

**Luiz Henrique Franco Giovanini**

**Abordagens de Classificação de Séries Temporais  
Posturográficas com Estratégias de Aprendizagem  
Multiescala e Multifrequência**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de Doutor em Informática.

**Curitiba, 2018**

**Luiz Henrique Franco Giovanini**

**Abordagens de Classificação de Séries Temporais  
Posturográficas com Estratégias de Aprendizagem  
Multiescala e Multifrequência**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná como requisito parcial para a obtenção do título de Doutor em Informática.

Área de Concentração: *Ciência da Computação*

Orientador: Prof. Dr. Júlio Cesar Nievola

Coorientadora: Profa. Dra. Elisangela Ferretti Manffra

**Curitiba, 2018**

Dados da Catalogação na Publicação  
Pontifícia Universidade Católica do Paraná  
Sistema Integrado de Bibliotecas – SIBI/PUCPR  
Biblioteca Central  
Edilene de Oliveira dos Santos CRB 9 / 1636

G512a  
2018

Giovanini, Luiz Henrique Franco  
Abordagens de classificação de séries temporais posturográficas com estratégias de aprendizagem multiescala e multifrequência / Luiz Henrique Franco Giovanini ; orientador, Júlio Cesar Nievola ; coorientadora, Elisangela Ferretti Manffra. -- 2018  
113 f. : il. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2018.  
Bibliografia: f. 97-108

1. Informática. 2. Mineração de dados (Computação). 3. Aprendizado do computador. 4. Análise de séries temporais. 5. Redes neurais (Computação). I. Nievola, Júlio Cesar. II. Manffra, Elisangela Ferretti. III. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Informática. IV. Título

CDD 20. ed. – 004



Pontifícia Universidade Católica do Paraná

## DECLARAÇÃO

Declaro para os devidos fins que o aluno **LUIZ HENRIQUE FRANCO GIOVANINI**, defendeu sua tese de doutorado intitulada “**Abordagens de Classificação de Séries Temporais Posturográficas com Estratégias de Aprendizagem Multiescala e Multifrequência**”, na área de concentração Ciência da Computação, no dia 20 de novembro de 2018, no qual foi aprovado.

Declaro ainda que foram feitas todas as alterações solicitadas pela Banca Examinadora, cumprindo todas as normas de formatação definidas pelo Programa.

Por ser verdade, firmo a presente declaração.

Curitiba, 26 de novembro de 2018.

Prof. Dr. Emerson Cabrera Paraiso  
Coordenador do Programa de Pós-Graduação em Informática  
Pontifícia Universidade Católica do Paraná



## Agradecimentos

Gostaria de agradecer a todas as pessoas que, direta ou indiretamente, contribuíram para a realização deste trabalho.

Dedico um agradecimento especial ao meu orientador e à minha coorientadora, professores Júlio César Nievola e Elisangela Ferretti Manffra, respectivamente, que vêm contribuindo imensuravelmente para a minha formação. Obrigado por todo o apoio prestado em mais essa etapa. Eu aprendi muito com vocês e continuo aprendendo, como estudante e também como colega de profissão.

Um agradecimento especial também aos professores Alceu de Souza Britto Jr, Emerson Cabrera Paraiso e Myriam Regattieri de Biase da Silva Delgado, por contribuírem significativamente para o aprimoramento desta pesquisa por meio de ideias, sugestões e críticas construtivas que me fizeram refletir sobre diversos aspectos.

Agradeço também à minha família por todo o suporte, carinho e incentivo, principalmente minha esposa, Adriana Livia Franco Giovanini.

Finalmente, em termos de apoio financeiro, agradeço à PUCPR pela bolsa de estudos Marcelino Champagnat, e também à empresa NVIDIA pela doação de uma placa aceleradora que viabilizou a realização de diversos experimentos da pesquisa.

# Sumário

<b>Lista de Figuras.....</b>	<b>ix</b>
<b>Lista de Tabelas .....</b>	<b>xi</b>
<b>Lista de Abreviações .....</b>	<b>xii</b>
<b>Lista de Símbolos .....</b>	<b>xiii</b>
<b>Resumo.....</b>	<b>xiv</b>
<b>Abstract.....</b>	<b>xv</b>

## Capítulo 1

<b>1. Introdução .....</b>	<b>1</b>
1.1. Motivação e Justificativa .....	2
1.2. Objetivos .....	3
1.3. Hipóteses de Pesquisa .....	3
1.4. Contribuições .....	4
1.5. Organização da Tese .....	5

## Capítulo 2

<b>2. Classificação de Séries Temporais .....</b>	<b>6</b>
2.1. Considerações Iniciais .....	6
2.2. A Tarefa de Classificação .....	7
2.2.1. Treinamento e Avaliação de Classificadores.....	7
2.2.2. Seleção de Atributos .....	7
2.2.3. Modelos Tradicionais de AM.....	8
2.2.4. Modelos Profundos de AM .....	10
2.2.5. Redes Neurais Convolucionais.....	12
2.3. Classificação de Séries Temporais .....	16
2.3.1. Séries Temporais com Propriedades Multiescala e Multifrequência .....	16
2.3.2. Principais Abordagens de Classificação.....	18
2.3.3. Abordagens Baseadas em Extração de Características.....	19
2.3.4. Abordagens Baseadas em Aprendizagem Automática de Características	20
2.3.5. Limitações das Abordagens Existentes .....	21
2.4. Considerações Finais .....	22

### Capítulo 3

<b>3. Controle Postural.....</b>	<b>23</b>
3.1. Considerações Iniciais .....	23
3.2. Definição.....	24
3.3. Debilitações do Controle Postural .....	24
3.3.1. Acidente Vascular Encefálico .....	25
3.3.2. Envelhecimento e Risco de Quedas.....	25
3.4. Posturografia.....	27
3.5. Parametrização de Séries Temporais Posturográficas .....	29
3.5.1. Métricas de Avaliação Global .....	31
3.5.2. Métricas de Avaliação Estrutural .....	37
3.6. Considerações Finais .....	43

### Capítulo 4

<b>4. Trabalhos Relacionados.....</b>	<b>44</b>
4.1. Considerações Iniciais .....	44
4.2. Classificação de Séries Posturográficas com Modelos Tradicionais.....	44
4.3. Classificação de Séries Temporais com Redes Convolucionais.....	48
4.4. Considerações Finais .....	54

### Capítulo 5

<b>5. Método.....</b>	<b>56</b>
5.1. Considerações Iniciais .....	56
5.2. Bases de Dados .....	57
5.2.1. Base 1: Adultos e Idosos .....	57
5.2.2. Base 2: Risco de Quedas em Idosos .....	58
5.2.3. Base 3: Adultos Saudáveis e Adultos Pós-AVE.....	58
5.3. Abordagem de Classificação Baseada em Modelos Tradicionais .....	59
5.3.1. Etapa de Extração de Atributos .....	59
5.3.2. Etapa de Seleção de Atributos .....	65
5.3.3. Etapa de Classificação .....	66
5.3.4. Avaliação da Abordagem .....	68
5.4. Abordagem de Classificação Baseada em Redes Convolucionais .....	69
5.4.1. Etapa de Separação dos Dados .....	70

5.4.2.	Etapa de Maximização dos Dados.....	70
5.4.3.	Etapa de Normalização dos Dados .....	71
5.4.4.	Etapa de Extração de Subsequências.....	72
5.4.5.	Etapa de Classificação .....	72
5.4.6.	Avaliação da Abordagem .....	76
5.5.	Considerações Finais .....	77

## Capítulo 6

<b>6.</b>	<b>Resultados Experimentais.....</b>	<b>78</b>
6.1.	Considerações Iniciais .....	78
6.2.	Resultados .....	78
6.2.1.	Abordagem de Classificação Baseada em Modelos Tradicionais .....	78
6.2.2.	Abordagem de Classificação Baseada em Redes Convolucionais .....	83
6.3.	Discussão .....	84
6.3.1.	Abordagem de Classificação Baseada em Modelos Tradicionais .....	84
6.3.2.	Abordagem de Classificação Baseada em Redes Convolucionais .....	87
6.3.3.	Análises Complementares .....	89

## Capítulo 7

<b>7.</b>	<b>Conclusão .....</b>	<b>92</b>
7.1.	Limitações e Trabalhos Futuros.....	94

<b>Referências .....</b>	<b>97</b>
--------------------------	-----------

<b>ANEXOS .....</b>	<b>109</b>
ANEXO A.....	109
ANEXO B.....	110
ANEXO C.....	111
ANEXO D.....	113



## Lista de Figuras

Figura 1. Ilustração de um neurônio artificial ou Perceptron. ....	9
Figura 2. Ilustração de uma MLP. ....	9
Figura 3. Curva da velocidade de aprendizagem para uma RNA composta por quatro camadas ocultas. ....	10
Figura 4. Ilustração da conectividade entre neurônios em uma rede convolucional. ....	12
Figura 5. Rede convolucional de dois estágios utilizada na classificação de séries temporais. ....	13
Figura 6. Ilustração do processamento de uma série temporal por um filtro convolucional. ....	14
Figura 7. Ilustração da sub-amostragem de uma série temporal pela média aritmética. ....	15
Figura 8. Entropia amostral sobre diferentes escalas de tempo para séries posturográficas de pessoas idosas nas direções cartesianas $x$ (painel da direita) e $y$ (painel da esquerda). ....	17
Figura 9. Ilustração do mapeamento de séries temporais para vetores de atributos. ....	19
Figura 10. Ilustração das estratégias posturais (a) do tornozelo, (b) do quadril e (c) do passo. ....	24
Figura 11. Representação ilustrativa (a) de uma plataforma de força e (b) de um sujeito na postura ereta quieta sobre a plataforma. ....	28
Figura 12. Ilustração (a) de um indivíduo posicionado sobre uma plataforma de força, (b) de um estatocinesiógrama e (c,d) de estabilogramas. ....	29
Figura 13. Desvio padrão e entropia amostral para uma série determinística (à esquerda) e aleatória (à direita) ....	30
Figura 14. Ilustração de uma elipse (linha preta tracejada) que engloba 95% da área do estatocinesiógrama. ....	36
Figura 15. Espectro de potências de uma série CPd com a indicação das frequências de pico, média, em 50% e em 80% da concentração espectral total. ....	36
Figura 16. Curva da entropia multiescala para séries posturográficas nas direções $x$ (painel da esquerda) e $y$ (painel da direita). ....	38
Figura 17. Transformação de uma série para fatores de escala iguais a 2 (painel superior) e 3 (painel inferior). ....	39

Figura 18. Ilustração da auto-similaridade de uma série posturográfica em diferentes escalas de tempo. ....	40
Figura 19. Faixa de excursão possível do expoente de escala. ....	40
Figura 20. Ilustração da abordagem <i>Multi-Channels Deep Convolutional Neural Net</i> , de forma (a) global e (b) local. ....	50
Figura 21. Ilustração da abordagem <i>Multi-Scale Convolutional Neural Network</i> . ....	52
Figura 22. Resposta em frequência de um filtro Butterworth passa-baixa (painel à direita) e de um filtro média móvel (painel à esquerda). ....	54
Figura 23. Diagrama ilustrando as principais etapas do método da tese. ....	56
Figura 24. Abordagem de classificação baseada em modelos tradicionais da tese. ....	59
Figura 25. Recomendações de exclusão de tamanhos de janela para os métodos DFA e SWV. ....	62
Figura 26. Série posturográfica representada para os fatores de escala 1, 2 e 10. ....	63
Figura 27. Curva de um atributo calculado nos esquemas multiescala (esquerda) e multifrequência (direita). ....	64
Figura 28. Fluxograma da abordagem de classificação baseada em redes convolucionais da tese. ....	69
Figura 29. Séries posturográficas antes (esquerda) e depois (direita) da normalização. ....	72
Figura 30. Ilustração dos quatro cenários experimentais de classificação da tese. ....	73
Figura 31. Ilustração da análise de diferentes escalas temporais das séries ao longo da rede. ....	75
Figura 32. Composição das bases de dados em estudo após a seleção de atributos. ....	79
Figura 33. Curvas da acurácia geral nos oito cenários avaliados para as três bases de dados. ....	80
Figura 34. Histograma de contagem dos melhores cenários de classificação para as três bases de dados. ....	81
Figura 35. Curvas das acurácias individuais dos modelos de AM nas três bases de dados. Os retângulos em cinza indicam o cenário que rendeu a melhor acurácia para cada modelo. ....	82
Figura 36. Acurácias da abordagem baseada em redes convolucionais. Os asteriscos (*) e as cruzes (†) indicam, respectivamente, o melhor e o pior resultado em cada base de dados. ....	83

## Lista de Tabelas

Tabela 1. Métricas de avaliação global populares na literatura, com seus respectivos domínios, série de origem e estudos correlatos. ....	32
Tabela 2. Métricas de avaliação estrutural mais populares na literatura. ....	37
Tabela 3. Principais características de estudos correlatos envolvendo modelos tradicionais de AM. ....	45
Tabela 4. Principais características das bases utilizadas nos experimentos da tese. ....	57
Tabela 5. Atributos incluídos nos cenários de classificação. ....	66
Tabela 6. Modelos tradicionais de classificação avaliados na tese. ....	67
Tabela 7. Tamanho dos conjuntos de treino, validação e teste nos cenários de classificação. ....	74
Tabela 8. Levantamento da concentração espectral das cinco últimas IMFs dos dados. ....	79
Tabela 9. Relação das acurácias individuais dos modelos de AM para as três bases de dados. ....	83

## Lista de Abreviações

<b>AD:</b>	Árvore de Decisão
<b>AM:</b>	Aprendizagem de Máquina
<b>AVE:</b>	Acidente Vascular Encefálico
<b>CFS:</b>	<i>Correlation-based Feature Selection</i>
<b>CP:</b>	Centro de Pressão
<b>CPd:</b>	Deslocamentos do Centro de Pressão
<b>CPv:</b>	Velocidade do Centro de Pressão
<b>DFA:</b>	<i>Detrended Fluctuation Analysis</i>
<b>DOT:</b>	Deslocamento da Oscilação Total
<b>DP:</b>	Desvio Padrão
<b>EMD:</b>	<i>Empirical Mode Decomposition</i>
<b>EntAm:</b>	Entropia Amostral
<b>EntMe:</b>	Entropia Multiescala
<b>FA:</b>	Florestas Aleatórias
<b>FES-I:</b>	<i>Falls Efficacy Scale International</i>
<b>IA:</b>	Inteligência Artificial
<b>IC:</b>	Índice de Complexidade
<b>IMFs:</b>	<i>Intrinsic Mode Functions</i>
<b>k-NN:</b>	<i>k-Nearest Neighbours</i>
<b>MC:</b>	Medo de Cair
<b>MLP:</b>	<i>Multi-Layer Perceptron</i>
<b>NB:</b>	Naive Bayes
<b>PG:</b>	Programação Genética
<b>pp:</b>	Pontos percentuais
<b>PPGIa:</b>	Programa de Pós-Graduação em Informática
<b>PUCPR:</b>	Pontifícia Universidade Católica do Paraná
<b>RBF:</b>	<i>Radial Basis Function</i>
<b>ReLU:</b>	<i>Rectified Linear Unit</i>
<b>RMS:</b>	<i>Root Mean Square</i>
<b>RNA:</b>	Rede Neural Artificial
<b>ROC:</b>	<i>Receiver Operator Characteristic</i>
<b>RQ:</b>	Risco de Quedas
<b>SCP:</b>	Sistema de Controle Postural
<b>SP:</b>	<i>Sway Path</i>
<b>SVM:</b>	<i>Support Vector Machines</i>
<b>SWV:</b>	<i>Scaled Windowed Variance</i>
<b>VC:</b>	Validação Cruzada

## Lista de Símbolos

$\omega$	Peso sináptico de neurônios artificiais
$pj$	Passo de deslizamento de uma janela computacional
$w$	Comprimento de uma janela computacional
$m$	Comprimento da série temporal
$n$	Número de pontos da entropia amostral
$r$	Tolerância da entropia amostral
$k$	Fator de escala
$\alpha$	Expoente de escala
$H$	Expoente de Hurst
$t_a$	Tempo de amostragem
$f_a$	Frequência de amostragem

## Resumo

A classificação de séries temporais é uma tarefa amplamente conhecida na área de Aprendizagem de Máquina (AM). Essa tarefa tem sido realizada com o auxílio tanto de modelos tradicionais de AM como também de modelos profundos, com destaque às redes neurais convolucionais, sendo que cada tipo de modelo possui vantagens e desvantagens de uso. O presente trabalho focou na classificação de séries temporais posturográficas, o que permite distinguir grupos de pessoas com base em seu controle postural, que é a habilidade de manter o equilíbrio de forma estável e segura. Já existem algumas abordagens de classificação para este propósito na literatura, porém, elas não consideram os padrões multiescala e multifrequência presentes nas séries, que são fundamentais para a sua caracterização. Portanto, o objetivo desta tese foi avaliar duas abordagens de classificação de séries posturográficas com estratégias de aprendizagem de padrões multiescala e multifrequência, uma baseada em modelos tradicionais de AM e a outra em redes convolucionais, comparando-as com o uso de estratégias convencionais de aprendizagem. A hipótese testada foi que as estratégias propostas podem aprimorar o desempenho da classificação com as duas abordagens em comparação com as estratégias convencionais. A primeira abordagem possuiu três etapas principais: (i) extração de 42 atributos, (ii) seleção de atributos e (iii) classificação dos dados com seis modelos populares de AM utilizados com sucesso por estudos correlatos. Os atributos foram extraídos primeiro de forma convencional e depois utilizando estratégias multiescala e multifrequência propostas na tese. Então, o desempenho da abordagem foi estatisticamente comparado entre tais cenários. A segunda abordagem possuiu cinco etapas: (i) separação dos dados em treino, validação e teste, (ii) maximização, (iii) normalização, (iv) extração de subsequências e (v) classificação com a rede convolucional. O desempenho foi comparado estatisticamente entre quatro cenários experimentais: o primeiro deles sendo o padrão da literatura, o segundo com foco na aprendizagem multiescala, o terceiro com foco na aprendizagem multifrequência e o quarto combinando as aprendizagens multiescala e multifrequência. A acurácia foi adotada como métrica de desempenho para as duas abordagens, que foram avaliadas utilizando três bases de séries posturográficas, cada uma contendo dados oriundos de duas populações. Dentre os resultados, fazendo uma análise média de desempenho entre os modelos da primeira abordagem, observou-se acurácias sutilmente maiores nas três bases para os cenários propostos em relação ao convencional. Já ao analisar o desempenho dos modelos individualmente, para alguns deles, os cenários propostos renderam acurácias superiores em mais de 10,0% para duas das três bases consideradas. No caso da segunda abordagem, a acurácia dos cenários propostos também superou àquela do cenário convencional nas três bases. Além disso, a estratégia de aprendizagem multiescala mostrou-se superior à multifrequência em todos os experimentos. Em outras palavras, os achados foram ao encontro da hipótese, confirmando a relevância das estratégias de aprendizagem multiescala e multifrequência para as duas abordagens. Vale ressaltar que, embora contribua no desempenho, o uso de tais estratégias implica em maior esforço, tanto manual como computacional. Portanto, antes de se optar por uma ou outra estratégia, recomenda-se uma análise cautelosa dos custos e dos possíveis benefícios de cada uma delas.

**Palavras-chave:** classificação de séries temporais, aprendizagem de máquina, aprendizagem multiescala, aprendizagem multifrequência, séries temporais posturográficas.

## Abstract

Time series classification is very popular in the Machine Learning (ML) field. It has been performed with the help of traditional ML models, such as support vector machines, as well as deep models, mainly the convolutional neural networks. This work has focused on the classification of posturographic time series data. This allows one to distinguish between populations based on their postural control, that is, their ability of maintaining balance. It already exists some approaches for this purpose in the literature, but they do not take into account the multiscale and multifrequency patterns of the time series, which play a major role for their characterization. Therefore, the goal of this work was to evaluate two multiscale and multifrequency-based approaches for posturographic time series classification: the first one employing traditional ML models and the second one using convolutional neural networks. It was hypothesized that the multiscale and multifrequency learning strategies proposed in this work would improve the performance of the two approaches compared to the standard strategies found in the literature. The first approach has three main steps: (i) extraction of 42 features, (ii) feature selection, and (iii) data classification via six popular ML models that were successfully used by previous studies. The features were first extracted in a more traditional fashion, and then using multiscale and multifrequency schemes designed in this work. Then, the classification performance was statistically compared across such experimental scenarios. The second approach has five main steps: (i) data clustering into training, validation, and test sets, (ii) data augmentation, (iii) data normalization, (iv) subsequences extraction, and (v) data classification. Its classification performance was statistically compared across four scenarios. The first one was the baseline and employed traditional learning. The second one has focused on the multiscale learning, whereas the third one has focused on multifrequency learning. The last scenario has combined both multiscale and multifrequency learning. The two approaches were evaluated under three datasets, where accuracy was adopted as performance metric. An average analysis across results from traditional models of the first approach showed slightly better accuracies for the use of the proposed strategies in the three datasets. Considering the individual performances, some models reached an increase of more than 10.0% in accuracy for two datasets when changing from traditional to multiscale and multifrequency learning. Regarding the second approach, accuracy was also greater in the proposed scenarios for the three datasets. In this case, the multiscale strategy has shown to be more effective than the multifrequency one for all experiments. All these findings are in line with the hypothesis, thus supporting the relevance of the multiscale and multifrequency learning strategies for both approaches tested. Although these strategies help improving classification performance, it is important to remark that they imply more efforts. Therefore, before choosing among traditional, multiscale, and/or multifrequency learning, it is advisable to take into account the disadvantages and benefits of each one of them.

**Keywords:** time series classification, machine learning, multiscale learning, multifrequency learning, posturographic time series.

# Capítulo 1

## Introdução

Nos últimos anos, a evolução e a popularização de tecnologias de aquisição e armazenamento de informação, tais como computadores, celulares e sensores, tem alavancado mundialmente a produção de dados na forma de séries temporais, nas mais diversas áreas do conhecimento [1]. A classificação de séries temporais já vem sendo estudada há décadas no campo da Inteligência Artificial (IA) devido ao amplo rol de aplicações práticas [2], [3], tais como assistência médica [4]–[6], previsões clínicas [7]–[9] e detecção de atividade humana [10]. Entretanto, esta tarefa permanece um desafio até os dias de hoje em função de certas propriedades típicas deste tipo de dado, como por exemplo: alta dimensionalidade, presença de componentes não-estacionárias e contaminação por ruído, geralmente em larga escala [3].

Na área de IA, a classificação de séries temporais tem sido realizada com o auxílio de modelos de Aprendizagem de Máquina (AM) [2], tanto com os mais tradicionais, tratados em algumas literaturas como *rasos*, como também com modelos mais complexos, conhecidos como *profundos* [3], os quais vêm ganhando popularidade na última década e cujo uso tem se viabilizado graças a recentes avanços científicos e tecnológicos [11]. Esses dois tipos de modelo possuem vantagens e desvantagens, sendo que a melhor escolha pode variar conforme demandas da pesquisa, dados em estudo e recursos disponíveis.

Por exemplo, os modelos tradicionais possuem baixa complexidade computacional em geral, capacidade de lidar com poucos dados e, em alguns casos, possibilidade de



visualização das regras de classificação (e.g., árvore de decisão). Porém, demandam o mapeamento das séries temporais para vetores de atributos, um processo altamente trabalhoso e que impacta diretamente nos resultados [2]. Já os modelos profundos vêm oferecendo melhor desempenho do que os tradicionais em diversos cenários, permitindo também a aprendizagem automática de características a partir das próprias séries, ou seja, dispensando a extração de atributos. Entretanto, eles demandam grandes quantidades de dados em geral, implicando assim em tempos de treinamento mais elevados [12], [13]. Nesta categoria, destacam-se as redes neurais convolucionais, cuja arquitetura possui diversas vantagens para a classificação de séries temporais, e que vêm figurando como estado da arte nesta tarefa [7], [12], [14].

Uma das possíveis aplicações da classificação de séries temporais está na área do controle postural, onde é possível, por exemplo, prever o risco de quedas em pessoas idosas [15] e também mapear indicadores clínicos que distinguem pessoas saudáveis de pessoas com comprometimentos neuromotores decorrentes de doenças como o acidente vascular encefálico (AVE) [16], entre outras contribuições. Para isso, são utilizados dados coletados com a posturografia, uma técnica onde a oscilação corporal do indivíduo é mensurada por meio de séries temporais dos deslocamentos do centro de pressão (CP) nos eixos cartesianos  $x$  e  $y$ , estando o CP associado ao centro de massa do corpo [17]. Essas séries são conhecidas também como séries posturográficas.

### **1.1. Motivação e Justificativa**

De maneira geral, séries temporais possuem propriedades complexas que as diferenciam de outros tipos de dados e que tornam sua classificação uma tarefa desafiadora [3]. Algumas destas propriedades são amplamente discutidas na literatura, tais como o ruído, a alta dimensionalidade e a não-estacionariedade. Outras, porém, ainda não são tão difundidas, como é o caso das propriedades multiescala e multifrequência. A primeira denota a existência de padrões relevantes em escalas de tempo específicas da série temporal [18], enquanto a segunda implica na presença de padrões relevantes sobre diferentes distribuições espectrais de potência da série [14].

Essas propriedades multiescala e multifrequência têm sido úteis para a caracterização de séries temporais posturográficas com análises mais tradicionais, permitindo uma melhor compreensão do controle postural em diferentes populações [19]–[23]. Isso pode ser um indicativo de que tais propriedades podem contribuir também para a classificação

desses dados com modelos de AM. Entretanto, até onde se sabe, as abordagens existentes na literatura não levam em conta tais aspectos. Ao invés disso, as séries são analisadas em uma única escala de tempo e em uma única distribuição espectral de potência.

A limitação supracitada é a principal motivação deste trabalho, que se destina a investigar a relevância dos padrões multiescala e multifrequência de séries posturográficas para a sua classificação utilizando modelos tradicionais de AM e também redes neurais convolucionais. Em um estudo inicial já realizado nesta direção, o autor e colaboradores mostraram que uma análise individualizada de tais padrões pode levar a diferentes desempenhos de classificação, tanto usando testes estatísticos convencionais como também a árvore de decisão, um modelo tradicional de AM [24]. Agora, na tese, propõe-se estratégias de análise conjunta, que visam combinar padrões multiescala e multifrequência oriundos de múltiplas escalas de tempo e espectro de potência, respectivamente.

## **1.2. Objetivos**

O objetivo geral da tese é propor e avaliar estratégias de aprendizagem multiescala e multifrequência para a classificação de séries temporais posturográficas com modelos tradicionais de AM e com redes neurais convolucionais, combinando-as com estratégias convencionais de aprendizagem da literatura.

Os objetivos específicos são:

- Elaborar estratégias de aprendizagem de padrões multiescala e multifrequência a partir de séries temporais posturográficas para a classificação com modelos tradicionais de AM e também com redes convolucionais.
- Realizar experimentos de avaliação das estratégias propostas em diferentes bases de séries posturográficas para cada modelo considerado.

## **1.3. Hipóteses de Pesquisa**

A hipótese investigada é a de que, em comparação com o uso isolado de estratégias convencionais da literatura, a combinação delas com as estratégias de aprendizagem multiescala e multifrequência propostas na tese permite acrescentar informações relevantes para a classificação de séries temporais posturográficas, aprimorando assim o desempenho de modelos tradicionais de AM e de redes neurais convolucionais.

## 1.4. Contribuições

A principal contribuição da tese está na elaboração de estratégias de aprendizagem multiescala e multifrequência para a classificação de séries temporais posturográficas, algo inédito na literatura até onde se sabe. Dadas as evidências científicas de que os padrões multiescala e multifrequência destas séries podem afetar o desempenho de modelos de AM, conforme levantado pelo autor em um estudo anterior [24], o presente trabalho permite elucidar qual a relevância de considerar tais padrões durante a classificação, bem como as principais implicações disso em termos de custo-benefício frente ao uso de estratégias convencionais da literatura.

A relevância das estratégias propostas é avaliada para a classificação dos dados tanto com modelos tradicionais de AM, já utilizados com sucesso em séries posturográficas por estudos anteriores — inclusive do autor [16], [25], [26], como também redes neurais convolucionais, ainda não utilizadas em séries posturográficas até onde se sabe, mas que vêm apresentando resultados promissores para a classificação de séries temporais em geral. Este escopo envolvendo modelos tradicionais e redes convolucionais permite ampliar o alcance das discussões e conclusões do trabalho.

Como as estratégias propostas são projetadas para a classificação de séries posturográficas, sua aplicação se estende para além das bases aqui investigadas, alcançando os mais diversos cenários que envolvem o uso deste tipo de dado. Além disso, feitos os devidos ajustes, entende-se que tais estratégias possam ser empregadas também para a classificação de outros tipos de séries temporais com propriedades multiescala e multifrequência, tais como sinais da variabilidade da frequência cardíaca [18] e sinais de música [27], por exemplo.

Até o momento, esta pesquisa gerou três publicações em congressos internacionais da área da informática, todas elas envolvendo análises sobre a classificação de séries posturográficas com modelos de AM [16], [24], [25]. Além disso, foi conduzido um projeto de iniciação científica com um estudante de graduação envolvendo algumas práticas desta pesquisa, em um cenário mais simplificado. Tal projeto ajudou a difundir na comunidade local as práticas inovadoras propostas na pesquisa original.

## **1.5. Organização da Tese**

A tese está organizada da seguinte forma: no Capítulo 2, serão apresentadas as principais abordagens de classificação de séries temporais da literatura, discutindo suas vantagens e desvantagens, bem como os principais modelos de AM usados em cada uma delas. Em seguida, no Capítulo 3, são abordados os principais aspectos fisiológicos do controle postural, que é o fenômeno investigado nesta pesquisa, discutindo também as adversidades acarretadas nesse contexto pelo envelhecimento e pelo AVE. Tal capítulo aborda também a posturografia e a aquisição de séries posturográficas. Na sequência, o Capítulo 4 discute os principais estudos da literatura que possuem relação com a tese, ponderando seus aspectos promissores e limitações para auxiliar em diversas escolhas do método proposto, que, por sua vez, é apresentado no Capítulo 5. O Capítulo 6 discute os resultados experimentais alcançados com o método, avaliando então a validade da hipótese de pesquisa. Por fim, o Capítulo 7 apresenta a conclusão do estudo, juntamente com as limitações e sugestões de trabalhos futuros.

# Capítulo 2

## Classificação de Séries Temporais

### 2.1. Considerações Iniciais

Nos últimos anos, com o crescimento acentuado da produção de dados nas mais diversas áreas do conhecimento, pesquisas envolvendo mineração de séries temporais têm contribuído significativamente para o processo de descoberta de conhecimento em bases de dados, ganhando assim destaque na literatura [1], [7]. Somente na última década, foram produzidas centenas de artigos científicos propondo abordagens de indexação, classificação, agrupamento e segmentação de séries temporais [28]. A tarefa de classificação em particular vem desempenhando um papel importante em diversas aplicações práticas, tais como assistência médica [4]–[6], previsões clínicas [7]–[9], [29]–[35], detecção de atividade humana [10] e recomendação de músicas [36], entre muitas outras.

A classificação de séries temporais tem sido realizada com o auxílio de modelos tradicionais e também de modelos profundos de AM. No primeiro caso, parece não haver um modelo específico que represente o estado da arte. Já no segundo caso, as redes neurais convolucionais vêm se destacando na literatura com resultados promissores em diversos cenários [7], [12], [14]. Neste capítulo, será feita uma discussão geral sobre a tarefa de classificação com modelos tradicionais e profundos de AM (seção 2.2), abordando em seguida o uso desses modelos especificamente para a classificação de séries temporais (seção 2.3). Por fim, serão realizadas as considerações finais do capítulo (seção 2.4).

## 2.2. A Tarefa de Classificação

A classificação de uma base de dados qualquer consiste na categorização de todos os seus exemplos (ou instâncias) para dentro de classes pré-definidas [37]. Este processo compreende duas etapas principais [38], [39]:

- (i) *Aprendizagem (ou treinamento)*: aqui, um determinado algoritmo de AM é executado sobre um subconjunto da base original denominado conjunto de treinamento, no qual todos os exemplos estão associados a uma ou mais classes. Então, o algoritmo aprende padrões discriminantes dos dados, gerando um modelo de classificação capaz de diferenciar as classes do problema com uma certa precisão.
- (ii) *Teste*: nesta etapa, avalia-se a capacidade do modelo de inferir corretamente uma classe para os exemplos de teste (aqueles que não foram utilizados na fase de treinamento). Caso o desempenho seja considerado aceitável, o modelo pode ser utilizado para classificar novos exemplos cuja classe seja desconhecida.

### 2.2.1. Treinamento e Avaliação de Classificadores

Um dos métodos mais utilizados para avaliar o desempenho de modelos de classificação é a validação cruzada (VC), realizada geralmente a partir de 10 partições (*folds*) estratificadas para garantir resultados mais precisos [38]. Outro método bem conhecido na literatura é o *holdout*, que utiliza conjuntos fixos para as fases de treinamento (geralmente 70% da base), validação (geralmente 10% da base) e teste (geralmente 20% da base) [38]. Este segundo método é mais observado em situações que envolvem alto custo computacional, onde a VC torna-se inviável, tais como no uso de modelos profundos de AM ou na análise de bases com muitos dados. Neste contexto, uma das métricas mais utilizadas para descrever o desempenho de um classificador é a acurácia ou taxa de acerto, que representa o percentual de exemplos de teste corretamente categorizados tendo em vista todas as classes do problema. Informações mais detalhadas sobre os temas abordados nesta subseção podem ser encontradas na literatura da área [38], [39].

### 2.2.2. Seleção de Atributos

A seleção de atributos é um recurso amplamente utilizado em conjunto com modelos tradicionais de AM. Esse procedimento consiste em, para um dado conjunto de

atributos candidatos, selecionar um subconjunto contendo apenas os atributos mais discriminantes. Isso permite eliminar informação redundante ou irrelevante, proporcionando assim melhores resultados de classificação em geral [40]. Por meio desta prática, diversos trabalhos têm obtido resultados promissores em diferentes áreas de pesquisa [41], inclusive na classificação de séries temporais posturográficas [42], que é objeto de estudo nesta tese.

Dentre os mais diversos métodos de seleção de atributos existentes, àqueles pertencentes à categoria filtro visam avaliar a relevância de cada atributo do conjunto original independentemente do classificador a ser utilizado [38]. Mais especificamente, os atributos são ranqueados por meio de métricas de “peso”, tais como a informação mútua e a correlação [38]. A partir disso, seleciona-se o subconjunto contendo os atributos de mais alto posto conforme um determinado limiar ou critério de parada [43]. Essa estratégia é interessante quando se deseja avaliar os efeitos de um método de classificação sobre diferentes modelos de aprendizagem, como é o caso neste trabalho.

### 2.2.3. Modelos Tradicionais de AM

Diante da recente popularização dos modelos profundos de AM na literatura, que são compostos por vários níveis de representação do conhecimento (e.g., redes convolucionais, redes recorrentes), alguns estudos passaram a tratar os modelos tradicionais, que possuem poucos níveis, como *rasos* [44]. Alguns dos modelos tradicionais/rasos mais populares são: árvore de decisão (AD), floresta aleatória (FA),  $k$ -vizinhos mais próximos ( $k$ -NN), máquinas de vetor de suporte (SVM), naive Bayes (NB) e redes neurais artificiais (RNA). Estes modelos diferem nos procedimentos utilizados para gerar as regras de classificação, mas todos realizam esta tarefa a partir de instâncias representadas por conjuntos de características (ou atributos), que podem ser nominais, binárias, ordinais ou numéricas [2], [38], [39]. Informações mais detalhadas sobre tais modelos podem ser encontradas na literatura da área [38], [39].

Dentre os modelos supracitados, as RNAs têm sido amplamente utilizadas para uma série de tarefas de classificação, tais como reconhecimento de voz [45], reconhecimento de atividade humana [46] e identificação de doenças cardíacas [30]. A unidade fundamental de uma RNA é o neurônio artificial ou Perceptron, que, para um dado conjunto de valores de entrada, de pesos sinápticos e de termos de *bias*, gera um determinado

valor de ativação na saída (Figura 1). Neste contexto, uma RNA é composta pelo enca-deamento de múltiplos Perceptrons, o que na prática constitui uma MLP (*Multi-Layer Perceptron* ou Perceptron de Múltiplas Camadas) (Figura 2). Isso se dá pois Perceptrons isolados são incapazes de lidar com dados linearmente inseparáveis [47], algo muito co-mum nas aplicações práticas em geral.




Figura 1. Ilustração de um neurônio artificial ou Perceptron.  
Fonte: o autor.




Figura 2. Ilustração de uma MLP.  
Fonte: traduzido de Simon [48].

O treinamento de uma RNA consiste em ajustar seus parâmetros (pesos e *biases*) de forma a estimar corretamente a saída (classe) para um determinado padrão de entrada [38]. Para isso, busca-se minimizar o valor de uma função de erro (ou custo) calculada entre os valores de saída obtido e desejado. Um dos algoritmos mais utilizados para este propósito é o de retropropagação, que, em uma visão geral, utiliza pares de entrada-saída conhecidos para o ajuste dos parâmetros por meio de um mecanismo de redução de erros. Esse ajuste é feito normalmente pelo método estocástico de descida do gradiente [49],



que visa configurar os parâmetros de forma a operar no mínimo global da função de custo, analisando para isso a derivada (ou gradiente) dos erros. O procedimento é realizado iterativamente para diferentes conjuntos de entrada-saída, até que se atinja um certo critério de parada, como um determinado número de épocas ou limiar de erro.

No entanto, a retropropagação combinada com a descida do gradiente possui uma séria limitação conhecida como dissipação do gradiente [50]. De maneira breve, este problema reside no fato dos gradientes diminuírem progressivamente a medida em que são retropropagados pela rede, fazendo com que as camadas mais distantes da saída sofram atualizações praticamente insignificantes. Em outras palavras, o treinamento das camadas iniciais da RNA é consideravelmente mais lento do que nas últimas camadas [51] (Figura 3). Assim, quanto mais camadas forem consideradas, mais acentuado será o fenômeno.

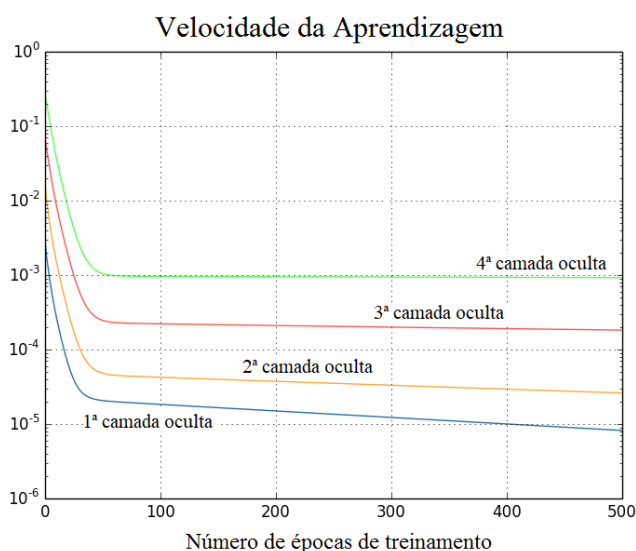


Figura 3. Curva da velocidade de aprendizagem para uma RNA composta por quatro camadas ocultas. Fonte: traduzido de Nielsen [51].

#### 2.2.4. Modelos Profundos de AM

Diante da limitação da dissipação do gradiente, RNAs mais profundas (com mais de duas camadas ocultas) foram investigadas sem sucesso na literatura durante anos [52], predominando assim o uso de redes mais rasas, com apenas uma ou duas camadas ocultas [38]. Entretanto, essa limitação foi superada com a introdução da técnica *greedy layer-wise pre-training* [11], [53] em 2006, ano a partir do qual redes mais profundas voltaram a atrair a atenção dos pesquisadores, representando hoje um dos assuntos mais promissores na área de AM.

A técnica supracitada consiste em realizar um pré-treinamento não-supervisionado independente em cada camada da rede, utilizando então os parâmetros ajustados para a inicialização. Isso resulta em pesos e *biases* iniciais mais apropriados em comparação com a inicialização tradicional, onde são utilizados valores aleatórios. Por fim, com o auxílio da retropropagação, realiza-se um ajuste fino da rede completa de forma supervisionada [44]. Mais recentemente, porém, constatou-se que a etapa de pré-treinamento pode ser desconsiderada para grandes quantidades de dados e inicialização/configuração adequadas da rede [54]. Neste cenário, alguns tipos de RNAs profundas passaram a registrar bons desempenhos somente por meio de treinamento supervisionado, tal como as redes neurais convolucionais [55].

De maneira geral, argumenta-se que modelos profundos de AM possuem algumas vantagens em relação aos tradicionais em tarefas de classificação; dentre elas, destacam-se [3], [44], [52], [54]:

- Aprendizagem/extração automática de características, que ocorre de forma hierárquica ao longo das diferentes camadas. Ou seja, não é necessário extrair características manualmente, como normalmente ocorre com os modelos tradicionais.
- Capacidade de aprender funções complexas e dinâmicas, permitindo modelar de forma mais eficiente e robusta dados com estruturas complexas e de alta dimensionalidade, tais como séries temporais e imagens.
- Capacidade de capturar as estruturas estatísticas dos dados durante a aprendizagem automática de características.
- Desempenho mais promissor para diferentes tipos de dados, oriundos das mais diversas áreas do conhecimento. Pode-se mencionar, por exemplo: classificação de sinais fisiológicos [7]–[9], [56]–[60], reconhecimento de voz [61], [62], classificação de música [63]–[65], reconhecimento de imagens [13], [66], classificação de texto [67] e identificação de emoções [68], [69].

Entretanto, deve-se mencionar que os modelos profundos também possuem desvantagens em relação aos tradicionais. Por exemplo, dado o grande número de parâmetros devido ao uso de várias camadas, eles demandam grandes volumes de dados para a obtenção de resultados satisfatórios, o que implica em elevados tempos de treinamento em geral [12], [13], podendo ser necessário o uso de placas gráficas aceleradoras para viabilizar seu uso. Outra questão reside na representação das regras de classificação, algo de grande utilidade em problemas de certas áreas como a da saúde, permitindo, por exemplo,

mapear indicadores clínicos decisivos para caracterizar certas patologias [16]. Embora já esteja sendo estudada e aprimorada para modelos profundos [70], [71], essa representação ainda não é tão clara e intuitiva como em modelos tradicionais do tipo caixa-branca, como a árvore de decisão.

Dentre os modelos profundos mais populares atualmente, estão as redes neurais convolucionais (ou simplesmente redes convolucionais), as redes neurais recorrentes, as redes de crenças profundas e os *auto-encoders* [54]. No entanto, como será discutido na sequência, as redes convolucionais possuem diversas vantagens em relação aos outros modelos citados para o escopo desta tese. Portanto, será dada ênfase a este modelo no presente trabalho.

### 2.2.5. Redes Neurais Convolucionais

Argumenta-se que o primeiro modelo profundo utilizado com sucesso teve origem nas redes convolucionais rasas propostas em 1995 por LeCun e Bengio [72], onde as diferentes camadas que compõem o modelo foram encadeadas em múltiplos estágios para a obtenção de uma arquitetura profunda [73].

Uma das principais características das redes convolucionais que as difere de outros modelos é o fato dos neurônios das camadas ocultas não estarem conectados a todos os neurônios da camada anterior, mas sim a apenas um subconjunto deles [3] (Figura 4). Isso reduz consideravelmente o número de parâmetros a serem ajustados no treinamento, tornando o modelo particularmente interessante para a análise de dados com alta dimensionalidade, como séries temporais [3].




Figura 4. Ilustração da conectividade entre neurônios em uma rede convolucional.  
Fonte: traduzido de Dalto [74].

A arquitetura de uma rede convolucional apresenta dois módulos principais [73] (Figura 5):

- (i) *Módulo de extração de características*: é composto pelo encadeamento de múltiplos estágios, cada um deles formado por uma camada de convolução seguida por uma camada de sub-amostragem. Na saída dessas camadas são gerados diferentes mapas de características, que representam padrões discriminantes aprendidos diretamente a partir dos dados, e que vão sendo aprimorados e temporalmente reduzidos ao longo dos estágios.
- (ii) *Módulo de classificação*: tem a função de realizar a classificação dos dados a partir dos mapas de características aprendidos. Consiste geralmente em uma MLP totalmente conectada ou em uma função *softmax*.

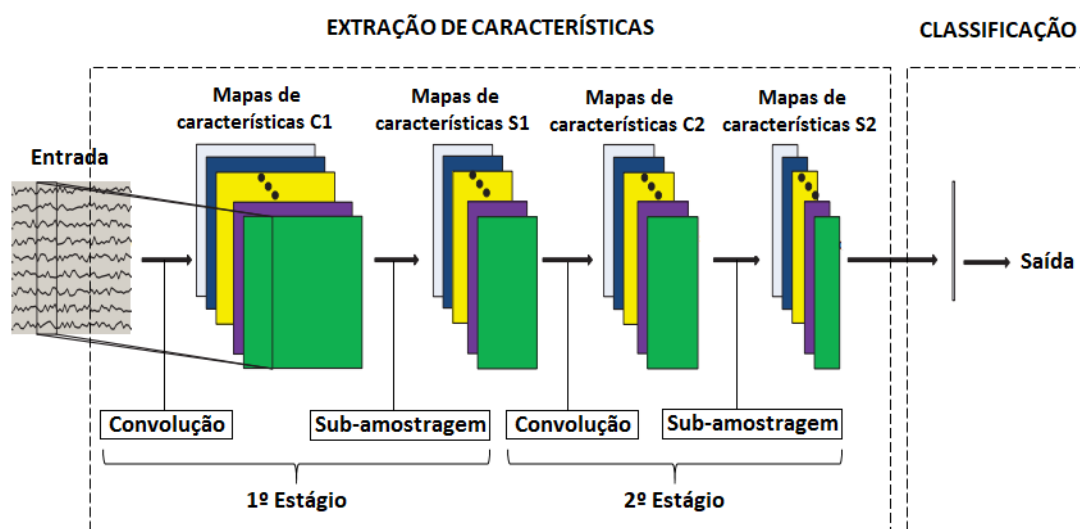


Figura 5. Rede convolucional de dois estágios utilizada na classificação de séries temporais.

Fonte: traduzido e adaptado de Yang et al. [75].

### Camada de convolução

Na camada de convolução da rede, diferentes filtros treináveis são aplicados nos dados de entrada. Cada filtro é composto por um subconjunto de neurônios de uma camada oculta localmente conectados a neurônios da camada anterior [3], [72] (vide Figura 4), o que permite explorar correlações locais. Em outras palavras, os filtros definem trechos locais dos dados que serão analisados por meio de convoluções. Este processo é exemplificado na Figura 6, que mostra uma série temporal de sete amostras sendo percorrida por um filtro de tamanho igual a três amostras e passo unitário. Neste cenário, cada janela de três amostras da entrada é convoluída pelo filtro, resultando em uma nova amostra. Como resultado final, o filtro produz um mapa de características de cinco amostras no total.

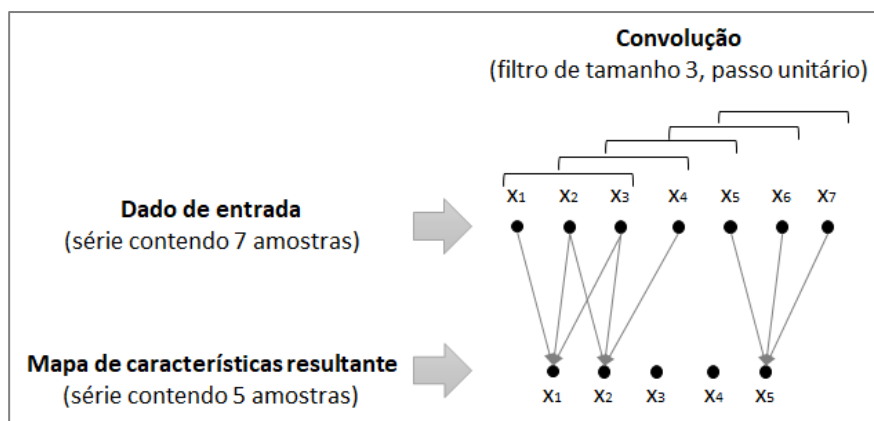


Figura 6. Ilustração do processamento de uma série temporal por um filtro convolucional.  
Fonte: o autor.

Com relação à ativação dos neurônios, as funções mais populares na literatura são a sigmoide e a tangente hiperbólica. Entretanto, uma nova função denominada ReLU (*Rectified Linear Unit* ou Unidades Retificadoras Lineares) tem ganhado destaque nos últimos anos por permitir o treinamento da rede de forma consideravelmente mais rápida em comparação com as demais funções [76]. Esta função já vem sendo utilizada com sucesso em redes convolucionais para a classificação de séries temporais [12], [14].

### Camada de sub-amostragem

A camada de sub-amostragem tem a função de reduzir os mapas de características gerados pelas camadas de convolução, o que acontece de forma gradual ao longo dos diferentes estágios [3], [72] (vide Figura 5). Este procedimento consiste em extrair uma determinada medida estatística (e.g., média, variância) dos mapas ao longo de sub-regiões delimitadas por uma janela deslizante de tamanho e passo arbitrários [27]. Para exemplificar, a Figura 7 ilustra a sub-amostragem de uma série temporal via média aritmética para uma janela deslizante não-sobreposta de tamanho igual a dois (painel superior) e igual a três (painel inferior) pontos amostrais.

Além de proporcionar redução de dimensionalidade, a sub-amostragem dos mapas permite preservar informações úteis enquanto elimina ruído, redundâncias e outros tipos de informação irrelevante, oferecendo também robustez a eventuais variações nos dados de entrada, como deslocamentos temporais [27], [54], [72].

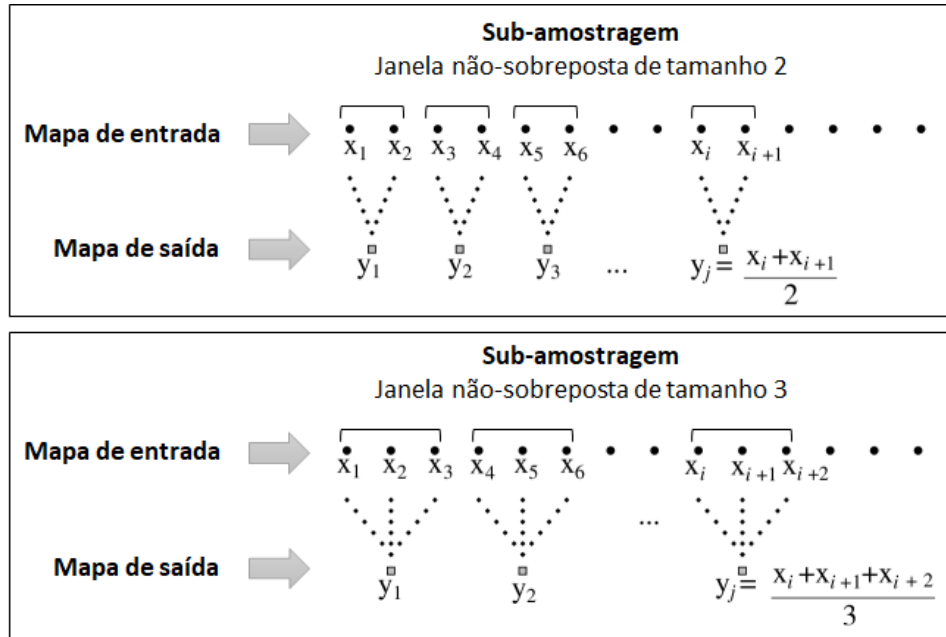


Figura 7. Ilustração da sub-amostragem de uma série temporal pela média aritmética.  
Fonte: adaptado de Silva [77].

Argumenta-se que a função de sub-amostragem mais adequada pode variar caso a caso, a depender das características do problema e dos dados em estudo [27], [78]. Para a classificação de séries temporais, tem-se observado atualmente o uso das funções de média aritmética [7] e *max-pooling* [14]. Parece não haver também um consenso quanto ao tamanho da janela de sub-amostragem, que varia de estudo para estudo. Já o deslizamento da janela costuma ser de forma não-sobreposta [7], [12], [14], diante de evidências anteriores de que janelas sobrepostas não oferecem ganhos significativos [79].

### Treinamento de Redes Convolucionais

Redes convolucionais podem ser treinadas de forma supervisionada, por meio da retropropagação combinada ao método estocástico de descida do gradiente [73], ambos já abordados na subseção 2.2.3. Esta combinação proporciona maior agilidade em comparação com outros métodos de otimização propostos na literatura [80].

Durante o treinamento, os exemplos não são todos apresentados à rede de uma só vez, mas sim divididos em subconjuntos menores: os chamados mini-lotes. A apresentação de um mini-lote completo representa uma iteração no processo de treinamento, ao passo que a apresentação de todos os mini-lotes representa uma época de treinamento. A atualização dos parâmetros da rede acontece a cada iteração do processo. Neste cenário, para melhorar a aprendizagem do modelo e também minimizar a dissipação do gradiente

durante a retropropagação, recomenda-se o uso da função ReLU em conjunto com a normalização de lote [81]. Isso consiste em normalizar os valores de ativação dos neurônios para cada mini-lote apresentado, mantendo a média próxima de zero e o desvio padrão próximo da unidade.

O treinamento da rede ao longo de muitas épocas pode levar a um fenômeno conhecido como sobreajuste (ou *overfitting*), situação onde o modelo torna-se especialista nos dados de treinamento mas apresenta baixo poder preditivo sobre os exemplos de teste, perdendo assim o poder de generalização. Para evitar este fenômeno, costuma-se utilizar um critério de parada no treinamento, geralmente relacionado com o desempenho da rede nos dados de validação, que é verificado dentro de uma certa periodicidade de iterações. Assim, se o desempenho na validação não melhora dentro de um certo limite consecutivo de verificações, o treinamento é automaticamente encerrado. Deve-se estabelecer também um valor máximo de épocas de treinamento, para o caso do critério de parada nunca ser satisfeito.

Diante do exposto, percebe-se que a otimização da rede requer o ajuste de uma série de parâmetros de configuração (ou hiperparâmetros), dentre os quais destacam-se: taxa de aprendizagem e decaimento, tamanho dos mini-lotes, número máximo de épocas de treinamento, função de custo a ser minimizada e critério de validação/parada [54], [81]. O ajuste desses hiperparâmetros impacta diretamente na otimização dos parâmetros (pesos sinápticos e *biases*) da rede, afetando seu desempenho e poder de generalização [81]. Isso pode ser feito seguindo recomendações de estudos correlatos [81], ou também utilizando métodos automáticos de ajuste como o *random grid search* [82], pois a verificação de todas as combinações possíveis de hiperparâmetros é algo inviável [54].

## 2.3. Classificação de Séries Temporais

### 2.3.1. Séries Temporais com Propriedades Multiescala e Multifrequência

Formalmente, uma série temporal  $T$  representa um conjunto de valores reais amostrados ao longo do tempo a partir de um fenômeno contínuo qualquer [3], [7], [83], podendo ser representada como:

$$T = \{t_1, t_2, \dots, t_m\} \quad (1)$$

Sendo  $t_i$  a  $i$ -ésima amostra da série e  $m$  o seu comprimento (i.e., o número total de pontos amostrais).

A presença de propriedades multiescala em uma série temporal denota a existência de padrões relevantes em escalas de tempo específicas, as quais são determinadas pela frequência de amostragem dos dados. Por exemplo, para séries de temperatura do corpo humano, foi demonstrada a presença de padrões que permitem prever a ocorrência da sepse (conhecida popularmente como infecção generalizada) ao analisar escalas de tempo maiores do sinal, da ordem de horas. Entretanto, isso já não foi possível ao analisar padrões locais em escalas de tempo menores, da ordem de segundos ou minutos [84].

Na área do controle postural, diversos estudos têm evidenciado a presença de propriedades multiescala em séries temporais posturográficas, as quais vêm permitindo uma melhor compreensão e caracterização do fenômeno em diferentes populações [19]–[23]. Por exemplo, por meio da análise da entropia amostral, demonstrou-se que, com o aumento da escala de tempo, a oscilação postural nos idosos torna-se menos estruturada (aumento da entropia) na direção  $y$ , porém mais regular (redução da entropia) na direção  $x$  [19], conforme ilustrado na Figura 8 para dados de idosos coletados em duas situações: na postura ereta quieta (condição controle) e na presença de estímulos sensoriais (condição estímulo).

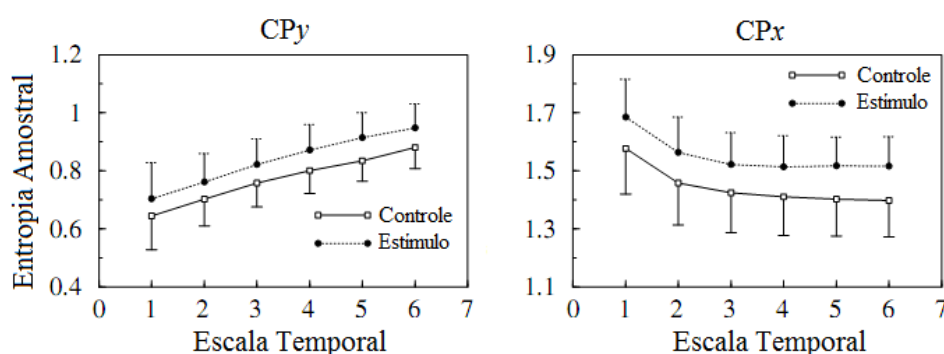


Figura 8. Entropia amostral sobre diferentes escalas de tempo para séries posturográficas de pessoas idosas nas direções cartesianas  $x$  (painel da direita) e  $y$  (painel da esquerda).

Fonte: traduzido de Costa et al. [19].

A presença de propriedades multifrequência em uma série temporal implica na existência de padrões relevantes sobre distribuições espectrais de potência específicas, as quais são determinadas pela frequência de corte utilizada na filtragem digital dos dados. Por exemplo, a partir de séries posturográficas de adultos saudáveis, um estudo obteve



conclusões conflitantes ao analisar os dados originais e depois repetir as análises para os dados filtrados com um filtro passa-baixa [23]. Sem a filtragem, as métricas expoente de escala e entropia amostral revelaram padrões de oscilação postural muito mais irregulares e menos estruturados em comparação com os dados filtrados.

A conclusão dos autores daquele estudo foi que a filtragem permitiu atenuar artefatos de alta frequência que introduziam no sinal certas irregularidades não oriundas do processo de controle postural [23]. Neste cenário, um outro trabalho argumenta que os padrões discriminantes em séries temporais no geral são frequentemente distorcidos por perturbações de alta frequência e por ruídos aleatórios, sendo necessária assim uma suavização destas componentes para tornar mais evidentes os padrões relevantes [14].

### **2.3.2. Principais Abordagens de Classificação**

De acordo com a literatura, as abordagens de classificação de séries temporais podem ser agrupadas em quatro categorias principais [2], [3]:

- (i) Abordagens baseadas em extração de características, onde a série é mapeada para um vetor de atributos.
- (ii) Abordagens baseadas em avaliação de similaridade, onde a série é dividida em subsequências e a classificação é realizada com base em medidas de distância.
- (iii) Abordagens baseadas em modelos probabilísticos, que realizam as inferências a partir de cálculos de probabilidade.
- (iv) Abordagens baseadas em aprendizagem automática de características por meio de modelos profundos de AM.

Nas abordagens das duas primeiras categorias supracitadas, a classificação é feita com o auxílio de modelos tradicionais de AM. Fazendo uma comparação entre elas, argumenta-se que, em geral, as abordagens baseadas em similaridade fornecem resultados competitivos em relação às baseadas em características, porém, com a desvantagem de serem consideravelmente mais lentas [12] (mais informações podem ser consultadas na literatura [2], [28]). Por este motivo, as abordagens baseadas em similaridade não foram incluídas no escopo desta tese. Foram excluídas do escopo também as abordagens da terceira categoria, na qual destaca-se o uso dos modelos ocultos de Markov (mais informações podem ser encontradas na literatura [2], [85], [86]).

Em outras palavras, incluiu-se no escopo da tese a primeira categoria de abordagens, que é mais utilizada em séries posturográficas na literatura, e também a quarta categoria, que ainda não foi empregada em séries posturográficas até onde se sabe, mas que vêm apresentando resultados promissores para séries temporais em geral.

### 2.3.3. Abordagens Baseadas em Extração de Características

Neste tipo de abordagem, a classificação dos dados é realizada com o auxílio de modelos tradicionais de AM, que são capazes de aprender padrões discriminantes a partir de atributos discretos, conforme já mencionado na subseção 2.2.3. Portanto, o primeiro passo dessas abordagens consiste em mapear as séries temporais em estudo para um conjunto de características, conhecido também como vetor de atributos, incluindo o rótulo da classe, assim como ilustra a Figura 9 para um conjunto de  $j$  séries mapeadas em  $k$  atributos cada. Este processo é denominado extração de características ou atributos [38], [87].




Figura 9. Ilustração do mapeamento de séries temporais para vetores de atributos.

Fonte: o autor.

Abordagens baseadas em extração de características são amplamente utilizadas na literatura para uma série de aplicações, inclusive para a classificação de séries temporais posturográficas, como será apresentado na seção de trabalhos correlatos. Conforme já mencionado anteriormente, suas principais vantagens são: treinamento rápido de forma geral, capacidade de lidar com poucos dados e possibilidade de visualizar as regras de classificação de forma intuitiva com modelos caixa-branca, como a árvore de decisão.

A principal desvantagem está na extração de atributos, a etapa mais importante e também a mais complexa deste tipo de abordagem [7], que demanda conhecimentos específicos da área, consumindo tempo e recursos [87]. Ainda assim, é um grande desafio identificar atributos que possam representar as propriedades dos dados em sua totalidade

[87]. Vale lembrar que os atributos escolhidos têm impacto decisivo no desempenho do modelo, independentemente da aplicação [7], [27], [87]. Diante do exposto, pode-se dizer que a extração de atributos reduz a praticidade e a robustez de abordagens que se utilizam deste recurso.

#### **2.3.4. Abordagens Baseadas em Aprendizagem Automática de Características**

Neste tipo de abordagem, a classificação dos dados é realizada por meio de modelos profundos de AM, que, conforme já elucidado, são capazes de aprender automaticamente padrões discriminantes das séries temporais, sem a necessidade de mapeá-las para atributos (vide subseção 2.2.4).

Estudos recentes têm realizado a classificação de séries temporais com diferentes modelos profundos, tais como as redes convolucionais, as redes profundas de crenças [8], [68], os *auto-encoders* e as redes recorrentes [3]. Dentre eles, têm-se observado destaque para as redes convolucionais, principalmente em termos de desempenho e de tempo de treinamento. Além disso, este modelo se encaixa mais adequadamente no escopo desta tese por permitir a aprendizagem de padrões multiescala dos dados, algo cuja relevância é objeto de investigação. São elencados abaixo os principais aspectos que diferem as redes convolucionais de outros modelos profundos, os quais embasaram a decisão pela sua inclusão neste trabalho:

- Representam atualmente o estado da arte para a classificação de séries temporais de diferentes origens [12], [14], [88], inclusive séries derivadas do movimento humano [7], que se assemelham aos dados em estudo nesta pesquisa.
- Permitem a aprendizagem de características multiescala dos dados [14], [27], o que acontece de forma hierárquica entre os diferentes estágios da rede por meio das camadas de sub-amostragem (vide subseção 2.2.5).
- Permitem a classificação de séries temporais com menor tempo de treinamento devido à sua arquitetura particular, onde os neurônios de camadas vizinhas são parcialmente conectados entre si [3] (vide subseção 2.2.5).

Focando a discussão nas abordagens que utilizam redes convolucionais, a classificação de séries temporais envolve a realização de algumas etapas. Primeiramente, as séries costumam ser normalizadas para a média nula e variância unitária [7], [8], trazendo robustez em termos de faixa de excursão dos sinais e também de eventuais deslocamentos

em amplitude. Depois, com o auxílio de uma janela deslizante de tamanho e passo arbitrários, as séries temporais são desmembradas em subsequências de menor tamanho, sendo cada uma delas rotulada com a classe da série original [7], [8], [14]. No treinamento, as subsequências são apresentadas à rede, uma a uma, para a aprendizagem automática de características. Depois, na fase de teste, contabiliza-se os rótulos de classe inferidos a todas as subsequências que compõem cada série, prevalecendo àquele mais frequente, como num esquema de voto [12].

Como já discutido em outros momentos, em comparação com as abordagens baseadas em extração de atributos, estas com redes convolucionais possuem algumas vantagens, destacando-se: taxas de acerto mais promissoras em geral e aprendizagem automática de características, que traz maior praticidade e robustez ao processo. A principal desvantagem está na necessidade de grandes volumes de dados para a obtenção de bons resultados, implicando em tempos de treinamento razoavelmente mais elevados.

### **2.3.5. Limitações das Abordagens Existentes**

A classificação de séries temporais representa uma das tarefas mais desafiadoras na área de AM devido à presença de propriedades complexas que as diferenciam de outros tipos de dados [3]. Estas propriedades são ainda mais acentuadas em séries fisiológicas, incluindo as séries posturográficas analisadas neste estudo.

Algumas destas propriedades são amplamente conhecidas e discutidas na literatura, tais como: alta dimensionalidade, ruído (tipicamente em larga escala) e componentes não-estacionárias [3]. Sendo assim, algumas abordagens de classificação já foram elaboradas levando em conta estes aspectos de alguma maneira. Outras, no entanto, ainda não são tão difundidas, como é o caso das propriedades multiescala e multifrequência abordadas na subseção 2.3.1, que têm se mostrado relevantes para a caracterização de séries, inclusive da posturografia, podendo assim contribuir para a classificação. Apesar disso, são raras as abordagens que levam em conta estes dois aspectos [14].

Esta limitação é a principal motivação desta tese, onde deseja-se investigar a relevância das propriedades multiescala e multifrequência para a classificação de séries posturográficas com modelos tradicionais de AM e também com redes convolucionais. Como estudo inicial nesta direção, o autor e colaboradores mostraram que os resultados da classificação podem ser influenciados por tais propriedades ao utilizar a árvore de decisão [24], um dos modelos tradicionais mais populares da literatura.

No estudo em questão, os experimentos foram realizados de forma independente para diferentes cenários de obtenção dos dados, tais como para certas frequências de amostragem e certas frequências de filtragem analisadas individualmente. Nesta tese, porém, dá-se ênfase a estratégias que permitam capturar as propriedades multiescala das séries ao longo de múltiplas escalas distintas, bem como as propriedades multifrequência ao longo de múltiplos espectros de potência, utilizando esquemas de análise conjunta.

## **2.4. Considerações Finais**

Neste capítulo, foram apresentadas as principais abordagens de classificação de séries temporais existentes na literatura, juntamente com os principais modelos de AM empregados para este propósito: os modelos tradicionais, no caso das abordagens baseadas em extração de características, e os modelos profundos, no caso das abordagens baseadas em aprendizagem automática de características. Neste último caso, foram discutidos os principais aspectos que embasaram a escolha pelas redes convolucionais nesta pesquisa. Foram apresentadas as vantagens e desvantagens de cada tipo de abordagem, ressaltando que a melhor escolha pode variar de estudo para estudo. O presente capítulo abordou também a limitação em comum destas abordagens, que figura como principal motivação da tese: a incapacidade de considerar as propriedades multiescala e multifrequência de séries temporais no processo de classificação.

# Capítulo 3

## Controle Postural

### 3.1. Considerações Iniciais

Neste capítulo, será discutido inicialmente na seção 3.2 os principais aspectos fisiológicos do controle postural, que é a capacidade do indivíduo de manter-se em equilíbrio durante as atividades de vida diária, garantindo sua segurança e independência [89]. Na sequência, a seção 3.3 abordará situações adversas como o envelhecimento e o acometimento por AVE, que, por trazerem diversas sequelas sensório-motoras, acarretam debilitações no controle postural do sujeito e aumentam o risco de acidentes envolvendo quedas, o que representa a principal causa mundial de morte em pessoas idosas [90]–[92]. Depois, na seção 3.4, será apresentada a posturografia, uma técnica amplamente utilizada nos meios acadêmico e clínico para a avaliação do controle postural por meio de séries temporais [17]. Em seguida, serão abordadas na seção 3.5 as principais métricas da literatura para a parametrização de séries da posturografia, as quais têm sido utilizadas como indicadores clínicos em diversos cenários. Por fim, serão apresentadas as considerações finais do capítulo na seção 3.6.

### 3.2. Definição

Nas mais diversas tarefas motoras, o alinhamento do corpo humano está em constante oscilação, mesmo que de forma sutil, em resposta à força da gravidade e aos mecanismos de controle neural. Isso acontece até mesmo na postura ereta quieta, ou seja, parado em pé o mais quieto possível, quando nenhuma força externa parece perturbar o equilíbrio [93]–[95]. Neste caso, observa-se um padrão específico de movimento denominado oscilação postural espontânea [95].

O controle postural constitui-se de dois componentes: equilíbrio (capacidade de manter o corpo em equilíbrio com as forças externas, sendo a mais proeminente delas a gravidade) e orientação (posicionamento dos múltiplos segmentos corporais em relação mútua e com o ambiente) [96]. Em outras palavras, o controle postural é a habilidade do indivíduo de manter o equilíbrio [97], [98]. Esta tarefa é realizada pelo sistema de controle postural (SCP), composto pelas componentes sensorial e motora do sistema nervoso central em um trabalho integrado [89]. O SCP tem a função determinar constantemente a melhor estratégia postural para a manutenção do equilíbrio, que pode ser a estratégia do tornozelo, do quadril, do passo ou uma combinação delas [94] (Figura 10). Isso permite a realização das atividades de vida diária de forma independente e segura [89].




Figura 10. Ilustração das estratégias posturais (a) do tornozelo, (b) do quadril e (c) do passo.  
Fonte: extraído de Shumway-Cook e Woollacott [99].

### 3.3. Debilitações do Controle Postural

Para a manutenção do equilíbrio, o SCP integra informações do sistema vestibular (e.g., forças gravitacionais que atuam no sujeito, aceleração da cabeça), de receptores visuais (i.e., informações sobre o ambiente e a localização, direção e velocidade do movimento) e do sistema somatossensorial (i.e., informações sobre o contato e a posição do corpo, incluindo os receptores cutâneos, receptores musculares, tendões, ligamentos e articulações) [100]–[102].

Assim, como o equilíbrio depende de múltiplas entradas sensoriais, uma falha em algum dos sistemas envolvidos pode dificultar a escolha de estratégias posturais adequadas, podendo ocasionar desequilíbrios e quedas [103], [104]. Neste cenário, falhas podem se originar, por exemplo, das alterações biológicas decorrentes do envelhecimento, e também das sequelas sensório-motoras decorrentes de doenças como o AVE.

### **3.3.1. Acidente Vascular Encefálico**

O AVE é caracterizado como um conjunto de alterações neurológicas causadas por falhas no suprimento sanguíneo do encéfalo [105]. Atualmente, além de figurar como uma das principais causas de morte no Brasil e no mundo, o AVE é uma das patologias que mais incapacitam o sujeito, tornando-o assim dependente de terceiros e gerando um grande impacto econômico e social [106], [107].

As inúmeras sequelas decorrentes do AVE expõem o indivíduo a uma série de conflitos sensoriais, aumentando significativamente o risco de acidentes envolvendo quedas. Isso porque pessoas pós-AVE utilizam estratégias posturais alternativas que nem sempre são efetivas para mantê-las em equilíbrio [108]. Por exemplo, um estudo relatou incidência de quedas de até 73% em indivíduos com até seis meses de lesão. Uma discussão mais detalhada deste assunto pode ser encontrada no trabalho de Silva [109].

### **3.3.2. Envelhecimento e Risco de Quedas**

De acordo com diretrizes da Organização Mundial da Saúde [110] e também com o estatuto do idoso<sup>1</sup> no Brasil, é considerado idoso todo indivíduo com 60 anos ou mais. Atualmente, uma em cada nove pessoas no mundo se enquadra nesta categoria, mas estima-se um crescimento alarmante para as próximas décadas [111]. De 810 milhões em 2012 (11,5% da população mundial), acredita-se que o número de idosos chegará a 1,4 bilhão em 2030 e a 2,1 bilhões em 2050 (cerca de 22% da população mundial), ano a partir do qual poderá haver mais idosos do que crianças menores de 15 anos no mundo, pela primeira vez na história. Este cenário é ainda mais crítico no Brasil, pois o crescimento deverá superar a média internacional. Acredita-se que a população idosa estimada em 2012 no país quase triplique até 2050, saindo de 12,6% (26,1 milhões de pessoas) para 30% da população (64 milhões de pessoas) [112].

---

<sup>1</sup> Disponível em: [http://www.planalto.gov.br/ccivil\\_03/leis/2003/110.741.htm](http://www.planalto.gov.br/ccivil_03/leis/2003/110.741.htm)



O envelhecimento é um processo dinâmico onde há alterações morfológicas, funcionais e bioquímicas que afetam progressivamente o organismo, limitando-o e tornando-o mais susceptível a agressões intrínsecas e extrínsecas, que terminam por leva-lo à morte [113]. Neste processo, os sistemas vestibular, visual e somatossensorial também são comprometidos, de forma que várias etapas do controle postural podem ser suprimidas, diminuindo assim a eficiência do SCP e levando a um aumento da instabilidade e do risco de quedas (RQ) [114], [115].

Define-se a queda como um evento onde a pessoa cai inesperadamente ao chão ou a algum outro nível mais baixo [92]. Dada a sua alta incidência e severidade, a queda em pessoas idosas é tratada hoje mundialmente como questão de saúde pública [116], sendo a principal causa de morte e de lesões graves nesta população [90], [91]. Estima-se que um em cada três idosos sofre pelo menos uma queda por ano [58]. Além de sequelas físicas e emocionais, isto gera também um grande impacto econômico. Por exemplo, somente nos Estados Unidos, gastou-se cerca de 19,2 milhões de dólares com o tratamento de complicações decorrentes de quedas em idosos no ano de 2000 [117].

O evento da queda possui uma série de fatores de risco envolvidos, que podem ser de origem interna (e.g., histórico de quedas, debilitações musculares, problemas de visão) e externa (e.g., iluminação inadequada, presença de obstáculos no ambiente, uso de calçados inapropriados) ao indivíduo [92], [118]. Um dos fatores de origem interna mais graves é o medo de cair (MC) em proporção excessiva [118], [119], que possui alta incidência entre os idosos residentes na comunidade, mesmo entre aqueles que nunca sofreram uma queda [118], [120]. Isso porque, ao tomar proporções excessivas, este medo se torna uma obsessão e passa a influenciar a rotina funcional do idoso, acarretando, por exemplo, em inatividade, redução da mobilidade e piora do condicionamento físico [120]–[126]. Já em proporções moderadas, o medo de cair não representa um problema, mas sim um reflexo da percepção do idoso frente ao real risco de cair em determinadas atividades [127].

Dentre os métodos propostos para avaliar RQ em idosos, os principais são [128]:

- *Aplicação de escalas clínicas específicas.* Por meio da análise de fatores de risco internos e externos, escalas clínicas como a *Morse Fall Scale* [129] e a *Fall Risk Assessment Tool* [130] permitem classificar o RQ do sujeito como baixo, moderado ou alto.

- *Monitoramento da ocorrência de quedas.* Aqui, monitora-se o indivíduo em ambiente doméstico por períodos de 6 a 12 meses em geral, verificando em tempo integral a ocorrência de quedas.
- *Análise do histórico de quedas.* Neste caso, considera-se o fato de que pessoas com episódios anteriores de queda (geralmente nos últimos 12 meses, reportado pelo próprio sujeito ou adquirido em prontuário médico) possuem risco aumentado para a ocorrência de novas quedas, desconsiderando outros fatores.
- *Aplicação de testes clínicos.* Neste caso, utiliza-se testes que objetivam avaliar condições específicas relacionadas ao RQ. Para isso, compara-se a pontuação obtida pelo sujeito no teste com valores de corte estabelecidos na literatura. Aqui, destacam-se o *Short Falls Efficacy Scale - International* (Short FES-I) e o *Mini-Balance Evaluation Systems Test* (Mini-BESTest).

O Short FES-I (ANEXO A) é um questionário clínico contendo sete perguntas sobre a preocupação do sujeito a respeito da possibilidade de cair durante atividades de vida diária [127]. Ao final, pode-se obter uma pontuação total mínima de 7 e máxima de 28 pontos, representando, respectivamente, preocupação mínima e preocupação máxima de cair. Valores de corte disponíveis na literatura estabelecem que um resultado entre 7 e 10 pontos representam baixo MC, ao passo que um resultado entre 11 e 28 pontos denota alto MC [131], sugerindo risco aumentado para quedas.

O Mini-BESTest [132] (ANEXO B) é um teste funcional que envolve a realização de 14 tarefas pelo indivíduo, onde são avaliadas limitações biomecânicas, limites de estabilidade, ajustes posturais antecipatórios, respostas posturais automáticas, organização sensorial e estabilidade durante a marcha. Cada tarefa é pontuada pelo terapeuta em uma escala de 0 a 2, sendo 0 para desempenho insatisfatório, 1 para desempenho moderado e 2 para desempenho normal. Assim, pode-se atingir uma pontuação total mínima de zero e máxima de 28. Este teste já foi utilizado com sucesso para estabelecer valores de corte sobre RQ em idosos, sendo que um resultado menor ou igual a 16 representa alto risco, enquanto um resultado maior do que 16 denota baixo risco [133], [134].

### **3.4. Posturografia**

A posturografia é uma técnica utilizada no meio clínico e principalmente no meio acadêmico para a avaliação do controle postural [17], possuindo assim muitas aplicações, tais como identificação dos efeitos de protocolos de reabilitação [22] e reconhecimento

de déficits posturais em diferentes populações [16], [20], [135]. Esta técnica consiste em mensurar alguma variável associada à oscilação postural espontânea do sujeito [17], que é observada na postura ereta quieta [95]. Uma das variáveis mais utilizadas é o centro de pressão (CP) [17], [136], [137], que representa o ponto de aplicação das forças de reação do solo em resposta aos movimentos do centro de gravidade do corpo. O CP reflete as respostas neuromusculares do indivíduo em função das perturbações internas (e.g., movimento involuntário dos órgãos, contrações musculares) e externas (e.g., força da gravidade) sofridas [89], [136].

Neste cenário, deve-se ressaltar que o CP não é mensurado diretamente, mas sim calculado a partir de componentes de força e de momento angular, as quais podem ser capturadas com o auxílio de certos dispositivos eletrônicos, dentre eles a plataforma de força [17]. Tal dispositivo consiste em uma placa de metal contendo diversos sensores de pressão, normalmente do tipo célula de carga ou piezoelétrico, capazes de mensurar as componentes de força,  $F_x$ ,  $F_y$  e  $F_z$ , e também de torque,  $M_x$ ,  $M_y$  e  $M_z$ , nas direções  $x$ ,  $y$  e  $z$ , respectivamente [17], conforme ilustrado na Figura 11.




Figura 11. Representação ilustrativa (a) de uma plataforma de força e (b) de um sujeito na postura ereta quieta sobre a plataforma.

Fonte: extraído de (a) Duarte e Freitas [17] e (b) Ferdjallah et al. [138].

Para capturar adequadamente as dinâmicas do controle postural, recomenda-se a coleta dos sinais de força e de momento com a plataforma em períodos de um a dois minutos, com uma frequência de amostragem de 100 Hz [139], [140]. Então, convencioando o posicionamento do indivíduo na plataforma conforme mostrado na Figura 12-(a), os sinais de força e de momento podem ser utilizados para calcular séries temporais das trajetórias do CP nas direções  $x$  e  $y$ , também conhecidas como séries temporais posturográficas, de acordo com as seguintes equações [17]:

$$CP_x = (-h \cdot F_y + M_x) / F_z \quad (2)$$

$$CP_y = (-h \cdot F_x - M_y) / F_z \quad (3)$$

Onde  $h$  é a altura de uma eventual base de apoio posicionada em cima da plataforma de força, como um tapete ou espuma.

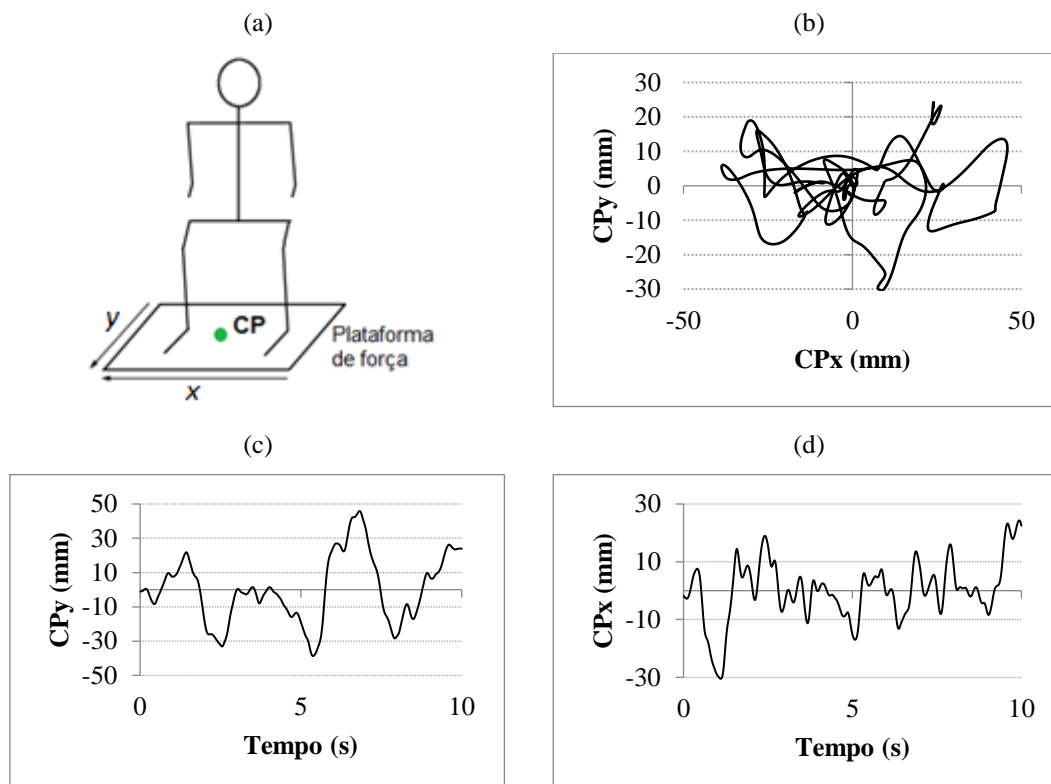


Figura 12. Ilustração (a) de um indivíduo posicionado sobre uma plataforma de força, (b) de um estatio-cinesiograma e (c,d) de estabilogramas.

Fonte: (a) adaptado de Duarte e Zatsiorsky [89], (b,c,d) o autor.

Existem duas formas principais de representação das séries posturográficas [17], [141]: individual em cada direção ( $x$  ou  $y$ ), o que constitui um estabilograma (Figura 12-(c,d)), e conjunta em ambas as direções ( $x$  versus  $y$ ), o que constitui um estatio-cinesiograma (Figura 12-(b)).

### 3.5. Parametrização de Séries Temporais Posturográficas

Uma prática comum na literatura é a parametrização de séries temporais posturográficas para valores discretos, como a média, por exemplo, o que facilita a análise dos

dados. Para isso, procura-se utilizar métricas capazes de capturar propriedades importantes das séries, pois assim elas podem ser utilizadas como indicadores clínicos nos mais diversos cenários, tais como para avaliar as capacidades e limitações posturais do sujeito e para decidir sobre protocolos de reabilitação e avaliar sua efetividade [22], [135], [142], [143]. Certas métricas têm sido utilizadas com sucesso para o estudo do controle postural em idosos [144], [145], inclusive na avaliação do risco de quedas [146], e também em pessoas pós-AVE [22], [109], [143], [147].

A literatura apresenta duas perspectivas principais de parametrização de séries posturográficas: a global e a estrutural [17], [20]. Na primeira, são extraídas informações a partir das amplitudes da série, tanto no domínio do tempo como no domínio da frequência [17], [20]. Já na segunda, são extraídas informações a partir da estrutura temporal da série [20]. A Figura 13 exemplifica a diferença entre métricas de avaliação global e estrutural para duas séries distintas, ambas com os mesmos níveis de amplitude, capturadas pelo desvio padrão, porém com uma estrutura temporal completamente diferente, mensuradas pela entropia amostral. Neste exemplo, percebe-se que somente a métrica estrutural é capaz de distinguir as duas séries.

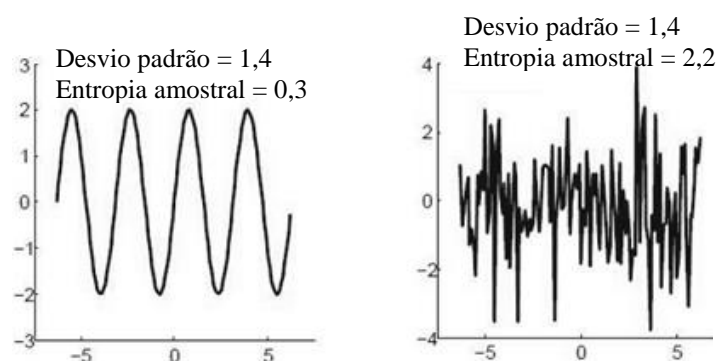


Figura 13. Desvio padrão e entropia amostral para uma série determinística (à esquerda) e aleatória (à direita)

Fonte: traduzido e adaptado de Kirchner [148].

As mais diversas métricas de avaliação global existentes descrevem uma mesma propriedade do controle postural: a estabilidade [20], [148]. Isso porque, nessa perspectiva, considera-se que as oscilações em uma série posturográfica representam uma espécie de erro motor cometido durante o controle da postura, sendo que, quanto maiores as amplitudes, maior a instabilidade [148]. Assim, são esperadas amplitudes maiores de oscilação para pessoas com algum tipo de acometimento sensório-motor. Por outro lado, as métricas de avaliação estrutural têm mapeado com sucesso várias outras propriedades do controle postural, tais como regularidade, complexidade e auto-similaridade [20], [148].

Atualmente, há um grande número de métricas de avaliação global e estrutural disponíveis na literatura [17]. Algumas delas são de uso mais geral, podendo ser aplicadas também a outros tipos de séries temporais, enquanto outras são destinadas especificamente a séries posturográficas. Essas métricas têm sido utilizadas na parametrização de séries tanto dos deslocamentos do CP (CPd) como da velocidade do CP (CPv), pois a velocidade é a forma mais precisa de informação sensorial utilizada para o controle da postura ereta quieta [149]. Neste contexto, não há um consenso sobre quais métricas são mais relevantes [17], motivo pelo qual recomenda-se considerar diferentes métricas, de avaliação global e estrutural, para uma avaliação mais completa do controle postural [150]–[152]. Nas duas subseções seguintes, serão apresentadas as métricas mais populares na literatura.

### 3.5.1. Métricas de Avaliação Global

A Tabela 1 elenca as métricas de avaliação global mais utilizadas na literatura para a parametrização de séries posturográficas, que podem ser divididas em três domínios: temporal, espectral e espacial. Nos dois primeiros casos, as métricas são unidimensionais, ou seja, calculadas para as séries nas direções  $x$  e  $y$  separadamente. Já as métricas espaciais são bidimensionais, i.e., calculadas simultaneamente para as séries em ambas as direções. Em outras palavras, enquanto as métricas temporais e espectrais são extraídas a partir dos estabilogramas (vide Figura 12-(c,d)), as métricas espaciais são extraídas a partir do estatocinesiograma (vide Figura 12-(b)).

#### Distância média

A distância média ( $Dm$ ) representa a distância entre o valor médio da série CPd e a origem [153]:

$$Dm_x = \frac{1}{m} \sum_{i=1}^m |CPd_x(i)| \quad (4)$$

$$Dm_y = \frac{1}{m} \sum_{i=1}^m |CPd_y(i)| \quad (5)$$

Sendo  $m$  o comprimento da série, ou seja, o número total de pontos amostrais.

Tabela 1. Métricas de avaliação global populares na literatura, com seus respectivos domínios, série de origem e estudos correlatos.

Domínio	Métrica	Série de origem	Estudos relacionados
Temporal	Distância média ( $Dm$ )	CPd	Carpenter et al. [154], Demura et al. [155], Ganesan et al. [153], Genthon et al. [147], Rugelj e Sevsek [156], Vette et al. [157], Zok et al. [158].
	Distância <i>root-mean-square</i> ( $Drms$ )	CPd	Cabeza-Ruiz et al. [159], Carpenter et al. [154], Deffeyes et al. [160], Demura et al. [155], Duarte e Freitas [17], Ganesan et al. [153], Rhea et al. [23].
	Desvio padrão ( $DP$ )	CPd	Castro [161], Demura et al. [155], Donker et al. [142], Duarte e Freitas [17], Ghomashchi et al. [150], Gurses e Celik [162], Kirchner et al. [20], Kirchner [148], Madeleine et al. [163]
	Amplitude de deslocamento ( $Ad$ )	CPd	Blaszczyk [164], Castro [161], Corriveau et al. [165], Deffeyes et al. [160], Doyle et al. [166], Duarte e Freitas [17], Ganesan et al. [153], Kirchner et al. [20], Kirchner [148], Lafond et al. [139], Zok et al. [158].
	Velocidade média ( $Vm$ )	CPv	Blaszczyk [164], Cabeza-Ruiz et al. [159], Castro [161], Corriveau et al. [165], Duarte e Freitas [17], Demura et al. [155], Ganesan et al. [153], Kirchner et al. [20], Kirchner [148], Lafond et al. [139], Rugelj e Sevsek [156], Vette et al. [157], Zok et al. [158].
	Desvio padrão da velocidade média ( $DPVm$ )	CPv	Demura et al. [155], Rhea et al. [23].
	Velocidade de pico ( $Vp$ )	CPv	Doyle et al. [166], Hewson et al. [15]
	Velocidade <i>root-mean-square</i> ( $Vrms$ )	CPv	Demura et al. [155], de Haart et al. [143], Rhea et al. [23], Silva [109].
Espacial	Velocidade média total ( $VTm$ )	CPv	Duarte e Freitas [17].
	Sway path ( $SP$ )	CPd	Baratto et al. [167], Deffeyes et al. [160], Donker et al. [135], [142], Han et al. [152], Lebiedowska e Syczewska [95].
	Deslocamento da Oscilação Total ( $DOT$ )	CPd	Blaszczyk [164], Castro [161], Duarte e Freitas [17], Kirchner et al. [20], Kirchner [148], Rugelj e Sevsek [156], Silva [109].
	Área do CP ( $Area$ )	CPd	Baratto et al. [167], Blaszczyk [164], Cabeza-Ruiz et al. [159], Castro [161], Deffeyes et al. [160], Demura et al. [155], Doyle et al. [166], Duarte e Freitas [17], Kirchner et al. [20], Kirchner [148], Lafond et al. [139], Oliveira et al. [168], Rugelj e Sevsek [156], Tallon et al. [151].
Espectral	Frequência espectral média ( $Fm$ )	CPd	Cabeza-Ruiz et al. [159], Carpenter et al. [154], Duarte e Freitas [17], Ganesan et al. [153], Genthon et al. [147], Lafond et al. [139], Silva [109], Zok et al. [158].
	Frequência de pico ( $Fpico$ )	CPd	Duarte e Freitas [17], Kirchner et al. [20].
	Concentração de $p\%$ da potência espectral ( $Fp$ )*	CPd	Baratto et al. [167], Demura et al. [155], Duarte e Freitas [17], Gurses e Celik [162], Kirchner et al. [20], Kirchner [148].

\* Este parâmetro é calculado para  $p = 50, 80$  e  $95$ .

### Distância RMS

A distância RMS (*Root Mean Square*) (*Drms*) representa uma forma alternativa de cálculo de distância a partir do sinal CPd [17], [153]:

$$Drms_x = \sqrt{\frac{1}{m} \sum_{i=1}^m [CPd_x(i)]^2} \quad (6)$$

$$Drms_y = \sqrt{\frac{1}{m} \sum_{i=1}^m [CPd_y(i)]^2} \quad (7)$$

### Desvio padrão

O desvio padrão (*DP*) mede a dispersão do sinal CPd ao longo do tempo em relação a um valor médio constante [17], [153]:

$$DP_x = \sqrt{\frac{\sum_{i=1}^m [CPd_x(i) - Dm_x]^2}{m - 1}} \quad (8)$$

$$DP_y = \sqrt{\frac{\sum_{i=1}^m [CPd_y(i) - Dm_y]^2}{m - 1}} \quad (9)$$

### Amplitude de deslocamento

A amplitude de deslocamento (*Ad*) representa a distância entre os deslocamentos máximo e mínimo do sinal CPd [17], [153]:

$$Ad_x = \max[CPd_x(n)] - \min[CPd_x(n)] \quad (10)$$

$$Ad_y = \max[CPd_y(n)] - \min[CPd_y(n)] \quad (11)$$

### Velocidade média

Por definição, a partir de uma série de posição, pode-se obter a respectiva série de velocidade a partir da aplicação da derivada de primeira ordem [19]. Portanto, em ambas



as direções  $x$  e  $y$ , uma série de velocidade do CP pode ser calculada a partir da derivada da série dos deslocamentos do CP naquela direção [153]:

$$CPv_x(n) = \frac{CPd_x(n+1) - CPd_x(n)}{t_a}, \quad n = 1, \dots, m-1 \quad (12)$$

$$CPv_y(n) = \frac{CPd_y(n+1) - CPd_y(n)}{t_a}, \quad n = 1, \dots, m-1 \quad (13)$$

Sendo  $t_a$  o tempo de amostragem da série CPd, que é o inverso da frequência de amostragem. Na sequência, a velocidade média ( $Vm$ ) pode ser calculada como [17]:

$$Vm_x = \frac{1}{m} \sum_{i=1}^m CPv_x(i) \quad (14)$$

$$Vm_y = \frac{1}{m} \sum_{i=1}^m CPv_y(i) \quad (15)$$

### Desvio padrão da velocidade média

O desvio padrão da velocidade média ( $DPVm$ ) está associado com a dispersão da série CPv em relação ao seu nível médio ( $Vm$ ) [155]:

$$DPVm_x = \sqrt{\frac{\sum_{i=1}^m [CPv_x(i) - Vm_x]^2}{m-1}} \quad (16)$$

$$DPVm_y = \sqrt{\frac{\sum_{i=1}^m [CPv_y(i) - Vm_y]^2}{m-1}} \quad (17)$$

### Velocidade de pico

A velocidade de pico ( $Vp$ ) representa o maior valor observado na série CPv [166]:

$$Vp_x = \max[|CPv_x(n)|] \quad (18)$$

$$Vp_y = \max[|CPv_y(n)|] \quad (19)$$

### Velocidade RMS

A velocidade RMS ( $Vrms$ ) representa uma forma alternativa de cálculo da velocidade da série CPd [155]:

$$Vrms_x = \sqrt{\frac{1}{m} \sum_{i=1}^m [CPv_x(i)]^2} \quad (20)$$

$$Vrms_y = \sqrt{\frac{1}{m} \sum_{i=1}^m [CPv_y(i)]^2} \quad (21)$$

### Velocidade média total

A velocidade média total ( $VTm$ ) considera as séries CPv nas direções  $x$  e  $y$  simultaneamente [17]:

$$VTm = \frac{f_a}{m} \sum_{i=1}^m \sqrt{[CPv_x(i)]^2 + [CPv_y(i)]^2} \quad (22)$$

Sendo  $f_a$  a frequência de amostragem da série CPd.

### Sway path

O *sway path* ( $SP$ ) é um parâmetro clínico utilizado para capturar a quantidade de atividade postural exibida no estatocinesiógrama [135], [152]:

$$SP = \sum_{i=1}^{m-1} \sqrt{[CPd_x(i+1) - CPd_x(i)]^2 + [CPd_y(i+1) - CPd_y(i)]^2} \quad (23)$$

### Deslocamento da oscilação total

O deslocamento da oscilação total ( $DOT$ ) representa o comprimento da série CPd sobre a base de suporte do indivíduo no estatocinesiógrama [17]:

$$DOT = \sum_{i=1}^m \sqrt{[CPd_x(i)]^2 + [CPd_y(i)]^2} \quad (24)$$

### Área do CP

Esta métrica é utilizada para estimar a dispersão da série CPd por meio da área de uma elipse que engloba 95% das trajetórias dentro do estatocinesiograma [17], conforme ilustra a Figura 14.

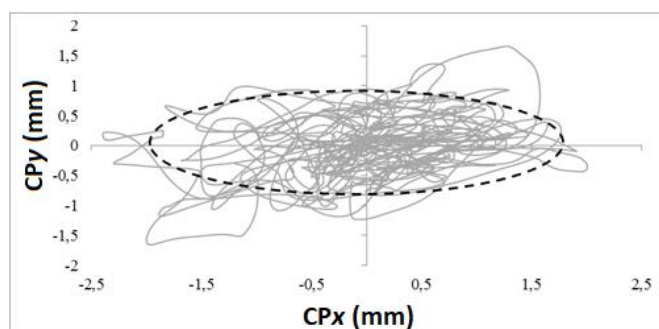


Figura 14. Ilustração de uma elipse (linha preta tracejada) que engloba 95% da área do estatocinesiograma.

Fonte: o autor.

### Métricas espectrais

A frequência espectral média ( $F_m$ ) representa o valor médio do espectro de potências das séries CPd nas direções  $x$  e  $y$ , enquanto a frequência de pico ( $F_{pico}$ ) consiste no maior valor daqueles espectros, conforme ilustra a Figura 15. Já a concentração de potência espectral ( $F_p$ ) estima o valor de frequência até onde, partindo da origem, concentram-se  $p\%$  da potência total do espectro [17], [148], [153] (Figura 15).




Figura 15. Espectro de potências de uma série CPd com a indicação das frequências de pico, média, em 50% e em 80% da concentração espectral total.

Fonte: extraído de Duarte e Freitas [17].

### 3.5.2. Métricas de Avaliação Estrutural

A Tabela 2 apresenta uma relação de métricas de avaliação estrutural amplamente utilizadas na literatura, juntamente com as propriedades do controle motor descritas por elas, a série a partir da qual são calculadas e, finalmente, alguns estudos que as utilizaram com sucesso. Todas as métricas em questão são unidimensionais, ou seja, calculadas para as séries nas direções  $x$  e  $y$  separadamente.

Tabela 2. Métricas de avaliação estrutural mais populares na literatura.

Métrica	Propriedade mapeada	Série de origem	Estudos relacionados
Entropia Amostral (EntAm)	Regularidade (ou previsibilidade)	CPd e CPv	Duarte e Sternad [21], Donker et al. [135], [142], Kirchner et al. [20], Kirchner [148], Madeleine et al. [163], Rhea et al. [23], Roerdink et al. [22], Tallon et al. [151].
Entropia Multiescala (EntMe)	Complexidade	CPd e CPv	Duarte e Sternad [21], Costa et al. [19], Kirchner et al. [20], Kirchner [148].
Expoentes de escala ( $\alpha$ ) e de Hurst (H)	Auto-similaridade (ou fractalidade)	CPd e CPv	Amoud et al. [169], Delignières et al. [170], [171], Donker et al. [142], Duarte e Sternad [21], Duarte e Zatsiorsky [89], [136], Kirchner et al. [20], Kirchner [148], Rhea et al. [23],
Dimensão de correlação	Graus de liberdade ativos	CPd	Gurses e Celik [162], Donker et al. [142], Doyle et al. [166], Ghomashchi et al. [150], Han et al. [152], Roerdink et al. [22].
Expoente de Lyapunov	Estabilidade local	CPd	Donker et al. [142], Pascolo et al. [172], Roerdink et al. [22].

#### Entropia amostral

A entropia amostral (EntAm) [173] é uma métrica que avalia o grau de regularidade ou previsibilidade em uma série temporal; em outras palavras, ela mensura o grau de surpresa ou incerteza da série ao longo do tempo [22], [174]. Neste contexto, pequenos valores de EntAm representam alto grau de regularidade, sugerindo um comportamento determinístico nos dados. Por outro lado, valores mais elevados de EntAm denotam baixo grau de regularidade, sugerindo assim comportamento aleatório nos dados. Para séries posturográficas, quanto menor o valor da EntAm, mais regulares e estruturados são os padrões de oscilação postural do indivíduo [22], [142].

O procedimento de cálculo da EntAm pode ser descrito de maneira breve: dada uma série temporal qualquer, calcula-se o logaritmo natural negativo da probabilidade condicional de que sequências similares com  $n$  pontos amostrais permaneçam similares após a adição de um ponto amostral vizinho ( $n+1$ ) dentro de uma tolerância  $r$  [173]. Em outras palavras, o parâmetro  $r$  representa um limiar de distância utilizado para definir se os segmentos de comprimento  $n$  e  $n+1$  representam padrões similares dentro da série.

### Entropia multiescala

O cálculo da EntAm não leva em conta as múltiplas escalas de tempo existentes em uma série temporal. Diante desta limitação, Costa et al. [18], [175] introduziram a chamada entropia multiescala (EntMe), capaz de mensurar a complexidade de uma série por meio da análise de sua regularidade sob diferentes escalas.

A EntMe consiste em calcular a EntAm para  $k$  escalas de tempo distintas de uma série, e então plotar os resultados como uma função da escala, conforme ilustra a Figura 16 para séries posturográficas obtidas de adultos e de idosos. Na  $k$ -ésima escala, a série é transformada calculando-se a média dentro de janelas consecutivas e não-sobrepostas de  $k$  pontos amostrais, como mostra Figura 17. Por fim, calcula-se o chamado índice de complexidade (IC), que estima a área sob a curva plotada [18]. Este índice é obtido fazendo o somatório dos valores da EntAm para as diferentes escalas [18], assim como:

$$IC = \sum_{k=1}^K EntAm(k) \quad (25)$$

Sendo  $K$  o fator máximo de escala considerado.

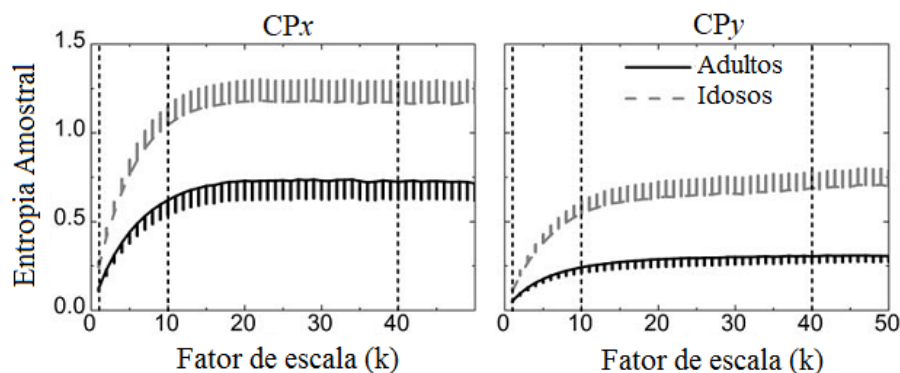


Figura 16. Curva da entropia multiescala para séries posturográficas nas direções  $x$  (painel da esquerda) e  $y$  (painel da direita).

Fonte: traduzido de Duarte e Sternad [21].




Figura 17. Transformação de uma série para fatores de escala iguais a 2 (painel superior) e 3 (painel inferior).

Fonte: adaptado de Silva [77].

Como pode ser observado na Figura 16, a oscilação corporal de idosos torna-se mais irregular (maior EntAm) em comparação com adultos com o aumento da escala de tempo das séries posturográficas. Neste exemplo, o IC é maior para os idosos em ambas as direções  $x$  e  $y$ , representando maior complexidade na oscilação postural desta população frente aos adultos.

### Expoentes de escala e de Hurst

Processos com correlações de longa duração, denominados também auto-similares ou fractais, são conhecidos por exibirem aparência similar sob diferentes escalas de tempo [21]. Este parece ser o caso do processo de controle postural, pois estudos da área têm encontrando auto-similaridade em séries temporais posturográficas [89], [136], [176], como pode ser visto na Figura 18.

Dentre os métodos existentes para a investigação de auto-similaridade em séries temporais, destacam-se dois: *Detrended Fluctuation Analysis* (DFA) [177] e *Scaled Windowed Variance* (SWV) [178], que permitem o cálculo do expoente de escala ( $\alpha$ ) e do expoente de Hurst ( $H$ ), respectivamente. Estas métricas podem ser relacionadas por meio da equação (26) para processos do tipo Gaussiano fracionário, ou por meio da equação (27) para processos do tipo Browniano fracionário [148], [170]:

$$H = \alpha \quad (26)$$

$$H = \alpha - 1 \quad (27)$$




Figura 18. Ilustração da auto-similaridade de uma série posturográfica em diferentes escalas de tempo.  
Fonte: traduzido de Duarte e Zatsiorsky [136].

É importante mencionar que processos Gaussiano e Browniano fracionários são amplamente utilizados para modelar processos auto-similares reais, inclusive o processo de controle postural [94]. Neste cenário, séries posturográficas de velocidade do CP têm sido modeladas com sucesso via processo Gaussiano, ao passo que séries de deslocamento do CP vêm sendo descritas via processo Browniano, que é a função integrada do Gaussiano [148]. A Figura 19 ilustra a faixa de valores que  $\alpha$  pode assumir para estes dois tipos de processos, dentro dos quais estão inseridos os ruídos do tipo Gaussiano ( $\alpha = 0,5$ ;  $H = 0$ ),  $1/f$  ( $\alpha = 1$ ) e Browniano ( $\alpha = 1,5$ ;  $H = 0,5$ ) [22], [89], [142].

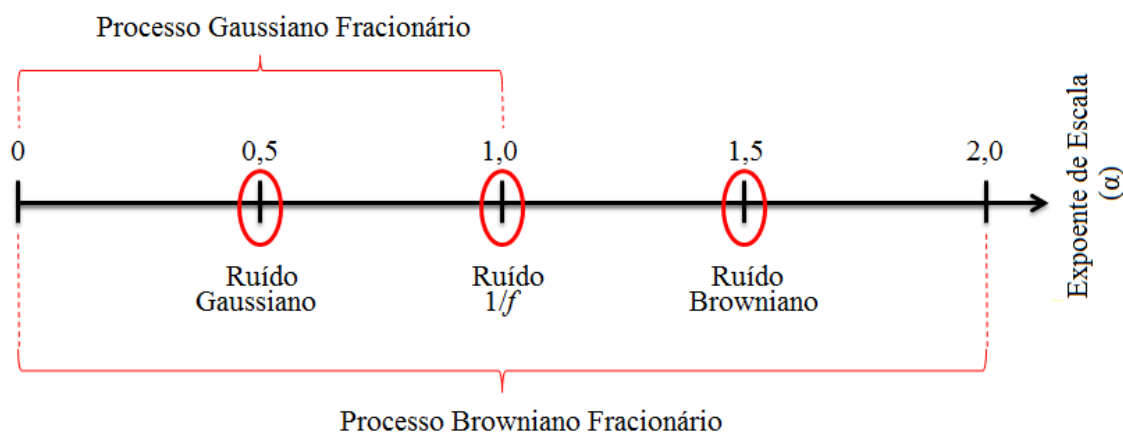


Figura 19. Faixa de excursão possível do expoente de escala.  
Fonte: o autor.

Os expoentes  $\alpha$  e de  $H$  descrevem a suavidade de uma série temporal, sendo que quanto maior o valor dessas métricas, mais suave é a dinâmica da série [89], [142], [177]. Tomando como exemplo o expoente de Hurst ( $\alpha$  pode ser deduzido pelas equações (26) e (27)),  $H = 0,5$  sugere comportamento estocástico, enquanto  $H \neq 0,5$  indica a presença de algum tipo de correlação nos dados. Se  $0 \leq H < 0,5$ , é mais provável que valores positivos sejam sucedidos por valores negativos e vice-versa, refletindo transições mais rápidas e menor suavidade na série. Por outro lado, se  $0,5 \leq H \leq 1$ , é mais provável que valores positivos sejam sucedidos por valores positivos, e negativos sucedidos por negativos, refletindo transições mais lentas e maior suavidade na série [22], [176], [179].

Na literatura, argumenta-se que o método DFA fornece boas estimativas para  $\alpha$  para séries temporais que se comportam como processo Gaussiano, como é o caso da séries de velocidade do CP, mas perdem precisão para séries como as dos deslocamentos do CP, que se comportam como um processo Browniano [180]. Neste segundo caso, considera-se mais adequado analisar o expoente  $H$  obtido pelo método SWV [170]. Por isso a importância de se considerar ambas as métricas, mesmo elas estando altamente relacionadas.

Com relação ao cálculo de  $\alpha$  com o método DFA, para uma série temporal  $x(n)$  qualquer de comprimento  $m$ , o primeiro passo é remover a delimitação da série por meio do processo de integração [20]–[22], tal como:

$$y(n) = \sum_{i=1}^n x(i), \quad n = 1, \dots, m \quad (28)$$

Isso se aplica também a séries posturográficas, pois as oscilações do CP são delimitadas dentro de uma área de suporte [22]. Na sequência, a série integrada  $y(n)$  é dividida em janelas não sobrepostas de comprimento  $w$  onde  $w < m$ . Então, em cada janela, a tendência local  $y_w(n)$  é estimada por um ajuste linear utilizando o método dos mínimos quadrados, sendo depois subtraída da série integrada. A flutuação da série integrada sem a componente de tendência pode ser estimada pela seguinte expressão [148], [169]:

$$F(w) = \sqrt{\frac{1}{m} \sum_{i=1}^m [y(i) - y_w(i)]^2} \quad (29)$$



Para séries temporais fisiológicas com propriedades complexas, a curva  $F(w)$  versus  $w$  obedece uma relação de potência na forma  $F(w) \propto w^\alpha$ , sendo  $\alpha$  o expoente de escala [21]. Assim,  $\alpha$  pode ser estimado por meio da inclinação de uma linearização da curva  $F(w)$  versus  $w$  em escala logarítmica [21], [148], [169].

Já para o cálculo de H pelo método SWV, o primeiro passo consiste em dividir uma série temporal  $x(n)$  qualquer de comprimento  $m$  em  $k$  janelas consecutivas e não sobrepostas de tamanho  $w$ . Então, remove-se da série a tendência local dentro de cada janela. Depois, calcula-se o desvio padrão para cada uma das  $k = 1, \dots, m/w$  janelas, assim como:

$$DP_k = \sqrt{\frac{1}{w-1} \sum_{i=l}^{w+(l-1)} [x(i) - x_{med}]^2}, \quad \begin{cases} l = (w(k-1)) + 1 \\ k = 1, \dots, m/w \end{cases} \quad (30)$$

Onde  $x_{med}$  representa a média da série dentro de uma determinada janela  $k$ . Na sequência, calcula-se a média do desvio padrão entre todas as janelas da série, ou seja:

$$S_k = \frac{1}{m/w} \sum_{i=1}^{m/w} DP_i \quad (31)$$

Finalmente, o expoente H pode ser estimado como sendo a inclinação de uma linearização da curva  $S_k$  versus  $w$  em escala logarítmica [178].

### **Dimensão de correlação e máximo expoente de Lyapunov**

Alguns estudos já testaram o uso de métricas oriundas da teoria de sistemas dinâmicos para a parametrização de séries posturográficas, com destaque para a dimensão de correlação e para o máximo expoente de Lyapunov [22]. Entretanto, tais métricas podem fornecer estimativas duvidosas quando aplicadas nestes dados [148]. Isso porque, para a obtenção de resultados confiáveis, as séries precisam apresentar comportamento puramente determinístico, o que não acontece em séries posturográficas. Embora possuam componentes determinísticas, processos fisiológicos de maneira geral são influenciados

também por diversos fatores estocásticos [181], inclusive o processo de controle postural [176]. Diante do exposto, as métricas em discussão não serão consideradas nesta tese.

### **3.6. Considerações Finais**

O controle postural é uma habilidade de máxima importância na vida do indivíduo, pois garante sua independência funcional. Porém, há diversas situações que podem prejudicar esta habilidade, aumentando a chance de desequilíbrios e quedas, o que representa hoje a principal causa de morte em pessoas idosas no mundo. Deu-se ênfase neste capítulo a duas destas situações: o envelhecimento, cujas estatísticas de crescimento são alarmantes a nível mundial e principalmente nacional, e o AVE, uma das principais causas mundiais de morte e de incapacidade funcional em adultos. Tudo isso demonstra a importância de tecnologias destinadas à compreensão e caracterização do controle postural que permitam, por exemplo, identificar déficits posturais ou risco de quedas aumentado. Isso pode ser feito aliando modelos de AM, tradicionais ou profundos, e séries temporais posturográficas, conforme realizado nesta tese.

# Capítulo 4

## Trabalhos Relacionados

### 4.1. Considerações Iniciais

Neste capítulo, serão discutidos os principais estudos da literatura que possuem relação com esta tese. Mais especificamente, na seção 4.2, serão abordados trabalhos que utilizaram modelos tradicionais de AM especificamente para a classificação de séries temporais posturográficas. Na seção 4.3, dada a ausência de estudos utilizando redes convolucionais para este mesmo fim, serão discutidos trabalhos que empregaram tal modelo para a classificação de outros tipos de séries temporais com propriedades similares às séries posturográficas. Então, por meio da análise dos aspectos promissores e das limitações destes estudos correlatos, serão justificadas diversas escolhas feitas para o método proposto na tese. Por fim, serão feitas as considerações finais do capítulo na seção 4.4.

### 4.2. Classificação de Séries Posturográficas com Modelos Tradicionais

Em comparação com outras aplicações, ainda é consideravelmente baixo o número de estudos na literatura que empregam modelos tradicionais de AM para a classificação de séries temporais posturográficas. Neste cenário, a Tabela 3 relaciona alguns destes estudos e aponta suas principais características, que serão melhor discutidas na sequência. Como pode ser visto na Tabela 3, tais estudos visam diferentes investigações sobre o controle postural, tais como detecção de quedas em tempo real [182] e identificação de estratégias motoras utilizadas para a manutenção do equilíbrio [183].

Tabela 3. Principais características de estudos correlatos envolvendo modelos tradicionais de AM.

Estudo	Finalidade	Amostra	Tempo de coleta (s)	Freq. de amostragem (Hz)	Pré-processamento	Atributos	Classificador(es) utilizado(s)	Método de avaliação	Melhor desempenho
Hewson et al. [15]	Identificação de histórico de quedas	- 10 adultos jovens - 10 idosos com histórico de quedas - 10 idosos sem histórico de quedas	10	100	<sup>a</sup> Filtragem passa-baixa dos sinais	<sup>d</sup> 01 global	Modelo de Função Discriminante (MFD)	<i>Leave-one-out</i>	<sup>f</sup> 90%
Kim et al. [182]	Deteção de quedas em tempo real	01 robô bípede	-	100	-	<sup>e</sup> 05 globais	SVM	VC (10 partições)	<sup>f</sup> 98,5%
Goh et al. [183]	Identificação de habilidades posturais	- 19 adultos saudáveis - 11 adultos autistas	60	100	<sup>b</sup> Seleção de atributos	<sup>d,e</sup> 41 globais <sup>d,e</sup> 01 estrutural	AD, FA, NB, MLP, Rede Bayesiana, SVM, <i>k</i> -NN	VC (10 partições)	<sup>g</sup> 97,6% (FA)
Saripalle et al. [42]	Identificação de estratégias posturais	14 jovens saudáveis	40	1000	<sup>c</sup> Seleção de atributos	<sup>d,e</sup> 23 globais	SVM, <i>k</i> -NN, MFD	VC (4 partições)	<sup>f</sup> 88% (SVM)
Rasku [184]	Identificação de estratégias/habilidades posturais	- *41 adultos saudáveis - *33 pessoas idosas	60	50	-	<sup>e</sup> 01 global	<i>k</i> -NN	VC (10 partições)	<sup>f</sup> 91,5%
Giovanini e Nievola [26]	Identificação de habilidades posturais	- *19 adultos saudáveis - *19 adultos pós-AVE	60	100	<sup>a</sup> Filtragem passa-baixa dos sinais <sup>b</sup> Seleção de atributos	<sup>d,e</sup> 28 globais <sup>d,e</sup> 18 estruturais	AD, NB, MLP, SVM, <i>k</i> -NN, Programação Genética (PG)	<i>Leave-one-out</i>	<sup>f</sup> $\cong$ 80% (MLP)
Giovanini et al. [16]	Identificação de habilidades/tarefas posturais	- *19 adultos pós-AVE	60	100	-	<sup>d,e</sup> 16 globais	AD e PG	-	<sup>f</sup> 72,8% (AD)

\* Amostra submetida a mais de uma tarefa de equilíbrio

<sup>a</sup> Filtro do tipo Butterworth com frequência de corte igual a 10 Hz<sup>b</sup> Seleção tipo filtro com o algoritmo *Correlation-based Feature Selection*<sup>c</sup> Seleção tipo filtro com a técnica *Fast Simulated Annealing*<sup>d</sup> Atributos calculados a partir do sinal CPV<sup>e</sup> Atributos calculados a partir do sinal CPD<sup>f</sup> Desempenho medido pela acurácia<sup>g</sup> Desempenho medido pela área sob a curva ROC (*Receiver Operator Characteristic*)

Com a análise dos estudos correlatos listados na Tabela 3, identificou-se aspectos promissores e também aspectos limitantes comuns entre eles, os quais serão aproveitados e aprimorados nesta tese para a elaboração de soluções mais eficientes e robustas. Dentre os aspectos promissores, destacam-se:

- *Uso da velocidade de pico média e da posição média do CP como atributos.* Com isso, tanto Hewson et al. [15] como Kim et al. [182] obtiveram desempenhos satisfatórios com diferentes classificadores. Na tese, além dos atributos em questão, são considerados também outros atributos posturográficos de avaliação global e estrutural (vide seção 3.5), conforme sugerido por aqueles autores para estudos futuros [15], [182].
- *Uso de atributos derivados da velocidade do CP.* Isto foi observado na maioria dos estudos correlatos, tendo auxiliado na obtenção de resultados satisfatórios. Isso porque a velocidade é a forma mais precisa de informação sensorial utilizada para a estabilização do equilíbrio na postura quieta [149]. Na tese, são utilizados 17 atributos oriundos da velocidade do CP (vide seção 3.5).
- *Uso de métodos de seleção de atributos.* Com o auxílio desta prática, Goh et al. [183] obtiveram desempenho acima de 90% para seis dos sete classificadores avaliados, ao passo que Saripalle et al. [42] reportaram 92,4% de acurácia com o  $k$ -NN e, finalmente, Giovanini e Nievola [26] alcançaram cerca de 80% de acurácia com uma MLP. Esta prática é adotada também na tese, só que considerando um número maior de atributos em comparação com os estudos citados (vide seção 3.5), oferecendo assim mais opções de escolha durante a seleção.
- *Avaliação de vários modelos.* Como pode ser observado na Tabela 3, estudos têm alcançado desempenhos satisfatórios utilizando os mais diversos classificadores. Ou seja, não há superioridade de algum deles em particular para lidar com séries posturográficas. Por este motivo, na tese, diversos classificadores são avaliados para diferentes parâmetros de configuração.

Dentre as limitações observadas em comum nos estudos correlatos, destacam-se:

- *Ausência de captura de padrões multiescala e multifrequência.* Em todos os estudos correlatos, a extração de atributos foi realizada para uma única escala temporal das séries, determinada pela frequência de amostragem dos dados, bem como para uma única distribuição espectral de potência, determinada pela frequência de corte da filtragem dos dados, quando houve filtragem no pré-processamento. Porém, conforme abordado na subseção 2.3.1, séries posturográficas possuem padrões multiescala e multifrequência úteis para a sua caracterização, os quais podem ajudar a aprimorar a classificação. Na tese, a extração de atributos foi otimizada de forma a capturar tais padrões.
- *Tamanho restrito da população.* Tanto Hewson et al. [15] como Goh et al. [183] utilizaram bases de dados com menos de 20 instâncias por classe, limitando assim a confiabilidade dos resultados. Na tese, são utilizadas bases maiores.
- *Tempo de coleta inadequado.* Hewson et al. [15] e Saripalle et al. [42] utilizaram séries coletadas durante, respectivamente, 10 segundos e 40 segundos. Entretanto, para o estudo do controle postural, recomenda-se o uso de dados coletados em períodos de um a dois minutos [139]. Na tese, são utilizadas séries posturográficas coletadas por 60 segundos.
- *Frequência de amostragem inadequada.* O processo de controle postural se reflete em uma ampla variedade de escalas temporais de uma série posturográfica [19], [185]. Para capturar adequadamente todas estas variações, recomenda-se o uso de uma frequência de amostragem de 100 Hz [140]. Valores mais baixos, tal como 50 Hz utilizado por Rasku [184], podem ser insuficientes para capturar as oscilações posturais em sua totalidade. Já valores mais altos, tal como 1000 Hz adotado por Saripalle et al. [42], podem provocar colinearidades que alteram as estruturas da série [186]. Na tese, são utilizadas séries coletadas a 100 Hz, conforme a recomendação citada.
- *Ausência de atributos estruturais.* Com exceção de Goh et al. [183] e de Giovanini e Nievola [26], os demais estudos correlatos utilizaram somente atributos oriundos da avaliação global do CP. Conforme já discutido, tais atributos descrevem

apenas a estabilidade postural do sujeito, ao passo que atributos de avaliação estrutural mapeiam diversas outras propriedades do controle postural, sendo amplamente utilizados em estudos da área [22], [142]. Portanto, visando uma caracterização mais completa, diversos atributos de avaliação global e estrutural são considerados na tese (vide seção 3.5).

- *Ausência de manipulação sensorial no controle da postura.* Dentre os trabalhos correlatos, somente Rasku [184], Giovanini e Nievola [26] e Giovanini et al. [16] utilizaram dados capturados em diferentes condições sensoriais de equilíbrio, tais como sob privação da visão e sob alteração na superfície de contato do pé com o solo. Tais manipulações permitem identificar certas limitações do sujeito, como alta dependência da visão ou da atenção para o controle postural [143]. Na tese, são utilizadas séries coletadas em quatro situações distintas de controle da postura.

Por fim, deve-se fazer uma ponderação sobre o estudo de Kim et al. [182]: foram utilizados dados coletados de um robô bípede, e não de pessoas. Porém, grosso modo, pode-se supor que o controle postural naquela máquina se assemelha ao do corpo humano, podendo servir assim para investigações preliminares sobre as quedas em seres humanos. Este é o único estudo listado na Tabela 3 que considerou dados de outras fontes — acelerômetros, mais especificamente — além das séries posturográficas.

### 4.3. Classificação de Séries Temporais com Redes Convolucionais

Até onde se sabe, não há estudos na literatura que tenham utilizado redes convolucionais para a classificação de séries temporais posturográficas. Mas alguns trabalhos já utilizaram com sucesso estas redes para a classificação de outros tipos de séries com propriedades similares, os quais serão discutidos em mais detalhes nesta seção.

#### Estudo Correlato 1

O conceito de aprendizagem multiescala em séries temporais com modelos profundos foi inicialmente abordado por Hamel et al. [27], que propuseram uma abordagem inspirada nas redes convolucionais para a classificação de sinais de música, denominada *Multi-Time-Scale Learning model*. A inspiração está no uso de uma camada de sub-amostragem entre a primeira e a segunda camada oculta do modelo, que, levando em conta as

camadas de entrada e de saída, possui cinco camadas no total. Os hiperparâmetros mais relevantes são: função de ativação sigmoide e entropia cruzada como função de custo a ser minimizada.

Para a avaliação da abordagem, os autores utilizaram 14660 exemplos de treinamento, 1629 exemplos de validação e 6499 exemplos de teste, sendo cada exemplo uma série de áudio rotulada com o respectivo gênero musical. Utilizou-se o *holdout* como método de avaliação e a área sob a curva ROC como métrica de desempenho. Dentre os resultados experimentais, o melhor desempenho obtido foi de 85%, ultrapassando quatro outras abordagens do estado da arte para a classificação da mesma base em estudo.

O estudo em questão evidencia principalmente a relevância da aprendizagem de padrões multiescala para a classificação de séries temporais. Mesmo possuindo uma única camada de sub-amostragem, o que restringe as análises a apenas duas escalas de tempo das séries, a abordagem proposta foi capaz de superar outros métodos do estado da arte. Na tese, visando a análise de mais escalas, são consideradas mais camadas de sub-amostragem, conforme recomendado inclusive por Hamel et al. [27] para estudos futuros. Outro aprimoramento está no uso da função de ativação ReLU, que tem rendido melhores resultados do que funções mais tradicionais como a sigmoide utilizada por aqueles autores [13], [76], [81]. Por fim, este trabalho correlato não utiliza estratégias de aprendizagem de padrões multifrequência das séries.

## **Estudo Correlato 2**

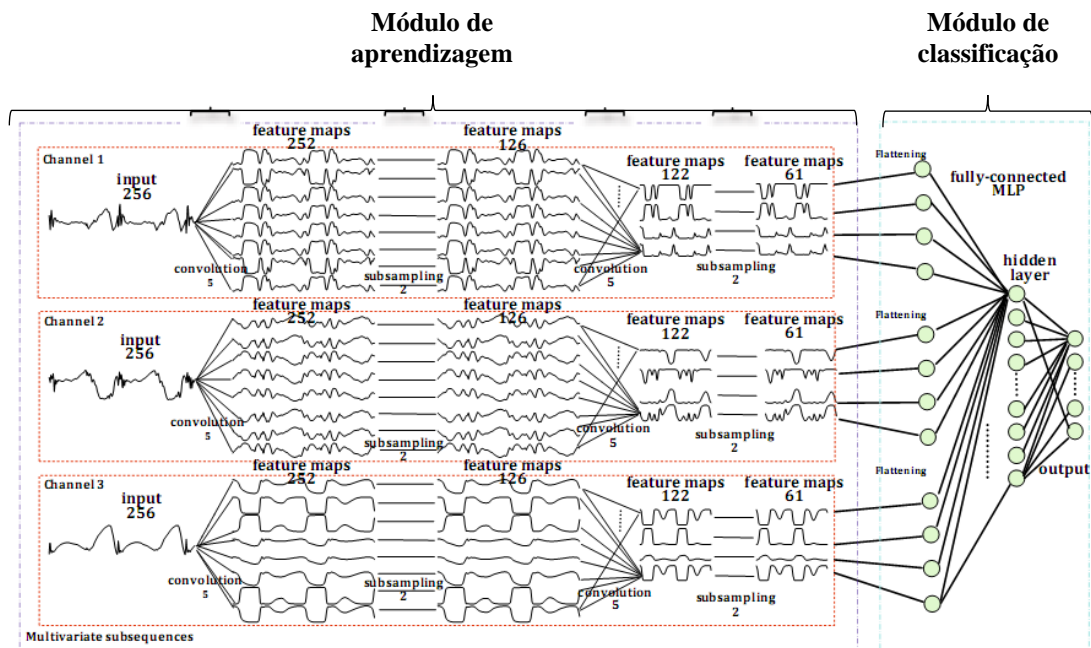
No trabalho de Zheng et al. [7], os autores propuseram uma abordagem baseada em redes convolucionais de múltiplos canais para a classificação de séries temporais multivariadas, situação em que cada instância é composta por mais de uma série. Batizada de *Multi-Channels Deep Convolutional Neural Net*, a abordagem possui: três canais de entrada, um módulo de aprendizagem com dois estágios encadeados por canal, cada um deles composto por uma camada de convolução e uma camada de sub-amostragem, e, finalmente, um módulo de classificação composto por uma MLP, que unifica as características aprendidas ao longo dos três canais. A Figura 20 ilustra a abordagem em questão de forma global, mostrando todos os seus canais, e também de forma local, mostrando um canal em particular e detalhando os parâmetros de configuração.

Para a avaliação da abordagem, foi utilizada uma base contendo 84 séries temporais fisiológicas de movimento humano com 6000 amostras cada, coletadas com sensores



inerciais. Após normalizadas para a média nula e variância unitária, as séries foram desmembradas em subsequência com o auxílio de uma janela deslizante de tamanho 256 pontos amostrais. Experimentos foram realizados para determinar o melhor passo de deslizamento da janela entre 128, 64, 32, 16 e 8. Em todos os casos, o desempenho foi avaliado com o método *leave-one-out*, adotando a acurácia como métrica. Dentre os resultados, foi observado um aumento linear sutil da acurácia em função da redução do deslizamento da janela, variando desde 90,3% para o passo 128 até 93,4% para o passo 8.

(a)



(b)

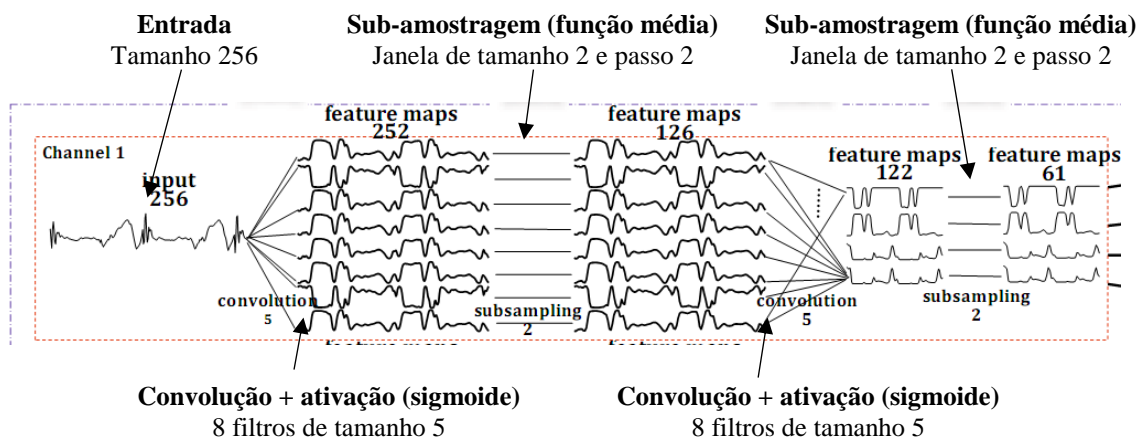


Figura 20. Ilustração da abordagem *Multi-Channels Deep Convolutional Neural Net*, de forma (a) global e (b) local.

Fonte: traduzido e adaptado de Zheng et al. [7].

O principal aspecto promissor observado neste estudo é a utilização bem sucedida de redes convolucionais para a classificação de séries fisiológicas multivariadas oriundas do movimento humano, tal como objetiva-se nesta tese. Na solução apresentada, as séries de uma instância passam por canais individuais no módulo de aprendizagem, e depois as características aprendidas são combinadas para a classificação. A mesma estratégia está sendo utilizada na tese visto que, nas bases em estudo, cada instância é composta por pares de séries posturográficas.

Outra contribuição importante deste estudo correlato é a indicação de pequenos passos de deslizamento para a extração de subsequências com a janela deslizante. Isso pode ser explicado pelo fato de que, quanto menor o passo, mais subsequências são geradas para o treinamento da rede convolucional, que sabidamente demanda muitos exemplos para a obtenção de bons resultados [12], [13].

Embora os autores não mencionem, a abordagem proposta por eles realiza a aprendizagem de padrões multiescala dos dados, dada a presença de duas camadas de sub-amostragem por canal. Porém, como ambas empregam uma janela não-sobreposta de tamanho 2 apenas, a aprendizagem se restringe a escalas de tempo muito próximas da escala original. O uso de janelas maiores poderia permitir a análise de escalas de tempo mais variadas, revelando padrões de curta e de longa duração. Outra limitação está no uso da função sigmoide para ativação dos neurônios da rede, que poderia ser substituída por funções mais eficientes como a ReLU. Por fim, a abordagem em questão não utiliza estratégias de aprendizagem multifrequência.

### **Estudo Correlato 3**

Dentre os estudos descritos nesta seção, o trabalho de Cui et al. [14] é o que mais se alinha com os propósitos desta tese. Isso porque aqueles autores propuseram uma abordagem baseada em redes convolucionais para a classificação de séries temporais diversas considerando a aprendizagem de padrões multiescala e multifrequência dos dados. Denominada *Multi-Scale Convolutional Neural Network*, a abordagem em questão possui: um estágio de transformação dos dados que alimenta múltiplos canais de entrada, um estágio de convolução e de sub-amostragem locais, um estágio de convolução e sub-amostragem globais, e, finalmente, um estágio de classificação (Figura 21).

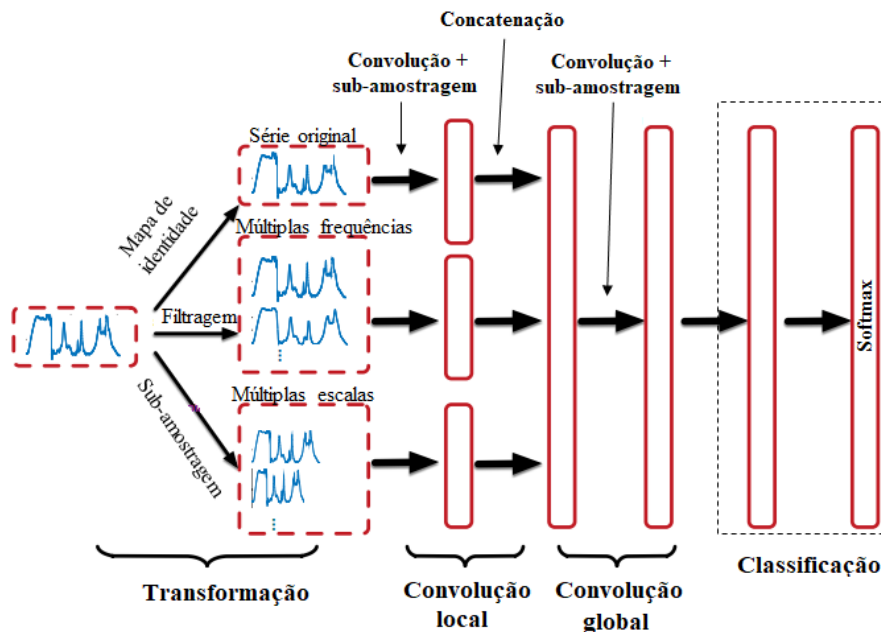


Figura 21. Ilustração da abordagem *Multi-Scale Convolutional Neural Network*.  
Fonte: traduzido de Cui et al. [14].

No estágio de transformação, os dados passam por dois tipos de pré-processamento: (i) sub-amostragem pela função de média aritmética, para obter variantes do sinal em diferentes escalas de tempo, e (ii) filtragem passa-baixa via média móvel com diferentes tamanhos de janela, para obter variantes da série com diferentes níveis de suavização. Então, por meio dos múltiplos canais, a série original e suas variantes são inseridas simultaneamente na rede.

Primeiro, a série original, as versões sub-amostradas e as versões filtradas são processadas separadamente por camadas de convolução e de sub-amostragem, o que os autores chamaram de convolução local. Então, os mapas de características resultantes dessa análise individual são concatenados entre si e seguem para uma nova etapa de convolução e sub-amostragem, que os autores denominam convolução global, já que os mapas foram unificados. As camadas de convolução foram configuradas com 256 filtros cada, e as camadas de sub-amostragem empregaram a função *max-pooling*. Por fim, os mapas resultantes seguem para a classificação, realizada com o auxílio da função softmax precedida por uma camada de entrada com 256 neurônios.

Para a avaliação do modelo, foram utilizadas 44 bases de séries temporais, cada qual com seu número de exemplos, comprimento de série e quantidade de classes. Para cada base, os dados foram normalizados e depois divididos em subsequências com uma

janela deslizante de passo unitário e tamanho igual a 90% do comprimento da série. O treinamento da rede foi realizado com o algoritmo de retropropagação em conjunto com o método estocástico de descida do gradiente, utilizando o erro no conjunto de teste como métrica de desempenho. O erro de validação foi usado como critério de parada do treinamento. Alguns dos hiperparâmetros foram otimizados com o auxílio do método *grid search*, tais como o tamanho dos mini-lotes, o tamanho dos filtros convolucionais e o tamanho da janela de sub-amostragem.

Dentre os resultados do estudo, em comparação com outras 14 abordagens do estado da arte, os autores registraram desempenho superior para a abordagem proposta em 10 das 44 bases analisadas, perdendo somente para duas das abordagens concorrentes.

O principal aspecto promissor observado neste estudo correlato é o sucesso obtido na classificação de séries temporais ao utilizar redes convolucionais em conjunto com estratégias de aprendizagem multiescala e multifrequência, o que representa um dos principais propósitos desta tese. Com isso, aqueles autores conseguiram superar abordagens do estado da arte para diversas bases de dados.

Vale ressaltar, porém, que a abordagem de Cui et al. [14] realiza a aprendizagem de padrões multiescala em dois momentos: de forma manual, no estágio inicial de transformação dos dados; e de forma automática dentro da rede, por meio das camadas de sub-amostragem. Na tese, visando reduzir esforços manuais com o pré-processamento dos dados, priorizou-se a aprendizagem multiescala automática realizada nas camadas de sub-amostragem, deixando assim este trabalho para a rede. Isso melhora também a praticidade de uso da abordagem, evitando a necessidade de armazenar e gerenciar diferentes variantes das séries.

Outra questão importante reside na aprendizagem de padrões multifrequência. Para este propósito, Cui et al. [14] empregaram filtragem passa-baixa nos dados por meio da média móvel, utilizando diferentes tamanhos de janela deslizante para obter diferentes níveis de suavização. Como pode ser visto na Figura 22, quanto maior a janela de um filtro do tipo média móvel, maior é a banda passante na curva de resposta em frequência. Neste cenário, os tamanhos da janela foram definidos pelos autores em função do comprimento das séries de entrada, que variou conforme a base analisada. Acredita-se que o uso dessa estratégia se deva ao fato daquela abordagem visar a classificação de séries temporais em geral, sem focar em um tipo específico. Assim, não foi necessário definir

parâmetros mais específicos que geralmente variam conforme o tipo da série em estudo, como a ordem do filtro e a frequência de corte.

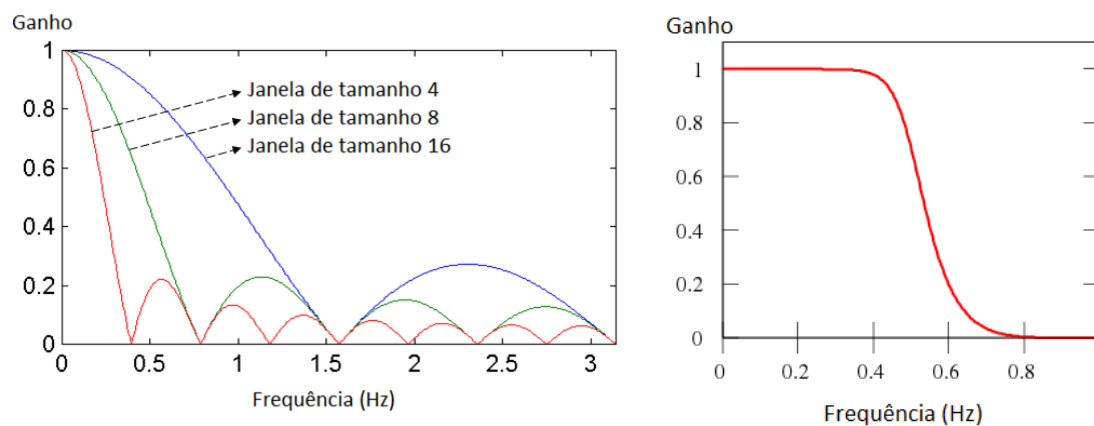


Figura 22. Resposta em frequência de um filtro Butterworth passa-baixa (painel à direita) e de um filtro média móvel (painel à esquerda).

Fonte: adaptado de [187].

A desvantagem dessa estratégia é que, em comparação com outros filtros digitais passa-baixa como o Butterworth, a média móvel possui resposta em frequência não tão bem comportada, com maior atenuação dentro da banda passante e alta oscilação de ganho fora dela, região onde o ganho deveria ser nulo idealmente. Além disso, sem um conhecimento mais profundo sobre os dados em análise, este processamento pode atenuar componentes espectrais relevantes das séries. Na tese, como se objetiva especificamente a classificação de séries temporais posturográficas, a etapa de filtragem é projetada considerando tipo de filtro, atraso, ordem e frequência de corte ideais para este sinal. Isto permite obter séries filtradas com distribuição espectral de potência mais adequada em comparação com técnicas como a média móvel.

Finalmente, ao invés de incorporar múltiplos canais para alimentar de uma só vez na rede as diferentes variantes da série, como optaram Cui et al. [14], fixou-se nesta tese apenas dois canais de entrada para as séries posturográficas nas direções  $x$  e  $y$ , apresentando as variações em diferentes rodadas de treinamento. Esta prática permite maximizar os exemplos de treinamento e traz robustez a possíveis variações nos dados [12], [13].

#### 4.4. Considerações Finais

Este capítulo abordou alguns trabalhos da literatura relacionados com esta tese, os quais envolvem o uso de modelos tradicionais de AM e de redes convolucionais para a

classificação de, respectivamente, séries posturográficas e séries temporais de diferentes tipos.

Em resumo, diversos modelos tradicionais têm sido utilizados com sucesso para a classificação de séries posturográficas, mas as abordagens propostas não realizam a aprendizagem de padrões multiescala e multifrequência dos dados, o que poderia ajudar a aprimorar os resultados. Redes convolucionais também têm mostrado grande potencial para a classificação de séries temporais em geral, inclusive séries fisiológicas oriundas do movimento humano. Neste cenário, algumas abordagens introduzidas já permitem a aprendizagem de padrões multiescala e multifrequência dos dados, mas ainda necessitam de modificações para tornar o processo mais prático, eficiente e customizado para séries posturográficas.

# Capítulo 5

## Método

### 5.1. Considerações Iniciais

A Figura 23 ilustra as principais etapas do método proposto na tese para a avaliação da hipótese de pesquisa, as quais serão descritas em detalhes ao longo deste capítulo.

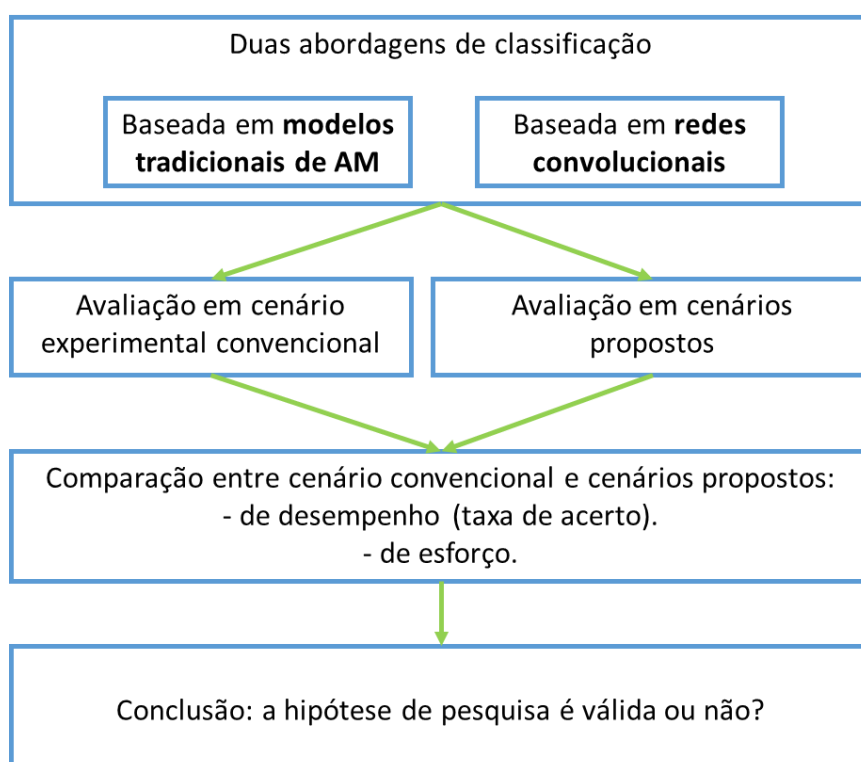


Figura 23. Diagrama ilustrando as principais etapas do método da tese.  
Fonte: o autor.

## 5.2. Bases de Dados

Para uma melhor compreensão das abordagens de classificação da tese, que serão explicadas mais adiante, serão apresentadas primeiro as três bases de dados selecionadas para os experimentos. Isso porque algumas etapas das abordagens foram ajustadas de acordo com certas particularidades destes dados. Em resumo, cada uma das bases contém séries temporais posturográficas oriundas de dois grupos distintos: adultos e idosos, na primeira base; idosos com alto risco de quedas e idosos com baixo risco, na segunda base, e; adultos saudáveis e adultos pós-AVE, na terceira base. Por meio de tais bases, foi possível avaliar o desempenho das abordagens para distinguir o controle postural em situações onde as diferenças provêm principalmente de déficits sensorio-motores decorrentes: do envelhecimento, do aumento do risco de quedas, e de um episódio de AVE, respectivamente (vide seção 3.3). A Tabela 4 resume as principais características das bases em questão. Em todas elas, uma instância denota um par de séries posturográficas nas direções  $x$  e  $y$  com 6000 pontos amostrais cada (60 s de duração  $\times$  100 Hz de amostragem).

Tabela 4. Principais características das bases utilizadas nos experimentos da tese.

	<b>Base 1</b>	<b>Base 2</b>	<b>Base 3</b>
Número total de instâncias	1908	864	114
Número de instâncias por grupo	Adultos: 1044 Idosos: 864	Idosos com alto risco: 432 Idosos com baixo risco: 432	Adultos saudáveis: 57 Adultos pós-AVE: 57
Duração de tempo das séries (s)	60	60	60
Frequência de amostragem das séries (Hz)	100	100	100
Comprimento das séries (em pontos amostrais)	6000	6000	6000

### 5.2.1. Base 1: Adultos e Idosos

A primeira base utilizada na tese foi originalmente coletada por Santos e Duarte [188] e disponibilizada publicamente<sup>2</sup> pelos autores. Essa base contém séries posturográficas de dois grupos: um de 87 adultos com idades entre 18 e 59 anos, e o outro de 76 idosos com idades entre 60 e 85 anos. As séries foram obtidas a partir dos dados de força e de momento daqueles sujeitos em quatro tarefas de controle da postura ereta quieta, cada uma repetida três vezes: (i) permanecer sobre uma superfície rígida com os olhos abertos, (ii) sobre uma superfície rígida com os olhos fechados, (iii) sobre uma superfície

<sup>2</sup> Disponível em: <https://physionet.org/physiobank/database/hbedb/>



macia (espuma) com os olhos abertos, e (iv) sobre uma superfície macia com os olhos fechados. Em todos os casos, os dados foram coletados com o auxílio de uma plataforma de força durante 60 s a uma frequência de amostragem de 100 Hz.

Dentre os 76 idosos recrutados no estudo original, quatro não foram capazes de executar todas as tarefas de controle postural solicitadas pelos autores, motivo pelo qual foram excluídos das análises nesta tese. Com isso, dispõe-se no total de 1908 instâncias: 1044 oriundas do grupo de adultos ( $87 \text{ sujeitos} \times 4 \text{ tarefas} \times 3 \text{ repetições}$ ) e 864 derivadas do grupo de idosos ( $72 \text{ sujeitos} \times 4 \text{ tarefas} \times 3 \text{ repetições}$ ), como mostrado na Tabela 4.

### **5.2.2. Base 2: Risco de Quedas em Idosos**

A segunda base utilizada na tese foi composta a partir de uma reorganização da primeira base, apresentada na subseção anterior. Primeiro, descartou-se todo o grupo de adultos, mantendo apenas os 72 idosos. Isso porque os métodos clínicos de caracterização do risco de quedas existentes na literatura são destinados especificamente a esta população (vide subseção 3.3.2). Na sequência, os sujeitos foram separados em dois grupos: idosos com alto risco de quedas, comportando 36 deles, e idosos com baixo risco de quedas, comportando os outros 36. Com isso, dispõe-se de 436 instâncias em cada grupo ( $36 \text{ sujeitos} \times 4 \text{ tarefas} \times 3 \text{ repetições}$ ), totalizando assim 864 instâncias.

Para a separação dos sujeitos, foi utilizado um critério envolvendo a análise de três fatores de risco principais (vide subseção 3.3.2): (i) histórico de pelo menos uma queda no último ano, (ii) presença de MC em proporções elevadas, indicado por um resultado superior a 10 pontos no Short FES-I, e (iii) debilitações funcionais severas, indicadas por uma pontuação menor ou igual a 16 no Mini-BESTest. Todas estas informações (histórico de quedas e resultados dos testes mencionados) foram disponibilizadas por Santos e Duarte no estudo original [188]. Neste cenário, foi categorizado com alto risco de quedas todo sujeito que se encaixou em pelo menos um dos três critérios acima. Em outras palavras, só foi identificado com baixo risco o sujeito que não se encaixou em nenhum dos critérios.

### **5.2.3. Base 3: Adultos Saudáveis e Adultos Pós-AVE**

A terceira base utilizada na tese foi coletada originalmente por Silva [109] a partir de dois grupos de sujeitos, um com 19 adultos pós-AVE e o outro com 19 adultos saudá-

veis pareados, todos submetidos a três tarefas de controle da postura ereta quieta: (i) permanecer sobre uma superfície rígida com os olhos abertos, (ii) sobre uma superfície rígida com os olhos fechados, e (iii) sobre uma superfície macia (espuma) com os olhos abertos. Em todos os casos, os dados de força e de momento foram adquiridos com uma plataforma de força durante 60 s a 100 Hz, e depois utilizadas para calcular as séries posturográficas. Assim, dispõe-se de 114 instâncias no total: 57 provenientes do grupo de adultos pós-AVE e as outras 57 do grupo de adultos saudáveis (19 sujeitos  $\times$  3 tarefas, em ambos os casos), como mostra a Tabela 4. O uso desta base foi aprovado pelo Comitê de Ética em Pesquisa da PUCPR sob o parecer de n. 991.103 (ANEXO C) e formalizado por meio de um Termo de Compromisso de Utilização de Dados (ANEXO D).

### 5.3. Abordagem de Classificação Baseada em Modelos Tradicionais

A Figura 24 ilustra a abordagem de classificação de séries temporais posturográficas baseada em modelos tradicionais de AM proposta na tese. Cada etapa da abordagem será detalhada ao longo desta seção.

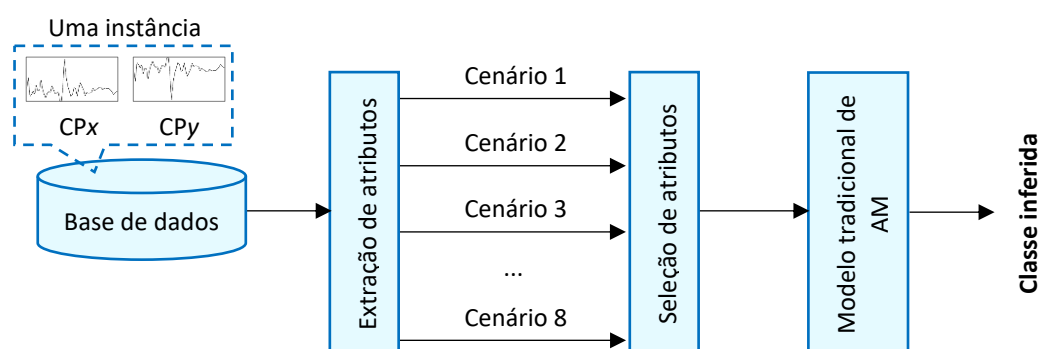


Figura 24. Abordagem de classificação baseada em modelos tradicionais da tese.

Fonte: o autor.

#### 5.3.1. Etapa de Extração de Atributos

Para o mapeamento das séries posturográficas em atributos discretos, foram implementadas duas rotinas computacionais no Matlab R2013b [189]: a rotina de parametrização global, responsável pelo cálculo de 30 atributos de avaliação global, e a rotina de parametrização estrutural, responsável pelo cálculo de 12 atributos de avaliação estrutural, totalizando assim 42 atributos por instância, ou seja, por par de séries do CP nas direções  $x$  e  $y$ . Tais rotinas serão descritas em mais detalhes na sequência.

### Rotina de parametrização global

A rotina de parametrização global realiza o cálculo das 17 métricas de avaliação global apresentadas na subseção 3.5.1. Dentre elas, 13 são unidimensionais, produzindo assim 26 atributos por instância. As outras quatro métricas são bidimensionais, resultando em mais quatro atributos por instância. Em outras palavras, cada instância da base é mapeada para 30 atributos de avaliação global. O funcionamento da rotina em questão pode ser resumido nos passos a seguir:

- 
- (i) *Para cada instância da base de dados:*
  - (ii) Lê as séries de deslocamento CP<sub>x</sub> e CP<sub>y</sub> armazenadas em planilha Excel.
  - (iii) Remove o nível médio das séries.
  - (iv) Calcula as métricas de avaliação global listadas na Tabela 1.
  - (v) Armazena os 30 atributos resultantes em uma planilha Excel de saída.
- 

O passo (iii) é um procedimento comum na literatura visto que a posição média do CP depende apenas da posição absoluta da pessoa sobre a plataforma de força, que geralmente não é controlada, sendo desprovida assim de qualquer informação relevante sobre o controle postural [17].

Sobre o passo (iv), o cálculo das métricas é feito seguindo seus respectivos procedimentos e equações matemáticas descritas na subseção 3.5.1. Neste cenário, para o cálculo da métrica área do CP, os eixos da elipse são determinados com o auxílio da técnica de análise de componentes principais [190]. Por fim, as métricas espectrais são calculadas utilizando uma implementação disponibilizada na literatura [17].

### Rotina de parametrização estrutural

A rotina de parametrização estrutural calcula as três métricas de avaliação estrutural descritas na subseção 3.5.2, desconsiderando a dimensão de correlação e o máximo expoente de Lyapunov, conforme justificado. As métricas consideradas são unidimensionais e calculadas para as séries de deslocamento e também de velocidade do CP, produzindo assim 12 atributos por instância (3 métricas × 2 tipos de série × 2 direções). O funcionamento desta rotina pode ser resumido nos seguintes passos:

- 
- (i) *Para cada instância da base de dados:*
  - (ii) Lê as séries de deslocamento CP<sub>x</sub> e CP<sub>y</sub> armazenadas em planilha Excel.

- (iii) Realiza o detrending das séries, dependendo da métrica a ser calculada.
  - (iv) Calcula as séries de velocidade nas direções  $x$  e  $y$  seguindo as equações (12) e (13), respectivamente.
  - (v) Calcula as métricas EntAm,  $\alpha$  e  $H$  a partir das séries de posição e de velocidade sob condições específicas de pré-processamento.
  - (vi) Armazena os 12 atributos resultantes em uma planilha Excel de saída.
- 

Sobre o passo (iii), o uso de detrending depende da métrica em análise. No caso dos expoentes  $\alpha$  e  $H$ , os dados não são submetidos a nenhum tipo de detrending manual, pois os métodos de cálculo já empregam técnicas específicas para este fim. Já no caso da EntAm, as séries passam inicialmente por detrending via *Empirical Mode Decomposition* (EMD) [19], [175], o que ajuda a remover as correlações de longa duração e as componentes não-estacionárias dos dados que afetam a precisão dos cálculos [19]. A técnica EMD consiste em decompor uma série qualquer em *Intrinsic Mode Functions* (IMFs) de diferentes distribuições espectrais, eliminando depois àquelas de menor frequência, cuja maior parte da potência espectral se concentra em até 1 Hz. Na tese, após um levantamento de 99% da concentração espectral das IMFs dos dados em estudo, conforme mostrado no Capítulo de Resultados Experimentais (vide subseção 6.2.1), decidiu-se subtrair de cada série as quatro últimas funções.

Para o cálculo da EntAm, a série é primeiramente normalizada para a média nula e variância unitária [173], [191]. Para isso, é realizada a subtração do nível médio e depois a divisão pelo desvio padrão. Então, com o auxílio de uma rotina em Matlab disponível na literatura [192], a EntAm é calculada utilizando os parâmetros  $n = 2$  e  $r = 0,15$  para as séries de deslocamento do CP [19], [21], e  $n = 2$  e  $r = 0,55$  para as séries de velocidade do CP [20], [148].

O cálculo dos expoentes  $\alpha$  e  $H$  com os métodos DFA e SWV, respectivamente, envolve o processamento da série em janelas consecutivas e não sobrepostas por repetidas vezes, usando a cada vez um tamanho de janela que permita a divisão exata da série, começando em dois pontos amostrais (i.e., dividindo a série em  $m/2$  janelas) e terminando em  $m$  pontos (i.e., dividindo a série em uma única janela). Porém, seguindo recomendações da literatura para a obtenção de resultados mais precisos, são descartados alguns dos menores e alguns dos maiores tamanhos de janela [178], como mostra a Figura 25.

Tamanho série	$2^6$	$2^7$	$2^8$	$2^9$	$2^{10}$	$2^{11}$	$2^{12}$	$2^{13}$	$2^{14}$	$2^{15}$	$2^{16}$	$2^{17}$
Linear det.	2-0	2-1	2-2	2-2	2-2	3-4	3-5	3-5	4-5	5-5	6-5	7-5
Bridge det.	1-0	1-0	1-0	2-2	2-3	2-4	2-4	2-5	3-6	3-7	3-7	3-7

Figura 25. Recomendações de exclusão de tamanhos de janela para os métodos DFA e SWV.  
Fonte: traduzido de Cannon et al. [178].

Como pode ser visto, a decisão dos tamanhos de janela a se descartar (que é feita de forma automática pela rotina) depende de dois fatores: o tipo de detrending empregado nos dados e o comprimento da série temporal. Por exemplo, se a série possui aproximadamente  $2^7$  pontos amostrais, e se o método de análise emprega *linear detrending* nos dados, deve-se desconsiderar dos cálculos os dois menores e o maior tamanho possíveis de janela. Na tese, é utilizada a técnica *bridge detrending* com o SWV, que consiste em subtrair da série a linha que conecta a primeira com a última amostra dentro de cada janela [178]. Já a DFA utiliza por padrão a técnica *linear detrending*, onde remove-se da série a tendência estimada dentro de cada janela por meio de uma regressão linear. Com relação ao segundo fator, como será explicado posteriormente, o comprimento da série depende da escala de tempo analisada, variando desde 6000 pontos amostrais ( $\cong 2^{12}$ ) na escala original até 600 pontos ( $\cong 2^9$ ) na maior escala considerada neste trabalho.

### Cenários de geração de atributos

Além do cálculo convencional, realizado para as séries apenas na escala de tempo e espectro de potência originais, cada um dos 42 atributos é calculado também nos esquemas multiescala e multifrequência propostos nesta tese, visando investigar a hipótese.

O esquema multiescala consiste em calcular um mesmo atributo para diferentes fatores de escala  $k$  da série temporal tomando  $k = 1, 2, \dots, 10$ , onde a série é transformada calculando-se a média dentro de janelas consecutivas e não sobrepostas de  $k$  pontos amostrais, de maneira análoga ao procedimento da entropia multiescala (vide Figura 17). Com isso, o número de amostras da série é gradualmente reduzido sem alterar a sua duração de tempo original, pois produz-se amostras mais espaçadas no tempo. Como os dados em estudo foram coletados a 100 Hz, este esquema permite analisar as séries com uma resolução máxima de 0,01 s, quando  $k = 1$ , e mínima de 0,1 s, quando  $k = 10$ , como mostra a Figura 26 para uma série posturográfica em uma janela de 1 s de duração.




Figura 26. Série posturográfica representada para os fatores de escala 1, 2 e 10.  
Fonte: o autor.

Como discutido, o processo de escalamento tem como consequência a redução do número de pontos amostrais da série, o que pode prejudicar a precisão dos atributos de forma geral. Neste cenário, a entropia amostral é a métrica mais sensível, requerendo de  $10^n$  a  $20^n$  pontos para a obtenção de boas estimativas [193], ou seja, de 100 a 400 pontos quando  $n = 2$ , como na tese. Diante disso, foi escolhido um fator máximo de escala igual a 10, que reduz o comprimento das séries em estudo de 6000 para 600 pontos amostrais.

O esquema multifrequência consiste em calcular um mesmo atributo para diferentes espectros de potência da série, que são obtidos empregando filtragem digital do tipo Butterworth passa-baixa sem atraso de 4ª ordem [17], [188] com três frequências de corte praticadas na literatura para séries posturográficas: 10 Hz [17], 5 Hz [194] e 2,5 Hz [168]. Como estas séries possuem a maior parte da potência espectral concentrada abaixo de 1 Hz em geral [148], tal procedimento permite atenuar os artefatos de mais alta frequência sem causar perda de informação significativa. Em outras palavras, isso permite suavizar gradualmente as séries, ajudando a evidenciar padrões relevantes distorcidos por eventuais artefatos e ruídos presentes nos dados.

Em ambos os esquemas multiescala e multifrequência, obtêm-se uma curva do atributo, ou em função do fator de escala, no primeiro caso, ou então em função da frequência de filtragem, no segundo caso, conforme exemplifica a Figura 27 para o atributo expoente de escala calculado para uma série posturográfica na direção  $x$ . Neste contexto,

são introduzidas seis técnicas de parametrização destas curvas para valores discretos, visando capturar diferentes características:

- Técnica do somatório: inspirada no índice de complexidade da entropia multiescala (vide subseção 3.5.2), esta técnica consiste em calcular a soma dos valores da curva, estimando assim a área sob a curva.
- Técnica da média: consiste em calcular a média entre os valores da curva, estimando assim o comportamento médio do atributo.
- Técnica da variância: consiste em calcular a variância entre os valores da curva, estimando assim a dispersão do atributo em torno do valor médio.
- Técnica do coeficiente angular: consiste em calcular o coeficiente angular de uma linearização da curva, descrevendo assim a taxa de variação do atributo.
- Técnica do somatório sinalizado: consiste em calcular a soma dos valores da curva, multiplicando o resultado por -1 caso ela seja decrescente, ou mantendo o resultado caso seja crescente. O comportamento da curva é determinado com a técnica do coeficiente angular, onde um coeficiente positivo representa curva crescente, e um coeficiente negativo, curva decrescente.
- Técnica da média sinalizada: análoga à técnica anterior, só que utilizando a média dos valores da curva ao invés do somatório.

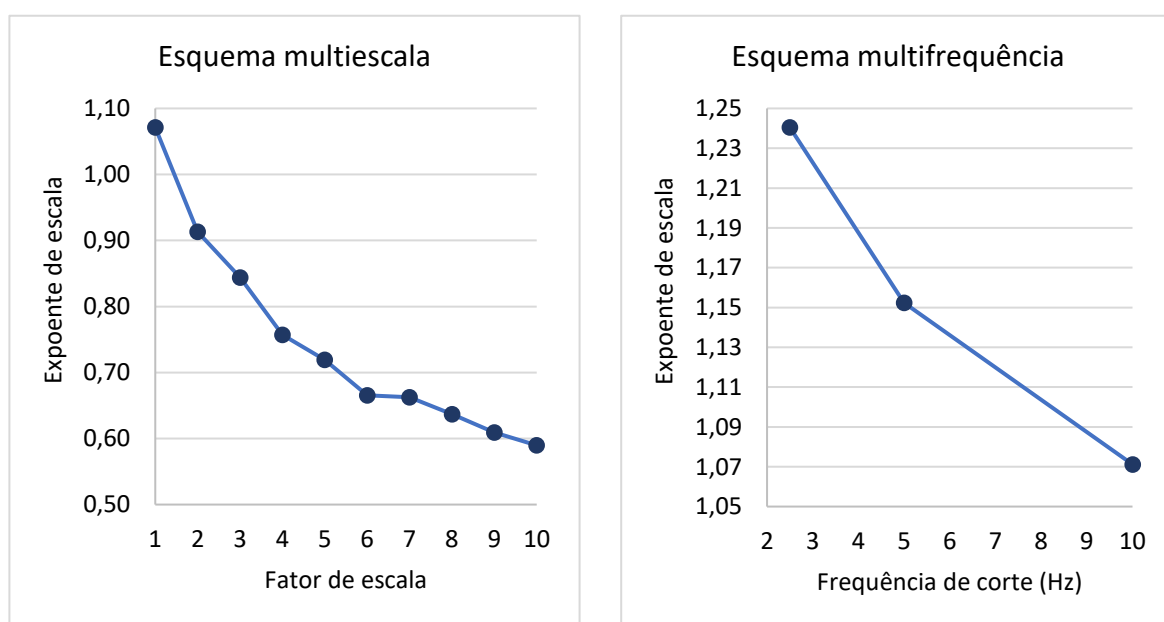


Figura 27. Curva de um atributo calculado nos esquemas multiescala (esquerda) e multifrequência (direita).  
Fonte: o autor.

Diante do exposto, como pode ser visto na Figura 24, são avaliados oito cenários de geração de atributos para a classificação, sendo que o primeiro deles é o cenário padrão da literatura, enquanto os demais, até onde se sabe, são inéditos da tese. São eles:

- 1º cenário: utilizando apenas os 42 atributos calculados no esquema convencional.
- 2º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica do somatório, totalizando assim 126 atributos.
- 3º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica da média, totalizando assim 126 atributos.
- 4º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica da variância, totalizando assim 126 atributos.
- 5º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica do coeficiente angular, totalizando assim 126 atributos.
- 6º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica do somatório sinalizado, totalizando assim 126 atributos.
- 7º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com a técnica da média sinalizada, totalizando assim 126 atributos.
- 8º cenário: combinando os atributos convencionais com os multiescala e multifrequência calculados com todas as seis técnicas propostas, totalizando assim 546 atributos.

As informações supracitadas podem ser melhor visualizadas na Tabela 5, que indica a quantidade total e os tipos de atributos incluídos em cada um dos oito cenários de classificação avaliados. Em todos os cenários, os atributos foram normalizados para uma faixa de valores entre zero e um, para que todos tivessem a mesma influência durante a classificação [38].

### **5.3.2. Etapa de Seleção de Atributos**

Como pode ser visto na Figura 24, antes da etapa de classificação com os modelos tradicionais de AM, os atributos passam por uma etapa de seleção, visando eliminar informações redundantes para aprimorar o desempenho dos modelos. Conforme discutido



Tabela 5. Atributos incluídos nos cenários de classificação.

	Atributos convencionais	Atributos multiescala e multifrequência						Número total de atributos
		Técnica do somatório	Técnica da média	Técnica da variância	Técnica do coeficiente angular	Técnica do somatório sinalizado	Técnica da média sinalizada	
1º cenário	X							42
2º cenário	X	X						126
3º cenário	X		X					126
4º cenário	X			X				126
5º cenário	X				X			126
6º cenário	X					X		126
7º cenário	X						X	126
8º cenário	X	X	X	X	X	X	X	546

anteriormente, estudos correlatos já mostraram a relevância deste procedimento para a classificação de séries posturográficas (vide seção 4.2).

Para isso, é utilizada a implementação disponível no software WEKA [195] do algoritmo *Correlation-based Feature Selection* em conjunto com o método de busca *best first*, ambos com parâmetros de configuração padrão do software. Decidiu-se utilizar um método de seleção da categoria filtro porque assim, em cada cenário de classificação avaliado na tese, obtém-se um subconjunto padronizado de atributos para os diferentes modelos de AM testados (vide subseção 2.2.2). É importante mencionar que a seleção foi realizada a partir das instâncias de treinamento, para não haver influência dos dados de teste no processo de escolha dos atributos mais discriminativos.

### 5.3.3. Etapa de Classificação

Nesta última etapa de classificação dos dados, são empregados seis modelos tradicionais de AM utilizados com sucesso na literatura para lidar com séries temporais posturográficas. Estes modelos são listados na Tabela 6, juntamente com os respectivos algoritmos do software WEKA utilizados e com os diferentes parâmetros de configuração testados, seguindo recomendações bem sucedidas de estudos correlatos (vide seção 4.2). Considerando todas estas variações, são empregados 20 modelos no total.

Tabela 6. Modelos tradicionais de AM avaliados na tese.

Modelo de AM	Algoritmo do WEKA	Parâmetros de configuração	Estudo(s) correlato(s)	Acrônimo
AD	J48 (C4.5)	-Poda desabilitada. -Demais parâmetros padrão.	Giovanini et al. [16].	AD <sub>1</sub>
		-Poda habilitada. -Demais parâmetros padrão.	Goh et al. [183].	AD <sub>2</sub>
FA	RandomForest	-Geração de 100 árvores. -06 atributos por árvore. -Demais parâmetros padrão.	Goh et al. [183].	FA
<i>k</i> -NN	IBk	-Variando $k = 1, 3, \dots, 19$ . -Distância Euclidiana. -Demais parâmetros padrão.	Saripalle et al. [42], Rasku [184], Goh et al. [183].	<i>k</i> -NN
MLP	Multilayer-Perceptron	-500 épocas de treinamento. -Tamanho do conjunto de validação: 0%. - <i>Learning rate</i> : 0,3. - <i>Momentum</i> : 0,2. - <i>Validation threshold</i> : 20. Demais parâmetros padrão.	Goh et al. [183], Giovanini e Nievola [184].	MLP <sub>1</sub>
		-10 mil épocas de treinamento. -Tamanho do conjunto de validação: 5%. - <i>Learning rate</i> : 0,3. - <i>Momentum</i> : 0,2. - <i>Validation threshold</i> : 20. Demais parâmetros padrão.	Giovanini [196].	MLP <sub>2</sub>
		-10 mil épocas de treinamento. -Tamanho do conjunto de validação: 10%. - <i>Learning rate</i> : 0,3. - <i>Momentum</i> : 0,2. - <i>Validation threshold</i> : 20. Demais parâmetros padrão.	Giovanini [196].	MLP <sub>3</sub>
NB	NaiveBayes	Todos os parâmetros padrão.	Goh et al. [183], Giovanini [196].	NB
SVM	LibSVM	-Kernel: RBF. -Grau do kernel: 3 -Custo: 1,0. -Demais parâmetros padrão.	Kim et al. [182], Giovanini [196].	SVM <sub>1</sub>
		-Kernel: RBF. -Grau do kernel: 3 -Custo: 10,0. -Demais parâmetros padrão.	Kim et al. [182], Saripalle et al. [42].	SVM <sub>2</sub>
		-Kernel: polinomial. -Grau do kernel: 4 -Custo: 0,09. -Demais parâmetros padrão.	Goh et al. [183], Saripalle et al. [42].	SVM <sub>3</sub>

### 5.3.4. Avaliação da Abordagem

Para a avaliação da abordagem, foram utilizadas as três bases de dados apresentadas na seção 5.2 em conjunto com os oito cenários de classificação elucidados na subseção 5.3.1, que objetivam a investigação da hipótese de pesquisa. Em todos os casos, o desempenho foi avaliado para os 20 modelos de AM considerados na abordagem. Este processo pode ser descrito por meio dos seguintes passos:

- 
- (i) *Para cada uma das três bases de dados:*
  - (ii) *Para cada um dos 20 modelos de AM incluídos na abordagem:*
  - (iii) *Para cada um dos oito cenários de classificação propostos:*
  - (iv) *Avalia o desempenho do modelo dentro de 15 repetições.*
- 

Com relação ao passo (iv), como método de avaliação de desempenho, foi utilizada a validação cruzada com 10 partições para os experimentos envolvendo as bases 1 e 2. Já para a base 3, que conta com um número mais baixo de instâncias (vide Tabela 4), foi utilizado um método mais apropriado para estes casos [38]: o *leave-one-out*, que consiste na validação cruzada com um número de partições igual ao número total de instâncias da base (114, a saber). Em todos os casos, a acurácia foi adotada como métrica de desempenho. Isso porque o número de instâncias entre classes é perfeitamente balanceado nas bases 2 e 3, e apenas sutilmente desbalanceado na base 1.

Como primeiro passo para a investigação da hipótese, avaliou-se a relevância dos atributos calculados nos esquemas convencional, multiescala e multifrequência por meio dos resultados da seleção de atributos. Mais especificamente, verificou-se o percentual de atributos destas três categorias que foram selecionados nos cenários de classificação propostos. O primeiro cenário foi desconsiderado desta análise por envolver somente atributos do esquema convencional. Nesta investigação, a observação de um maior percentual de atributos multiescala e multifrequência poderia sugerir superioridade destes em relação aos convencionais, confirmando a hipótese de pesquisa.

Na sequência, avaliou-se a relevância dos cenários de classificação propostos na tese em relação ao cenário convencional. Para isso, foi considerado o desempenho médio da abordagem em cada cenário, calculado como sendo a média entre as acurácias resultantes de todos os modelos naquele cenário. Neste contexto, o desempenho médio no primeiro cenário, que envolve apenas atributos do esquema convencional, foi comparado

com o desempenho nos demais cenários, que envolvem a inclusão de atributos multiescala e multifrequência. Essas comparações foram feitas com o teste U de Mann-Whitney no ambiente Matlab. Nesta investigação, a observação de melhores desempenhos para os cenários propostos em relação ao convencional poderia ajudar a confirmar a hipótese de pesquisa.

Por fim, foi realizada uma última investigação sobre os efeitos dos cenários propostos para cada um dos modelos de AM individualmente. Mais especificamente, para cada modelo, foram identificados os melhores cenários, ou seja, aqueles que proporcionaram o maior aumento de acurácia, tendo como base a acurácia no cenário convencional.

#### 5.4. Abordagem de Classificação Baseada em Redes Convolucionais

A Figura 28 mostra um fluxograma da abordagem de classificação de séries temporais posturográficas baseadas em redes convolucionais proposta na tese. Cada etapa da abordagem será discutida ao longo da presente seção.

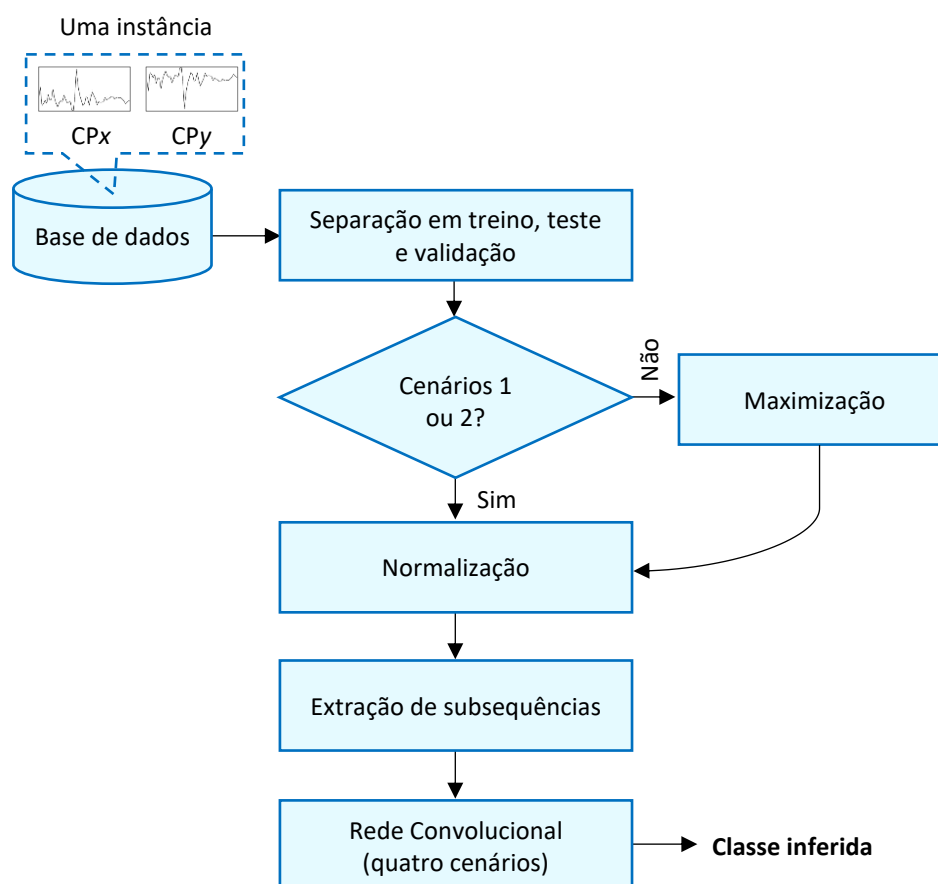


Figura 28. Fluxograma da abordagem de classificação baseada em redes convolucionais da tese.  
Fonte: o autor.

### 5.4.1. Etapa de Separação dos Dados

Nesta etapa da abordagem, para uma dada base de dados, as instâncias são separadas em três conjuntos fixos visando a avaliação de desempenho pelo método *holdout*, (vide subseção 2.2.1), sendo um deles de treino, o outro de validação, e o último de teste. Em outras palavras, isso implica em separar os sujeitos de pesquisa de cada base nestes três conjuntos. Ao invés de fazer essa separação de forma aleatória, buscou-se primeiro avaliar a similaridade entre os sujeitos de um mesmo grupo, e depois garantir que àqueles com maior similaridade fossem alocados em conjuntos distintos, proporcionando assim maior diversidade nestes conjuntos. Este processo pode ser descrito por meio dos seguintes passos:

- 
- (i) *Para cada uma das três bases de dados:*
  - (ii) *Para cada um dos dois grupos de sujeitos (i.e., classes):*
  - (iii) *Para cada sujeito:*
  - (iv) Calcula um vetor de 42 atributos.
  - (v) Emprega o algoritmo *k*-médias com  $k = 3$ , para formar 3 grupos.
  - (vi) *Para cada um dos três grupos formados:*
  - (vii) Sorteia 70% dos sujeitos para o conjunto de treino.
  - (viii) Sorteia 10% dos sujeitos para o conjunto de validação.
  - (ix) Sorteia 20% dos sujeitos para o conjunto de teste.
- 

Com relação ao passo (iv), cada sujeito é representado por um vetor de 42 atributos calculados no esquema convencional, os mesmos considerados na abordagem baseada em modelos tradicionais (vide subseção 5.3.1). Este vetor é calculado no Matlab fazendo a média entre os vetores de todas as instâncias provenientes de cada sujeito.

Sobre o passo (v), foi utilizada a implementação do algoritmo *k*-médias disponível no Matlab. O uso do parâmetro  $k = 3$  permite separar os sujeitos de cada classe em três grupos distintos em função da similaridade. Então, ao misturar de forma aleatória sujeitos destes três grupos para compor os conjuntos de treino, validação e teste, garante-se maior diversidade no treinamento e avaliação da abordagem.

### 5.4.2. Etapa de Maximização dos Dados

Como pode ser visto na Figura 28, dois dos quatro cenários de classificação testados, que serão explicados na sequência, envolvem uma etapa de maximização dos dados

(ou *data augmentation*). Essa etapa destina-se a proporcionar maior diversidade em termos de espectro de potências dos dados, visando assim a aprendizagem de padrões multifrequência para a investigação da hipótese de pesquisa. Para isso, cada instância dos conjuntos de treino, validação e teste é filtrada no Matlab a 2,5 Hz com um filtro Butterworth passa-baixa sem atraso de 4ª ordem, duplicando assim o tamanho destes conjuntos, visto que as instâncias originais (sem filtragem) são mantidas.

Neste contexto, testes preliminares mostraram que o uso de várias frequências de corte, tal como feito na abordagem anterior, apenas aumenta o tempo de treinamento (por maximizar ainda mais os dados) sem trazer melhorias de desempenho. Isso porque, como os principais componentes espectrais da série se concentram abaixo de 1 Hz, a filtragem acima deste limiar para diferentes frequências de corte produz séries altamente similares entre si, cujas diferenças parecem não ser percebidas pela abordagem. Por este motivo, optou-se somente pela menor frequência de corte praticada na literatura para séries posturográficas: 2,5 Hz.

#### 5.4.3. Etapa de Normalização dos Dados

Nesta etapa, cada instância dos conjuntos de treino, validação e teste é normalizada no Matlab para uma faixa de amplitude excursionando entre zero e um, tal como:

$$CPx_{norm}(n) = \frac{CPx(n) - CPx_{min}}{CPx_{max} - CPx_{min}}, \quad n = 1, \dots, m \quad (32)$$

$$CPy_{norm}(n) = \frac{CPy(n) - CPy_{min}}{CPy_{max} - CPy_{min}}, \quad n = 1, \dots, m \quad (33)$$

Sendo  $CPx_{min}$  e  $CPx_{max}$  o mínimo global e o máximo global, respectivamente, da série na direção  $x$  (o mesmo se aplica para a série na direção  $y$ ).

Conforme discutido na subseção 2.3.4, este procedimento é comum na literatura e visa normalizar a faixa de ativação dos neurônios da rede, permitindo agilizar o treinamento. Ademais, isso permite igualar a influência das séries em termos de amplitude no processo de classificação. Com isso, por um lado, perde-se informação em termos de excursão em amplitude das séries, que caracteriza a estabilidade postural do indivíduo (vide subseção 3.5.1). Por outro lado, pode-se focar em distinguir os sujeitos por meio das es-

truturas temporais das séries, que além de descreverem diversas outras propriedades importantes do controle postural (vide subseção 3.5.2), têm-se mostrado mais discriminantes do que a excursão em amplitude na literatura [20], [148]. A Figura 29 ilustra este processo para duas séries posturográficas de 60 s na direção  $x$ , uma de um adulto e outra de um idoso, antes e depois da normalização.

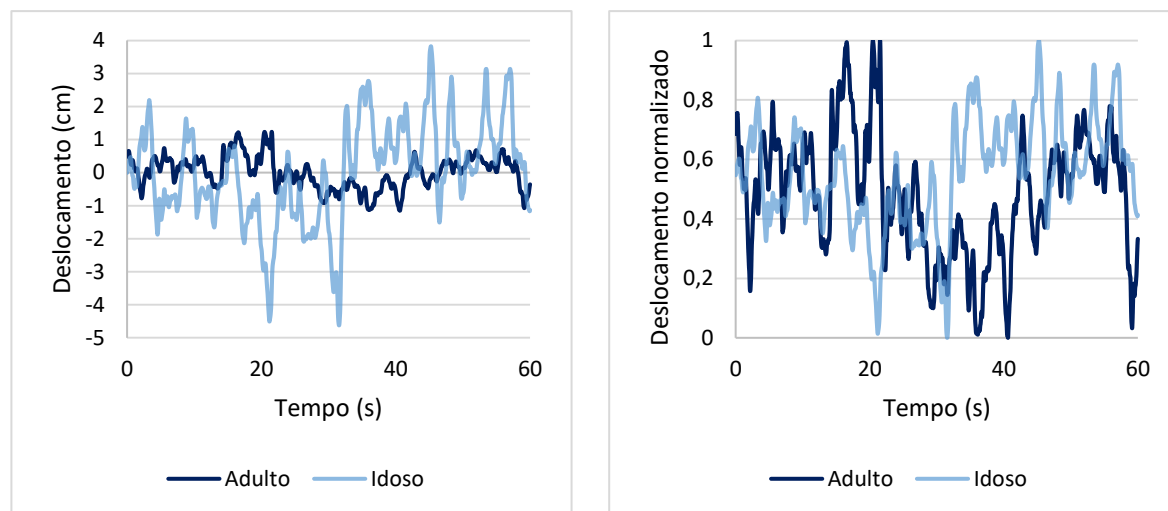


Figura 29. Séries posturográficas antes (esquerda) e depois (direita) da normalização.  
Fonte: o autor.

#### 5.4.4. Etapa de Extração de Subsequências

Nesta etapa, as séries são divididas em subsequências de menor comprimento para posterior inserção na rede convolucional (vide subseção 2.3.4). Para isso, no Matlab, emprega-se uma janela deslizante de 5000 pontos amostrais, que representa 83% do tamanho total das séries, com passo de deslizamento igual a 20 pontos. Esses ajustes foram feitos com base em estudos correlatos que obtiveram resultados promissores ao utilizar uma janela de tamanho igual a 90% do comprimento das séries em estudo [12], [14] e passo de deslizamento inferior a 30 pontos [7], [14]. Com isso, cada instância deu origem a 51 subsequências, que são inseridas separadamente na rede convolucional. Em outras palavras, os conjuntos de treino, validação e teste são maximizados 51 vezes.

#### 5.4.5. Etapa de Classificação

Nesta etapa, utiliza-se uma rede neural convolucional para a classificação dos dados por meio da aprendizagem automática de características. Para a investigação da hipótese de pesquisa, quatro cenários de classificação são avaliados no total (Figura 30):

- 1º cenário (padrão da literatura): desconsidera a etapa de maximização dos dados e emprega uma rede de apenas dois estágios encadeados.
- 2º cenário (foco na aprendizagem multiescala): desconsidera a etapa de maximização dos dados e emprega uma rede de três estágios encadeados.
- 3º cenário (foco na aprendizagem multifrequência): considera a etapa de maximização dos dados e emprega uma rede de apenas dois estágios encadeados.
- 4º cenário (combinação entre aprendizagens multiescala e multifrequência): considera a etapa de maximização dos dados e emprega uma rede de três estágios.

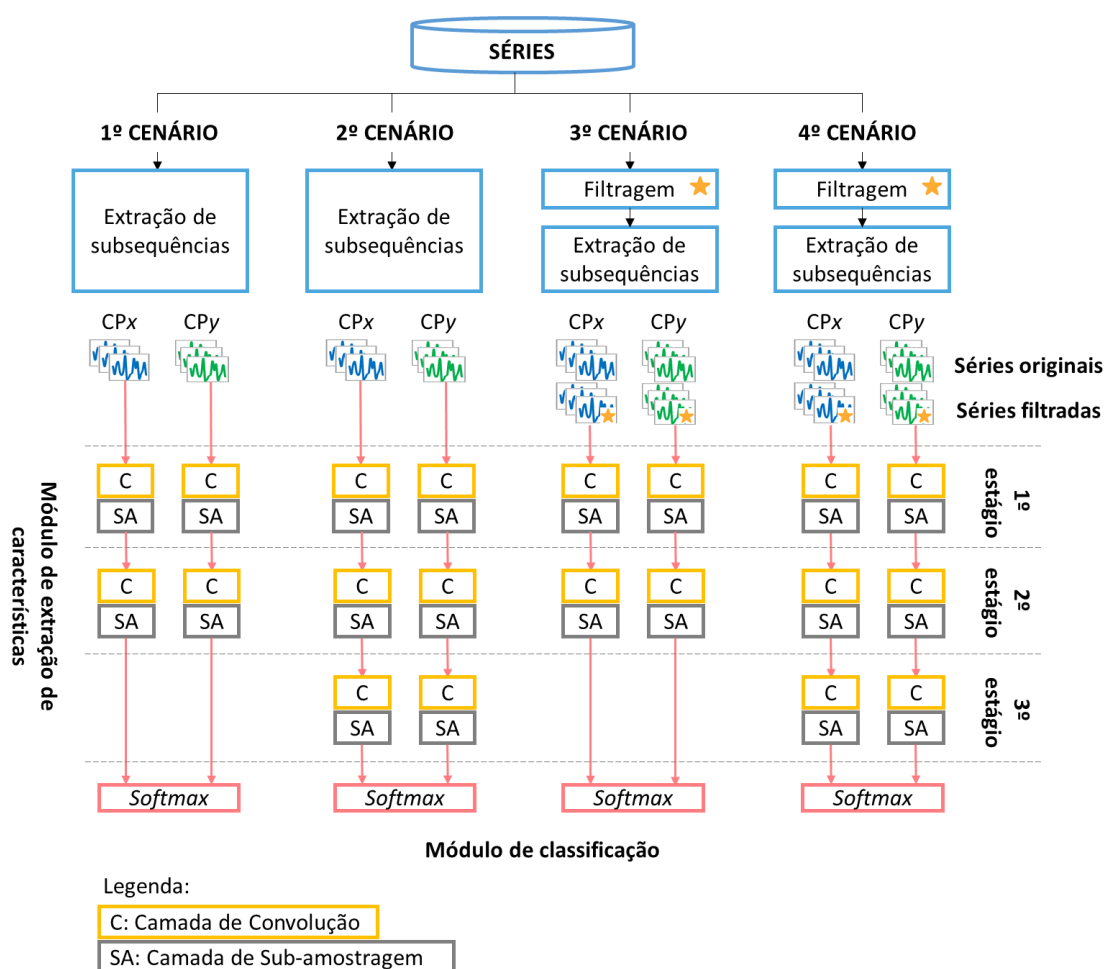


Figura 30. Ilustração dos quatro cenários experimentais de classificação da tese.

Fonte: o autor.

O primeiro cenário é o cenário mais praticado na literatura, onde a análise multifrequência dos dados é inexistente e a análise multiescala se limita a apenas dois estágios (vide seção 4.3). O segundo cenário apresenta a inclusão de um terceiro estágio na rede, no intuito de investigar o impacto no desempenho da abordagem ao analisar mais escalas



de tempo das séries, ou seja, mais padrões multiescala. O terceiro cenário retorna à rede de apenas dois estágios, mas inclui a maximização dos dados, visando investigar os efeitos da análise de padrões multifrequência. Por fim, o quarto cenário une as duas estratégias anteriores: inclusão de um terceiro estágio na rede e maximização dos dados, objetivando avaliar a combinação das aprendizagens multiescala e multifrequência.

Neste contexto, o tamanho dos conjuntos de treino, validação e teste varia entre os cenários de classificação devido à inclusão ou não da maximização dos dados, como mostra a Tabela 7 para as três bases em estudo. Tomando como exemplo a base 3, que possui originalmente 114 instâncias no total (vide Tabela 4), esta quantia sobe para 5.814 instâncias no primeiro e segundo cenários ( $114 \text{ instâncias} \times 51 \text{ subsequências}$ ), que não empregam maximização, e para 11.628 instâncias no terceiro e quarto cenários ( $114 \text{ instâncias} \times 2 \text{ tipos de filtragem} \times 51 \text{ subsequências}$ ), que empregam maximização. Estas instâncias são divididas sempre na proporção de 70%, 10% e 20% entre os conjuntos de treino, validação e teste, respectivamente, conforme elucidado na subseção 5.4.1.

Tabela 7. Tamanho dos conjuntos de treino, validação e teste nos cenários de classificação.

		1º e 2º cenários		3º e 4º cenários	
		Instâncias por conjunto	Total	Instâncias por conjunto	Total
Base 1	Treino	67.932	97.308	135.864	194.616
	Validação	9.792		19.584	
	Teste	18.972		37.944	
Base 2	Treino	30.600	44.064	61.200	88.128
	Validação	4.896		9.792	
	Teste	8.568		17.136	
Base 3	Treino	3.978	5.814	7.956	11.628
	Validação	612		1.224	
	Teste	1.224		2.448	

Em todos os cenários de classificação ilustrados na Figura 30, a rede convolucionais possui dois canais de entrada para a inserção simultânea de subsequências oriundas das séries nas direções  $x$  e  $y$ . Essa solução foi inspirada no estudo de Zheng et al. [7] sobre classificação de séries temporais multivariadas (vide seção 4.3). Ademais, a rede possui uma estrutura padrão, onde cada estágio envolve uma camada de convolução seguida por uma camada de sub-amostragem.

Cada camada de convolução emprega 8 filtros de comprimento igual a 5 pontos amostrais para a aprendizagem dos mapas de características a partir dos dados de entrada, juntamente com a função de ativação ReLU. As camadas de sub-amostragem empregam função de média aritmética dentro de janelas consecutivas e não sobrepostas com 10 pontos amostrais de comprimento. Com isso, são extraídas características das séries em diferentes escalas de tempo, como ilustra a Figura 31 para o terceiro e quarto cenários, que envolvem três estágios cada.

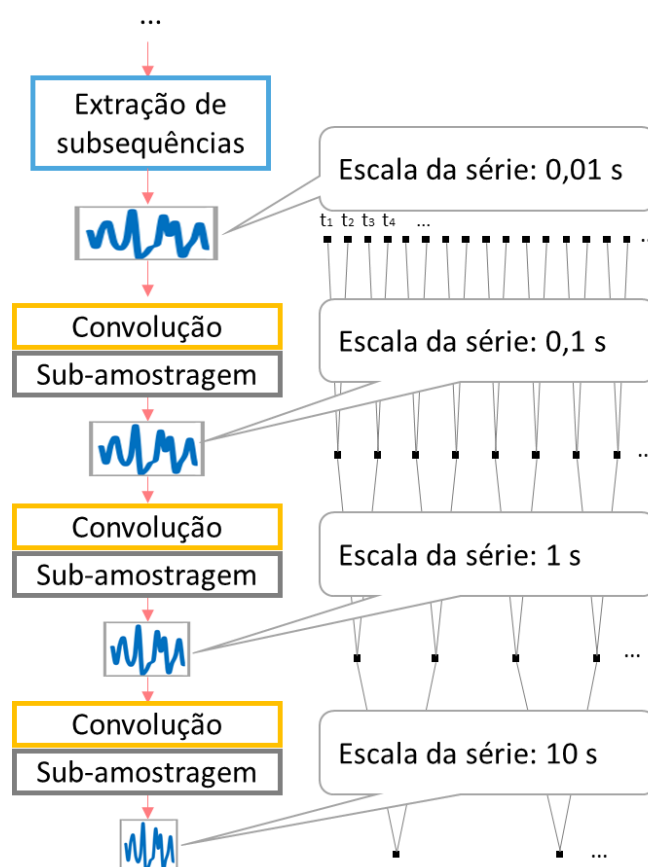


Figura 31. Ilustração da análise de diferentes escalas temporais das séries ao longo da rede.  
Fonte: o autor.

Após a aprendizagem de características, os mapas seguem para o módulo de classificação, composto por neurônios de entrada seguidos por uma função *softmax*, a qual permite minimizar significativamente o tempo de treinamento em comparação com o uso de uma MLP. Todas as implementações foram feitas no Matlab R2018 como auxílio da toolbox *Deep Learning*.

Redes convolucionais de configurações similares às supracitadas já foram utilizadas com sucesso na literatura para a classificação de séries temporais, inclusive séries

derivadas do movimento humano, conforme abordado na seção 4.3. No entanto, é importante destacar que o objetivo nesta tese não é encontrar valores ótimos para os parâmetros de configuração visando alcançar o melhor desempenho possível. O real propósito é adotar valores promissores com base em estudos correlatos bem sucedidos e mantê-los fixos para os diferentes cenários de classificação propostos, avaliando assim os efeitos dos cenários no desempenho da abordagem.

#### 5.4.6. Avaliação da Abordagem

Para a avaliação da abordagem em questão, foram utilizadas as três bases de dados apresentadas na seção 5.2 em conjunto com os quatro cenários de classificação discutidos na subseção 5.4.5, que visam a investigação da hipótese de pesquisa. Esse processo de avaliação pode ser descrito por meio dos seguintes passos:

- 
- (i) *Para cada uma das três bases de dados:*
  - (ii) *Para cada um dos quatro cenários de classificação propostos:*
  - (iii) *Enquanto o critério de parada não é satisfeito:*
  - (iv) Treina a rede utilizando o conjunto de treinamento.
  - (v) Avalia o desempenho da rede no conjunto de validação.
  - (vi) Avalia o desempenho da rede no conjunto de teste.
- 

Com relação ao passo (iv), o treinamento da rede para a otimização dos parâmetros foi realizado com o algoritmo de retropropagação combinado com o método estocástico de descida do gradiente, adotando a entropia cruzada como função de custo a ser minimizada [14]. Além disso, utilizou-se *momentum* de 0,9 [7], [13], [81] e divisão dos dados em mini-lotes normalizados de tamanho 128 [14], [81]. A taxa de aprendizagem foi ajustada para cada base em função do número de instâncias, sendo  $1 \times 10^{-3}$ ,  $1 \times 10^{-4}$  e  $1 \times 10^{-5}$  para as bases 1, 2 e 3, respectivamente, com decaimento linear [81] em todos os casos.

O treinamento da rede é feito de forma iterativa sobre o conjunto de treino, sendo que, a cada 50 iterações concluídas, realizou-se o passo (v) de avaliação de desempenho no conjunto de validação por meio da acurácia. Este processo se repetiu até que a acurácia de validação parasse de melhorar dentro de 15 verificações consecutivas, ou então até que o limite de 500 épocas de treinamento fosse atingido, que figuram como critério de parada do passo (iii). Após encerrado o treinamento, verificou-se a acurácia da rede no conjunto de teste, realizando para isso o esquema de voto (vide subseção 2.3.4), onde o rótulo de

classe inferido para uma dada instância é calculado como a moda (i.e., valor mais frequente) entre os rótulos inferidos para todas as suas subsequências. Este processo foi feito via *holdout*, ou seja, ocorre dentro de uma única repetição para conjuntos fixos de treino, validação e teste, cuja composição foi elucidada na subseção 5.4.1.

Todos os experimentos em questão foram realizados em uma máquina do PPGIa com processador i7-3770 de 3.40 GHz (64 bits) e 8 GB de memória RAM, equipada com uma placa gráfica NVIDIA Titan X com 3584 núcleos e 12 GB de memória, que foi doada pela empresa NVIDIA como forma de apoio a este projeto.

Após os experimentos, para a investigação da hipótese, comparou-se o desempenho da abordagem entre os quatro cenários de classificação para as três bases de dados. Neste contexto, melhores desempenhos para o segundo, terceiro e quarto cenários poderiam sugerir a superioridade das aprendizagens multiescala e multifrequência para a classificação de séries posturográficas em relação à aprendizagem convencional, sustentando a hipótese de pesquisa. Complementarmente, analisou-se quais bases renderam os melhores desempenhos, ou seja, quais fenômenos de controle postural puderam ser melhor identificados com a abordagem proposta.

## **5.5. Considerações Finais**

Este capítulo apresentou o método proposto na tese, que envolve essencialmente duas abordagens de classificação de séries temporais posturográficas, uma baseada em modelos tradicionais de AM e a outra em redes convolucionais. Ambas as abordagens são avaliadas em um cenário experimental convencional, que remete às práticas mais comuns da literatura, e depois em cenários mais sofisticados, envolvendo estratégias de aprendizagem de padrões multiescala e multifrequência dos dados. Isso com o intuito de comparar o desempenho das abordagens entre tais cenários, avaliando assim a validade da hipótese de pesquisa.

# Capítulo 6

## Resultados Experimentais

### 6.1. Considerações Iniciais

Neste capítulo, apresentam-se na seção 6.2 os resultados alcançados com o método proposto na tese, seguido então por uma discussão detalhada dos achados na seção 6.3, a partir da qual avalia-se a validade da hipótese de pesquisa

### 6.2. Resultados

#### 6.2.1. Abordagem de Classificação Baseada em Modelos Tradicionais

Primeiramente, para o cálculo da entropia amostral durante a etapa de extração de atributos, as séries foram submetidas ao detrending EMD para a remoção das quatro IMFs de menor frequência, com componentes principais até 1 Hz (vide subseção 5.3.1). Neste contexto, a Tabela 8 mostra os valores de frequência que concentram 99% da potência espectral das cinco últimas IMFs para as séries nas direções  $x$  e  $y$  das bases em estudo. São exibidos os valores médios e os respectivos desvios, considerando todas as instâncias de cada base, bem como o percentual de instâncias cuja concentração excedeu o limiar de 1 Hz. Como pode ser observado, um percentual significativo das quintas últimas IMFs tem concentração acima de 1 Hz. Assim, decidiu-se pela remoção das quatro últimas apenas.

Tabela 8. Levantamento da concentração espectral das cinco últimas IMFs dos dados.

		5ª última		4ª última		Antepenúltima		Penúltima		Última	
		CPx	CPy	CPx	CPy	CPx	CPy	CPx	CPy	CPx	CPy
Base 1	Média (Hz)	0,81	0,80	0,43	0,43	0,25	0,26	0,18	0,18	0,14	0,14
	Desvio (Hz)	0,32	0,32	0,15	0,14	0,07	0,07	0,03	0,03	0,01	0,01
	> 1 Hz (%)	20,6	19,8	0,5	0,2	0,0	0,0	0,0	0,0	0,0	0,0
Base 2	Média (Hz)	0,81	0,80	0,43	0,43	0,25	0,26	0,18	0,18	0,14	0,14
	Desvio (Hz)	0,32	0,32	0,15	0,14	0,07	0,07	0,03	0,03	0,01	0,01
	> 1 Hz (%)	20,6	19,8	0,5	0,2	0,0	0,0	0,0	0,0	0,0	0,0
Base 3	Média (Hz)	0,75	0,70	0,41	0,41	0,24	0,24	0,18	0,18	0,15	0,15
	Desvio (Hz)	0,26	0,26	0,13	0,13	0,06	0,06	0,03	0,03	0,00	0,00
	> 1 Hz (%)	18,1	19,3	0,3	0,5	0,0	0,0	0,0	0,0	0,0	0,0

Na sequência, a Figura 32 exibe a composição das três bases de dados em estudo após a seleção de atributos, tendo em vista os sete cenários de classificação propostos na tese, que incorporam atributos calculados nos esquemas convencional, multiescala e multifrequência. O primeiro cenário foi desconsiderado por incluir apenas atributos oriundos do esquema convencional (vide subseção 5.3.1).

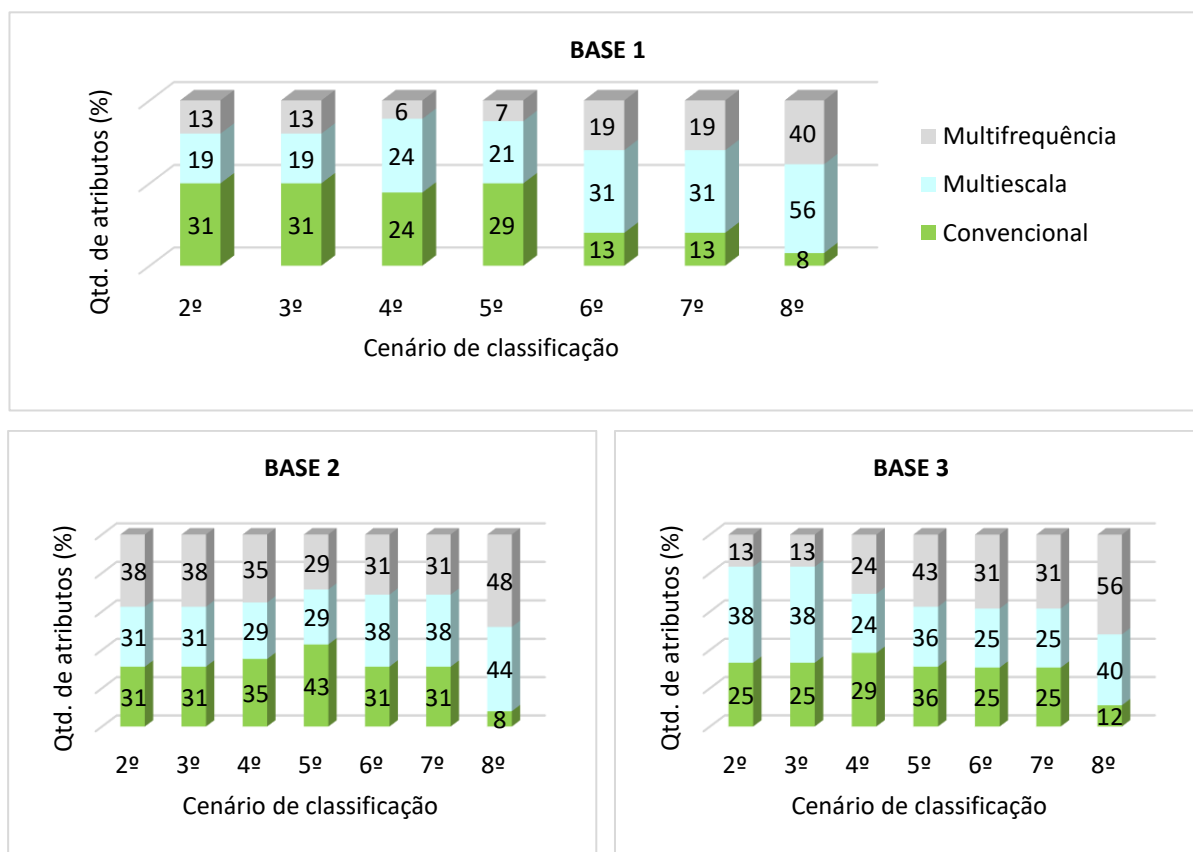


Figura 32. Composição das bases de dados em estudo após a seleção de atributos.

Com relação ao desempenho da abordagem, a Figura 33 mostra, para cada uma das bases em estudo, uma curva da acurácia geral para os oito cenários de classificação avaliados. Em cada cenário, essa acurácia geral foi calculada como sendo a média entre as acurácias resultantes de todos os 20 modelos de AM. Na figura, marcadores preenchidos representam diferença estatisticamente significativa ( $p < 0,05$ ) entre a acurácia geral do cenário observado e àquela do primeiro cenário.




Figura 33. Curvas da acurácia geral nos oito cenários avaliados para as três bases de dados.

Na Figura 33, tomando como referência o primeiro cenário, observa-se um aumento sutil e variável da acurácia geral ao longo das três curvas, que atinge um crescimento máximo de: 6,7 pontos percentuais (pp) para a Base 1 no oitavo cenário; 2,3 pp para a Base 2, também no oitavo cenário, e; 3,6 pp para a Base 3 no quinto cenário. Em média, comparado ao primeiro cenário, os cenários propostos na tese renderam um aumento na acurácia geral de:  $3,1 \pm 1,7$  pp para a Base 1;  $1,0 \pm 0,8$  pp para a Base 2, e;  $2,7 \pm 0,6$  pp para a Base 3.

Sobre o desempenho individual da abordagem para cada modelo de AM testado, primeiramente, a Figura 34 exibe um histograma da contagem de quantas vezes cada cenário avaliado rendeu melhor acurácia que os demais para as três bases em estudo. Por exemplo, para a Base 1, percebe-se que todos os 20 modelos atingiram sua maior acurácia no oitavo cenário em comparação com os demais.




Figura 34. Histograma de contagem dos melhores cenários de classificação para as três bases de dados.

Na sequência, para cada modelo de AM, a Figura 35 mostra uma comparação entre a acurácia obtida no primeiro cenário, a acurácia média calculada entre os cenários propostos (2º a 8º cenários), e a acurácia resultante no melhor cenário, i.e., a maior observada dentre os oito cenários experimentais. Tais resultados são exibidos para as três bases em estudo, sendo que, em cada caso, os modelos foram organizados da maior para a menor diferença de acurácia observada entre o primeiro cenário e o melhor cenário.

Complementarmente, para cada modelo de AM, a Tabela 9 exibe uma relação das acurácias obtidas tanto no primeiro cenário quanto no melhor cenário, juntamente com o aumento de acurácia observado de um para o outro (em pontos percentuais). Esses resultados são mostrados para as três bases de dados em estudo.



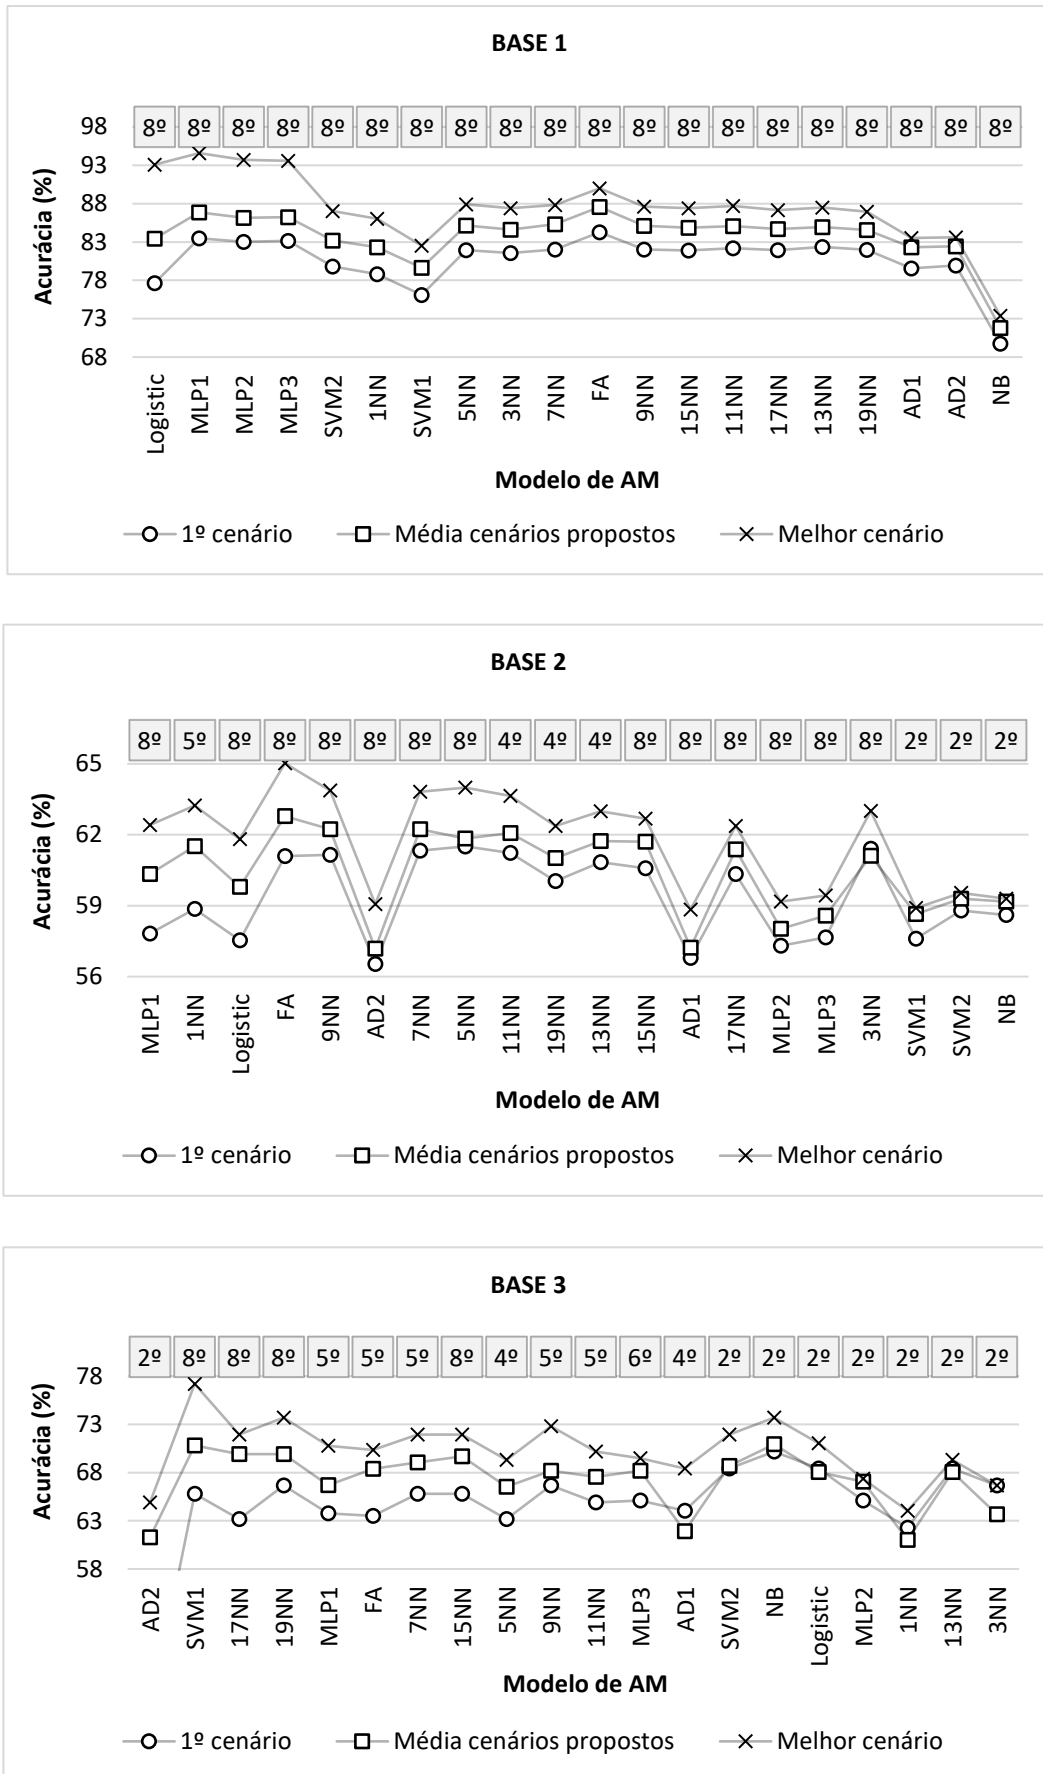


Figura 35. Curvas das acurácias individuais dos modelos de AM nas três bases de dados. Os retângulos em cinza indicam o cenário que rendeu a melhor acurácia para cada modelo.

Tabela 9. Relação das acurácias individuais dos modelos de AM para as três bases de dados.

	Base 1 – Acurácias (%)			Base 2 – Acurácias (%)			Base 3 – Acurácias (%)		
	1°	Melhor	Aumento	1°	Melhor	Aumento	1°	Melhor	Aumento
MLP1	83,5	94,6 <sup>(8)</sup>	11,1	57,8	62,4 <sup>(8)</sup>	4,6	63,8	70,8 <sup>(5)</sup>	7,0
MLP2	83,0	93,7 <sup>(8)</sup>	10,7	57,3	59,2 <sup>(8)</sup>	1,9	65,1	67,4 <sup>(2)</sup>	2,3
MLP3	83,1	93,6 <sup>(8)</sup>	10,4	57,7	59,4 <sup>(8)</sup>	1,8	65,1	69,5 <sup>(6)</sup>	4,4
SVM1	76,1	82,5 <sup>(8)</sup>	6,4	57,6	58,9 <sup>(2)</sup>	1,3	65,8	77,2 <sup>(8)</sup>	11,4
SVM2	79,8	87,0 <sup>(8)</sup>	7,2	58,8	59,5 <sup>(2)</sup>	0,7	68,4	71,9 <sup>(2)</sup>	3,5
1NN	78,8	86,0 <sup>(8)</sup>	7,2	58,9	63,2 <sup>(5)</sup>	4,4	62,3	64,0 <sup>(2)</sup>	1,8
3NN	81,6	87,4 <sup>(8)</sup>	5,8	61,4	63,0 <sup>(8)</sup>	1,6	64,9	66,7 <sup>(2)</sup>	1,8
5NN	82,0	87,9 <sup>(8)</sup>	6,0	61,5	64,0 <sup>(8)</sup>	2,5	63,2	69,3 <sup>(4)</sup>	6,1
7NN	82,0	87,8 <sup>(8)</sup>	5,8	61,3	63,8 <sup>(8)</sup>	2,5	65,8	71,9 <sup>(5)</sup>	6,1
9NN	82,0	87,6 <sup>(8)</sup>	5,6	61,1	63,9 <sup>(8)</sup>	2,7	66,7	72,8 <sup>(5)</sup>	6,1
11NN	82,2	87,7 <sup>(8)</sup>	5,5	61,2	63,6 <sup>(4)</sup>	2,4	64,9	70,2 <sup>(5)</sup>	5,3
13NN	82,4	87,5 <sup>(8)</sup>	5,1	60,8	63,0 <sup>(4)</sup>	2,2	68,4	69,3 <sup>(2)</sup>	0,9
15NN	81,9	87,4 <sup>(8)</sup>	5,5	60,6	62,7 <sup>(8)</sup>	2,1	65,8	71,9 <sup>(8)</sup>	6,1
17NN	81,9	87,2 <sup>(8)</sup>	5,2	60,3	62,4 <sup>(8)</sup>	2,0	63,2	71,9 <sup>(8)</sup>	8,8
19NN	82,0	87,0 <sup>(8)</sup>	5,0	60,0	62,4 <sup>(4)</sup>	2,3	66,7	73,7 <sup>(8)</sup>	7,0
AD1	79,5	83,5 <sup>(8)</sup>	4,0	56,8	58,8 <sup>(8)</sup>	2,0	64,0	68,4 <sup>(4)</sup>	4,4
AD2	79,9	83,6 <sup>(8)</sup>	3,7	56,5	59,1 <sup>(8)</sup>	2,5	53,0	64,9 <sup>(2)</sup>	11,9
FA	84,3	90,0 <sup>(8)</sup>	5,7	61,1	65,0 <sup>(8)</sup>	3,9	63,5	70,4 <sup>(5)</sup>	6,8
NB	69,7	73,4 <sup>(8)</sup>	3,7	58,6	59,3 <sup>(2)</sup>	0,7	70,2	73,7 <sup>(2)</sup>	3,5
Logistic	77,6	93,1 <sup>(8)</sup>	15,4	57,5	61,8 <sup>(8)</sup>	4,3	68,4	71,1 <sup>(2)</sup>	2,6

O número sobrescrito entre parênteses indica o cenário no qual a melhor acurácia foi obtida.

### 6.2.2. Abordagem de Classificação Baseada em Redes Convolucionais

Na Figura 36, para as três bases em estudo, são comparados os valores percentuais de acurácia obtidos com a abordagem baseada em redes convolucionais nos quatro cenários experimentais de classificação (vide subseção 5.4.5).

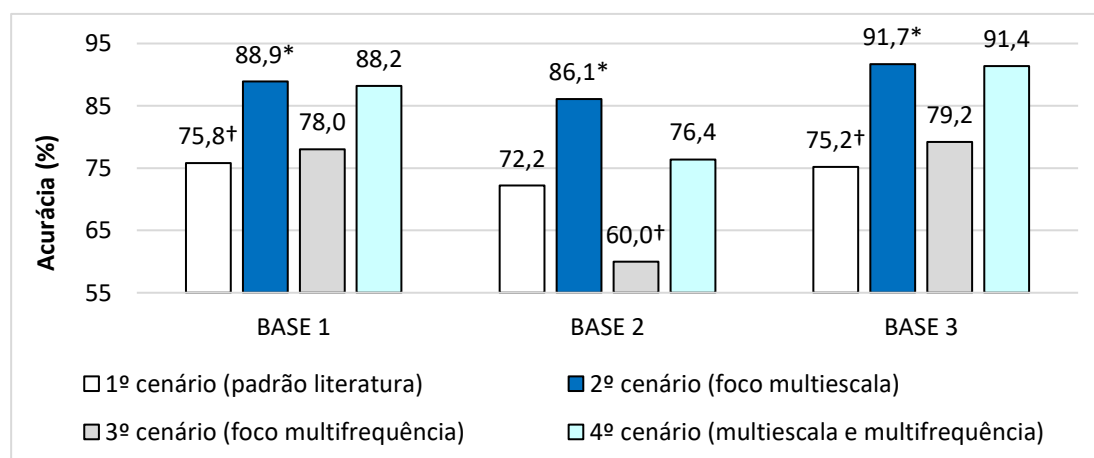


Figura 36. Acurácias da abordagem baseada em redes convolucionais. Os asteriscos (\*) e as cruzes (†) indicam, respectivamente, o melhor e o pior resultado em cada base de dados.

### **6.3. Discussão**

#### **6.3.1. Abordagem de Classificação Baseada em Modelos Tradicionais**

##### **Tipos mais discriminantes de atributos**

Por meio de uma inspeção geral da Figura 32, nota-se para as três bases que a seleção de atributos resultou uma mistura de atributos calculados nos esquemas convencional, multiescala e multifrequência, sendo que a concentração de cada um desses tipos variou de cenário para cenário. Em uma análise mais ampla, isso sugere que todos os três tipos de atributos são capazes de capturar padrões discriminantes do controle postural contidos nas séries em estudo.

Entretanto, deve-se salientar que o oitavo cenário figurou como um dos mais promissores durante os experimentos, como será detalhado na sequência. Nele, em comparação com os demais, observa-se maior prevalência de atributos multiescala e multifrequência (Figura 32). Estes achados demonstram a relevância e também uma possível superioridade de tais atributos frente aos atributos convencionais para a classificação de séries temporais posturográficas, sustentando assim a hipótese de pesquisa. Em partes, é possível que essa presença reduzida de atributos convencionais no oitavo cenário se deva ao fato de que, antes da seleção, havia originalmente 42 atributos deste tipo apenas, contra 504 atributos dos outros dois tipos no total (vide subseção 5.3.1).

##### **Relevância dos cenários de classificação propostos na tese**

Na Figura 33, nota-se para as três bases que os cenários de classificação propostos (do segundo ao oitavo) forneceram acurácias gerais sutilmente maiores do que o primeiro cenário, que é o padrão da literatura. Além disso, os histogramas da Figura 34, que refletem o desempenho individual dos modelos de AM, mostram que o primeiro cenário não rendeu a melhor acurácia em nenhum dos experimentos, sendo sempre vencido por algum dos cenários propostos, que combinam atributos calculados nos esquemas convencional, multiescala e multifrequência. Esses achados mostram que tal combinação permite aprimorar sutilmente o desempenho da classificação de séries temporais posturográficas em comparação com o uso de apenas atributos convencionais, em conformidade com a hipótese. No entanto, essa prática demanda maior esforço no processamento das séries para a extração dos atributos multiescala e multifrequência, como descrito na subseção 5.3.1.

Além disso, os resultados mostram também que a relevância dessa combinação de atributos varia conforme as populações que se deseja distinguir. Isso porque, como reportado na subseção 6.2.1, o aumento médio de acurácia geral observado do primeiro cenário para os cenários propostos foi ligeiramente maior para as Bases 1 e 3 do que para a Base 2. Ou seja, a inclusão de atributos multiescala e multifrequência contribuiu menos para distinguir o controle postural entre idosos com alto RQ e idosos com baixo RQ do que entre os outros grupos de sujeitos em estudo.

Nesse contexto, vale destacar que a acurácia no primeiro cenário, que só envolve atributos convencionais, também foi menor para a Base 2, que em comparação com as outras bases, possui os grupos supostamente mais similares em termos de controle postural, ou seja, os mais difíceis de se distinguir. Assim, pode-se especular que o uso de atributos multiescala e multifrequência contribuiu menos na classificação quando as diferenças posturais dos grupos em estudo são menos evidentes.

### **Melhores cenários de classificação**

Analisando as acurácias gerais da Figura 33, pode-se destacar como melhor cenário (i.e., que rendeu o melhor desempenho): o oitavo para as Bases 1 e 2, e o quinto para a Base 3. Isso indica, no primeiro caso, que todas as seis técnicas de cálculo de atributos multiescala e multifrequência propostas na tese (vide seção 5.3.1), que são combinadas no oitavo cenário, geram algum tipo de informação relevante para distinguir tanto adultos de idosos como idosos com alto RQ de idosos com baixo RQ. Já no segundo caso, esses achados sugerem que a técnica do coeficiente angular adotada no quinto cenário se destaca entre as demais para distinguir adultos saudáveis de adultos pós-AVE. Em outras palavras, as diferenças posturais daqueles sujeitos parecem se tornar mais evidentes quando considerada a taxa de variação das propriedades descritas pelos atributos sob diferentes escalas de tempo e distribuições espectrais de potência

Como esperado, conclusões similares são obtidas ao analisar os histogramas da Figura 34, que foram gerados a partir da acurácia individual dos modelos de AM. Para a Base 1, todos os modelos atingiram seu melhor desempenho no oitavo cenário. Algo similar foi observado para a Base 2, não para todos os modelos, mas para a maioria deles. Já para a Base 3, houve uma maior distribuição de melhores cenários. Embora o segundo cenário tenha vencido em quantidade, o quinto rendeu resultados relativamente melhores, vencendo em qualidade, motivo pelo qual produziu a maior acurácia geral na Figura 33.

Em síntese, tanto a análise mais geral dos resultados (Figura 33) como a análise mais específica (Figura 34) leva a três conclusões principais. Primeiro que, nas três bases, os melhores desempenhos foram alcançados sempre em algum cenário envolvendo o uso de atributos multiescala e multifrequência, o que sustenta a hipótese da pesquisa. Segundo que as técnicas mais adequadas de cálculo de tais atributos podem mudar conforme as populações em estudo, sendo recomendada uma avaliação caso a caso. E, por fim, que o oitavo cenário representa a melhor opção para uma recomendação geral sobre classificação de séries posturográficas com modelos tradicionais de AM.

### **Desempenho individual dos modelos de AM**

A Figura 35 permite avaliar a contribuição dos cenários propostos na tese para cada um dos modelos de AM considerados. Nela, pode-se notar que, de maneira geral, os modelos alcançaram melhor desempenho nos cenários propostos do que no primeiro cenário para as três bases de dados. Pode-se notar também que a melhor acurácia de todos os modelos foi obtida sempre em algum dos cenários propostos, nunca no primeiro. Todos esses achados reforçam as conclusões apresentadas previamente de que o uso de atributos multiescala e multifrequência contribui para a classificação de séries posturográficas, sustentando a hipótese de pesquisa.

Entretanto, a relevância dos cenários AM propostos variou consideravelmente de modelo para modelo, e de forma diferente para cada base. Isso pode ser visto na Tabela 9 ao analisar os aumentos de acurácia de cada modelo observados do primeiro para o melhor cenário. Por exemplo, para a Base 1, destacaram-se os modelos Logistic, MLP1, MLP2 e MLP3, cujos aumentos foram de mais de 10,0 pp cada. Já para a Base 2, destacaram-se os modelos MLP1, 1NN e Logistic, com aumentos na faixa dos 4,0 pp cada. Por fim, para a Base 3, destacaram-se os modelos AD2 e SVM1, com aumentos de mais de 11,0 pp cada. De maneira geral, o modelo com aumento de acurácia mais promissor para as três bases foi o MLP1, e o menos promissor, o NB.

Ainda em termos de aumento de acurácia do primeiro para o melhor cenário, curiosamente, alguns modelos alcançaram resultados promissores para uma certa base e resultados pouco satisfatórios para outras. Foi o caso dos modelos AD2 e SVM1, que figuraram como os melhores para a Base 3, mas não se destacaram para as Bases 1 e 2. Outro exemplo é o Logistic, que se destacou para as Bases 1 e 2, mas foi pouco influenciado na Base 3. No caso do *k*-NN, os resultados mais promissores nas Bases 1 e 2 foram obtidos

para menores valores de  $k$ , ao passo que os melhores resultados na Base 3 foram alcançados para maiores valores de  $k$ . Todos esses achados mostram a importância de, ao considerar cenários de classificação envolvendo atributos multiescala e multifrequência, avaliar diferentes modelos para cada base, identificando os mais promissores caso a caso.

### **6.3.2. Abordagem de Classificação Baseada em Redes Convolucionais**

#### **Aprendizagem convencional vs. aprendizagens multiescala e multifrequência**

Na Figura 36, nota-se para as Bases 1 e 3 que as acurácias no segundo, terceiro e quarto cenários superaram a acurácia do primeiro, que é o padrão da literatura. Isso mostra que, para tais bases, as aprendizagens de padrões multiescala e multifrequência, realizadas tanto de maneira individual como combinada, permitem aprimorar o desempenho de redes convolucionais na classificação de séries posturográficas, sustentando assim a hipótese de pesquisa. Já para a Base 2, a hipótese pode ser apenas parcialmente aceita pois, surpreendentemente, o enfoque na aprendizagem multifrequência do terceiro cenário piorou o desempenho em relação ao cenário padrão.

Nesse contexto, deve-se lembrar que o terceiro cenário empregou uma rede de mesma profundidade que o primeiro, dois estágios, dispondo, porém, do dobro de instâncias devido à etapa de maximização dos dados por meio da filtragem das séries. Diante desses achados, é razoável supor que somente dois estágios foram insuficientes para lidar de maneira adequada com o maior volume de instâncias do terceiro cenário, acarretando uma melhora pouco expressiva das acurácias para as Bases 1 e 3, bem como uma surpreendente piora para a Base 1 em relação ao primeiro cenário.

A conclusão acima pode ser sustentada analisando os resultados do quarto cenário, onde, ao acrescentar um terceiro estágio na rede e, por conseguinte, aumentar o número de parâmetros treináveis e de características aprendidas, alcançou-se aumentos mais expressivos de acurácia do que no terceiro cenário para as três bases de dados (Figura 36). Todos esses achados mostram a importância de se encontrar um equilíbrio entre a quantidade de instâncias e a profundidade da rede convolucional.

#### **Melhor cenário de classificação**

Dentre os cenários de classificação avaliados, deve-se destacar a superioridade do segundo, inclusive em comparação com o quarto cenário (Figura 36). Em primeiro lugar,

estes achados apontam a superioridade da aprendizagem multiescala frente às aprendizagens convencional e multifrequência para a classificação de séries posturográficas com redes convolucionais. Além disso, os resultados sugerem também que, quando há uma aprendizagem multiescala adequada, por meio do correto ajuste da profundidade da rede, a inclusão de instâncias com maior diversidade em termos de distribuição espectral não contribui para a classificação; pelo contrário, apenas aumenta o custo do processo, demandando mais tempo para treinar a rede sem trazer benefícios aos resultados. Isso diferiu do esperado, pois argumenta-se que redes convolucionais conseguem obter melhores resultados ao dispor de mais instâncias de treinamento [12], [13], o que já foi demonstrado para a classificação de séries temporais por alguns estudos [7], [14].

Uma possível justificativa para este achado está justamente na técnica de maximização dos dados considerada: a filtragem passa-baixa das séries a 2,5 Hz. Isso porque, em geral, 99% da potência espectral de uma série posturográfica se concentra nas frequências abaixo de 1 Hz [148]. Em outras palavras, as séries filtradas e não filtradas podem apresentar alto grau de similaridade, principalmente se há pouca contaminação por ruído, oferecendo assim um tipo de diversidade nos dados difícil de ser detectado pela rede, mesmo com os filtros convolucionais de pequeno comprimento adotados. Para oferecer algum tipo de diversidade de mais fácil detecção pela rede, talvez fosse necessário utilizar uma frequência de corte ainda mais baixa na filtragem, o que não é praticado na literatura, pois poderia atenuar frequências importantes da série.

Diante do exposto, pode-se concluir que a criação de diversidade espectral por meio da filtragem passa-baixa não oferece grandes vantagens para a classificação de séries posturográficas. Uma possibilidade de estudo futuro nesta direção seria avaliar outras técnicas de maximização dos dados, tais como diferentes tipos de detrending e transformação para outras séries relevantes sobre o controle postural, como por exemplo: velocidade do CP, forças e momentos angulares, entre outras.

### **Estratégia de aprendizagem multiescala proposta: vantagens e desvantagens**

Conforme discutido anteriormente, os melhores resultados com a abordagem baseada em redes convolucionais foram obtidos no segundo cenário experimental, com foco na aprendizagem de padrões multiescala dos dados. A principal diferença da rede utilizada naquele cenário em relação a outras redes do estado da arte para a classificação de séries temporais reside na profundidade: três estágios nesta tese, contra dois estágios nos

cenários propostos por Zheng et al. [7] e por Cui et al. [14] (vide seção 4.3), sendo que este último estudo também objetivou a aprendizagem multiescala.

Neste contexto, é importante lembrar que, embora redes mais profundas permitam analisar mais escalas de tempo de uma série temporal por empregarem mais camadas de sub-amostragem, seu uso pode ser inviável diante de uma baixa quantidade de instâncias, ou então na falta de *hardware* com poder de processamento adequado. Tais restrições têm levado alguns estudos a limitarem-se ao uso de redes de até dois estágios, como é o caso do trabalho de Zheng et al. [7].

Já no trabalho de Cui et al. [14], os autores optaram por manter a rede com apenas dois estágios e utilizar estratégias de captura de padrões multiescala focadas no pré-processamento dos dados, o que possui vantagens e desvantagens. Por um lado, redes menos profundas podem ser treinadas mais rapidamente e com uma quantidade menor de instâncias. Por outro, ao focar no pré-processamento, perde-se em termos de praticidade de uso, pois há um maior esforço manual com etapas como criação, armazenamento e gerenciamento de variantes dos dados originais, entre outras.

Fazendo uma comparação, a rede de três estágios proposta na tese pode demandar mais dados para atingir bons resultados, o que implica também em mais tempo de treinamento. Porém, tem-se mais praticidade de uso, pois a própria rede realiza todo o trabalho relacionado à aprendizagem multiescala por meio das camadas de sub-amostragem, sem demandar esforços do usuário para isso. Como as duas redes em questão foram utilizadas em bases de dados e contextos distintos, uma comparação direta de desempenho não seria adequada. O que se pode concluir da presente análise é que a escolha por uma rede mais profunda e automática, ou então por uma menos profunda e com algumas etapas manuais, é algo que vai depender das características do problema, dos dados em estudo e dos recursos que o pesquisador dispõe.

### **6.3.3. Análises Complementares**

#### **Redes convolucionais vs. modelos tradicionais de AM**

Embora não seja o objetivo deste trabalho comparar as duas abordagens propostas, uma análise inicial nesta direção pode ajudar a compreender o custo-benefício de cada uma delas para a classificação de séries temporais posturográficas, algo que, até onde se



sabe, ainda é desconhecido na literatura. Antes disso, porém, deve-se fazer algumas ressalvas que, em alguma medida, podem afetar a credibilidade das comparações feitas e das conclusões decorrentes.

Primeiramente, o desempenho das duas abordagens foi obtido utilizando métodos distintos de avaliação: validação cruzada para os modelos tradicionais de AM, e *holdout* para as redes convolucionais. Além disso, os ajustes nas abordagens foram feitos não no intuito de obter o máximo desempenho possível, mas sim visando observar os efeitos da aprendizagem de padrões multiescala e multifrequência das séries nos resultados da classificação, em conformidade com a hipótese de pesquisa. Assim, as conclusões descritas na sequência valem apenas para os modelos da tese sob os ajustes experimentais adotados, e podem mudar para outras configurações de ajuste.

Fazendo uma comparação entre os resultados gerais das duas abordagens, é notável a superioridade das redes convolucionais (Figura 36) frente aos modelos tradicionais (Figura 33) para as Bases 2 e 3 na maior parte dos cenários experimentais. Fazendo uma média entre todos os modelos e cenários, a acurácia na Base 2 com os modelos tradicionais foi de  $60,3 \pm 0,8\%$  contra  $73,7 \pm 10,8\%$  das redes. Para a Base 3, os valores foram de  $66,9 \pm 1,1\%$  com os modelos tradicionais contra  $84,4 \pm 8,4\%$  com as redes.

Intuitivamente, conclusões análogas são obtidas ao observar o desempenho das duas abordagens nos melhores cenários de classificação. Para a Base 2, a maior acurácia dos modelos tradicionais foi de 65,0%, alcançada com a FA (vide Tabela 9) contra 86,1% das redes (vide Figura 36), uma diferença de 21,1%. Para a Base 3, o SVM1 registrou a maior acurácia de 77,2% contra 91,7% das redes, uma diferença de 14,5%. Todos estes achados sugerem que, das duas abordagens propostas, àquela baseada em redes convolucionais permite identificar com maior precisão os déficits posturais decorrentes do RQ em idosos, assim como os déficits oriundos do AVE. No entanto, deve-se ter em mente a maior complexidade e custo computacional envolvidos no uso dessas redes.

Já para a Base 1, os resultados das duas abordagens foram bastante similares. Analisando novamente a média entre todos os modelos e cenários experimentais, tem-se uma acurácia de  $83,4 \pm 1,9\%$  com os modelos tradicionais contra  $82,7 \pm 6,8\%$  com as redes convolucionais. Nos melhores cenários, registrou-se para as redes acurácia de 88,9%, que foi superada pelos seguintes modelos: MLP1 (94,6%), MLP2 (93,7%), MLP3 (93,6%), Logistic (93,1%) e FA (90,0%). Em outras palavras, diferentemente do RQ em idosos e do

AVE, os déficits posturais decorrentes do envelhecimento podem ser melhor identificados utilizando modelos tradicionais de AM, algo desejável diante da maior facilidade de uso e menor custo computacional em relação às redes convolucionais, de maneira geral.

### **Desempenho das abordagens propostas nas três bases de dados**

A comparação do desempenho das abordagens entre as três bases de dados pode trazer informações relevantes, tais como revelar quais tipos de déficits posturais são mais fáceis e quais são mais difíceis de se detectar, bem como qual tipo de modelo de AM é mais promissor para distinguir o controle postural em certas populações. Essas informações podem ser úteis para pesquisadores da área da saúde e também da informática.

Começando pela abordagem baseada em modelos tradicionais, observaram-se resultados mais promissores para a Base 1, seguido pelas Bases 3 e 2, respectivamente, em termos tanto de acurácia geral (Figura 33) como também de acurácia individual (Tabela 9). De maneira similar, para a abordagem baseada em redes convolucionais, destacaram-se as acurácias alcançadas nas Bases 1 e 3 em relação à Base 2 nos quatro cenários experimentais, principalmente no terceiro e no quarto (Figura 36).

Em outras palavras, tanto para os modelos tradicionais como para as redes convolucionais, foi mais difícil distinguir os déficits posturais relacionados ao RQ em idosos do que os déficits decorrentes do envelhecimento e do AVE, o que já era esperado. Vale apenas ressaltar que esse achado pode ter sido influenciado pela considerável diferença de instâncias entre as Bases 1 e 3 (1908 contra 114, uma diferença de aprox. 17 vezes), oferecendo vantagem para a Base 1 por proporcionar maior diversidade amostral.

Por fim, diferentemente do observado para os modelos tradicionais, onde a curva de acurácia geral foi consideravelmente maior para a Base 1 do que para a Base 3 (Figura 33), os cenários envolvendo redes convolucionais exibiram acurácias bastante similares para essas duas bases. Inclusive, tais acurácias foram ligeiramente maiores para a Base 3 nos três cenários propostos na tese. Estes achados sugerem maior versatilidade das redes convolucionais em relação aos modelos tradicionais para a classificação de séries posturográficas considerando diferentes grupos de sujeitos.

# Capítulo 7

## Conclusão

Nesta tese, investigou-se a hipótese de que, em comparação com estratégias convencionais de aprendizagem, o uso de estratégias de aprendizagem de padrões multiescala e multifrequência poderia melhorar o desempenho da classificação de séries temporais posturográficas, seja utilizando abordagens baseadas em modelos tradicionais de AM ou em redes neurais convolucionais. A principal motivação para isso reside na incapacidade das abordagens existentes na literatura de lidar com tais aspectos, mesmo sabendo-se que os padrões multiescala e multifrequência de uma série temporal, inclusive posturográfica, são importantes para a sua caracterização.

Para essa investigação, foram propostas duas abordagens de classificação: a primeira delas baseada em seis modelos tradicionais populares, utilizados com sucesso por estudos correlatos anteriores, e a outra baseada em redes neurais convolucionais, que representam o estado da arte na classificação de séries temporais em geral. Então, as duas abordagens foram avaliadas em um cenário experimental envolvendo estratégias convencionais de aprendizagem, e depois em outros cenários empregando estratégias de aprendizagem multiescala e multifrequência. Por fim, comparou-se o desempenho de cada abordagem entre os diferentes cenários. Esses testes foram realizados para três bases de séries posturográficas oriundas de dois grupos de sujeitos cada: pessoas adultas e pessoas idosas na primeira base, idosos com alto RQ e idosos com baixo RQ na segunda base, e adultos saudáveis e adultos pós-AVE na terceira base.

Nesse contexto, os achados experimentais da tese vão de encontro com a hipótese, confirmando a relevância das estratégias de aprendizagem multiescala e multifrequência propostas para as duas abordagens. O impacto disso em termos de desempenho varia de acordo com os grupos de sujeitos que se deseja distinguir, e também conforme o modelo em uso, no caso da abordagem baseada em modelos tradicionais. Vale ressaltar que, embora contribua no desempenho, o uso de tais estratégias de aprendizagem implica em maior esforço, tanto manual como computacional, com a extração de mais atributos, treinamento dos modelos mediante maior volume de dados, etc. Portanto, antes de se optar por uma ou outra estratégia, recomenda-se uma análise cautelosa dos custos e dos possíveis benefícios de cada uma delas.

Com respaldo nos achados experimentais, pode-se estabelecer algumas outras recomendações. Começando pela abordagem baseada em modelos tradicionais, sugere-se que, dentre as seis técnicas de cálculo de atributos multiescala e multifrequência introduzidas na tese, dê-se preferência àquela do coeficiente angular ao distinguir pessoas saudáveis de pessoas pós-AVE, priorizando a AD e o SVM na etapa de classificação. Já para distinguir idosos com alto RQ de idosos com baixo RQ, bem como adultos de idosos, recomenda-se combinar todas as seis técnicas, priorizando os modelos Logistic e MLP. De maneira geral, desaconselha-se o uso do NB, que rendeu desempenhos aquém dos demais modelos na maior parte dos experimentos. Por fim, independentemente do modelo em uso, recomenda-se considerar algum método de seleção de atributos, visando reduzir eventuais redundâncias no conjunto de atributos.

Com relação à abordagem baseada em redes convolucionais, recomenda-se utilizar a estratégia de aprendizagem multiescala proposta para distinguir todas as populações consideradas neste trabalho. Embora tal estratégia envolva somente mais um estágio encadeado na rede em relação ao cenário padrão da literatura, isso implica em mais parâmetros a serem ajustados, podendo assim aumentar o tempo de treinamento, a depender do número de filtros convolucionais utilizados. Finalmente, os resultados desencorajam o uso da estratégia de aprendizagem multifrequência proposta, seja isolada ou combinada com a estratégia multiescala.

## 7.1. Limitações e Trabalhos Futuros

Para as duas abordagens avaliadas na tese, pode-se elencar algumas situações que, hipoteticamente, poderiam melhorar a relevância das estratégias de aprendizagem multiescala e multifrequência propostas, figurando assim como lacunas pertinentes para investigações em trabalhos futuros. Começando pela abordagem baseada em modelos tradicionais de AM, tais situações são:

- Avaliação de novas técnicas de cálculo de atributos multiescala e multifrequência, capazes de mapear outras propriedades relevantes das curvas geradas nesses esquemas (vide Figura 27).
- Avaliação de outros métodos de seleção de atributos além do *BestFirst*, pois isso determina o subconjunto de atributos que será utilizado na classificação.
- Avaliação do uso de mais atributos por meio da inclusão de mais métricas de parametrização das séries, visando maior diversidade de propriedades posturográficas. Entretanto, isso representa um dos maiores desafios no uso de modelos de AM baseados em extração de atributos [87], diante da ampla e crescente quantidade de métricas propostas na literatura. Nesse contexto, acredita-se que os 42 atributos considerados na tese após ampla revisão científica propiciaram diversidade suficiente de propriedades sobre o controle postural, permitindo avaliar a hipótese de pesquisa com grau adequado de confiança.

Outro aspecto a ser discutido é o limite de escalamento das séries posturográficas durante a extração de atributos multiescala, o que pode variar dependendo do comprimento da série e também dos atributos escolhidos. Na tese, em virtude do comprimento das séries em estudo, foi adotado um fator máximo de escala igual a 10 para não prejudicar a estimativa da entropia amostral (vide subseção 5.3.1). Mas para conjunto de séries de maior comprimento, seria possível e aconselhável explorar escalas maiores, o que poderia aumentar o poder de discriminação dos atributos multiescala.

No caso dos atributos multifrequência, um possível questionamento sobre o procedimento de cálculo usado na tese é o uso de apenas três frequências de corte (10 Hz, 5 Hz e 2,5 Hz), ao invés de aumentar a resolução considerando mais valores. No entanto, como predominam as frequências abaixo de 1 Hz no espectro de potências de séries posturográficas na postura ereta quieta [148], [197], [198], é razoável supor que a filtragem das séries com outras frequências de corte além das já utilizadas não produziria diferenças

significativas nos espectros. Ou seja, pressupõe-se que a inclusão de outras frequências de corte acarretaria apenas maior esforço com os cálculos, sem trazer benefícios aos resultados.

Com relação à abordagem baseada em redes convolucionais, algumas possibilidades de estudos futuros são:

- Avaliar o uso de redes com mais de três estágios encadeados (máximo adotado na tese), visando maximizar a aprendizagem multiescala por meio de mais camadas de sub-amostragem. Porém, quanto mais profunda a rede, mais desafiadora é a tarefa de encontrar bases com instâncias suficientes para um treinamento adequado. Essa questão pode ser contornada com o auxílio de técnicas de maximização de dados, conforme feito na tese por meio da estratégia multifrequência.
- Avaliar outras técnicas de maximização de dados além da filtragem digital passa-baixa das séries, adotada na estratégia de aprendizagem multifrequência da tese, cujo uso é desencorajado pelos resultados experimentais. Algumas possibilidades seriam: uso de detrending EMD, transformação para outras séries relevantes como o espectro de potências e a velocidade do CP, desmembramento da série em componentes de *rambling* e *trembling* [199], uso das séries originais de forças e momentos angulares.
- Avaliar a influência de diferentes hiperparâmetros na rede convolucional. Para isso, poderiam ser utilizados métodos automáticos de ajuste.
- Utilizar a validação cruzada ao invés do *holdout* para a avaliação da rede, o que permite obter resultados mais precisos mediante um custo computacional mais elevado, uma vez que o modelo precisa ser treinado e testado várias vezes.
- Investigar a relevância das estratégias propostas para outros modelos de AM, tais como as redes recorrentes, as redes de crenças profundas e os *auto-encoders*, que também vêm sendo utilizados para a classificação de séries temporais. Só que, como não há camada de sub-amostragem prevista originalmente na arquitetura de tais modelos, seria necessário repensar a estratégia de aprendizagem multiescala, focando talvez no pré-processamento dos dados. Ou então, visando maior automatização, seria possível avaliar uma arquitetura híbrida que incorporasse a camada de sub-amostragem.

Finalmente, para as duas abordagens avaliadas, os piores desempenhos gerais foram registrados ao distinguir idosos com alto RQ de idosos com baixo RQ. É importante lembrar que a separação desses grupos foi feita a partir de um critério de categorização proposto na tese, que envolveu a análise de três importantes fatores de risco para quedas. Nesse contexto, pode-se especular que a inclusão de mais fatores de risco no critério poderia melhorar a separação dos sujeitos, reduzindo eventuais *outliers* e permitindo talvez melhorar o desempenho de classificação. No entanto, isso demandaria a análise de informações complementares dos sujeitos que não foram disponibilizadas pelo estudo original [188] e que são de difícil controle do pesquisador, tais como condições do ambiente residencial e do bairro (e.g., iluminação, tipo do piso ou da pavimentação, obstáculos, etc.).

# Referências

- [1] U. Fayyad, G. Piatetsky-Shapiro, e P. Smyth, “From data mining to knowledge discovery in databases”, *AI Mag.*, vol. 17, nº 3, p. 37, 1996.
- [2] Z. Xing, J. Pei, e E. Keogh, “A brief survey on sequence classification”, *ACM SIGKDD Explor. Newsl.*, vol. 12, nº 1, p. 40–48, 2010.
- [3] M. Långkvist, L. Karlsson, e A. Loutfi, “A review of unsupervised feature learning and deep learning for time-series modeling”, *Pattern Recognit. Lett.*, vol. 42, p. 11–24, 2014.
- [4] A. Reiss e D. Stricker, “Introducing a modular activity monitoring system”, in *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, 2011, p. 5621–5624.
- [5] A. Kampouraki, G. Manis, e C. Nikou, “Heartbeat time series classification with support vector machines”, *Inf. Technol. Biomed. IEEE Trans. On*, vol. 13, nº 4, p. 512–518, 2009.
- [6] E. Haselsteiner e G. Pfurtscheller, “Using time-dependent neural networks for EEG classification”, *Rehabil. Eng. IEEE Trans. On*, vol. 8, nº 4, p. 457–463, 2000.
- [7] Y. Zheng, Q. Liu, E. Chen, Y. Ge, e J. L. Zhao, “Time series classification using multi-channels deep convolutional neural networks”, in *Web-Age Information Management*, Springer, 2014, p. 298–310.
- [8] D. Wang e Y. Shang, “Modeling physiological data with deep belief networks”, *Int. J. Inf. Educ. Technol. IJIET*, vol. 3, nº 5, p. 505, 2013.
- [9] M. Långkvist, L. Karlsson, e A. Loutfi, “Sleep stage classification using unsupervised feature learning”, *Adv. Artif. Neural Syst.*, vol. 2012, p. 5, 2012.
- [10] P. C. Ribeiro e J. Santos-Victor, “Human activity recognition from video: modeling, feature selection and classification architecture”, in *Proceedings of International Workshop on Human Activity Recognition and Modelling*, 2005, p. 61–78.
- [11] Y. Bengio, P. Lamblin, D. Popovici, e H. Larochelle, “Greedy layer-wise training of deep networks”, *Adv. Neural Inf. Process. Syst.*, vol. 19, p. 153, 2007.
- [12] A. Le Guennec, S. Malinowski, e R. Tavenard, “Data Augmentation for Time Series Classification using Convolutional Neural Networks”, in *ECML/PKDD Workshop on Advanced Analytics and Learning on Temporal Data*, 2016.
- [13] A. Krizhevsky, I. Sutskever, e G. E. Hinton, “Imagenet classification with deep convolutional neural networks”, in *Advances in neural information processing systems*, 2012, p. 1097–1105.
- [14] Z. Cui, W. Chen, e Y. Chen, “Multi-Scale Convolutional Neural Networks for Time Series Classification”, *ArXiv Prepr. ArXiv160306995*, 2016.
- [15] D. J. Hewson, N. K. Singh, H. Snoussi, e J. Duchene, “Classification of elderly as fallers and non-fallers using Centre of Pressure velocity”, in *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, 2010, p. 3678–3681.



- [16] L. H. G. Marrega, S. M. Silva, E. F. Manffra, e J. C. Nievola, “Comparison between Decision Tree and Genetic Programming to distinguish healthy from stroke postural sway patterns”, in *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, 2015, p. 6820–6823.
- [17] M. Duarte e S. Freitas, “Revisão sobre posturografia baseada em plataforma de força para avaliação do equilíbrio”, *Rev Bras Fisioter*, vol. 14, n° 3, p. 183–92, 2010.
- [18] M. Costa, A. L. Goldberger, e C.-K. Peng, “Multiscale entropy analysis of complex physiologic time series”, *Phys. Rev. Lett.*, vol. 89, n° 6, p. 068102, 2002.
- [19] M. Costa *et al.*, “Noise and poise: enhancement of postural complexity in the elderly with a stochastic-resonance-based therapy”, *EPL Europhys. Lett.*, vol. 77, n° 6, p. 68008, 2007.
- [20] M. Kirchner, P. Schubert, D. Schmidtbleicher, e C. T. Haas, “Evaluation of the temporal structure of postural sway fluctuations based on a comprehensive set of analysis tools”, *Phys. Stat. Mech. Its Appl.*, vol. 391, n° 20, p. 4692–4703, 2012.
- [21] M. Duarte e D. Sternad, “Complexity of human postural control in young and older adults during prolonged standing”, *Exp. Brain Res.*, vol. 191, n° 3, p. 265–276, 2008.
- [22] M. Roerdink, M. De Haart, A. Daffertshofer, S. F. Donker, A. C. H. Geurts, e P. J. Beek, “Dynamical structure of center-of-pressure trajectories in patients recovering from stroke”, *Exp. Brain Res.*, vol. 174, n° 2, p. 256–269, 2006.
- [23] C. K. Rhea, A. W. Kiefer, W. G. Wright, L. D. Raisbeck, e F. J. Haran, “Interpretation of postural control may change due to data processing techniques”, *Gait Posture*, vol. 41, n° 2, p. 731–735, 2015.
- [24] L. H. Giovanini, S. M. Silva, E. F. Manffra, e J. C. Nievola, “Sampling and Digital Filtering Effects When Recognizing Postural Control with Statistical Tools and the Decision Tree Classifier”, *Procedia Comput. Sci.*, vol. 108, p. 129–138, 2017.
- [25] L. H. Giovanini, E. F. Manffra, e J. C. Nievola, “Discriminating Postural Control Behaviors from Posturography with Statistical Tests and Machine Learning Models: Does Time Series Length Matter?”, in *International Conference on Computational Science*, 2018, p. 350–357.
- [26] L. H. G. Marrega e J. C. Nievola, “Evaluation of the Relevance of Linear and Non-linear Posturographic Features in the Recognition of Healthy Subjects and Stroke Patients”, in *2014 IEEE International Conference on Data Mining Workshop (ICDMW)*, 2014, p. 111–118.
- [27] P. Hamel, S. Lemieux, Y. Bengio, e D. Eck, “Temporal Pooling and Multiscale Learning for Automatic Annotation and Ranking of Music Audio.”, in *ISMIR*, 2011, p. 729–734.
- [28] E. Keogh e S. Kasetty, “On the need for time series data mining benchmarks: a survey and empirical demonstration”, *Data Min. Knowl. Discov.*, vol. 7, n° 4, p. 349–371, 2003.
- [29] H. D. Masethe e M. A. Masethe, “Prediction of heart disease using classification algorithms”, in *Proceedings of the World Congress on Engineering and Computer Science*, 2014, vol. 2.
- [30] S. Palaniappan e R. Awang, “Intelligent heart disease prediction system using data mining techniques”, in *Computer Systems and Applications, 2008. AICCSA 2008. IEEE/ACS International Conference on*, 2008, p. 108–115.
- [31] K. Srinivas, B. K. Rani, e A. Govrdhan, “Applications of data mining techniques in healthcare and prediction of heart attacks”, *Int. J. Comput. Sci. Eng. IJCSE*, vol. 2, n° 02, p. 250–255, 2010.

- [32] P. Venkatesan e N. R. Yamuna, “Treatment response classification in randomized clinical trials: a decision tree approach”, *Indian J. Sci. Technol.*, vol. 6, n° 1, p. 3912–3917, 2013.
- [33] S. Joshi, D. Shenoy, G. G. Vibhudendra Simha, P. L. Rrashmi, K. R. Venugopal, e L. M. Patnaik, “Classification of Alzheimer’s disease and Parkinson’s disease by using machine learning and neural network methods”, in *Machine Learning and Computing (ICMLC), 2010 Second International Conference on*, 2010, p. 218–222.
- [34] D. Delen, G. Walker, e A. Kadam, “Predicting breast cancer survivability: a comparison of three data mining methods”, *Artif. Intell. Med.*, vol. 34, n° 2, p. 113–127, 2005.
- [35] C.-L. Liu, C.-H. Lee, e P.-M. Lin, “A fall detection system using k-nearest neighbor classifier”, *Expert Syst. Appl.*, vol. 37, n° 10, p. 7174–7181, 2010.
- [36] G. Lukacs, M. Jani, e G. Takacs, “Acoustic feature mining for mixed speech and music playlist generation”, in *ELMAR, 2013 55th International Symposium*, 2013, p. 275–278.
- [37] M. H. Dunham, *Data mining: Introductory and advanced topics*. Pearson Education India, 2006.
- [38] J. Han, M. Kamber, e J. Pei, *Data mining: concepts and techniques*. Elsevier, 2011.
- [39] F. Gorunescu, *Data Mining: Concepts, models and techniques*, vol. 12. Springer Science & Business Media, 2011.
- [40] A. Jain e D. Zongker, “Feature selection: Evaluation, application, and small sample performance”, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 19, n° 2, p. 153–158, 1997.
- [41] H. B. Borges e J. C. Nievola, “Feature Selection as a Preprocessing Step for Classification in Gene Expression Data”, in *Seventh International Conference on Intelligent Systems Design and Applications (ISDA 2007)*, 2007.
- [42] S. K. Saripalle, G. C. Paiva, T. C. Cliett, R. R. Derakhshani, G. W. King, e C. T. Lovelace, “Classification of body movements based on posturographic data”, *Hum. Mov. Sci.*, vol. 33, p. 238–250, 2014.
- [43] S. Dinakaran e P. R. J. Thangaiah, “Comparative Analysis of Filter-Wrapper approach for Random forest performance on multivariate data”, in *Intelligent Computing Applications (ICICA), 2014 International Conference on*, 2014, p. 174–178.
- [44] Y. Bengio, “Learning deep architectures for AI”, *Found. Trends® Mach. Learn.*, vol. 2, n° 1, p. 1–127, 2009.
- [45] K. J. Lang, A. H. Waibel, e G. E. Hinton, “A time-delay neural network architecture for isolated word recognition”, *Neural Netw.*, vol. 3, n° 1, p. 23–43, 1990.
- [46] A. M. Khan, Y.-K. Lee, S. Y. Lee, e T.-S. Kim, “A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer”, *Inf. Technol. Biomed. IEEE Trans. On*, vol. 14, n° 5, p. 1166–1172, 2010.
- [47] M. Minsky e S. Papert, *Perceptrons; an introduction to computational geometry. 1969*. Cambridge, Mass.: MIT Press, 1987.
- [48] H. Simon, *Redes Neurais—Princípios e Prática*. Porto Alegre: Bookman, 2001.
- [49] Y. LeCun, L. Bottou, Y. Bengio, e P. Haffner, “Gradient-based learning applied to document recognition”, *Proc. IEEE*, vol. 86, n° 11, p. 2278–2324, 1998.
- [50] Y. Bengio, P. Simard, e P. Frasconi, “Learning long-term dependencies with gradient descent is difficult”, *Neural Netw. IEEE Trans. On*, vol. 5, n° 2, p. 157–166, 1994.
- [51] M. A. Nielsen, “Neural Networks and Deep Learning”, URL [Httpneuralnetworksanddeeplearning Comvisited 0111 2014](http://neuralnetworksanddeeplearning.com/visited/01112014/), 2015.

- [52] Y. Bengio e Y. LeCun, “Scaling learning algorithms towards AI”, *Large-Scale Kernel Mach.*, vol. 34, n° 5, 2007.
- [53] G. E. Hinton, S. Osindero, e Y.-W. Teh, “A fast learning algorithm for deep belief nets”, *Neural Comput.*, vol. 18, n° 7, p. 1527–1554, 2006.
- [54] M. Längkvist, “Modeling time-series with deep networks”, 2014.
- [55] D. Ciresan, U. Meier, e J. Schmidhuber, “Multi-column deep neural networks for image classification”, in *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, 2012, p. 3642–3649.
- [56] M. M. Al Rahhal, Y. Bazi, H. AlHichri, N. Alajlan, F. Melgani, e R. R. Yager, “Deep learning approach for active classification of electrocardiogram signals”, *Inf. Sci.*, vol. 345, p. 340–354, 2016.
- [57] H.-C. Shin, M. Orton, D. J. Collins, S. Doran, e M. O. Leach, “Autoencoder in time-series analysis for unsupervised tissues characterisation in a large unlabelled medical image dataset”, in *Machine Learning and Applications and Workshops (ICMLA), 2011 10th International Conference on*, 2011, vol. 1, p. 259–264.
- [58] B. Jokanovic, M. Amin, e F. Ahmad, “Radar Fall Motion Detection Using Deep Learning”.
- [59] S. Jankowski, Z. Szymański, U. Dziomin, P. Mazurek, e J. Wagner, “Deep learning classifier for fall detection based on IR distance sensor data”, in *Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), 2015 IEEE 8th International Conference on*, 2015, vol. 2, p. 723–727.
- [60] L. Zhang *et al.*, “Classification of older adults with/without a fall history using machine learning methods”, in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015, p. 6760–6763.
- [61] A. Graves, A. Mohamed, e G. Hinton, “Speech recognition with deep recurrent neural networks”, in *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, 2013, p. 6645–6649.
- [62] N. Jaitly e G. Hinton, “Learning a better representation of speech soundwaves using restricted boltzmann machines”, in *Acoustics, Speech and Signal Processing (ICASSP), 2011 IEEE International Conference on*, 2011, p. 5884–5887.
- [63] N. Boulanger-Lewandowski, Y. Bengio, e P. Vincent, “Modeling temporal dependencies in high-dimensional sequences: Application to polyphonic music generation and transcription”, *ArXiv Prepr. ArXiv12066392*, 2012.
- [64] E. J. Humphrey, J. P. Bello, e Y. LeCun, “Feature learning and deep architectures: new directions for music informatics”, *J. Intell. Inf. Syst.*, vol. 41, n° 3, p. 461–481, 2013.
- [65] H. Lee, P. Pham, Y. Largman, e A. Y. Ng, “Unsupervised feature learning for audio classification using convolutional deep belief networks”, in *Advances in neural information processing systems*, 2009, p. 1096–1104.
- [66] K. He, X. Zhang, S. Ren, e J. Sun, “Deep residual learning for image recognition”, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, p. 770–778.
- [67] A. Coates *et al.*, “Text detection and character recognition in scene images with unsupervised feature learning”, in *Document Analysis and Recognition (ICDAR), 2011 International Conference on*, 2011, p. 440–445.
- [68] W.-L. Zheng, J.-Y. Zhu, Y. Peng, e B.-L. Lu, “EEG-based emotion classification using deep belief networks”, in *Multimedia and Expo (ICME), 2014 IEEE International Conference on*, 2014, p. 1–6.

- [69] S. Jirayucharoensak, S. Pan-Ngum, e P. Israsena, “EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation”, *Sci. World J.*, vol. 2014, 2014.
- [70] M. D. Zeiler e R. Fergus, “Visualizing and understanding convolutional networks”, in *European Conference on Computer Vision*, 2014, p. 818–833.
- [71] J. Yosinski, J. Clune, A. Nguyen, T. Fuchs, e H. Lipson, “Understanding neural networks through deep visualization”, *ArXiv Prepr. ArXiv150606579*, 2015.
- [72] Y. LeCun e Y. Bengio, “Convolutional networks for images, speech, and time series”, *Handb. Brain Theory Neural Netw.*, vol. 3361, n° 10, 1995.
- [73] Y. LeCun, K. Kavukcuoglu, e C. Farabet, “Convolutional networks and applications in vision.”, in *ISCAS*, 2010, p. 253–256.
- [74] M. Dalto, “Deep neural networks for time series prediction with applications in ultra-short-term wind forecasting”, *Rn  $\Theta$ 1*, vol. 1, p. 2.
- [75] J. B. Yang, M. N. Nguyen, P. P. San, X. L. Li, e S. Krishnaswamy, “Deep convolutional neural networks on multichannel time series for human activity recognition”, in *Proceedings of the 24th International Joint Conference on Artificial Intelligence (IJCAI), Buenos Aires, Argentina*, 2015, p. 25–31.
- [76] V. Nair e G. E. Hinton, “Rectified linear units improve restricted boltzmann machines”, in *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 2010, p. 807–814.
- [77] L. E. V. da Silva, “Ferramentas computacionais na análise da variabilidade da frequência cardíaca através do paradigma não extensivo no estudo de cardiopatias”, Universidade de São Paulo, 2010.
- [78] Y.-L. Boureau, J. Ponce, e Y. LeCun, “A theoretical analysis of feature pooling in visual recognition”, in *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010, p. 111–118.
- [79] D. Scherer, A. Müller, e S. Behnke, “Evaluation of pooling operations in convolutional architectures for object recognition”, in *Artificial Neural Networks–ICANN 2010*, Springer, 2010, p. 92–101.
- [80] O. Bousquet e L. Bottou, “The tradeoffs of large scale learning”, in *Advances in neural information processing systems*, 2008, p. 161–168.
- [81] D. Mishkin, N. Sergievskiy, e J. Matas, “Systematic evaluation of CNN advances on the ImageNet”, *ArXiv Prepr. ArXiv160602228*, 2016.
- [82] Y. Bengio, “Practical recommendations for gradient-based training of deep architectures”, in *Neural Networks: Tricks of the Trade*, Springer, 2012, p. 437–478.
- [83] S. Lee, D. Kwon, e S. Lee, “Minimum distance queries for time series data”, *J. Syst. Softw.*, vol. 69, n° 1, p. 105–113, 2004.
- [84] A. M. Drewry, B. M. Fuller, T. C. Bailey, e R. S. Hotchkiss, “Body temperature patterns as a predictor of hospital-acquired sepsis in afebrile adult intensive care unit patients: a case-control study”, *Crit. Care*, vol. 17, n° 5, p. 1, 2013.
- [85] P. Baldi, Y. Chauvin, T. Hunkapiller, e M. A. McClure, “Hidden Markov models of biological primary sequence information.”, *Proc. Natl. Acad. Sci.*, vol. 91, n° 3, p. 1059–1063, 1994.
- [86] S. Laxman e P. S. Sastry, “A survey of temporal data mining”, *Sadhana*, vol. 31, n° 2, p. 173–198, 2006.
- [87] D. Eads, K. Glocer, S. Perkins, e J. Theiler, “Grammar-guided feature extraction for time series classification”, in *Proceedings of the 9th Annual Conference on Neural Information Processing Systems (NIPS’05)*, 2005.

- [88] Z. Wang, W. Yan, e T. Oates, “Time series classification from scratch with deep neural networks: A strong baseline”, in *Neural Networks (IJCNN), 2017 International Joint Conference on*, 2017, p. 1578–1585.
- [89] M. Duarte e V. M. Zatsiorsky, “Long-range correlations in human standing”, *Phys. Lett. A*, vol. 283, n° 1, p. 124–128, 2001.
- [90] P. Kannus *et al.*, “Fall-induced injuries and deaths among older adults”, *Jama*, vol. 281, n° 20, p. 1895–1899, 1999.
- [91] A. Shumway-Cook, M. Baldwin, N. L. Polissar, e W. Gruber, “Predicting the probability for falls in community-dwelling older adults”, *Phys. Ther.*, vol. 77, n° 8, p. 812–819, 1997.
- [92] W. H. Organization, *WHO global report on falls prevention in older age*. World Health Organization, 2008.
- [93] C. Sforza, G. P. Grassi, M. Turci, N. Fragnito, G. Pizzini, e V. F. Ferrario, “Influence of training on maintenance of equilibrium on a tilting platform”, *Percept. Mot. Skills*, vol. 96, n° 1, p. 127–136, 2003.
- [94] M. Duarte, “Análise estabilométrica da postura ereta humana quasi-estática”, Universidade de São Paulo, 2000.
- [95] M. K. Lebedowska e M. Syczewska, “Invariant sway properties in children”, *Gait Posture*, vol. 12, n° 3, p. 200–204, 2000.
- [96] J. M. Macpherson e F. B. Horak, “Posture. In: Kandel ER, Schwartz JH, Jessel TM, Siegelbaum SA, Hudspeth A, editors”, *Princ. Neural Sci. N. Y. McGraw-Hill*, p. 935–59, 2013.
- [97] F. B. Horak, “Postural orientation and equilibrium: what do we need to know about neural control of balance to prevent falls?”, *Age Ageing*, vol. 35, n° suppl 2, p. ii7–ii11, 2006.
- [98] F. M. Alfieri e M. C. L. de Moraes, “Envelhecimento e o controle postural”, *Saúde Coletiva*, vol. 4, n° 19, p. 30–3, 2008.
- [99] A. Shumway-Cook, M. H. Woollacott, e M. de Lourdes Gianini, *Controle motor: teoria e aplicações práticas*. Manole, 2003.
- [100] P. A. Hageman, J. M. Lebowitz, e D. Blanke, “Age and gender effects on postural control measures”, *Arch. Phys. Med. Rehabil.*, vol. 76, n° 10, p. 961–965, 1995.
- [101] I. Melzer, N. Benjuya, e J. Kaplanski, “Age-related changes of postural control: effect of cognitive tasks”, *Gerontology*, vol. 47, n° 4, p. 189–194, 2001.
- [102] M. M. da COSTA NETO e J. A. Silvestre, “Atenção à Saúde do Idoso-Instabilidade postural e queda”, *Cad. Atenção Básica Voltado Para Atenção À Pessoa Idosa Brasília Dep. Atenção Básica Secr. Políticas Saúde Minist. Saúde*, 1999.
- [103] M. J. D. Diogo, A. L. Neri, e M. Cachioni, “Saúde e qualidade de vida na velhice”, in *Coleção velhice e sociedade*, Alínea, 2006.
- [104] L. M. B. Presumido, M. A. Baraúna, C. Ferreira, e K. C. Silva, “Estudo comparativo entre o equilíbrio estático de indivíduos sedentários e não sedentários do sexo feminino”, *Ícone*, vol. 3, n° 2, p. 39–62, 1995.
- [105] C. D. Wolfe, “The impact of stroke”, *Br. Med. Bull.*, vol. 56, n° 2, p. 275–286, 2000.
- [106] M. J. Aminoff e S. A. Josephson, *Aminoff’s neurology and general medicine*. Elsevier, 2014.
- [107] Ministério da Saúde, “Acidente vascular cerebral (AVC)”. [Online]. Disponível em: <http://www.brasil.gov.br/editoria/saude/2012/04/acidente-vascular-cerebral-avc>.

- [108] O. Pyöriä, P. Era, e U. Talvitie, “Relationships between standing balance and symmetry measurements in patients following recent strokes ( $\leq 3$  weeks) or older strokes ( $\geq 6$  months)”, *Phys. Ther.*, vol. 84, n° 2, p. 128–136, 2004.
- [109] Silva, S. M., “Análise do controle postural de indivíduos pós-acidente vascular encefálico frente a perturbações dos sistemas visual e somatossensorial”, M.S. thesis, PUCPR, 2012.
- [110] W. H. Organization, *A glossary of terms for community health care and services for older persons*. WHO, 2004.
- [111] Secretaria Especial de Direitos Humanos, “Pessoa Idosa”. [Online]. Disponível em: <http://www.sdh.gov.br/assuntos/pessoa-idosa/dados-estatisticos>.
- [112] Organização Mundial da Saúde, “Relatório Mundial de Envelhecimento e Saúde”. [Online]. Disponível em: <http://sbgg.org.br/wp-content/uploads/2015/10/OMS-ENVELHECIMENTO-2015-port.pdf>. [Acessado: 02-ago-2016].
- [113] A. C. M. Rennó, “Atividade física e osteoporose: uma revisão bibliográfica”, *Fisioter Mov*, vol. 13, n° 2, p. 49–54, 2001.
- [114] S. L. Ruwer, A. G. Rossi, e L. F. Simon, “Equilíbrio no idoso”, *Rev Bras Otorrinolaringol*, vol. 71, n° 3, p. 298–303, 2005.
- [115] F. B. Horak e J. M. Macpherson, “Postural orientation and equilibrium”, *Compr. Physiol.*, 2011.
- [116] WHO Media centre, “Falls”, 2017. [Online]. Disponível em: <http://www.who.int/mediacentre/factsheets/fs344/en/>. [Acessado: 06-abr-2017].
- [117] J. A. Stevens, P. S. Corso, E. A. Finkelstein, e T. R. Miller, “The costs of fatal and non-fatal falls among older adults”, *Inj. Prev.*, vol. 12, n° 5, p. 290–295, 2006.
- [118] C. Todd e D. Skelton, *What are the Main Risk Factors for Falls Amongst Older People and what are the Most Effective Interventions to Prevent These Falls?*. World Health Organization, 2004.
- [119] M. E. Tinetti, C. F. M. De Leon, J. T. Doucette, e D. I. Baker, “Fear of falling and fall-related efficacy in relationship to functioning among community-living elders”, *J. Gerontol.*, vol. 49, n° 3, p. M140–M147, 1994.
- [120] E. C. Jørstad, K. Hauer, C. Becker, e S. E. Lamb, “Measuring the psychological outcomes of falling: a systematic review”, *J. Am. Geriatr. Soc.*, vol. 53, n° 3, p. 501–510, 2005.
- [121] A. C. Scheffer, M. J. Schuurmans, N. Van Dijk, T. Van Der Hooft, e S. E. De Rooij, “Fear of falling: measurement strategy, prevalence, risk factors and consequences among older persons”, *Age Ageing*, vol. 37, n° 1, p. 19–24, 2008.
- [122] C. L. Arfken, H. W. Lach, S. J. Birge, e J. P. Miller, “The prevalence and correlates of fear of falling in elderly persons living in the community.”, *Am. J. Public Health*, vol. 84, n° 4, p. 565–570, 1994.
- [123] D. G. Bruce, A. Devine, e R. L. Prince, “Recreational physical activity levels in healthy older women: the importance of fear of falling”, *J. Am. Geriatr. Soc.*, vol. 50, n° 1, p. 84–89, 2002.
- [124] S. Franzoni, R. Rozzini, S. Boffelli, G. B. Frisoni, e M. Trabucchi, “Fear of falling in nursing home patients”, *Gerontology*, vol. 40, n° 1, p. 38–44, 1994.
- [125] J. Howland, E. W. Peterson, W. C. Levin, L. Fried, D. Pordon, e S. Bak, “Fear of falling among the community-dwelling elderly”, *J. Aging Health*, vol. 5, n° 2, p. 229–243, 1993.
- [126] J. A. Painter, L. Allison, P. Dhingra, J. Daughtery, K. Cogdill, e L. G. Trujillo, “Fear of falling and its relationship with anxiety, depression, and activity engagement among community-dwelling older adults”, *Am. J. Occup. Ther.*, vol. 66, n° 2, p. 169–176, 2012.

- [127] G. I. Kempen *et al.*, “The Short FES-I: a shortened version of the falls efficacy scale-international to assess fear of falling”, *Age Ageing*, vol. 37, n° 1, p. 45–50, 2008.
- [128] J. Howcroft, J. Kofman, e E. D. Lemaire, “Review of fall risk assessment in geriatric populations using inertial sensors”, *J. Neuroengineering Rehabil.*, vol. 10, n° 1, p. 1, 2013.
- [129] J. Morse, *Preventing patient falls. 1997*. Thousand Oaks, CA: Sage Publications, Inc Google Scholar.
- [130] S. S. Poe, M. M. Cvach, D. G. Gartrell, B. R. Radzik, e T. L. Joy, “An Evidence-based Approach to Fall Risk Assessment, Prevention, and Management: Lessons Learned”, *J. Nurs. Care Qual.*, vol. 20, n° 2, p. 107–116, 2005.
- [131] K. Delbaere, J. C. Close, A. S. Mikolaizak, P. S. Sachdev, H. Brodaty, e S. R. Lord, “The falls efficacy scale international (FES-I). A comprehensive longitudinal validation study”, *Age Ageing*, vol. 39, n° 2, p. 210–216, 2010.
- [132] F. Franchignoni, F. Horak, M. Godi, A. Nardone, e A. Giordano, “Using psychometric techniques to improve the Balance Evaluation Systems Test: the mini-BESTest”, *J. Rehabil. Med.*, vol. 42, n° 4, p. 323–331, 2010.
- [133] R. P. Duncan *et al.*, “Accuracy of fall prediction in Parkinson disease: six-month and 12-month prospective analyses”, *Park. Dis.*, vol. 2012, 2011.
- [134] A. Yingyongyudha, V. Saengsirisuwan, W. Panichaporn, e R. Boonsinsukh, “The Mini-Balance Evaluation Systems Test (Mini-BESTest) demonstrates higher accuracy in identifying older adult participants with history of falls than do the BESTest, Berg Balance Scale, or Timed Up and Go Test”, *J. Geriatr. Phys. Ther.*, vol. 39, n° 2, p. 64–70, 2016.
- [135] S. F. Donker, A. Ledebt, M. Roerdink, G. J. Savelsbergh, e P. J. Beek, “Children with cerebral palsy exhibit greater and more regular postural sway than typically developing children”, *Exp. Brain Res.*, vol. 184, n° 3, p. 363–370, 2008.
- [136] M. Duarte e V. M. Zatsiorsky, “On the fractal properties of natural human standing”, *Neurosci. Lett.*, vol. 283, n° 3, p. 173–176, 2000.
- [137] S. Freitas e M. Duarte, “Métodos de análise do controle postural”, *Laboratório Biofísica Esc. Educ. Física E Esporte Universidade São Paulo*, 2006.
- [138] M. Ferdjallah, G. F. Harris, P. Smith, e J. J. Wertsch, “Analysis of postural control synergies during quiet standing in healthy children and children with cerebral palsy”, *Clin. Biomech.*, vol. 17, n° 3, p. 203–210, 2002.
- [139] D. Lafond, H. Corriveau, R. Hébert, e F. Prince, “Intrasession reliability of center of pressure measures of postural steadiness in healthy elderly people”, *Arch. Phys. Med. Rehabil.*, vol. 85, n° 6, p. 896–901, 2004.
- [140] A. Ruhe, R. Fejer, e B. Walker, “The test–retest reliability of centre of pressure measures in bipedal static task conditions—a systematic review of the literature”, *Gait Posture*, vol. 32, n° 4, p. 436–445, 2010.
- [141] M. R. M. Mainenti, “Análise de sinais estabilométricos em testes com estímulos sonoros”, UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, 2005.
- [142] S. F. Donker, M. Roerdink, A. J. Greven, e P. J. Beek, “Regularity of center-of-pressure trajectories depends on the amount of attention invested in postural control”, *Exp. Brain Res.*, vol. 181, n° 1, p. 1–11, 2007.
- [143] M. de Haart, A. C. Geurts, S. C. Huidekoper, L. Fasotti, e J. van Limbeek, “Recovery of standing balance in postacute stroke patients: a rehabilitation cohort study”, *Arch. Phys. Med. Rehabil.*, vol. 85, n° 6, p. 886–895, 2004.

- [144] R. W. Baloh, K. M. Jacobson, J. A. Enrietto, S. Corona, e V. Honrubia, “Balance disorders in older persons: quantification with posturography”, *Otolaryngol.-Head Neck Surg.*, vol. 119, n° 1, p. 89–92, 1998.
- [145] R. W. Baloh *et al.*, “Comparison of static and dynamic posturography in young and older normal people”, *J. Am. Geriatr. Soc.*, vol. 42, n° 4, p. 405–412, 1994.
- [146] A. Forster e J. Young, “Incidence and consequences offalls due to stroke: a systematic inquiry”, *Bmj*, vol. 311, n° 6997, p. 83–86, 1995.
- [147] N. Genthon, P. Rougier, A.-S. Gissot, J. Froger, J. Pélissier, e D. Pérennou, “Contribution of each lower limb to upright standing in stroke patients”, *Stroke*, vol. 39, n° 6, p. 1793–1799, 2008.
- [148] M. Kirchner, “Characterising postural sway fluctuations in humans using linear and nonlinear methods”, Univ.-Bibliothek Frankfurt am Main, 2013.
- [149] J. Jeka, T. Kiemel, R. Creath, F. Horak, e R. Peterka, “Controlling human upright posture: velocity information is more accurate than position or acceleration”, *J. Neurophysiol.*, vol. 92, n° 4, p. 2368–2379, 2004.
- [150] H. Ghomashchi, A. Esteki, J. C. Sprott, e A. M. Nasrabadi, “Identification of dynamic patterns of body sway during quiet standing: Is it a nonlinear process?”, *Int. J. Bifurc. Chaos*, vol. 20, n° 04, p. 1269–1278, 2010.
- [151] G. Tallon, H. Blain, B. Seigle, P. L. Bernard, e S. Ramdani, “Dynamical and stabilometric measures are complementary for the characterization of postural fluctuations in older women”, *Gait Posture*, vol. 38, n° 1, p. 92–96, 2013.
- [152] J. Han, Z. Moussavi, T. Szturm, e V. Goodman, “Application of nonlinear dynamics to human postural control system”, in *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, 2006, p. 6885–6888.
- [153] M. Ganesan, Y.-J. Lee, e A. S. Aruin, “The effect of lateral or medial wedges on control of postural sway in standing”, *Gait Posture*, vol. 39, n° 3, p. 899–903, 2014.
- [154] M. G. Carpenter, J. S. Frank, D. A. Winter, e G. W. Peysar, “Sampling duration effects on centre of pressure summary measures”, *Gait Posture*, vol. 13, n° 1, p. 35–40, 2001.
- [155] S. Demura, T. Kitabayashi, e H. Aoki, “Body-sway characteristics during a static upright posture in the elderly”, *Geriatr. Gerontol. Int.*, vol. 8, n° 3, p. 188–197, 2008.
- [156] D. Rugelj e F. Sevšek, “The effect of load mass and its placement on postural sway”, *Appl. Ergon.*, vol. 42, n° 6, p. 860–866, 2011.
- [157] A. H. Vette, K. Masani, V. Sin, e M. R. Popovic, “Posturographic measures in healthy young adults during quiet sitting in comparison with quiet standing”, *Med. Eng. Phys.*, vol. 32, n° 1, p. 32–38, 2010.
- [158] M. Zok, C. Mazzà, e A. Cappozzo, “Should the instructions issued to the subject in traditional static posturography be standardised?”, *Med. Eng. Phys.*, vol. 30, n° 7, p. 913–916, 2008.
- [159] R. Cabeza-Ruiz, X. García-Massó, R. A. Centeno-Prada, J. D. Beas-Jiménez, J. C. Colado, e L.-M. González, “Time and frequency analysis of the static balance in young adults with Down syndrome”, *Gait Posture*, vol. 33, n° 1, p. 23–28, 2011.
- [160] J. E. Deffeyes, R. T. Harbourne, A. Kyvelidou, W. A. Stuberger, e N. Stergiou, “Non-linear analysis of sitting postural sway indicates developmental delay in infants”, *Clin. Biomech.*, vol. 24, n° 7, p. 564–570, 2009.
- [161] O. G. de Castro, “Deslocamento do centro de pressão nas posições bipodal e unipodal em crianças”, 2013.
- [162] S. Gurses e H. Celik, “Correlation dimension estimates of human postural sway”, *Hum. Mov. Sci.*, vol. 32, n° 1, p. 48–64, 2013.



- [163] P. Madeleine, M. Nielsen, e L. Arendt-Nielsen, “Characterization of postural control deficit in whiplash patients by means of linear and nonlinear analyses—a pilot study”, *J. Electromyogr. Kinesiol.*, vol. 21, n° 2, p. 291–297, 2011.
- [164] J. W. B<sup>3</sup>aszczyk, “Sway ratio a new measure for quantifying postural stability”, *Acta Neurobiol Exp*, vol. 68, p. 51–57, 2008.
- [165] H. Corriveau, R. Hébert, F. Prince, e M. Raïche, “Postural control in the elderly: an analysis of test-retest and interrater reliability of the COP-COM variable”, *Arch. Phys. Med. Rehabil.*, vol. 82, n° 1, p. 80–85, 2001.
- [166] T. L. Doyle, R. U. Newton, e A. F. Burnett, “Reliability of traditional and fractal dimension measures of quiet stance center of pressure in young, healthy people”, *Arch. Phys. Med. Rehabil.*, vol. 86, n° 10, p. 2034–2040, 2005.
- [167] Baratto, L, Morasso, PG, C. Re, e G. Spada, “A new look at posturographic analysis in the clinical context: sway-density versus other parameterization techniques”, *Motor Control*, vol. 6, p. 246–2, 2002.
- [168] L. F. Oliveira, T. M. Vieira, A. R. Macedo, D. M. Simpson, e J. Nadal, “Postural sway changes during pregnancy: a descriptive study using stabilometry”, *Eur. J. Obstet. Gynecol. Reprod. Biol.*, vol. 147, n° 1, p. 25–28, 2009.
- [169] H. Amoud, M. Abadi, D. J. Hewson, V. Michel-Pellegrino, M. Doussot, e J. Duchêne, “Fractal time series analysis of postural stability in elderly and control subjects”, *J. NeuroEngineering Rehabil.*, vol. 4, p. 12–12, 2007.
- [170] D. Delignieres, S. Ramdani, L. Lemoine, K. Torre, M. Fortes, e G. Ninot, “Fractal analyses for ‘short’ time series: a re-assessment of classical methods”, *J. Math. Psychol.*, vol. 50, n° 6, p. 525–544, 2006.
- [171] D. Delignières, T. Deschamps, A. Legros, e N. Caillou, “A methodological note on nonlinear time series analysis: is the open-and closed-loop model of Collins and De Luca (1993) a statistical artifact?”, *J. Mot. Behav.*, vol. 35, n° 1, p. 86–96, 2003.
- [172] P. B. Pascolo, A. Marini, R. Carniel, e F. Barazza, “Posture as a chaotic system and an application to the Parkinson’s disease”, *Chaos Solitons Fractals*, vol. 24, n° 5, p. 1343–1346, 2005.
- [173] J. S. Richman e J. R. Moorman, “Physiological time-series analysis using approximate entropy and sample entropy”, *Am. J. Physiol.-Heart Circ. Physiol.*, vol. 278, n° 6, p. H2039–H2049, 2000.
- [174] G. D. Moulin, “Técnicas de entropia e de geoestatística no dimensionamento de redes pluviométricas”, Dissertação de Mestrado em Engenharia Ambiental). Universidade Federal do Espírito Santo, UFES, Vitória, 2005.
- [175] M. Costa, A. L. Goldberger, e C.-K. Peng, “Multiscale entropy analysis of biological signals”, *Phys. Rev. E*, vol. 71, n° 2, p. 021906, 2005.
- [176] J. J. Collins e C. J. De Luca, “Open-loop and closed-loop control of posture: a random-walk analysis of center-of-pressure trajectories”, *Exp. Brain Res.*, vol. 95, n° 2, p. 308–318, 1993.
- [177] C.-K. Peng, S. V. Buldyrev, S. Havlin, M. Simons, H. E. Stanley, e A. L. Goldberger, “Mosaic organization of DNA nucleotides”, *Phys. Rev. E*, vol. 49, n° 2, p. 1685, 1994.
- [178] M. J. Cannon, D. B. Percival, D. C. Caccia, G. M. Raymond, e J. B. Basingthwaighte, “Evaluating scaled windowed variance methods for estimating the Hurst coefficient of time series”, *Phys. Stat. Mech. Its Appl.*, vol. 241, n° 3, p. 606–626, 1997.
- [179] R. A. Ribeiro, “Correlações nos dfa de diversos perfis geológicos. estudo de caso: Bacia de Campos-RJ”, 2010.

- [180] R. M. Bryce e K. B. Sprague, “Revisiting detrended fluctuation analysis”, *Sci. Rep.*, vol. 2, 2012.
- [181] C.-K. Peng, M. Costa, e A. L. Goldberger, “Adaptive data analysis of complex fluctuations in physiologic time series”, *Adv. Adapt. Data Anal.*, vol. 1, n° 01, p. 61–70, 2009.
- [182] J.-J. Kim, Y.-J. Kim, e J.-J. Lee, “A machine learning approach to falling detection and avoidance for Biped Robots”, in *SICE Annual Conference (SICE), 2011 Proceedings of*, 2011, p. 562–567.
- [183] K. L. Goh, S. Morris, S. Rosalie, C. Foster, T. Falkmer, e T. Tan, “Typically developed adults and adults with autism spectrum disorder classification using centre of pressure measurements”, in *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2016, p. 844–848.
- [184] J. Rasku, “A method for the classification of corrective activity in context dependent postural controlling tasks”, *Comput. Biol. Med.*, vol. 39, n° 10, p. 940–945, 2009.
- [185] J. R. Chagdes *et al.*, “Multiple timescales in postural dynamics associated with vision and a secondary task are revealed by wavelet analysis”, *Exp. Brain Res.*, vol. 197, n° 3, p. 297–310, 2009.
- [186] C. K. Rhea *et al.*, “Noise and complexity in human postural control: interpreting the different estimations of entropy”, *PLoS One*, vol. 6, n° 3, p. e17696, 2011.
- [187] UC Berkeley, “EECS20N: Signals and Systems”, 2018. [Online]. Disponível em: <https://ptolemy.berkeley.edu/eecs20/week12/freqResponseRA.html>.
- [188] D. A. Santos e M. Duarte, “A public data set of human balance evaluations”, *PeerJ Preprints*, jun. 2016.
- [189] M. U. Guide, “The mathworks”, *Inc Natick MA*, vol. 5, p. 333, 1998.
- [190] L. F. Oliveira, D. M. Simpson, e J. Nadal, “Calculation of area of stabilometric signals using principal component analysis”, *Physiol. Meas.*, vol. 17, n° 4, p. 305, 1996.
- [191] D. E. Lake, J. S. Richman, M. P. Griffin, e J. R. Moorman, “Sample entropy analysis of neonatal heart rate variability”, *Am. J. Physiol.-Regul. Integr. Comp. Physiol.*, vol. 283, n° 3, p. R789–R797, 2002.
- [192] A. L. Goldberger *et al.*, “Physiobank, physiotoolkit, and physionet components of a new research resource for complex physiologic signals”, *Circulation*, vol. 101, n° 23, p. e215–e220, 2000.
- [193] F. G. Borg e G. Laxåback, “Entropy of balance—some recent results”, *J. Neuroengineering Rehabil.*, vol. 7, n° 1, p. 1, 2010.
- [194] T. E. Prieto, J. B. Myklebust, R. G. Hoffmann, E. G. Lovett, e B. M. Myklebust, “Measures of postural steadiness: differences between healthy young and elderly adults”, *IEEE Trans. Biomed. Eng.*, vol. 43, n° 9, p. 956–966, 1996.
- [195] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, e I. H. Witten, “The WEKA data mining software: an update”, *ACM SIGKDD Explor. Newsl.*, vol. 11, n° 1, p. 10–18, 2009.
- [196] L. H. F. Giovanini, “Avaliação de relevância de atributos posturográficos globais e estruturais para a identificação do acidente vascular encefálico utilizando modelos de classificação”, PUCPR, Curitiba.
- [197] C. Maurer e R. J. Peterka, “A new interpretation of spontaneous sway measures based on a simple model of human postural control”, *J. Neurophysiol.*, vol. 93, n° 1, p. 189–200, 2005.

- [198] T. M. M. Vieira, L. F. Oliveira, e J. Nadal, “Estimation procedures affect the center of pressure frequency analysis”, *Braz. J. Med. Biol. Res.*, vol. 42, n° 7, p. 665–673, 2009.
- [199] V. M. Zatsiorsky e M. Duarte, “Rambling and trembling in quiet standing”, *Motor Control*, vol. 4, n° 2, p. 185–200, 2000.

# ANEXOS

## ANEXO A - VERSÃO TRADUZIDA PARA O PORTUGÊS DO BRASIL DO SHORT FES-I

<b>Escala de eficácia de quedas – Internacional – Brasil (FES-I-Brasil)</b>				
Agora nós gostaríamos de fazer algumas perguntas sobre qual é sua preocupação a respeito da possibilidade de cair. Por favor, responda imaginando como você normalmente faz a atividade. Se você atualmente não faz a atividade (por ex. alguém vai às compras para você), responda de maneira a mostrar como você se sentiria em relação a quedas se você tivesse que fazer essa atividade. Para cada uma das seguintes atividades, por favor, marque o quadradinho que mais se aproxima de sua opinião sobre o quão preocupado você fica com a possibilidade de cair, se você fizesse esta atividade.				
	Nem um pouco preocupado	Um pouco preocupado	Muito preocupado	Extremamente preocupado
	1	2	3	4
1. Limpando a casa (ex: passar pano, aspirar ou tirar a poeira)	1	2	3	4
2. Vestindo ou tirando a roupa	1	2	3	4
3. Preparando refeições simples	1	2	3	4
4. Tomando banho	1	2	3	4
5. Indo às compras	1	2	3	4
6. Sentando ou levantando de uma cadeira	1	2	3	4
7. Subindo ou descendo escadas	1	2	3	4
8. Caminhando pela vizinhança	1	2	3	4
9. Pegando algo acima de sua cabeça ou do chão	1	2	3	4
10. Indo atender o telefone antes que pare de tocar	1	2	3	4
11. Andando sobre superfície escorregadia (ex: chão molhado)	1	2	3	4
12. Visitando um amigo ou parente	1	2	3	4
13. Andando em lugares cheios de gente	1	2	3	4
14. Caminhando sobre superfície irregular (com pedras, esburacada)	1	2	3	4
15. Subindo ou descendo uma ladeira	1	2	3	4
16. Indo a uma atividade social (ex: ato religioso, reunião de família ou encontro no clube)	1	2	3	4

## ANEXO B - VERSÃO TRADUZIDA PARA O PORTUGÊS DO BRASIL DO MINIBESTEST

<p>NOME DO EXAMINADOR _____ DATA ____/____/____ INDIVÍDUO _____</p> <p style="text-align: center;"><b>MINIBESTest</b> <i>Avaliação do Equilíbrio – Teste dos Sistemas</i></p> <p>Os indivíduos devem ser testados com sapatos sem salto ou sem sapatos nem meias. Se o indivíduo precisar de um dispositivo de auxílio para um item, pontue aquele item em uma categoria mais baixa. Se o indivíduo precisar de assistência física para completar um item, pontue na categoria mais baixa (0) para aquele item.</p>	<p>7. OLHOS ABERTOS, SUPERFÍCIE FIRME (PÉS JUNTOS) (<i>Tempo em segundos: _____</i>) (2) Normal: 30 s (1) Moderado: &lt;30 s (0) Grave: Incapaz</p> <p>8. OLHOS FECHADOS, SUPERFÍCIE DE ESPUMA (PÉS JUNTOS) (<i>Tempo em segundos: _____</i>) (2) Normal: 30 s (1) Moderado: &lt;30 s (0) Grave: Incapaz</p> <p>9. INCLINAÇÃO – OLHOS FECHADOS (<i>Tempo em segundos: _____</i>) (2) Normal: Fica de pé independentemente 30 s e alinha com a gravidade (1) Moderado: Fica de pé independentemente &lt;30 s OU alinha com a superfície (0) Grave: Incapaz de ficar de pé &gt;10 s OU não tenta ficar de pé independentemente</p> <p>10. MUDANÇA NA VELOCIDADE DA MARCHA (2) Normal: Muda a velocidade da marcha significativamente sem desequilíbrio (1) Moderado: Incapaz de mudar velocidade da marcha ou desequilíbrio (0) Grave: Incapaz de atingir mudança significativa da velocidade E sinais de desequilíbrio</p> <p>11. ANDAR COM VIRADAS DE CABEÇA – HORIZONTAL (2) Normal: realiza viradas de cabeça sem mudança na velocidade da marcha e bom equilíbrio (1) Moderado: realiza viradas de cabeça com redução da velocidade da marcha (0) Grave: realiza viradas de cabeça com desequilíbrio</p> <p>12. ANDAR E GIRAR SOBRE O EIXO (2) Normal: Gira com pés próximos, RÁPIDO (<math>\leq 3</math> passos) com bom equilíbrio (1) Moderado: Gira com pés próximos, DEVAGAR (<math>\geq 4</math> passos) com bom equilíbrio (0) Grave: Não consegue girar com pés próximos em qualquer velocidade sem desequilíbrio</p> <p>13. PASSAR SOBRE OBSTÁCULOS (2) Normal: capaz de passar sobre as caixas com mudança mínima na velocidade e com bom equilíbrio (1) Moderado: passa sobre as caixas, porém as toca ou demonstra cautela com redução da velocidade da marcha (0) Grave: não consegue passar sobre as caixas OU hesita OU contorna</p> <p>14. "GET UP &amp; GO" CRONOMETRADO (ITUG) COM DUPLA TAREFA (<i>TUG: _____s; TUG dupla tarefa _____s</i>) (2) Normal: Nenhuma mudança notável entre sentado e de pé na contagem regressiva e nenhuma mudança na velocidade da marcha no TUG (1) Moderado: A tarefa dupla afeta a contagem OU a marcha (0) Grave: Para de contar enquanto anda OU para de andar enquanto conta</p>
-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

1. SENTADO PARA DE PÉ

- (2) Normal: Passa para de pé sem a ajuda das mãos e se estabiliza independentemente  
(1) Moderado: Passa para de pé na primeira tentativa **COM** o uso das mãos  
(0) Grave: Impossível levantar de uma cadeira sem assistência – **OU** – várias tentativas com uso das mãos

2. FICAR NA PONTA DOS PÉS

- (2) Normal: Estável por 3 s com altura máxima  
(1) Moderado: Calcanhares levantados, mas não na amplitude máxima (menor que quando segurando com as mãos) OU instabilidade notável por 3 s  
(0) Grave:  $\leq 3$  s

3. DE PÉ EM UMA PERNA

- |                                                                                                                                                                  |                                                                                                                                                                 |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p><u>Esquerdo</u><br/>Tempo (em segundos) Tentativa 1: ____<br/>Tentativa 2: ____</p> <p>(2) Normal: 20 s<br/>(1) Moderado: &lt;20 s<br/>(0) Grave: Incapaz</p> | <p><u>Direito</u><br/>Tempo (em segundos) Tentativa 1: ____<br/>Tentativa 2: ____</p> <p>(2) Normal: 20 s<br/>(1) Moderado: &lt;20 s<br/>(0) Grave: Incapaz</p> |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|

4. CORREÇÃO COM PASSO COMPENSATÓRIO – PARA FRENTE

- (2) Normal: Recupera independentemente com passo único e amplo (segundo passo para realinhamento é permitido)  
(1) Moderado: Mais de um passo usado para recuperar o equilíbrio  
(0) Nenhum passo, OU cairia se não fosse pego, OU cai espontaneamente


5. CORREÇÃO COM PASSO COMPENSATÓRIO – PARA TRÁS

- (2) Normal: Recupera independentemente com passo único e amplo  
(1) Moderado: Mais de um passo usado para recuperar o equilíbrio  
(0) Grave: Nenhum passo, OU cairia se não fosse pego, OU cai espontaneamente

6. CORREÇÃO COM PASSO COMPENSATÓRIO - LATERAL

- |                                                                                                                                                                                                                         |                                                                                                                                                                                                                        |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p><u>Esquerdo</u><br/>(2) Normal: Recupera independentemente com um passo (cruzado ou lateral permitido)<br/>(1) Moderado: Muitos passos para recuperar o equilíbrio<br/>(0) Grave: Cai, ou não consegue dar passo</p> | <p><u>Direito</u><br/>(2) Normal: Recupera independentemente com um passo (cruzado ou lateral permitido)<br/>(1) Moderado: Muitos passos para recuperar o equilíbrio<br/>(0) Grave: Cai, ou não consegue dar passo</p> |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

## ANEXO C – TERMO DE APROVAÇÃO DO COMITÊ DE ÉTICA EM PESQUISA



### PARECER CONSUBSTANCIADO DO CEP

#### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** ANÁLISE E MODELAGEM DO CONTROLE DO EQUILÍBRIO EM INDIVÍDUOS PÓS-AVC

**Pesquisador:** Elisangela Ferretti Manffra

**Área Temática:**

**Versão:** 1

**CAAE:** 42106815.7.0000.0020

**Instituição Proponente:** Pontifícia Universidade Católica do Parana - PUCPR

**Patrocinador Principal:** MINISTERIO DA CIENCIA, TECNOLOGIA E INOVACAO

#### DADOS DO PARECER

**Número do Parecer:** 991.103

**Data da Relatoria:** 18/03/2015

#### Apresentação do Projeto:


Estudo exploratório baseado em estatísticas e técnicas de Mineração de Dados sobre uma base de dados secundária referente a indivíduos hígidos e pós-AVC. Os dados foram coletados entre julho de 2011 e setembro de 2011 a partir de 38 voluntários (19 adultos pós-AVC e 19 adultos hígidos pareados) no Centro Hospitalar de Reabilitação Ana Carolina Moura Xavier. O procedimento de coleta dos dados primários foi aprovado no CEP sob o parecer nº 319/2011. As etapas deste projeto consistem (i) no pré-processamento dos dados, mais especificamente, no cálculo de determinadas variáveis a partir das séries temporais do movimento do centro de pressão; (ii) na análise descritiva e comparativa das variáveis calculadas; (iii) na análise dos resultados por meio de técnicas de Mineração de Dados, e; (iv) na proposta de modelos teóricos do controle motor e sua comparação os com dados experimentais.

#### Objetivo da Pesquisa:

**Objetivo Primário:**

O objetivo primário desta pesquisa é avaliar a relevância do uso conjunto entre parâmetros posturográficos tradicionais das categorias global e estrutural em comparação com o uso de parâmetros de apenas uma categoria em particular para, com o auxílio de técnicas de Mineração

<b>Endereço:</b> Rua Imaculada Conceição 1155		<b>CEP:</b> 80.215-901
<b>Bairro:</b> Prado Velho		
<b>UF:</b> PR	<b>Município:</b> CURITIBA	
<b>Telefone:</b> (41)3271-2103	<b>Fax:</b> (41)3271-2103	<b>E-mail:</b> nep@pucpr.br



Continuação do Parecer: 991.103

de Dados, diferenciar os perfis de oscilação corporal produzidos por pacientes pós-AVC e indivíduos saudáveis pareados.

**Objetivo Secundário:**

O objetivo secundário desta pesquisa é avaliar o poder individual de descrição de diferentes parâmetros posturográficos tradicionais das categorias global e estrutural para, através de análises estatísticas, diferenciar os perfis de oscilação corporal produzidos (i) por diferentes populações na mesma condição de controle do equilíbrio e (ii) pela mesma população em diferentes condições. As populações avaliadas serão pacientes pós-AVC e indivíduos saudáveis pareados.

**Avaliação dos Riscos e Benefícios:**

**Riscos:**

Uma vez que este projeto envolve a utilização de uma base de dados secundária sem a identificação dos indivíduos, não existem riscos para os voluntários que participaram da coleta da base de dados primária. Também não existe risco de que os resultados sejam utilizados com fins de prejuízo ao acesso a tratamento e/ou planos de saúde, tendo em vista o compromisso assumido pelos pesquisadores de apenas utilizar os dados para fins descritivos e não para tomadas de decisão.

**Benefícios:**

Como benefício científico destaca-se a oportunidade de avaliar o quanto as técnicas de Mineração de Dados podem contribuir para a descrição dos mecanismos fisiológicos que determinam o controle postural de indivíduos pós-AVC. Como benefício científico complementar, tem-se a oportunidade de identificar variáveis com potencial para serem indicadores clínicos de pacientes pós-AVC, os quais podem vir a ser utilizados para avaliar resultados de tratamentos. A partir da identificação de algumas limitações da Mineração de Dados no atendimento dos objetivos será gerada demanda por novas pesquisas na área.

**Comentários e Considerações sobre a Pesquisa:**

PESQUISA COMPLEXA E IMPORTANTE.

**Considerações sobre os Termos de apresentação obrigatória:**

Foi apresentado o projeto de pesquisa, a folha de rosto, o TCUD, e termo de aprovação do comitê de ética em relação ao projeto cujos dados secundários fornecerão subsídios de análise para este projeto.

**Recomendações:**

Nenhuma.

**Endereço:** Rua Imaculada Conceição 1155  
**Bairro:** Prado Velho **CEP:** 80.215-901  
**UF:** PR **Município:** CURITIBA  
**Telefone:** (41)3271-2103 **Fax:** (41)3271-2103 **E-mail:** nep@pucpr.br

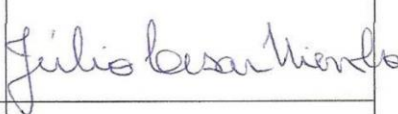
## ANEXO D – TERMO DE COMPROMISSO DE UTILIZAÇÃO DE DADOS

Nós, **Luiz Henrique Franco Giovanini**, **Simone Massaneiro Silva**, **Julio Cesar Nievola** e **Elisangela Ferretti Manffra**, abaixo assinados, pesquisadores envolvidos no projeto de título **ANÁLISE E MODELAGEM DO CONTROLE DO EQUILÍBRIO EM INDIVÍDUOS PÓS-AVC**, nos comprometemos a manter a confidencialidade sobre os dados coletados por Simone Massaneiro Silva (abaixo assinada) para a sua dissertação de mestrado intitulada "**ANÁLISE DO CONTROLE POSTURAL DE INDIVÍDUOS PÓS-ACIDENTE VASCULAR ENCEFÁLICO FRENTE A PERTURBAÇÕES DOS SISTEMAS VISUAL E SOMATOSSENSORIAL**" e apresentada ao Programa de Pós-Graduação em Tecnologia em Saúde (PPGTS) da PUCPR no ano de 2012 sob a orientação da Prof.<sup>a</sup> Dr.<sup>a</sup> Elisangela Ferretti Manffra (abaixo assinada), bem como a privacidade de seus conteúdos, como preconizam os Documentos Internacionais e a Res. 466/12 do Conselho Nacional de Saúde.

Informamos que os dados a serem utilizados dizem respeito à manutenção do equilíbrio postural em indivíduos saudáveis e pós-AVC coletados entre julho de 2011 e setembro de 2011.

Curitiba, ..... de ..... de 2015

Envolvidos na manipulação e coleta dos dados

Nome completo	CPF	Assinatura
<b>Luiz Henrique Franco Giovanini</b>	063.041.129-80	
Simone Massaneiro Silva	010.336.149-98	
Julio Cesar Nievola	463.009.889-53	
Elisangela Ferretti Manffra	874.269.009-91	