MARCO TÚLIO OLIVEIRA ABREU

Orientador: Saul Emanuel Delabrida Silva
Co-orientador: Thiago D'Angelo

# RECONHECIMENTO AUTOMÁTICO DE ATIVIDADES FÍSICAS COMPORTAMENTAIS UTILIZANDO UM ACELERÔMETRO

Ouro Preto
Dezembro de 2019

Universidade Federal de Ouro Preto
Instituto de Ciências Exatas
Bacharelado em Ciência da Computação

# RECONHECIMENTO AUTOMÁTICO DE ATIVIDADES FÍSICAS COMPORTAMENTAIS UTILIZANDO UM ACELERÔMETRO

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do grau de Bacharel em Ciência da Computação.

MARCO TÚLIO OLIVEIRA ABREU

Ouro Preto
Dezembro de 2019

A85r Abreu, Marco Túlio Oliveira.
Reconhecimento automático de atividades físicas comportamentais utilizando um acelerômetro [manuscrito] / Marco Túlio Oliveira Abreu – 2020.
46 f. : il., color., graf., tab.

Orientador: Prof. Dr. Saul Emanuel Delabrida Silva.
Coorientador: Prof. MSc Thiago D'Angelo

Monografia - Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Biológicas. Departamento de Computação.

1. Aprendizado do computador. 2. Saúde. 3. Exercícios físicos. I. Silva, Saul Emanuel Delabrida. II. D'Angelo, Thiago. III.Universidade Federal de Ouro Preto. IV. Título.

CDU: 004.85

Catalogação: sisbin@sisbin.ufop.br

UNIVERSIDADE FEDERAL DE OURO PRETO

FOLHA DE APROVAÇÃO

# Reconhecimento automático de atividades físicas comportamentais utilizando um acelerômetro

MARCO TÚLIO OLIVEIRA ABREU

Monografia defendida e aprovada pela banca examinadora constituída por:

Dr. SAUL EMANUEL DELABRIDA SILVA – Orientador
Universidade Federal de Ouro Preto

Thiago D'Angelo
Ms. THIAGO D'ANGELO – Co-orientador
Universidade Federal de Ouro Preto

Dr. PUCA HUACHI VAZ PENNA
Universidade Federal de Ouro Preto

Dr. RODRIGO FERNANDO BIANCHI
Universidade Federal de Ouro Preto

Ouro Preto, Dezembro de 2019

# Resumo

Este documento apresenta um processo de reconhecimento automático de atividades físicas comportamentais com os dados de um acelerômetro localizado no pulso de usuários. O dispositivo tem o seu uso voltado para portadores da doença diabetes, como uma alternativa para o acompanhamento de suas necessidades diárias. A funcionalidade de reconhecimento dessas atividades fornece informações chave para a criação de um sistema de recomendações visando as necessidades de uma pessoa com diabetes. Também foi realizado o desenvolvimento de um protótipo desse vestível com o objetivo de validar o processo de classificação proposto. Por fim, é levantada uma discussão em torno dos resultados obtidos a partir desse protótipo, principalmente no que diz respeito à reprodução das bases de dados públicas.

*Palavras-chave:* aprendizado de máquina, saúde, reconhecimento de atividades.

# Abstract

This paper presents a process used for automatic physical activity recognition with accelerometer data located on the user's wrist. The device has its use intended for people with diabetes as an alternative for keeping up with their daily needs. Activity recognition provides important information for creating a recommendation system intended for people with diabetes health. A prototype of this wearable device was developed to validate the recognition system. Finally, is presented a discussion about the obtained results with the prototype related to the public datasets reproducibility.

*Keywords: machine learning, health, activity recognition.*

# Dedicatória

*Dedico este trabalho primeiramente aos meus pais, que me apoiaram sempre durante esses anos de graduação principalmente nas horas de insegurança. Dedico também aos meus amigos que conheci na universidade, que sem eles todos os dias seriam apenas mais um dia vazio na universidade. Por fim, dedico também aos meus orientadores e contribuidores deste trabalho em que, sem eles, nada teria acontecido. Obrigado a todos!*

# Sumário

**Dedicatória** **iv**

**1 Introdução** **1**
1.1 Justificativa . . . 2
1.2 Objetivos . . . 2
1.3 Organização do Trabalho . . . 2

**2 Revisão da Literatura** **3**
2.1 Conceitos Fundamentais . . . 3
2.1.1 Árvores de Decisão . . . 3
2.1.2 *Random Forest* . . . 3
2.1.3 *K Nearest Neighbors* . . . 4
2.1.4 *Gaussian Naive Bayes* . . . 4
2.1.5 *Multilayer Perceptron* . . . 5
2.1.6 *Support Vector Machine (SVM)* . . . 5
2.2 *Gradient Boosting* . . . 6
2.3 Trabalhos Relacionados . . . 6

**3 Desenvolvimento** **13**
3.1 Representação dos dados . . . 13
3.2 Seleção da base de dados . . . 14
3.3 Pré-processamento . . . 15
3.4 Seleção de características . . . 15
3.5 Métricas de avaliação . . . 16
3.6 Modelos de classificação avaliados . . . 17
3.7 Especificações do protótipo . . . 18
3.8 Testes em tempo real do modelo treinado . . . 19

**4 Experimentos** **22**
4.1 Descrição dos experimentos iniciais . . . 22

4.2 Resultados iniciais . . . . . 22
4.3 Resultados . . . . . 24
4.4 Teste do modelo de classificação adaptado . . . . . 27
4.5 Discussão sobre os resultados . . . . . 29

**5 Conclusões** **36**

**Referências Bibliográficas** **37**

# Lista de Figuras


2.1 Representação de uma árvore de decisão para decidir se uma determinada pessoa deve jogar futebol. . . . . 4
2.2 Representação sintética de um *multilayer perceptron* com duas camadas ocultas, por Gardner e Dorling (1998). . . . . 5
2.3 Representação do objetivo do SVM linear. . . . . 6

3.1 Ferramenta de visualização das amostras desenvolvida. . . . . 14
3.2 Comparação de uma mesma amostra, antes e depois da aplicação do filtro de mediana. 15
3.3 Representação de parte do protótipo, correspondente à caixa contendo o acelerômetro e o *Arduino Nano*. . . . . 18
3.4 Representação geral do protótipo. . . . . 19
3.5 Foto do protótipo. . . . . 19
3.6 Foto do protótipo em uso. . . . . 19
3.7 Processo de concatenação das amostras. . . . . 20
3.8 Representação da formação das janelas. . . . . 20

4.1 Parte da amostra da atividade "escovar os dentes" extraída a partir do protótipo. . 27
4.2 Amostra da atividade "escovar os dentes" presente na base de dados utilizada. . . . 28
4.3 Histograma da Tabela 4.8. . . . . 29
4.4 Amostra da atividade "comer com um garfo" extraída a partir do protótipo. . . . . 31
4.5 Amostra da atividade "comer com um garfo" presente na base de dados utilizada. . 31
4.6 Histograma da Tabela 4.10. . . . . 32
4.7 Comparação entre o resultado da divisão de janelas entre as atividades "Descer escadas" e "Andar". . . . . 34

1 Representação gráfica de uma amostra da atividade *Andar* do *dataset* escolhido. . 39
2 Representação gráfica de uma amostra da atividade *Beber com um copo* do *dataset* escolhido. . . . . 40
3 Representação gráfica de uma amostra da atividade *Comer com um garfo* do *dataset* escolhido. . . . . 40

4 Representação gráfica de uma amostra da atividade *Comer com uma colher* do *dataset* escolhido. . . . . 41
5 Representação gráfica de uma amostra da atividade *Deita em uma cama* do *dataset* escolhido. . . . . 41
6 Representação gráfica de uma amostra da atividade *Descer escadas* do *dataset* escolhido. . . . . 42
7 Representação gráfica de uma amostra da atividade *Escovar os dentes* do *dataset* escolhido. . . . . 42
8 Representação gráfica de uma amostra da atividade *Levantar de uma cadeira* do *dataset* escolhido. . . . . 43
9 Representação gráfica de uma amostra da atividade *Levantar de uma cama* do *dataset* escolhido. . . . . 43
10 Representação gráfica de uma amostra da atividade *Pentear os cabelos* do *dataset* escolhido. . . . . 44
11 Representação gráfica de uma amostra da atividade *Sentar em uma cadeira* do *dataset* escolhido. . . . . 44
12 Representação gráfica de uma amostra da atividade *Servir água* do *dataset* escolhido. 45
13 Representação gráfica de uma amostra da atividade *Subir escadas* do *dataset* escolhido. . . . . 45
14 Representação gráfica de uma amostra da atividade *Usar o telefone* do *dataset* escolhido. . . . . 46

# Lista de Tabelas


2.1 Comparação de características utilizadas em cada pesquisa . . . . . 10
2.2 Comparação de modelos de classificação testados nas pesquisas. . . . . 11
2.3 Melhores resultados de acurácia apresentados em cada pesquisa. . . . . 12

4.1 Resultados obtidos (em porcentagem) para classificação das amostras do *dataset*. . 23
4.2 Resultados (em porcentagem) apresentados no trabalho de Bruno et al. (2012). . . 23
4.3 Resultados deste trabalho (em porcentagem) com o conjunto de métricas do trabalho de Bruno et al. (2012). . . . . 24
4.4 Resultados obtidos pelo modelo *Gradient Boosting* treinado na primeira etapa aplicado à classificação de janelas. . . . . 24
4.5 Matriz de confusão referente aos resultados obtidos pelo modelo *Gradient Boosting* treinado na primeira etapa aplicado à classificação de janelas. . . . . 25
4.6 Matriz de confusão referente aos resultados obtidos pelo modelo *Gradient Boosting* retreinado utilizando o processo de adaptação. . . . . 26
4.7 Resultados obtidos pelo modelo *Gradient Boosting* retreinado utilizando o processo de adaptação. . . . . 26
4.8 Resultados, por atividade, da classificação de uma amostra de "escovar dentes". . . 28
4.9 Comparação entre as características extraídas das amostras a partir do protótipo e as características extraídas a partir da base de dados a partir da atividade "escovar os dentes". . . . . 30
4.10 Resultados, por atividade, da classificação de uma amostra de "comer com um garfo". 32
4.11 Comparação entre as características extraídas das amostras a partir do protótipo e as características extraídas a partir da base de dados a partir da atividade "comer com um garfo". . . . . 33

# Capítulo 1

# Introdução

O diabetes, de acordo com Góes et al. (2007), é uma doença caracterizada pela baixa produção do hormônio insulina no organismo. Ainda de acordo com os autores, o tratamento da doença depende de vários níveis de atuação que dependem, principalmente, do doente. Nem sempre é possível seguir essas recomendações à risca, seja por descuidos ou esquecimento por parte do paciente e isso pode gerar uma série de complicações a longo prazo.

Já existem aplicativos voltados para a avaliação do comportamento dos diabéticos, como a pesquisa de Baldo et al. (2015). Esses métodos, porém, exigem do usuário conhecimentos específicos, que podem dificultar o uso da aplicação. Além disso, é necessário um engajamento constante do usuário para atualizar suas informações dentro do aplicativo, o que pode ser um problema.

Este documento apresenta o desenvolvimento de um sistema de classificação de atividades a partir de dados extraídos de um acelerômetro, fazendo o uso de aprendizado de máquina. O sistema tem como objetivo ser utilizado em uma aplicação para *smartwatch*, de forma que o usuário, diabético, não tenha a necessidade de atualizar o aplicativo sobre o que foi feito, ou o que está sendo feito. Neste trabalho, espera-se as seguintes contribuições:

- A seleção de um conjunto de características para realizar a classificação de atividades comportamentais a partir de dados de acelerômetro;
- A aplicação de um modelo treinado a partir das características selecionadas em cenários ideais, próximos dos reais e reais;
- Tentativa de replicar amostras da base de dados a partir de um protótipo;

Em paralelo a este projeto, está sendo realizada uma pesquisa visando a criação de um dispositivo vestível voltado para pacientes com diabetes. Esse dispositivo vestível, a partir das informações sensoreadas, irá fornecer ao usuário, um conjunto de recomendações personalizadas, que têm o objetivo de manter a saúde do usuário.

## 1.1 Justificativa

A criação de formas de alertar o usuário sobre suas tarefas é realizada de forma frequente. Diversos métodos, no entanto, necessitam de um engajamento por parte do usuário para atualizar periodicamente as atividades realizadas. Novas tecnologias, disponíveis no mercado, como os *smartwatches* são uma alternativa em potencial na solução deste problema, visto que a presença de sensores (acelerômetro) que permitem a classificação automática de atividades que sejam realizadas pelo paciente, removendo a necessidade dessa atualização constante dos dados do usuário.

## 1.2 Objetivos

Esta pesquisa tem, como objetivo principal, o estudo de métodos de classificação automática de atividades, utilizando apenas os dados fornecidos por um acelerômetro localizado no pulso dominante de um usuário. As atividades a serem classificadas neste trabalho se dividem em escovar os dentes, subir escadas, descer escadas, comer, beber, pentear os cabelos, levantar da cama, deitar na cama, servir água, sentar em uma cadeira, levantar de uma cadeira, usar o telefone e andar conforme o conjunto de dados *Dataset for ADL Recognition with Wrist-worn Accelerometer Data Set*. Como objetivos específicos para este trabalho, podem ser citados:

- O desenvolvimento de um *software* para realizar uma representação visual das amostras, com o objetivo de tornar possível uma classificação manual, caso seja necessário testar modelos mais complexos;
- Realizar uma comparação dos resultados obtidos aplicando métodos selecionados na literatura;
- Determinar um conjunto de atributos a serem extraídos das amostras, de forma que seja alcançada uma maior taxa de acurácia em pelo menos um dos modelos;

## 1.3 Organização do Trabalho

Este documento está organizado de acordo com o descrito neste tópico. O Capítulo 2 apresenta a revisão da literatura deste trabalho, com os trabalhos relacionados. O Capítulo 3 descreve, detalhadamente, toda a estratégia proposta para a solução do problema de classificação. A etapa de experimentação é apresentada no Capítulo 4, incluindo os resultados obtidos. Por fim, segue o Capítulo 5 com a conclusão e as considerações finais do trabalho.

# Capítulo 2

# Revisão da Literatura

## 2.1 Conceitos Fundamentais

Nesta seção serão apresentados, de forma objetiva, o conceito e o princípio básico de funcionamento de cada um dos algoritmos de aprendizado de máquina utilizados ao longo do desenvolvimento do trabalho.

### 2.1.1 Árvores de Decisão

A árvore de decisão, de acordo com Swain e Hauska (1977), é um classificador que se baseia na similaridade e em diversos estágios de decisões lógicas. De forma geral, este método é representado por diagramas de árvores onde cada nó representa uma decisão lógica e cada nó folha representa uma classe, ou um resultado. É válido ressaltar que uma árvore pode ser tão complexa quanto seja necessário, podendo realizar várias decisões antes de chegar a uma resposta concreta.

Considere a Figura 2.1 como um exemplo de uma árvore de decisão para uma pessoa hipotética decidir se deve ou não sair para jogar futebol na rua. Observa-se que na árvore apresentada, seriam consideradas características de interesse para o processo de classificação: condições climáticas (se está chovendo ou não) e a disposição do jogador (se está cansado ou não). Dessa forma, caso esteja chovendo e o jogador não esteja cansado, o classificador irá inferir que ele irá jogar.

### 2.1.2 *Random Forest*

*Random forest* é outro algoritmo que pode ser utilizado tanto para classificação como para regressão. De acordo com Breiman (2001), o *random forest* é uma combinação de preditores em árvores em que o seu resultado final depende de todas as árvores utilizadas.

De forma simplificada, pode-se considerar uma versão do *random forest* em que é feito o uso de árvores de decisão como os seus preditores em árvores. Durante o processo de treinamento

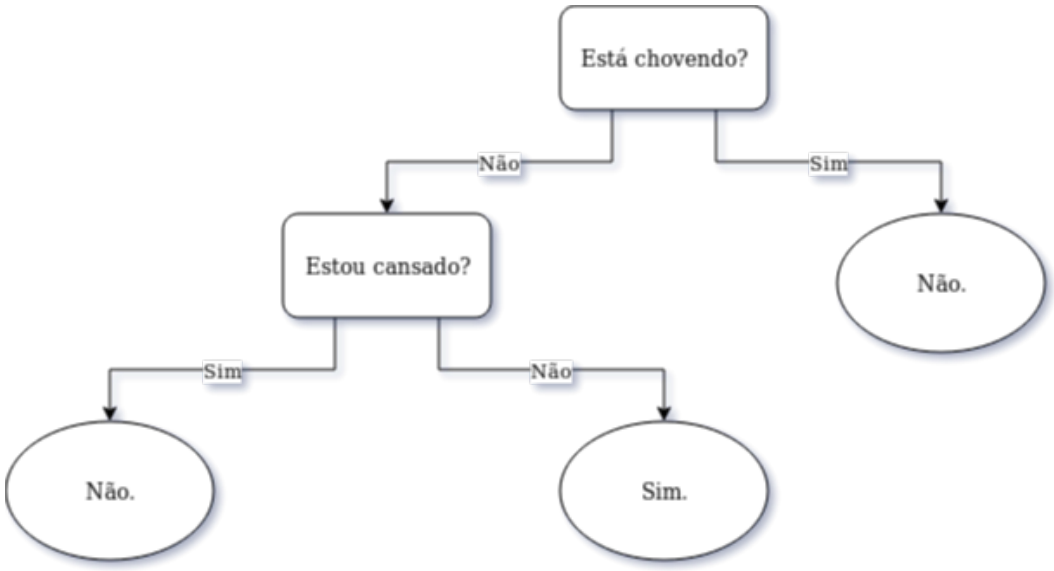


Figura 2.1: Representação de uma árvore de decisão para decidir se uma determinada pessoa deve jogar futebol.

do algoritmo, são geradas N árvores de decisão diferentes voltadas para um mesmo objetivo.

Em seu processo de classificação, podem ser adotadas diferentes formas de se atingir um resultado, um desses é a votação. Neste método, a partir do vetor de características de uma amostra são extraídos os resultados das N árvores de decisão, a partir disso, o resultado do *random forest* é dado pela moda dos resultados dessas árvores.

### 2.1.3 *K Nearest Neighbors*

O *k Nearest Neighbors* (KNN) é um algoritmo utilizável tanto para classificação como para regressão. Conforme a explicação de Alpaydin (1997) em seu artigo, o método KNN faz o seu processo de predição diretamente a partir de uma amostra.

A ideia por trás do KNN é, a partir de uma função de distância de uma amostra a ser classificada e demais amostras já rotuladas, é obtida uma vizinhança dos K vizinhos mais próximos à amostra em questão. A partir desses vizinhos rotulados, é realizada uma votação baseada em seus rótulos e, o rótulo mais recorrente é dado como o resultado da classificação.

A função de distância mencionada anteriormente se baseia nas características de uma dada amostra e podem ser utilizadas diferentes funções de distância, como a distância Euclidiana.

### 2.1.4 *Gaussian Naive Bayes*

*Naive Bayes* é um método utilizado para a construção de classificadores. O autor Rish et al. (2001) especifica que, a ideia do método é simplificar o aprendizado ao assumir que as características de uma determinada classe são independentes. Conforme a documentação

da biblioteca de aprendizado de máquina utilizada (*Scikit learn*, devido a sua simplicidade, esse tipo de modelo tem um tempo de execução menor se comparado com métodos mais sofisticados.

### 2.1.5 *Multilayer Perceptron*

O *multilayer perceptron* é uma rede neural artificial e que é frequentemente utilizado como alternativa aos tradicionais métodos estatísticos. De acordo com Gardner e Dorling (1998), o algoritmo considera os conceitos de neurons, camada de entrada, camada de saída e as camadas ocultas.

Um neuron, nesse contexto, é representado por um nó de um grafo contendo um conjunto de valores de entrada, uma saída e um conjunto de pesos. A saída desse neuron será dada a partir de uma função chamada de função de ativação que irá utilizar em seus cálculos o conjunto de entrada e de pesos. Dessa forma, conforme o resultado dessa função, o neuron pode ou não ser ativado. A Figura 2.2 apresenta um exemplo de rede neural artificial com duas camadas ocultas.

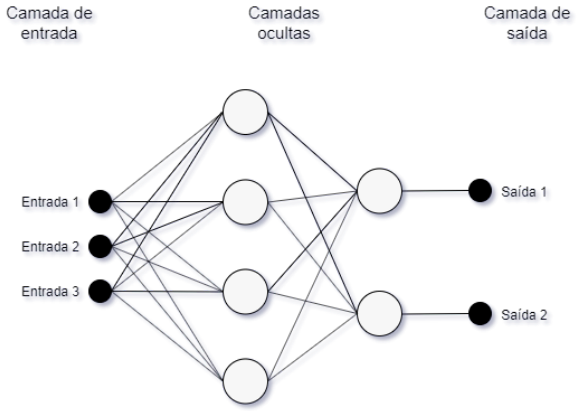


Figura 2.2: Representação sintética de um *multilayer perceptron* com duas camadas ocultas, por Gardner e Dorling (1998).

Como é possível observar, entre as camadas de entrada e saída estão as camadas ocultas - sendo que podem ser utilizadas tantas quanto forem necessárias. As camadas ocultas serão responsáveis por calcular, a partir da camada de entrada, o resultado na camada de saída. Desta forma, o processo de treinamento dessa rede neural consiste em modificar constantemente os pesos desses neurons, de forma a alterar os resultados das funções de ativação dos neurons.

### 2.1.6 *Support Vector Machine (SVM)*

*Support Vector Machine* é um dos métodos clássicos de aprendizado supervisionado que pode ser utilizado para classificação ou regressão. O objetivo principal deste modelo é a

obtenção de uma curva capaz de dividir as amostras de treinamento de forma adequada. É necessário ressaltar, no entanto, que nem sempre é desejada essa divisão exata, visto que esta pode configurar uma situação de *overfitting*, que é quando o modelo de classificação está ajustado em excesso para o conjunto de dados observado.

Na Figura 2.3 é apresentado um exemplo de execução do algoritmo SVM linear. A reta representa a limiar utilizada pelo SVM para classificar uma dada amostra, dividindo as amostras azuis para a esquerda e as vermelhas para a direita da reta. Na figura ainda são apresentados alguns indícios de erros (onde existem amostras que seriam classificadas incorretamente), representando as limitações de ser utilizada uma reta linear.

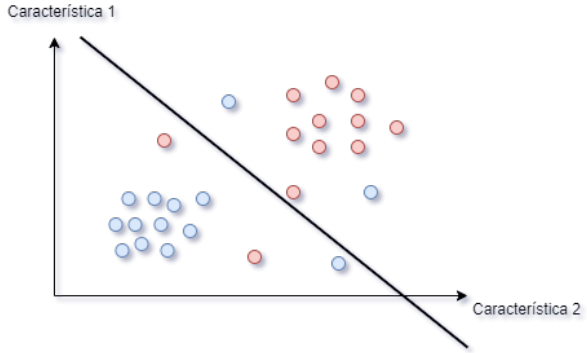


Figura 2.3: Representação do objetivo do SVM linear.

## 2.2 *Gradient Boosting*

O *Gradient boosting* é uma técnica de aprendizado de máquina que pode ser utilizada tanto em problemas de regressão como de classificação. Uma de suas principais características é que, semelhante ao *Random Forest* apresentado anteriormente, faz o uso de outros modelos de predição para atingir o seu resultado.

Conforme Friedman (2001), o algoritmo funciona de forma semelhante a métodos de otimização sendo o principal objetivo deste a minimização de uma dada função de perda - que pode representar, por exemplo, a taxa de erros do algoritmo. No algoritmo a partir de um modelo inicial simples, é realizado um cálculo dos erros e uma modificação do modelo por M iterações - sendo M um hiper-parâmetro. Ao final das iterações é obtido o modelo de classificação resultado do algoritmo.

## 2.3 Trabalhos Relacionados

O problema de classificação de atividades físicas é muito explorado e, em sua maioria, são resolvidos com técnicas de aprendizado de máquina. Em geral, os trabalhos podem ser

resumidos nas etapa das de coleta de dados, seleção de características e de treinamento dos modelos de classificação, com seus respectivos resultados.

Kwapisz et al. (2011) realizaram a tentativa de classificar atividades como sentar em uma cadeira, levantar de uma cadeira, caminhar, andar, subir e descer escadas utilizando apenas os dados de um acelerômetro no bolso dos voluntários. A partir dos dados obtidos, os autores optaram pela extração das características: média, desvio padrão, tempo entre picos e diferença média absoluta. Na pesquisa, as características foram utilizadas nos modelos de classificação: árvore de decisão, regressão logística e *multilayer perceptron* (MLP). Entre os modelos testados, o MLP obteve a maior acurácia, de 91,7%. Este trabalho, no entanto, não considera atividades que envolvam apenas os movimentos dos braços, o que dificulta sua aplicação no contexto desejado.

Bayat et al. (2014) realizou uma pesquisa em que o foco é a utilização exclusiva do acelerômetro de *smartphones* na coleta de dados. Na pesquisa, as atividades a serem classificadas foram: corrida, caminhada lenta, caminhada rápida, subir escadas, descer escadas e dançar. Neste caso, as características extraídas das amostras foram média, tempo entre picos, variância, valor eficaz, desvio padrão, valores de máximo e mínimo, para cada um dos três eixos do acelerômetro. A partir das atividades, ainda foi feita uma separação do conjunto de dados em relação a onde seria carregado o celular - nas mãos ou nos bolsos. Os classificadores utilizados nesta pesquisa foram *multilayer perceptron* (MLP), *support vector machine* (SVM), *random forest*, *logistic model tree*, logística simples, *logitboost* e ainda foi feita a tentativa de classificação com múltiplos classificadores o que, na maioria dos casos, aumentou a acurácia final. Apesar de possuir bons resultados, os métodos de coleta de dados utilizados (com o *smartphone* nas mãos ou no bolso) não são desejáveis no contexto almejado.

Seguindo os artigos que utilizam apenas dados de acelerômetro, temos a pesquisa de Yang et al. (2008). Em sua pesquisa, é feito o uso de redes neurais multicamadas para realizar a classificação das atividades, que se dividem em andar, correr, levantar, trabalhar no computador, escovar os dentes, sentar, utilizar aspirador de pó, limpar o chão. A partir das amostras são calculadas as seguintes características: média, correlação entre os eixos, energia, desvio padrão, variância, amplitude interquartil, desvio absoluto e valor eficaz. O uso da rede neural para a classificação destas atividades obteve uma acurácia geral de 95%. Apesar dos resultados satisfatórios, os acelerômetros foram colocados em cinco partes do corpo dos voluntários, tornando a coleta de dados inviável para o uso diário do equipamento.

No trabalho de Zhang et al. (2011) em adição aos dados obtidos do acelerômetro, foi também utilizado o sensor de eletromiografia (EMG), que de acordo com os autores, representa de forma direta o nível de atividade dos músculos. As características escolhidas para a classificação foram amplitude, média e desvio padrão para a aceleração e, para o EMG, desvio absoluto e um modelo autorregressivo. Por fim, para fazer a classificação árvores de decisão e o modelo oculto de Markov foram utilizados de forma conjunta para obter os resultados

finais, que correspondem a uma acurácia de 97,6%. Apesar dos bons resultados, neste caso os sensores de eletromiografia não são desejados, devido à falta de praticidade em seu uso diário.

Voltada para o reconhecimento de atividades diárias como andar, correr, levantar, subir escadas, descer escadas, aspirar e escovar os dentes, a pesquisa de Ravi et al. (2005) utilizou como características média, desvio padrão, energia e correlação. Na tarefa de classificação, foram testados os modelos árvores de decisão, Naive Bayes, *support vector machine*, *k-Nearest Neighbors*. Para os testes foram utilizadas quatro configurações variando a quantidade de indivíduos cujos dados foram coletados e se a coleta foi realizada durante um ou vários dias. O maior nível de acurácia atingido foi de 99,57%. Apesar dos bons resultados, o artigo comentou a dificuldade de classificar determinadas atividades que dependiam dos movimentos das mãos (considerando que o acelerômetro neste caso estava próximo da região pélvica), problema que possivelmente seria resolvido caso o acelerômetro fosse utilizado no pulso. Além disso, não foi apresentado no artigo a viabilidade de fazer essa classificação em tempo real (pelo contrário, já que foram utilizadas inúmeras camadas de software para a obtenção dos dados).

Os pesquisadores Sarcevic et al. (2015) propuseram o uso de sensores nos pulsos dos usuários para a classificação das atividades: levantar de uma cadeira, sentar em uma cadeira, andar, virar-se para uma direção, caminhar, levantar o braço esquerdo enquanto se levanta, levantar o braço, abaixar o braço e algumas outras atividades formadas pela combinação destas. No pulso do usuário, foram utilizados três sensores: acelerômetro, giroscópio e magnetômetro. A partir dos dados extraídos, foram utilizadas características temporais, apenas, sendo elas: desvio absoluto, número de vezes que passou pelo zero, quantidade de vezes em que a direção mudou, a altura do comprimento de onda para os três eixos dos sensores utilizados. Os classificadores testados neste caso foram o *multilayer perceptron* (MLP), *support vector machine* (SVM), estratégia de distância mínima e Naive Bayes. Na conclusão deste artigo é argumentada a dificuldade de se utilizar o SVM devido ao seu gasto imprevisível de memória, além de necessitar de muito tempo em sua etapa de treinamento. Esta solução porém, se torna inviável neste caso, já que são requisitadas atividades um pouco menos genéricas, que possam indicar uma possível ação diária do usuário.

Formas de aumentar a acurácia de determinados modelos também devem ser testadas, como é a pesquisa de Abbas et al. (2013). Na pesquisa, os autores constataram um aumento nas taxas de acurácia da classificação ao realizar uma remoção de ruídos dos dados sensoreados. No documento foram descritos testes de diversos algoritmos utilizados para remover dados considerados específicos (ou detalhes) da sequência de leituras, de forma que o modelo de classificação trabalhe com amostras mais genéricas. Nesse caso, o classificador final obteve uma acurácia de 97,5% em seus testes, demonstrando a sua relevância.

Na classificação de esportes também podem ser encontradas diversas etapas úteis no reconhecimento de atividades, mesmo que na prática não sejam exatamente iguais. O trabalho de Margarito et al. (2016) utiliza um acelerômetro no pulso do usuário a fim de realizar o processo

de classificação. Neste caso, os métodos de classificação propostos foram comparados com os seguintes: Naive Bayes, redes neurais, árvore de decisão e regressão logística, apesar de nenhum dos modelos propostos ultrapassarem a acurácia dos modelos estatísticos mencionados nos resultados apresentados. As características utilizadas no processo de treinamento foram média, variância, valores de máximo e mínimo, energia, assimetria, entropia, valor eficaz e os quantis (0.25, 0.50 e 0.75). Apesar das boas medidas de acurácia obtidas com os modelos estatísticos, apenas parte da metodologia da pesquisa pode ser testada.

Bruno et al. (2012), autores da base de dados a ser utilizada neste artigo, também realizaram pesquisas na área de classificação de atividades. Essa pesquisa, no entanto, fez uso de apenas um conjunto restrito de atividades, sendo elas subir escadas, levantar de uma cadeira, sentar em uma cadeira, servir água. Em sua etapa de preprocessamento, foi utilizado um filtro de mediana para a remoção de ruídos de alta frequência e, em seguida, um filtro Chebyshev I de quinta ordem, para fazer uma diferenciação da gravidade e da aceleração do corpo. As características utilizadas nesta pesquisa foram a gravidade e a aceleração do corpo, que foram utilizadas para alimentar os modelos *Gaussian Mixture Modelling*(GMM) e *Gaussian Mixture Regression*(GMR). Seus resultados foram apresentados como porcentagens de verdadeiros positivo (TP) e verdadeiros negativo (TN), variando seu método de utilização dos modelos. Para uma primeira abordagem, sua média de verdadeiros positivos é de 65,83% e de verdadeiros negativos é de 94,82%. Para uma segunda abordagem 79,17% foi a porcentagem média de verdadeiros positivos e 92,54% de verdadeiros negativos.

A seguir, são apresentadas três tabelas que resumem os principais pontos tratados nos artigos dos trabalhos relacionados. A Tabela 2.1 apresenta uma comparação de quais características foram utilizadas para cada um dos trabalhos relacionados e, ao final, é apresentada uma coluna indicando quais foram escolhidas para este trabalho. Na segunda tabela são apresentados, para cada trabalho, os modelos de classificação ou regressão utilizados em cada uma das pesquisas, ao final, são apresentados os escolhidos para esta pesquisa. Por fim, na Tabela 2.3, são apresentados os melhores resultados dentro do conjunto de modelos escolhidos. A falta de padronização nas bases de dados utilizadas, no entanto, dificultam a comparação dos métodos utilizados pelos autores.

| Autores | Kwapisz et al. | Bayat et al. | Yang et al. | Zhang et al. | Ravi et al. | Sarcevic et al. | Margarito et al. | Esta pesquisa |
|---|---|---|---|---|---|---|---|---|
| Média | ✓ | ✓ | ✓ | ✓ | ✓ | | ✓ | ✓ |
| Desvio Padrão | ✓ | ✓ | ✓ | ✓ | ✓ | | | ✓ |
| Tempo entre picos | ✓ | ✓ | | | | | | |
| Diferença Média Absoluta | ✓ | | | | | | | |
| Variância | | ✓ | ✓ | | | | ✓ | ✓ |
| Valor Eficaz | | ✓ | ✓ | | | | ✓ | ✓ |
| Máximo/Mínimo | | ✓ | | | | | ✓ | ✓ |
| Correlação | | | ✓ | | ✓ | | | ✓ |
| Amplitude interquartil | | | ✓ | | | | | |
| Desvio absoluto | | | ✓ | ✓ | | ✓ | | |
| Energia | | | ✓ | | ✓ | | ✓ | ✓ |
| Amplitude | | | | ✓ | | ✓ | | |
| Mudanças de Direção | | | | | | ✓ | | |
| Número de raízes zero | | | | | | ✓ | | |
| Mediana | | | | | | | | ✓ |
| Posição final | | | | | | | | ✓ |

Tabela 2.1: Comparação de características utilizadas em cada pesquisa

| Autores | Kwapisz et al. | Bayat et al. | Yang et al. | Zhang et al. | Ravi et al. | Sarcevic et al. | Margarito et al. | Esta pesquisa |
|---|---|---|---|---|---|---|---|---|
| Árvores de Decisão | ✓ | | | ✓ | ✓ | | ✓ | ✓ |
| Regressão Logística | ✓ | | | | | | | |
| *Multilayer Perceptron* | ✓ | | ✓ | | | ✓ | | ✓ |
| *Support Vector Machine* | | ✓ | | | ✓ | ✓ | | ✓ |
| *Random Forest* | | ✓ | | | | | | ✓ |
| *Logistic Model Tree* | | ✓ | | | | | | |
| Logística Simples | | ✓ | | | | | ✓ | |
| *Logiboost* | | ✓ | | | | | | |
| *Markov hidden models* | | | | ✓ | | | | |
| *Naive Bayes* | | | | | ✓ | ✓ | ✓ | ✓ |
| *k-Nearest Neighbors* | | | | | ✓ | ✓ | | ✓ |
| *Neural Networks* | | | | | | | ✓ | |
| *Gradient Boosting* | | | | | | | | ✓ |

Tabela 2.2: Comparação de modelos de classificação testados nas pesquisas.

| Autores | Acurácia |
|---|---|
| Ravi et al. | 0,996 |
| Zhang et al. | 0,976 |
| Sarcevic et al. | 0,970 |
| Kwapisz et al. | 0,917 |
| Bayat et al. | 0,897 |
| Margarito et al. | 0,850 |

Tabela 2.3: Melhores resultados de acurácia apresentados em cada pesquisa.

# Capítulo 3

# Desenvolvimento

Neste capítulo é feita uma descrição, em detalhes, do processo de desenvolvimento desta pesquisa. Em um primeiro momento, é apresentada a tentativa de criação de uma ferramenta para a representação visual dos gráficos. Em seguida, são apresentados os processos de seleção da base de dados, pré-processamento, seleção de características. A partir da quinta subseção é feita a apresentação das especificações do protótipo construído seguida de um detalhamento das etapas de extração de características.

## 3.1 Representação dos dados

Nesta etapa, o principal objetivo é o desenvolvimento de uma aplicação que possa representar visualmente os movimentos realizados pelo pulso do usuário a partir de leituras de um acelerômetro, em alternativa à representação gráfica.

O principal objetivo desta aplicação, em um primeiro momento, era criar uma forma de identificar ruídos em uma amostra (sequência de leituras de acelerômetro), de forma manual. A identificação de ruídos torna possível a realização manual de uma segmentação das leituras do acelerômetro, de forma a extrair apenas as sequências desejadas.

No *software*, foi utilizado o modelo 3D de um braço para representar o pulso do usuário e que passará por transformações geométricas de translação, apenas, com o objetivo de simular a movimentação do pulso do usuário, no momento da gravação da amostra.

Desta forma, a cada *frame*, o braço 3D recebe uma força de aceleração correspondente a uma leitura da amostra do acelerômetro. Os dados da amostra não foram modificados e o ambiente virtual da aplicação não considera a força da gravidade. A Figura 3.1 apresenta a visão geral desta ferramenta, onde eram exibidos dois modelos: o primeiro com a posição de seu pivô modificado para o pulso e o segundo com a posição padrão de seu pivô.

As amostras utilizadas nos testes foram gravadas a partir do acelerômetro de um *smartphone*, preso ao pulso de um usuário, que realizava movimentos simples - em uma fase posterior, foram realizados testes com amostras da base de dados escolhida. Como a amostra

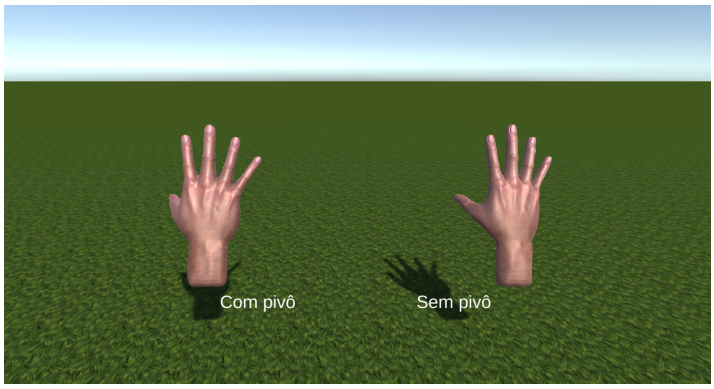


Figura 3.1: Ferramenta de visualização das amostras desenvolvida.

gerada possui apenas as informações de aceleração dos eixos, sem qualquer referência no espaço, não há uma forma simples de detectar a direção em que os movimentos foram realizados.

Apesar do problema mencionado, algumas atividades demonstraram um determinado padrão na forma como eram representadas e, em alguns casos, foi possível realizar a identificação manual da atividade em questão.

Mesmo obtendo alguns resultados, durante o processo de desenvolvimento, não foi feito o uso desta ferramenta de forma concreta, visto que foi encontrada uma base de dados, contendo dados extraídos de um acelerômetro vestido no pulso de um usuário e que possui um interessante conjunto de classes, visando o contexto em que se deseja aplicar esta pesquisa.

## 3.2 Seleção da base de dados

O conjunto de dados público utilizado foi o *Dataset for ADL recognition with wrist-worn accelerometer*, por Bruno et al. (2014), que possui dados extraídos do acelerômetro de um dispositivo utilizado nos pulsos de 16 voluntários. Essas amostras são de atividades como: escovar os dentes, subir escadas, pentear o cabelo, descer escadas, beber com um copo, comer com um garfo, comer com uma colher, levantar de uma cama, deitar em uma cama, servir água, sentar em uma cadeira, levantar de uma cadeira, usar o telefone e caminhar.

A escolha deste conjunto de dados se deve, principalmente, a presença das classes que envolvem o ato de beber ou comer, visto que o foco desta aplicação é ser utilizada em aparelhos voltados para pessoas com diabetes. Um dos pontos negativos do uso desta base de dados, no entanto, é o fato desta ser uma base de dados desbalanceada, ou seja, cada atividade possui uma quantidade de amostras muito diferente das demais. Além disso, a base de dados possui apenas 840 amostras ao todo, o que pode não ser suficiente considerando modelos de classificação probabilísticos.

No apêndice deste documento são apresentadas as Figuras 1 até 12, que representam algumas amostras disponíveis neste conjunto de dados - é apresentada uma amostra aleatória

para cada classe de atividade do conjunto. Nota-se, visualmente, as diferenças presentes entre as classes e, que em alguns casos, pode ser difícil fazer a classificação manual sem conhecer todos os dados da amostra.

## 3.3 Pré-processamento

Na etapa de pré-processamento dos dados, em ambos os experimentos (de ambiente controlado e de execução em tempo real), foi utilizado o filtro da mediana de ordem 3 para fazer uma redução do ruído presente nas amostras. Apesar de não remover o ruído totalmente, ainda é capaz de tornar as amostras mais genéricas e, nos testes, aumentou a precisão média do classificador. A Figura 3.2 mostra uma amostra antes e após o pré-processamento.

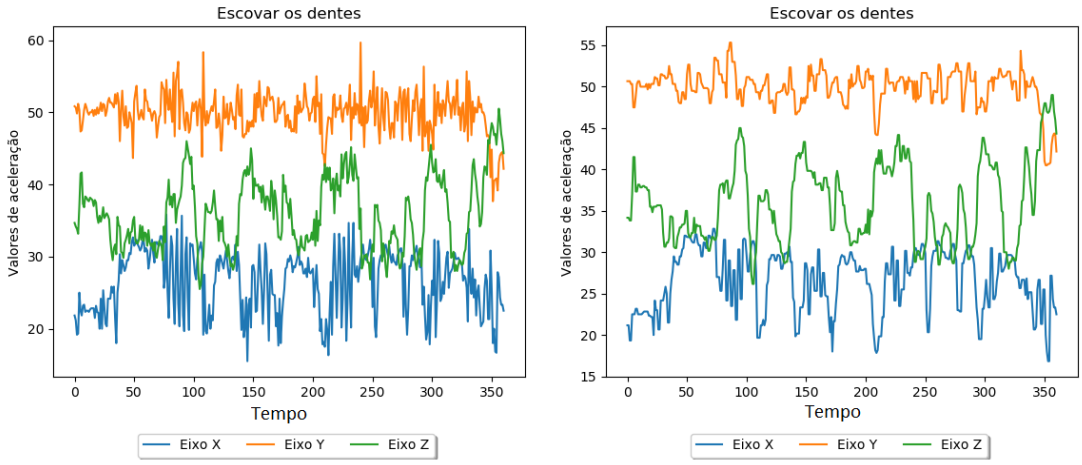


Figura 3.2: Comparação de uma mesma amostra, antes e depois da aplicação do filtro de mediana.

A Figura 3.2 representa uma mesma amostra, antes (esquerda) e depois (direita) da etapa de pré-processamento. O eixo Y dos gráficos representa os valores de aceleração mapeados no intervalo de 0 a 63. O eixo X, por outro lado, corresponde à quantidade de leituras presentes na amostra.

## 3.4 Seleção de características

Nesta etapa, o principal objetivo é a redução de dimensionalidade das amostras, sem perder os dados descritivos da atividade. Além disso, a imprevisibilidade do tamanho das amostras é outro fator que faz esta etapa necessária, visto a necessidade de escolher um conjunto fixo de valores a serem comparados durante o processo de classificação.

A seleção das características teve a maior parte de sua base na revisão da literatura, onde foram utilizados diferentes atributos. O cálculo dessas características faz o uso de um conjunto sequencial de leituras de acelerômetro, contendo os eixos x, y e z, para cada leitura. Segue abaixo a lista de atributos selecionados:

- Média dos valores de aceleração para cada um dos eixos do acelerômetro;
- Mediana dos valores de aceleração para cada um dos eixos do acelerômetro;
- Desvio padrão dos valores de aceleração para cada um dos eixos do acelerômetro;
- Variância dos valores de aceleração para cada um dos eixos do acelerômetro;
- Correlação entre os valores dos eixos X e Y do acelerômetro;
- Correlação entre os valores dos eixos Y e Z do acelerômetro;
- Correlação entre os valores dos eixos X e Z do acelerômetro;
- Valor de mínimo para cada um dos eixos do acelerômetro;
- Valor de máximo para cada um dos eixos do acelerômetro;
- Valor eficaz para cada um dos eixos do acelerômetro;
- Posição final do objeto aplicando, a cada segundo, os valores de aceleração a um objeto em repouso e localizado em X = 0, Y = 0 e Z = 0;

## 3.5 Métricas de avaliação

Nesta seção serão apresentadas as métricas de avaliação usadas na pesquisa, sendo elas a acurácia, a revocação e o *F1 score*.

A acurácia foi escolhida como métrica por representar, de forma resumida, a porcentagem de acertos do classificador. Dado um conjunto de predições, a acurácia representa a porcentagem de predições realizadas de forma correta, isto é, quando o rótulo real coincide com o rótulo previsto. Segue abaixo a forma de se extrair a acurácia A, dados os valores de verdadeiro positivo *TP*, verdadeiro negativo *TN*, falso negativo *FN* e falso positivo *FP*.

$$A = \frac{TP + TN}{TP + FN + TN + FP}$$

Outra medida que se mostrou interessante foi a revocação que, para cada classe, extrai a taxa de verdadeiros positivos, dado o conjunto de positivos original. A revocação se mostra interessante ao considerar a utilização do relógio, em que o pior caso seria realizar a classificação

$$R = \frac{TP}{TP + FN}$$

de uma atividade que não foi realizada. Segue abaixo a equação utilizada para o cálculo da revocação $R$, dados os números de verdadeiros positivos $TP$ e de falsos negativos $FN$.

O *F1 score* neste trabalho, foi utilizada como uma métrica voltada para o desempate entre os modelos de classificação. Este tipo de medida é dado pela média harmônica de precisão e revocação, desta forma, ela busca um meio termo entre essas duas métricas em seu resultado. Segue abaixo a equação utilizada para o cálculo do F1, para uma precisão $P$ e uma revocação $R$.

$$F1 = 2 * \frac{P * R}{P + R}$$

## 3.6 Modelos de classificação avaliados

Na escolha dos modelos de classificação a serem utilizados, foram considerados resultados de outras pesquisas que atingiram bons resultados com tarefas similares (classificação de atividades, em geral). A implementação desses modelos corresponde à biblioteca *Scikit Learn*, disponível para a linguagem de programação *Python*. Dentre os modelos testados nesta pesquisa e seus respectivos hiperparâmetros utilizados (os hiperparâmetros não apresentados equivalem aos valores padrão), temos:

- *Support Vector Machine (SVM):*
  - *kernel = linear;*
  - *random_state = 1;*
- *k-Nearest Neighbors (kNN):*
  - *n_neighbors = 6;*
- *Árvores de decisão:*
  - *random_state = 1;*
- *Random Forest:*
  - *n_estimators = 100;*
  - *random_state = 1;*

- *Naive Bayes;*
- *Gradient Boosting:*
  - *n_ estimators = 160;*
  - *random_ state = 1;*

Nesses testes, para a divisão da base em treino e teste, foi utilizada a classe *Kfold* da biblioteca *scikit*, que permite a realização de um processo semelhante ao *cross-validation*, em que o conjunto de dados é divido em K partes e, em cada iteração, uma parte é utilizada para validação e as restantes para treinamento. Para o experimento, foi considerada a constante K igual a 3. O processo de seleção de modelos de avaliação e os seus respectivos resultados serão apresentados mais detalhadamente na Seção 4.2.

## 3.7 Especificações do protótipo

Nesta seção serão apresentadas as especificações de um protótipo desenvolvido para a pesquisa. É de interesse que esse protótipo seja utilizado para verificar a viabilidade da utilização os modelos treinados a partir da base de dados selecionada.

A Figura 3.3 representa de forma simplificada a forma como o protótipo foi construído. A caixa utilizada nos pulsos possui um *Arduino Nano* e um acelerômetro MMA8452. O acelerômetro está posicionado de forma com que o eixo X esteja na reta entre o braço e o antebraço do usuário e o eixo Y apontando para a esquerda do usuário. Como é possível verificar, o artefato utilizado nos pulsos ainda não possui o *Raspberry*, visto que o seu tamanho pode prejudicar a forma como o usuário realiza os seus movimentos.

Figura 3.3: Representação de parte do protótipo, correspondente à caixa contendo o acelerômetro e o *Arduino Nano*.

A Figura 3.6 representa o protótipo como um todo, sendo a "Caixa contendo acelerômetro e Arduino" a parte correspondente à Figura 3.3 conectada via USB a uma caixa contendo um *Raspberry Pi*, que por sua vez é alimentado por um *Power Bank* via USB.

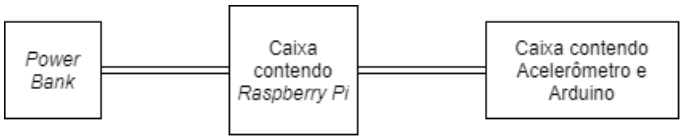


Figura 3.4: Representação geral do protótipo.

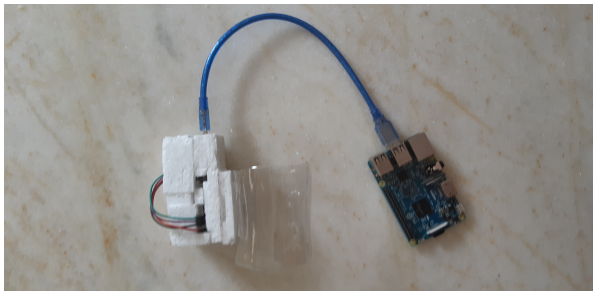

Figura 3.5: Foto do protótipo.

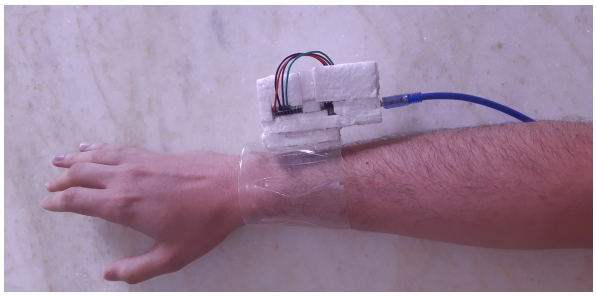

Figura 3.6: Foto do protótipo em uso.

## 3.8 Testes em tempo real do modelo treinado

Nesta seção é descrito o processo de adaptação do classificador para ser feita a tentativa de utilizá-lo com dados "reais" de um acelerômetro.

O modelo treinado até o momento tem como objetivo a classificação de atividades completas, ou seja, tendo o conhecimento de todas as leituras dessas atividades, do início ao fim. Por outro lado, considerando o contexto da aplicação final, ainda não é possível ter o conhecimento de quando uma atividade começa ou termina. Considerando essas informações, pode-se dizer que o classificador não foi treinado com o objetivo de ser utilizado na aplicação final.

Na aplicação, será considerada uma amostra, um segmento contínuo de leituras de um tamanho fixo N, que durante o documento, será chamado de janela.

Com o objetivo utilizar a base de dados de Bruno et al. (2014) para o treinamento do modelo de classificação, foi realizada uma concatenação de todas as amostras disponíveis nessa base. Nesse processo de concatenação, a ordem das amostras é embaralhada de forma aleatória. Na Figura 3.7, é feita uma representação gráfica desse processo de concatenação, sendo X, Y, e Z na amostra resultante responsáveis por demonstrar a aleatoriedade gerada na

ordem de concatenação.

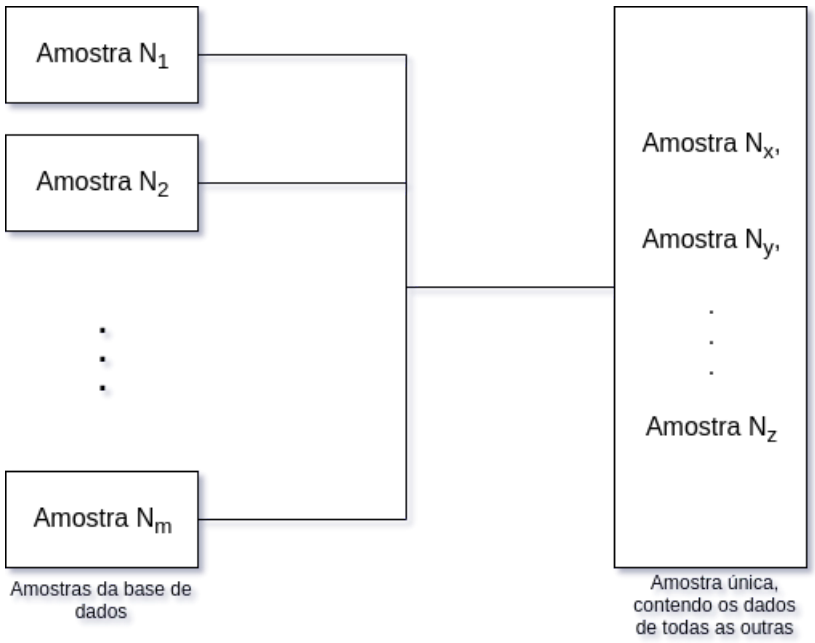


Figura 3.7: Processo de concatenação das amostras.

A partir desta amostra única, gerada pelo processo citado anteriormente, é feita uma geração de janelas. Essas janelas possuem um tamanho fixo N e ainda é aplicada certa redundância nas amostras iniciais e finais, de forma que o começo da próxima janela compartilhe o final da janela atual. Esse processo é representado na Figura 3.8, que apresenta melhor as constantes "tamanho de janela" S e o "tamanho de salto" T entre janelas. Na representação abaixo, temos os valores S=2 e T=1.

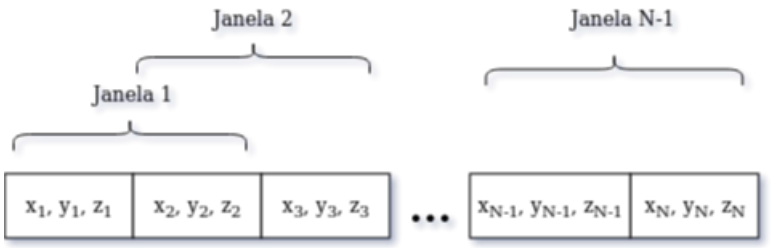


Figura 3.8: Representação da formação das janelas.

A partir desse processo, foi realizada uma tentativa de classificação dessas janelas fazendo o uso do modelo treinado na primeira etapa do desenvolvimento. Os resultados dos testes, que serão apresentados no Capítulo 4, se mostraram muito inferiores aos anteriores, o que trouxe a necessidade de uma reformulação do processo de treinamento do modelo. A adaptação adotada para o modelo de treinamento foi fazer o uso de janelas também para o processo de treina-

mento. Essa alteração trouxe resultados relativamente mais consistentes que os resultados obtidos anteriormente.

# Capítulo 4

# Experimentos

Neste capítulo serão apresentadas as estratégias utilizadas na etapa de experimentação deste trabalho, assim como os resultados obtidos nesses experimentos. Em um primeiro momento será feita a apresentação do que foi utilizado no processo para, em seguida, apresentar os experimentos e seus resultados.

## 4.1 Descrição dos experimentos iniciais

Na experimentação dos modelos de classificação, foi utilizada a função *KFold*, da própria biblioteca *Scikit Learn* para realizar a divisão das bases de treinamento e validação. Esta função dividiu o conjunto de dados em cinco partes e, dessa forma, é possível realizar cinco experimentos e, em cada um deles, utilizando uma parte diferente para validação (um processo semelhante à validação cruzada).

Em seguida é realizada a etapa de extração das características, já mencionadas no capítulo de desenvolvimento, para, enfim, realizar o treinamento do conjunto de dados, em cada iteração do *KFold*. Ao final de cada iteração, são extraídas as métricas de avaliação e, ao fim, é calculada a média dessas métricas para atingir o resultado final.

## 4.2 Resultados iniciais

Nesta seção são apresentados os resultados dos experimentos computacionais realizados para a pesquisa. Em um primeiro momento, serão apresentados os resultados de um ambiente controlado (onde são conhecidos os tempos de início e fim das atividades). Em seguida, serão apresentados os resultados obtidos para um ambiente semelhante ao real, onde as atividades ocorrem de forma imprevisível. No primeiro experimento, foram obtidos os resultados presentes na Tabela 4.2.

| **Classificador** | **Acurácia** | **Revocação** | ***F1 Score*** |
|---|---|---|---|
| *Support Vector Machine* | 83,70 | 83,54 | 83,07 |
| *K Nearest Neighbors* | 78,54 | 78,54 | 76,71 |
| *Árvore de Decisão* | 76,16 | 76,16 | 76,53 |
| *Random Forest* | 86,16 | 86,16 | 85,25 |
| *Naive Bayes* | 78,90 | 78,90 | 79,26 |
| *Gradient Boosting* | 86,17 | 86,17 | 85,34 |
| *Multilayer Perceptron* | 82,83 | 82,83 | 82,09 |

Tabela 4.1: Resultados obtidos (em porcentagem) para classificação das amostras do *dataset*.

Os valores apresentados foram extraídos a partir da matriz de confusão resultante do somatório das matrizes de cada iteração do *KFold*. A partir desses resultados, foram decididos quais seriam os classificadores testados para o próximo experimento, que se simula o comportamento do classificador para um ambiente real. Outra informação importante é que os dados de acurácia apresentados na tabela foram extraídos com a biblioteca *Scikit Learn*. De acordo com a documentação da biblioteca, sua extração de acurácia, para classificação multi-classe é considerada a porcentagem de rótulos previstos que coincidem com os originais.

| **Atividades** | **TP** | **TN** |
|---|---|---|
| Subir escadas | 83.34 | 87.14 |
| Beber com um copo | 93.34 | 94.29 |
| Sentar em uma cadeira | 60 | 98.75 |
| Levantar de uma cadeira | 80 | 90 |

Tabela 4.2: Resultados (em porcentagem) apresentados no trabalho de Bruno et al. (2012).

Na Seção 2 foi mencionado o trabalho de Bruno et al. (2012), realizado pelos autores da base dados utilizada para esse trabalho. No artigo, os autores apresentam resultados com as métricas de porcentagem de verdadeiros positivos e de verdadeiros negativos, para cada uma das abordagens utilizadas em seu processo de classificação. São apresentados, na Tabela 4.2, os resultados obtidos na pesquisa de Bruno et al. (2012), com as métricas de porcentagem de verdadeiros positivo (TP) e de verdadeiros negativo (TN).

Na tentativa de fazer uma comparação entre os dois trabalhos, foram realizados experimentos de classificação com apenas as classes da base de dados presentes no trabalho de Bruno et al. (2012), o trabalho não apresenta quais foram as amostras utilizadas e, desta forma, ainda não é possível ter uma comparação completa entre os dois resultados.

Neste experimento, foi utilizado o classificador com maior acurácia deste trabalho, o *gradient boosting*, e também foi utilizado o *KFold* (K=3) para fazer a divisão do conjunto de dados para as etapas de treinamento e validação. Os resultados obtidos são apresentados na Tabela 4.3.

| **Atividades** | **TP** | **TN** |
|---|---|---|
| Subir escadas | 97.03 | 98.68 |
| Beber com um copo | 98.0 | 99.34 |
| Sentar em uma cadeira | 90.82 | 96.41 |
| Levantar de uma cadeira | 90.48 | 97.66 |

Tabela 4.3: Resultados deste trabalho (em porcentagem) com o conjunto de métricas do trabalho de Bruno et al. (2012).

## 4.3 Resultados

Nesta seção foram apresentados os resultados dos experimentos descritos na Seção 3.8 que se relacionam ao processo de classificação das janelas como amostras. Para todos os experimentos desta seção as constantes "tamanho de janela" e "tamanho de salto entre janelas" foram considerados como 80 e 20, respectivamente.

Um primeiro teste teve como objetivo comprovar a ineficiência do uso dos modelos treinados na primeira etapa para a classificação dessas janelas. Os resultados desse teste são apresentados na Tabela 4.4. A matriz de confusão da Tabela 4.5 apresenta os resultados desse teste de forma mais detalhada, sendo que as linhas da matriz representam qual é o rótulo real e as colunas, o rótulo previsto pelo classificador.

| **Índice** | **Atividade** | **Precisão** | **Revocação** | **F1** |
|---|---|---|---|---|
| 0 | Escovar os dentes | 0.88 | 0.84 | 0.86 |
| 1 | Subir escadas | 0.23 | 0.71 | 0.34 |
| 2 | Pentear os cabelos | 0.95 | 0.29 | 0.44 |
| 3 | Descer escadas | 0.84 | 0.07 | 0.13 |
| 4 | Beber com um copo | 0.70 | 0.31 | 0.43 |
| 5 | Comer com garfo | 0.0 | 0.0 | 0.0 |
| 6 | Comer com colher | 0.0 | 0.0 | 0.0 |
| 7 | Levantar da cama | 0.11 | 0.0 | 0.0 |
| 8 | Deitar na cama | 0.0 | 0.0 | 0.0 |
| 9 | Servir água | 0.46 | 0.38 | 0.41 |
| 10 | Sentar na cadeira | 0.10 | 0.65 | 0.17 |
| 11 | Levantar da cadeira | 0.13 | 0.22 | 0.17 |
| 12 | Usar telefone | 0.47 | 0.04 | 0.08 |
| 13 | Andar | 0.0 | 0.0 | 0.0 |
| 14 | Atividade desconhecida | 0.0 | 0.0 | 0.0 |

Tabela 4.4: Resultados obtidos pelo modelo *Gradient Boosting* treinado na primeira etapa aplicado à classificação de janelas.

Os resultados, de forma geral, apresentaram baixas taxas de precisão, revocação e F1. Outro problema relacionado aos resultados está na sua inconsistência, visto a alta variância dos resultados, que estão no intervalo de 0,0% a 95%. Os problemas apontados reforçam a

| | **0** | **1** | **2** | **3** | **4** | **5** | **6** | **7** | **8** | **9** | **10** | **11** | **12** | **13** | **14** |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| **0** | 430 | 6 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 54 | 15 | 0 | 0 | 0 |
| **1** | 10 | 414 | 0 | 1 | 9 | 0 | 0 | 2 | 0 | 5 | 68 | 78 | 0 | 0 | 0 |
| **2** | 0 | 31 | 99 | 0 | 6 | 0 | 0 | 2 | 0 | 47 | 135 | 20 | 6 | 0 | 0 |
| **3** | 0 | 142 | 0 | 16 | 0 | 0 | 0 | 0 | 0 | 0 | 28 | 34 | 0 | 0 | 0 |
| **4** | 12 | 0 | 0 | 0 | 189 | 0 | 0 | 0 | 0 | 46 | 354 | 0 | 1 | 0 | 0 |
| **5** | 0 | 0 | 0 | 0 | 6 | 0 | 0 | 0 | 0 | 43 | 167 | 0 | 0 | 0 | 0 |
| **6** | 3 | 0 | 0 | 0 | 18 | 0 | 0 | 0 | 0 | 6 | 84 | 3 | 0 | 0 | 0 |
| **7** | 6 | 103 | 5 | 0 | 7 | 0 | 0 | 1 | 1 | 55 | 360 | 112 | 1 | 0 | 0 |
| **8** | 0 | 28 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 5 | 87 | 32 | 0 | 0 | 0 |
| **9** | 21 | 0 | 0 | 0 | 11 | 0 | 0 | 0 | 0 | 222 | 336 | 2 | 0 | 0 | 0 |
| **10** | 4 | 48 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 9 | 233 | 63 | 0 | 0 | 0 |
| **11** | 0 | 108 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 5 | 184 | 85 | 0 | 0 | 0 |
| **12** | 0 | 0 | 0 | 0 | 16 | 0 | 0 | 0 | 0 | 17 | 129 | 0 | 7 | 0 | 0 |
| **13** | 2 | 935 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 6 | 88 | 154 | 0 | 0 | 0 |
| **14** | 0 | 19 | 0 | 2 | 5 | 0 | 0 | 1 | 0 | 9 | 111 | 43 | 0 | 0 | 0 |

Tabela 4.5: Matriz de confusão referente aos resultados obtidos pelo modelo *Gradient Boosting* treinado na primeira etapa aplicado à classificação de janelas.

necessidade de uma adaptação do modelo treinado, como já foi apresentado no Capítulo 3. Na adaptação adotada, o modelo é treinado a partir de janelas extraídas da base de dados concatenada.

É importante ressaltar que a atribuição de rótulos às janelas demanda uma certa atenção, em vista de que uma janela pode conter leituras de mais de uma atividade - e que cada janela possui apenas um rótulo. Para esse tipo de caso, foi considerada uma porcentagem P mínima igual a 60% para que uma janela pudesse receber um determinado rótulo. Quando essa porcentagem P não é atingida pela atividade predominante da janela, o rótulo "atividade desconhecida" é atribuído àquela janela. Exemplificando, uma janela de 100 leituras de acelerômetro (com 59 leituras da atividade andar e 41 leituras da atividade escovar os dentes) seria classificada como "atividade desconhecida", visto que a atividade predominante "andar" não representa um valor maior do que 60 leituras.

Após o desenvolvimento do classificador adaptado, o mesmo teste utilizado na primeira etapa foi executado. Os resultados dos novos testes são apresentados na Tabela 4.6. A matriz de confusão apresentada na Tabela 4.7 demonstra os resultados obtidos de forma mais detalhada, tendo a sua formatação igual à apresentada anteriormente (linhas representando os rótulos originais e colunas os rótulos atribuídos pelo classificador).

Uma comparação entre os resultados das Tabelas 4.4 e 4.6 demonstra uma ligeira melhora nos resultados obtidos no processo de classificação dessas janelas. Considerando a métrica de acurácia, o primeiro teste obteve uma acurácia de 27% enquanto o segundo, de 61%.

Complementando os resultados anteriores, são apresentadas nas Tabelas 3.3 e 3.4 as ma-

| Índice | Atividade | Precisão | Revocação | F1 |
|---|---|---|---|---|
| 0 | Escovar os dentes | 0.90 | 0.90 | 0.90 |
| 1 | Subir escadas | 0.63 | 0.41 | 0.49 |
| 2 | Pentear os cabelos | 0.82 | 0.75 | 0.78 |
| 3 | Descer escadas | 0.86 | 0.76 | 0.81 |
| 4 | Beber com um copo | 0.50 | 0.69 | 0.58 |
| 5 | Comer com garfo | 0.33 | 0.20 | 0.25 |
| 6 | Comer com colher | 0.77 | 0.71 | 0.74 |
| 7 | Levantar da cama | 0.50 | 0.59 | 0.54 |
| 8 | Deitar na cama | 0.10 | 0.06 | 0.07 |
| 9 | Servir água | 0.65 | 0.70 | 0.68 |
| 10 | Sentar na cadeira | 0.36 | 0.35 | 0.35 |
| 11 | Levantar da cadeira | 0.42 | 0.29 | 0.35 |
| 12 | Usar telefone | 0.77 | 0.62 | 0.69 |
| 13 | Andar | 0.68 | 0.83 | 0.35 |
| 14 | Atividade desconhecida | 0.41 | 0.31 | 0.35 |

Tabela 4.6: Matriz de confusão referente aos resultados obtidos pelo modelo *Gradient Boosting* retreinado utilizando o processo de adaptação.

| | **0** | **1** | **2** | **3** | **4** | **5** | **6** | **7** | **8** | **9** | **10** | **11** | **12** | **13** | **14** |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| **0** | 461 | 0 | 2 | 0 | 3 | 0 | 0 | 19 | 2 | 2 | 1 | 2 | 0 | 16 | 2 |
| **1** | 12 | 238 | 14 | 14 | 7 | 0 | 0 | 21 | 8 | 4 | 10 | 9 | 1 | 242 | 7 |
| **2** | 7 | 2 | 258 | 0 | 7 | 0 | 0 | 20 | 2 | 4 | 4 | 17 | 3 | 18 | 4 |
| **3** | 0 | 25 | 0 | 167 | 2 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 23 | 2 |
| **4** | 2 | 1 | 5 | 0 | 416 | 31 | 6 | 12 | 6 | 69 | 24 | 11 | 13 | 0 | 6 |
| **5** | 0 | 0 | 0 | 0 | 130 | 44 | 5 | 21 | 2 | 14 | 0 | 0 | 0 | 0 | 0 |
| **6** | 0 | 0 | 0 | 0 | 8 | 2 | 81 | 1 | 0 | 22 | 0 | 0 | 0 | 0 | 0 |
| **7** | 8 | 8 | 17 | 0 | 40 | 10 | 0 | 385 | 41 | 25 | 27 | 35 | 7 | 39 | 9 |
| **8** | 1 | 1 | 1 | 1 | 1 | 0 | 0 | 72 | 9 | 6 | 25 | 11 | 0 | 21 | 3 |
| **9** | 13 | 0 | 3 | 0 | 63 | 21 | 7 | 14 | 0 | 413 | 32 | 12 | 1 | 1 | 12 |
| **10** | 3 | 2 | 4 | 1 | 38 | 10 | 2 | 62 | 11 | 28 | 124 | 35 | 5 | 16 | 18 |
| **11** | 1 | 5 | 2 | 1 | 30 | 1 | 3 | 94 | 5 | 12 | 59 | 113 | 0 | 46 | 12 |
| **12** | 0 | 0 | 2 | 0 | 37 | 7 | 1 | 1 | 0 | 10 | 2 | 2 | 105 | 0 | 2 |
| **13** | 4 | 87 | 1 | 2 | 20 | 2 | 0 | 36 | 1 | 7 | 24 | 13 | 2 | 981 | 8 |
| **14** | 3 | 7 | 5 | 8 | 23 | 4 | 0 | 14 | 2 | 15 | 11 | 8 | 0 | 32 | 58 |

Tabela 4.7: Resultados obtidos pelo modelo *Gradient Boosting* retreinado utilizando o processo de adaptação.

trizes de confusão geradas nos processos de classificação correspondentes das Tabelas 4.4 e 4.6, respectivamente. É válido destacar que, nos testes acima foram utilizados 33% da base de dados para testes e o restante para o processo de treinamento. Os testes fazendo o uso desse método adaptado no protótipo serão apresentados no Capítulo 4, de experimentos.

## 4.4 Teste do modelo de classificação adaptado

Nesta seção será apresentado o processo adotado para o teste do classificador adaptado, além de uma breve discussão sobre os resultados obtidos. Um protótipo do *smartwatch* foi construído com o objetivo de realizar a validação do modelo final de classificação. Esse protótipo é composto por um *Arduino Nano*, um acelerômetro triaxial (modelo MMA8452), um *Raspberry Pi 3*, sendo apenas o arduino e o acelerômetro as partes presentes no pulso.

Além da montagem do *hardware* do protótipo, foi também implementado um programa para realizar a gravação e o processamento dos dados gerados pelo acelerômetro, de forma a adequá-los ao formato disponibilizado na base de dados utilizada. Neste caso, como as especificações do acelerômetro utilizado no protótipo diferem do que foi utilizado na base de dados, foram realizadas as seguintes operações na tentativa de compensar essa diferença:

1. Os dados do acelerômetro crus estão em um intervalo [-2.5g, +2.5g] (devido às suas especificações). Dessa forma, para se adequar ao intervalo [-1.5g, +1.5g] utilizado pela base de dados, todos os valores que ultrapassaram esses limites foram transformados para os valores limite;

2. Os dados presentes na base de dados são mapeados para o intervalo [0, 63], dessa forma, a realização desse mapeamento também se tornou necessária.

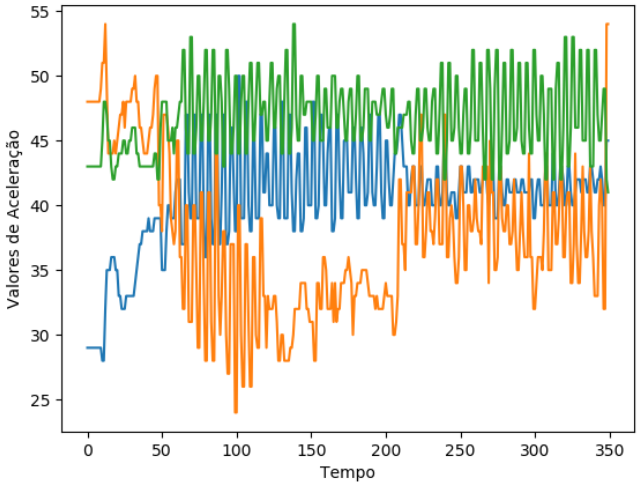


Figura 4.1: Parte da amostra da atividade ”escovar os dentes” extraída a partir do protótipo.

Inicialmente foi feita a escolha da atividade de ”escovar os dentes” para a validação. A Figura 4.1 apresenta parte da amostra dessa atividade coletada a partir do protótipo criado. A partir de uma comparação visual entre as Figuras 4.1 e 4.2 é possível notar uma grande

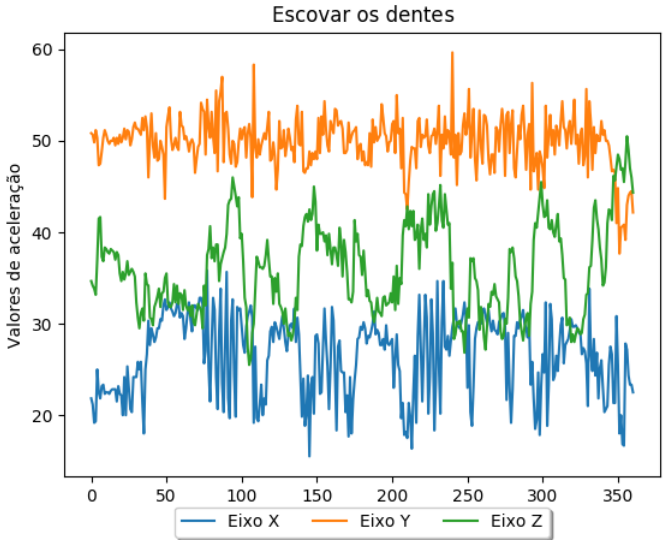


Figura 4.2: Amostra da atividade ”escovar os dentes” presente na base de dados utilizada.

| **Atividade** | **Janelas Previstas** |
|---|---|
| Escovar os Dentes | 0 |
| Subir escada | 0 |
| Pentear os cabelos | 5 |
| Descer escadas | 0 |
| Beber com um copo | 12 |
| Comer com garfo | 0 |
| Comer com colher | 0 |
| Levantar da cama | 10 |
| Deitar na cama | 0 |
| Servir água | 1 |
| Sentar na cadeira | 0 |
| Levantar da cadeira | 0 |
| Usar telefone | 1 |
| Andar | 0 |
| Atividade desconhecida | 0 |

Tabela 4.8: Resultados, por atividade, da classificação de uma amostra de “escovar dentes”.

diferença entre valores coletados e os valores disponíveis na amostra da base de dados, o que pode representar um grande problema para o classificador treinado.

Após a comparação visual, a amostra completa foi divida em janelas de tamanho 80 e tamanho de pulo igual a 20, resultando em 29 amostras a serem classificadas. As janelas foram classificadas pelo modelo adaptado de classificação, que obteve os resultados apresentados na Tabela 4.8. De forma alternativa, os resultados também são apresentados no histograma da Figura 4.3.

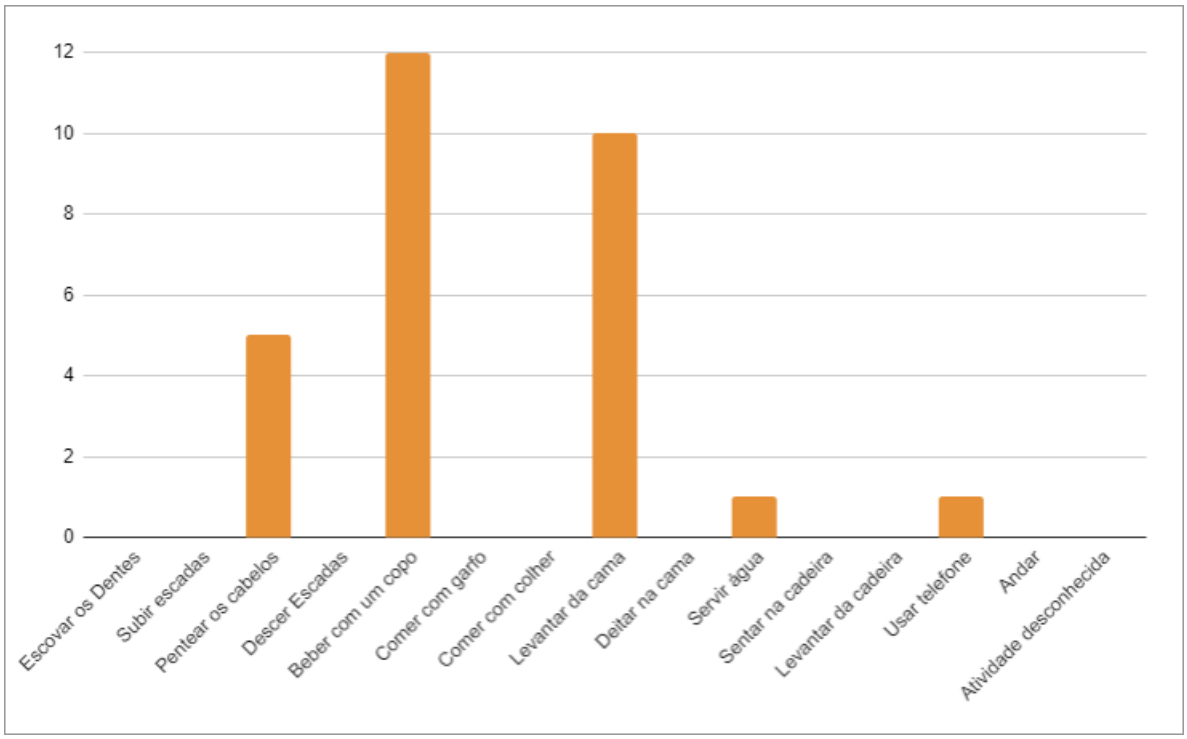


Figura 4.3: Histograma da Tabela 4.8.

Também foi realizado um processo mais confiável de verificação entre a diferença entre a amostra gravada a partir do protótipo e as amostras da base de dados. Neste processo, foram extraídas as características da amostra do protótipo, de todas as amostras da atividade "escovar dentes" disponíveis na base de dados, sendo essas informações confrontadas na Tabela 4.9.

A atividade "comer com um garfo" também foi gravada para que fosse realizada a sua validação, sendo que a Figura 4.4 apresenta um gráfico dessa gravação.

A partir da amostra gravada foram extraídas janelas, o que totalizou em 42 amostras a serem classificadas pelo modelo adaptado. Os resultados dos testes com essa nova amostra são apresentados na Tabela 4.10 e podem ser vistos, de forma visual, no histograma da Figura 4.6.

Finalmente, para comprovar a diferença presente entre as amostras gravadas pelo protótipo e os disponíveis na base de dados, foi realizada uma extração características dessas amostras. A Tabela 4.11 apresenta, em cada linha, uma característica extraída da amostra do protótipo, a média dessa característica extraída a partir das amostras da base de dados e o desvio padrão dessas características, respectivamente.

## 4.5 Discussão sobre os resultados

O objetivo inicial desta pesquisa era encontrar um conjunto de características que fornecessem bons resultados no processo de classificação de atividades diárias do usuário. Tendo

| Característica | Medição no protótipo | Média na base de dados |
|---|---|---|
| Média (eixo X) | 41.981 | 27.408 (± 3.235) |
| Média (eixo Y) | 37.554 | 49.274 (± 0.818) |
| Média (eixo Z) | 46.394 | 34.626 (± 2.838) |
| Desvio padrão (eixo X) | 4.879 | 9.863 (± 0.917) |
| Desvio padrão (eixo Y) | 7.177 | 9.115 (± 0.798) |
| Desvio padrão (eixo Z) | 3.786 | 8.194 (± 1.424) |
| Mediana (eixo X) | 42.000 | 27.041 (± 3.595) |
| Mediana (eixo Y) | 37.000 | 50.416 (± 0.793) |
| Mediana (eixo Z) | 46.000 | 35.166 (± 2.724) |
| Mínimo (eixo X) | 27.000 | 0.166 (± 0.577) |
| Mínimo (eixo Y) | 12.000 | 12.500 (± 5.125) |
| Mínimo (eixo Z) | 38.000 | 6.750 (± 6.982) |
| Máximo (eixo X) | 55.000 | 61.416 (± 1.975) |
| Máximo (eixo Y) | 62.000 | 63.000 (± 0.000) |
| Máximo (eixo Z) | 57.000 | 57.250 (± 3.840) |
| Variância (eixo X) | 23.807 | 98.059 (± 18.169) |
| Variância (eixo Y) | 51.521 | 83.685 (± 14.855) |
| Variância (eixo Z) | 14.336 | 69.001 (± 22.56) |
| Desvio absoluto (eixo X) | 28.000 | 61.250 (± 2.416) |
| Desvio absoluto (eixo Y) | 50.000 | 50.500 (± 5.125) |
| Desvio absoluto (eixo Z) | 19.000 | 50.500 (± 8.118) |
| Valor eficaz (eixo X) | 42.263 | 29.153 (± 3.112) |
| Valor eficaz (eixo Y) | 38.232 | 50.117 (± 0.724) |
| Valor eficaz (eixo Z) | 46.548 | 35.633 (± 2.483) |
| Posição final (eixo X) | 97105.452 | -526073.706 (± 703351.795) |
| Posição final (eixo Y) | 66322.880 | 2720802.504 (± 1125884.845) |
| Posição final (eixo Z) | 155464.500 | 578891.448 (± 515260.171) |
| Correlação (eixos XY) | 0.181 | 0.356 (± 0.143) |
| Correlação (eixos XZ) | -0.589 | -0.315 (± 0.140) |
| Correlação (eixos YZ) | -0.612 | -0.491 (± 0.145) |

Tabela 4.9: Comparação entre as características extraídas das amostras a partir do protótipo e as características extraídas a partir da base de dados a partir da atividade “escovar os dentes”.

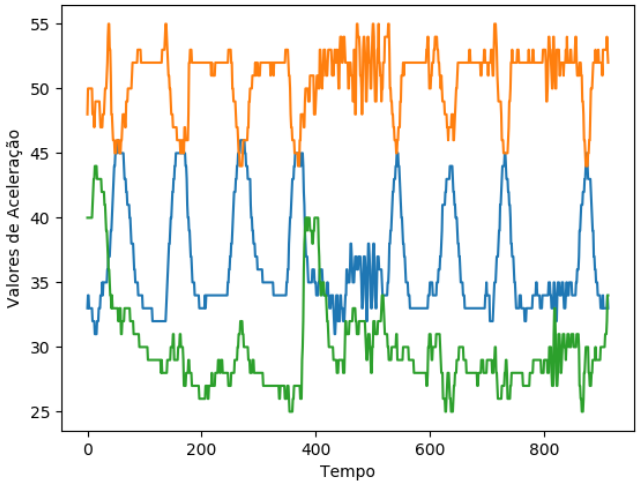


Figura 4.4: Amostra da atividade ”comer com um garfo” extraída a partir do protótipo.

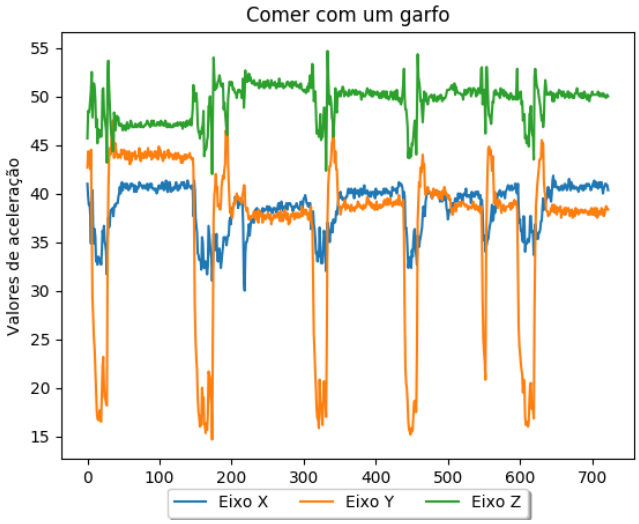


Figura 4.5: Amostra da atividade ”comer com um garfo” presente na base de dados utilizada.

esse objetivo em mente, pode-se dizer que o projeto teve três etapas principais:

1. Classificação de amostras de atividades;
2. Classificação de janelas das amostras de atividades;
3. Classificação de janelas de amostras gravadas pelo protótipo;

Na primeira etapa, de classificação de amostras de atividades, foi realizada uma extração de características de cada uma das amostras da base de dados que por sua vez foram divididas

| Atividade | Janelas Previstas |
|---|---|
| Escovar os Dentes | 36 |
| Subir escada | 0 |
| Pentear os cabelos | 1 |
| Descer escadas | 0 |
| Beber com um copo | 0 |
| Comer com garfo | 0 |
| Comer com colher | 0 |
| Levantar da cama | 1 |
| Deitar na cama | 0 |
| Servir água | 0 |
| Sentar na cadeira | 4 |
| Levantar da cadeira | 0 |
| Usar telefone | 0 |
| Andar | 0 |
| Atividade desconhecida | 0 |

Tabela 4.10: Resultados, por atividade, da classificação de uma amostra de "comer com um garfo".

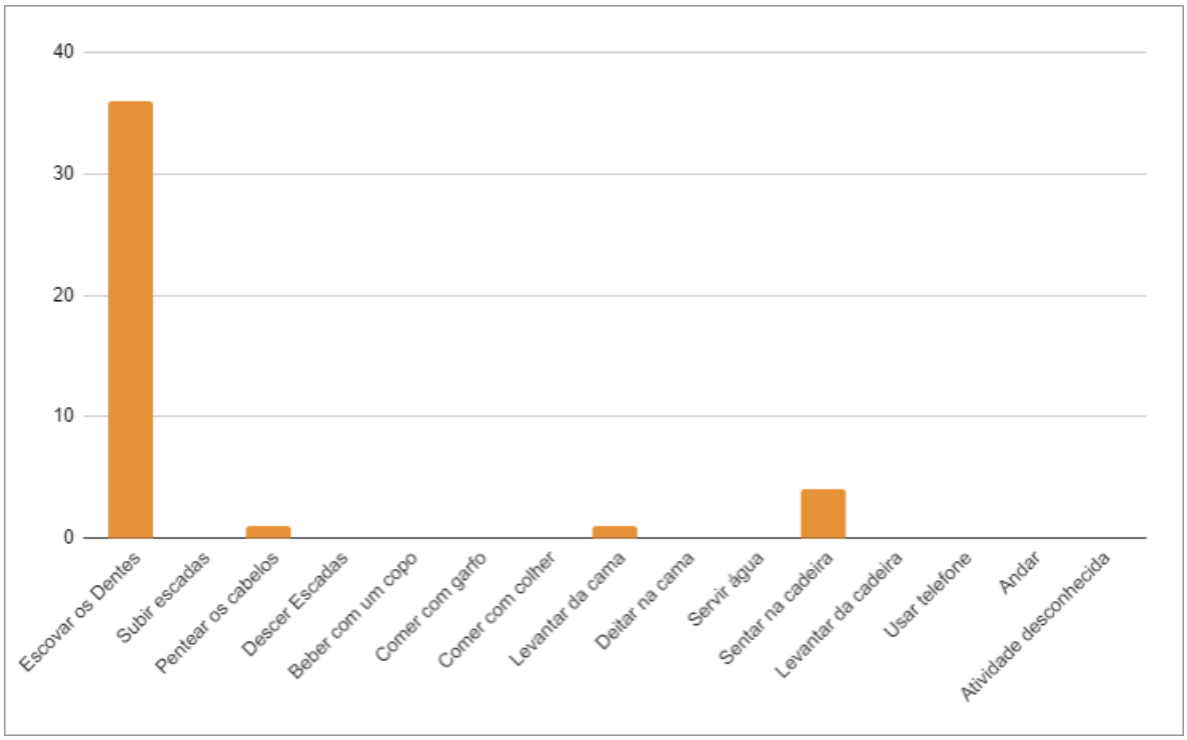


Figura 4.6: Histograma da Tabela 4.10.

por um processo chamado *Stratified KFold*. Essas bases de treino e teste foram utilizadas para alimentar diferentes modelos de classificação e, por fim, foi feita uma média de todas as métricas utilizadas, o que resultou em cerca de 86,17% de acurácia a partir do modelo *Gradient*

| **Característica** | **Medição no protótipo** | **Média na base de dados** |
|---|---|---|
| Média (eixo X) | 36.456 | 34.691 (± 2.234) |
| Média (eixo Y) | 50.704 | 35.027 (± 1.110) |
| Média (eixo Z) | 29.890 | 50.740 (± 1.054) |
| Desvio padrão (eixo X) | 4.073 | 1.995 (± 0.397) |
| Desvio padrão (eixo Y) | 2.592 | 7.224 (± 1.669) |
| Desvio padrão (eixo Z) | 3.591 | 2.436 (± 0.748) |
| Mediana (eixo X) | 35.000 | 34.600 (± 2.510) |
| Mediana (eixo Y) | 52.000 | 37.200 (± 1.304) |
| Mediana (eixo Z) | 29.000 | 51.400 (± 0.894) |
| Mínimo (eixo X) | 30.000 | 26.000 (± 2.000) |
| Mínimo (eixo Y) | 43.000 | 7.400 (± 4.775) |
| Mínimo (eixo Z) | 25.000 | 33.400 (± 2.881) |
| Máximo (eixo X) | 46.000 | 43.400 (± 2.702) |
| Máximo (eixo Y) | 57.000 | 51.400 (± 2.881) |
| Máximo (eixo Z) | 45.000 | 58.800 (± 1.643) |
| Variância (eixo X) | 16.593 | 4.108 (± 1.659) |
| Variância (eixo Y) | 6.717 | 54.407 (± 25.551) |
| Variância (eixo Z) | 12.898 | 6.381 (± 4.338) |
| Desvio absoluto (eixo X) | 16.000 | 17.400 (± 3.507) |
| Desvio absoluto (eixo Y) | 14.000 | 44.000 (± 6.205) |
| Desvio absoluto (eixo Z) | 20.000 | 25.400 (± 4.037) |
| Valor eficaz (eixo X) | 36.682 | 34.749 (± 2.245) |
| Valor eficaz (eixo Y) | 50.770 | 35.796 (± 1.079) |
| Valor eficaz (eixo Z) | 30.105 | 50.802 (± 1.033) |
| Posição final (eixo X) | 104365.119 | 2291562.929 (± 686408.055) |
| Posição final (eixo Y) | 375661.390 | 2710711.690 (± 1233649.984) |
| Posição final (eixo Z) | -18700.928 | 19361014.0905 (± 12717192.801) |
| Correlação (eixos XY) | -0.766 | 0.057 (± 0.361) |
| Correlação (eixos XZ) | -0.085 | -0.162 (± 0.320) |
| Correlação (eixos YZ) | -0.130 | 0.557 (± 0.203) |

Tabela 4.11: Comparação entre as características extraídas das amostras a partir do protótipo e as características extraídas a partir da base de dados a partir da atividade "comer com um garfo".

*Boosting*. Nesse cenário foram obtidos os melhores resultados das métricas utilizadas e isso se deve, principalmente, pela fácil diferenciação das atividades a partir das características extraídas - que se deve, principalmente, ao conhecimento exato do início e fim de cada uma das amostras.

Ao final da primeira etapa foi necessário fazer uma escolha em relação a como seriam feitas as classificações em tempo real. Essa decisão se faz necessária devido às limitações relacionadas ao cenário almejado, onde não deveria haver qualquer indicação de começo e fim de uma dada atividade. Dessa forma, a decisão final foi de separar as amostras em diversas

janelas com um tamanho fixo, o que resolveria a limitação do cenário de execução em tempo real, que é o desconhecimento de quando uma atividade começa a ser realizada ou de quando termina. Desta forma, a pesquisa seguiu com o uso da base de dados mas, desta vez, foi realizada uma concatenação de todas amostras disponíveis para que fosse possível considerar a base como uma gravação da realização diversas atividades, em tempo real (nesta etapa é interessante considerar uma divisão entre base de testes e treinamento antes de realizar essa concatenação, visto que a redundância presente nas janelas extraídas futuramente faria com que os resultados não fossem corretos). Feita a divisão entre treino e testes, foram obtidos os resultados relativamente piores que os da primeira etapa, mas que já eram esperados desta forma.

Apesar das vantagens visíveis da divisão de janelas, há também uma considerável perda ao considerar a perda de detalhes de determinadas amostras. Na Figura 4.7 é possível observar uma semelhança entre as amostras apresentadas, que se tornam ainda maiores se forem consideradas apenas as janelas, separadas. Janelas da atividade "Andar", nesta figura, se mostram muito semelhantes às janelas da atividade "Descer escadas", ou seja, as partes semelhantes representam a maioria nos exemplos de treinamento repassados para o modelo de classificação treinar.

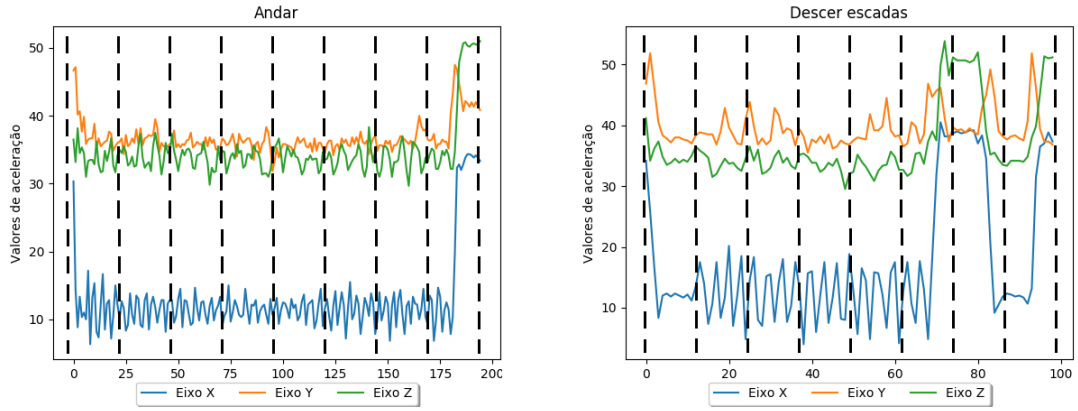


Figura 4.7: Comparação entre o resultado da divisão de janelas entre as atividades "Descer escadas" e "Andar".

Durante a terceira etapa da pesquisa, foram realizados testes em que o classificador resultante da segunda etapa foi aplicado no protótipo construído. Apesar das limitações do *hardware*, foram realizadas diversas operações de preprocessamento dos dados com o objetivo de simular o processo de captura de dados utilizado na base de dados selecionada para treinamento. Apesar das operações realizadas, atividades de interesse gravadas com o protótipo não apresentaram semelhanças visuais com exemplos da base de dados e que, como consequência, resultou em uma taxa de acurácia extremamente baixa. Desta forma, a possibilidade de replicar as amostras gravadas da base de dados se mostrou uma das etapas cruciais em sua

utilização para o reconhecimento de atividades em tempo real.

A partir desta pesquisa, surgem possíveis trabalhos futuros como a pesquisa de uma forma de padronizar essa coleta de dados, de forma que uma etapa preprocessamento possa reduzir essa diferença dos dados das amostras. Outra possibilidade seria a gravação de uma base de dados utilizando um conjunto de *hardware* similar a fim de obter resultados conclusivos para o processo de classificação estudado nesta pesquisa.

# Capítulo 5

# Conclusões

O trabalho teve como objetivos três principais tópicos, sendo eles o desenvolvimento de um *software* para a representação visual de amostras de acelerômetro, uma comparação de resultados obtidos aplicando métodos selecionados na literatura e a determinação de um conjunto de atributos a serem extraídos das amostras.

Em relação ao *software* de representação visual das amostras de acelerômetro, o processo de desenvolvimento demonstrou a inviabilidade de uma representação fiel sem estudos apropriados na área. Em outros testes, fazendo o uso dos sensores acelerômetro e giroscópio em conjunto demonstraram resultados mais fieis, mas que trazem a necessidade de um sensor adicional.

Ainda foram realizadas diversas etapas de experimentos com o objetivo de realizar a classificação de atividades a partir de uma base de dados existente. Na primeira etapa, onde apenas as amostras foram classificadas, resultados satisfatórios foram atingidos utilizando o modelo de classificação *Gradient Boosting* a partir das características selecionadas. A segunda etapa transformou a base de dados em uma única amostra e a dividiu em diversas janelas, a fim de tornar a entrada do classificador mais próxima de um cenário real. Ao tentar classificar essas janelas com o classificador da primeira etapa os resultados apresentaram métricas muito abaixo das primeiras, o que trouxe a necessidade de novos experimentos.

Em uma terceira etapa do trabalho houve a classificação das janelas utilizando parte desse conjunto de janelas para o treinamento. Como esperado, ao utilizar essas janelas para o treinamento, houve uma ligeira melhora nos resultados obtidos, mas ainda longe dos resultados iniciais. Durante os testes finais com um protótipo, no entanto, não foi possível atingir amostras semelhantes às da base de dados utilizada - ainda que feito um preprocessamento para simular o cenário descrito pelos autores desta. Essa diferença presente entre as amostras, como discutido no Capítulo 4, dificulta uma análise com resultados concretos sobre a utilização do processo de classificação descrito utilizando artefatos semelhantes ao protótipo gerado para o trabalho.

# Referências Bibliográficas


Abbas, B.; Farooq, O.; Uzzaman, Y.; Khan, A. A. e Vyas, A. L. (2013). Enhancing classification accuracy of wrist movement by denoising semg signals. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 5762–5764.

Alpaydin, E. (1997). Voting over multiple condensed nearest neighbors. *Artificial Intelligence Review*, 11(1):115–132.

Baldo, C.; Zanchim, M.; Ramos, V. e Marchi, A. (2015). Diabetes food control – um aplicativo móvel para avaliação do consumo alimentar de pacientes diabéticos. *Revista Eletrônica de Comunicação, Informação e Inovação em Saúde*, 9(3).

Bayat, A.; Pomplun, M. e Tran, D. A. (2014). A study on human activity recognition using accelerometer data from smartphones. *Procedia Computer Science*, 34:450 – 457. The 9th International Conference on Future Networks and Communications (FNC'14)/The 11th International Conference on Mobile Systems and Pervasive Computing (MobiSPC'14)/Affiliated Workshops.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.

Bruno, B.; Mastrogiovanni, F. e Sgorbissa, A. (2014). A public domain dataset for adl recognition using wrist-placed accelerometers. In *The 23rd IEEE International Symposium on Robot and Human Interactive Communication*, pp. 738–743.

Bruno, B.; Mastrogiovanni, F.; Sgorbissa, A.; Vernazza, T. e Zaccaria, R. (2012). Human motion modelling and recognition: A computational approach. In *2012 IEEE International Conference on Automation Science and Engineering (CASE 2012)*, pp. 156–161, Los Alamitos, CA, USA. IEEE Computer Society.

Dua, D. e Graff, C. (2017). UCI machine learning repository.

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5):1189–1232.

Gardner, M. e Dorling, S. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14):2627 – 2636.

Góes, A.; Vieira, M. e Liberatore Junior, R. (2007). Diabetes mellitus tipo 1 no contexto familiar e social. *Revista Paulista De Pediatria*, 25.

Kwapisz, J. R.; Weiss, G. M. e Moore, S. A. (2011). Activity recognition using cell phone accelerometers. *SIGKDD Explor. Newsl.*, 12(2):74–82.

Margarito, J.; Helaoui, R.; Bianchi, A. M.; Sartor, F. e Bonomi, A. G. (2016). User-independent recognition of sports activities from a single wrist-worn accelerometer: A template-matching-based approach. *IEEE Transactions on Biomedical Engineering*, 63(4):788–796.

Ravi, N.; Dandekar, N.; Mysore, P. e Littman, M. L. (2005). Activity recognition from accelerometer data. In *Proceedings of the 17th Conference on Innovative Applications of Artificial Intelligence - Volume 3*, IAAI'05, pp. 1541–1546. AAAI Press.

Rish, I. et al. (2001). An empirical study of the naive bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence*, volume 3, pp. 41–46.

Sarcevic, P.; Kincses, Z. e Pletl, S. (2015). Comparison of different classifiers in movement recognition using wsn-based wrist-mounted sensors. In *2015 IEEE Sensors Applications Symposium (SAS)*, pp. 1–6.

Swain, P. H. e Hauska, H. (1977). The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, 15(3):142–147.

Yang, J.-Y.; Wang, J.-S. e Chen, Y.-P. (2008). Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers. *Pattern Recognition Letters*, 29(16):2213 – 2220.

Zhang, X.; Xiang, C.; Li, Y.; Lantz, V.; Wang, K. e Yang, J. (2011). A framework for hand gesture recognition based on accelerometer and emg sensors. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, 41:1064 – 1076.

# Apêndice

A seguir são apresentados os gráficos indicados na seção 3.2, de seleção de base de dados.

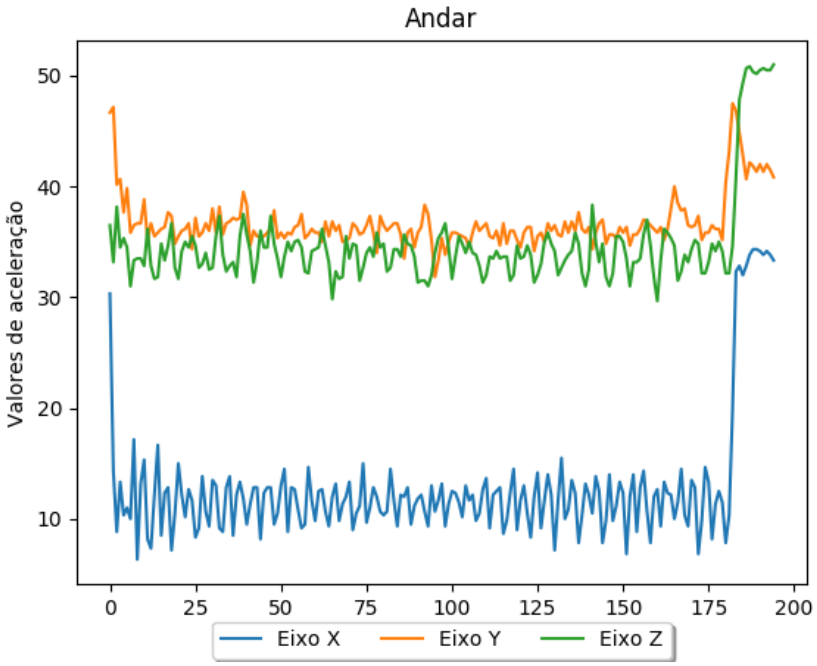


Figura 1: Representação gráfica de uma amostra da atividade *Andar* do *dataset* escolhido.

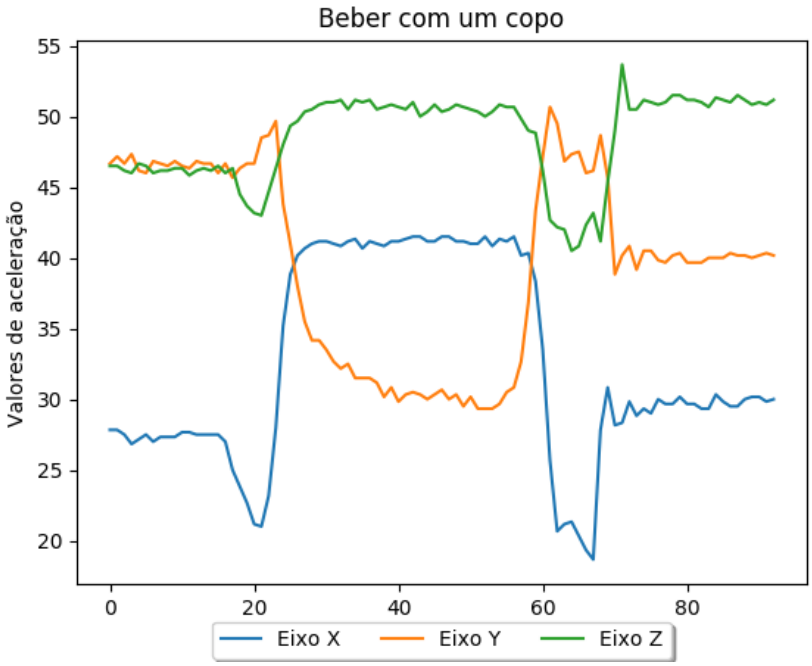


Figura 2: Representação gráfica de uma amostra da atividade *Beber com um copo* do *dataset* escolhido.

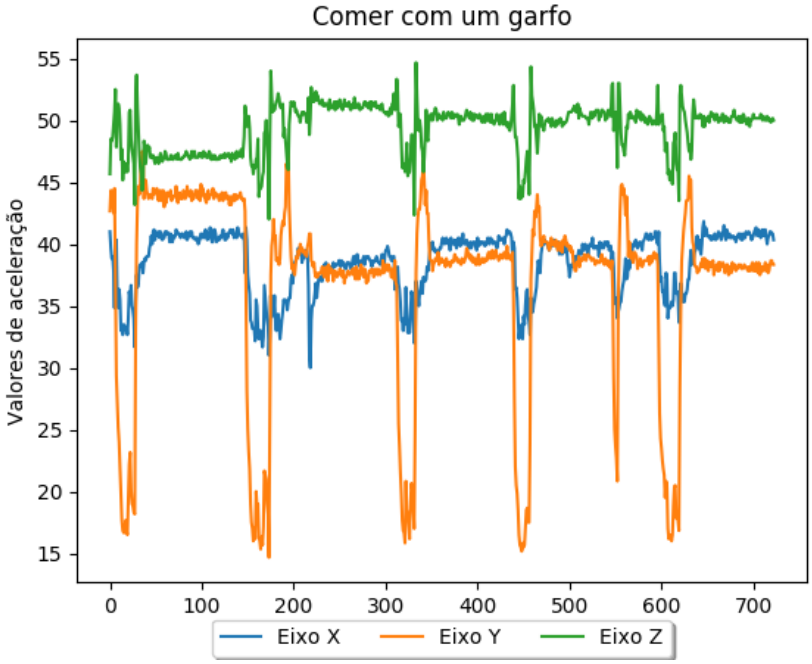


Figura 3: Representação gráfica de uma amostra da atividade *Comer com um garfo* do *dataset* escolhido.

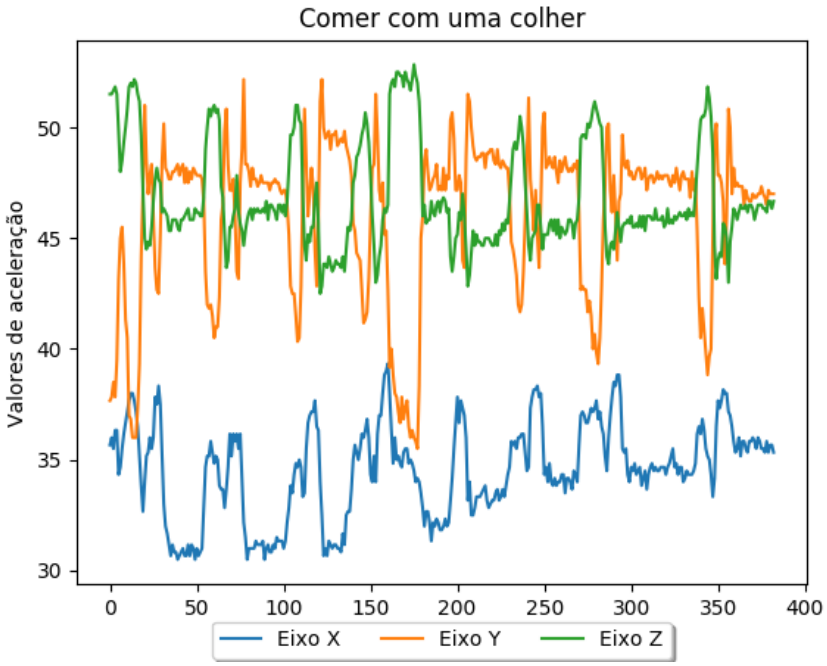


Figura 4: Representação gráfica de uma amostra da atividade *Comer com uma colher* do *dataset* escolhido.

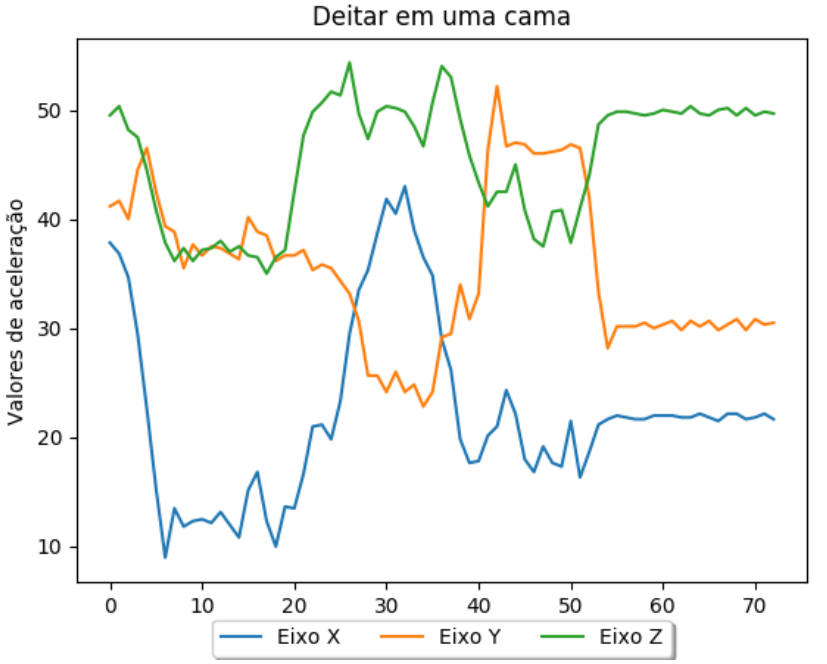


Figura 5: Representação gráfica de uma amostra da atividade *Deita em uma cama* do *dataset* escolhido.

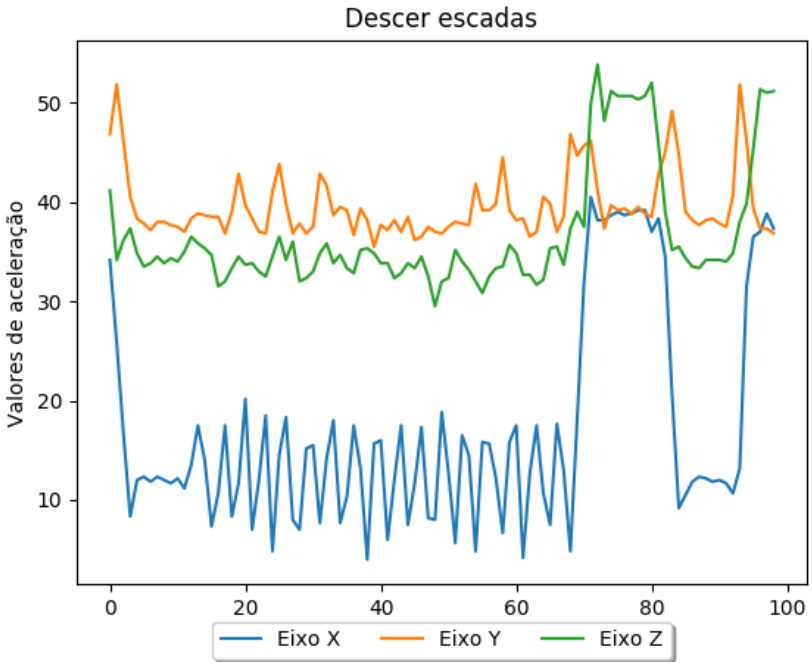


Figura 6: Representação gráfica de uma amostra da atividade *Descer escadas* do *dataset* escolhido.

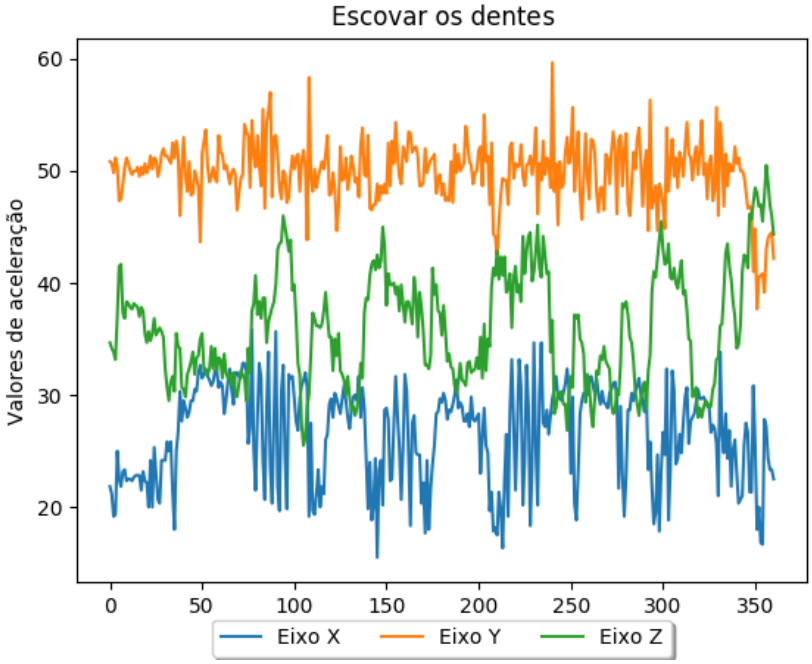


Figura 7: Representação gráfica de uma amostra da atividade *Escovar os dentes* do *dataset* escolhido.

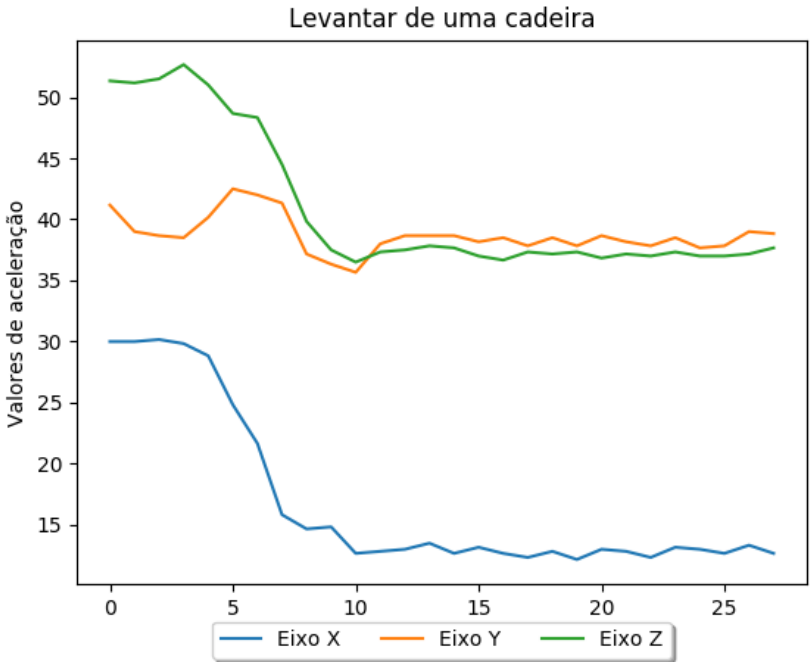


Figura 8: Representação gráfica de uma amostra da atividade *Levantar de uma cadeira* do *dataset* escolhido.

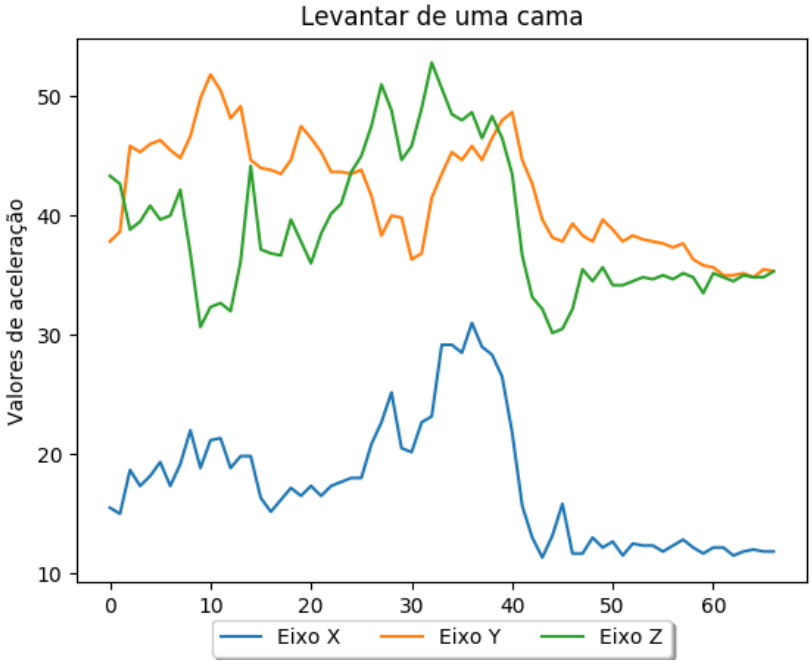


Figura 9: Representação gráfica de uma amostra da atividade *Levantar de uma cama* do *dataset* escolhido.

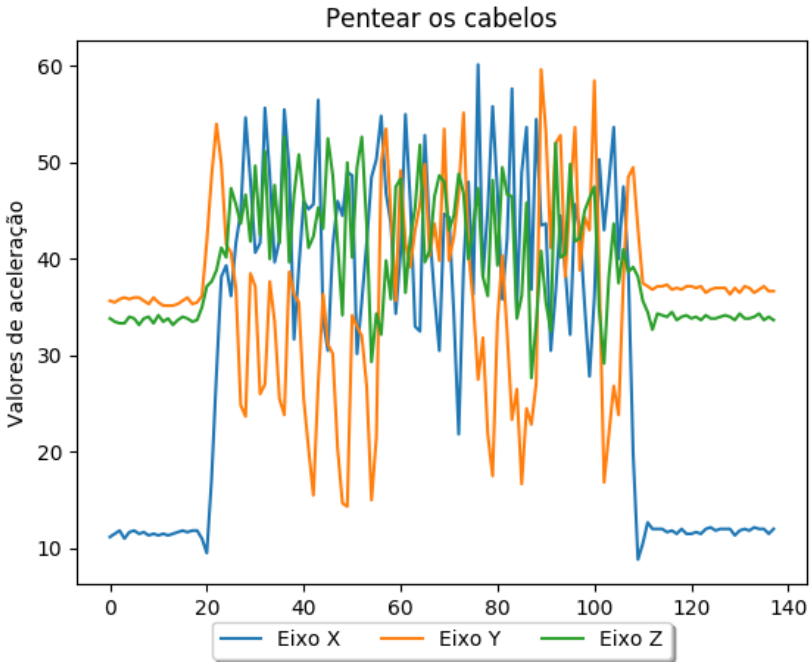


Figura 10: Representação gráfica de uma amostra da atividade *Pentear os cabelos* do *dataset* escolhido.

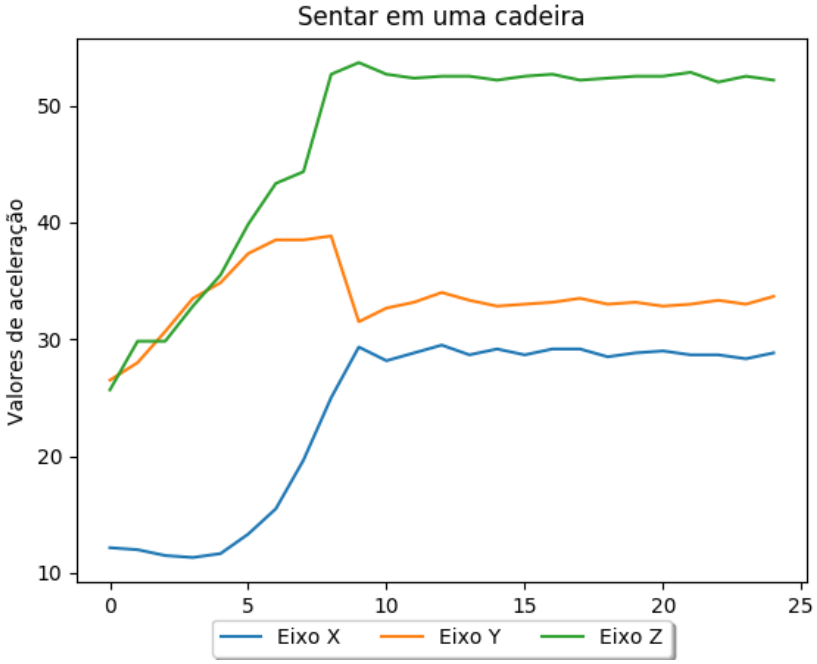


Figura 11: Representação gráfica de uma amostra da atividade *Sentar em uma cadeira* do *dataset* escolhido.

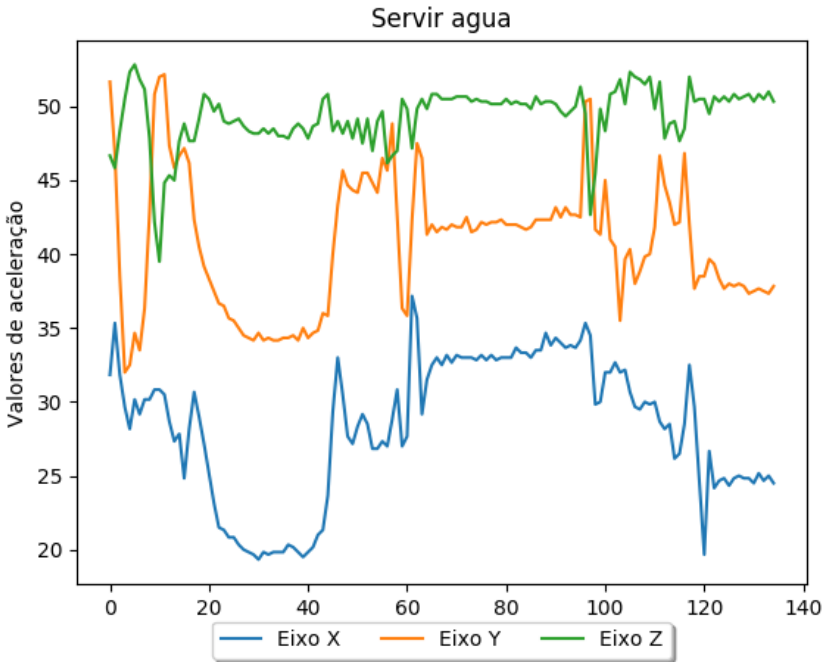


Figura 12: Representação gráfica de uma amostra da atividade *Servir água* do *dataset* escolhido.

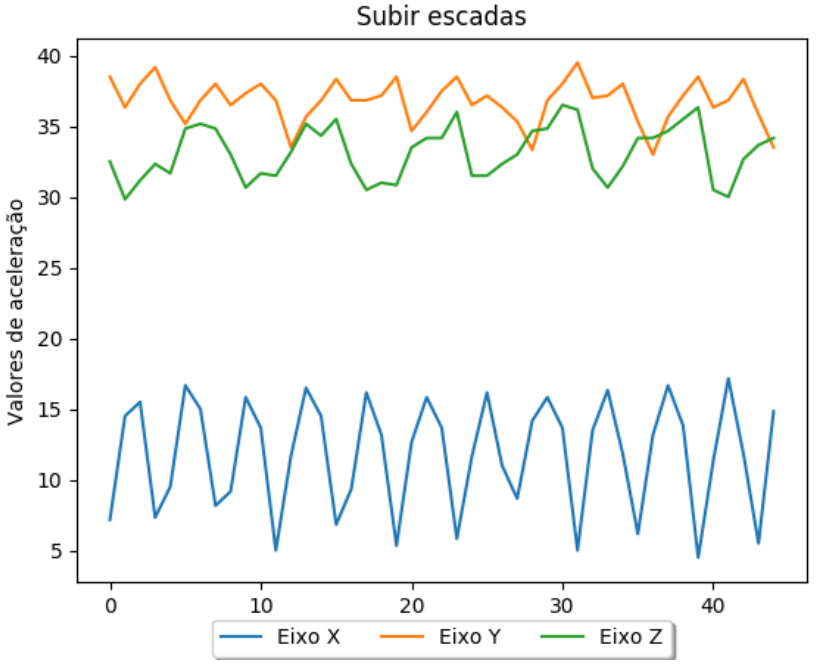


Figura 13: Representação gráfica de uma amostra da atividade *Subir escadas* do *dataset* escolhido.

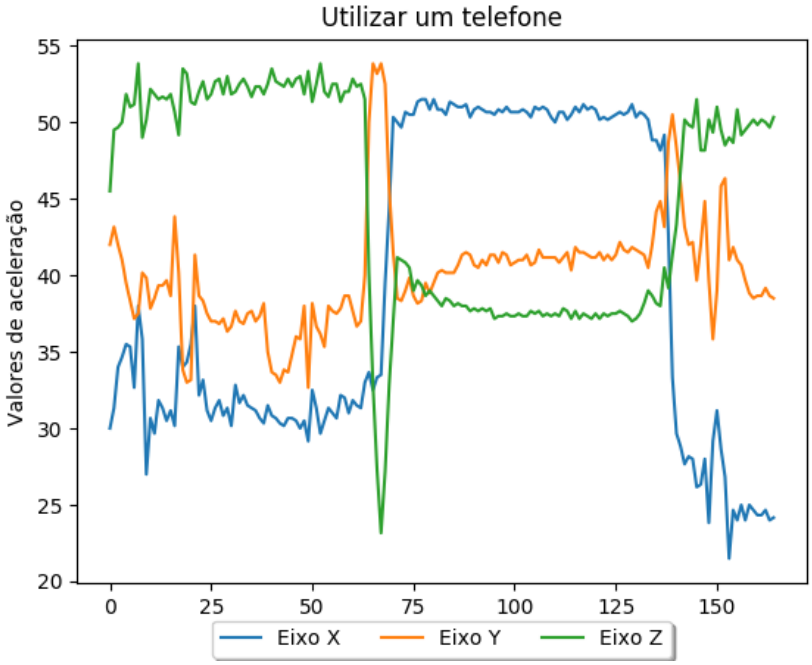


Figura 14: Representação gráfica de uma amostra da atividade *Usar o telefone* do *dataset* escolhido.