostas relacionadas, um capítulo dedicado à proposta deste projeto de aplicação, capítulo 3, utiliza-se das reflexões do capítulo anterior. Nesse capítulo é apresentado o desenvolvimento do módulo de reconhecimento de atividade (RA) conceitual, deixando lacunas para futuros desenvolvimentos, e abordando mais profundamente os submódulos a serem implementados. Um desses submódulos é o detector de quedas, onde a proposta é estabelecer um módulo confiável sem prejudicar a privacidade de uma pessoa. O outro submódulo corresponde ao inferidor de nível de atividade física (AF), onde foi necessário definir o escopo das atividades residenciais de forma que fosse possível avaliar esse nível em contexto apropriado. Ambos os submódulos utilizam-se de técnicas de aprendizagem de máquina, conceitos de máquina de vetor de suporte (SVM, do inglês) e o algoritmo C4.5.

Questões de implementações são abordadas no capítulo 4. Neste capítulo são mostradas as partes do módulo RA que foram implementadas e são definidas as ferramentas utilizadas nessas implementações. A respeito da escolha de ferramentas é avaliada a importância do uso de dispositivos de medida sem fio. Este tipo de ferramenta torna o tratamento mais cômodo, aumentando a adesão do paciente ao tratamento. Apresentamos ainda a implementação dos submódulos de detecção de quedas e inferência AF, os quais fazem uso de um relógio para a inferência AF e o uso de um celular para a detecção de quedas.

Descritas as implementações, as considerações de integração com o SCIADS e os critérios para realização de testes são definidos no capítulo 5. Os critérios de testes foram separados em testes para o detector de quedas e testes para o inferidor AF. Para cada submódulo foi estabelecida a categorização de atividades e especificados os treinamentos

dos classificadores, definidos no capítulo 3, nas seções 3.1 e 3.2. A análise dos resultados mediante os testes estabelecidos é apresentada no capítulo 6. A conclusão e indicação de propostas futuras são apresentadas no capítulo 7.

Capítulo 2

Trabalhos relacionados

O reconhecimento de atividades de um indivíduo é um estudo direcionado a diversas áreas da ciência e tecnologia. O principal intuito de nosso estudo é acompanhar o estado de um ser humano, o qual interessa principalmente à área da medicina. Uma vez que o reconhecimento da atividade humana é um parâmetro essencial para o telemonitoramento da saúde de um paciente. Há inúmeras publicações sobre o assunto de atividade humana. Além disso, o estudo feito em [3] ajuda a concluir sobre essa quantidade de publicações relacionadas.

Há questões específicas da área da saúde que são importantes e devem ser consideradas antes da elaboração de uma abordagem de monitoramento. Dentre essas questões, podem ser citadas a adesão ao tratamento, fator determinante para a melhora do quadro clínico. Também é importante considerar o fator intrusivo no tratamento. Ou seja, o quanto um fator externo à saúde do paciente está interferindo nos resultados desses cuidados. Um exemplo está na síndrome do jaleco branco, quando a presença de um profissional da saúde pode causar alteração na pressão medida. Um sistema computacional voltado para o telemonitoramento, como o SCIADS, tem que levar em conta essas preocupações.

É importante também considerar os princípios éticos da área médica. Há também, questões mais abrangentes que estão relacionadas à privacidade e confiabilidade das informações obtidas. A questão da privacidade tem que ser cuidadosamente tratada neste trabalho, mais especificamente, na escolha dos sensores de atividade. Para a confiabilidade, pode se ter como principal consideração a taxa de acerto do reconhecimento da atividade, que é avaliada comparando a atividade reconhecida com a real.

Avaliando os trabalhos relacionados e baseado nas principais questões consideradas, foi permitido definir um escopo menor de estudos de atividades. O SCIADS, como visto em

[2][1], torna evidente a necessidade de uma abordagem com menor intrusão no cotidiano do paciente. Esse tipo de abordagem é decisiva para ponderações em relação à privacidade. Em [6], dentre os sensores propostos é observado um sensor de mancha. Esse sensor pode ser definido como uma câmera de filmagem, que gera uma imagem. Essa imagem define uma pessoa na forma de uma mancha branca sobre um plano de fundo escuro. O uso desse dispositivo ajuda na identificação, através de técnicas de processamento de imagem, e ainda preserva a identidade do indivíduo. Apesar desta preocupação, o uso desse tipo de sensor pode causar uma sensação desconfortável de vigilância ao paciente. Nesse sentido, um monitoramento que cause essa sensação contradiz a ideia básica de um sistema computacional pervasivo proposto pelo SCIADS [2][1].

Para estabelecer um escopo de técnicas apropriadas para uma aplicação de telemonitoramento residencial pervasivo, um trabalho revisando análises da atividade humana é proposto em [3]. Nessa revisão é estabelecida uma classificação de alto nível de técnicas de reconhecimento. As atividades detectadas podem ser classificadas como uma ação individual ou em grupo, uma interação entre homem e objeto ou entre dois indivíduos. Como há o foco na ação individual do paciente para o telemonitoramento, exclui-se abordagens que não tenham por objetivo identificar este tipo de ação dos trabalhos relacionados.

Nessa revisão também é encontrada uma taxonomia hierárquica para técnicas de análise. Essas técnicas são separadas entre abordagens de camada única e abordagens hierárquicas. As propostas de camada única são, de forma mais comum, usadas para reconhecimento de gestos e movimentos sequenciais. As imagens são os parâmetros mais utilizados para definir um reconhecimento desse tipo. Um exemplo de técnica desse tipo é a concatenação de imagens de duas dimensões (2-D) ao longo do tempo. Essas imagens concatenadas geram um volume de três dimensões (3-D), que são as imagens 2-D e a dimensão de tempo. Cada novo volume gerado é rotulado após ser comparado a modelos 3-D de atividades.

As propostas do tipo hierárquicas são adequadas para definições em alto nível, utilizando-se como parâmetro atividades de menor nível. Um exemplo está em identificar uma queda, onde informações mais simples como atividade de movimentação brusca e orientação postural podem ser utilizadas.

Ao comparar as duas abordagens é preciso avaliar como precedente sua aplicabilidade. Essa aplicabilidade deve considerar um sistema de telemonitoramento o menos intrusivo possível. Deve ser observado ainda o nível de atividade pretendido de uma determinada técnica. Como para o SCIADS são necessárias atividades de alto nível, a

abordagem hierárquica foi escolhida por ser a que melhor responde a essa necessidade.

Ao avaliar melhor o conjunto de técnicas hierárquicas, foi possível verificar uma divisão entre abordagens estatísticas, sintáticas e baseadas em descrições [3]. Nessa pesquisa apresentada em [3], a técnica sintática foi analisada como predominante para reconhecimento de interações. Mas não há em [3] nenhuma referência a bibliografias que explorem esse tipo de técnica para o reconhecimento de ações individuais. Nas soluções baseadas em descrições há referências que estudam reconhecimento de aspectos de comportamento individual. Esse tipo de solução, utiliza eventos auxiliares e considerações temporais para determinar atividades de nível maior. O outro grupo de técnicas aplicadas a comportamentos de uma pessoa é o modo estatístico de reconhecimento. Esse grupo engloba técnicas que fazem uso de probabilidade, e pode ser composto de duas fases. Uma fase especifica os dados probabilísticos, e a outra avalia efetivamente a atividade baseada nas probabilidades. Por ser, dos três tipos de análises hierárquicas, a que menos foca em ações individuais, a análise sintática é vista como a menos adequada aos propósitos do nosso projeto.

Com a necessidade de estabelecer um módulo de reconhecimento de atividade voltado para o SCIADS, uma pesquisa por estudos de reconhecimento de alto nível foi necessária. Esse nível fornece ampla informação sobre a movimentação e comportamento de um indivíduo. Essa informação é imprescindível para contribuir com um modelo de correlação de dados como apresentado em [5]. As publicações [14][10][13], abordadas na seção 2.1, trazem uma ideia mais abrangente de classificação, sendo de grande contribuição para o desenvolvimento do módulo desejado.

Analisando estudos realizados sobre o comportamento do paciente é possível verificar diversas contribuições. Algumas vão além de um auxílio aos dados clínicos, são importantes também para estabelecer diretamente uma situação que possa vir a comprometer a saúde. A detecção de quedas é um exemplo que está inserido nesse tipo de estudo. Este componente pode determinar diretamente a situação do indivíduo quando ocorre a queda. Existem diversas propostas voltadas para esse tipo de inferência [11] [4] [17] [15]. Essas abordagens selecionadas têm em comum o fato das técnicas abordadas serem predominantemente estatísticas.

Além da análise de propostas para detecção de quedas, existem estudos que são complementares ao desenvolvimento de um sistema voltado à saúde. Em geral, esses estudos provêm técnicas de reconhecimento que retornam dados como parte de um modelo de inferência, tal como indicado em [5]. Neste caso indicado, para ajudar a inferir a

situação de um paciente, a informação do nível de atividade física relacionada a uma medida de pressão é necessária. É esse tipo de parâmetro auxiliar que nosso projeto pretende explorar, porque aumenta a possibilidade de integração com o SCIADS. As publicações [7][16] são voltadas para identificação desse parâmetro.

As próximas seções têm como meta estabelecer uma comparação das publicações citadas. Na seção 2.1, há uma análise de módulos de identificação de propósito geral. A seção 2.2 contém as análises de trabalhos que propõem a detecção de quedas. E a seção 2.3 tem reunida as análises de trabalhos que identificam os níveis de atividade física.

2.1 Análise de estudos gerais sobre reconhecimento de atividades

A obtenção de informações sobre a atividade de um paciente ajuda profissionais de saúde a entenderem seu comportamento geral. Para possibilitar essa definição de um padrão compreensível à área médica, a utilização da técnica hierárquica é explorada. Essa categoria infere, a partir de um nível menor, um nível maior de atividade. Ao saber disso, o elo entre o estudo de atividades da área computacional e o estudo de medidas fisiológicas da área de medicina pode ser fortalecido.

A quantidade de informações geradas sobre um indivíduo aproxima cada vez mais o telemonitoramento de um tratamento mais pessoal. Isso melhora o aspecto de aderência ao tratamento, o que traz resultados mais sólidos. Por isso é grande o interesse em resultados concretos sobre a análise de atividades. Alguns estudos como [4][15][17][16][11][7], se concentram na detecção de atividades de nível menor, porque isso gera resultados mais concretos atendendo interesses mais específicos. Com abordagens mais gerais, os estudos [6][10][13][14] são alguns exemplos em que atividades de menor nível são necessárias para obtenção de resultados mais sólidos. Esses estudos mais gerais, se concretizados, possibilitam estabelecer um módulo robusto de reconhecimento de atividade.

Há diversas formas de estabelecer uma composição de atividades simples para detectar um comportamento mais geral. Algumas utilizam redes neurais e Bayesianas, aplicação de conceitos de aprendizagem de máquina e sensibilidade a contexto. A sensibilidade ao contexto é um tema abordado em diversos desenvolvimentos da computação ubíqua. Esse conceito explora a necessidade de reconhecer mudanças de contexto por meio de sensores, e permite a aplicação de resoluções condizentes com o novo contexto.

Para todo desenvolvimento usando esse conceito é necessário estabelecer um foco.

Como características comuns dessas técnicas estão a necessidade de duas fases. Uma primeira fase visa estabelecer critérios, na segunda fase ocorre a interpretação desses critérios para identificar a atividade em um dado momento. Essas fases podem ser denominadas como fase de calibragem e fase de interpretação, respectivamente. Em redes Bayesianas, a fase de calibragem consiste em gerar o grafo direcionado acíclico, e a fase de interpretação percorre esse grafo. Na sensibilidade a contexto, a primeira etapa pode consistir em definir as variáveis de contexto a partir dos sensores, enquanto a segunda pode ser definida pela fusão dessas variáveis. E quando se trata de aprendizado de máquina, a fase de treinamento está associada a fase de calibragem, enquanto a fase de teste corresponde a fase interpretação.

Em [13], o reconhecimento de atividades em um escritório é estabelecido como o foco de sensibilidade a contexto. Este artigo cita o uso de três tipos de sensores: microfones binaurais, câmera USB e dispositivos de entrada, como mouse e teclado. Os dados desses sensores são relacionados a um modelo oculto de Markov de duas camadas, que podem gerar até seis estados de atividade. As atividades estão relacionadas ao ambiente em questão. Em uma aplicação voltada para um ambiente residencial, essa mesma abordagem para o modelo oculto de Markov poderia ser utilizada alterando-se seus sensores e seus estados resultantes. Sendo assim, pode ser visto como uma referência a ser compatibilizada com este projeto. Ainda assim é preciso verificar outras resoluções que tenham mais afinidade com o assunto deste projeto de aplicação.

Quando não há parâmetros lógicos bem definidos para resolver determinada questão, o uso da aprendizagem de máquina pode ser explorado. A partir da necessidade de uma resolução confiável, torna-se importante a descoberta de parâmetros que definam uma lógica apropriada. O aprendizado de máquina se aplica a isso, e pode ser visto como ferramenta de classificação comportamental em diversas publicações, tais como [10][11][15][17]. Em [10] é encontrada uma abordagem generalizada, que sustenta as ideias de aprendizados semisupervisionados e ativos. No caso semisupervisionado, o fator de confiança das previsões é verificado em tempo real, e, com base nas novas amostras geradas pelos sensores, adiciona os dados com maior fator ao conjunto de dados de treinamento. Com isso o classificador é reconstruído a partir deste novo conjunto. No caso ativo, antes da reconstrução do classificador, as novas amostras são rotuladas explicitamente pelo usuário.

Ainda em [10], são apontadas diferentes formas semisupervisionadas de estabelecer este tipo de melhora na classificação, tais como a autoaprendizagem e a coaprendizagem.

O coaprendizado é diferenciado, pois compara o fator de confiança entre diferentes técnicas de aprendizagem de máquina. A coaprendizagem democrática foi apontada como a técnica supervisionada mais efetiva, esta técnica rotula novas amostras de acordo com regra da maioria. Esta nova amostra rotulada é adicionada nos dados de treinamento dos classificadores correspondentes à minoria. Estas amostras são adicionadas de acordo com um valor de prioridade, que é definido por um cálculo feito com o grau de confiança. Esse cálculo é feito com base na diferença entre a soma dos fatores de confiança das previsões de resultado majoritário e a soma dos fatores de confiança das previsões da minoria. As amostras com as maiores diferenças têm maiores prioridades associadas. Aplicando essa técnica em tempo real, o aprendizado de máquina contribui para estabelecer o aperfeiçoamento de detecção de atividades. Para possibilitar a aplicação desta técnica, as atividades a serem detectadas devem ser compostas de atributos bem definidos, tanto em cardinalidade quanto em suas respectivas morfologias.

Há casos em que identificar certos comportamentos vão além da exploração de atributos bem definidos e da fusão de variáveis. Há situações em que é necessário considerar as probabilidades de eventos de significados mais específicos ocorrerem. Com esses eventos, informações com significado maior do que os sinais de um sensor, ou de vários deles podem ser obtidos. Essas informações são úteis para a compreensão do estado do ser humano. Atividades como dormir, comer, cozinhar e tomar banho não são complexas de serem reconhecidas por nós, seres humanos, mas certamente são mais complexas de serem interpretadas por um sistema computacional. Nessa espécie de atividade, muitos trabalhos abordam o uso de redes Bayesianas e neurais. As redes neurais são utilizadas devido ao fato de que o seu conceito se baseia na estrutura cerebral. Essa mesma estrutura é capaz de distinguir facilmente certas atividades através do raciocínio humano. As redes Bayesianas trazem o conhecimento adquirido de forma explícita, em que cada nó representa probabilidades. Através desta rede, um escopo mais definido possibilitando um processamento mais direto pode ser estabelecido. Este é um fator interessante para as características de processos que ocorrem em tempo real.

Em [14], o uso de uma rede Bayesiana possibilita detectar a probabilidade de uma pessoa estar executando certa atividade a partir dos objetos que ela esteja manipulando. Um exemplo de rede apresentado, há o caso em que a ocorrência simultânea das ações de pegar garfo e faca, ligar a torradeira, pegar a manteiga e pegar o prato podem identificar uma atividade de maior nível, como fazer torradas.

Ainda seguindo esta ideia, podemos realizar detecção de uma atividade através da

detecção de movimentação e localização do indivíduo. A construção dessa rede exige uma série de dados do paciente predispostos sobre sua movimentação e localização. Esses dados fazem com que a construção dos nós com as respectivas probabilidades sejam possíveis. Ao fazer isso é possível gerar um sistema de inferência probabilística de atividades de alto nível.

Ao analisar os diferentes modos de abordar o reconhecimento de atividades, foi possível verificar vantagens e desvantagens em cada um deles. Avaliando cada modo é possível usar as vantagens de cada uma e compô-las em uma única solução. Primeiramente, observando o conceito mais geral de sensibilidade ao contexto, foi possível concluir que quanto mais sensores estiverem a disposição para uma solução, mais efetivo é esse tipo de abordagem, mas, ao mesmo tempo, torna-se mais complexo. Ao utilizar uma solução composta de uma rede Bayesiana é esperada a possibilidade de obter uma resolução com mesmo nível de confiança, mas utilizando uma quantidade menor de sensores. Ao considerar o uso de aprendizagem de máquina sobre essa rede é possível chegar a um aumento da confiabilidade da detecção.

Além das considerações sobre confiabilidade e complexidade, ainda há o levantamento de informações sobre os efeitos das abordagens na adesão do paciente ao sistema. Por isso, a implementação deve levar em conta o requisito de ubiquidade, não aumentando os níveis de intrusão do sistema no cotidiano do usuário. Um exemplo de aumento é observado na geração de uma rede Bayesiana. Para gerar essa rede, são necessários dados treinados, inicialmente de forma ativa com a interação do usuário. Nessa fase de treinamento é verificado um nível de intrusão indesejado devido essa necessidade de interação. Apesar disso, ao concluir essa fase, o usuário não precisa mais interagir de forma ativa, porque o mecanismo semisupervisionado de aprendizado pode ser utilizado. A partir desse momento, a solução pode ser considerada um meio ubíquo de reconhecimento de atividades.

O estudo de técnicas de avaliação generalizadas é apenas uma parte dos estudos relacionados à nossa abordagem de módulo RA. Existem trabalhos que abordam de forma dedicada um determinado tipo de atividade. Estes trabalhos são citados nas seções 2.2 e 2.3. A seção 2.2 contém avaliações de técnicas de detecção de quedas, e a seção 2.3 tem relacionadas as técnicas de detecção do nível de atividade física. Ambas são partes importantes no telemonitoramento da saúde do paciente.

2.2 Análise de técnicas voltadas à detecção de quedas

Os estudos sobre quedas em idosos têm importância em uma diversidade de contextos. As pesquisas, que geralmente estão voltadas para a área da saúde, podem ter diversos focos. Esses focos dependem do ambiente e de como são manipuladas as informações e as ferramentas utilizadas. Nosso projeto tem o propósito de preservar a privacidade do paciente e fornecer seus dados de forma confiável a profissionais da saúde. A detecção de queda, nos casos em que não são verificados danos iniciais, pode ser utilizada para prevenção. No caso em que a queda causa danos imediatos, essa detecção exige atendimento emergencial. Em relação à prevenção, a informação da queda pode ser analisada e ocasionar exames mais aprofundados sobre a saúde da pessoa.

Em uma integração com o SCIADS procura-se a utilização de sensores não intrusivos para a detecção de queda. Nesse contexto é observado que há quedas que não têm caráter emergencial. Por isso há um grande risco de se gerar alarmes falsos, e uma análise posterior pode ser utilizada para reduzir isso. Essa análise corresponde à verificação de ocorrência de dano; ao identificar o dano uma situação de emergência pode ser definida para o usuário monitorado. Esse processo é um ciclo completo de detecção de quedas para o SCIADS. Nesta seção é estabelecida a avaliação de técnicas utilizadas para detectar uma queda emergencial.

A necessidade de definir uma técnica de análise de quedas apropriada motivou a realização de pesquisas na literatura em busca de estudos já realizados com esse foco. Existem diversas abordagens que necessitam de sensores de movimentos corporais, tais como o acelerômetro. Esses sensores são idealmente vestíveis. Algumas análises sobre a quantidade e localização dos sensores no corpo humano estão presentes em [4][15][17]. Em [4], recomenda-se o uso de dois acelerômetros, um na região da coxa e outro na região torácica. Nos estudos feitos em [15][17] é recomendada a utilização do acelerômetro embutido no celular e posto na região da cintura. Essas diferenças na utilização estão relacionadas às diferentes técnicas utilizadas em cada proposta.

A busca por precisão está presente nas diferentes propostas para detecção de quedas a serem analisadas. O falso alarme de quedas é o problema mais preocupante, por ser mais difícil de tratar. Esta preocupação fundamenta-se em soluções mais triviais, as quais geralmente verificam a ocorrência de movimentações bruscas. A detecção desse tipo de movimento não garante a detecção de queda, pois saltos e impactos nos sensores podem também ser identificados. Os estudos realizados em [4][11][15][17], buscam a detecção

mais confiável possível. As técnicas exploradas em [11][15][17] estão relacionadas ao uso de aprendizagem de máquina. Já em [4], avalia-se uma abordagem mais direta, que utiliza faixa de valores relacionados a quedas.

Quanto mais sensores localizados em diferentes regiões do corpo forem utilizados, mais informações podem ser obtidas. Dependendo de como são manipuladas essas informações, mais confiáveis são seus resultados. Em [4] uma técnica utilizando-se de dois sensores, que são acelerômetros de três eixos é aplicada com essa finalidade. A ideia é usar os valores oriundos dos sensores e obtidos em simulações de queda para inferir faixas correspondentes a essa situação crítica. Em cima desses valores é feito a raiz da soma de cada eixo elevado ao quadrado, o que fornece a aceleração resultante. Para cada sensor, existem duas faixas correspondentes à queda, a LFT (do inglês, *Lower Fall Threshold*) e UFT (do inglês, *Upper Fall Threshold*). A LFT corresponde às acelerações muito abaixo do valor estacionário. A UFT corresponde às acelerações muito acima do valor estacionário. A UFT caracteriza-se pela fase da queda em que há o impacto reverso ao piso. A LFT caracteriza-se pela fase imediatamente anterior a esse impacto. O valor da UFT, foi estabelecido pelas acelerações próximas dos picos positivos. Para a LFT, foi realizado o mesmo processo para picos negativos. Como resultado dessa abordagem, foi obtida uma precisão de 100% para detecção de quedas. Em relação a essa precisão é importante ressaltar que esse percentual é obtido a partir de testes comparativos com atividades cotidianas de idosos. Dentre essas atividades não é possível identificar uma categoria de testes dedicados a movimentos bruscos. Isso significa que não foram testadas outras atividades que geram picos extremos de aceleração. Ao incluir atividades como saltos dentro do escopo de atividades cotidianas, um simples teste permitiria verificar picos de aceleração tão altos quanto os obtidos com as quedas. Logo, seria possível ocorrer falsa detecção de queda apesar do percentual apresentado.

Para reduzir a ambiguidade ocasionada pelo uso de limiares, a aprendizagem de máquina no reconhecimento de quedas mostrou ser uma solução bem aplicável e explorada em diversas publicações. Em [11][15][17] são apresentadas diferentes formas de explorar esse conceito. Em [11], um estudo mais geral sobre uso de algoritmos de aprendizado de máquina é apresentado. Este trabalho usa sensores infravermelhos espalhados pelo corpo e ambiente. Como resultado de testes em diversos classificadores, o uso de máquina de vetor de suporte (SVM – do inglês, *Support Vector Machine*) foi identificado como o mais eficiente para detecção de quedas. Esta técnica consiste em relacionar um vetor de atributos a uma classe. Para isso é definido um conjunto de hiperplanos que delimitam a

região pertencente a cada classe pré-definida.

Em geral, como indicado em [15][17], utiliza-se a técnica de SVM de classe única. Em sua fase de treinamento, uma hipersfera é definida como a região desta classe. Isso é obtido gerando uma função de decisão, onde os resultados positivos indicam a pertinência da amostra de teste a classe única representando a queda. Em [17] o vetor de entrada é apresentado como tendo seis atributos. Neste estudo a fase de treinamento consiste em identificar uma seção de tempo. Os dados de aceleração captados dentro desta seção são utilizados para calcular os elementos de um vetor. Cada vetor gerado representa uma seção de tempo. Cada vetor é rotulado de acordo com a verificação da ocorrência de mudanças agudas, tanto nas acelerações relativas ao eixo vertical (a_y) quanto nas acelerações relativas à transversal (a_{xz}). Essa aceleração transversal é a soma vetorial das acelerações no eixo x (a_x) e z (a_z). Quando uma mudança aguda é identificada o vetor é rotulado como representativo de queda. A fase de teste compreende em rotular os vetores de acordo com a função de decisão gerada pela fase de treinamento. Esse ciclo de treinamento e teste se repete por dezesseis vezes, com a finalidade de otimizar o classificador. A abordagem de [15] define uma continuação da ideia de [17], com o fator adicional de se tratar de uma aplicação destinada a celulares.

O celular apresenta certa diversidade em seu uso, com isso é necessário abordar questões que vão além do uso de sensores fixos no corpo de uma pessoa. Não há apenas a preocupação de diferenciar a queda de atividades do dia a dia, há também a preocupação de como o celular está sendo utilizado. Ao saber que um fator complicador para inferência de queda está na localização do celular, torna-se importante indicar um posicionamento adequado. Um exemplo de uso que fornece um posicionamento considerado ideal por [17] é colocar o celular em um bolso justo e frontal da calça. Em [15], para evitar erro por conta do celular não estar no bolso, verificou-se a necessidade de um algoritmo classificador a mais do que o utilizado em [17]. Através da técnica de classificação chamada de k vizinhos mais próximos é verificado se o movimento é uma queda, ou uma manipulação aleatória do celular.

É importante fazer algumas considerações sobre as abordagens [4][15][17] antes de se comparar os seus resultados. Primeiro é preciso avaliar o escopo de cada abordagem, e, com base nessa avaliação associar os fatores como a utilização de recursos, a confiabilidade e a adesão. Em [4], pôde-se perceber um escopo mais reduzido, devido à desconsideração de outras atividades bruscas que podem ter variações no pico de aceleração semelhante às das quedas. Ainda é necessário comparar [15] e [17], onde as abordagens têm análises

de escopo de atividades semelhantes. Como a abordagem em [17] é anterior à [15], as ferramentas utilizadas foram menos potentes, e por considerar a fixação do sensor ao corpo, sua portabilidade de uso acaba sendo menor do que a possibilitada em [15]. Apesar disso, os resultados de confiabilidade em [17], utilizando a uma quantidade de amostra maior, foram melhores do que os obtidos em [15]. Apresentando isso em números, foi verificado que para quedas de baixo e alto risco, a técnica de [17] obteve 98,3% e 97,3% de efetividade respectivamente. Já em [15] essa efetividade foi de 97,5% e 96,6% respectivamente. Ainda assim, são valores muito próximos que não servem para destacar uma vantagem de uma proposta em relação à outra.

Apesar da técnica de [15] apresentar a vantagem de lidar com um sensor não necessariamente fixo ao corpo, vale relembrar a utilidade do serviço de detecção de quedas no monitoramento do paciente, que é voltado para a área da saúde. Com essa utilidade, um produto que detecta queda deve monitorar constantemente esse nível de risco, o que faz de um produto que permite liberdade de uso para outros fins algo fora do foco deste trabalho. Isso faz da abordagem em [17], mais compatível que a contida em [15]. Por isso, nossa proposta abordará a necessidade de estabelecer um critério de localização de seus sensores.

Mediante a essa análise específica de detecção de quedas, um outro tipo de atividade que pode auxiliar na detecção de uma situação de emergência é a atividade física. Na próxima seção são mostrados os tipos de abordagens exploradas para este fim, tal como sua respectiva importância no contexto de telemonitoramento.

2.3 Análise de técnicas voltadas à inferência do nível de atividade física

Com o passar do tempo e o advento de novas tecnologias que visam facilitar o dia a dia das pessoas, a preocupação com o sedentarismo tem se tornado mais crescente. Estudos como os feitos em [7][16] destacam a importância do acompanhamento da atividade física do paciente. Em geral procura-se uma minimização de rotinas sedentárias. O grupo mais necessitado dessa preocupação é o dos idosos. Há ainda a preocupação com a adesão dessas pessoas às práticas de exercícios físicos. A fragilidade presente nessa faixa etária mais avançada está sujeita ao desânimo em seguir as recomendações de atividades físicas. O acompanhamento desses níveis de atividades define um parâmetro da situação física do

indivíduo.

A informação de situação física tem importância específica ao SCIADS [2][1]. Em [5] é mostrado um modelo de decisão, onde medidas podem ser relacionadas para inferir uma situação clínica geral para cada paciente. Dentre essas medidas está o nível de atividade física. Uma correlação entre os dados de pressão arterial e o nível de atividade captado em dado instantâneo, pode gerar diferentes situações. Por exemplo, quando uma pressão acima do normal é medida, nesse momento o nível de atividade física foi identificado como alto. Essa situação não é necessariamente emergencial, porque esse aumento de pressão pode ser consequência desse nível de atividade, sendo a detecção de uma situação clínica normal a mais adequada à situação. Com isso, fica evidenciada a importância dessa informação para o contexto desse trabalho.

Existem diversas considerações relacionadas ao reconhecimento desse tipo de atividade. Algumas a consideram atividades de alto nível para estipular um nível de desgaste. Por exemplo, atividades como dormir são consideradas de um nível baixo de atividade, correr é interpretado como um nível alto, andar é relacionado a um nível mediano e assim por diante. Em outros casos, há considerações de baixo nível, em que o nível de atividade é diretamente obtido através processamento de sinais dos sensores. Este processo gera uma questão importante sobre a representatividade dessas informações. Essa representatividade está relacionada com a faixa de tempo que determinada identificação representa. Por exemplo, no processamento de um sinal de aceleração é preciso avaliar a janela de dados que melhor representa o estado do paciente no momento em que uma medida de pressão é realizada. Se por um lado definir essa faixa de valores é complexo, por outro identificar atividades de alto nível também será. Para chegar a uma conclusão sobre uma melhor solução, uma análise de técnicas buscando uma melhor adaptabilidade aos requisitos do SCIADS é apresentada nessa seção.

As técnicas de aquisição dos níveis de atividade física estão presentes em grande parte de propostas relacionadas ao reconhecimento de atividades. Há artigos que abordam isso de maneira mais específica, como em [7][16], e outros que abordam isso como parte do estudo, como em [9]. Dentre essas propostas, há uma que utiliza vários sensores espalhados pelo corpo, como em [7], e outra que utiliza o acelerômetro, como é citado em [9]. É preciso aprofundar-se em cada estudo para se ter uma ideia do que é mais conveniente.

Uma análise de sensores apropriados para este tipo de detecção pode ser verificada em [16]. A calorimetria é citada como forma indireta de estimativa de gasto de energia,

no entanto lida com medidas fisiológicas obtidas de analisadores de gases. Esta é uma abordagem custosa e com a necessidade de conhecimento especializado. Ainda em [16], o uso de acelerômetro é incentivado como forma de detectar atividade física, e ainda há a indicação de localizações mais apropriadas para implantação no corpo de uma pessoa. A região da cintura foi considerada mais apropriada por se mover em grande parte das atividades. A exceção está nos movimentos dos membros superiores. Outro problema da técnica em [16] é a possibilidade de identificar um gasto metabólico errado em movimentos verticais, como subir escadas e andar de elevador. O uso de sensores de pressão atmosférica pode auxiliar neste último caso. Para os movimentos superiores um acelerômetro nessa região pode dar mais confiança a essa proposta.

Ao usar acelerômetros, o estudo em [9] faz uma abordagem indireta de inferência do nível de atividade. Neste trabalho é utilizada a da detecção de atividades de alto nível para avaliar o desgaste físico. A partir de ações como andar, se sentar, se deitar, entre outras. Todos esses movimentos, são identificados por valores limites, que definem angulações e intensidades a partir de um acelerômetro posicionado em lugar específico da cintura. Além do fator indireto de inferência, ainda é apresentada certa imprecisão em atividades como deitar e andar, tornando-a imprecisa para ser usada em um mecanismo de decisão.

Já em [7], são utilizados cinco acelerômetros para identificar os movimentos realizados na parte superior do corpo. Uma informação gráfica do nível de atividade pode ser mostrada diretamente ao paciente. Apesar da vantagem de ser uma técnica de inferência mais direta em relação ao trabalho realizado em [9], este trabalho está em fase preliminar, não sendo possível ainda avaliar a precisão desta abordagem.

Há também a necessidade de uma abordagem mais direta para atender os requisitos do SCIADS. Em muitos casos, a identificação de atividades mais gerais resolvem o problema, mas chegar a essa solução pode ser um desafio maior que solucionar uma parte desse problema. Identificar o gasto de energia metabólica pode ser visto como parte de um módulo de reconhecimento, que ao se tornar o principal objetivo para inferir o nível de atividade física, pode fornecer um módulo RA mais robusto.

A seção de trabalhos relacionados foi importante para esclarecer os caminhos realizados até a obtenção de uma abordagem própria. Para construir um módulo de reconhecimento aplicado ao ambiente residencial e apropriado ao uso em um sistema pervasivo de saúde, o próximo capítulo utiliza as conclusões obtidas e introduz outras questões de escolha de técnicas.

2.4 Conclusão do capítulo

Foram vistas neste capítulo as principais referências bibliográficas deste projeto de aplicação. Como foi possível perceber, essas referências foram selecionadas de acordo com uma análise preliminar dos tipos de técnicas de reconhecimento de atividade. Essas análises foram apresentados em [3], que é uma revisão dos trabalhos relacionados a análise da atividade humana. Desta revisão foi observado um grupo de técnicas interessantes para o módulo RA. Esse grupo contém as técnicas estatísticas, nas quais prevaleceram as análises das técnicas de aprendizagem de máquina.

Como resultado dessa primeira análise, foram definidos três importantes pontos. Primeiro, foi realizada uma análise de propostas mais gerais e como resultado, foram selecionadas as abordagens [10] [14] como as principais bases. Em seguida, foram avaliadas as propostas para detecção de quedas, onde dois artigos interessantes, [15] e [17], foram selecionados. Ao identificar que [15] utiliza uma técnica voltada para um celular de uso geral, foi observada nisso a desvantagem da proposta de [15] em relação à disponibilidade do sensor. Em [17] sua proposta foi vista como suficiente como base à nossa proposta, pois tem resultados de confiabilidades compatíveis e exige uma menor carga de processamento. Essa carga menor é identificada na utilização de menos métodos de classificações que em [15].

Em relação às propostas analisadas para inferência do nível de atividade física, observou-se que a busca por um parâmetro de valor que pode ser linearmente associado aos níveis especificados, como o gasto metabólico de energia definido em [9], é uma abordagem inicial adequada e que pode trazer resultados experimentais mais imediatos. Esses resultados podem contribuir com uma análise mais robusta em trabalhos futuros.

Este capítulo tem como principais importâncias, a definição de bases conceituais e referências técnicas. Isso permite o progresso do nosso projeto de aplicação para a parte da abordagem de um módulo de reconhecimento de atividades (RA), componente do sistema computacional inteligente de assistência domiciliar a saúde (SCIADS) [1][2].

Capítulo 3

Metodologia proposta

O objetivo deste capítulo é desenvolver um módulo de reconhecimento de atividade (RA) conceitual que reúna as soluções específicas em um único fluxo de informação direcionado para o SCIADS [2][1]. O desenvolvimento desse módulo cobre uma lacuna do desenvolvimento de um sistema pervasivo como o SCIADS. Para concretizá-lo é necessário considerar as dificuldades que são encontradas no estabelecimento dessa abordagem. Quando superadas essas dificuldades o módulo RA integrável ao projeto SCIADS [1] poderá ser implementado.

Os problemas relacionados à identificação não intrusiva de atividades geralmente são os de confiabilidade, disponibilidade, comunicação, acessibilidade e implantabilidade. Os problemas de confiabilidade são vistos como aqueles relacionados com a precisão da identificação obtida. Em grande parte dos testes realizados, seu fator é representado percentualmente. Este percentual é obtido com a divisão do número de amostras corretas pelo número de amostras totais. O problema de disponibilidade está relacionado com a quantidade de tempo em que o sensor exerce continuamente sua função. Pode até ser estabelecida uma taxa de uso, mas é necessário considerar algumas limitações, como o tempo de vida da bateria de um sensor e o tempo que é gasto para recarregá-la. A comunicação, envolve uma série de problemas de interação entre o sistema e os sensores. Alguns desses problemas podem causar impactos significativos, como ocorre com a perda de conexão, e consequente perda das informações por um certo período de tempo. Os problemas de acessibilidade indicam a dificuldade na utilização de dispositivos por parte do paciente. A implantabilidade é vista como a dificuldade de se aplicar o módulo desenvolvido no ambiente residencial.

Os inúmeros desafios da avaliação comportamental motivaram diversos estudos.

No capítulo 2, foi possível ter uma noção dessa diversidade de estudos relacionados. No entanto, o módulo RA é submetido às restrições da área da saúde e de um ambiente residencial. Essas restrições são formas de orientar o desenvolvimento de um material robusto para inferência de atividade, e agregam no fechamento de escopo para o qual o módulo está voltado. Isso torna mais viável o estabelecimento de uma solução confiável, e quando uma solução confiável é conquistada, submeter o módulo a um processo incremental se torna mais fácil. O critério de confiabilidade acaba sendo um foco importante de desenvolvimento, que permite estabelecer um módulo RA facilmente incrementável.

Para obter um módulo confiável a escolha de ferramentas adequadas deve ser avaliada. Fora m estipuladas, no capítulo 2, as condições para estabelecer os tipos de sensores a serem utilizados. A partir da constatação dos tipos de técnicas, em [3], mais adequados para o módulo RA, pode ser observado que esses tipos exploravam sensores tridimensionais de aceleração. Esse tipo de acelerômetro é capaz de captar sinais de aceleração em três eixos que são denominados eixos x, y e z, respectivamente. Esse é o tipo de sensor que exploramos nas técnicas que desenvolvemos. Se fosse desconsiderada a privacidade do indivíduo em sua residência, a escolha mudaria para sensores de imagens, o que torna a abordagem mais confiável por prover uma maior carga de informação. Além disso, outros tipos de técnicas seriam exploradas, geralmente, as com foco em análise sequencial de imagens como foi constatado em [3]. Mas estudos como os feitos em [11][15][17] apontam resultados de confiabilidade animadores com a utilização de técnicas estatísticas baseados nos sinais de aceleração.

Com o acelerômetro definido como sensor, foi preciso avaliar as propostas que utilizam esta ferramenta. Também é necessário identificar os componentes que agregam uma solução viável e adaptável. No capítulo 2, foi sugerida a composição de uma solução usando as ideias expostas em [10] e [14]. Esta composição consiste basicamente em utilizar aprendizado semisupervisionado para estabelecer e aprimorar uma rede Bayesiana. Essa rede é composta de atividades de nível significativamente mais simples que geram probabilidades condicionais. Essas probabilidades são conferidas para identificar atividades de nível significativo maior. O problema é a necessidade de uma quantidade considerável de atividades de nível menor, o suficiente para que seja possível alcançar altas probabilidades de ocorrência para atividades de nível maior. É necessário ainda que essa probabilidade seja condizente com o teor de confiabilidade. Isso significa que a atividade classificada, utilizando a rede Bayesiana, deve corresponder à atividade real.

Estabelecer um módulo RA concreto depende da resolução dos diversos tipos de

atividades que podem ser associadas a uma pessoa. Essa diversidade é reduzida quando são considerados os aspectos específicos de nossa proposta. Esses aspectos são definidos pela localização residencial, utilização por pessoas idosas e atuação na área da saúde individual. Ainda assim, resta uma diversidade considerável de atividades. Para identificar uma atividade dentro dessa diversidade é preciso avaliar as técnicas de reconhecimentos de atividades mais específicas. Após isso um módulo RA concreto pode ser estabelecido juntando essas soluções. Uma ideia organizacional dessas soluções específicas dentro de uma solução geral pode ser ilustrada como um módulo RA conceitual. A Figura 3.1 refere-se ao fluxograma que representa essa ideia de organização do fluxo do módulo RA. Alguns componentes desse módulo já tiveram suas implementações realizadas e testadas, outros ainda são espaços para desenvolvimentos futuros.

Pelo fluxograma da Figura 3.1, há três tipos de sensores. Os relativos a objetos são sensores que captam interações entre homem e objeto, ideia que é explorada em [14] e definida como um tipo de atividade a ser detectada em [3]. Os sensores de ambiente são responsáveis por indicar a localização do paciente no ambiente residencial. Os sensores corporais são utilizados para detectar sinais vindos diretamente do corpo do paciente.

Existe uma série de aplicações que podem ser implementadas com sensores em objetos. Um exemplo, são os lembretes para o paciente tomar remédios, onde sensores indicam se o paciente ingeriu um determinado remédio no horário prescrito. Quando são utilizados sensores de ambiente espalhados pela casa, uma série de informações de alto nível podem ser obtidas. Um exemplo está na relação entre a postura identificada e o cômodo onde o indivíduo está localizado. Se a posição deitada for percebida dentro do banheiro, uma situação de risco pode ser apontada dada essa excepcionalidade. Os sensores corporais têm sua descrição mais detalhada, com alguns componentes definidos.

Apesar de ser possível utilizar outros tipos de sensores corporais, os acelerômetros foram os mais focados em nossa proposta. Nessa primeira abordagem, o fluxograma indica que os valores de aceleração de cada eixo, são sinais a serem processados em cada componente inserido no escopo de dispositivos móveis. Esses dispositivos estão relacionados ao sensoriamento corporal. Dentro de um dispositivo móvel, esses sinais passam por um pré-processamento que utiliza filtro passa-baixo para minimizar os efeitos de ruídos. Esses dados filtrados são processados pelo componente de inferência de contexto, que define se o sensor está localizado corretamente de acordo com a predefinição de cada sensor, não estando, o estado de não posicionado é enviado à estação base, caso contrário o processamento do sinal continua. Nessa continuação, os sinais são processados pelo componente de

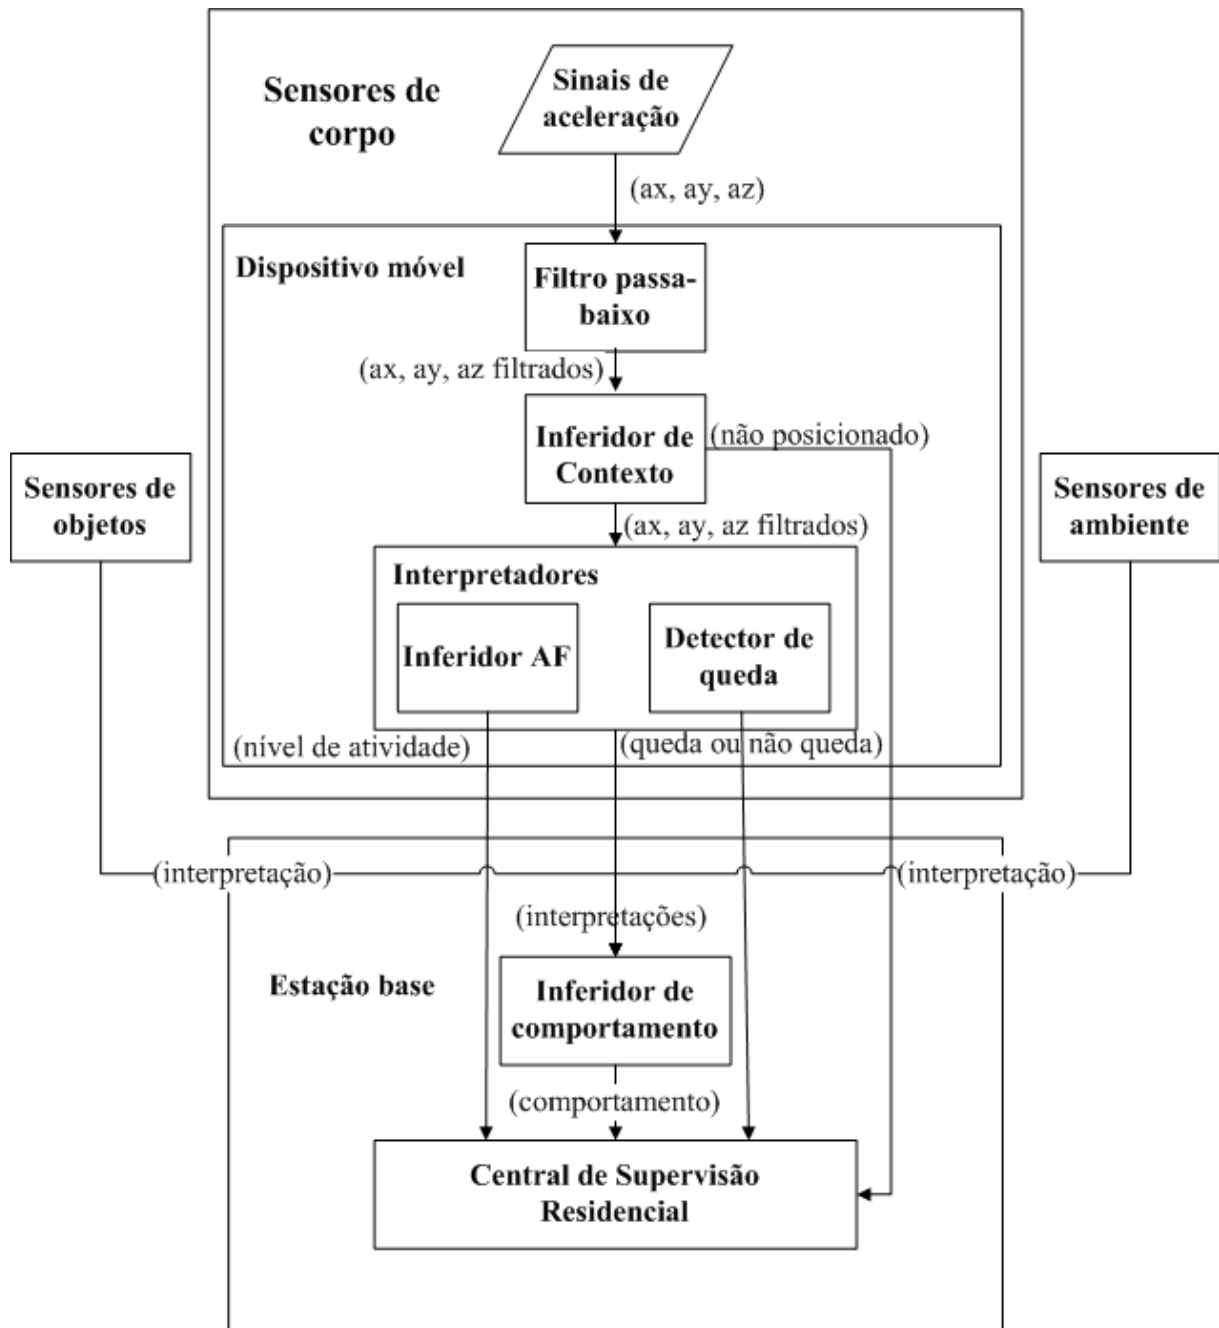


Figura 3.1: Módulo de Reconhecimento de Atividade Conceitual

inferência do nível de atividade física e o de detecção de quedas. Cada componente gera uma classificação, e essas informações geradas são enviadas para uma estação base. No SCIADS [2], a estação base é denominada central de supervisão residencial (CSR). Além de serem utilizadas diretamente pelo sistema, esses dados classificados são usados no identificador de atividades de alto nível. Este módulo de inferência captura as informações processadas de cada diferente sensor e as utilizam no modelo de classificação por redes Bayesianas. Esse classificador retorna uma atividade de alto nível de maior probabilidade. Esse fluxo de informação repete-se em períodos de tempo aproximadamente fixos.

Informações de três tipos de atividades são enviadas para um sistema de telemonitoramento. São informações sobre a situação de queda, nível de desgaste físico e o comportamento de alto nível. Esse tipo de atividades são definidas em linguagem mais próxima do entendimento geral. São exemplos atividades como correr, andar, comer, dormir, cochilar, tomar banho, entre outras tantas que são comuns ao cotidiano do ser humano. Comportamentos como esses são geralmente descritos em publicações como atividades cotidianas (ADL, do inglês, *Activities of Daily Living*).

Nossa proposta focou na identificação de duas dessas informações, são as detecções de quedas e a inferência do nível de atividade física (AF). Por se tratarem de aspectos mais específicos, podem ser definidos antes de inferir uma ADL. As próximas seções indicam como a elaboração de cada componente é realizada. A seção 3.1 descreve a metodologia utilizada para a elaboração da detecção de quedas, que por sua vez tem a implementação descrita na seção 4.2. E a seção 3.2 descreve a metodologia para identificar o nível de atividade física, que tem implementação descrita na seção 4.3.

3.1 Detecção de queda

A detecção de queda está inserida como componente do módulo RA e é uma informação de atividade importante. Esta informação é utilizada como parâmetro para avaliação do estado clínico de um paciente. Os estudos relativos a obtenção desse tipo de parâmetro [4][11][15][17] destacam a importância dessa abordagem para pessoas idosas. Estabelecer esse detector confiável torna-se importante para não prejudicar a avaliação do estado clínico em idosos.

Os problemas que comprometem a confiabilidade nas técnicas de detecção de quedas são as falsas detecções e a não detecção de uma queda. A não detecção de queda, como pode ser constatada em abordagens como a feita em [4], é um problema de certa

forma trivial de ser evitado. O falso alarme de quedas é uma preocupação que exige um tratamento mais aprimorado. As abordagens que utilizam faixas de valores não são eficazes para corrigir esse problema, os movimentos como saltos podem ser confundidos com uma queda. Uma solução que pode complementar é a identificação da postura do paciente. Nesta solução é feita uma avaliação do ângulo do eixo vertical do acelerômetro. Esse sensor previamente fixado na cintura do corpo do paciente, auxilia uma abordagem baseada nos picos positivos e negativos de aceleração [4]. Isso não é o suficiente para evitar a detecção falsa de quedas.

Quando um dispositivo móvel acessível é utilizado como ferramenta, os problemas podem aumentar. No caso do celular há problemas devido ao escopo de movimentação mais amplo, quando comparados com sensores fixos ao corpo. Esse aumento no escopo aumenta o desafio para a identificação de atividades, mas em troca há o fator de acessibilidade, um requisito importante para aplicações voltadas para idosos.

Neste projeto, o celular foi definido como dispositivo móvel, portanto é preciso definir sua localização ideal no corpo do paciente. Quando se trata de captação de movimentos, há vantagens e desvantagens no uso do acelerômetro. Dentre as vantagens, está a captação de grande parte dos movimentos do corpo, e dentre as desvantagens está a não captação eficiente de movimentos dos membros superiores. O foco nessa seção é a detecção de quedas, e os movimentos dos membros superiores não são vistos como tendo valor significativo para essa avaliação. Apesar de ainda ser necessário refletir sobre as considerações de uso do dispositivo móvel é possível estabelecer uma solução viável quando o sensor está devidamente posicionado.

Na seção 2.2, uma comparação entre as abordagens [15][17] ilustra a necessidade do estabelecimento de critério de utilização. Em [12], uma proposta de detecção de contexto ajuda a inferir se um celular está no bolso. Essa informação torna-se indispensável para definir a adesão do paciente ao uso do celular como um detector de queda. Ainda é fornecida a possibilidade de um sistema de telemonitoramento informar ao paciente da necessidade de posicionar devidamente o aparelho. Esta notificação é útil para celulares, pois é um aparelho que não tem lugar fixo de utilização como o relógio tem. Esse notificador torna possível o usufruto de funções de detecção de quedas. A abordagem em [17], em conjunto com o estudo feito em [12], são suficientes aos anseios do telemonitoramento voltado à saúde. Dentre esses dois estudos, [17] foi utilizado como a base principal de nossa metodologia de detecção de quedas.

Um modelo de detecção de quedas deve considerar o contexto atual de uso, como

é considerado em [12]. Este estudo de contexto, que utiliza o microfone do celular como sensor, se apresenta em estágio inicial. No melhor caso, foi atingida uma precisão de 84% para detecção do celular no bolso e 83% para detecção dele fora do bolso. Esse é um dos motivos pelo qual não se abordou concretamente essa detecção de contexto. No entanto, nossa metodologia proposta para detecção de quedas levará em conta o fato do celular estar devidamente posicionado. O fluxograma apresentado na Figura 3.2 ilustra uma descrição mais detalhada do componente de detecção de quedas apresentado na Figura 3.1.

Na Figura 3.2 é apresentado o interior do componente de detecção de queda. O sinal é considerado como pré-processado, tal como indicado pela Figura 3.1, com o identificador de contexto inferindo o posicionamento correto do sensor. Nessa parte do fluxo de informação, como não se aborda uma proposta concreta para inferência de contexto, considera-se que o dispositivo móvel está devidamente posicionado. Com essa consideração, o processo continua e os sinais do acelerômetro são gravados em uma seção de tempo. O tamanho desta seção segue as recomendações feitas em [17], com a justificativa de que uma queda tem uma duração entre 0,4 e 0,8 segundos. Foi definida uma seção de 1,5 segundos. Esse tempo permite captar os sinais antes, durante e após a queda. Primeiramente, desta seção de tempo é feito o cálculo da variância da aceleração transversal (Δa_{xz}^σ) e da variância da aceleração no eixo vertical y (Δa_y^σ). A aceleração transversal (a_{xz}) é relativa a soma vetorial dos eixos x e z de aceleração. Além de Δa_{xz}^σ e Δa_y^σ , é obtido como saída da seção de tempo a lista das acelerações resultantes (a_{res}) captadas. A a_{res} é dada pela soma vetorial das acelerações relativas a cada um dos três eixos.

Após obter todos os dados relativos a uma seção de tempo é preciso destacar o que desenvolvemos e o que muda na metodologia em relação à abordagem feita em [17]. Essa mudança ocorre na avaliação da ocorrência de mudanças agudas nos sinais de aceleração. Enquanto em [17] é feita analogia com um padrão específico de queda (que no caso descrito foi considerada uma queda de impacto brusco no chão), neste projeto, busca-se uma solução que atenda uma diversidade maior de quedas. Para isso definiu-se um algoritmo classificador para identificar se há mudanças agudas na respectiva seção.

Em [17], os testes realizados para a identificação de uma seção de mudança aguda dos sinais foram feitos a partir da comparação de valores limiares, que identificava um padrão de queda com forte impacto reverso. Em nossa proposta um algoritmo de classificação apropriado para essa resolução específica geraria uma árvore de decisão. Uma árvore gerada a partir da conjunção entre as comparações de dois atributos, Δa_{xz}^σ ou Δa_y^σ , com seus respectivos limiares. O algoritmo C4.5, citado em [11], atende a essa necessidade.

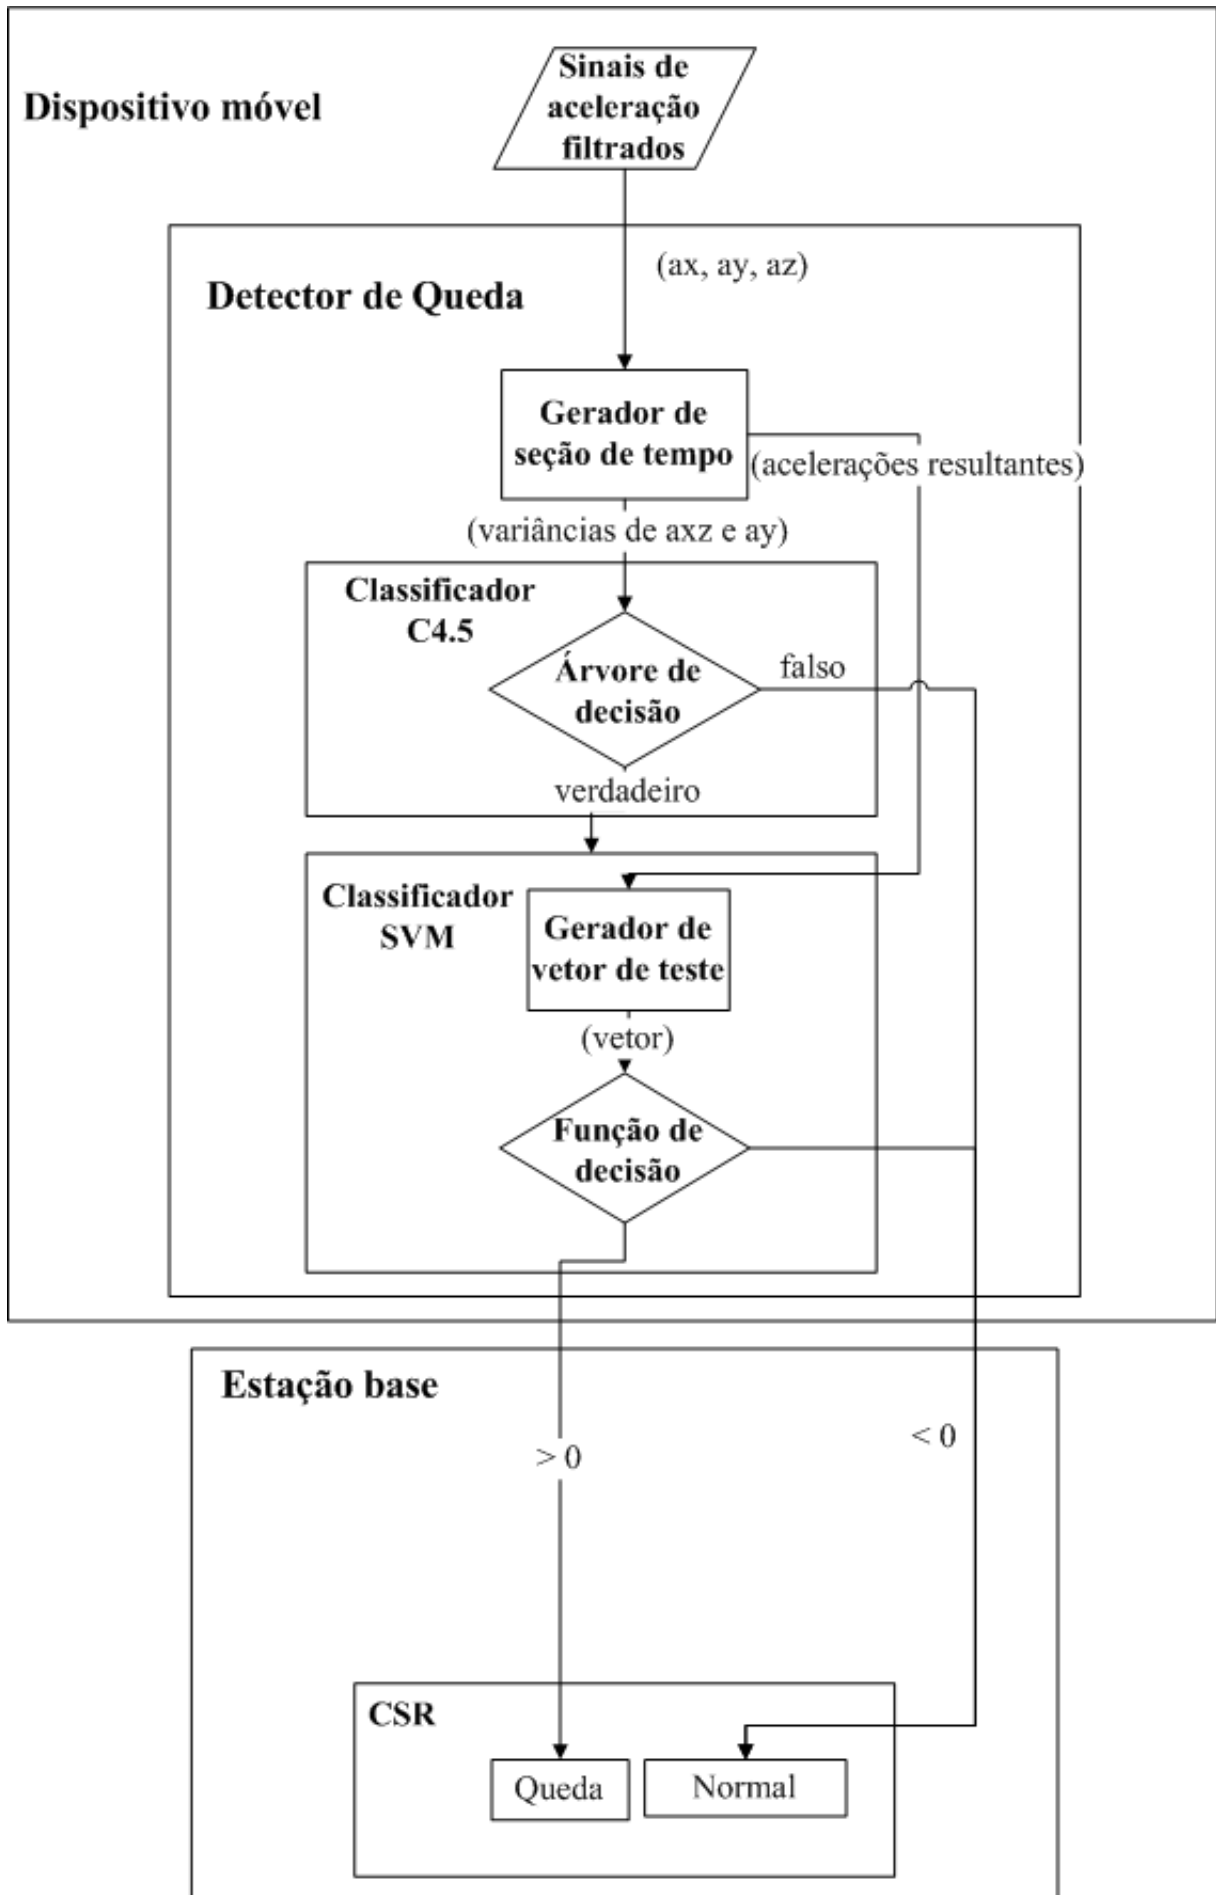


Figura 3.2: Detector de quedas

No capítulo 6, que trata sobre os resultados, os parâmetros utilizados nesse algoritmo têm seus valores especificados.

A árvore é gerada pelo algoritmo de classificação C4.5 com base nos dados de treinamento, utilizando como atributos as variâncias Δa_{xz}^σ e Δa_y^σ . Após gerada essa árvore, um teste é feito para verificar se uma seção tem mudanças agudas. Se essa mudança aguda não ocorre, o componente de detecção atribui valor falso de queda a essa seção. Caso ocorra, a seção é avaliada por uma máquina de vetor de suporte (SVM), que segue a ideia expressa em [17] ao incluir como escolha, a função de base radial como função *kernel*. Contudo, o método de otimização que aplicamos difere por utilizar a técnica de otimização mínima sequencial (SMO).

Seguindo no fluxograma é verificado que dentro do componente, denominado de classificador SVM, existe o processo de geração do vetor de entrada. Para gerar esse vetor, a seção é dividida em duas subseções contendo as acelerações resultantes (a_{res}). A primeira é relativa ao instante anterior ao impacto reverso, e a segunda aos sinais captados durante o impacto reverso. O vetor tem seis elementos: o intervalo de tempo da primeira subseção (Δt_1), a média de aceleração da primeira subseção (Δa_1), a variância de aceleração da primeira subseção (Δa_1^σ), o intervalo de tempo da segunda subseção (Δt_2), a média de aceleração da segunda subseção (Δa_2) e a variância de aceleração da segunda subseção (Δa_2^σ). O vetor correspondente a uma seção de tempo é utilizado como parâmetro da função de decisão. Essa função de decisão foi gerada pelo algoritmo de treinamento do classificador SVM. Caso o resultado retornado por essa função seja positivo então, a detecção retorna verdade para queda, caso contrário é retornado falso para queda. Esse fluxo é repetido em uma frequência aproximada de 20 Hz. Essa frequência é mais detalhada no capítulo 4, onde há considerações de implementação.

Há dois subcomponentes da detecção de quedas que precisam ser previamente definidos. São respectivamente, a árvore e a função de decisão. Esses componentes são gerados a partir de dados de treinamento. Os atributos desse conjunto de dados são os mesmos utilizados como entrada desses modelos de decisão. A Figura 3.3 ilustra o esquema de geração de uma árvore de decisão. Enquanto que, a Figura 3.4 ilustra o esquema de geração de uma função de decisão. Este esquema utiliza a árvore de decisão previamente definida pelo esquema da Figura 3.3.

Para definir a árvore de decisão, a situação inicial de captação e pré-processamento é utilizada de forma semelhante ao que é feito no esquema de detecção de quedas. Isso pode ser notado comparando o início do fluxograma da Figura 3.3 com o início do fluxograma

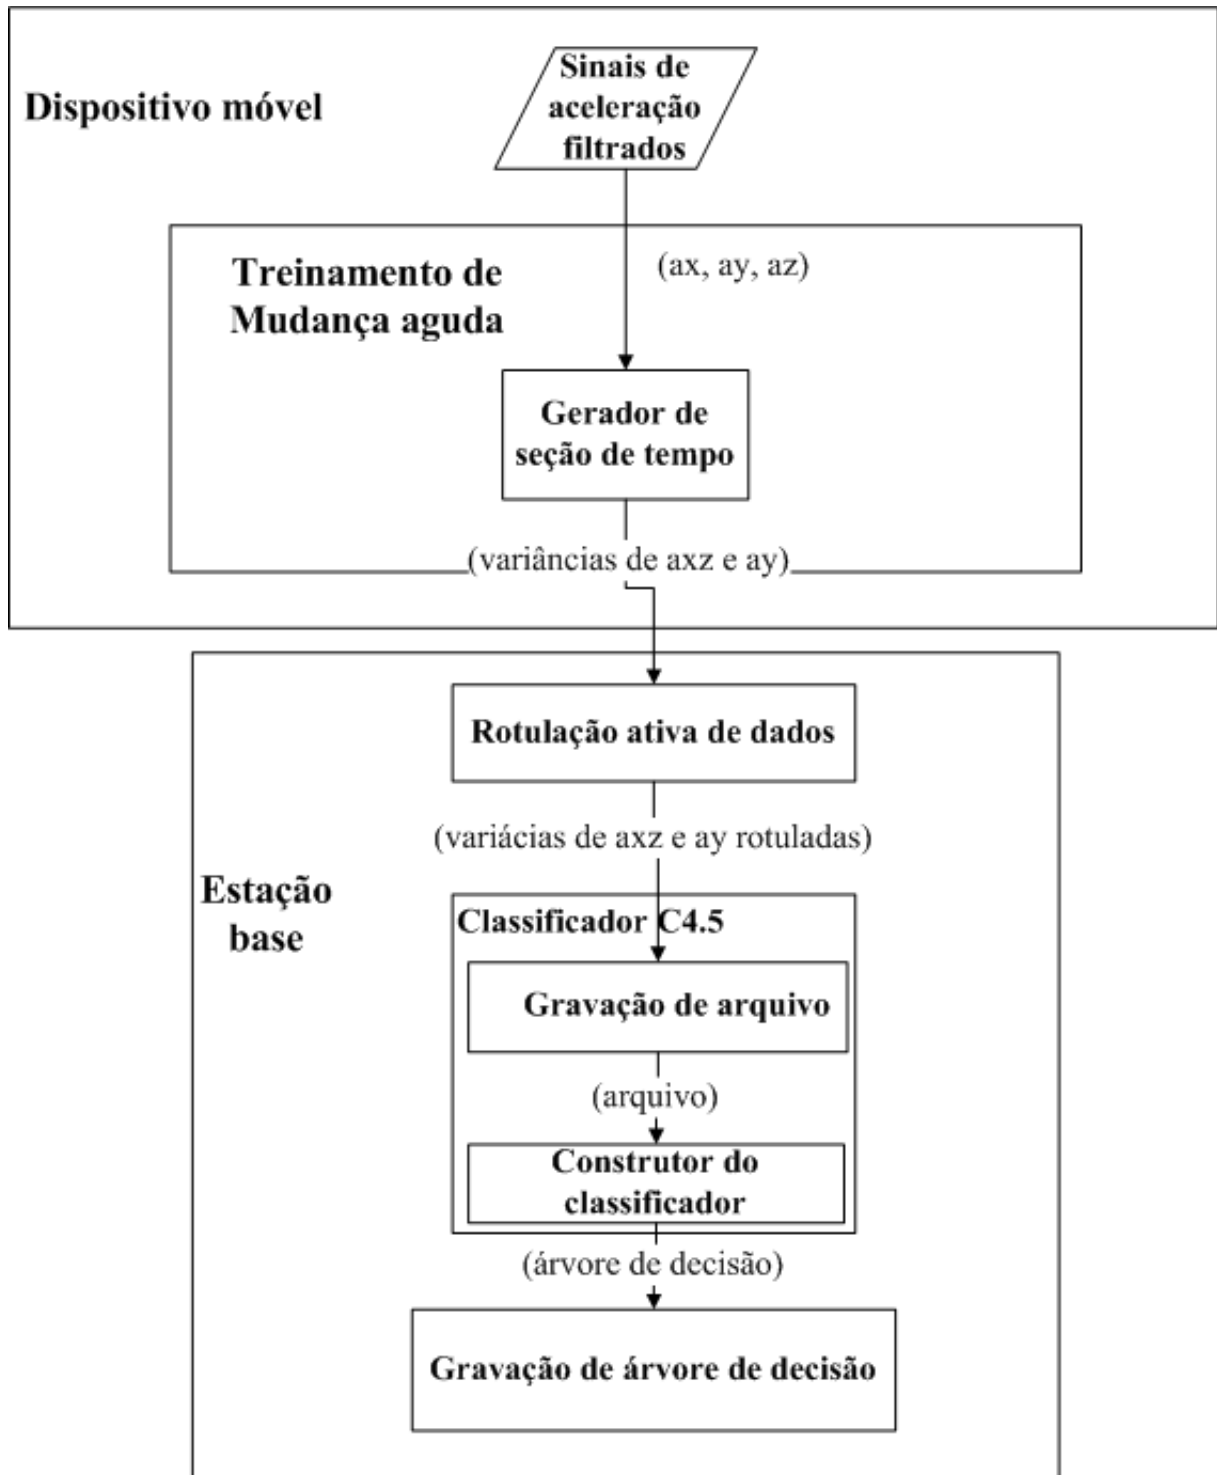


Figura 3.3: Treinamento do classificador C4.5

da Figura 3.2. A diferença começa quando se há a necessidade de uma árvore de decisão, que ainda não é definida quando aplicado esse treinamento. Por isso as variâncias Δa_{xz}^σ e Δa_y^σ são enviados diretamente para um outro sistema, denominado estação base. Esse sistema atua como ambiente de observação, que permite a interação com o usuário, assim é possível rotular ativamente o par de variâncias em relação à situação de queda. Essa rotulação é expressa no componente de rotulação ativa de dados, que gera como saída a avaliação verdadeira ou falsa para a ocorrência de queda. Junto com esse rótulo são gravadas em um arquivo, o par de variâncias, Δa_{xz}^σ e Δa_y^σ correspondente. No final do treinamento, o arquivo é submetido ao algoritmo de classificação C4.5. A partir disso uma representação da árvore de decisão gerada é gravada em um arquivo. Essa árvore gerada é utilizada no processo de treinamento do classificador que utiliza SVM. Além disso é utilizada no detector como elemento de definição mudanças agudas na seção de tempo.

A Figura 3.4 ilustra a definição de como é gerada uma função de decisão. Nesta figura é observada que da seção de tempo são extraídas as variâncias, Δa_{xz}^σ e Δa_y^σ , e as acelerações resultantes. As variâncias são testadas na árvore de decisão predefinida, o resultado desse teste é utilizado na rotulação dos dados correspondentes a seção. Esse rótulo é definido como 1 para resultado verdadeiro e -1 para resultado falso. Um vetor com as mesmas características do utilizado no algoritmo detector é gerado. Esse vetor é gravado em um arquivo com a associação do respectivo rótulo. Quando encerrado o treinamento, o arquivo é submetido ao algoritmo de SVM para geração da função de decisão. A função gerada é gravada para ser utilizada pelo detector de quedas.

A definição do ciclo de abordagens para a detecção de queda está separada em três etapas: treinamento do classificador C4.5, treinamento do classificador SVM, e a detecção de quedas. A primeira etapa define as decisões para as possíveis quedas, a segunda etapa define as decisões para confirmar as possíveis quedas e a terceira interpreta os sinais do utilizador em tempo real utilizando os dois modelos de decisão. No capítulo 5, uma definição de como se procede no treinamento de dados é detalhado.

É importante fazer algumas observações em relação à abordagem proposta nesta seção. Primeiramente, o algoritmo C4.5 é abordado mais detalhadamente no capítulo 4. A justificativa está na utilização de uma implementação de código aberto Java denominada J48. Esta implementação faz parte da biblioteca de mineração de dados *Weka* [8]. Além disso, há o algoritmo classificador SVM que utiliza uma implementação de código aberto Java denominada SMO. Essa implementação também faz parte da biblioteca de mineração de dados *Weka*. A otimização mínima sequencial (SMO) é um conceito utilizado para

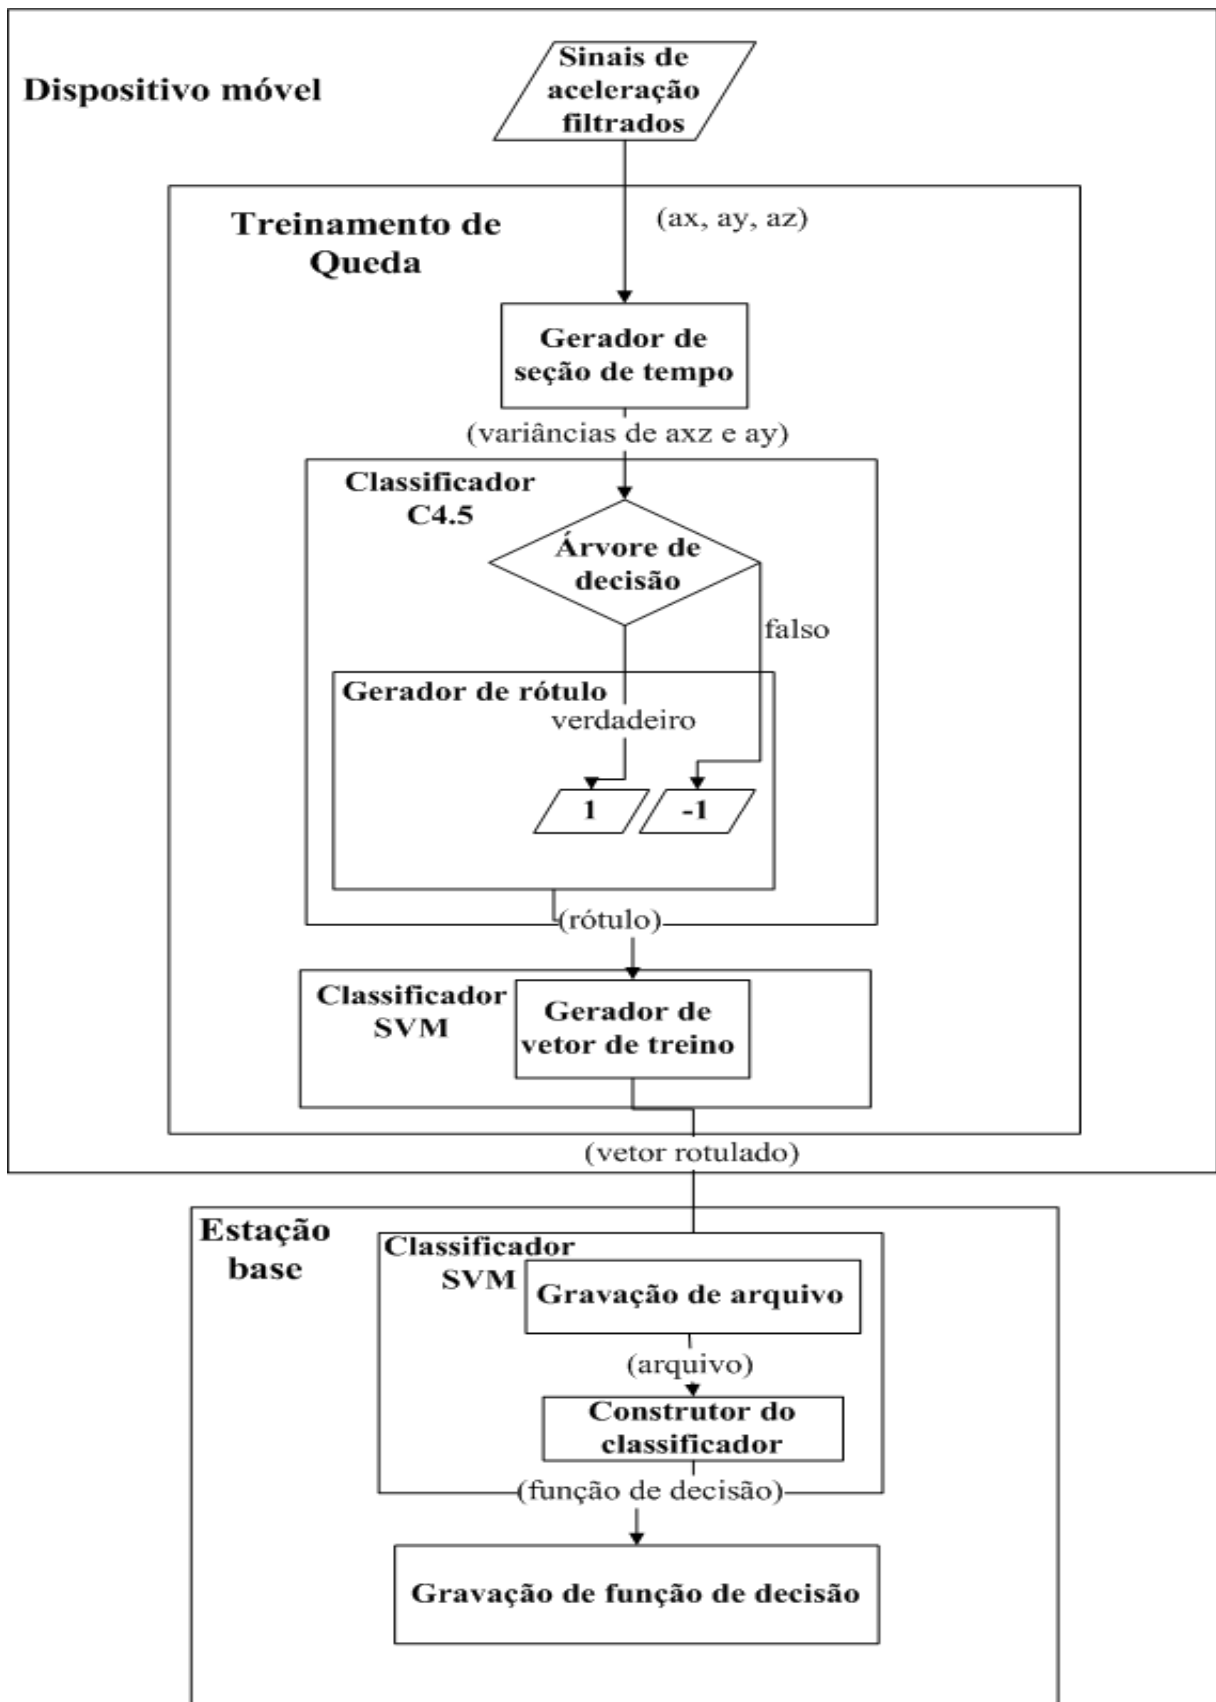


Figura 3.4: Treinamento do classificador SVM

treinamento rápido de SVM. Esse conceito de otimização permite gerar uma função de decisão com redução de complexidade. Os parâmetros utilizados para executar o algoritmo de SMO tem seus valores especificados no capítulo 6, onde os resultados associados a esses valores são apresentados.

A metodologia proposta nesta seção terá sua concretização devidamente descrita na seção 4.3, onde uma implementação do detector de quedas é abordada. Além dessa implementação ser um passo do desenvolvimento, é também um caminho a se percorrer antes da realização de testes. Os testes podem definir se esta metodologia atende um fator de confiança considerável. Ainda assim é possível ter uma margem deste fator, utilizando-se dos resultados obtidos em técnicas relacionadas. Ao concluir os testes, uma comparação com essas técnicas é realizada no capítulo 6, onde estão contidos os resultados.

Uma parte da abordagem do módulo RA é concretizada com a implementação e teste do detector de quedas. Ainda existe uma parte deste módulo que se utiliza dos mesmos sinais de aceleração para gerar uma informação relativa a atividade. Na próxima seção, essa parte fica esclarecida com a descrição da proposta para inferência do nível de atividade física, que na discussão anterior realizada na seção 2.3, é considerada um importante dado para inferência da situação clínica do paciente.

3.2 Inferência do nível de atividade física

O nível de atividade física é um parâmetro que pode estar associado a diversos tipos de medidas. Essas medidas podem ser o somatório das movimentações captadas em um período de tempo. Essa abordagem é citada como de gasto metabólico de energia em [9]. Outra forma está na associação da identificação de atividades de alto nível, ou associar medidas clínicas mais complexas sobre a fisiologia do paciente. Por se tratar de um dado importante na configuração da situação do indivíduo, essas possíveis associações devem ser confiáveis.

O gasto calórico pode ser associado a um nível de atividade e há sensores capazes de medir esse gasto. A maioria desses sensores são acompanhados de um relógio, que vão além de um meio de acompanhar a medida captada pelo sensor. Esses sensores também realizam comunicação sem fio (*wireless*) com um outro computador, que pode armazenar as informações captadas. Esse sensor é, geralmente, uma cinta torácica que capta o ritmo cardíaco. Ainda há relógios capazes de atuar como sensores, alguns possuem acelerômetro. A vantagem de seu uso está na vida útil da bateria, que dura em média um ano.

Ao analisar o escopo de atividades comuns ao meio residencial, as atividades domésticas, que incluem lavar roupa e louças, varrer a casa, cozinhar, organizar a casa, entre outras, são atividades que exigem demasiado esforço físico dentro desse ambiente. Isso é fator importante por determinar um desgaste físico. Ao colocar como foco a detecção de intensidade de movimentação nesse tipo de atividade, pode ser estabelecido um modelo de inferência do nivelamento. Com essa finalidade, o sensor de aceleração deve estar localizado em local que represente a intensidade das tarefas domésticas. O uso do relógio com acelerômetro embutido é visto como ideal, essa ferramenta atende a exigência comum de movimentação braçal. Essa movimentação aparece nos exemplos de tarefas anteriormente citadas.

Apesar da predominância de atividades domésticas no cotidiano, ainda devem ser considerados os exercícios físicos, que são tarefas frequentemente indicadas por profissionais da saúde para pessoas sedentárias. Há a necessidade de mais um sensor além do localizado no braço para indicar o nível de esforço de um paciente. Ao utilizar o mesmo dispositivo móvel que detecta quedas, pode-se complementar a inferência de atividade física. Isso é conveniente devido à localização desse dispositivo. Atividades, como o *spinning*, podem ter sua real intensidade inferida pela captação de movimentos da cintura. Nesse caso, também podem ser utilizados os mesmos sinais usados para detectar quedas.

Para ajudar a compor esse identificador é utilizada a ideia proposta para o cálculo de gasto de energia metabólica em [9]. É proposto nessa ideia a de captação as somas das integrais em relação ao tempo das acelerações de cada eixo, e divisão pela faixa de tempo correspondente ao período estipulado. Uma adaptação dessa ideia é necessária substituindo a continuidade da integral pelo cálculo numérico de somatório, e dividindo esse somatório pelo número de amostras captados em um período de tempo estipulado. Dessa forma é obtida a média da aceleração resultante. Um porém dessa média é o fato de que pode mascarar a real intensidade realizada em um período. A variância pode ser um dado mais representativo que a média, visto que em muitas atividades domésticas há uma característica oscilatória de movimentação braçal. Sendo a variância a nossa escolha como parâmetro da solução de inferência que este projeto visa propor.

A partir da variância da aceleração resultante (Δa_{res}^σ) relacionada a uma seção de tempo, separa-se as intensidades em três níveis: pouca, moderada e intensa. Essa separação responde às necessidades de integração com o SCIADS. Para classificar essas intensidades deve ser definido um interpretador que associa uma intensidade respectiva a uma Δa_{res}^σ calculada. Esse interpretador tem dois limites: um define o limite entre a

pouca intensidade e a moderada, o outro define o limite entre a moderada e a intensa. Para defini-los, uma técnica de aprendizado de máquina pode ser utilizada. A definição de uma árvore de decisão pode ser aplicada ao interpretador, logo o algoritmo C4.5 pode ser utilizado para definir os limitadores de níveis. A árvore gerada deve ser idealmente podada para que não haja limitadores redundantes.

Para treinar os dados, devem ser utilizados um sensor no braço e outro na cintura, cada sensor é responsável por gerar um arquivo com a tupla $(\Delta a_{res}^{\sigma}, \text{intensidade})$, onde a intensidade é definida explicitamente pelo usuário, isso corresponde a técnica de aprendizado ativo citada em [10]. Com isso, são gerados os arquivos que são submetidos ao algoritmo C4.5 de treinamento. São obtidos então uma árvore de decisão para o sensor do braço e uma outra para o sensor da cintura. A Figura 3.5 ilustra o algoritmo resumido do interpretador. Nele é utilizada uma ideia da árvore de decisão idealmente podada para definição de nível de atividade física. O fluxo apresentado é repetido a uma frequência aproximada de 20 Hz. Esse valor é explicado no capítulo 4, onde há considerações de implementação.

Esse interpretador é uma versão aprimorada da utilizada na versão do protótipo do SCIADS apresentado em [2], e que foi utilizada como parâmetro de atividade no módulo de raciocínio [5]. Há ainda que ser considerado o fato de que a informação sobre o nível de atividade responde a uma situação momentânea, que corresponde a uma seção de tempo de 1,5 segundos. Ao considerarmos o exemplo em que o ritmo cardíaco fica acelerado devido à intensa movimentação, foi percebido que após o término dessa atividade é observada uma redução lenta e gradual no ritmo, demorando questão de minutos até haver uma adequação à situação de repouso do indivíduo. Um aumento na seção de tempo avaliada retardaria essa momentaneidade. Se for utilizada uma seção de tempo muito grande para avaliação, podem ser ignorados os esforços físicos de curta duração. Uma ponderação mais elaborada sobre essa questão é apresentada no capítulo 6, onde se trata dos resultados obtidos nos testes realizados e que foram descritos no capítulo 5.

As questões de implementação servem para esclarecer alguns pontos das abordagens descritas neste capítulo. Vimos a necessidade da utilização de ferramentas que complementem soluções propostas aqui. No próximo capítulo, a seção 4.1 de ferramentas de desenvolvimento expõe as escolhas de ferramentas que cumprem os requisitos ainda não resolvidos. Além disso, o capítulo 4, como um todo, traz descrições mais detalhadas de implementações. Este capítulo ajuda a concluir que a metodologia apresentada busca atingir objetivos bem definidos, como confiabilidade e acessibilidade. E não deixa de res-

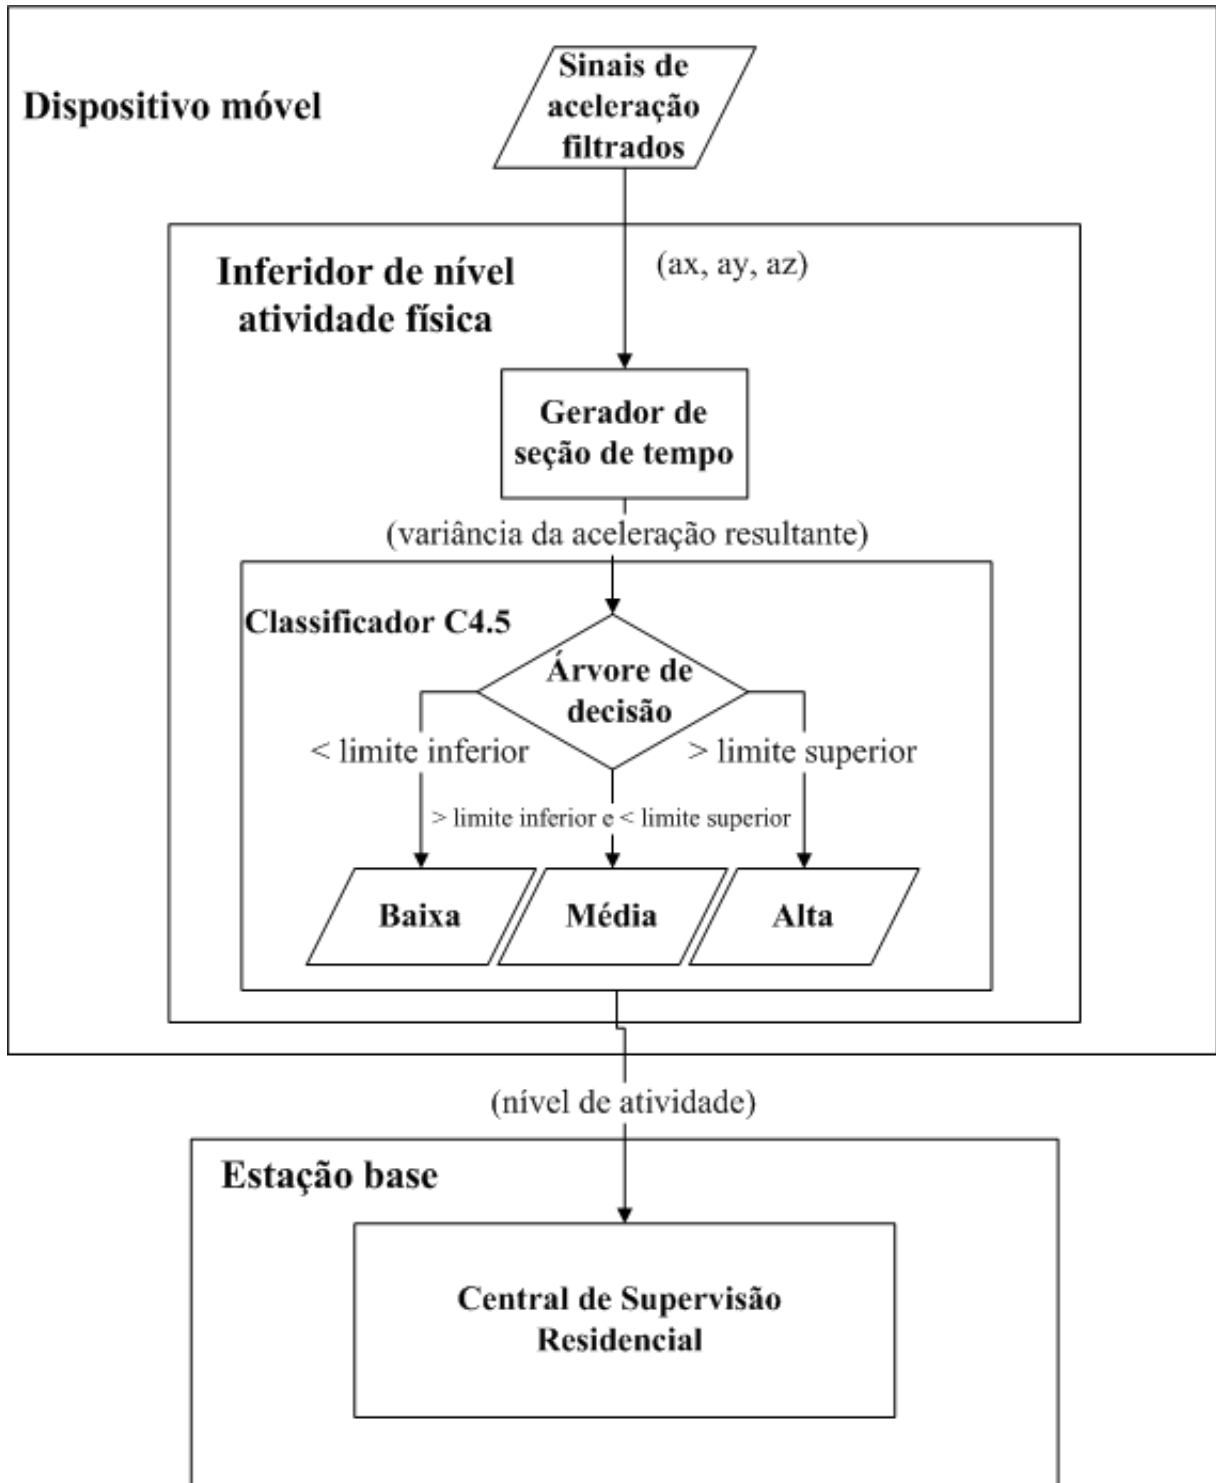


Figura 3.5: Inferidor AF

saltar a importância de outras questões como disponibilidade e comunicação. As questões de implantabilidade citadas no início deste capítulo são abordados mais precisamente no capítulo 5.

3.3 Conclusão do capítulo

Este capítulo teve como objetivo estabelecer a nossa proposta de trabalho. Isso inclui a apresentação de um módulo de reconhecimento de atividade conceitual, onde são inseridos componentes específicos que contribuem para efetivação desse módulo. Dois submódulos foram mais especificamente tratados neste capítulo. Com o módulo de detecção de quedas foi introduzido a ideia de aprendizagem de máquina. Foram utilizadas as técnicas como SVM e C4.5 para classificação de instâncias. Parte dessa ideia foi utilizada na abordagem do identificador do nível de atividade física. Para este componente, o algoritmo classificador C4.5 é utilizado como método de definição de limiares das faixas de intensidade. O que é destacado nessa abordagem é o uso de um sensor a mais do que é utilizado no detector de quedas. Esse sensor é um relógio que tem sua descrição detalhada na seção 4.1.3. No próximo capítulo, capítulo 4, são apresentados as implementações do detector de queda e o inferior de nível de atividade física.

Como contribuição, este capítulo fornece um direcionamento de uma proposta adequada a integração com o SCIADS. Também direciona esse trabalho para o desenvolvimento das abordagens a serem implementadas. Além disso, foi possível identificar questões deixadas em aberto, como a definição da frequência de envio dos sinais e a especificação dos parâmetros dos algoritmos classificadores.

Com as observações sobre as abordagens apresentadas aqui, o seu caráter experimental é percebido. As técnicas estatísticas descritas neste capítulo necessitam de informações experimentais. Informações que agregam valores efetivos a previsores de situações de alto nível. Esse fator experimental pode ser diretamente associado a fases de treinamento, onde há a exigência de uma grande massa de dados para se definir a lógica do classificador associado. A especificação desses treinamentos é realizada no capítulo 5.

Capítulo 4

Desenvolvimento de um Módulo de Reconhecimento de Atividades

No capítulo anterior foram estabelecidas abordagens que visam preencher o arcabouço de reconhecimento de atividade. Neste capítulo será explorada a sua implementação e implantação. Ao estabelecer o contexto que a implementação deve se integrar temos o SCIADS como referência. Em [2], esse sistema é visto como um sistema protótipo composto de uma central de supervisão médica (CSM) e uma central de supervisão residencial (CSR). No ambiente residencial, a CSR recebe medidas como peso, pressão e atividade vindos de dispositivos móveis. Essas informações são repassadas para a CSM através da internet. Nesse processo, utilizam-se dispositivos de medidas que têm comunicação sem fio através da rede local com a CSR.

A implementação de soluções em dispositivos móveis que se comunicam com um outro computador, onde se localiza a CSR, pode gerar problemas. Alguns desses problemas são comuns em qualquer desenvolvimento envolvendo comunicação entre sistemas. Ainda há problemas que refletem na definição de estado do paciente monitorado. Uma questão específica importante é a definição de frequência de envio de dados, comum em processamento de sinais. Essa questão é tida como atrelada à implementação, devido à influência que a ferramenta utilizada tem nesse parâmetro. Além disso é válido ressaltar que nossa proposta foca na resolução do reconhecimento de atividades, sem explorar detalhes de tolerância a falhas para problemas na conexão. No entanto, a importância de tal configuração para efetivar sua implantação no telemonitoramento à saúde é indispensável.

Ainda há outras considerações para implantação, uma delas é a implementação dos componentes. Como visto no capítulo 3, que fala sobre metodologia, foram feitas algumas

considerações abstratas para que certas partes do módulo RA fossem elaborados. Um exemplo dessas considerações está no componente de inferência de contexto, presente no fluxograma da Figura 3.1 que representa a sequência de processamento do módulo RA. Este componente, assim como a parte de sensores de ambiente e sensores no objeto, não é abordado neste capítulo, uma vez que não foram efetivamente implementados.

Este capítulo abordará a implementação dos componentes já descritos no capítulo anterior, mais especificamente os componentes de detecção de queda e o identificador de nível de atividade física. Para efetivação de cada um foi necessário implementar um módulo de treinamento associado. Para detecção de queda, esse módulo divide-se em dois componentes, o de treinamento para detecção de possível queda e o de treinamento para confirmação da queda. Para inferência AF, o módulo de treinamento associado define os níveis relativos aos sinais de aceleração captados. Essa organização é parte do processo de obtenção dos dois componentes importantes do módulo RA implementados.

Para esclarecer as questões de implementação, esse capítulo foi separado nas seções de ferramentas de desenvolvimento, detecção de queda e identificação do nível de atividade física. A primeira seção explora as questões de escolha de ferramentas e descreve cada uma delas. A segunda seção descreve a implementação do detector de quedas, desde o módulo de treinamento até o interpretador em si. A terceira seção faz o mesmo processo para o identificador de nível de atividade física.

4.1 Ferramentas de Desenvolvimento

Em [2] é abordado a importância do uso de dispositivos de medida sem fio. Esses dispositivos permitem a comunicação em uma rede local sem fio. Esse tipo de ferramenta torna o tratamento mais cômodo ao paciente. Isso ocorre devido à mobilidade permitida por um aparelho sem fio. Consequentemente é uma forma de aumentar sua adesão ao tratamento e aprimorar o reconhecimento não intrusivo de atividade de um indivíduo, o que torna a mobilidade um requisito indispensável.

Também em [2], o Sun SPOT foi apresentado como ferramenta voltada para o reconhecimento de atividade. Essa ferramenta contém um acelerômetro, sensores de temperatura-ambiente e de luminosidade. Esse equipamento programável em Java possibilita uma programação ágil e organizada com suas funcionalidades muito bem documentadas. Quando propomos o uso de um dispositivo sensorial vestível, a expectativa é era do uso de algo pequeno. O Sun SPOT cabe na palma da mão, mas comparado a um

relógio, por exemplo, sua vestibilidade é bem menor. Além disso sua familiaridade menor de utilização pelo usuário, se comparado a um celular, é um fator prejudicial a adesão ao tratamento. O uso de ferramentas mais comuns ao cotidiano de uma pessoa define bem a adequação exigida em nosso projeto.

Na identificação do nível de atividade física, como definido no capítulo 3, utiliza-se sensores de movimento no braço e na cintura. No braço, foi visto como adequado o uso de um relógio, e na cintura há o uso de um celular, ambos com um acelerômetro embutido. A escolha atende a uma utilização comum desses aparelhos nos respectivos locais do corpo. Com o objetivo de obter uma maior adesão, uma margem maior de utilização do sensor em local correto é desejado. O relógio de pulso e o celular permite atingir essa margem. No caso do celular, ao ser encontrado no bolso de uma calça com maior facilidade atende o requisito de localização estipulado na seção 3.1 e citado na seção 3.2.

Em uma pesquisa de mercado, foram realizadas as escolhas de dois produtos de interesse. O celular com o sistema Android embutido foi escolhido por fornecer um SDK (sigla em inglês para Kit de Desenvolvimento de Software) que permite seu desenvolvimento. Este SDK tem boa documentação dos recursos e é integrável aos ambientes de desenvolvimentos mais utilizados. Com relação ao relógio, foi escolhido o *eZ430-Chronos* que possibilita o desenvolvimento ágil. Isso é possível dado a grande parte das implementações de comunicação estarem estabelecidas.

As próximas seções contém a descrição de cada ferramenta utilizada. A seção 4.1.1 apresenta a biblioteca de aprendizagem de máquina *Weka*. Na seção 4.1.2 é apresentado o sistema *Android* e o celular no qual está embutido esse sistema. A seção 4.1.3 descreve as características do *eZ430-Chronos Development Tool*.

4.1.1 Weka

A necessidade de se utilizar algoritmos de aprendizagem de máquina para resolução de problemas de detecção de atividade foi vista no capítulo 3. Em [11], há o teste de vários algoritmos desse tipo. Nesse artigo, o software de mineração de dados *Weka* (encontrado no site: <http://www.cs.waikato.ac.nz/ml/weka/>) foi utilizado para implementar esses vários algoritmos. Em relação ao seu funcionamento é preciso primeiramente gerar um arquivo de dados que esteja devidamente formatado. No início do arquivo é preciso estabelecer os atributos e as classes relacionadas aos dados coletados. O arquivo gerado deve estar na formatação ARFF (do inglês, *Attribute-Relation File Format*), formato que

é aceito pela aplicação. Dado esse arquivo é preciso escolher um algoritmo de classificação e definir seus respectivos parâmetros. Depois disso o software é executado gerando os resultados.

Essa ferramenta foi utilizada por facilitar o uso das técnicas de aprendizagem, o que não exige conhecimento específico dos detalhes do processo. Facilita também no processo de aprendizagem semisupervisionada descrita em [10], por trazer métodos que possibilitam traduzir as abstrações feitas nesse artigo de forma ágil. Apesar da não exigência de conhecimento específico é importante que cada técnica utilizada tenha sua função conhecida. Além disso é preciso entender os efeitos das atribuições feitas a cada parâmetro da técnica escolhida. Um exemplo disso é a escolha da função *kernel* utilizada na técnica de SVM. Essa escolha influi diretamente na classificação de amostras.

O *Weka* é um software de código aberto Java, o que torna possível a aplicação dessa ferramenta diretamente no desenvolvimento de nossa proposta. Uma aplicação utilizando essa ferramenta pode importar diretamente da API (sigla em inglês para Interface de Programação de Aplicações) de *Weka* a funcionalidade desejada. Para classificar um conjunto de dados basta invocar um método de construção de classificador para esse conjunto. Com essa construção, basta um método para classificar uma nova instancia de dados. É possível, inclusive, configurar os parâmetros do classificador.

No desenvolvimento do módulo RA, importante considerar as vantagens e desvantagens do uso de *Weka*. Suas principais vantagens estão em modularizar o aspecto de classificação agregado a esse módulo e em possibilitar o teste de diferentes classificadores. Os testes permitem a conclusão sobre a técnica mais eficaz para determinado problema. Quanto as suas desvantagens, há a sua estruturação inflexível de dados, principalmente quando se deixa apenas que arquivos sejam utilizados para atribuir o conjunto de dados de treinamento. Isso leva a um carregamento de dados de treinamento mais lento. Em um processo mais dinâmico, como o semisupervisionado, essa lentidão aumenta em relação ao carregamento desses dados diretamente da memória. Esse efeito retardante ainda é mínimo diante dos benefícios citados nesta seção.

4.1.2 Android

O *Android* é um sistema operacional aplicado a acessórios móveis como celulares e *tablets*. O controle dos dispositivos desses acessórios é permitido através de programação Java, onde há a utilização de bibliotecas apropriadas desenvolvidas pela *Google*. Seu

SDK pode ser encontrado no site dedicado para desenvolvimento (encontrado no site <http://developer.android.com/sdk/index.html>). O SDK pode ser integrado com uma IDE de java. Isso permite o desenvolvimento de aplicativos de forma organizada e torna simples a geração de arquivo a ser importado a um celular.

Como visto nos capítulos anteriores, o celular com acelerômetro é apontado como uma ferramenta de grande utilidade para captar sinais de atividade de uma pessoa. Diferentemente de sensores mais especializados, como o Sun SPOT, o celular permite trabalhar com interfaces gráficas mais elaboradas. Suas saídas são mais acessíveis aos usuários mais leigos. Essa interface também beneficia o desenvolvimento, dada a facilidade do gerenciamento dos arquivos de dados a serem utilizados. Por exemplo, os dados que correspondem a uma função de decisão contidos em um arquivo, que é usado no detector de quedas proposto no capítulo 3, podem ser carregados e visualizados no celular.

Neste trabalho foi utilizado o celular *Samsung Galaxy 5* com a versão 2.1 do Android embutida. Ao especificar melhor o equipamento, as principais configurações que podem ser conferidas são as seguintes: acelerômetro de três eixos, bateria de 1200 mAh, GPS, Wi-Fi, câmera de 2 Mpix e tela sensível ao toque. Dessas configurações, Wi-Fi, acelerômetro e bateria devem ser avaliadas devido à importância na implementação. O acelerômetro é requisito indispensável para detecção de movimentos. A disposição de Wi-Fi é necessária para comunicação sem fio com a CSR do SCIADS. E a bateria deve ser avaliada quanto à sua durabilidade. A conexão por Wi-Fi não é indispensável, pois existem outros meios de comunicação sem fio, como *ZigBee* citado em [2], um protocolo que proporciona um gasto menor de energia em comunicação. Apesar disso a conexão Wi-Fi tem maior disponibilidade e aceitação no mercado. O problema no uso do Wi-Fi no celular *Samsung Galaxy 5* é o seu alto gasto de energia, reduzindo o tempo de duração da carga da bateria. Portanto, esse fator afeta diretamente as questões de disponibilidade de um sensor de atividade, onde a necessidade de recarregamento da bateria é frequente.

As implementações detalhadas nessa seção e que necessitam dessa ferramenta utilizam comunicação por Wi-Fi. É importante configurar o celular para não desativar a conexão Wi-Fi enquanto uma aplicação do módulo RA é executada. Foi desativado então o modo de economia da bateria presente na configuração padrão do *Android*. Ainda é preciso configurar a permissão para efetuar a comunicação sem fio. Essa configuração é realizada através de codificação das configurações de cada aplicativo, onde a edição de seus respectivos arquivos de configuração denominados de *AndroidManifest.xml* devem especificar isso. Com o celular devidamente configurado, foi preciso definir o posiciona-

mento adequado do celular em relação ao corpo de uma pessoa. Considerando as análises de posicionamento feitas nas seções 3.1 e 3.2, definiu-se a cintura como a região adequada. Ainda é preciso considerar um modo de fixação do aparelho celular na cintura do indivíduo. Mediante a necessidade de um aspecto o menos intrusivo possível, a utilização de vestimentas comuns a cada pessoa é suficiente. Desde que uma roupa como calça, ou bermuda, tenham um bolso justo ao tamanho do celular. Isso é necessário para não permitir que sua posição mude no interior do bolso. Desse modo, o celular deve estar na posição vertical, com a parte superior do celular acima da parte inferior.

Apesar da vantagem da acessibilidade, o uso de celular implica em uma série de complicações em relação ao tratamento necessário. Tanto que no capítulo 3, foi considerado a verificação de contexto no fluxograma do módulo RA, onde é verificado se o celular está corretamente posicionado no bolso. No caso do relógio esse tratamento não é tão crítico assim devido ao padrão de uso desse equipamento ser bem resolvido. O pulso é o único lugar visto pelos usuários desses relógios como o correto.

4.1.3 Kit de desenvolvimento do eZ430-Chronos

Em complemento ao celular, outro produto necessário é um relógio. Esse relógio é utilizado como um dos sensores de nível de atividade física. Sua função é captar os movimentos dos membros superiores, que foram analisados na seção 3.2 como movimentos predominantes em atividades domésticas. Um relógio que atende essa necessidade de sensoriamento é o *eZ430-Chronos*, um relógio com comunicação sem fio que permite programação de alto nível através de um ambiente de desenvolvimento personalizado. Essa ambiente de desenvolvimento é um dos componentes do kit de desenvolvimento denominado *Code Composer Studio*. Esse ambiente utiliza a linguagem C++.

A necessidade de uso desse kit responde a exigência de um sensor vestível. O Sun SPOT, por exemplo, necessita de um aparato auxiliar para fixação no corpo, e seu uso no braço pode causar desconforto devido ao seu tamanho desproporcional. Ao desenvolver aplicativos para o *eZ430-Chronos* foi verificado um nível de dificuldade semelhante ao encontrado no desenvolvimento voltado para Sun SPOT. Isso significa que desenvolvedores com experiência com Sun SPOT podem ter certa facilidade em desenvolver aplicações para o *eZ430-Chronos*.

Para uso efetivo da ferramenta nessa implementação é preciso estabelecer uma localização do relógio no corpo do paciente. Duas possibilidades são evidentes, ou se coloca

no braço direito, ou no braço esquerdo. Para pessoas destras é comum observar que seu braço direito é o mais utilizado, por isso este seria o local ideal. Para pessoas canhotas, o braço esquerdo é adequado para monitoração. Com isso estabelecido é necessário que uma aplicação receba os sinais captados pelo sensor do relógio. Nesse caso, uma aplicação implementada C++ no Code Composer Studio recebe essa informação, e retransmite localmente para uma aplicação de telemonitoramento, como a CSR do SCIADS. É possível verificar que o uso de outras linguagens, como *Python*, permitem a implementação do aplicativo com esse papel de retransmissor. Isso é possível porque basta capturar os sinais de aceleração através de porta serial correspondente ao ponto de acesso.

Apesar da vantagem de ter um sensor como acessório de comum utilização como o relógio, é importante considerar questões complicadoras de desenvolvimento. Diferente de um celular, o relógio não permite visualizar diretamente os arquivos presentes. Outro fator é o uso predominante de linguagem C++, diferente da linguagem Java utilizada no celular. Apesar disso, os benefícios que esse kit traz na implementação desta proposta compensam o esforço gasto para contornar essas questões. O ponto de acesso específico é uma das vantagens de seu uso. Diferentemente do celular é possibilitada a transmissão dos dados captados pelo relógio, sem a necessidade de especificar um endereço de destino, basta plugar o ponto de acesso onde é desejado conectar e instalar o kit de ferramentas de desenvolvimento nessa máquina.

Com as ferramentas bem estabelecidas é preciso descrever a implementação realizada. O *Weka* apresentado na seção 4.1.1 é utilizado para geração de classificadores. O celular com *Android* apresentado na seção 4.1.2 é utilizado na detecção de queda e também como informação complementar de nível de atividade física. E o kit de desenvolvimento *eZ430-Chronos* é utilizado para implementar o receptor de movimento do braço, informação complementar para inferir o nível de atividade física.

4.2 Detecção de quedas

A ocorrência de queda é de alto risco para a saúde de idosos. Sua detecção pode auxiliar que um atendimento emergencial ocorra da forma mais rápida possível. Há inúmeras propostas para a detecção de quedas, a maioria delas detecta facilmente a ocorrência de queda, e assim, não permite que uma ocorrência passe despercebida. O maior problema é a detecção de queda quando não há ocorrência real, na qual denomina-se de falsa queda.

Estabelecer um filtro que possibilite a diminuição da ocorrência de falsos alarmes é



Figura 4.1: Arquitetura utilizada para detecção de queda

um desafio para estudos de detecção de quedas. A redução de escopo do contexto é uma das formas de filtrar as possibilidades de ocorrência desse problema. Ao estabelecer condições para o uso de determinada aplicação de detecção é possível obter essa redução de escopo. Na aplicação proposta neste trabalho também foram estabelecidas condições. Inicialmente é preciso avaliar o ambiente em que é aplicada a detecção, depois a área para a qual está voltada a detecção. Estabelecido o ambiente residencial e determinando a aplicação na área da saúde é possível identificar as necessidades específicas de nossa proposta.

O primeiro passo para concretizar a implementação do nosso detector de quedas foi estabelecer uma arquitetura. Esta arquitetura deixa a organização dos componentes de implementação visível. Para detectar a queda é necessária a interação entre dois sistemas diferentes, um contido no celular e outro contido na estação base. A estação base corresponde à CSR do SCIADS. A visualização dessa interação pode ser conferida na Figura 4.1.

A Figura 4.1 apresenta uma visão arquitetural mais geral da interação entre um dispositivo móvel e uma estação base. O dispositivo móvel, no caso de detecção de queda, é o celular. E a estação base, pode ser qualquer sistema receptor dessas informações, bem como a CSR do SCIADS. Observe que a interação de informação ocorre em sentido unidirecional, partindo do dispositivo móvel para a estação base. Essa definição ocorre pois as aplicações desenvolvidas para o dispositivo móvel não necessitam de informação de seu destinatário para serem executadas. A definição dessa informação pode ser identificada de acordo com os fluxogramas definidos no capítulo 3. Nessa seção, as informações tratadas nos fluxogramas da seção 3.1 detalham esse fluxo. Quando se trata da fase de interpretação, essa informação é a representação de um valor booleano para detecção de

queda. Quando se trata da fase de treinamento do classificador C4.5, essa informação é correspondente a uma tupla de variâncias de componentes de aceleração. Quando se trata da fase de treinamento do classificador SVM, essa informação é relativa a um vetor rotulado.

Com relação aos classificadores citados é necessário fazer uso da biblioteca de mineração de dados *Weka*. Essa biblioteca possui as implementações dos classificadores apresentados no capítulo 3 de metodologia proposta. Com essa ferramenta é possível estabelecer a classificação confiável dos sinais de entrada. A classificação resulta em atividades como saída, que é a informação desejada pela aplicação de saúde localizada na estação base.

Com relação a essa arquitetura apresentada na Figura 4.1, verificou-se a necessidade de se estabelecer aplicações voltadas para dispositivos móveis e os seus correspondentes em uma estação base. Para o detector de queda, o dispositivo móvel é especificamente um celular com Android como o especificado na seção 4.1.2. Com as três fases relativas a esse detector, duas de treinamento e uma de interpretação, cada fase possui duas aplicações associadas: uma é executada no dispositivo móvel e outra é executada na estação base.

Na fase de treinamento do classificador C4.5, a sua implementação ocorre por meio de um algoritmo denominado J48 pertencente a biblioteca de *Weka*. A Figura 3.3 ilustra fluxograma correspondente. Da parte inserida no quadro de dispositivo móvel gerou-se uma aplicação equivalente, denominada *FallTraining*. E da parte da estação base obteve-se a aplicação denominada *TrainingServer*.

Com o arquivo contendo a representação da árvore de decisão, gerada pela implementação J48, é possível prosseguir para a próxima fase. Essa fase corresponde ao treinamento do classificador SVM. Esse classificador tem a abordagem representada na Figura 3.4. Um aplicativo voltado para o dispositivo móvel que é denominado *FallSV-Training*, e um aplicativo para ser executado na estação base que é denominado *SVTrainingServer*.

Utilizando a implementação SMO para gerar o arquivo contendo a representação da função de decisão é possível executar a fase de interpretação. Essa é fase final do detector de quedas, que tem ilustrada na Figura 3.2 a respectiva abordagem. O aplicativo contido no dispositivo móvel é denominado *FallDetection* e o correspondente na estação de base é denominado *HostFallDetector*. A Figura 4.2 representa o diagrama de classe relacionado com o módulo de detecção de queda presente na aplicação *FallDetection*.

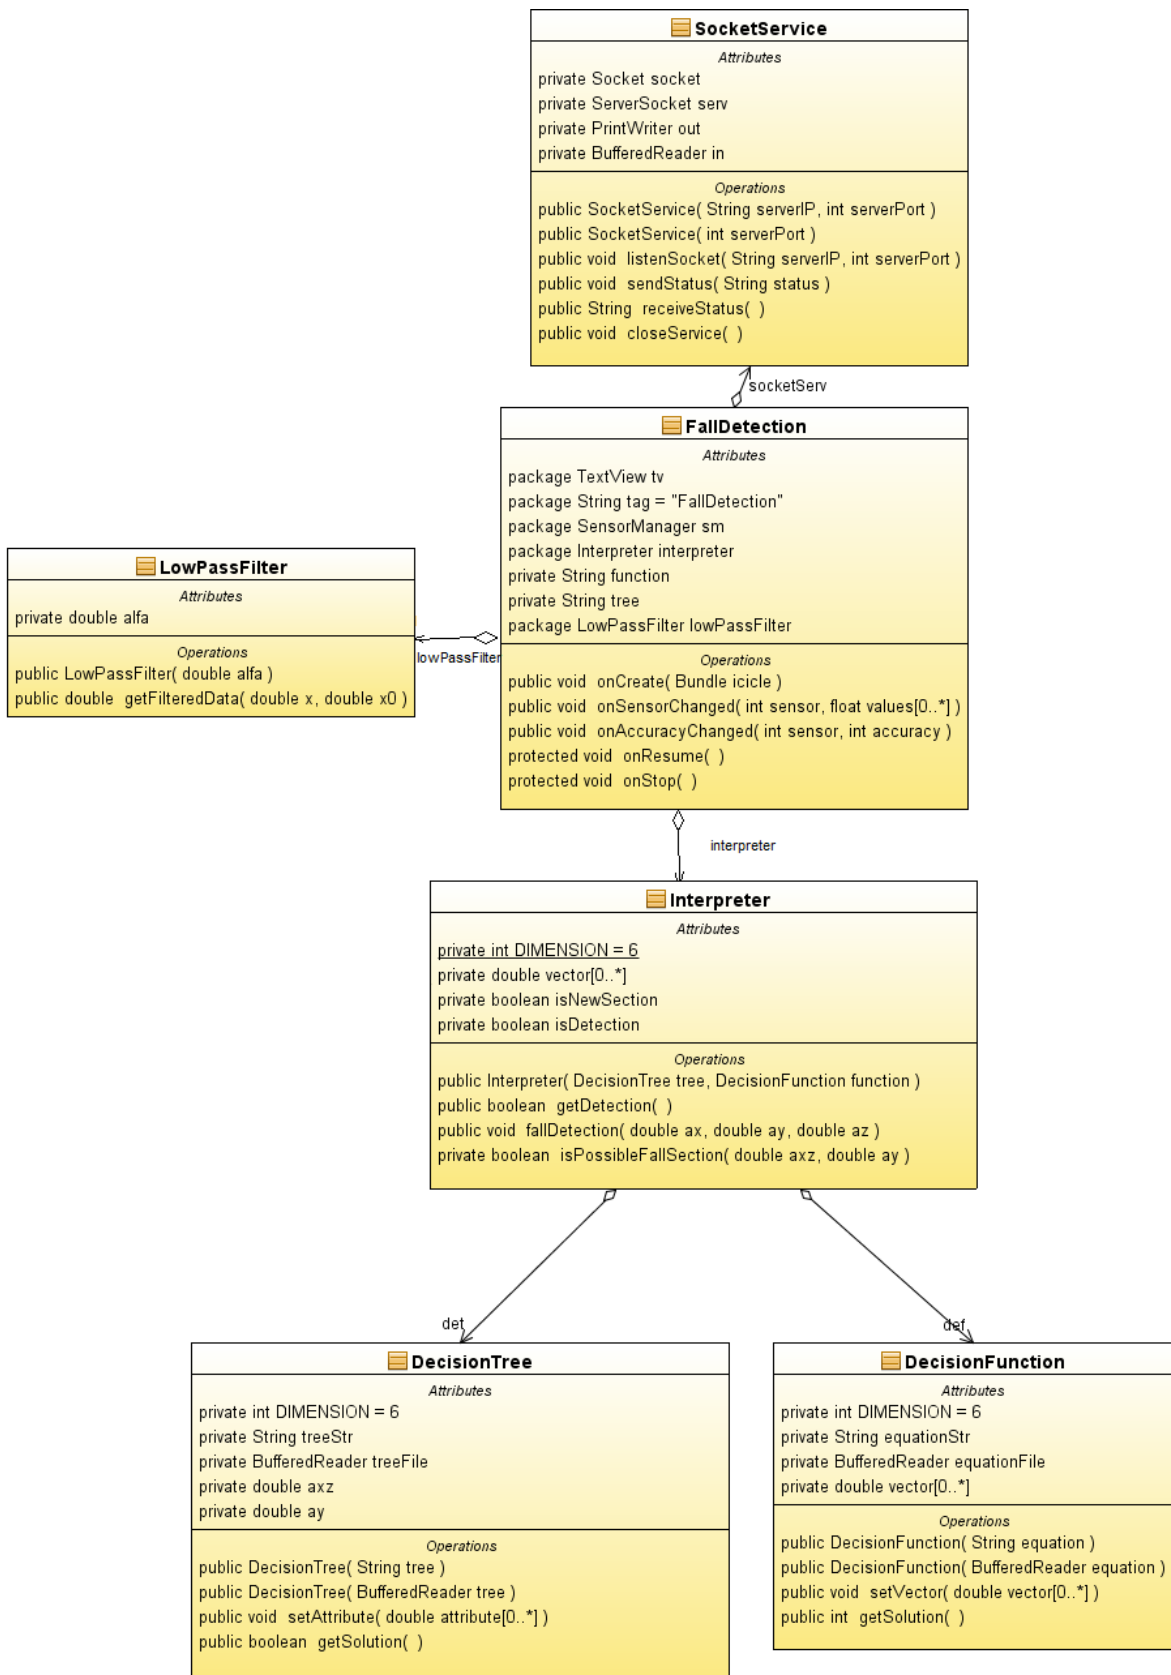


Figura 4.2: Diagrama de classe do módulo de detecção de queda

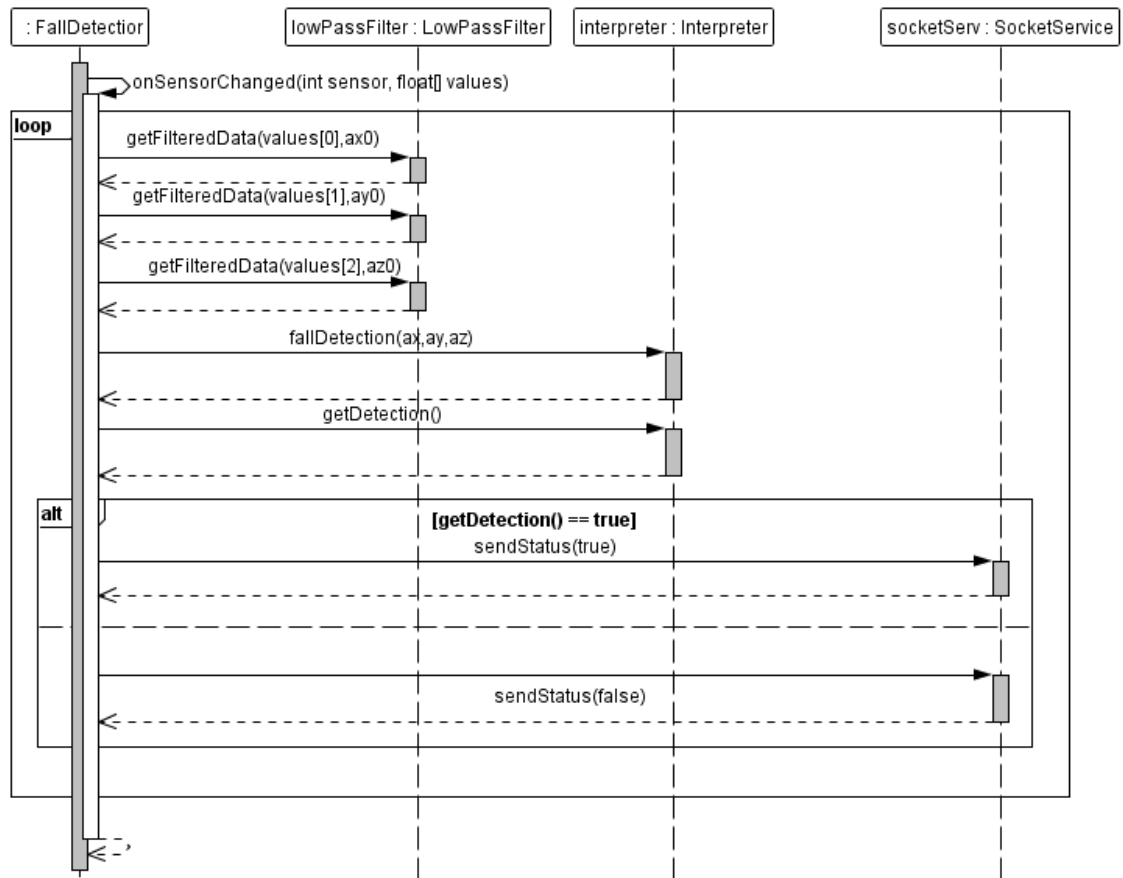


Figura 4.3: Diagrama da sequência principal do módulo de detecção de queda

Nesse diagrama é possível identificar que o interpretador é utilizado pela classe principal *FallDetection*. Esse interpretador por sua vez necessita da árvore de decisão e da função de decisão para o correto funcionamento. A classe principal necessita também do serviço de socket utilizado para implementar a comunicação Wi-Fi e do filtro passa-baixo.

Para visualizar a implementação do detector de quedas de forma dinâmica, comparando com o fluxograma apresentado na Figura 3.2, um diagrama de sequência foi elaborado e ilustrado na Figura 4.3. O diagrama de sequência possibilita comparar se a implementação traduz a ideia de detecção de queda proposta na seção 3.1.

O diagrama de sequência da Figura 4.3 apresenta o fluxo principal de execução do aplicativo *FallDetection*. O método principal é o *onSensorChanged*, um método ativado sempre que uma mudança nas medidas obtidas pelo sensor é detectada; a caixa de repetição ilustra essa ocorrência. Para cada repetição é aplicado o filtro nas acelerações dos três eixos. As acelerações já filtradas são aplicadas ao método *fallDetection*. Este método

verifica se houve queda e assinala verdadeiro ou falso à variável *isDetection* do objeto *interpreter*, esse objeto pode ser observado como pertencente à classe *Interpreter*. Essa classe é descrita no diagrama de classe da Figura 4.2. O método *getDetection* retorna o valor de *isDetection* e envia a informação de falso para queda caso retorne falso, e de confirmação de queda caso retorne verdadeiro. Esse envio é tratado pelo objeto da classe *SocketService*, que tem o endereço da estação base.

Ao se avaliar a implementação proposta é preciso fazer algumas observações mais detalhadas sobre o processo de desenvolvimento. A geração de dois arquivos importantes ao final de cada fase de treinamento foi observada. O arquivo que contém a árvore de decisão deve ser transferido para o celular, e ser colocado na mesma pasta contendo o arquivo *FallSVTraining.apk* que é relativo ao aplicativo *FallSVTraining*. O aplicativo *FallSVTraining* faz a leitura desse arquivo para utilizar a árvore de decisão gerada na fase anterior. O mesmo processo de transferência ocorre para o arquivo contendo a função de decisão. Nesse caso, este arquivo deve ser colocado na mesma pasta contendo o arquivo *FallDetection.apk* que é relativo ao aplicativo *FallDetection*. O aplicativo *FallDetection* faz a leitura do arquivo para utilizar a função de decisão, que foi gerada na fase anterior. Esse processo é realizado apenas uma vez e não precisa ser executado pelo usuário final.

Com relação à implementação do filtro passa-baixo é importante definir a frequência de corte. Essa frequência define o fator constante de tempo RC usado para se obter a constante α . Esta constante é um parâmetro que influencia diretamente na eliminação de ruídos dos sinais. Para defini-la é preciso estabelecer a frequência em que os sinais de aceleração são captados. Foi observada uma frequência aproximada de 20 Hz na captação desses sinais. Consequentemente, esse foi o valor da frequência de corte definida para o filtro passa-baixo. O fator RC calculado, a partir dessa frequência, resultou em aproximadamente 0,008 segundos. Ao considerar um dt , que é o intervalo de tempo entre uma medida atual e uma imediatamente anterior, é calculado α obtido pelo seguinte cálculo: $\alpha = \frac{dt}{dt+RC}$. Como são captadas 20 medidas por segundo, o valor de dt estabelecido é de 0,05 segundos. Como resultado do cálculo, α é obtido com valor aproximado de 0,862.

A seção 5.1 ilustra os critérios estabelecidos para testar a implementação deste componente. Ainda nesta seção são definidos parâmetros de treinamento correspondentes às duas fases. Tanto essas escolhas de parâmetros para classificadores quanto esses testes vão auxiliar na conclusão sobre as técnicas escolhidas.

4.3 Identificador do nível de intensidade da atividade física

A identificação do nível de atividade física (AF) é importante para definição da situação do paciente. A identificação pode ser usada de forma auxiliar, por um módulo de inferência baseado em regras [5], para definir essa situação. Isso torna possível evitar equívocos na análise clínica, bem como evitar a geração de falsos alarmes. Há diversas formas de se obter esse parâmetro de desgaste físico. Algumas delas abordam de forma indireta sua obtenção, a partir de outras informações de atividade. Diferentemente, nossa proposta é calcular um valor representativo de desgaste físico e associá-lo a um determinado nível.

O problema de relacionar um valor de movimentação diretamente com um nível está na sua representatividade. O ideal seria esse valor corresponder à sensação de desgaste do usuário. Por exemplo, seria ideal poder estabelecer a diferença entre a pressão estar alta porque houve um desgaste físico, e identificar que a pressão está alta sem desgaste físico. O último caso indicaria uma situação de risco. Ao lidar com a relação entre atividades de alto nível e desgaste físico, algumas propostas pretendem obter maior representatividade nessa informação. Atividades como dormir, comer, tomar banho, lavar louça, cozinhar, entre outras descrições mais gerais de atividade, tem uma duração mínima de tempo na ordem de minutos. Isso fornece uma qualidade de representatividade maior do que na solução que propomos.

Uma proposta para resolver essa questão, utilizando processamento direto dos sinais de aceleração, é definir um histórico de intensidades detectadas. Se considerar quantas vezes o nível mais alto de atividade esteve presente durante uma faixa de tempo, então um nível mais representativo pode ser obtido. Para implementar essa proposta, uma série de testes devem ser realizados para verificar o fator de confiança. Essa seção trata da implementação da abordagem proposta na seção 3.2, deixando definido um modo prático de verificar o desgaste físico momentâneo do paciente.

Com informações de movimentação do braço e da cintura é proposta uma arquitetura geral. Essa arquitetura, apresentada na Figura 4.4, demonstra a interação entre os componentes dessa solução. A diferença dessa arquitetura para a apresentada na Figura 4.1 está na divisão do componente de dispositivos móveis em superior e inferior. O dispositivo superior é referente aos sensores presentes na parte superior do corpo, e o inferior é referente aos sensores presentes na parte inferior. Isto é necessário para captar os diversos tipos de atividades físicas possíveis de serem realizadas. A estação base,




Figura 4.4: Arquitetura utilizada na inferência AF

pode ser qualquer sistema receptor dessas informações, como por exemplo a CSR do SCI-ADS. As informações, tanto as inferiores quanto as superiores, podem ser identificadas de acordo com o fluxograma da Figura 3.5 apresentada na seção 3.2. Essa informação é a representação de um nível de atividade física quando se trata da fase de interpretação expressa nessa figura. Quando se trata da fase de treinamento do classificador C4.5, essa informação representa uma tupla contendo a variância da aceleração resultante e sua rotulação.

A ferramenta utilizada na parte superior é o relógio *eZ430-Chronos*. Este relógio com função de sensor deve estar localizado no braço mais utilizado pelo paciente, posicionamento enfatizado na seção 3.2. Na parte inferior é utilizado o mesmo celular aplicado à detecção de quedas, inclusive explorando o mesmo posicionamento. Há duas fases nesse identificador, uma de treinamento e uma de interpretação, cada fase possui três aplicações associadas, uma é executada no dispositivo móvel inferior e as outras duas são executadas na estação base. Das aplicações da estação base, há uma utilizada para receber os dados brutos de aceleração do *eZ430-Chronos* e retransmitir o dado processado para a outra aplicação desta estação. A outra aplicação, além de receber o dado processado do

eZ430-Chronos, recebe os dados processados do sensor da parte inferior.

Na fase de treinamento é utilizado o classificador C4.5, implementado pelo algoritmo denominado J48 pertencente à biblioteca de *Weka*. A abordagem é semelhante à apresentada pelo fluxograma da Figura 3.3. Da parte inserida no quadro de dispositivo móvel inferior, foi gerada uma aplicação equivalente, denominada *PALevelTraining*. E da parte da estação base foi obtida a aplicação denominada *PALevelTrainingServer*, onde são gerados duas árvores de decisão, um para a parte superior e outro para a parte inferior. Na parte superior é utilizada a aplicação padrão do *eZ430-Chronos*, o *Sports Watch*, para o envio de sinais de aceleração. Uma aplicação na estação base denominada *PALevelAdapter* se responsabiliza por calcular a variância das acelerações resultantes (Δa_{res}^{σ}) e retransmiti-la para a *PALevelTrainingServer*. A *PALevelAdapter* foi implementada em *Python*.

As aplicações, contidas no dispositivo inferior, são implementadas em Java. Ainda na fase de interpretação, temos o *PALevelPredictor*, uma aplicação relativa a implementação do interpretador no dispositivo móvel inferior. Essa aplicação é executada após concretizada a fase de treinamento. A aplicação *PALevelServer*, também implementada na fase de interpretação, é um programa em java que corresponde ao receptor de dados processados na estação base. Essa aplicação recebe os sinais dos dois dispositivos. Porém para o dispositivo superior também é utilizada a *PALevelAdapter* para intermediar o envio da informação de aceleração do *eZ430-Chronos* para a *PALevelServer*. Na *PALevelServer* é feita a comparação entre as classificações resultantes, o maior nível detectado, dentre os dois sensores, é o escolhido como resposta do interpretador.

As mesmas considerações de transferência de arquivo com o resultado da árvore de decisão feitas na seção 4.2 são feitas entre a fase de treinamento e a fase de interpretação do módulo AF. Nesse caso, o aplicativo *PALevelServer* gera um arquivo contendo a árvore de decisão para parte superior e outra para a parte inferior. O arquivo da parte inferior é transferido para o celular, e o arquivo da parte superior é lido pela aplicação *PALevelAdapter*. O processo de geração de cada árvore é utilizado pelo interpretador, que tem a implementação seguindo a ilustração da Figura 3.5. Com relação à implementação do filtro passa-baixo, segue-se a definição realizada na seção 4.2.

Esta abordagem mostra eficácia para tradução da intensidade momentânea, mas ainda é importante avaliar as dificuldades de integração com o SCIADS. Essa avaliação será melhor mencionada na seção 5.1. Um resultado com testes, tanto dessa implementação quanto do detector de quedas será apresentado no capítulo 6. Uma conclusão sobre

confiabilidade poderá ser melhor formulada após esses resultados serem apresentados.

4.4 Conclusão do capítulo

Este capítulo apresentou quais os componentes do módulo RA implementados. Foram definidas as implementações do submódulo de detecção de quedas e do submódulo de inferência AF, partes críticas do módulo RA. O desenvolvimento desses componentes foi um passo adiante no desenvolvimento de um módulo cada vez mais robusto, apesar de estarem condicionados a outras partes não concretizadas neste projeto.

No desenvolvimento do detector de queda, esteve presente o uso da biblioteca de manipulação de sensores do *Android*. A biblioteca é uma adaptação da J2ME (do inglês, *Java Platform Micro Edition*), tecnologia Java que permite o desenvolvimento de aplicações para sistemas embarcados. Todas as aplicações citadas na seção 4.2 para resolução de percepção de queda, foram implementadas em Java. No desenvolvimento do inferidor AF, além de Java, foi utilizada a implementação padrão feita em CCS. CCS é um compilador de linguagem C voltado para aplicação em microcontroladores como o relógio *eZ430-Chronos* utilizado. Essa implementação padrão, denominada *Sports Watch* vem instalada no relógio. Foi visto que a *Sports Watch* provê uma série de informações, onde as requeridas por nosso desenvolvimento foram as acelerações. Quando o modo de aceleração é ativado, o *eZ430-Chronos* envia esses sinais para o ponto de acesso. O ponto de acesso está associado a uma porta serial, e uma aplicação como a *PALevelAdapter* escuta essa porta para poder captar os sinais de aceleração. É importante observar que não é feito tratamento de possíveis erros de comunicação, o que torna essa mais uma das condições a se considerar.

Este capítulo tem contribuição fundamental neste projeto porque são concretizadas algumas das abordagens feitas ao longo deste trabalho. Este capítulo também contribui para uma análise mais concreta das propostas feitas no capítulo 3. Com os módulos de detecção de quedas e inferência AF implementados é possível estabelecer testes e avaliar seus resultados.

Capítulo 5

Integração e Teste

Esse projeto de desenvolvimento de um módulo RA é proposto como um módulo focado em um sistema computacional pervasivo de assistência domiciliar a saúde, sendo o SCIADS [2][1] o projeto motivador. Este capítulo pretende avaliar a integração entre o módulo e esse sistema. Isso é feito avaliando a confiabilidade e a contribuição que essa integração proporciona. Ao estabelecer testes específicos para avaliação do módulo RA é possível avaliar a integração com o SCIADS.

O objetivo deste capítulo é definir os critérios dos testes a serem realizados. A partir desses testes pretendemos gerar resultados que indiquem o grau de confiabilidade associado ao módulo RA. Conseqüentemente, torna-se possível a reflexão sobre sua integração com um sistema como SCIADS. Esse processo é um fator motivador para que no futuro testes mais completos de integração possam ser realizados. Os testes aqui discutidos não são só uma forma de comparar essa proposta com as relacionadas, mas também servem como um próximo passo em direção a um teste com pacientes reais. Esse tipo de teste já vem ocorrendo com o protótipo do SCIADS, só que sem o módulo RA, por ainda não se ter resultados confiáveis relatados até o início desse processo.

Como apresentado no capítulo 4, foram desenvolvidos dois componentes de identificação de atividades: um detecta se há ocorrência de queda e outro associa um nível de atividade física a um paciente em dado momento. Na seção 5.1, há a definição dos testes realizados para treinamento e para a interpretação da detecção de quedas. A seção 5.2 apresenta os testes realizados para o treinamento e interpretação sobre o nível de atividade física do paciente.

5.1 Testes do detector de quedas

A maioria das propostas relacionadas à detecção de quedas apresentadas na seção 2.2 estabelece o escopo de atividades realizadas nos testes. Nos resultados dos testes é estabelecido um percentual de confiabilidade para a detecção de queda. Há a necessidade de estabelecer cuidadosamente esse escopo de atividades realizadas. Esse cuidado é necessário para que uma taxa de confiança não pareça superficial demais a uma situação real.

O objetivo dessa seção é estabelecer critérios nos testes de detecção de quedas a serem realizados. Estabelecer a organização das avaliações possibilita a obtenção de parâmetros bem definidos para a taxa de confiança. Com essa necessidade é preciso estabelecer o grupo de atividades presentes no cotidiano. Esse grupo deve ser representativo, de tal forma que possa proporcionar a comparação da ocorrência dessas atividades com a detecção de queda. A maior preocupação dessa comparação é verificar a ocorrência de falsa detecção de queda.

A detecção falsa de queda é um dos problemas mais comuns a serem resolvidos, e é apresentado como preocupação nos trabalhos relacionados da seção 2.2. Ao seguir a proposta de testes em [17], definimos uma categorização de atividades executadas para teste. As categorias são apresentadas e enumeradas desta forma: 1) atividades bruscas; as quais representam atividades de forte movimentação como saltos, atividades domésticas como lavar roupas e louças entre outras; 2) atividades leves, como andar, se levantar da cadeira, se levantar da cama, pegar objetos, entre outras. 3) repouso, representando o estado em que a pessoa não se desloca muito; 4) atividade de queda, representando a queda propriamente. Cada categoria terá um número de amostras respectivo, as quais serão capturadas em um módulo de teste que avalia a interpretação do detector de queda. A avaliação de cada categoria tem uma taxa que a caracteriza, denominada taxa de confiança. Essa taxa é obtida pela razão entre o número de inferências corretas e o número de amostras totais. Para as três primeiras categorias, são consideradas a não detecção de queda como inferência correta. Já para categoria 4, relativa à queda, a detecção de queda é avaliada como inferência correta.

No entanto, antes de realizar os testes de confiabilidade para o detector de quedas, é preciso descrever o processo de aquisição de dados para treinamento. No início, foi utilizado o conjunto de aplicações para treinamento do algoritmo C4.5 definidos na seção 4.2. Como visto nessa seção, a implementação J48 foi utilizada, para este teste deixou-se

a configuração de parâmetros padrão de *Weka*. A árvore gerada é definida como binária e o fator de confiança para sua poda tem valor de 0,25. Com isso estabelecido, um arquivo de dados das variâncias, Δa_{xz}^σ e Δa_y^σ , associadas a rotulação de verdadeiro ou falso foi gerado. Essa rotulação ocorre de forma ativa, sendo realizada por um indivíduo com função de observador. As quedas são feitas por uma pessoa capacitada para simular esses eventos, com a queda ocorrendo sobre um colchão macio. O arquivo gerado tem dados relativos a quatro tipos de quedas que são as para frente, para trás, para o lado esquerdo, e para o lado direito. Com isso, foi possível obter 168 amostras, com aproximadamente um terço correspondendo a queda. Esse arquivo foi dado como entrada ao classificador J48 do *Weka* gerando uma árvore de decisão. Apesar de utilizados dois parâmetros de variância, Δa_{xz}^σ e Δa_y^σ , apenas Δa_y^σ foi identificada como referência para indicação de queda. Como resultado foi obtido a comparação $\Delta a_y^\sigma \leq 13,45$ m/s resultando em falso para possível queda, e $\Delta a_y^\sigma > 13,45$ m/s resultando em verdadeiro.

Com a árvore de decisão definida, ainda é necessária a definição da função de decisão. Utilizando a árvore gerada para rotular os dados, o arquivo de vetores representativos das amostras de simulação de queda foi gerado. Essas amostras são obtidas em uma nova simulação, com os mesmos tipos de quedas sendo realizados. O arquivo contém 85 vetores rotulados como amostras, onde aproximadamente um quinto desses vetores são exemplos de quedas. Esses rótulos são 1 e -1, onde 1 é atribuído a vetor de queda e -1 a vetor de situação normal. O arquivo é dado como entrada no algoritmo de treinamento rápido de SVM usando otimização mínima sequencial, implementado pela classe SMO de *Weka*. A definição padrão para complexidade constante C, que tem valor 1, é utilizada. A função de base radial é definida como função *kernel*, e o valor de sua σ é definida por padrão como sendo de valor 0,01. Como saída, foi obtida a função de decisão com 40 vetores de suporte a serem utilizados.

Com a árvore e a função de decisão definidas, os testes de confiabilidade do detector de quedas podem ser realizados. No capítulo 6, sobre os resultados, há a seção 6.1, onde os resultados de confiabilidade obtidos para as quatro categorias de atividades aqui definidas são apresentados. A seção 5.2 descreve como foram realizados os testes para identificar os níveis de atividade física do paciente.

5.2 Testes do identificador do nível de atividade física (AF)

Para inferir o nível de atividade física de um indivíduo, os testes são vistos como fundamentais para estabelecer parâmetros confiáveis. A seção anterior descreve quatro categorias de atividades, e as três primeiras são as que mais interessam nos testes de avaliação do desgaste físico. Essas categorias podem ser utilizadas como classes no treinamento do inferidor AF. Isso porque cada categoria é facilmente associável a um nível de atividade estabelecido na seção 3.2. A categoria de atividades bruscas, 1, é associável às atividades físicas de alto nível, a de atividades leves é semelhante às atividades de nível de desgaste médio e a de repouso pode estar associada às atividades de nível baixo de desgaste.

O objetivo de especificação desses testes é prover uma associação entre atividades de alto nível e um nível de esforço físico. Com esses testes, são melhoradas as possibilidades de obter uma representação mais próxima da real sensação de cansaço físico do corpo. Para concretizar isso, o primeiro teste deve ser realizado para gerar a árvore de decisão e com isso possibilitar o teste de interpretação do inferidor AF. Conseqüentemente, uma taxa de confiança, para cada um dos três níveis, é estabelecida.

Há três seções definidas para treinamento: a primeira contém amostras de variâncias Δa_{res}^{σ} para atividades de nível alto, a segunda para atividades de nível mediano e a terceira para atividades de nível baixo. Essas amostras são devidamente rotuladas de acordo com o nível da seção e cada seção tem duração de dois minutos. São coletadas amostras da região da cintura e da região do braço. Essas seções têm suas amostras reunidas em um único arquivo, esse arquivo é utilizado no classificador C4.5, que é implementado através da classe J48 pertencente à biblioteca de *Weka*. A definição padrão dos parâmetros é utilizada, com o fator de confiança equivalente a 0,25 e a árvore definida como binária. Com uma árvore de decisão gerada para o sensor da cintura e outra para o sensor do braço, foram estabelecidos dois limiares para o nivelamento em cada árvore. Para a região da cintura ficou definido que a faixa de valores de Δa_{res}^{σ} incluindo 0,28 m/s e menores são rotuladas como de baixa atividade física. A faixa de valores acima de 0,28 m/s e menores ou igual a 2,16 m/s é rotulada como de nível médio de atividade física. Para representar atividades de nível alto de desgaste físico ficou estabelecido a faixa de valores de Δa_{res}^{σ} maiores que 2,16 m/s. A árvore gerada correspondendo ao braço teve como limiares, entre a faixa de nível baixo e médio, o valor de 0,70 m/s, e entre a faixa de nível médio e alto de atividade, o valor de 3,17 m/s. Foram utilizadas 219 amostras

de variâncias da região da cintura e 221 da região do braço.

A partir dessas árvores definidas, o interpretador pode ser testado. Na seção 6.2, uma abordagem mostrando a confiabilidade na inferência do nível da atividade é mostrada. Dessa forma será possível constatar a possibilidade de integração, ou a necessidade de aprimoramento da técnica.

5.3 Conclusão do capítulo

Esse capítulo apresentou a importância da integração com o SCIADS na realização de testes mais completos. Os testes específicos dos módulos de detecção de queda e inferência AF foram descritos com o intuito de avaliar a taxa de confiança para cada categoria de atividade predefinida.

Os procedimentos de teste apresentados para o detector de queda verificaram primeiramente a necessidade de especificar o modo de treinamento. Em relação ao resultado, como árvore de decisão relativa ao treinamento de mudanças agudas, foi observada uma estrutura básica de comparação. Essa estrutura apresentou apenas a componente y de aceleração no teste. Isso pode ter ocorrido devido à especificação dos tipos de quedas. Dentre os quatro tipos de quedas, para frente, para trás, para a direita e para a esquerda, é possível observar como característica comum a variação direcional do eixo vertical y e similar, um dos principais motivos para tal resultado. Em relação à confirmação da queda, foram gerados 40 vetores de suporte para definir a classificação. Isso demonstra que o hiperplano relacionado à classificação de queda está bem especificado. Para o interpretador do inferior AF, foi necessária a poda da árvore de decisão para evitar a fragmentação das faixas de valores Δa_{res}^{σ} . Sem a fragmentação, cada faixa pode ser diretamente associada com um nível.

Como contribuição a esse projeto, a especificação dos procedimentos de teste se mostrou uma parte essencial para posterior análise de seus resultados. E também possibilitou a geração dos interpretadores alvos de teste, que terão como resultados taxas de confianças a serem analisadas.

Capítulo 6

Resultados

Para verificar se um módulo RA é confiável é preciso analisar os resultados relacionados. A análise de resultados é um importante processo de desenvolvimento de soluções para o reconhecimento de atividade. Dependendo do que é obtido, um processo de aprimoramento, ou até mesmo uma mudança de abordagem é vista como necessária. Essas mudanças e aprimoramentos podem estar relacionadas com a escolha de ferramentas e das técnicas. É interessante ressaltar ainda a necessidade de se levar em conta outros requisitos, os quais poderiam ser considerados neste capítulo. Ainda que existam outros requisitos, nosso trabalho estabeleceu o foco na avaliação da taxa de confiabilidade.

Com esse foco é preciso avaliar essa taxa com relação às necessidades das informações estabelecidas. Uma referência é necessária para que seja possível uma melhor avaliação desta proposta. Essas referências são os resultados de outras abordagens, que são importantes para comparar com os resultados que obtivemos. Sobre essa comparação é preciso esclarecer os motivos para cada resultado. Ainda é preciso estabelecer critérios de testes que sejam compatíveis com os trabalhos relacionados. O capítulo 5, de integração e testes, estabeleceu isso e então tornou possível chegar a um conjunto de resultados que podem ser equiparados com o de outras propostas.

Foram realizadas as implementações de dois componentes do módulo RA: o detector de queda e o inferidor AF. Cada componente gerou testes que retornaram um percentual de confiabilidade a ser avaliado. A seção 6.1 apresenta esses resultados para o detector de quedas, e a seção 6.2 apresenta esses resultados para o identificador de nível de atividade física.

Tabela 6.1: Tabela de testes do detector de queda

Tipo de atividade	Total de amostras	Incorretas	Corretas	% de acerto aprox.
1	101	23	78	77
2	101	0	101	100
3	101	0	101	100
4	19	0	19	100
Total	322	23	299	Média: 93

6.1 Resultados do detector de quedas

Na seção 5.1, foram estabelecidas categorias de atividades. Essas categorias foram utilizadas para testar a confiabilidade do detector de quedas. Conseqüentemente, pôde ser verificada a ocorrência de falsos alarmes de quedas para atividades comuns. Os resultados apresentados aqui podem ajudar a aprimorar o método de detecção de queda, principalmente na questão da técnica abordada. A principal técnica utilizada, nesse detector de quedas, é o SVM. Existem algumas possibilidades de abordá-la, e os resultados apresentados aqui pode motivar mudanças nos seus parâmetros. Essas mudanças podem ocorrer na técnica de otimização utilizada, na escolha da função *kernel*, ou até mesmo na mudança do fator gama da função de base radial. Ainda há a possibilidade de mudar completamente de técnica, tendo em conta a amplitude de técnicas de aprendizagem de máquina que podem ser utilizadas.

Para uma melhor avaliação os resultados são apresentados na Tabela 6.1. A coluna de atividade corresponde aos tipos de atividades enumerados e descritos na seção 5.1. A coluna de amostras testadas é relativo ao número de amostradas utilizadas no teste de cada tipo de atividade. A coluna de amostras corretas, corresponde ao número de amostras que foram interpretadas corretamente pelo detector de quedas e a coluna de taxa de confiança é o percentual de amostras corretas em relação ao total de amostras.

Para o teste para atividades bruscas (1), foram captadas 101 amostras relacionadas. Ao testar essas amostras no interpretador do detector de quedas foi obtida uma taxa de erro de 23%. Isso significa que 23% das amostras de atividades bruscas foram identificadas equivocadamente como sendo quedas. Para os tipos de atividades 2 e 3 foi utilizado o mesmo número de amostras e não se obteve falsa detecção de queda. Para as atividades do tipo 4, relacionados a ocorrência de quedas, todas as 19 amostras foram rotuladas corretamente. No total, 322 amostras foram captadas, onde 93% se mostraram corretas.

A taxa de erro apresentada para as atividades de tipo 1 foi o fator mais preocupante do teste. Esse tipo de atividade tem uma categorização semelhante na parte de resultados de [17]. Um tipo de atividade, analisado em [17], que denomina atividades diárias de alta intensidade, como saltos, corridas e exercícios físicos, é semelhante à denominação de atividades do tipo 1. Em [17], esse tipo de atividade teve 10 amostras representativas, onde 20% se mostraram incorretas. Um resultado melhor foi apresentado, mas com o uso de um número significativamente menor de amostras. Um ponto forte em [17] foi a preocupação de capturar amostras de diferentes perfis corporais, utilizando informações de pessoas idosas e jovens. Nossa proposta de teste foi feita por apenas um perfil jovem, sendo uma questão que precisa de ajustes.

Como o público idoso tem foco maior nessa verificação é possível que se obtenha resultados mais efetivos caso esses testes sejam realizados com essa faixa etária mais avançada. Isso pode ocorrer devido às restrições físicas associadas a esse perfil. Para minimizar esses erros uma verificação extra após movimentos bruscos serem identificados, como por exemplo a verificação do posicionamento, podem ser efetivos.

6.2 Resultados do identificador do nível de atividade física

Como solução pertencente ao módulo RA, o inferidor AF foca mais na integração com um sistema computacional pervasivo de assistência domiciliar a saúde. As informações obtidas por esse identificador servem de complemento a uma análise composta de outras informações. Essa análise é processada no módulo de decisão proposto em [5], um componente pertencente ao SCIADS. Usando esse módulo é possível obter a situação do paciente em relação ao seu estado de saúde.

Os testes e seus parâmetros foram definidos na seção 5.2, utilizando a mesma categorização de atividades definida na seção 5.1, excluindo a categoria 4 relativa à queda. Uma tabela apresentando a taxa de confiança da inferência de nível é possível ser estabelecida. A Tabela 6.2 ilustra os tipos de atividades associados com o total de amostras testadas, as amostras inferidas corretamente e as taxas de acerto e de erro.

Ao utilizar simultaneamente dois sensores, um na cintura e outro no braço, foram testados seus respectivos interpretadores, o maior nível inferido dentre os dois é dado como resultado. No teste dos tipos de atividade 1, foi comparada a inferência captada no

Tabela 6.2: Tabela de testes do inferidor AF

Tipo de atividade	Total de amostras	Incorretas	Corretas	% de acerto aprox.
1	151	9	142	94
2	150	31	119	79
3	143	18	125	87
Total	444	58	386	Média: 87

teste com o nível alto de atividade gerando a taxa de 94% de acerto. Na categoria 2 de atividades, foi obtida uma taxa de acerto de 79%. Na categoria 3 houve um acerto em 87% dos casos.

As atividades de nível mediano foram mais complicadas de serem inferidas. A semelhança de intensidade, tanto com atividades bruscas quanto do estado de repouso, contribuiu para esse resultado mais baixo. Essa semelhança com atividades bruscas (categoria 1) pode ser constatada com atividades como andar, se levantar da cadeira ou da cama, entre outras, que podem variar suas amplitudes de sinais entre movimentos mais fortes e medianos. Em relação à comparação com o estado de repouso, há momentos em que se anda mais devagar, se levanta mais lentamente, entre outras atitudes que podem ser confundidas com o repouso. A necessidade de mais informações de contexto é observada como um meio de reafirmação das intensidades. Por exemplo, ao se verificar que a pessoa está deitada na cama, associar o estado de repouso é mais representativo do que inferir um nível mediano. Para que isso seja possível é necessário lidar com outros tipos de sensores, como sensores infravermelhos, sonares, sensores de luminosidade, entre outros.

Com os resultados obtidos aqui é possível avaliar possíveis trabalhos futuros. Com as taxas de confiança que se observou em cada teste é perceptível a necessidade de aprimoramento e agregação de técnicas. E isso é possível de ser feito, tendo em conta os espaços deixados em aberto na abordagem do módulo RA. O capítulo de conclusão, capítulo 7, apresenta uma análise dos pontos negativos e positivos desta proposta a partir dos resultados e de outras considerações, como a utilização de recursos e a possível adesão do paciente a um tratamento utilizando essas soluções.

6.3 Conclusão do capítulo

Neste capítulo foram avaliados os resultados obtidos nos testes. A partir disso, foi necessária uma reflexão sobre as técnicas abordadas. Com a detecção de quedas foram verificados

problemas de confiabilidade em comparação com atividades com movimentos bruscos. E para o inferidor AF, problemas associados à inferência de nível médio de atividade foram discutidos.

Para o detector de quedas, uma das possíveis soluções apontadas foi fechar mais o escopo, e definir sua confiança a partir do uso desse aplicativo por idosos. Uma verificação da orientação postural após uma queda detectada pode confirmar que a pessoa está caída após o impacto brusco. Para o inferidor AF, o uso de novos sensores como forma de resolver questões de ambiguidade podem ajudar no aprimoramento dos resultados. Com essa necessidade, uma relação de dependência à elaboração de outros componentes do módulo RA é observada.

Como contribuição, este capítulo fornece uma avaliação que serve para direcionar os trabalhos futuros e a realização de novos testes. Os resultados apresentados não fogem da margem de confiança obtida em trabalhos relacionados como [17] e [15]. O diferencial maior é o fator de integração a um sistema de telessaúde pervasivo como SCIADS.

Capítulo 7

Conclusão

Este trabalho provê um módulo RA conceitual, com elementos concretos como o detector de queda e o inferidor de nível de atividade física. A importância desses elementos em um sistema computacional inteligente de assistência domiciliar à saúde foram demonstradas durante todo o trabalho. Mostrou-se também a importância de se atingir requisitos de confiabilidade, sem desprezar as questões de privacidade de indivíduos que façam uso dessa abordagem. As técnicas que tratam sobre a questão da atividade foram exploradas, com a maioria a abordar a importância do reconhecimento de atividades na área da saúde.

No capítulo 2, que aborda uma série de trabalhos relativos ao reconhecimento de atividades, as ideias expostas pelos trabalhos relacionados são exploradas e há a busca pelas soluções mais adequadas. Como principais fatores de avaliação, estabelecemos o aumento das possibilidades de adesão de um paciente ao uso de um módulo RA e a confiança que esses dados trazem aos médicos que o acompanham. No início deste capítulo 2, foi explorada a visão conceitual que se tem das técnicas de reconhecimento de atividades. As classificações desses conceitos abordados em [3] foram referências exploradas nessa parte. Consequentemente, foi identificada que a exploração de conceitos de reconhecimento estatístico é a mais adequada aos objetivos deste trabalho.

Em seguida analisou-se propostas mais gerais para o reconhecimento de atividades, e chegamos à conclusão que o uso de redes Bayesianas associado às técnicas de aprendizagem de máquina poderiam alcançar resultados mais promissores. Ainda foi vista a necessidade de estabelecer a detecção de atividades que podem ser críticas ao estado de saúde do indivíduo, o que motivou a avaliação de propostas para a detecção de queda.

Uma avaliação de propostas para detecção de quedas foi realizada. Essa avaliação teve por objetivo estabelecer uma base para o desenvolvimento de um detector mais

adequado às necessidades expostas neste projeto. Chegamos à conclusão que o trabalho definido em [17] é o que corresponde melhor a esse propósito.

Para estabelecer um caminho mais direto e chegar a uma informação de atividade física, a informação pode ser utilizada em um modelo de regras para determinar a situação clínica do paciente [5]. Com o intuito de obter esse dado, foram estudadas técnicas de avaliação mais diretas da atividade física. Esse caminho curto foi estipulado para suprir a necessidade de reconhecer atividades de alto nível. As atividades de alto nível são foco de outro componente do módulo RA que ainda não foi implementado. Optamos assim por estabelecer um parâmetro que pudesse ser associado linearmente com um nível de desgaste físico.

O capítulo 2 forneceu os parâmetros iniciais para a definição de uma abordagem própria. Estabelecendo o uso de redes Bayesianas na identificação de comportamentos, o uso de máquinas de vetores de suporte (SVM) para detecção de quedas, e uso de sinais de aceleração para um identificador de nível de atividade física.

O acelerômetro que teve seu uso justificado no capítulo 3, onde se trata da abordagem metodológica proposta. Nesse capítulo é proposta uma metodologia especializada para uso em sistemas como o SCIADS. O foco inicial foi uma proposta conceitual do módulo RA, onde foi descrito como seria procedido o uso de redes Bayesianas nesse módulo. A justificativa para o fato de não se concretizar ainda a sua implementação está na necessidade, como pré-requisito, do estabelecimento de um conjunto variado de soluções mais simples. Com isso, o foco de abordagem se voltou para os dois submódulos que utilizam acelerômetros. Com a abordagem [17] como base, o detector de queda definido na seção 3.1 buscou a modificação em um ponto. Foi utilizada como característica extra uma técnica de classificação para verificar a ocorrência de mudanças bruscas nos sinais do acelerômetro e depois utiliza-se a técnica de SVM para confirmar a queda. Foram necessárias duas fases de treinamento, uma para cada classificador definido. Na seção 3.2, utilizou-se deste mesmo conceito de aprendizagem para o inferidor de nível de atividade física. Nesse caso, o algoritmo de verificação de mudanças agudas utilizado foi o classificador C4.5. Com a diferença de se utilizar sensores em duas regiões do corpo, o braço e a cintura. Como classificação de nível final foi definida a maior obtida dos dois sensores.

Neste capítulo de metodologia há a representação conceitual de cada desenvolvimento abordado no capítulo 4. Foram definidas suas respectivas fases de treinamento e interpretação, que tem implementações organizadas e definidas no capítulo de desenvolvimento do módulo RA. Observou-se ainda que há partes do módulo RA que não são

implementadas e são consideradas apenas como condições de utilização. Mas essas partes podem ser desenvolvidas futuramente.

No capítulo 4 é explorada a necessidade de ferramentas para implementar o que foi descrito no capítulo 3. Primeiramente, na seção 4.1.1, foi apresentado o uso do *Weka*, utilizado para implementar os algoritmos classificadores. Na seção 4.1.2, foi apresentado o sistema operacional *Android* voltado para celulares. Na seção 4.1.3, foi apresentado o relógio *eZ430-Chronos* utilizado para captação de sinais de aceleração. Com essas ferramentas definidas, na seção 4.2 e 4.3, foram descritas as implementações do detector de quedas e do inferidor de atividade física, respectivamente. O detector de queda explora a utilização do *Weka* e do sensor do celular com *Android*. O indentificador de atividades tem uma organização arquitetural que lida com dois dispositivos móveis. Um representa a parte superior do corpo com o uso do relógio e outro representa a parte inferior com o uso de celular. Para esse identificador foi desenvolvido uma aplicação de intermediação entre a parte superior e a aplicação no servidor. Isso ocorreu devido ao fato de que *eZ430-Chronos* usa linguagem de programação diferente.

Concluída a parte de implementação, foi possível estabelecer testes, a partir da realização dos treinamentos que são pré-requisitos para o funcionamento dos interpretadores. Esses treinamentos foram descritos no capítulo 5, relativo as abordagens de integração e teste. Ainda no capítulo 4, foram estabelecidas as frequências em que eram processados os sinais de aceleração, verificou-se então uma média de aproximadamente 20 medidas por segundo, valor que definiu a frequência de corte do filtro passa-baixo.

No capítulo 5, discutiu-se sobre a necessidade de fazer testes integrados com o sistema *SCIADS*, mas ponderou-se sobre a necessidade de prioridade maior a testes mais específicos das implementações realizadas. Para atender essa necessidade, os critérios de testes para o detector de queda e para o inferidor AF foram estabelecidos. Baseado nos trabalhos relacionados, foram estabelecidas categorias de atividades para avaliar a confiança do detector de queda. Esta categorização é utilizada, em partes, nos testes do inferidor AF. Também foram definidos, para treinamento dos classificadores, os parâmetros de cada um deles, o C4.5 e o SVM. Os resultados desse treinamento geraram uma árvore de decisão representando o classificador C4.5, e uma função de decisão representando a solução do classificador SVM. Para o inferidor AF foi preciso duas árvores de decisão, uma para região da cintura e outra para região do braço.

Com os testes definidos foi possível visualizar os resultados no capítulo 6. É nesse capítulo que se abordam os resultados. Há ainda considerações sobre resultados obtidos

em outras abordagens, onde são verificados os critérios estabelecidos de forma comum nas abordagens relacionadas. Verificados que os resultados foram similares a outras abordagens foram comparadas às qualidades dos testes feitos. A qualidade de nossos testes foram piores por terem menos representatividade. Em [17] houve diversos perfis testando a implementação enquanto em nossa abordagem houve apenas um perfil.

Em relação aos resultados, os parâmetros utilizados foram a taxa de confiança. Para o detector de queda, o grande problema ocorreu com as atividades bruscas, verificou-se que suas semelhanças estavam no impacto que exerciam. De imediato, propôs-se novas verificações, como identificar a orientação postural do indivíduo após essa detecção. Para isso é preciso avaliar os efeitos dessa mudança no estabelecimento de uma nova abordagem. Já no inferidor AF, verificou-se problemas em inferir nível médio a uma atividade, esses problemas foram associados a ambiguidade de certas atividades desse nível com os dois níveis vizinhos.

A importância de obter resultados, mesmo que prévios, sobre a abordagem proposta, é trazer a rediscussão dessa abordagem propondo seu aprimoramento. Também é importante ressaltar as contribuições do que foi feito, uma delas é a definição do arcabouço de reconhecimento de atividades voltados especializados para sistemas computacionais de assistência domiciliar a saúde. O detector de queda e o inferidor AF, atendem a esse requisito. Observe que o utilizador final desses submódulos, os utilizam apenas como interpretadores. A fase de treinamento é algo que ocorre no desenvolvimento dos testes. Esse treinamento serve para especificar, a partir do espaço de amostras, um comportamento a ser reconhecido por um interpretador.

Ainda foram verificados problemas de confiabilidade como os representados pelas taxas de confiança resultante nos testes realizados no capítulo 6. Uma ideia disso está no detector de quedas, que apresenta uma taxa de erro de 23% para atividades bruscas o que significa a ocorrência de aproximadamente um alarme falso a cada cinco ocorrências de atividades bruscas. Isso, em um sistema de telemonitoramento traz preocupação desnecessária dos acompanhadores, seja a família sejam os profissionais da saúde. Ou seja, essa taxa de erro pode trazer um custo desnecessário. Para o inferidor AF o custo de uma associação equivocada pode estar diretamente ligado a definição da situação emergencial do paciente. Com as taxas de confianças obtidas, essa integração direta é dificultada, mas uma visualização gráfica da intensidade de atividade física pode ajudar aos médicos, a confirmar se a situação é realmente de risco.

Portanto, com intuito de informar melhor sobre a atividade de um paciente, essa

proposta contribui para que o paciente não precise indicar explicitamente o que está fazendo para o sistema. Ainda é preciso considerar algumas limitações, como o uso de poucos sensores, e a pouca informação de contexto. Outras restrições estão indicadas no uso das ferramentas como celular e o relógio. É preciso que se esteja o máximo de tempo possível com esses aparelhos devidamente posicionados no corpo. Nesse caso a obtenção informação de contexto deve ser implementada para que esse posicionamento seja verificado.

7.1 Trabalhos futuros

Há soluções que são apontadas como necessárias, mas não são abordadas. Essas soluções estão no escopo de trabalhos futuros. Exemplo disso são os componentes de inferência de contexto e de inferência de comportamento, os quais são mostrados na Figura 3.1 e definidos atualmente como abstratos. Outras partes a serem desenvolvidas são as abordagens de sensores em outros locais, como os espalhados pelo ambiente e os associados a objetos. Tudo isso pode ser verificado e desenvolvido para incrementar o módulo RA.

Há ainda abordagens que se apresentam como alvo de desenvolvimento mais imediato, como o inferidor de contexto. A ideia é elaborar um módulo capaz de retornar a situação que se encontra determinado aparelho. Essa ideia é vista como essencial quando se utiliza celular aplicado como sensor. Pois é um aparelho que não tem propriedade de estar preso a algum lugar do corpo, e pode ser utilizado para outros fins, como atender ligações. Saber se o celular está posicionado corretamente no bolso da calça é um exemplo de informação que este módulo de inferência de contexto pode ajudar a alcançar. Em [12], essa ideia é explorada e traz uma abordagem preliminar para solucionar essa questão.

Para se atingir o objetivo de implementar a inferência de comportamento, onde é proposto o uso de redes Bayesianas, preciso pelo menos abordar a utilização de sensores de ambiente, e com isso poder estabelecer um outro tipo de informação, que pode ser desde a localização da pessoa na casa até a identificação do estado do ambiente. Alguns sensores que podem ser utilizados para definir o estado do ambiente são os de temperatura e os de luminosidade. Um exemplo, em uma rede Bayesiana, poderia ser utilizar a informação de luminosidade associada com a orientação postural do paciente para reforçar uma informação sobre o fato do paciente estar dormindo.

Pretende-se ainda, com o desenvolvimento de novos componentes para o módulo RA melhorar a taxa de confiança para a detecção de queda. Um componente conceitual

que pode ilustrar a ideia de melhora é a identificação de mobilidade após a queda. Essa identificação ocorreria após a confirmação da queda, e serviria para avaliar se houve danos ao paciente, e depois de verificado o dano é que seria enviado o alarme ocasionado por queda com danos.

Todas essas propostas futuras são baseados nos estudos de trabalhos relacionados, e no estudo desenvolvido em nosso projeto de aplicação. O desenvolvimento de um arcabouço permite que novas propostas sejam agregadas de forma a atingir um módulo RA concreto. Ao estabelecer um arcabouço voltado para o reconhecimento de atividades, a intenção foi estabelecer um processo incremental e evolutivo no desenvolvimento de seu módulo.

Referências Bibliográficas

- [1] S.T. Carvalho; A. Copetti; O. Loques. Um Sistema Computacional Inteligente de Assistência Domiciliar à Saúde. In: XII Congresso Brasileiro de Informática em Saúde, CBIS 2010. Porto de Galinhas, Pernambuco, Brasil, 2010.
- [2] S.T. Carvalho; M. Erthal; D. Mareli; A. Sztajnberg; A. Copetti; O. Loques. Monitoramento Remoto de Pacientes em Ambiente Domiciliar. In: XXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos - Salão de Ferramentas, SBRC 2010, Gramado, Rio Grande do Sul, Brasil, 2010.
- [3] J.K. Aggarwal e M.S. Ryoo. Human activity analysis: A review. *ACM Computing Survey*, 43:16:1–16:43, April 2011.
- [4] A.K. Bourke, J.V. O'brien e G.M. Lyons. Evaluation of a Threshold-Based Tri-axial Accelerometer Fall Detection Algorithm. *Gait & Posture*, 26:194–199, July 2007.
- [5] A. Copetti. *Monitoramento Inteligente e Sensível ao Contexto na Assistência Domiciliar Telemonitorada*. Tese de doutorado, Instituto de Computação, Universidade Federal Fluminense, Niterói, RJ, Brasil, 2010.
- [6] M. ElHelw, J. Pansiot, D. McIlwraith, R. Ali, B. Lo and L. Atallah. An Integrated Multi-Sensing Framework for Pervasive Healthcare Monitoring. *3rd International Conference on Pervasive Computing Technologies for Healthcare*, 1:1–7, London, UK, May 2009.
- [7] G. Hendeby, I. Lamprinos, D. Stricker and G. Bleser. Healthy aging using physical activity monitoring. In: *AALLIANCE conference*, 1–5, Malaga, Spain, March 2010.
- [8] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann e Ian H. Witten. The weka data mining software: an update. *SIGKDD Explorer Newsletter*, 11:10–18, November 2009.

- [9] D. M. Karantonis, M. R. Narayanan, M. Mathie, N. H. Lovell e B. G. Celler. Implementation of a Real-Time Human Movement Classifier Using a Triaxial Accelerometer for Ambulatory Monitoring. *Information Technology in Biomedicine, IEEE Transactions on*, 10(1):156–167, 2006.
- [10] B. Longstaff, S. Reddy and D. Estrin. Improving Activity Classification for Health Applications on Mobile Devices using Active and Semi-Supervised Learning. *Pervasive Computing Technologies for Healthcare (PervasiveHealth), 2010 4th International Conference on*, pp. 1–7, Munich, Germany, March 2010.
- [11] Mitja Luštrek e Boštjan Kaluža. Fall Detection and Activity Recognition with Machine Learning, *Informatika* 33(2), pp. 205–212, Ljubljana, Slovenia, July 2008.
- [12] Emiliano Miluzzo, Michela Pap, Nicholas D. Lane, Hong Lu and Andrew T. Campbell. Pocket, Bag, Hand, etc. - Automatically Detecting Phone Context through Discovery, *In Proceedings of PhoneSense 2010*, November 2010.
- [13] N. Oliver, E. Horvitz and A. Garg. Layered Representations for Human Activity Recognition. In: *Proceedings of the Fourth IEEE International Conference on Multimodal Interfaces, 2002*, pp. 3–8, 2002.
- [14] D. Osmani, V. Zhang and S. Balasubramaniam. Human Activity Recognition Supporting Context-Appropriate Reminders for Elderly. *Pervasive Computing Technologies for Healthcare, 2009. PervasiveHealth 2009. 3rd International Conference on*, pp. 1–4, London, UK, May 2009.
- [15] T. Zhang, P. Liu, J. Wang and J. Hou. Fall Detection by Embedding an Accelerometer in Cellphone and Using KFD Algorithm. *International Journal of Computer Science and Network Security*, 83(4):277–284, October 2006.
- [16] Che-Chang Yang and Yeh-Liang Hsu. A Review of Accelerometry-Based Wearable Motion Detectors for Physical Activity Monitoring. *Sensors in Biomechanics and Biomedicine*, 10(8):7772–7788, Basel, Switzerland, August 2010.
- [17] T. Zhang, P. Liu, J. Wang and J. Hou. Fall Detection by Wearable-Sensor and One-Class SVM Algorithm. In: *ICIC 2006. Lecture Notes in Control and Information Science*, vol. 345, pp. 858–863, 2006.