

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Daniela Freitas Giacomelli

**Estudo e caracterização das ferramentas para o
reconhecimento de atividade humana usando
sensores de acelerômetro**

Uberlândia, Brasil

2017

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Daniela Freitas Giacomelli

**Estudo e caracterização das ferramentas para o
reconhecimento de atividade humana usando sensores de
acelerômetro**

Trabalho de conclusão de curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, Minas Gerais, como
requisito exigido parcial à obtenção do grau
de Bacharel em Sistemas de Informação.

Orientador: Elaine Ribeiro de Faria Paiva

Universidade Federal de Uberlândia – UFU

Faculdade de Ciência da Computação

Bacharelado em Sistemas de Informação

Uberlândia, Brasil

2017

Agradecimentos

Agradeço imensamente à minha orientadora Elaine, por todo apoio, paciência, ensinamentos e profissionalismo dedicados a mim nesse ano em que trabalhamos juntas.

Agradeço a minha amiga Ruth, que dedicou várias tardes de sábado para me ajudar a desenvolver o código implementado neste trabalho. Além de ouvir meus desabafos e tentar acalmar a minha ansiedade.

Agradeço ao meu marido, Fernando, por me apoiar e me dar todo o suporte necessário para eu me formar. Além de meu companheiro, você é uma inspiração para mim, te admiro muito.

Agradeço à minha família e aos meus amigos, que sempre estiveram ao meu lado, foram compreensivos com a minha ausência nesse período ou com as minhas reclamações excessivas.

E acima de tudo, agradeço a Deus, que é o meu amparo e é aonde me refugio. Todas as minhas realizações são para honra e glória do Seu Nome.

Resumo

O Reconhecimento de Atividade Humana (RAH) tem o objetivo de classificar atividades humanas baseado em uma série de leituras realizadas por sensores de acelerômetro presentes em *smartphones*, *tablets* ou outros dispositivos semelhantes. Por meio dessa classificação, é possível reconhecer e prever as atividades que estão sendo realizadas pelo usuário, possibilitando um monitoramento de suas ações. Esse monitoramento permite oferecer serviços na área de cuidados médicos, no acompanhamento de idosos, ou, ainda, em planejamento *fitness*. Este trabalho visa estudar e caracterizar as principais ferramentas e bases de dados existentes para a tarefa de RAH, criar um conjunto de técnicas de extração de características a partir da leitura dos sensores e disponibilizar tais informações em um site na Internet. Ademais, busca-se fornecer orientações e diretrizes para futuras pesquisas nesta área. Após testar um grupo de aplicativos disponíveis para coleta de dados do sensor de acelerômetro, constatou-se que o AccDataRec apresentou as melhores características. Além disso, diferentes conjuntos de atributos foram utilizados nos experimentos com três classificadores (Árvore de Decisão, Naive Bayes e KNN), dentre os quais, o KNN apresentou o melhor resultado para a classificação em RAH e concluiu-se que os atributos média e desvio padrão podem ser suficientes para obter um bom desempenho nesta tarefa.

Palavras-chave: Reconhecimento de atividade humana, acelerômetro, sensores de acelerômetro, giroscópio.

Lista de ilustrações

Figura 1 – Árvore de decisão	17
Figura 2 – Tipos de janelas	29

Lista de tabelas

Tabela 1 – Matriz de confusão	19
Tabela 2 – Estudo comparativo dos trabalhos desenvolvidos sobre RAH - 1	22
Tabela 3 – Estudo comparativo dos trabalhos desenvolvidos sobre RAH - 2	23
Tabela 4 – Estudo comparativo das bases de dados disponíveis - 1	25
Tabela 5 – Estudo comparativo das bases de dados disponíveis - 2	26
Tabela 6 – Fórmulas utilizadas para o pré-processamento dos dados	30
Tabela 7 – Estudo comparativo dos aplicativos de coleta de dados	34
Tabela 8 – Bases de dados transformadas	37
Tabela 9 – Comparação dos experimentos - WISDM	38
Tabela 10 – Comparação dos experimentos - Chest	39

Lista de abreviaturas e siglas

RAH	Reconhecimento de Atividade Humana
KNN	k-nearest neighbor (K-vizinhos mais próximos)
Revoc.	Revocação
Prec.	Precisão
Chest	Activity Recognition from Single Chest-Mounted Accelerometer Data Set

Sumário

1	INTRODUÇÃO	9
1.1	Justificativa	10
1.2	Objetivos	11
1.2.1	Objetivo Geral	11
1.2.2	Objetivos específicos	11
1.3	Organização do Trabalho	11
2	REVISÃO BIBLIOGRÁFICA	13
2.1	Introdução	13
2.2	Reconhecimento de Atividade Humana e sua importância	13
2.2.1	Aplicações do RAH	13
2.2.2	RAH usando acelerômetro	14
2.3	Etapas do desenvolvimento de um sistema de RAH	15
2.3.1	Classificação em RAH	16
2.4	Metodologia e Medidas de Validação	17
2.5	Trabalhos desenvolvidos sobre RAH	19
2.6	Bases de dados disponíveis	24
3	PROPOSTA	27
3.1	Introdução	27
3.2	Coleta de dados	27
3.3	Pré-processamento	28
3.4	Classificação	31
3.5	Metodologia e Medidas de Validação	31
3.6	Construção do site	31
4	DESENVOLVIMENTO	33
4.1	Introdução	33
4.2	Estudo comparativo dos aplicativos para coleta de dados	33
4.3	Bases de dados	34
4.3.1	WISDM	34
4.3.2	Chest	36
4.3.3	Bases pré-processadas	36
4.4	Experimentos	37
5	CONCLUSÃO	41

5.1	Contribuições	41
5.2	Considerações finais e trabalhos futuros	41
	REFERÊNCIAS	43

1 Introdução

O avanço da tecnologia possibilita a aquisição de dados em alta velocidade e em larga escala (GAMA, 2010) (AGGARWAL, 2007). No entanto, lidar com essas grandes quantidades de dados, extraindo informações relevantes pode ser um desafio aos pesquisadores, pois ainda há limitações quanto aos recursos computacionais disponíveis.

A mineração de dados trata dessa capacidade de obter informações úteis e conhecimento mediante grandes depósitos de dados, recorrendo a técnicas para identificar padrões de interesse e fornecer a capacidade de prever ações ou comportamentos (TAN et al., 2006).

A classificação é uma tarefa da mineração de dados, que consiste em rotular objetos dentro de uma categoria ou classe, dentre diferentes classes pré-definidas (TAN et al., 2006). Uma das recentes aplicações da classificação consiste no reconhecimento de atividade humana, cujo escopo visa identificar atividades cotidianas por meio da leitura de sensores incorporados a dispositivos móveis (KWAPISZ; WEISS; MOORE, 2011), (WEISS et al., 2016).

Um sensor muito utilizado para o Reconhecimento de Atividade Humana (RAH) é o acelerômetro (RAVI et al., 2005), (SUN et al., 2010), (WEISS et al., 2016). Um aplicativo é instalado no *smartphone* ou outro dispositivo móvel, para coletar as leituras do acelerômetro. Estas leituras são transformadas em modelos de decisão para prever atividades de um usuário ao longo do tempo. O RAH tem diversas aplicações no mundo real, tais como:

- monitoramento *fitness*: o usuário pode ter uma estimativa da distância percorrida em uma corrida e a quantidade de calorias gasta.
- monitoramento de idoso: detecção de quedas ou outros incidentes.
- monitoramento de saúde: pacientes com a Doença de Parkinson, por exemplo, necessitam de períodos mais longos de exames para diagnosticar com precisão os sintomas e controlar o curso da condição. Logo, o monitoramento diário pode auxiliar os médicos a detectar os desvios de uma rotina ou a deterioração de um estado físico.

Devido à importância do Reconhecimento de Atividade Humana e à sua aplicabilidade em diferentes problemas do mundo real, a presente pesquisa propõe um estudo comparativo das principais ferramentas e bases de dados disponíveis para esta tarefa.

1.1 Justificativa

A tarefa de Reconhecimento de Atividade Humana (RAH) tem sido alvo de constante abordagem científica, como nos trabalhos de [Ravi et al. \(2005\)](#), [Lockhart, Pulickal e Weiss \(2012\)](#), dentre outros. A ideia geral é construir um classificador, que, por meio de um modelo de decisão, consiga identificar qual atividade está sendo desempenhada por determinado usuário. É importante que esses algoritmos consigam também identificar novas classes de atividade, para as quais o modelo não foi treinado.

A fim de testar os algoritmos de classificação desenvolvidos para RAH, foram utilizadas diferentes bases de dados contendo leituras de sensores de acelerômetros, como nos trabalhos de [Weiss et al. \(2016\)](#), [Kwapisz, Weiss e Moore \(2011\)](#) e [Anguita et al. \(2013\)](#). No entanto, poucas bases de dados de acelerômetro estão disponíveis publicamente.

Uma vez que os dados são coletados, eles são pré-processados antes de serem empregados na tarefa de classificação. Para realizar tal pré-processamento, diferentes transformações podem ser aplicadas. Em geral, os trabalhos transformam os atributos x, y e z, obtidos com o uso do sensor de acelerômetro (aceleração nos 3 eixos), em um conjunto de dezenas de outros atributos, extraindo a partir de janelas de dados, medidas estatísticas como média, desvio padrão, moda e mediana. A questão é que cada trabalho extrai um conjunto diferente de atributos, dificultando a comparação dos resultados obtidos por diferentes trabalhos. Além disso, várias das bases de dados disponibilizam apenas os dados pré-processados, o que impede que outros tipos de pré-processamentos sejam realizados nos dados brutos.

Faz-se necessário salientar que diferentes sensores de acelerômetros estão disponíveis, e, além de coletar os dados da aceleração nos três eixos (x, y e z), também é possível coletar dados do sensor de giroscópio. Alguns trabalhos como de [Weiss et al. \(2016\)](#), [Lockhart e Weiss \(2014\)](#) e [Kwapisz, Weiss e Moore \(2011\)](#), têm-se valido de tal informação, mas ainda não há um consenso se o uso dos dados desse sensor podem melhorar a qualidade da tarefa de RAH.

Outra importante característica de uma base de dados para RAH é a sua configuração com relação às atividades desenvolvidas, número de usuários envolvido no processo de coleta, tempo de coleta de cada atividade e se houve mudanças no comportamento dos usuários ao longo do tempo. Em geral, atividades como andar, correr, subir ou descer escadas, sentar e deitar são comumente avaliadas. Fatores como o tamanho da amostra, a forma como os dados foram coletados, o número e o perfil das pessoas que participam dos experimentos, podem influenciar nos resultados da avaliação do classificador utilizado.

Alguns trabalhos têm destacado a influência da posição na qual o acelerômetro se encontra, como em [Sun et al. \(2010\)](#), onde propõe-se coletar dados usando diferentes posições do sensor de acelerômetro.

Diante do cenário apresentado, torna-se difícil comparar e avaliar os diferentes trabalhos desenvolvidos para o RAH. Dessa forma, o presente projeto visa disponibilizar as informações dos estudos realizados e auxiliar as pesquisas nessa área.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo do presente projeto é estudar e caracterizar as principais ferramentas e bases de dados existentes para a tarefa de Reconhecimento de Atividade Humana (RAH), disponibilizando tais informações em um site na Internet. Ademais, busca-se fornecer diretrizes para futuras pesquisas nesta área.

1.2.2 Objetivos específicos

Para alcançar o objetivo geral, faz-se necessário estabelecer alguns objetivos específicos, tais como:

- Analisar e caracterizar as principais ferramentas para o registro das leituras dos sensores de acelerômetro.
- Analisar e caracterizar os diferentes trabalhos e bases de dados públicas disponíveis para RAH, indicando os diferentes tipos de transformação dos dados brutos para processados, bem como as tarefas comumente avaliadas.
- Implementar um conjunto de técnicas de pré-processamento e extração de características, a fim de transformar os dados brutos dos acelerômetros em dados a serem processados pelos algoritmos de classificação.
- Identificar qual conjunto de atributos tem obtido os melhores resultados na tarefa de RAH.
- Criar um site para disponibilizar os resultados desse estudo.

1.3 Organização do Trabalho

O trabalho será disposto da seguinte forma:

- **Capítulo 2:** traz uma revisão bibliográfica sobre os trabalhos já desenvolvidos acerca da temática da pesquisa, descreve as aplicações e detalha as etapas de desenvolvimento de um sistema de RAH.

- **Capítulo 3:** relata como a pesquisa foi conduzida, qual a metodologia empregada, quais etapas (bem como cada etapa foi conduzida) e fórmulas utilizadas.
- **Capítulo 4:** detalha e compara os experimentos realizados e descreve cada uma das bases de dados utilizadas.
- **Capítulo 5:** tece as conclusões da pesquisa.

2 Revisão Bibliográfica

2.1 Introdução

Este capítulo apresenta uma revisão bibliográfica acerca dos trabalhos já desenvolvidos sobre Reconhecimento de Atividade Humana. Serão discutidas, ainda, as aplicabilidades, as ferramentas de coleta de dados e as bases disponíveis para a realização de estudos sobre o tema.

2.2 Reconhecimento de Atividade Humana e sua importância

O Reconhecimento de Atividade Humana é uma tarefa com o objetivo de identificar ou prever atividades humanas, baseando-se em uma série de leituras de sensores, captura de imagens ou outro tipo de monitoramento. Segundo [Davies, Siewiorek e Sukthankar \(2008\)](#), a função do RAH é capturar o estado do usuário e do seu ambiente utilizando sensores heterogêneos.

O RAH tem gerado grande interesse dentro da computação móvel e ubíqua. A computação ubíqua diz respeito à alta disponibilidade de computadores de forma onipresente, ou seja, está em toda lugar e, às vezes, nem é percebido ([EDUCAÇÃO., 2016](#)). Já a computação móvel refere-se à portabilidade e à possibilidade de se conectar com redes em diferentes lugares ([EDUCAÇÃO., 2016](#)). Devido ao grande número de pesquisadores e empresas que trabalham nesta área, são esperadas muitas aplicações de reconhecimento de atividade ([LOCKHART; PULICKAL; WEISS, 2012](#)).

A aplicação da RAH propicia a oferta de serviços personalizados em diferentes áreas, tais como: saúde, acompanhamento *fitness*, segurança, entretenimento e monitoramento de idosos. Devido à importância do RAH e sua vasta gama de aplicabilidades, vários estudos foram desenvolvidos nessa área ([RAVI et al., 2005](#)); ([LOCKHART; PULICKAL; WEISS, 2012](#)); ([SUN et al., 2010](#)).

2.2.1 Aplicações do RAH

Diversos estudos têm sido desenvolvidos sobre Reconhecimento de Atividade Humana ([WEISS et al., 2016](#)), ([SUN et al., 2010](#)), ([LOCKHART; PULICKAL; WEISS, 2012](#)). Além disso, algumas áreas, como saúde, segurança e entretenimento, têm recorrido a esse método para desenvolver serviços e aplicações.

Na área da saúde, existem casos nos quais é difícil diagnosticar uma pessoa que procura atendimento médico, baseando-se apenas em consultas e exames pontuais. Dessa

forma, o monitoramento das atividades diárias, durante um determinado período de tempo, torna-se interessante. Pacientes com a doença de Parkinson, por exemplo, precisam de períodos mais longos de observação. Neste caso, o RAH é uma ferramenta para ajudar o médico a realizar um diagnóstico mais preciso, pois torna-se possível detectar desvios de uma rotina típica, resposta a um dado tratamento ou o agravamento do caso (LOCKHART; PULICKAL; WEISS, 2012).

O monitoramento de idosos é uma aplicação importante da tarefa de reconhecimento de atividade humana. É possível encontrar aplicativos, como o *Smart Fall Detection* (PLAY., 2016c) e o *freeWalker Beta* (PLAY., 2016a), que detectam quedas e enviam mensagens de texto para um número de emergência previamente registrado, com a localização do usuário acidentado.

Com a expansão do mercado *fitness*, os desenvolvedores se atentaram para o crescimento de um público interessado em monitorar a execução de exercícios físicos, fornecendo dados como intensidade e duração da atividade, além de detectar, automaticamente, a realização do exercício e indicar a técnica mais apropriada para o usuário. Com essa finalidade, foram desenvolvidos aplicativos, como o *Runtastic Squats* Agachamentos (PLAY., 2016b).

A indústria do entretenimento também soube aplicar o reconhecimento de movimentos. O *Kinect*, por exemplo, é um sensor desenvolvido para o *X-box 360* e *Xbox One*, que permite a maior interação do jogador com o game, pois tal tecnologia dispensa o uso de controles ou *joysticks*.

O estudo de Carvalho (2014) busca conciliar saúde e entretenimento. O jogo desenvolvido serve para estimular a prática de exercícios físicos e a adoção de hábitos alimentares mais saudáveis, tendo como objetivo o combate à obesidade infantil. Considerando possibilidade da execução incorreta dos movimentos pela criança, a ferramenta se baseia na captura e reconhecimento de padrões de movimento dos exercícios propostos, para registrar e avisar quando estes forem realizados incorretamente.

Outra finalidade para o reconhecimento de atividade humana é a segurança, existem câmeras de monitoramento capazes de detectar movimentos, servindo-se da tecnologia de reconhecimento de imagens.

2.2.2 RAH usando acelerômetro

O RAH pode ser feito por meio de imagens, usando câmeras para detectar visualmente o movimento das pessoas. Segundo Sun et al. (2010), a desvantagem desta solução é que, para monitorar uma pessoa em movimento, um grande número de câmeras seria necessário, elevando o custo. Além disso, faz-se necessário tratar questões como iluminação, ângulo e distância da montagem do equipamento de monitoramento.

Atualmente, vários trabalhos têm utilizado o sensor de acelerômetro na tarefa de reconhecimento de atividade (SUN et al., 2010); (KWAPISZ; WEISS; MOORE, 2011); (RAVI et al., 2005). Basicamente, pelo sensor de acelerômetro é possível medir a aceleração em relação à gravidade. Alguns desses sensores são capazes, ainda, de medir a direção dessa aceleração (BENFICA, 2016).

O acelerômetro pode ser encontrado em *smartphones*, *tablets*, *notebooks*, *smartwatches* e até em carros. Trata-se de um sensor pequeno, barato e com boa sensibilidade, por essas razões, são muito utilizados em sistemas nos quais é preciso detectar, mensurar ou captar qualquer movimento ou vibração.

Para o reconhecimento de atividade humana, o uso do sensor de acelerômetro torna-se interessante, por estar presente em dispositivos móveis que podem ser facilmente acoplados ao corpo. Ademais, tem um custo menor, se comparado ao uso de câmeras, é confortável para o usuário e pode ser utilizado durante a realização de atividades diárias, ou ainda, na execução de exercícios físicos.

Existem diversos aplicativos disponíveis capazes de coletar dados das leituras de sensores de acelerômetro. Enquanto alguns permitem que o usuário salve essas informações na forma de planilhas ou arquivos de texto, outros possibilitam apenas a visualização desses dados em tempo de execução.

2.3 Etapas do desenvolvimento de um sistema de RAH

No trabalho de Sun et al. (2010), os autores definem três etapas para o desenvolvimento de um sistema para o RAH: coleta e pré-processamento de dados, extração de atributos e treinamento dos classificadores.

Ao iniciar o desenvolvimento de um sistema de Reconhecimento de Atividade Humana, primeiramente, é necessário definir o grupo de pessoas que participarão da etapa de coleta de dados, fatores como quantidade, idade e sexo devem ser definidos nesse momento. O tipo de sensor e o dispositivo móvel a ser utilizado também fazem parte do planejamento do sistema. É preciso, ainda, estabelecer quantas e quais serão as classes de atividades avaliadas na classificação, qual o tamanho e o tipo da janela (fixa ou deslizante) na qual os dados serão divididos. Para a coleta dos dados utilizados na tarefa de RAH, é necessário que diferentes usuários executem diferentes atividades, podendo utilizar um ou mais sensores. Os sensores comumente empregados na literatura realizam em média 20 coletas de dados por segundo (PAIVA, 2014).

Na fase de extração de atributos, os dados são divididos em janelas das quais são extraídas algumas características, tais como: média, variância, correlação, desvio padrão, dentre outras. A partir da extração dessas características, são gerados os atributos. De-

pendendo do conjunto de atributos obtidos, diferentes resultados podem ser observados. É importante encontrar a melhor forma de representar os dados, a fim de alcançar o melhor desempenho na tarefa de classificação.

Em seguida, tem-se a etapa de classificação. Segundo [Witten et al. \(2016\)](#), a classificação pode ser chamada de aprendizagem supervisionada, pois o método opera sob supervisão. São fornecidos exemplos de treinamento já rotulados e, segundo [CAMILO Cássio O.; SILVA \(2017\)](#), o modelo de classificação deverá analisar esse conjunto rotulado e aprender a classificar novos exemplos.

2.3.1 Classificação em RAH

O reconhecimento de atividade humana é formulado como um problema de classificação, no qual as classes correspondem às atividades ([RAVI et al., 2005](#)). A tarefa de classificação é usada em diferentes aplicações do mundo real, dentre elas podem ser destacadas: aprovação de crédito, detecção de fraudes, diagnóstico médico, dentre outras ([CORREA, 2017](#)).

A qualidade do modelo de classificação pode ser julgada testando a descrição de conceito que foi aprendida, em um conjunto independente de dados de teste, para o qual as classificações verdadeiras são conhecidas, mas não disponibilizadas para o classificador. A taxa de sucesso nos dados de teste fornece uma medida objetiva de quão bem o conceito foi aprendido ([WITTEN et al., 2016](#)).

Diferentes métodos de classificação são empregados na literatura para a tarefa de RAH, tais como: árvore de decisão ([LOCKHART; WEISS, 2014](#)); ([RAVI et al., 2005](#)); ([KWAPISZ; WEISS; MOORE, 2011](#)), *Naive Bayes* ([RAVI et al., 2005](#)); ([LOPES; MENDES-MOREIRA; GAMA, 2012](#)), Redes Neurais ([LOCKHART; WEISS, 2014](#)), Máquina de Vetor Suporte ([RAVI et al., 2005](#)); ([ANGUITA et al., 2013](#)); ([SUN et al., 2010](#)), KNN ([KWAPISZ; WEISS; MOORE, 2011](#)), dentre outros. Neste trabalho, serão adotados os seguintes métodos: Árvore de Decisão, KNN e *Naive Bayes*. Esses classificadores foram escolhidos por serem comumente utilizadas na literatura para tratar de RAH. A seguir, será apresentada uma visão geral sobre tais métodos.

A Árvore de Decisão segue um modelo de aprendizagem baseado na abordagem "dividir e conquistar". Nesse modelo, o nó folha representa a classe ou rótulo e cada nó (não-folha) indica um teste feito sobre o exemplo. Para classificar um exemplo desconhecido, percorre-se a árvore de acordo com os valores dos atributos testados em nós sucessivos e, quando uma folha é atingida, a instância é classificada de acordo com a classe atribuída à folha ([WITTEN et al., 2016](#)). A figura 3.2 ilustra uma árvore de decisão com as seguintes classes:

Classe a: A pessoa trabalha e estuda;

Classe b: A pessoa só estuda;

Classe c: A pessoa só trabalha;

Classe d: A pessoa não trabalha e não estuda.



Figura 1 – Árvore de decisão

O classificador de vizinhos mais próximos (KNN), recorre à analogia para a classificação. Os exemplos são representados como pontos em um espaço n-dimensional. Para determinar a classe de um novo exemplo, verificam-se as classes dos K vizinhos mais próximos e a classe mais frequente será atribuída ao exemplo (TAN et al., 2006).

O algoritmo *Naive Bayes* é considerado simples e eficiente, por isso, é comumente utilizado para a classificação e recebe tal nome por ser baseado no teorema de Thomas Bayes. Segundo o teorema, é possível encontrar a probabilidade de determinado evento ocorrer, dada a probabilidade de um outro evento que já ocorreu: Probabilidade (B dado A) = Probabilidade (A e B)/Probabilidade(A) (CAMILO CÁSSIO O.; SILVA, 2017). Este classificador tem uma característica peculiar, ele é capaz de produzir estimativas de probabilidade ao invés de simples classificações. Desta forma, para cada rótulo de classe, o classificador pode gerar uma estimativa de o novo objeto pertencer a ela (CORREA, 2017).

2.4 Metodologia e Medidas de Validação

Existem diversos métodos para avaliar o desempenho de um classificador com a finalidade de estimar o erro de generalização de um modelo durante o treinamento. O erro estimado auxilia na escolha de um modelo que não é susceptível a *overfitting* – quando o modelo de classificação se adapta a detalhes específicos da base de treinamento, reduzindo a taxa de acertos (CAMPOS, 2017).

Será apresentada, a seguir, uma visão geral de algumas medidas comumente empregadas para avaliar o desempenho de um classificador na tarefa de RAH, mas, antes, é preciso definir a metodologia utilizada para dividir a base em dois conjuntos: treinamento e teste. O primeiro consiste em um conjunto de dados rotulados que são usados para construir um modelo de classificação que será aplicado em um conjunto de teste, cujos registros não estão rotulados.

No *Holdout*, os dados são divididos em dois conjuntos distintos, denominados de conjunto de treinamento e conjunto de teste. Um modelo de classificação é induzido a partir do primeiro e seu desempenho é avaliado no outro. Existem ressalvas quanto às limitações desse método, por considerar que alguns exemplos são retidos para teste e, consequentemente, há menos exemplos rotulados disponíveis para treinamento. Além disso, sua confiabilidade pode variar de acordo com a composição dos dois conjuntos formados (TAN et al., 2006).

O segundo método é chamado de Subamostragem Aleatória e consiste em repetir diversas vezes o método anterior, com a finalidade de melhorar a estimativa do desempenho de um classificador. Além das limitações herdadas do *Holdout*, a subamostragem ainda apresenta um outro problema, por não ter controle sobre o número de vezes que cada exemplo é utilizado para testes e treinamento, alguns podem ser usados com mais frequência em relação aos outros (TAN et al., 2006).

Existe, ainda, um método chamado de validação cruzada, no qual todos os registros são usados o mesmo número de vezes, durante a fase de treinamento, e apenas uma vez para teste. Na validação cruzada de duas pastas, os dados são subdivididos em dois conjuntos de mesmo tamanho. Primeiro, escolhe-se um subconjunto para treinamento e outro para teste, em seguida, invertem-se os papéis. Já na validação cruzada k-pastas, os dados são subdivididos em k partições de tamanho igual, uma partição é escolhida para teste e as outras ficam para o treinamento. Esse procedimento é repetido k vezes, até que todas as partições tenham sido utilizadas para teste apenas uma vez. Em ambos os casos, o erro estimado é obtido pela média entre os erros de cada execução (TAN et al., 2006).

Após definir a qual estratégia se recorreu para particionar os dados em treinamento e teste, passa-se para a etapa de avaliação do desempenho do classificador. Diferentes medidas podem ser analisadas nesse processo, tais como: acurácia, matriz de confusão, curva característica de operação de um receptor (curva ROC), aprendizagem sensível ao custo e abordagens baseadas em amostragens.

A acurácia refere-se ao número de instâncias previstas corretamente, expressa como uma proporção de todas as instâncias da base as quais se aplica. A fragilidade dessa medida está no fato de existirem conjuntos de dados com distribuição de classe desequilibrada. Por exemplo, se 1% das operações com cartão de crédito foram fraudulentas e 99% foram legítimas, o modelo que assuma toda transação como legítima possui uma precisão de

99% (TAN et al., 2006).

Uma classe rara é difícil de ser detectada, pelo fato de ocorrer com pouca frequência. Em uma matriz de confusão, tal classe é considerada a mais relevante, sendo denotada como a classe positiva. A matriz de confusão irá mostrar a quantidade de instâncias previstas correta ou incorretamente por um modelo de classificação, como pode ser visto na tabela.

	Classe prevista	
Classe verdadeira	+	-
+	TP	FN
-	FP	TN

Tabela 1 – Matriz de confusão

Na qual:

- TP indica o verdadeiro positivo: número de exemplos positivos previstos corretamente;
- FN indica o falso negativo: número de exemplos positivos previstos erroneamente como negativos;
- FP indica o falso positivo: número de exemplos negativos previstos erroneamente como positivos;
- TN indica o verdadeiro negativo: número de exemplos negativos previstos corretamente.

Existem, ainda, duas métricas muito utilizadas para avaliação do desempenho, são elas: precisão e revocação. A primeira determina a fração de exemplos classificados corretamente como positivos dentre todos os elementos classificados como positivos (verdadeiro positivo+falso positivo), enquanto a segunda corresponde à quantidade de exemplos classificados como positivos que realmente são positivos(TAN et al., 2006).

$$Precisão(Precision) = TP/(TP + FP) \quad (2.1)$$

$$Revocação(Recall) = TP/(TP + FN) \quad (2.2)$$

2.5 Trabalhos desenvolvidos sobre RAH

Muitos estudos têm sido propostos com enfoque no reconhecimento de atividade humana recorrendo aos sensores de acelerômetro. Em geral, os algoritmos de mineração

de dados mais usados são Árvore de Decisão (LOCKHART; WEISS, 2014); (RAVI et al., 2005); (KWAPISZ; WEISS; MOORE, 2011) e Máquina de Vetor Suporte (SVM) (RAVI et al., 2005); (ANGUITA et al., 2013); (SUN et al., 2010), os pré-processamentos mais aplicados são média e desvio padrão, e o tipo de sensor predominante é o acelerômetro triaxial, podendo ter uso concomitante com o giroscópio. As tabelas 2 e 3 apresentam estudos comparativos de alguns trabalhos já desenvolvidos.

No estudo de Weiss et al. (2016), foram utilizados *smartphones* com sensores de acelerômetro triaxial, para reconhecer 5 atividades humanas, são elas: andar, correr, subir/descer escadas, permanecer parado e sentar/deitar. Os dados brutos obtidos pelo acelerômetro foram divididos em janelas de 10 segundos, que foram transformadas em 43 atributos após o pré-processamento, aplicando funções como média e desvio-padrão. Os autores utilizaram o *Random Forest* como algoritmo de mineração e o aplicativo *Actitracker* para leitura e armazenamento dos dados coletados pelo sensor. Os resultados foram armazenados em um banco de dados que pode ser acessado pela internet, para fornecer relatórios de atividade a cada usuário por meio de sua conta pessoal *Actitracker*. O aplicativo foi considerado uma ferramenta fácil de aprender devido à sua interface simples, mas tem um impacto significativo no uso da bateria do *smartphone*.

Em Lockhart e Weiss (2014), os autores também utilizaram janelas de 10 segundos para obter 43 atributos usados na tarefa de classificação. Para este trabalho, foram consideradas 6 atividades humanas: permanecer parado, andar, correr, subir escadas e deitar. O sensor empregado foi o acelerômetro triaxial e diferentes classificadores foram testados (Árvore de decisão, aprendizagem baseada em instâncias, redes neurais, regra de indução e regressão logística). O classificador que registrou a maior acurácia foi redes neurais usando abordagem pessoal, que é quando se utilizam os dados de treinamento apenas para quem o modelo foi treinado. Participaram da coleta de dados 59 usuários, carregando no bolso um *smartphone* com *Android*, enquanto executavam as 6 atividades mencionadas. Os dados coletados foram armazenados no celular e também enviados para o servidor.

No trabalho de Ravi et al. (2005), as atividades foram classificadas em 9 tipos diferentes: permanecer parado, andar, correr, subir escadas, descer escadas, sentar, usar o aspirador de pó e escovar os dentes. Dois voluntários participaram do referido estudo. O sensor utilizado foi o acelerômetro triaxial com um transmissor *Bluetooth* acoplado, sendo os dados transmitidos via *Bluetooth* para um dispositivo da HP. Os autores valeram-se de janelas de 256 com 128 amostras de sobreposição entre janelas consecutivas. Aplicando-se média, desvio padrão, energia e correlação, foram extraídas 4 características de cada um dos 3 eixos do acelerômetro, totalizando 12 atributos. Os classificadores utilizados foram: árvore de decisão, tabelas de decisão, KNN, Máquinas de Vetor Suporte e *Naive Bayes*. Também avaliou-se o desempenho de alguns dos classificadores de meta-nível mais

avancados, que são conhecidos por evidenciar um desempenho melhor. *Plurality Voting* combina vários classificadores de nível básico e foi o que apresentou a melhor correlação de desempenho.

O estudo de [Lopes, Mendes-Moreira e Gama \(2012\)](#) utilizou janelas de 6 segundos de dados, o pré-processamento aplicado foi a extração da média e as atividades identificadas para classificação foram: andar, correr, inatividade e sentar. Os autores implementaram um aplicativo *Android*, para registrar os dados do acelerômetro. Foram coletados dados de 3 pessoas, porém apenas o de 2 foram usados para a criação de modelos. Os classificadores empregados foram *Naive Bayes* e *Hoeffding Trees*, sendo que o primeiro se destacou por economizar memória e bateria.

Em [Kwapisz, Weiss e Moore \(2011\)](#), os dados foram divididos em janelas de 10 segundos, sendo obtidos 43 atributos considerados para a classificação de 6 atividades (caminhar, correr, subir escadas, descer escadas, sentar e permanecer parado). Os classificadores foram: árvore de decisão, regressão logística e redes neurais múltiplas, resultando em níveis elevados de precisão. Para as atividades mais comuns (caminhar e correr), os autores conseguiram precisão acima de 90%. A base utilizada no estudo foi a WISDM.

No estudo de [Anguita et al. \(2013\)](#) foram empregadas janelas deslizantes de 2,56 segundos com sobreposição de 50%, extraindo 561 atributos. Além do acelerômetro triaxial, serviram-se também do giroscópio e dos sensores ao longo do corpo. Para a classificação, 6 atividades humanas foram consideradas (permanecer parado, sentar, deitar, caminhar, subir e descer escadas) e o modelo utilizado foi o SVM, que registrou uma precisão de 96% para os dados de teste. Os autores disponibilizaram, publicamente, um novo conjunto de dados para RAH usando *smartphones*. E, quanto à complexidade computacional, a duração de bateria e o processamento em tempo real para a aplicação foram aspectos levantados pelos autores para posterior avaliação.

Em [Sun et al. \(2010\)](#), foi utilizado o sensor de acelerômetro triaxial e foram reconhecidas 7 atividades humanas (permanecer parado, andar, correr, pedalar, descer escadas, subir escadas e dirigir). O tamanho da janela foi de 1 segundo, sendo obtidos 22 atributos após o pré-processamento aplicado (média, variância, correlação, entropia no domínio da frequência, FFT energia). Os autores recorreram a uma aplicação *python* para coletar as informações do acelerômetro, 7 usuários participaram do estudo e os dados não foram disponibilizados publicamente.

Artigo	Usuários	Dados brutos	Dados pré-processados	Janela	Atributos	Classes	Sensores	Classificadores	Pré-processamento	Software
A Smartphone-based Activity Recognition System for Improving Health and Well-Being	-	Não	Não	10 segundos	43	Andar, correr, subir/descer escadas, permanecer parado e sentar/deitar	Acelerômetro triaxial	Random Forest	Média, desvio-padrão, distribuição binomial e uma medida heurística do período da onda	Actitracker
The Benefits of Personalized Smartphone-Based Activity Recognition Models	59	Não	Não	10 segundos	43	Permanecer parado, andar, correr e pular	Acelerômetro triaxial	Árvore de decisão, aprendizagem baseada em instâncias, redes neurais, regra de indução e regressão logística	Não se aplica	Actitracker
Activity Recognition from Accelerometer Data	2	Não	Não	256 exemplos com sobreposição de 50%	12	Permanecer parado, andar, correr, subir escadas, descer escadas, sentar, usar o aspirador de pó e escovar os dentes	Acelerômetro triaxial	Árvore de decisão, tabela de decisão, KNN, Máquinas de Vetor Suporte e Naive Bayes	Média, desvio-padrão, energia e correlação	-
Semi-supervised learning: predicting activities in Android environment	2	Não	Não	6 segundos	-	Andar, correr, inatividade e sentar	-	Naive Bayes e Hoefding Trees	Média	Aplicativo próprio
Activity Recognition using Cell Phone Accelerometers	29	Sim	Sim	10 segundos	43	Caminhar, correr, subir escadas, descer escadas, sentar e permanecer parado	Acelerômetro triaxial com orientação do dispositivo	Árvore de decisão, regressão logística e redes neurais múltiplas	Média, desvio-padrão, diferença média absoluta, aceleração resultante média, distribuição binomial, tempo entre picos nas ondas sinoidais	Aplicativo próprio

Tabela 2 – Estudo comparativo dos trabalhos desenvolvidos sobre RAH - 1

Artigo	Usuários	Dados brutos	Dados pré-processados	Janela	Atributos	Classes	Sensores	Classificadores	Pré-processamento	Software
A Public Domain Dataset for Human Activity Recognition Using Smartphones	30	Não	Sim	2,56 segundos com sobreposição de 50%	561	Permanecer parado, sentar, deitar, caminhar, subir escadas e descer escadas	Acelerômetro triaxial	SVM	Média, desvio-padrão, valor absoluto médio, valores maiores em conjunto, média da soma dos quadrados, coeficiente de correlação, ângulo entre dois vetores, dentre outros	-
Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations	7	Não	Não	1 segundos	22	Permanecer parado, andar, correr, pedalar, descer escadas, subir escadas e dirigir	Acelerômetro triaxial	SVM	Média, variância, correlação, entropia no domínio da frequência, FFT energia	Aplicativo próprio
Human Activity Recognition from Accelerometer Data Using a Wearable Device	14	Sim	Não	1 segundo com sobreposição de 50%	319	Escadas, caminhar, conversar, permanecer parado e trabalhar no computador	Acelerômetro localizado no peitoral	Random Forest	Média, desvio-padrão, obliquidade ou assimetria, medida de dispersão, correlação, energia etc	-

Tabela 3 – Estudo comparativo dos trabalhos desenvolvidos sobre RAH - 2

2.6 Bases de dados disponíveis

Existem diversos trabalhos disponíveis acerca do tema RAH, em contrapartida, poucas dessas bases de dados são disponibilizadas (PAIVA, 2014). Para a criação da base WISDM (KWAPISZ; WEISS; MOORE, 2011), foram utilizadas janelas de 10 segundos, das quais foram extraídas 43 atributos e 6 classes (caminhar, correr, subir escadas, descer escadas, sentar e permanecer parado), 36 pessoas portando *smartphones* com sensor de acelerômetro triaxial participaram da coleta de dados. A aceleração registrada inclui, ainda, a aceleração gravitacional na direção do centro da Terra, podendo detectar a orientação do dispositivo móvel. A base disponibiliza os dados brutos e os dados processados.

Human Activity Recognition Using Smartphones Data Set (ANGUITA et al., 2013) é uma base de dados que foi criada a partir da coleta de dados de 30 pessoas, utilizando *smartphones* com sensores inerciais embutidos. Para cada registro é fornecido: a aceleração triaxial do acelerômetro, a aceleração estimada do corpo, a velocidade triaxial angular do giroscópio, um vetor de atributos, o rótulo da atividade e a identificação do usuário. Os dados brutos e processados foram disponibilizados.

Activity Recognition Challenge Data set (ANGUITA et al., 2013) tem 110 atributos e 4 classes. Compreende 72 sensores de 10 modalidades, integrados no ambiente, nos objetos e no corpo, foram coletados dados de 4 usuários. A base de dados disponibiliza apenas os dados já processados, sendo 6 arquivos para cada usuário.

A base *Activity Recognition*, disponibilizada pela *UCI Machine Learning Repository* (2016), tem 16 atributos e 6 classes de atividades, com dados obtidos de diferentes dispositivos: 4 *smartwatches* (2 relógios LG e 2 *Samsung Galaxy Gears*) e 8 *smartphones* de marcas e modelos distintos. Foi utilizado o sensor de acelerômetro com giroscópio. Os dados foram coletados em cenários diversos para tratar a heterogeneidade esperada no “mundo real”. Os dados brutos são disponibilizados. O arquivo de dados identifica o usuário e qual dispositivo foi empregado para a coleta.

E a *REALDISP Activity Recognition Dataset*, também disponibilizado pela *UCI Machine Learning Repository* (2016), é composta por 120 atributos e 33 classes. Apenas dados brutos são disponibilizados. O arquivo de dados identifica a atividade realizada, mas não o usuário. Diferentes sensores foram utilizados: acelerômetro triaxial, giroscópio, orientação do campo magnético 3D e *quaternions* 4D.

Por fim, a base *Activity Recognition from Single Chest-Mounted Accelerometer Data set* é composta apenas pelos dados brutos da coleta de dados de 15 usuários, com acelerômetros instalados no peitoral. São divididas em 7 classes de atividades, sendo: trabalhar no computador, levantar/ andar/ subir escadas, em pé, andar, abaixar/descer escadas, caminhar e conversar com alguém, em pé e conversando com alguém.

As tabelas 4 e 5 resumizam essas informações.

Nome	Site	Atributos	Atividades	Nº de Pessoas	Dados brutos	Dados pré-processados	Ferramenta de coleta	Janela
WISDM	http://www.cis.fordham.edu/wisdm/dataset.php	43	caminhar, correr, subir escadas, descer escadas, sentar e permanecer parado	36	Sim	Sim	Smartphone com Android, utilizando um aplicativo desenvolvido pelos pesquisadores, WISDM	10 segundos
Human Activity Recognition Using Smartphones Data Set	http://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones	561	6 atividades: permanecer parado, sentar, deitar, caminhar, subir escadas e descer escadas	30	Sim	Sim	Smartphone montado no pulso com sensores inerciais embarcados	Janelas de 2,56 seg e 50% de sobreposição
Activity Recognition Challenge - Dataset	http://www.opportunity-project.eu/challengeDataset	110	4 atividades: sentar, andar, permanecer parado e deitar	4	Não	Sim	15 sistemas de sensores em rede de diferentes origens. É composto por 72 sensores de 10 modalidades, integrados no ambiente, nos objetos e no corpo	-

Tabela 4 – Estudo comparativo das bases de dados disponíveis - 1

Nome	Site	Atributos	Atividades	Nº de Pessoas	Dados brutos	Dados pré-processados	Ferramenta de coleta	Janela
Heterogeneity Activity Recognition Data Set	https://archive.ics.uci.edu/ml/datasets/Heterogeneity+Activity+Recognition	16	pedalar, sentar, permanecer parado, caminhar, subir escada e descer escada	9	Sim	Não	<i>smartwatches</i> e <i>smartphones</i> com sensores de acelerômetro e giroscópio.	10 segundos
REALDISP Activity Recognition Dataset Data Set	https://archive.ics.uci.edu/ml/datasets/REALDISP+Activity+Recognition+Dataset	120	33 atividades diferentes	17	Sim	Não	31 smartphones, 4 smartwatches e 1 tablet, representando 13 modelos diferentes de 4 fabricantes, Android e iOS	1419 exemplos
Activity Recognition from Single Chest-Mounted Accelerometer Data Set	https://archive.ics.uci.edu/ml/datasets/Activity+Recognition+from+Single+Chest-Mounted+Accelerometer	Não se aplica (apenas dados brutos)	trabalhar no computador, levantar/ andar/ subir escadas, em pé, andar, abaixar/descer escadas, caminhar e conversar com alguém, em pé e conversando com alguém	15	Sim	Não	Acelerômetro instalado no peitoral	Não se aplica

Tabela 5 – Estudo comparativo das bases de dados disponíveis - 2

3 Proposta

3.1 Introdução

Este trabalho tem como objetivo estudar e caracterizar as principais ferramentas para reconhecimento de atividade humana utilizando sensor de acelerômetro. A tarefa de RAH envolve uma sequência de passos: coletar dados, realizar o pré-processamento, treinar um modelo de decisão capaz de classificar e, por fim, analisar e comparar os resultados.

Neste capítulo, será apresentada a forma como este trabalho foi desenvolvido, descrevendo cada etapa da tarefa de RAH. A seção 3.2 discute os detalhes da coleta de dados, quais fatores precisam ser definidos nessa fase e quais ferramentas são necessárias.

A seção 3.3 descreve a fase de pré-processamento, na qual é realizada a exclusão dos dados que não serão necessários e a padronização do arquivo em um formato pré-definido. Ao final desta etapa, será produzida uma base de dados, em um formato previamente definido, a ser utilizada na tarefa de RAH. Após essa etapa, a base passará pelo processo de classificação.

A seção 3.4 detalha a tarefa de classificação, que consiste em analisar o conjunto de dados e identificar a qual classe um determinado registro pertence. Nesta tarefa, o modelo analisa o conjunto de dados fornecidos como entrada (conjunto de treinamento), cada registro já contendo a indicação à qual classe pertence, de forma a aprender como classificar um novo registro ([CAMILO CáSSIO O.; SILVA, 2017](#)).

3.2 Coleta de dados

Para desenvolver um sistema de RAH, a primeira etapa a ser realizada é a coleta de dados. O primeiro passo, para realizar essa tarefa, é definir alguns fatores, tais como:

- Quantidade de pessoas que participarão do experimento;
- Idade e sexo dos participantes;
- Qual o sensor empregado para capturar os dados;
- Qual o aplicativo utilizado para obter os dados coletados pelo sensor.

Neste projeto, optou-se por avaliar o uso do sensor de acelerômetro, visto que se trata de um dispositivo pequeno, de baixo custo e comumente encontrado embutido em

smartphones, tablets e smartwatches. Além disso, tal sensor têm sido amplamente utilizado em trabalhos sobre RAH (SUN et al., 2010),(KWAPISZ; WEISS; MOORE, 2011) e (RAVI et al., 2005).

O sensor de acelerômetro é capaz de medir a aceleração em relação à gravidade, sendo que alguns deles são capazes, ainda, de medir a direção dessa aceleração (BENFICA, 2016).

Para coletar os dados do sensor de acelerômetro, é necessário instalar um aplicativo capaz de registrar as leituras obtidas. Na hora de escolher o *software* a ser utilizado, é preciso verificar algumas informações relevantes:

- Se o serviço é gratuito;
- O formato do arquivo gerado;
- Se o aplicativo salva as informações ou só é possível visualizar em tempo de execução;
- Se é possível nomear o arquivo ou se o salva automaticamente com um nome *default*;
- O local em que o arquivo é salvo;
- Se o aplicativo faz a leitura somente do sensor de acelerômetro ou do giroscópio também.

No capítulo 4, seção 4.2, será apresentado um estudo sobre os principais aplicativos disponíveis e as principais características de cada um.

Embora seja interessante realizar a coleta de dados e montar a própria base de dados para RAH, esta tarefa não foi realizada, pois seria necessária a aprovação do comitê de ética da Universidade Federal de Uberlândia, tarefa esta que demandaria muito tempo. Dessa forma, este trabalho foi realizado recorrendo apenas às bases de dados públicas descritas na seção 4.3.

3.3 Pré-processamento

A segunda etapa a ser realizada na tarefa de RAH é o pré-processamento dos dados coletados. Antes de extrair as características que darão origem aos atributos, é preciso eliminar dados irrelevantes e padronizar os arquivos.

Neste trabalho, foram eliminadas colunas consideradas desnecessárias à tarefa de RAH, como numeração de linhas e *timestamp* – marcador de tempo de cada registro – e mantidas apenas as colunas relativas à aceleração nos eixos X, Y e Z, além de Gx, Gy e Gz, que correspondem ao sensor de giroscópio nos eixos X, Y e Z, respectivamente, se estes estiverem disponíveis, e a classe.

Em geral, os dados são analisados em janelas com tipo e tamanho previamente escolhidos por quem realiza os testes. As janelas podem ser fixas ou deslizantes. A janela fixa terá um tamanho n definido e realizará a leitura de dados a cada n registros. Já a janela deslizante apresenta uma sobreposição de dados entre duas janelas consecutivas. A primeira janela contém os n primeiros registros (registro 1 até o registro n), na janela seguinte, o vetor voltará x registros - valor da sobreposição - e irá conter os próximos n registros. A figura 2 ilustra uma visão geral dos dois tipos de janelas.




Figura 2 – Tipos de janelas

De cada janela de registros são extraídas medidas estatísticas, que correspondem aos atributos usados na tarefa de classificação para RAH. Nesse projeto, as seguintes medidas foram calculadas: média, desvio-padrão, variância, maior, menor, energia, correlação, desvio médio absoluto, aceleração média resultante e distribuição binomial - as fórmulas utilizadas no algoritmo de pré-processamento estão detalhadas na Tabela 6. A escolha dessas medidas se deve ao fato de serem as mais utilizadas na literatura na extração de atributos para a classificação em RAH.

Nessa etapa, realiza-se, ainda, a reescala dos dados. No estudo em questão, foram encontrados dados negativos, positivos e fracionados, então, para obter melhores resultados e evitar a influência de atributos com grande intervalos de valores, utilizou-se a reescala dos dados para o intervalo $[0,1]$.

Diferentes trabalhos da literatura valem-se de diferentes conjuntos de atributos para a tarefa de RAH. Em busca de decidir qual conjunto de atributos obtém maior

Medidas	Fórmulas
Média	$x = \frac{\sum xi}{n}$
Desvio padrão	$S = \sqrt{\frac{\sum_{i=1}^n (xi - media)^2}{n - 1}}$
Variância	$S^2 = \frac{\sum_{i=1}^n (xi - media)^2}{n - 1}$
Maior	$if(maior \leq x) maior = x;$
Menor	$if(menor \geq x) menor = x;$
Energia	$E = \frac{\sum xi^2 }{n}$
Correlação	$corr(x, y) = \frac{cov(x, y)}{\Theta x \Theta y}$
Desvio médio absoluto	$\frac{1}{n} \sum_{i=1}^n (xi - m(x))$
Aceleração média resultante	$AvgRes = \frac{\sqrt{(xi^2 + yi^2 + zi^2)}}{n}$
Distribuição binomial	$Bd = \frac{maior - menor}{10}$

Tabela 6 – Fórmulas utilizadas para o pré-processamento dos dados

desempenho no processo de classificação, este trabalho propõe criar diferentes bases de dados, usando diferentes conjuntos de atributos e analisar o impacto da escolha dos atributos no desempenho do classificador. A seção 4.4, do capítulo 4, discute quais subconjuntos de atributos são mais indicados para o RAH.

Este trabalho disponibilizará, ainda, o código-fonte do conjunto de técnicas implementadas para o pré-processamento dos dados.

3.4 Classificação

Neste trabalho, o *software* utilizado para executar a tarefa de classificação foi o Weka, como nos trabalhos de [Ravi et al. \(2005\)](#), [Lopes, Mendes-Moreira e Gama \(2012\)](#), [Lockhart e Weiss \(2014\)](#) e [Kwapisz, Weiss e Moore \(2011\)](#). O Weka é um produto da Universidade de Waikato (Nova Zelândia), implementado em Java, e contém uma GUI para interagir com arquivos de dados e produzir resultados visuais. O *software* é uma coleção de algoritmos de aprendizagem de máquina e ferramentas de pré-processamento de dados. Ele fornece suporte extensivo para todo o processo de mineração de dados experimentais, incluindo a preparação dos dados de entrada, a avaliação estatística dos esquemas de aprendizagem e o resultado da aprendizagem ([WITTEN et al., 2016](#)).

Para a condução dos experimentos realizados, foram utilizados os seguintes classificadores: *Naive Bayes*, *Árvore de Decisão -J48* e *K-Nearest Neighbors* (KNN). As configurações adotadas no Weka foram as padrões.

3.5 Metodologia e Medidas de Validação

A metodologia mais utilizada em RAH, para dividir os dados em conjuntos de teste e conjuntos de treinamento, é a validação cruzada de 10 pastas ([RAVI et al., 2005](#)); ([SUN et al., 2010](#)); ([LOCKHART; WEISS, 2014](#)); ([KWAPISZ; WEISS; MOORE, 2011](#)). Nesse método, os dados são divididos em 10 partições de igual tamanho. Durante cada execução, uma das partições é escolhida para teste e o restante é utilizado para treinamento. O procedimento é repetido até que todas as partições tenham sido usadas para testes uma vez ([TAN et al., 2006](#)). O resultado é obtido pela média dos dez casos. Neste trabalho, optou-se por recorrer a tal estratégia para dividir em treinamento e teste as bases de dados usadas .

A medida de validação mais utilizada na literatura para o RAH é a acurácia ([RAVI et al., 2005](#)); ([WEISS et al., 2016](#)); ([LOPES; MENDES-MOREIRA; GAMA, 2012](#)); ([LOCKHART; WEISS, 2014](#)); ([KWAPISZ; WEISS; MOORE, 2011](#)). No entanto, a matriz de confusão gerada por meio dos dados da base de teste também tem sido amplamente buscada ([ANGUITA et al., 2013](#)); ([RAVI et al., 2005](#)); ([SUN et al., 2010](#));([LOCKHART; WEISS, 2014](#)); ([KWAPISZ; WEISS; MOORE, 2011](#)). Portanto, além da acurácia, este trabalho também propõe analisar o desempenho de um classificador por meio da análise de sua matriz de confusão, acurácia média, precisão e revocação.

3.6 Construção do site

A ideia da construção de um site, surgiu em razão da importância do Reconhecimento de Atividade Humana e da sua aplicabilidade em diferentes problemas do mundo

real. Ao propor um estudo das ferramentas e bases de dados disponíveis, assim como os atributos e algoritmos de mineração utilizados para realizar esta tarefa, considerou-se interessante divulgar os resultados encontrados, de forma a auxiliar futuros pesquisadores. No site, serão disponibilizados as seguintes informações:

- Código-fonte para pré-processamento dos dados, desenvolvido na linguagem Java;
- Estudo sobre os aplicativos disponíveis para smartphones que realizam a coleta de dados do sensor de acelerômetro;
- Indicação das principais bases de dados públicas disponíveis;
- Estudo sobre os experimentos realizados envolvendo diferentes conjuntos de atributos e indicação sobre os conjuntos que evidenciam os melhores resultados.

O site encontra-se disponível no seguinte endereço:

<http://rah-com-acelerometro.webnode.com/>

4 Desenvolvimento

4.1 Introdução

Nos capítulos anteriores, foram apresentados os trabalhos relacionados ao tema proposto nesta pesquisa e a forma como esta foi conduzida. Este capítulo irá descrever os experimentos realizados e discutir os resultados obtidos.

Primeiramente, será apresentado um estudo comparativo dos aplicativos testados para realização da coleta de dados do sensor de acelerômetro. Após, serão descritas as bases de dados utilizadas na execução dos experimentos. Para o desenvolvimento deste projeto, optou-se por buscar bases públicas disponíveis na Internet. Embora muitos trabalhos sejam desenvolvidos sobre o RAH, poucas bases são disponibilizadas. Muitos autores serviram-se de bases de dados particulares, dificultando a comparação de resultados por meio da reprodução de experimentos.

Em seguida, serão descritos os experimentos realizados e as configurações utilizadas para execução dos mesmos. Por fim, será apresentada uma discussão sobre os resultados obtidos anteriormente e as considerações finais.

4.2 Estudo comparativo dos aplicativos para coleta de dados

Um dos objetivos deste trabalho é fornecer direcionamentos e auxiliar novas pesquisas em RAH. Uma das importantes etapas dessa tarefa é a coleta de dados. Existem diversos aplicativos disponíveis para dispositivos móveis, gratuitos ou pagos, que realizam a leitura dos dados de sensores de acelerômetro. Portanto, é imprescindível identificar suas principais características, vantagens e desvantagens, a fim de possibilitar a escolha do melhor aplicativo em estudo. A tabela 6 expõe um estudo comparativo para avaliar alguns dos aplicativos mais utilizados.

Neste estudo, testou-se apenas aplicativos para a plataforma *Android*, pois é a plataforma comumente utilizada na literatura para coleta de dados com sensor de acelerômetro. Foram avaliadas questões como: gratuidade, formato do arquivo e possibilidade de nomeá-lo antes de salvar as informações.

Foram testados dois aplicativos homônimos chamados *Accelerometer* e um terceiro chamado *Accelerometer Analyzer*. A principal desvantagem desses aplicativos é que eles não permitem nomear o arquivo antes de salvá-lo, dificultando assim o processo de rotular a atividade desempenhada pelo usuário. Os três aplicativos salvam as informações no cartão de memória, sendo que os dois primeiros usam o formato .csv e o último o formato

.txt. Uma das grandes vantagens formato .csv é a sua portabilidade. Ao final da leitura de dados, esses aplicativos informam o nome com o qual o arquivo foi salvo.

Simple Accelerometer é um aplicativo também gratuito, porém não salva as leituras realizadas, é possível apenas visualizar os dados em tempo de execução.

O *Accelerometer Pro* é um aplicativo pago, por esse motivo, não foi testado, porém, em sua descrição, é atestado que ele não exibe anúncios, gera gráficos e é possível coletar uma grande quantidade de dados.

O *AccDataRec* foi considerado o mais interessante, visto que se trata de uma aplicação gratuita com interface amigável, permite que o usuário nomeie o arquivo antes de começar a coleta de dados e é possível ainda interromper a leitura para depois dar continuidade. O formato utilizado pelo aplicativo para salvar as informações é o .txt.

Nome	Gratuito	Permite nomear?	Formato	Local de armazenamento
AccDataRec	Sim	Sim	.txt	Cartão de memória
Accelerometer	Sim	Não	.csv	Cartão de memória
Accelerometer Analyzer	Sim	Não	.txt	Cartão de memória
Accelerometer	Sim	Não	.csv	Cartão de memória
Simple Accelerometer	Sim	Não se aplica	-	Somente leitura em tempo real
Accelerometer Pro	Não	-	.csv	-

Tabela 7 – Estudo comparativo dos aplicativos de coleta de dados

Embora muitos trabalhos optem por criar suas próprias bases de dados usando tais aplicações, este trabalho optou por buscar bases de dados públicas. Uma das motivações para isso, é que a coleta de dados exigiria aprovação do comitê de ética dessa universidade, processo que demandaria tempo e atrasaria o projeto de TCC, que foi desenvolvido em um ano.

4.3 Bases de dados

Para os experimentos que serão detalhados a seguir, as seguintes bases foram utilizadas: WISDM (KWAPISZ; WEISS; MOORE, 2011) e Activity Recognition from Single Chest-Mounted Accelerometer Data Set (Chest) (CASALE; PUJOL; RADEVA, 2011). A primeira base foi escolhida por ter sido utilizada em um trabalho que serviu de fundamentação para a realização deste estudo, enquanto a segunda base foi escolhida por apresentar uma estrutura semelhante à primeira.

4.3.1 WISDM

A base de dados WISDM (KWAPISZ; WEISS; MOORE, 2011) é composta por dois arquivos, um com os dados brutos - coletados por sensores de acelerômetro - e o outro com os dados pré-processados.

O primeiro arquivo apresenta 1.098.207 exemplos, 36 ID's para diferenciar os usuários e 6 atividades para classificação. A disposição do arquivo é: *[user]*, *[activity]*, *[timestamp]*, *[x]*, *[y]*, *[z]*.

Onde:

- *User* = Identificação do usuário (ID);
- *Activity* = Atividade realizada pelo usuário, pode ser: *walking*, *jogging*, *sitting*, *standing*, *upstairs*, *downstairs*;
- *Timestamp* = marcador de tempo de cada leitura do sensor;
- *X*, *Y* e *Z* = Aceleração nos eixos x, y e z, respectivamente.

O segundo arquivo contém os dados após um pré-processamento, que transforma a leitura da aceleração dos eixos x, y e z em 46 diferentes atributos, gerando, assim, a base transformada (os dados não foram normalizados). Trata-se de um arquivo do tipo .arff (formato exigido pelo Weka), com os dados dos 36 usuários. Os autores utilizaram janelas de 200 exemplos de dados, equivalentes a 10 segundos de leitura do sensor de acelerômetro. Os atributos obtidos foram:

- *UNIQUE ID*: identificador exclusivo para cada tupla;
- *User*: número de identificação do usuário ao qual os dados pertencem;
- *X0 a X9*, *Y0 a Y9* e *Z0 a Z9*: frações de amostras que caíram dentro de cada bin;
- *XAVG*, *YAVG* e *ZAVG*: média da aceleração dos eixos x, y e z, respectivamente;
- *XPeak*, *YPeak* e *ZPeak*: aproximações da frequência dominante;
- *XABSOLDEV*, *YABSOLDEV* e *ZABSOLDEV*: desvio absoluto médio das médias de cada eixo;
- *XSTANDDEV*, *YSTANDDEV* e *ZSTANDDEV*: desvio padrão da aceleração dos eixos x, y e z;
- *Resultante*: é a raiz quadrada da soma dos valores de cada eixo ao quadrado;
- *Classe*: atividade que o usuário desempenhou.

Para a condução dos experimentos, foi utilizada o arquivo com os dados pré-processados e a base com os dados brutos, na qual foram aplicadas as técnicas de pré-processamento implementadas neste estudo.

4.3.2 Chest

A base de dados Chest (CASALE; PUJOL; RADEVA, 2011) apresenta 15 arquivos no formato .csv, sendo um para cada usuário que tenha participado da coleta de dados. A disposição do arquivo é: [nº sequencial], [x], [y], [z], [atividade]. Sendo que as atividades estão identificadas por números. São elas:

- 1. *Working at Computer;*
- 2. *Standing Up, Walking and Going up-down stairs;*
- 3. *Standing;*
- 4. *Walking;*
- 5. *Going Up-Down Stairs;*
- 6. *Walking and Talking with Someone;*
- 7. *Talking while Standing;*

Os autores não disponibilizaram uma versão pré-processada dessa base. Portanto, foi empregado o processamento implementado neste estudo para a extração de atributos.

4.3.3 Bases pré-processadas

Foram montadas diversas bases transformadas a partir das bases WISDM e Chest, adicionando e excluindo atributos, a fim de identificar quais atributos são mais relevantes para a tarefa de RAH. Foram utilizadas janelas de 200 exemplos, sem sobreposição, para realizar o pré-processamento dos dados.

A tabela 7 detalha cada pré-processamento empregado na criação das novas bases. Após a extração dos atributos, utilizou-se a função *Normalize* do Weka para realizar a normalização, resultando em valores no intervalo [0,1].

Nos experimentos, as bases foram identificadas da seguinte forma:

- Nome da base - Pré-processamento. Exemplo: WISDM-P1 (pré-processamento 1 aplicado aos dados brutos da base WISDM).

Os pré-processamentos P1 a P6 foram inspirados nos *papers* relacionados na seção 2.5 deste trabalho. Enquanto o P7 surgiu da observação que, em geral, a maioria dos trabalhos sobre RAH adotam as medidas de média e desvio padrão.

Base	Atributos
WISDM com pré-processamento dos autores (WISDM-P0)	Exclusiva para a base WISDM. Base com todos os atributos implementados pelos autores da base, exceto "Unique ID" e "User", sendo um total de 44 atributos
Pré-processamento 1 (P1)	Média, desvio padrão e distribuição binomial. Total de 9 atributos
Pré-processamento 2 (P2)	Média, desvio padrão, energia e correlação. Total de 12 atributos.
Pré-processamento 3 (P3)	Média, desvio-padrão, desvio médio absoluto, aceleração resultante média e distribuição binomial. Total de 13 atributos.
Pré-processamento 4 (P4)	Média, variância, correlação e energia. Total de 12 atributos.
Pré-processamento 5 (P5)	Média, variância, desvio padrão, maior, menor, distribuição binomial, desvio absoluto médio, resultante e correlação. Todos os atributos implementados no pré-processamento deste estudo. Total de 28 atributos
Pré-processamento 6 (P6)	Média, variância e correlação. Total de 9 atributos.
Pré-processamento 7 (P7)	Apenas média e desvio padrão. Total de 6 atributos.
Pré-processamento 8 (P8)	Maior, menor e média. Total de 9 atributos.

Tabela 8 – Bases de dados transformadas

4.4 Experimentos

Os experimentos conduzidos no presente projeto consistem em extrair diferentes conjuntos de atributos, a partir das bases de dados brutas, por meio da aplicação de medidas estatísticas distintas, gerando assim, diferentes bases de dados transformadas. A seguir, será avaliado o desempenho dos classificadores *Árvore de decisão*, *Naive Bayes* e *KNN*, em cada uma dessas bases.

O objetivo dos experimentos é analisar qual conjunto de atributos produz os melhores resultados e identificar qual o classificador resulta no melhor desempenho para o problema de RAH.

A metodologia empregada para a condução dos experimentos foi a validação cruzada de 10 pastas. Os parâmetros dos algoritmos de classificação foram configurados com os valores *default* do Weka.

A tabela 8 expõe os resultados de cada base transformada a partir da base WISDM, para cada um dos três classificadores, utilizando três medidas de validação: precisão (Prec.), revocação (Revoc.) - suas médias ponderadas por atividade - e a acurária. Foram analisadas, ainda, as matrizes de confusão geradas. Todas essas medidas foram descritas na seção 2.4 do capítulo 2. A tabela 9 apresenta os resultados obtidos para as bases transformadas a partir da Chest, e está disposta da mesma forma que a tabela anterior.

Árvore de Decisão - J48																		
	WISDM-P0		WISDM-P1		WISDM-P2		WISDM-P3		WISDM-P4		WISDM-P5		WISDM-P6		WISDM-P7		WISDM-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
Walking	72,20%	81,00%	91,20%	93,70%	91,80%	92,40%	91,00%	93,70%	92,10%	92,60%	91,40%	94,10%	91,60%	93,40%	91,20%	92,70%	87,60%	91,70%
Jogging	89,30%	93,10%	95,10%	96,40%	96,00%	96,80%	95,90%	96,50%	96,10%	96,80%	96,70%	96,80%	95,70%	96,80%	96,30%	96,70%	94,40%	96,30%
Sitting	93,50%	93,20%	96,50%	96,80%	97,40%	95,50%	96,50%	96,80%	97,00%	94,90%	95,20%	95,20%	97,00%	95,20%	97,40%	95,50%	96,50%	96,10%
Standing	93,10%	95,30%	98,00%	96,80%	97,60%	96,80%	97,20%	96,80%	96,80%	96,80%	96,80%	96,80%	96,50%	97,20%	96,90%	97,20%	95,20%	93,70%
Upstairs	40,40%	28,10%	67,80%	65,00%	67,40%	66,20%	68,50%	65,20%	66,10%	65,90%	67,80%	66,40%	67,40%	63,50%	65,60%	64,90%	61,40%	53,40%
Downstairs	30,10%	22,70%	63,70%	57,60%	64,20%	62,90%	63,40%	58,80%	64,80%	62,90%	66,10%	59,90%	65,20%	62,90%	65,20%	61,70%	61,40%	56,70%
Média ponderada	84,50%	84,90%	87,50%	87,90%	88,00%	88,10%	87,70%	88,10%	88,10%	88,10%	88,20%	88,50%	87,90%	88,20%	87,80%	87,90%	84,80%	85,50%
Acurácia	84,88%		87,91%		88,14%		88,05%		88,14%		88,48%		88,18%		87,95%		85,48%	
Naive Bayes																		
	WISDM-P0		WISDM-P1		WISDM-P2		WISDM-P3		WISDM-P4		WISDM-P5		WISDM-P6		WISDM-P7		WISDM-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
Walking	70,90%	89,40%	72,20%	81,00%	67,90%	88,30%	67,90%	93,10%	67,10%	89,50%	69,40%	90,40%	66,40%	90,90%	73,40%	87,00%	66,10%	90,20%
Jogging	90,70%	92,20%	89,30%	93,10%	86,20%	95,50%	90,60%	92,10%	87,40%	96,00%	88,20%	93,70%	86,90%	97,20%	91,30%	94,40%	86,50%	84,40%
Sitting	37,00%	16,60%	93,50%	93,20%	92,90%	88,40%	95,10%	92,90%	92,60%	88,70%	95,40%	92,60%	96,20%	88,40%	93,00%	90,40%	93,60%	93,90%
Standing	42,20%	19,90%	93,10%	95,30%	93,90%	84,60%	92,90%	92,90%	93,90%	85,00%	90,70%	92,90%	94,50%	88,50%	95,50%	92,10%	90,40%	96,40%
Upstairs	90,60%	94,40%	40,40%	28,10%	38,50%	16,40%	36,80%	12,20%	30,20%	9,70%	37,80%	15,20%	35,00%	8,30%	45,80%	31,00%	38,60%	19,00%
Downstairs	69,10%	81,70%	30,10%	22,70%	33,60%	9,00%	38,70%	12,90%	31,10%	9,20%	41,50%	15,30%	32,10%	6,50%	34,90%	21,00%	55,00%	13,80%
Média ponderada	71,10%	74,90%	71,60%	74,00%	69,20%	74,10%	70,90%	75,30%	68,00%	73,90%	71,10%	75,40%	68,50%	74,60%	73,90%	76,60%	70,60%	73,00%
Acurácia	74,92%		74,05%		74,07%		75,33%		73,92%		75,39%		74,56%		76,57%		72,99%	
KNN																		
	WISDM-P0		WISDM-P1		WISDM-P2		WISDM-P3		WISDM-P4		WISDM-P5		WISDM-P6		WISDM-P7		WISDM-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
Walking	81,00%	86,60%	93,50%	96,80%	95,00%	97,50%	94,10%	96,80%	94,30%	97,00%	94,00%	96,90%	94,80%	97,20%	94,90%	97,30%	89,90%	96,40%
Jogging	97,30%	97,20%	97,90%	98,40%	97,00%	97,40%	97,40%	98,20%	97,30%	97,50%	97,40%	98,00%	97,90%	97,90%	97,40%	97,90%	94,80%	97,20%
Sitting	44,00%	47,20%	99,30%	97,40%	97,10%	97,40%	98,40%	97,10%	96,50%	97,10%	98,10%	97,10%	97,70%	97,10%	97,70%	97,10%	99,00%	97,70%
Standing	39,40%	37,50%	98,40%	97,60%	98,00%	97,20%	98,00%	98,00%	96,40%	95,30%	97,30%	98,00%	97,20%	96,80%	98,00%	97,60%	97,60%	98,00%
Upstairs	94,30%	75,80%	78,40%	74,00%	82,10%	77,70%	79,60%	76,20%	81,30%	77,20%	77,90%	72,90%	82,50%	79,50%	81,60%	78,00%	70,90%	58,60%
Downstairs	91,60%	53,30%	74,50%	69,20%	80,70%	76,80%	77,00%	70,90%	80,00%	75,70%	76,30%	71,80%	80,80%	77,20%	81,30%	76,80%	70,10%	59,90%
Média ponderada	78,80%	78,30%	91,70%	91,90%	92,90%	93,10%	92,10%	92,30%	92,50%	92,70%	91,80%	92,00%	93,20%	93,30%	93,10%	93,20%	88,10%	88,80%
Acurácia	78,28%		91,25%		93,08%		92,34%		92,67%		92,02%		93,32%		93,20%		88,76%	

Tabela 9 – Comparação dos experimentos - WISDM

Árvore de Decisão - J48																
	Chest-P1			Chest-P2	Chest-P3		Chest-P4		Chest-P5		Chest-P6		Chest-P7		Chest-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
WorkingPC	92,00%	93,40%	91,60%	94,10%	92,00%	93,80%	92,00%	94,40%	91,20%	91,60%	91,90%	94,00%	92,00%	94,00%	91,80%	93,30%
Standing Up	40,00%	33,70%	34,50%	24,80%	44,70%	33,20%	38,50%	28,20%	33,10%	29,70%	36,40%	27,70%	36,50%	30,70%	34,50%	24,80%
Standing	61,10%	59,70%	62,20%	59,70%	61,10%	60,70%	63,50%	61,50%	60,70%	59,20%	62,30%	62,40%	61,60%	60,80%	58,70%	57,90%
Walking	82,60%	86,90%	82,50%	86,70%	83,20%	86,90%	82,80%	86,90%	83,10%	86,90%	84,20%	86,60%	83,60%	86,80%	80,80%	84,70%
Going Up/Down	44,50%	38,90%	42,40%	38,90%	42,10%	35,80%	45,60%	38,90%	39,30%	36,20%	46,40%	42,40%	45,00%	35,40%	43,20%	38,90%
Walking Talking	35,40%	23,00%	36,70%	26,20%	42,90%	33,30%	35,50%	26,20%	28,60%	20,60%	38,60%	27,00%	36,10%	23,80%	34,80%	25,40%
Standing Talking	73,50%	74,40%	77,30%	77,10%	77,20%	77,20%	77,90%	78,20%	71,50%	72,80%	78,50%	78,20%	73,80%	75,70%	75,30%	75,90%
Média ponderada	78,80%	79,70%	79,00%	80,00%	79,60%	80,40%	79,60%	80,60%	77,80%	78,40%	79,90%	80,70%	79,10%	80,00%	77,90%	78,80%
Acurácia	79,68%		80,01%		80,37%		80,15%		78,44%		80,1 8%		80,01%		78,82%	
Naive Bayes																
	Chest-P1		Chest-P2		Chest-P3		Chest-P4		Chest-P5		Chest-P6		Chest-P7		Chest-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
WorkingPC	60,60%	94,80%	67,00%	85,00%	60,10%	95,70%	70,10%	70,80%	61,80%	94,30%	70,10%	71,30%	57,30%	97,00%	65,00%	92,60%
Standing Up	18,50%	5,00%	0,00%	0,00%	14,30%	3,00%	11,80%	1,00%	14,70%	2,50%	0,00%	0,00%	0,00%	0,00%	7,20%	2,50%
Standing	50,00%	0,20%	0,00%	0,00%	50,00%	0,10%	10,00%	0,10%	100,00%	0,10%	0,00%	0,00%	18,20%	0,20%	50,00%	0,80%
Walking	70,00%	91,50%	50,60%	93,30%	71,00%	90,40%	41,20%	94,50%	68,00%	92,10%	41,20%	94,60%	73,40%	81,90%	69,10%	91,50%
Going Up/Down	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	12,50%	0,40%
Walking Talking	7,50%	4,80%	6,80%	4,80%	7,00%	4,80%	8,20%	6,30%	8,10%	6,30%	6,70%	4,80%	6,40%	4,00%	7,60%	4,00%
Standing Talking	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	34,80%	3,50%	0,00%	0,00%	0,00%	0,00%	43,30%	23,10%
Média ponderada	50,30%	62,20%	40,50%	58,40%	50,20%	62,30%	41,40%	52,80%	61,20%	62,50%	39,50%	52,90%	44,60%	60,70%	56,70%	63,80%
Acurácia	62,24%		58,39%		62,28%		52,78%		62,47%		52,93%		60,66%		63,75%	
KNN																
	Chest-P1		Chest-P2		Chest-P3		Chest-P4		Chest-P5		Chest-P6		Chest-P7		Chest-P8	
Classe	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.	Prec.	Revoc.
WorkingPC	94,60%	92,90%	92,30%	90,80%	94,70%	92,90%	91,90%	90,30%	92,60%	90,80%	90,70%	89,50%	95,70%	94,40%	94,40%	92,10%
Standing Up	38,30%	31,70%	30,10%	25,70%	37,50%	31,20%	24,20%	19,30%	27,60%	23,30%	24,20%	19,30%	50,00%	42,10%	36,80%	33,20%
Standing	61,10%	60,00%	56,90%	56,70%	61,50%	60,00%	54,40%	53,30%	54,00%	53,20%	53,50%	53,80%	65,60%	65,30%	62,20%	58,90%
Walking	82,90%	86,70%	84,00%	87,00%	83,00%	86,90%	80,90%	85,50%	81,50%	86,40%	82,00%	84,70%	85,30%	88,00%	80,90%	86,40%
Going Up/Down	48,20%	47,20%	41,10%	43,20%	47,80%	47,60%	37,60%	35,80%	37,60%	35,80%	39,90%	38,00%	51,70%	52,40%	43,90%	46,70%
Walking Talking	43,10%	42,10%	31,50%	31,00%	42,40%	42,10%	29,70%	34,10%	32,00%	31,70%	27,90%	30,20%	45,50%	47,60%	39,50%	38,90%
Standing Talking	73,00%	76,80%	71,90%	72,90%	73,10%	77,10%	70,70%	71,70%	68,70%	70,30%	68,40%	70,70%	77,00%	78,80%	72,80%	74,30%
Média ponderada	80,20%	80,40%	78,00%	78,10%	80,30%	80,40%	76,20%	76,50%	76,50%	76,80%	75,70%	75,90%	82,80%	82,90%	79,50%	79,50%
Acurácia	80,35%		78,11%		80,43%		76,49%		76,84%		75,95%		82,89%		79,51%	

Tabela 10 – Comparação dos experimentos - Chest

É possível observar que a base WISDM-P0, que contém os atributos implementados pelos autores da base, resultou nos piores resultados em relação à acurácia, precisão e revocação, utilizando os classificadores J-48 e o KNN. Enquanto, em relação aos atributos implementados neste estudo, a base WISDM-P8 apresentou o pior desempenho, para todos os classificadores avaliados.

Foram identificadas duas classes difíceis para as bases derivadas da WISDM, são elas: *Upstairs* e *Downstairs*. Enquanto, para as bases derivadas da Chest, as classes difíceis foram: *Standing Up*, *Standing*, *Going Up/Down* e *Walking Talking*. As referidas classes apresentaram os menores percentuais de precisão e revocação, o que pode ser explicado pela menor ocorrência de exemplos para tais atividades.

O desempenho obtido com a base Chest não foi tão satisfatório quando comparado aos resultados apresentados pela WISDM. De forma geral, é possível observar percentuais mais baixos de acurácia, precisão e revocação. Outrossim, o classificador *Naive Bayes* não foi capaz de identificar algumas classes de atividades presentes nas bases derivadas da Chest.

Em tempo, o classificador KNN apresentou os maiores percentuais de acurácia, tanto para a base WISDM quanto para a base Chest. O bom desempenho do referido classificador se manteve inclusive para as classes consideradas difíceis.

O pré-processamento P7 foi implementado para avaliar os resultados obtidos quando se utilizam apenas os atributos média e desvio-padrão. O desempenho observado foi satisfatório, sendo que, para os classificadores J-48 e *Naive Bayes*, a base WISDM-P7 resultou na maior acurácia. Enquanto, para o classificador KNN, a referida base só não superou a base WISDM-P6, na qual além da média e desvio padrão, utilizou-se também a correlação.

5 Conclusão

5.1 Contribuições

O trabalho em pauta apresenta as seguintes contribuições:

1. Estudo comparativo das ferramentas empregadas para registro das leituras de sensores de acelerômetro, e indicação da mais viável;
2. Estudo comparativo de alguns trabalhos já desenvolvidos para a tarefa de RAH, disponibilizando informações sobre como foram conduzidos;
3. Estudo comparativo das bases de dados públicas, como os dados foram coletados e de que forma os autores disponibilizaram-nos;
4. Detalhamento das etapas de um sistema de RAH e orientações sobre como elas devem ser conduzidas;
5. Indicação do conjunto de atributos mais indicado para o reconhecimento de atividade humana;
6. Indicação do classificador com melhor desempenho para o RAH, dentre os três que foram testados;
7. Disponibilização de um conjunto de técnicas para o pré-processamento dos dados coletados por sensores de acelerômetro;
8. Orientações e diretrizes para futuras pesquisas na área;
9. Disponibilização de um site com todas as informações obtidas ao longo da presente pesquisa.

5.2 Considerações finais e trabalhos futuros

Para o desenvolvimento de um sistema de RAH é preciso, primeiramente, decidir sobre a forma de aquisição dos dados, se a coleta será realizada ou se serão buscadas bases de dados públicas. Caso o autor opte por construir uma base de dados própria, o projeto deverá ser submetido ao comitê de ética, pois envolve pesquisa com seres humanos. Em contrapartida, se o autor optar por valer-se de bases de dados públicas, poderá encontrar algumas dificuldades acerca da disponibilização das mesmas, visto que além do fato de

nem todos os estudos divulgarem suas bases, algumas pesquisas tornam acessíveis apenas os dados pré-processados.

Caso a opção seja pela coleta de dados, é preciso, ainda, definir qual será o sensor utilizado. Nesta pesquisa é indicado o uso do acelerômetro, devido ao seu baixo custo e alta disponibilidade, visto que dispositivos como *smartphones*, *tablets* e *smartwatches*, já possuem o referido sensor incorporado. No entanto, é possível optar por comprar o sensor separadamente e instalar em partes específicas do corpo. Nesse caso, é imprescindível verificar a existência de um *software* capaz de realizar a leitura dos dados coletados, se não houver, faz-se necessário instalar um aplicativo compatível. Em contrapartida, se for utilizado o acelerômetro de um *smartphone*, por exemplo, realizou-se um estudo comparativo dos principais aplicativos disponíveis, no qual concluiu-se que o *AccDataRec* expôs as melhores características.

Após escolher a forma de coleta dos dados, é fundamental pensar no pré-processamento. Poucos trabalhos divulgam os algoritmos utilizados para a transformação dos dados. Todavia, este estudo disponibilizou um conjunto de técnicas para realizar extração de atributos das informações coletadas pelo sensor de acelerômetro. Ademais, após a execução de diversos experimentos com diferentes conjuntos de atributos, observou-se que a média e desvio padrão são suficientes para garantir um bom desempenho na classificação.

Por fim, após o pré-processamento, segue a tarefa de classificação. Nessa etapa, é importante definir quais classificadores serão adotados, além da metodologia e medidas de validação. Foi observado, neste estudo, que o classificador KNN resultou nos melhores desempenhos - dentre os três que foram testados-, para ambas as bases testadas, inclusive quando se trata das classes difíceis.

Como possíveis trabalhos futuros, é possível indicar:

- Trabalhar com fluxo contínuo de dados: consiste em um desafio não tratado neste trabalho, pois podem surgir mudanças na forma como o usuário desempenha suas atividades, ou, ainda, o surgimento de novas classes de atividade ao longo do tempo.
- Desenvolvimento de aplicativos de reconhecimento de atividade humana: a partir do resultado de classificação, desenvolver aplicativos que empreguem o RAH (monitoramento de idosos, monitoramento *fitness*, jogos etc).
- Testar mais bases de dados públicas: fazer outros experimentos para comprovar os resultados. Testar outros conjuntos de atributos, outros classificadores, diferentes metodologia e medidas de validação.

Referências

- AGGARWAL, C. C. *Data streams: models and algorithms*. [S.l.]: Springer Science & Business Media, 2007. v. 31. Citado na página 9.
- ANGUITA, D. et al. A public domain dataset for human activity recognition using smartphones. In: *ESANN*. [S.l.: s.n.], 2013. Citado 6 vezes nas páginas 10, 16, 20, 21, 24 e 31.
- BENFICA, A. *Celulares com acelerômetro – O que é?* 2016. Disponível em: <<https://www.telefonescelulares.com.br/celulares-com-acelerometro>>. Citado 2 vezes nas páginas 15 e 28.
- CAMILO CÁSSIO O.; SILVA, J. C. *Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas*. 2017. Disponível em: <http://www.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf>. Citado 3 vezes nas páginas 16, 17 e 27.
- CAMPOS, T. *Problemas de generalização*. 2017. Disponível em: <<http://www.vision.ime.usp.br/~teo/publications/qualificacao/node8.html>>. Citado na página 17.
- CARVALHO, L. Reconhecimento de movimento para validação de exercícios físicos executados por crianças em um exergame. 2014. Citado na página 14.
- CASALE, P.; PUJOL, O.; RADEVA, P. Human activity recognition from accelerometer data using a wearable device. *Pattern Recognition and Image Analysis*, Springer, p. 289–296, 2011. Citado 2 vezes nas páginas 34 e 36.
- CORREA, E. *Naive Bayes: Mineração de dados na prática*. 2017. Disponível em: <<http://www.devmedia.com.br/naive-bayes-mineracao-de-dados-na-pratica-revista-sql-magazine-110/27490>>. Citado 2 vezes nas páginas 16 e 17.
- DAVIES, N.; SIEWIOREK, D. P.; SUKTHANKAR, R. Activity-based computing. *IEEE Pervasive Computing*, IEEE, v. 7, n. 2, p. 20–21, 2008. Citado na página 13.
- EDUCAÇÃO., C. P. . *Computação Móvel e Ubíqua*. 2016. Disponível em: <<https://www.portaleducacao.com.br/informatica/artigos/26926/computacao-movel-e-ubiqua>>. Citado na página 13.
- GAMA, J. *Knowledge discovery from data streams*. [S.l.]: CRC Press, 2010. Citado na página 9.
- KWAPISZ, J. R.; WEISS, G. M.; MOORE, S. A. Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, ACM, v. 12, n. 2, p. 74–82, 2011. Citado 10 vezes nas páginas 9, 10, 15, 16, 20, 21, 24, 28, 31 e 34.
- LOCKHART, J. W.; PULICKAL, T.; WEISS, G. M. Applications of mobile activity recognition. In: ACM. *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*. [S.l.], 2012. p. 1054–1058. Citado 3 vezes nas páginas 10, 13 e 14.

- LOCKHART, J. W.; WEISS, G. M. The benefits of personalized smartphone-based activity recognition models. In: SIAM. *Proceedings of the 2014 SIAM International Conference on Data Mining*. [S.l.], 2014. p. 614–622. Citado 4 vezes nas páginas 10, 16, 20 e 31.
- LOPES, A.; MENDES-MOREIRA, J.; GAMA, J. Semi-supervised learning: predicting activities in android environment. In: *Workshop on Ubiquitous Data Mining*. [S.l.: s.n.], 2012. p. 38. Citado 3 vezes nas páginas 16, 21 e 31.
- PAIVA, E. R. d. F. *Detecção de novidade em fluxos contínuos de dados multiclasse*. Tese (Doutorado) — Universidade de São Paulo, 2014. Citado 2 vezes nas páginas 15 e 24.
- PLAY., G. *Free Walker Beta*. 2016. Disponível em: <https://play.google.com/store/apps/details?id=com.mvitsor.freewalker&hl=pt_BR>. Citado na página 14.
- PLAY., G. *Runtastic Squats Agachamentos*. 2016. Disponível em: <https://play.google.com/store/apps/details?id=com.runtastic.android.squats.lite&hl=pt_BR>. Citado na página 14.
- PLAY., G. *Smart Fall Detection*. 2016. Disponível em: <https://play.google.com/store/apps/details?id=com.fall&hl=pt_BR>. Citado na página 14.
- RAVI, N. et al. Activity recognition from accelerometer data. In: *Aaai*. [S.l.: s.n.], 2005. v. 5, n. 2005, p. 1541–1546. Citado 8 vezes nas páginas 9, 10, 13, 15, 16, 20, 28 e 31.
- SUN, L. et al. Activity recognition on an accelerometer embedded mobile phone with varying positions and orientations. *Ubiquitous intelligence and computing*, Springer, p. 548–562, 2010. Citado 10 vezes nas páginas 9, 10, 13, 14, 15, 16, 20, 21, 28 e 31.
- TAN, P.-N. et al. *Introduction to data mining*. [S.l.]: Pearson Education India, 2006. Citado 5 vezes nas páginas 9, 17, 18, 19 e 31.
- WEISS, G. M. et al. Actitracker: a smartphone-based activity recognition system for improving health and well-being. In: IEEE. *Data Science and Advanced Analytics (DSAA), 2016 IEEE International Conference on*. [S.l.], 2016. p. 682–688. Citado 5 vezes nas páginas 9, 10, 13, 20 e 31.
- WITTEN, I. H. et al. *Data Mining: Practical machine learning tools and techniques*. [S.l.]: Morgan Kaufmann, 2016. Citado 2 vezes nas páginas 16 e 31.