



CLASSIFICAÇÃO DE MARCHA HUMANA VIA TRANSFORMADA WAVELET USANDO SMARTPHONES.

**Trabalho de Conclusão de Curso
Engenharia da Computação**

Nome do Aluno: Vinícius de Souza Cipriano

Orientador: DIEGO JOSE RÁTIVA MILLÁN



**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

VINICIUS DE SOUZA CIPRIANO

**CLASSIFICAÇÃO DE MARCHA HUMANA VIA
TRANSFORMADA WAVELET USANDO
SMARTPHONES.**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, novembro de 2014.

De acordo

Recife

____/____/____

Orientador da Monografia

(Na versão final esta página deve ser substituída pela folha de aprovação digitalizada.)

*Dedico este trabalho ao
meus pais, Valdeon e
Célia e à Deus.*

Agradecimentos

Gostaria de agradecer primeiramente a Deus pela força de vontade que tive durante esses 5 anos. Aos meus pais e demais familiares por estarem sempre comigo, mesmo nos momentos difíceis, e me deram forças para seguir em frente.

Aos amigos que fiz durante esse período da minha vida e que com certeza levarei para o resto da vida.

Um agradecimento especial ao Professor **Diego Rátiva** e seu aluno de mestrado **Rafael Caldas** por me darem a oportunidade de realizar este trabalho e de me fornecer toda a base de conhecimento necessária para a realização do mesmo.

Resumo

Transformadas wavelets são funções capazes de descrever e reproduzir um sinal de maneira eficiente em diferentes níveis de detalhamento, devido à sua capacidade de decompor os sinais temporais tanto no domínio da frequência quanto no domínio do tempo. As funções wavelet são ferramentas poderosas de processamento de sinais, aplicadas na compressão de dados, eliminação de ruído, separação de componentes no sinal, identificação de singularidades, detecção de auto-similaridade, entre outras. As redes neurais artificiais (RNAs) são uma técnica de inteligência computacional empregada em problemas de classificação de padrões, previsão financeira, detecção de anomalias, entre outros. A intenção deste trabalho é apresentar a combinação de extração de características via transformada Wavelet e redes neurais artificiais como um método para classificação de movimentos corporais através da identificação de padrões em sinais temporais, tendo em vista um potencial de utilização nas áreas de fisioterapia e reabilitação de pacientes com algum tipo de deficiência motora. O uso dessa combinação trouxe sucesso na classificação dos padrões de marcha adotados de maneira aceitável, encontrando características marcantes para cada tipo de sinal estudado.

Abstract

Wavelets transforms are functions capable of describing and reproducing a signal effectively at different levels , due to its ability to decompose the temporal signals in both frequency domain and time domain. The wavelet functions are powerful tools, applied signal processing in data compression, noise elimination, separation of components in the signal identification of singularities-similarity detection, among others. Artificial neural networks (Anns) are a computational intelligence technique employed in pattern classification problems, financial forecasting, detection of anomalies, among others. The intention of this paper is to present the combination of characteristics extraction via Wavelet transform and artificial neural networks as a method for classification of body movements through the identification of patterns in temporal signals, with a view to a potential use in the fields of physical therapy and rehabilitation of patients with motor disabilities. Using this combination brought success in the classification of gait patterns adopted from acceptable way, finding salient features for each signal type studied.

Sumário

Capítulo 1 INTRODUÇÃO	1
1.1 Motivação	1
1.2 Objetivos	2
1.2.1 Objetivo principal	2
1.2.2 Objetivos secundários	2
Capítulo 2 ESTADO DA ARTE	3
2.1 Transformada wavelet	3
2.1.1 Análise de Fourier versus análise por wavelets	4
2.1.2 CWT (<i>Continuous Wavelets Transform</i>)	5
2.1.3 DWT (<i>Discrete Wavelet Transform</i>)	5
2.1.4 Propriedades básicas da transformada wavelet	6
2.2 A wavelet de Haar	8
2.2.1 Cálculo rápido dos coeficientes de wavelets na base de Haar.	9
2.3 Wavelet Biortogonal	10
2.4 Wavelet Daubechies	11
2.5 A wavelet de Symlets	12
2.6 A wavelet de Coiflets	13
2.7 A wavelet de Meyer	13
2.8 Decomposição do sinal	14
2.8.1 Algoritmo de filtragem	14
2.9 Reconstrução do sinal	16
2.10 Sensores Inerciais de um Smartphone	16
2.10.1 Acelerômetro	17

2.10.2	Giróscopio	17
2.10.3	Acesso aos sensores do smartphone	18
2.11	Redes Neurais Artificiais	18
2.11.1	Função de ativação	20
2.11.2	Arquitetura MLP	21
2.11.3	Algoritmo de treinamento: <i>BackPropagation</i>	22
2.11.4	Validação cruzada	23
Capítulo 3	Metodologia	25
3.1	Desenvolvimento do aplicativo	25
3.2	Construção da base de dados	25
3.3	Aplicação de análise wavelet para sinais de acelerômetro	27
3.4	Classificação com RNA.	30
Capítulo 4		32
Resultados		32
Capítulo 5		37
Considerações Finais		37
Bibliografia		39

Índice de Figuras

Figura 1. Transformada de wavelets proporciona uma representação em tempo e escala.	5
Figura 2. Efeito do fator de escala “a” na função senoidal.	7
Figura 3. Translação de uma wavelet em k unidades	7
Figura 4. Espaço tridimensional das amplitudes dos coeficientes wavelets em cada nível de resolução e tempo de deslocação.	8
Figura 5. A função escala, φ , associada a wavelet de Haar.....	9
Figura 6. Algoritmo cascata para cálculo de wavelets.....	10
Figura 7. Algoritmo em cascata para reconstrução da função a partir dos seus coeficientes.	10
Figura 8. Função wavelet ψ de tipo biortogonal	11
Figura 9. Função Wavelet ψ de tipo Daubechies	12
Figura 10. Wavelet ψ de tipo Symlets	12
Figura 11. Função wavelet ψ de tipo Coiflets.	13
Figura 12. Wavelet ψ de tipo Meyer	13
Figura 13. Processo de decomposição e reconstrução.....	14
Figura 14. Processo de decomposição do sinal.	15
Figura 15. Reconstrução do sinal via coeficiente de wavelets.....	16
Figura 16. Chip responsável por simular um acelerômetro no smartphone	17
Figura 17. Eixos de rotação do aparelho.....	17
Figura 18. Diagrama de funcionamento de uma RNA com aprendizado supervisionado	19
Figura 19. Aprendizado não-supervisionado.	19
Figura 20. Estrutura de uma rede MLP	22
Figura 21. Posicionamento do smartphone durante experimentos.....	26

Figura 22.	Exemplo de sinal do eixo X para marcha Parkinsoniana.....	28
Figura 23.	Exemplo de sinal do eixo Y para marcha Parkinsoniana.....	28
Figura 24.	Exemplo de sinal no eixo Z para marcha Parkinsoniana.....	29
Figura 25.	Sinal para marcha Parkinsoniana.....	32
Figura 26.	Evolução do erro no treinamento da RNA.....	36

Índice de Tabelas

Tabela 1. Definição de algumas funções de ativação.....	23
Tabela 2. Tipos de Marcha utilizados no experimento.....	30
Tabela 3. Família de wavelets utilizadas no experimento.....	34
Tabela 4. Resultados para marcha Normal.....	37
Tabela 5. Resultados para marcha Ceifante	37
Tabela 6. Resultados para marcha Claudicante	38
Tabela 7. Resultados para marcha Talonante	38
Tabela 8. Resultados para marcha Parkinsoniana	38
Tabela 9. Média Geral dos resultados	39

Tabela de Símbolos e Siglas

AVC – Acidente Vascular Cerebral

CWT – *Continuous Wavelet Transform* (Transformada Wavelet Contínua)

DWT – *Discrete Wavelet Transform* (Transformada Wavelet Discreta)

EMQ – Erro Médio Quadrático

RNA – Redes Neurais Artificiais

TF – Transformada de Fourier

TJF – Transformada por Janela de Fourier

XML - *eXtensible Markup Language*

Capítulo 1

INTRODUÇÃO

1.1 Motivação

O reconhecimento de movimentos humanos é uma parte importante na área de aprendizado de máquina devido a muitas aplicações do mundo real. Os meios para avaliação da mobilidade de pacientes ainda são limitados. Avaliações clínicas na maioria das vezes requerem que o paciente se desloque para um local especializado e esse deslocamento muitas vezes é caro e em alguns casos nem é possível [1].

Os celulares das novas gerações são equipados com uma variedade de sensores como GPS, microfones, câmeras, sensores luminosos, de proximidade, acelerômetros, giroscópios [2]. Eles possuem sua própria fonte de energia, alta capacidade de armazenamento e são capazes de transmitir dados de maneira remota. Já existem vários estudos que mostram as vantagens de se colocar sensores em partes específicas do corpo de forma a conseguir sinais mais consistentes para cada indivíduo [3].

Em qualquer problema de classificação ou reconhecimento de padrões, a escolha de características deve ser feita de maneira cuidadosa a fim de se obter melhores resultados e reduzir o custo computacional do processo. A transformada **wavelet** é uma técnica de decomposição com considerável vantagem em relação as técnicas de baseadas em Fourier porque utiliza-se de famílias de funções que possuem diferentes características que se adequam melhor a cada tipo de sinal temporal, enquanto que Fourier utiliza-se como base aproximações utilizando senos e cossenos.

Diante desse cenário a combinação de Wavelet e redes neurais artificiais é uma importante ferramenta que é muito usada em problemas de classificação [4] e especialmente neste trabalho vai contribuir com um novo método que auxilie os

pacientes com algum tipo de deficiência motora através do posicionamento de um simples smartphone na parte do corpo analisada.

1.2 Objetivos

1.2.1 Objetivo principal

Analisar o desempenho dos mais diversos tipos de transformada wavelets na extração de coeficientes de um sinal gerado com valores extraídos de um acelerômetro de um smartphone e na posterior reconstrução do sinal de modo a obter a maior taxa de acerto possível, apresentando assim uma maior fidelidade ao sinal original.

1.2.2 Objetivos secundários

Para a completa execução do trabalho e com o intuito de atingir o objetivo principal deste trabalho, os seguintes objetivos secundários foram determinados:

- Implementar um aplicativo em plataforma Android que consiste em utilizar os próprios sensores contidos no smartphone para a realização de experimentos de movimentação de membros e registrar esses valores para formar uma base de dados consistente;
- Treinar uma rede neural para que o método proposto apresente uma nova maneira para classificar uma série de movimentos de marcha humana.

Capítulo 2

ESTADO DA ARTE

2.1 Transformada wavelet

Embora a primeira menção às *wavelets* tenha acontecido em 1909, por A. Haar [5], as *wavelets* de Haar ficaram sendo a única base de *wavelets* conhecida até 1985. O trabalho de Mallat foi de grande importância para o ramo e baseado nos seus resultados Yves Meyer chegou a uma família de *wavelets*, que ganhou o seu nome. Ao contrário do que ocorre com a *wavelet* de Haar, a *wavelet* de Meyer são diferenciáveis. Quando, Ingrid Daubechies usou toda a base de conhecimento descoberta até então para construir um conjunto de *wavelets* suaves que se tornariam a base das aplicações atuais das *wavelets*.

As transformadas de *wavelets* têm como principal alicerce um mecanismo de decomposição de sinais em diferentes domínios de frequências, na qual cada componente possui uma escala específica. Além disso, na análise de *wavelets*, é possível obter dados de sinais descontínuos.

O princípio básico de *wavelets* é que elas podem distinguir as características de um sinal em diferentes escalas e em diferentes níveis de detalhamento como podemos ver na Figura 1. Sendo assim, elas cobrem toda a região na qual o sinal é amostrado. As transformadas de *wavelet* são ferramentas de cálculo utilizadas para decompor funções, sejam elas imagens, sinais ou uma superfície qualquer, apresentado desde os menores detalhes até o sinal em um âmbito mais geral. A escolha adequada de uma transformada *wavelet* para um conjunto de dados facilita tanto a decomposição, quanto a compressão de informações.

Por causa de suas propriedades únicas, existem inúmeras aplicações onde o uso de transformadas *wavelet* é indicado, tais como: Compressão de dados, reconhecimento de padrões, processamento de imagens, problemas no campo da geometria, física [6], entre tantas outras alternativas.

A transformada wavelet tem qualidades que a tornam especialmente útil para para séries temporais, exibindo características que podem variar tanto em tempo como em frequência.

2.1.1 Análise de Fourier versus análise por wavelets

Antes de se tentar estudar a fundo os conceitos que se baseia a transformada wavelet, deve-se entender que existem formas mais simples de se representar sinais contínuos no tempo ou na frequência. Aplicando a análise de Fourier em um dado sinal é possível, obter informações que não são facilmente encontradas no domínio do tempo. Esta análise pode ser aplicada a sinais não estacionários, desde que, somente se esteja interessado em saber suas componentes no domínio da frequência.

A transformada de Fourier apenas trabalha com o conteúdo espectral do sinal, e não fornece informações sobre o que ocorre no domínio do tempo. Em diversas aplicações, a componente tempo é essencial na análise de certos comportamentos que ocorrem em dados intervalos, ou seja, para essa análise a transformada de Fourier já não é a mais indicada. Uma alternativa é a aplicação da chamada transformada por Janelas de Fourier (TPJF), que é uma generalização da TF.

Na maioria dos casos do mundo real as séries, como séries econômicas e financeiras, exibem certos comportamentos que a TF ou TPJF não é capaz de analisar de maneira eficiente devido ao fato da janela possuir um tamanho fixo, com isso uma função finita no domínio do tempo não é bem representada. Assim, a transformada de wavelet surge como uma ferramenta muito útil para analisar estas séries não estacionárias, dado que suas propriedades são indicadas na análise de muitas séries econômicas e financeiras.



Figura 1. Transformada de wavelets proporciona uma representação em tempo e escala.

Fonte: [<http://www.dbd.puc-rio.br/>]

2.1.2 CWT (Continuous Wavelets Transform)

A seguinte equação expressa a CWT:

$$TCW^f(a, b) = \int f(t)\psi_{j,k}(t)dt. \quad (1)$$

A função $\psi_{j,k}(t)$ é uma família de funções que são derivadas de uma única função $\psi(t)$, chamada wavelet mãe. Qualquer wavelet mãe tem de satisfazer a propriedade que garante a sua convergência no domínio dos número reais (\mathcal{R}) como expresso a seguir:

$$C_\psi = \int_{\mathcal{R}} \frac{|\psi(w)|^2}{|w|} dw < \infty, \quad (2)$$

onde $\psi(w)$ é a transformada de Fourier de $\psi(t)$. Isto implica que:

$$\int \psi(t)dt = \psi(0) = 0. \quad (3)$$

2.1.3 DWT (Discrete Wavelet Transform)

Caracteriza-se por uma transformada wavelet em que o sinal é amostrado de maneira discreta.

Dado que,

$$\|f\|_p = \left(\int_{-\infty}^{\infty} |f(x)|^p dx \right)^{\frac{1}{p}} < \infty, \quad (4)$$

onde para o caso particular em $p = 2$ define-se o produto interno de duas funções f e g como, $\langle f, g \rangle = \int_{-\infty}^{\infty} f(x)\overline{g(x)} dx$, onde a barra representa o complexo conjugado. Um conjunto de definições mostra as propriedades que precisam ser satisfeita na utilização de DWT.

Definição 1: Diz-se que uma função f tem suporte compacto, se existe um intervalo fechado e limitado, fora do qual $f(x)=0$.

Definição 2: Uma wavelet é uma função $\psi(x)$, tal que a família de funções pode ser derivada aplicando a equação 5.

$$\psi_{j,k}(x) = 2^{-j/2}\psi(2^{-j}x - k) \quad (5)$$

Onde j e k são inteiros arbitrários.

2.1.4 Propriedades básicas da transformada wavelet

Nesta seção são apresentadas as propriedades básicas da transformada wavelet.

- **Resolução de identidade**

Quando a condição de admissibilidade é satisfeita, é possível achar a transformada inversa. Assim, uma dada função pode ser reconstruída de sua transformação de wavelets.

$$f(t) = \frac{1}{C_\psi} \iint_{-\infty}^{\infty} TWC_f(a, b)\psi_{a,b}(t) \frac{da db}{a^2} \quad (6)$$

em que “ a ” é o fator de escala da função e o valor de “ b ” indica a magnitude da translação da função.

- **Escalonamento**

Escalonamento de uma wavelet significa estender ou recolher uma wavelet, de acordo com um fator de escala “a” como mostrado pela Figura 3.

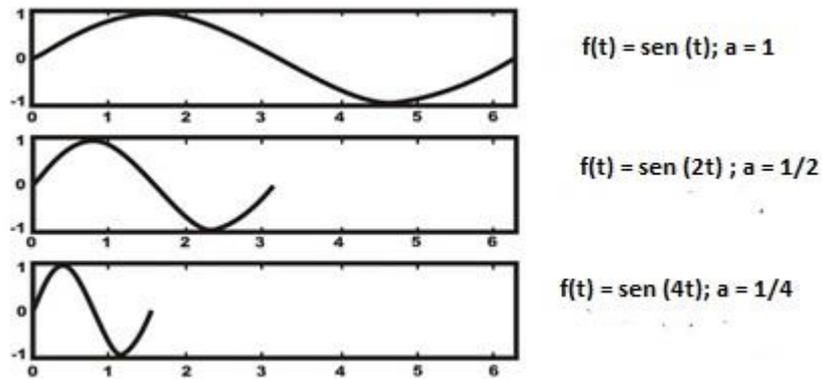


Figura 2. Efeito do fator de escala “a” na função senoidal.

Fonte: [<http://www.dbd.puc-rio.br/>]

É possível notar que o fator de escala é diretamente proporcional ao quão alongado ou comprimido é o sinal.

- **Translação**

Tem o mesmo significado de deslocamento e matematicamente pode ser descrito por $\psi(t - k)$. A Figura 3 apresenta um exemplo de deslocamento no eixo x de acordo com o valor de “k”.

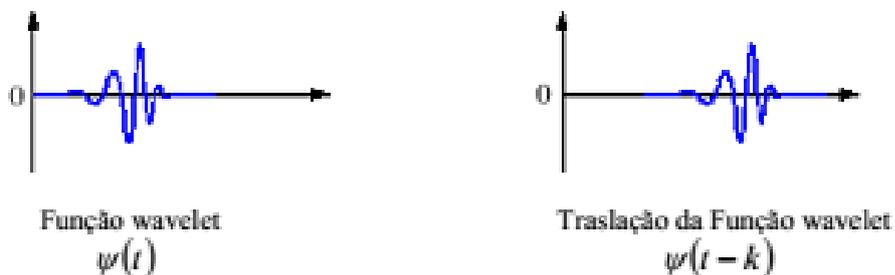


Figura 3. Translação de uma wavelet em k unidades

Fonte: [<http://www.dbd.puc-rio.br/>]

A propriedades de translação e deslocamento são essenciais para descrever o comportamento de sinais em três dimensões, como se mostra na Figura 4, cujos as variáveis “ k ” e “ j ” representam o parâmetro de translação e o parâmetro de deslocamento respectivamente.

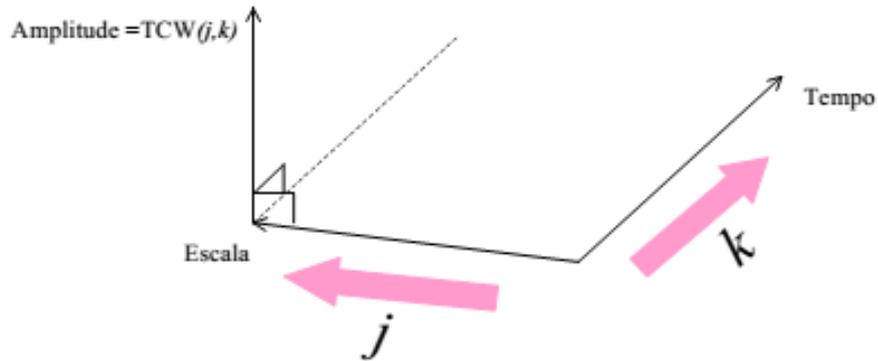


Figura 4. Espaço tridimensional das amplitudes dos coeficientes wavelets em cada nível de resolução e tempo de deslocação.

Fonte: [<http://www.dbd.puc-rio.br/>]

Há uma grande variedade de famílias de transformada wavelet que podem ser utilizadas em aplicações do mundo real, e neste capítulo serão apresentadas as 6 famílias de wavelets que foram utilizadas neste trabalho.

2.2 A wavelet de Haar

A wavelet de Haar segue os princípios da função degrau, como mostrado em (7).

$$\begin{cases} 1, & \text{se } x \in \left[0, \frac{1}{2}\right); \\ -1, & \text{se } x \in \left[\frac{1}{2}, 1\right); \\ 0, & \text{caso contrário.} \end{cases} \quad (7)$$

As seguintes regras se aplicam a família de wavelets de haar.

1. O conjunto $\{\psi_{m,n}\}$ é um conjunto ortonormal, ou seja, $\langle \psi_{j,k}, \psi_{j',k'} \rangle = \delta_{j,j'}, \delta_{k,k'}$, onde $\delta_{m,n} = 1$ se $m = n$ e 0, caso contrário.
2. Toda função $f \in L^1(\mathbb{R})$ pode ser arbitrariamente aproximada por uma combinação linear finita de $\psi_{m,n}$.

A função

$$\varphi(x) = \begin{cases} 1, & 0 \leq x < 1 \\ 0, & \text{caso contrário} \end{cases} \quad (8)$$

desempenha um papel muito importante no que se segue, seu gráfico aparece na Figura 5, ela é denominada **função escala** associada a wavelet de Haar.

Das definições de φ e ψ , temos as seguintes relações de escala:

$$\varphi(x) = \varphi(2x) + \varphi(2x - 1), \quad (9)$$

$$\psi(x) = \varphi(2x) - \varphi(2x - 1). \quad (10)$$

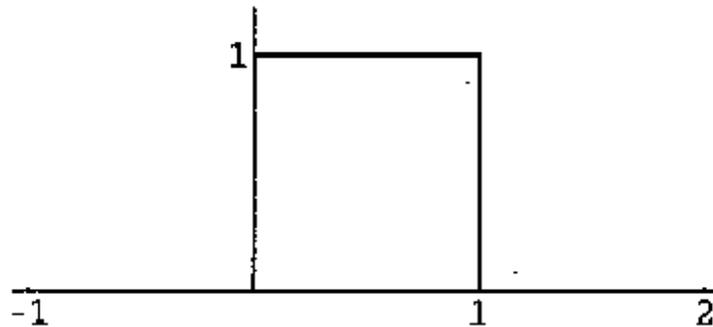


Figura 5. A função escala, φ , associada a wavelet de Haar.

Fonte: [<http://matematicauniversitaria.ime.usp.br/>]

2.2.1 Cálculo rápido dos coeficientes de wavelets na base de Haar.

Tem-se graficamente, expresso pela Figura 6, o seguinte algoritmo em cascata para calcular os coeficientes de wavelets $\{d_{j,n}\}$:

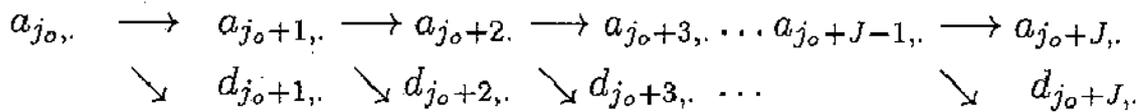


Figura 6. Algoritmo cascata para cálculo de wavelets.

Fonte: [<http://matematicauniversitaria.ime.usp.br/>]

Em termos gerais para cálculos de wavelets temos as seguintes equações:

$$a_{j,n} = \sum_k \bar{h}_k a_{j-1,2n+k} \quad (11)$$

$$d_{j,n} = \sum_k \bar{g}_k a_{j-1,2n+k} \quad (12)$$

O algoritmo para cálculo de coeficientes vale para qualquer tipo de wavelet, onde a passagem de $j-1$ para j é feita através das equações (11) e (12), dado que os coeficientes h_k e g_k são em geral reais

A partir das equações (11) e (12), chegamos no algoritmo, expresso pela Figura 7, para reconstruir f , ou seja $\{a_{j_0,k}\}_k$, a partir de seus coeficientes $\mathbf{a}_{j,n}$ e $\mathbf{d}_{j,n}$.

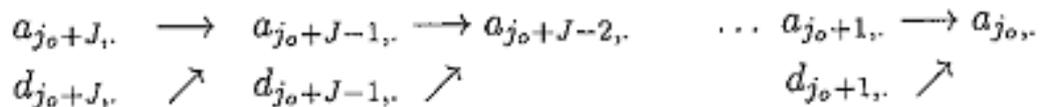


Figura 7. Algoritmo em cascata para reconstrução da função a partir dos seus coeficientes.

Fonte: [<http://matematicauniversitaria.ime.usp.br/>]

Concluimos que para uma wavelet geral temos a seguinte equação:

$$a_{j-1,n} = \sum_k \overline{h_{n-2k}} a_{j,k} + \sum_k \overline{g_{n-2k}} d_{j,k} \quad (13)$$

2.3 Wavelet Biortogonal

Esta família apresenta a propriedade da linearidade e tem esse nome porque usa duas wavelets, uma para a decomposição e outra para a reconstrução, em lugar

de uma só. A Figura 8 mostra exemplos de famílias wavelets biortogonais, sempre expressa em pares.

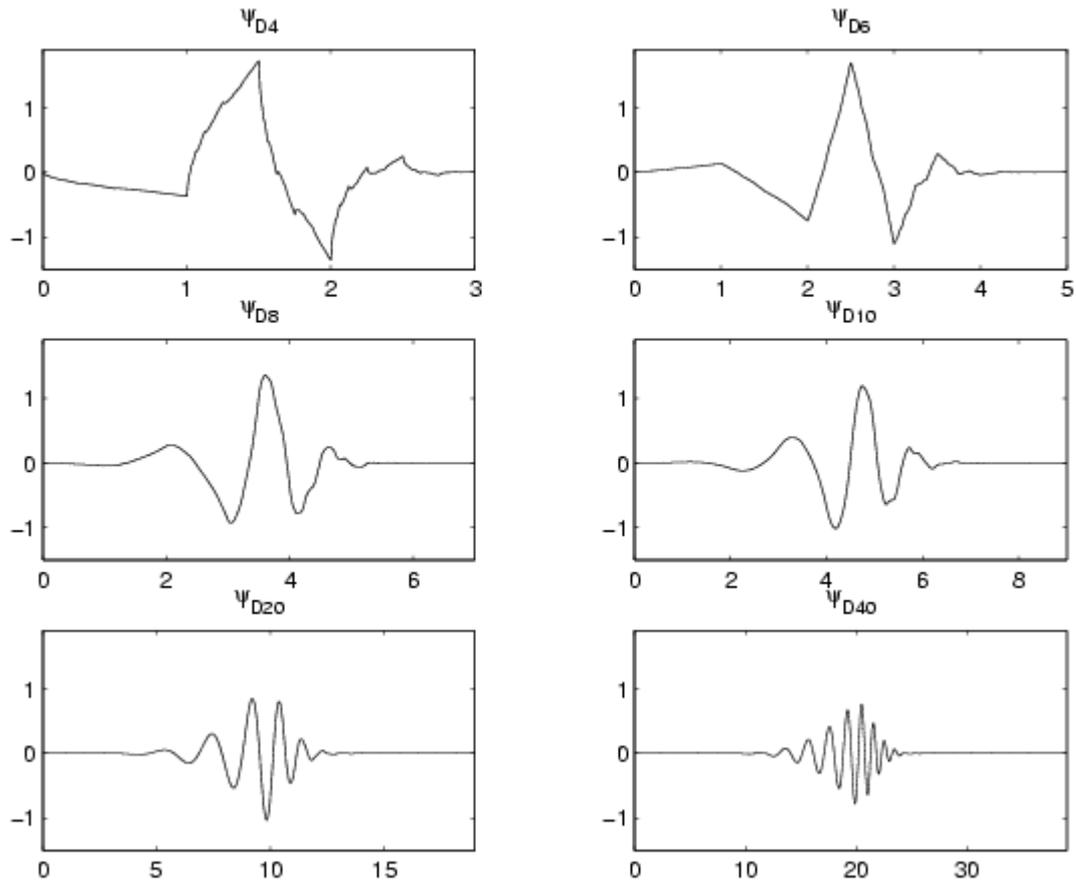


Figura 8. Função wavelet ψ de tipo biortogonal

Fonte: [<http://www.math.cornell.edu/>]

2.4 Wavelet Daubechies

As wavelets Daubechies são baseadas no trabalho de Ingrid Daubechies [7]. Existem vários tipos de wavelets Daubechies, mas todas são bem similares.

Elas são compactas no domínio do tempo, apresentando como maior vantagem a ortogonalidade, ou seja, um erro no sinal de entrada não se propaga e a estabilidade da reconstrução é assegurada. Na figura 9 tem-se as famílias de funções wavelet, que são representadas pela sua abreviação 'db' seguida do número que representa quantas vezes a curva passa pelo 0 no eixo x.

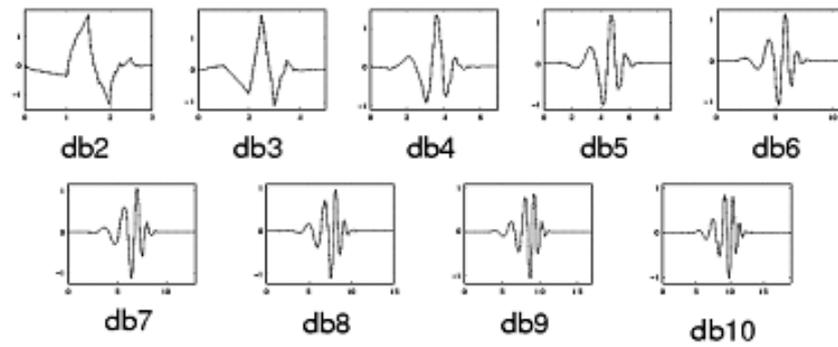


Figura 9. Função Wavelet ψ de tipo Daubechies

Fonte : [<http://matematicauniversitaria.ime.usp.br/>]

2.5 A wavelet de Symlets

Este tipo de *wavelet* foi proposto por Daubechies como uma modificação à família original da wavelets Daubechies, que possuem propriedades similares, e tendem a ser simétricas, pela representação vista na Figura 10, nota-se que .

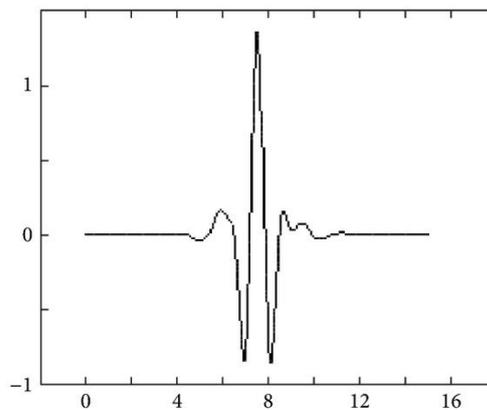


Figura 10. Wavelet ψ de tipo Symlets

Fonte: [<http://matematicauniversitaria.ime.usp.br/>]

2.6 A wavelet de Coiflets

Este tipo de *wavelet* foi também proposta por Daubechies possuindo uma simetria quase que completa. A figura 11 mostra as principais famílias wavelet utilizadas.

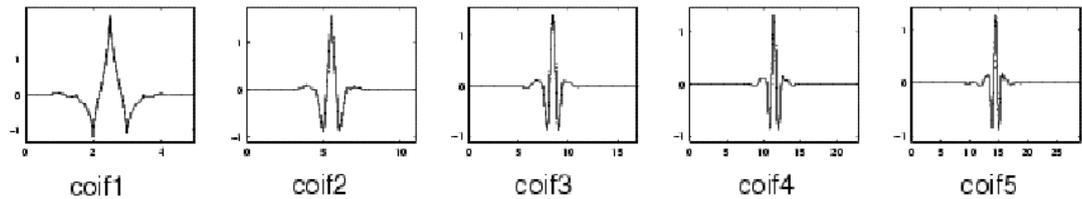


Figura 11. Função wavelet ψ de tipo Coiflets.

Fonte:[<http://www.mathworks.com>]

2.7 A wavelet de Meyer

Yves Meyer utilizou técnicas da transformada de Fourier para derivar os coeficientes de uma equação que possui dois fatores de escala.

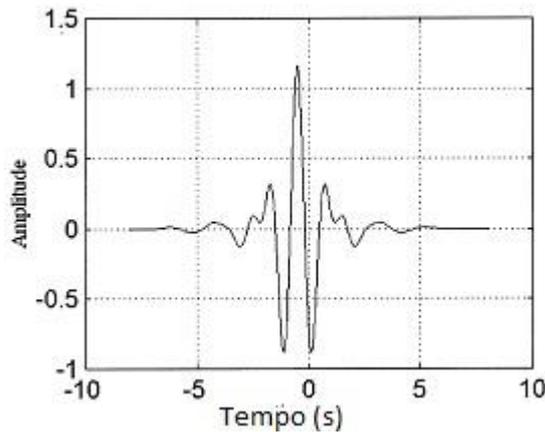


Figura 12. Wavelet ψ de tipo Meyer

Fonte:[<http://www.bssaonline.org/>]

2.8 Decomposição do sinal

É usando filtros que os dados são separados em componentes para cada frequência. A partir de funções matemáticas, é possível representar cada coeficiente em sua respectiva escala.

A escolha do filtro é de extrema importância para se obter uma maior taxa de acerto durante a reconstrução do sinal original. Essa reconstrução é plenamente possível dependendo do tipo do sinal a ser reconstruído, do filtro utilizado e dos componentes gerados. A escolha adequada de filtros durante as fases de decomposição e reconstrução podem minimizar os efeitos de *aliasing*, que consiste em um efeito que tornam um conjunto de amostras de sinais indistinguíveis entre si.

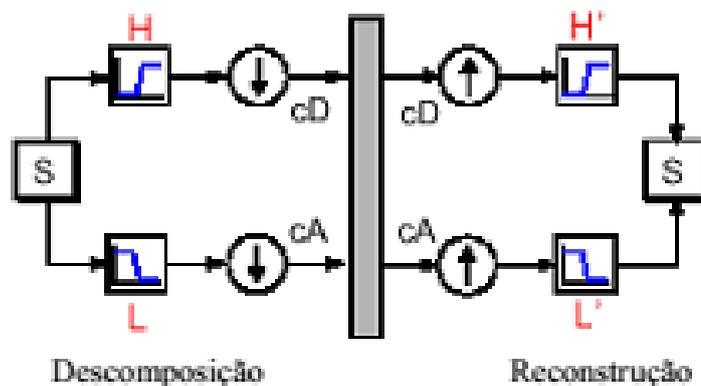


Figura 13. Processo de decomposição e reconstrução.

Fonte: [www.dbd.puc-rio.br]

Dois tipos de filtros (Passa-baixa – L e Passa-Alta - H), são responsáveis na reconstrução do sinal L' e H' e são chamados de filtros de quadratura.

Filtros escolhidos corretamente não só permitem uma reconstrução quase que perfeita, como também representam qual a transformada *wavelet* foi utilizada para a análise do sinal. Em outras palavras, a escolha é feita através do tipo de transformada e não do filtro em si.

2.8.1 Algoritmo de filtragem

Para cada iteração do algoritmo são necessários três dados de entrada. São eles:

1. O vetor de entrada (sinal);

2. O filtro *wavelets* do tipo mãe $h(k)$;
3. O filtro de escala.

Para o j -ésimo passo, o cálculo dos coeficientes $a_{j-1,k}$ do nível $j-1$, dado por:

$$a_{j,k} = \sum_n l(n - 2k)a_{j-1,n} \quad (14)$$

$$d_{j,k} = \sum_n h(n - 2k)a_{j-1,n} \quad (15)$$

A aplicação das transformadas *wavelets* é o mesmo que aplicar um processo de filtragem sendo que o número de coeficientes para $a_{j,k}$ que está em um certo nível j ., será a metade do número de coeficientes $a_{j-1,k}$ do nível $j-1$.

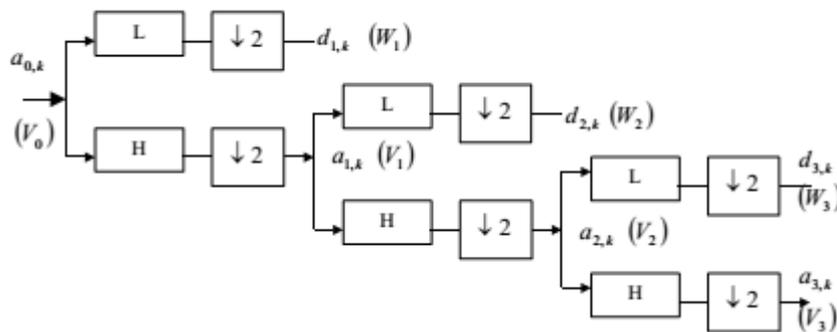


Figura 14. Processo de decomposição do sinal.

Fonte: [www.dbd.puc-rio.br]

Os coeficientes V_i são chamados coeficientes de aproximação e os coeficientes W_i são chamados de coeficientes de detalhes, o procedimento vai sendo aplicado até o nível desejado

O sinal original foi subdividido em diversos sinais com bandas diferentes onde cada coeficiente possui uma frequência única, podendo ser analisada da maneira mais conveniente ao objetivo que se deseja [8].

2.9 Reconstrução do sinal

A principal aplicação da transformada de wavelets é a de ser usada para analisar ou decompor sinais, levando em conta o mínimo de perda de informações possível.

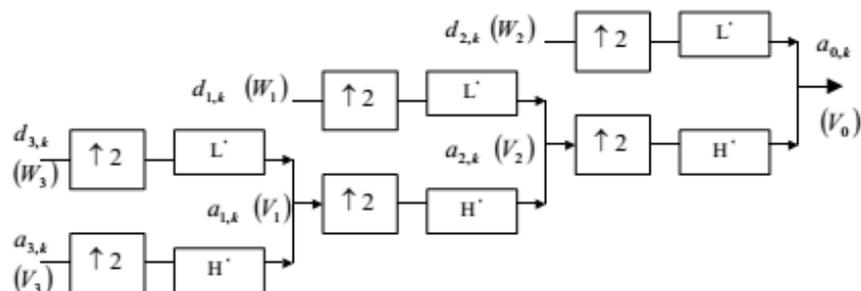


Figura 15. Reconstrução do sinal via coeficiente de wavelets

Fonte: [www.dbd.puc-rio.br]

A reconstrução do sinal é feita a partir dos coeficientes wavelets e assim como no caso de decomposição o procedimento se repete até obter o sinal reconstruído.

2.10 Sensores Inerciais de um Smartphone

Denomina-se comumente um sensor como sendo um dispositivo elétrico, eletrônico, mecânico ou biológico, capaz de responder a um determinado estímulo de natureza física, com isso, uma nova gama de possibilidades pode ser oferecida no quesito de interação usuário-dispositivo.

Esses sensores são eficazes em situações em que seja necessária uma monitoração de movimentação tridimensional do aparelho, seu posicionamento, ou até mudanças ambientais que ele possa vir a sofrer. Um exemplo disso é o uso desses sensores para classificação de posturas e movimentos corporais [9].

A maioria dos smartphones modernos são capazes de perceber e identificar dados com precisão e exatidão, e responder a informações acerca de aplicativos no aparelho que acaba facilitando o seu uso. Os principais sensores presentes em smartphones da nova geração são:

2.10.1 Acelerômetro

É um pequeno chip que tem como principal função medir as oscilações, localizado na placa de circuitos principal de um smartphone, como visto na Figura 16. Três tubos contendo molas simulam as três coordenadas tridimensionais, que permitem que o aparelho perceba seu posicionamento no espaço.

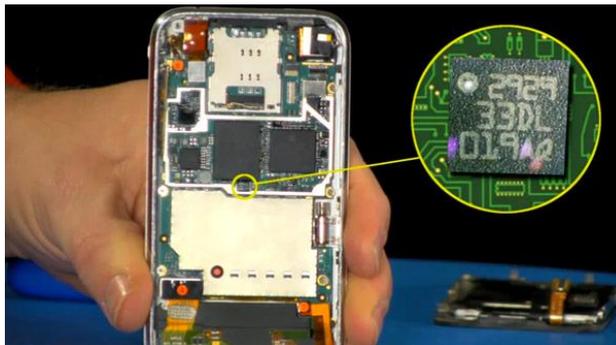


Figura 16. Chip responsável por simular um acelerômetro no smartphone

Fonte: [<http://www.omicrono.com/>]

2.10.2 Giróscopio

Outro sensor capaz de informar sobre a posição física do aparelho e possuem propriedades que permitem que ele possa monitorar e controlar a posição do aparelho, orientação, direção, movimento angular e rotação. A figura 17 indica os seus eixos de rotação.

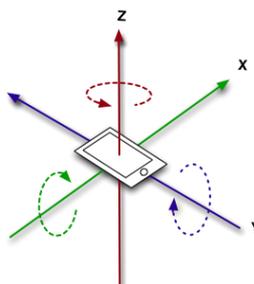


Figura 17. Eixos de rotação do aparelho

Fonte: [<http://www.commandfusion.com/>]

2.10.3 Acesso aos sensores do smartphone

O acesso aos sensores de um smartphone é feito através da classe *SensorManager*, sendo que através dela é possível registrar um *listener* que será responsável por gerar e tratar os dados do sensor. Para se obter uma instância da classe *SensorManager* [10] é feita uma chamada ao método *getSystemService* (*service_name*) da classe *Context*. A calibração dos sensores é feita pelas constantes inteiras da própria classe, que são:

- **SENSOR_STATUS_ACCURACY_HIGH**: A informação do sensor é tratada com o máximo de precisão;
- **SENSOR_STATUS_ACCURACY_LOW**: A informação do sensor é tratada com baixa precisão, sendo necessário uma calibração anterior de acordo com o ambiente;
- **SENSOR_STATUS_ACCURACY_MEDIUM**: A informação do sensor não é confiável e uma calibração pode melhorar os resultados;
- **SENSOR_STATUS_ACCURACY_UNRELIABLE**: A informação do sensor não é confiável;

2.11 Redes Neurais Artificiais

O cérebro humano tem uma capacidade enorme para o processamento de informações que ainda não foi totalmente explorado. A sua unidade primária chamada neurônio é responsável por formar uma intensa rede capaz de realizar aproximadamente 60 trilhões de ligações sinápticas [11].

Baseado no funcionamento das redes neurais do cérebro humano as redes neurais artificiais (RNA), ou simplesmente redes neurais são modelos compostos por um conjunto de neurônios artificiais interligados entre si. Cada ligação possui um peso associado, que determina a força e o significado da conexão [12].

Esse tipo de modelo possui a capacidade de aprendizado, feita através do ajuste dos pesos das interconexões dos neurônios a cada exemplo de treinamento apresentado ou ao final da apresentação de todos os exemplos. O treinamento das

RNA é feito através de épocas ou ciclos, em que uma época é concluída após o último registro do conjunto de dados de treinamento ser apresentado a rede. As principais técnicas de aprendizado são:

- **Aprendizado supervisionado:** Como a Figura 18 indica esse tipo de aprendizado caracteriza-se quando são apresentadas as respostas esperadas para os seus respectivos valores de entrada, de modo que a rede possa verificar a magnitude do erro e posteriormente realizar o ajuste dos pesos das interconexões;

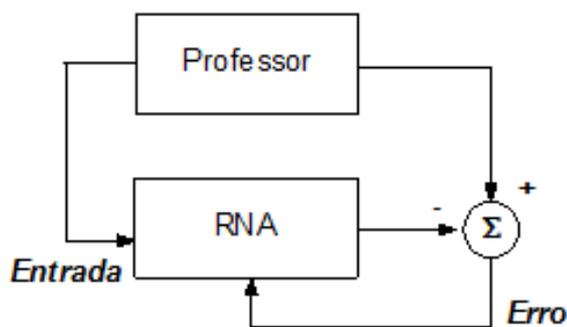


Figura 18. Diagrama de funcionamento de uma RNA com aprendizado supervisionado

Fonte: [<http://novos-cientistas.blogspot.com.br/2012/05/redes-neurais.html>]

- **Aprendizado não supervisionado:** Este tipo de aprendizado, como visto na Figura 19, caracteriza-se quando a rede não recebe as saídas esperadas e é capaz de aprender apenas com os parâmetros passados como entrada.



Figura 19. Aprendizado não-supervisionado.

- **Aprendizado com reforço:** Utiliza-se a opinião de um especialista para avaliar se a resposta foi correta ou não, em caso negativo os pesos serão ajustados. O especialista não informa o valor da saída esperada e sim o quanto está errada a resposta.

2.11.1 Função de ativação

As funções de ativação mais utilizadas na prática são a função sigmoide logística e a função tangente hiperbólica, dependendo das características dos dados de entrada. Entretanto, existem outros estudos que mostram a importância de outras funções de ativação no aprendizado da rede, como por exemplo Hornik [13] que utilizou funções de ativação não-polinomiais ou Gomes e Ludermir [14] que utilizaram as funções com log-log e probit para mostrar que quando os dados seguem uma distribuição binomial com características deste tipo de complemento, o uso da sigmoide logística na modelagem da rede é inadequado.

A Tabela 1 mostra a definição de algumas funções de ativação e seus intervalos de uso.

Função	Definição	Intervalo
Identidade	x	$(-\infty, \infty)$
Sigmoide logística	$\frac{1}{1 + e^{-x}}$	$(0, +1)$
Tangente hiperbólica	$\frac{1 - e^{-x}}{1 + e^{-x}}$	$(-1, +1)$
Exponencial negativa	e^{-x}	$(0, \infty)$
Softmax	$\frac{e^{-x}}{\sum_i e^{x_i}}$	$(0, +1)$
Soma unitária	$\frac{e^{-x}}{\sum_i x_i}$	$(0, +1)$

Raiz quadrada	\sqrt{x}	(0, +1)
Senô	Sen(x)	(0, ∞)
Rampa	$\begin{cases} 1, x \leq -1 \\ x, -1 < x < 1 \\ 1, x \geq 0 \end{cases}$	[-1, 1]
Degrau	$\begin{cases} 0, x < 0 \\ 1, x \geq 0 \end{cases}$	[0, 1]

Tabela 1. Exemplo de algumas funções de ativação

Com base nas informações mencionadas, surgiu uma importante classe de redes neurais: *Perceptron* de múltiplas camadas (do inglês, *Multilayer perceptron*, MLP).

2.11.2 Arquitetura MLP

Neste tipo de RNA há uma retroalimentação, ondes as saídas agora farão parte da entrada. Esse tipo de rede tem suporte para memória de curto praza, o que possibilita a construção de diferentes tipos de modelos.

Uma rede MLP é formada por três camadas. São elas:

- **Camada de entrada:** Composta por neurônios que representam as variáveis que alimentarão a rede. Essa camada também é responsável por fornecer as entradas para as camadas subsequentes. Os nós de entradas têm uma função de ativação linear e não possuem limiar;
- **Camada escondida:** Responsável pela não-linearidade da rede, podendo existir uma ou mais dela. Cada neurônio escondido possui um limiar e uma função de ativação, geralmente, não-linear;
- **Camada de saída:** É responsável pela resposta da rede, apresentando a variável que se pretende classificar ou prever;

A Figura 20 mostra uma representação gráfica destas três camadas.

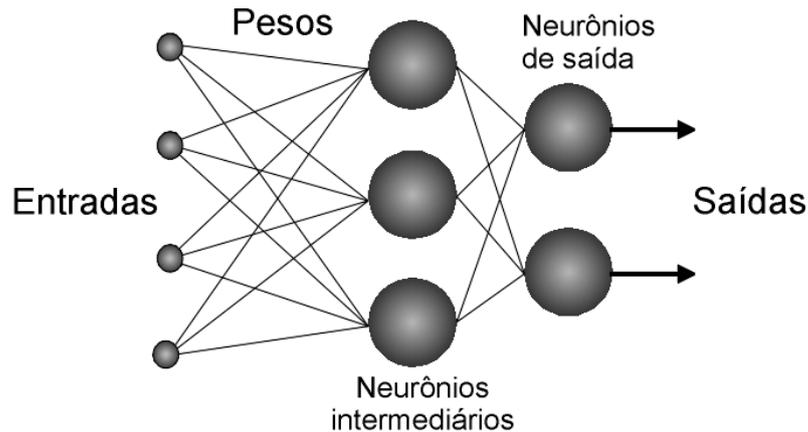


Figura 20. Estrutura de uma rede MLP

Fonte: [<http://www.cerebromente.org.br>]

Para uma configuração simples de três camadas, todas as entradas estão conectadas com algumas ou com todas as saídas [15].

2.11.3 Algoritmo de treinamento: *BackPropagation*

Este algoritmo foi proposto por Paul Werbos em 1974. É o algoritmo mais comum para treinamento de redes do tipo MLP na utilização da chamada regra delta para reajuste dos novos pesos. A rede MLP tem um treinamento supervisionado [11] reajustando os pesos através de uma propagação recursiva de erros que vão desde a camada de saída até a camada de entrada. O algoritmo conhecido por *BackPropagation* se divide em duas fases:

- **Forward:** O sinal de entrada é propagado da entrada para a saída, e posteriormente o sinal da saída e seu respectivo erro são calculados. O erro é calculado pela diferença da saída que era esperada e a saída que foi obtida e quanto menor o erro, menor será a proporção de reajuste dos pesos.
- **Backward:** Os erros são propagados de maneira recursiva da saída até a entrada) e os pesos são ajustados de acordo com a equação (16).

$$w_{ij}^m(t+1) = w_{ij}^m(t) + \alpha \delta_i^m f^{m-1}(j) j^{m-1} + \beta \Delta w_{ij}^m \quad (16)$$

em que:

$w_{ij}^m(t + 1)$: Representa o novo valor do i -ésimo peso da camada “ m ” para o neurônio “ j ”

$w_{ij}^m(t)$: Representa o valor do peso antigo do i -ésimo peso da camada “ m ” para o neurônio “ j ”

α : Representa a taxa de aprendizagem da rede, normalmente com valores entre 0 e 1.

δ_i^m : Representa uma característica do neurônio denominada sensibilidade, sendo calculada pelas equações (17) e (18).

$f^{m-1}(j)^{m-1}$: É o cálculo da função de ativação da camada $m-1$ para o neurônio j .

β : É o valor que indica a proporção da influência da variação passada por um determinado peso.

Δw_{ij}^m : É a variação do i -ésimo peso do neurônio “ j ” da camada “ m ”.

$$\delta_i^m = (d_i - y_i)f'(neurônio), \quad (17)$$

$$\delta_j^{m-1} = f'^{m-1}(neurônio_j^{m-1}) \sum_{i=1}^N w_{ij}^m \delta_i^m \quad (18)$$

2.11.4 Validação cruzada

É uma técnica que consiste em evitar um efeito chamado *overfitting*, que é resultado do treinamento excessivo da rede neural [11]. Caso isso ocorra, a rede neural perde a sua capacidade de generalizar através dos exemplos de treinamento. O conjunto de validação cruzada deve ser, sempre, diferente dos dados de treinamentos. A cada novo ciclo de treinamento são calculados os erros

correspondentes e no momento em que a taxa de erro do conjunto de validação cruzada começar a aumentar, o treino deve ser interrompido para evitar a perda da capacidade de generalização pela RNA.

Capítulo 3

Metodologia

3.1 Desenvolvimento do aplicativo

O primeiro passo para a realização deste trabalho foi o desenvolvimento de um aplicativo para smartphone com o sistema operacional Android que funciona em sua versão 4.0 e versões superiores utilizando da ferramenta **Xamarin Studio**. Todo o projeto foi implementado com o paradigma de orientação a objeto utilizando a linguagem de programação C# voltada para desenvolvimento mobile [16]. A construção da interface com o usuário também foi feita utilizando a ferramenta citada baseando-se em uma linguagem de marcação chamada **XML**.

Além das bibliotecas de projeto que vêm por padrão foram utilizados duas bibliotecas extras para esse projeto, são elas a **Android.Media** e a **Android.Hardware**, que permitem a gravação dos dados e a utilização dos sensores do aparelho, respectivamente [17].

Em sua totalidade o projeto do aplicativo possui 12 telas e 8 classes, cada qual com uma funcionalidade específica, entre as quais duas se destacam por serem a de maior importância:

- 1 MainActivity.cs: Classe principal responsável por gerenciar as outras classes e fazer a chamada da tela inicial do aplicativo que registra os dados do usuário;
- 2 Acelerômetro.CS: Faz a comunicação com o acelerômetro do smartphone, gerencia a tela para o usuário e registra todos os valores durante o uso do aplicativo.

3.2 Construção da base de dados

A base de dados foi gerada pelos experimentos realizados pelo aluno de Mestrado da Escola Politécnica de Pernambuco, Rafael Caldas. O experimento

realização consistiu na captação dos valores do acelerômetro nos eixos X,Y,Z com um smartphone posicionado na parte do corpo em questão.

A Tabela 2 indica os cinco tipos de caminhada foram estudados:

	Posição Cel	Posição Cel	Membro Referência	Tipo de Marcha
1	Ilíaco E	180	Esquerdo	Normal
2	Ilíaco E	180	Esquerdo	Ceifante
3	Ilíaco E	180	Esquerdo	Claudicante
4	Ilíaco E	180	Esquerdo	Talonante
5	Ilíaco E	180	Esquerdo	Parkinson

Tabela 2. Tipo de marcha utilizadas nos experimentos

O ilíaco (Osso do quadril) é o membro inferior especializado para sustentar o peso e a locomoção, a capacidade de mover-se de um lugar para outro e manter o equilíbrio.

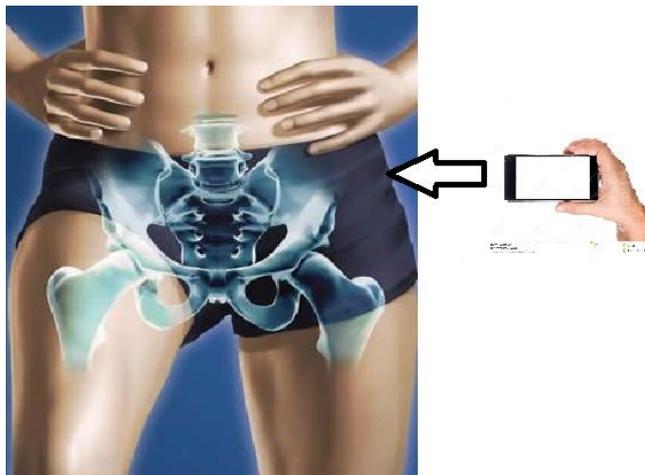


Figura 21. Posicionamento do smartphone durante experimentos.

Foram escolhidas cinco tipos de marcha diferentes que geraram sinais para a análise com a transformada wavelet e posteriormente sua correta classificação com RNA de arquitetura MLP. São elas:

- 1. Marcha normal:** Caracteriza-se pela caminhada sem patologia de um ser humano;
- 2. Marcha Ceifante:** Reflete a falta de capacidade de aumentar a velocidade de locomoção ou adaptar-se às irregularidades do terreno. Normalmente é resultado de AVC;
- 3. Marcha Claudicante:** Consiste na dificuldade de andar normalmente em razão da perda total ou parcial do membro ou movimento nervoso;
- 4. Marcha Talonante:** Caracteriza-se por passos inseguros e desordenados, o paciente caminha com as pernas afastadas uma da outra, levantando-as em excesso para em seguida projetá-las ao solo com energia, tocando o calcanhar;
- 5. Marcha Parkinsoniana:** O paciente tem dificuldade de locomoção por se encontrar com a musculatura rígida. Após certo tempo é possível realizar alguns passos curtos, com a cabeça e o tórax inclinados para a frente.

3.3 Aplicação de análise wavelet para sinais de acelerômetro

Dado que as amostras dos sinais de acelerômetro são de um mesmo intervalo de tempo, o tamanho dos dados brutos é variável de acordo com o tipo da marcha. Os dados do acelerômetro tem os seguintes atributos: Tempo, aceleração ao longo dos eixos X, Y e Z. As figuras 22, 23 e 24 mostram exemplos dos sinais nos seus respectivos eixos para uma marcha parkinsoniana.

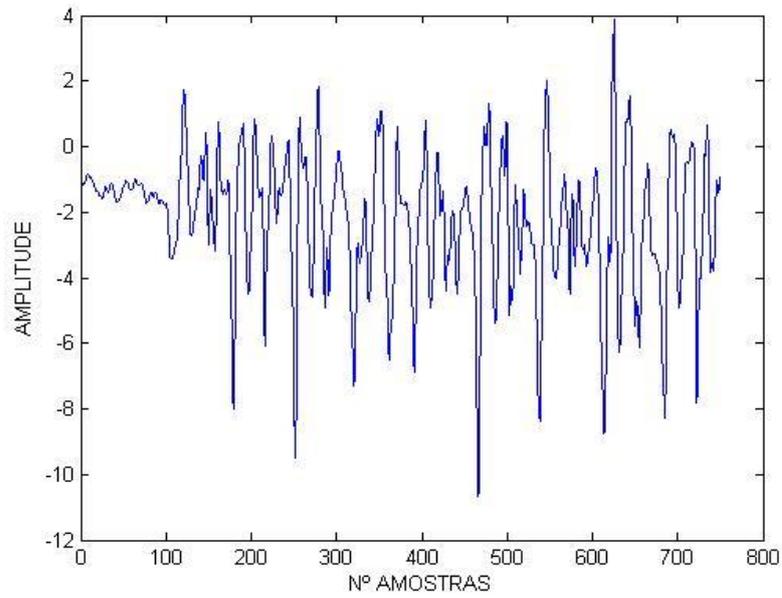


Figura 22. Exemplo de sinal do eixo X para marcha Parkinsoniana

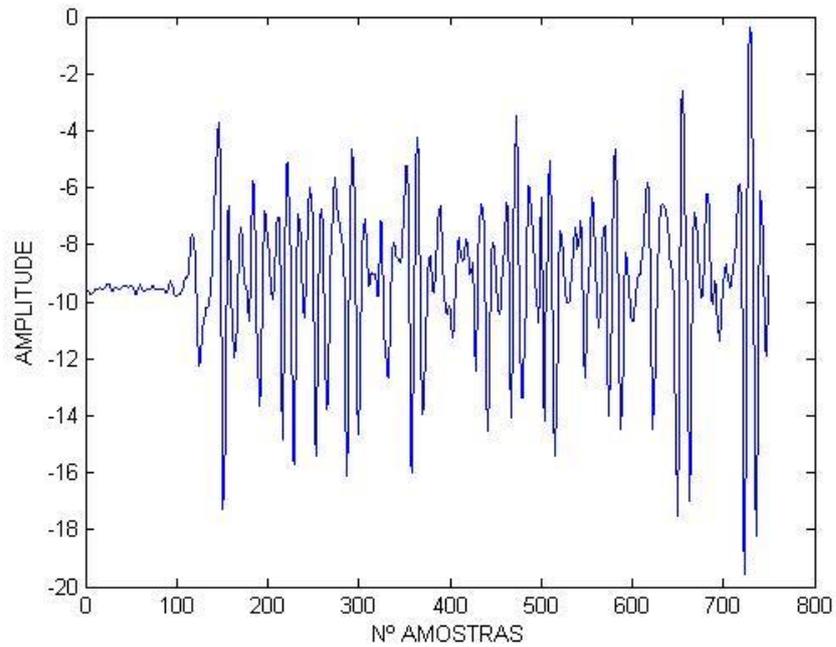


Figura 23. Exemplo de sinal do eixo Y para marcha Parkinsoniana

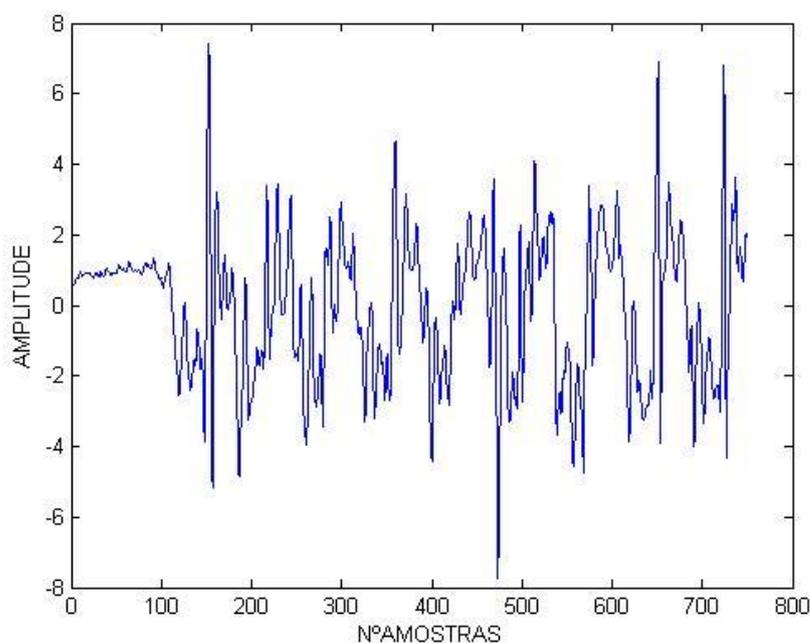


Figura 24. Exemplo de sinal no eixo Z para marcha Parkinsoniana

Para se ter liberdade no posicionamento do smartphone durante o experimento, ou seja, ele pode ser colocado em qualquer direção que não haverá influência na análise do sinal em questão, os três eixos foram somados formando uma única faixa de valores, que representa a média desse somatório. A Tabela 3 indica os 6 tipos de transformadas wavelets que foram aplicados na e mostra qual foi a família e o nível de decomposição utilizados para a análise.

Tipo da Wavelet	Família	Nível de decomposição
Symlet	8	12
Haar	**	12
Daubechies	10	12
Coiflets	5	12
Meyer	**	12
Biorotogonal	6.8	12

** Wavelet não possui classificação por família disponível.

Tabela 3. Famílias de Wavelets utilizadas no experimento.

A decisão de quais os melhores coeficientes foi feita com base na taxa de acerto na reconstrução do sinal original, quanto mais próximo ao original tiver sido o sinal sintetizado pela transformada wavelet mais representativos para o sinal original serão seus coeficientes.

3.4 Classificação com RNA.

Para mostrar que a transformada wavelet é um excelente meio de extrair características de sinais através do cálculo de seus coeficientes, foi utilizado uma RNA com arquitetura MLP para encontrar padrões e classificar os diferentes tipos de marcha que foram propostos inicialmente. Para realizar esse processo de classificação foram utilizados os seguintes parâmetros para configurar a rede MLP e treiná-la através do algoritmo de *BackPropagation* :

- Um neurônio na camada de entrada que é o valor médio dos coeficientes gerados pela família de wavelet escolhida em cada marcha;
- Número de neurônios na camada escondida: 10;
- Três neurônios na camada de saída:
{000 – Marcha Normal; 001-Marcha Ceifante; 010 – Marcha Claudicante;
011 – Marcha Talonante; 100 – Marcha Parkinsoniana }.
- Função de ativação da camada escondida: {Sigmóide Logística};
- Função de ativação das camadas de saída: {Função Linear};
- Taxa de aprendizado: {0,05}
- Pesos iniciais: Escolhidos aleatoriamente;
- Critério de parada: Validação cruzada

A base de dados foi dividida em 50% para treinamento, 25% validação cruzada, 25% para testes da rede.

O erro é calculado em função erro médio quadrático (EMQ) calculada pela seguinte equação:

$$EMQ = \sqrt{\frac{\sum(d-y)^2}{N}} \quad (19)$$

onde “ d ” é a saída desejada, “ y ” é a saída fornecida pelo treinamento e “ N ” o número total de saídas do conjunto calculado.

Capítulo 4

Resultados

4.1 Seleção da wavelet

Foram realizadas ao todo 150 combinações, com amostras de 750 valores, entre um tipo de marcha e um tipo de transformada wavelet, a fim de se obter a wavelet que melhor reconstrói os sinais gerados pelo acelerômetro e portanto a que gera coeficientes mais próximos da realidade do sinal.

Neste trabalho todos os resultados para todas as combinações ficaram acima dos 95% no que diz respeito ao grau de similaridade do sinal estudado e quanto mais aumentar a quantidade de amostras do sinal estudado, maior será o destaque para um determinado tipo de wavelet. Isso ocorre devido as características apresentadas por cada família e por cada tipo de marcha, por exemplo uma marcha de um indivíduo com Mal de Parkinson apresenta oscilações constantes e famílias de wavelets como a de Haar não são capazes de reproduzir esse sinal com uma fidelidade de quase 100%.

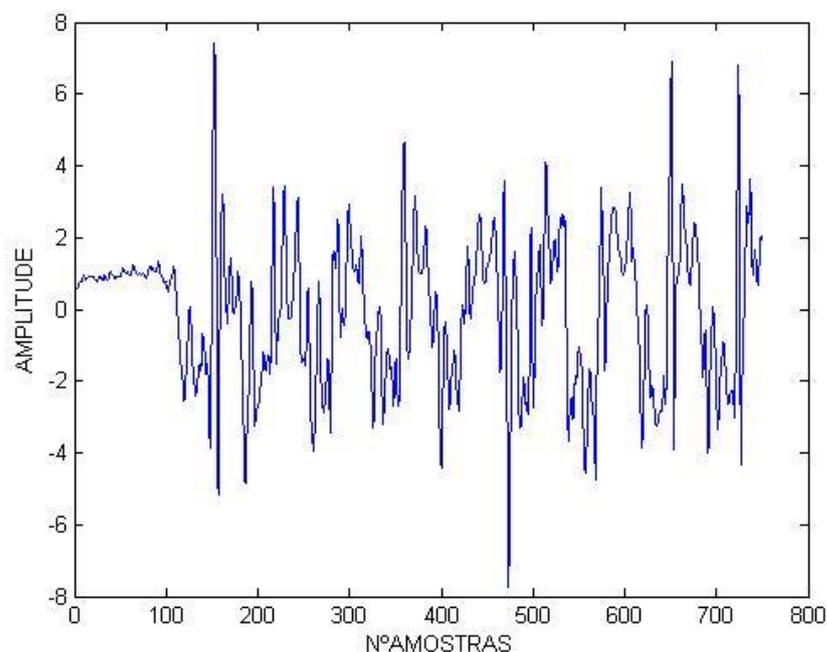


Figura 25. Sinal para marcha Parkinsoniana.

Apesar destas diferenças apresentadas, o que foi proposto neste trabalho é identificar a melhor família de transformada wavelets para um caso geral. Em média os melhor resultado foi apresentado pela família de wavelets **Meyer** que apresentou as taxas superiores em 2 das 5 marchas e também em um contexto mais global. As tabelas 4, 5, 6, 7, 8 mostram os resultados de cada wavelet em um determinado tipo de marcha.

Wavelet	Tipo da Marcha	Reconstrução Média (%)
Haar	Normal	97,62
Daubechies		98,39
Symlets		98,80
Coiflets		98,40
Birtogonal		98,80
Meyer		98,94

Tabela 4. Resultados para marcha normal.

Wavelet	Tipo da Marcha	Reconstrução Média (%)
Haar	Ceifante	98,30
Daubechies		98,46
Symlets		98,62
Coiflets		98,49
Birtogonal		98,64
Meyer		98,54

Tabela 5. Resultados para marcha ceifante.

Wavelet	Tipo da Marcha	Reconstrução Média (%)
Haar	Claudicante	95,38
Daubechies		95,17
Symlets		96,50
Coiflets		94,92
Biorotogonal		95,60
Meyer		96,34

Tabela 6. Resultados para marcha claudicante.

Wavelet	Tipo da Marcha	Reconstrução Média (%)
Haar	Talonante	98,65
Daubechies		98,68
Symlets		98,83
Coiflets		98,81
Biorotogonal		98,77
Meyer		98,69

Tabela 7. Resultados para marcha Talonante.

Wavelet	Tipo da Marcha	Reconstrução Média (%)
Haar	Parkinsoniana	95,20
Daubechies		95,81
Symlets		95,86
Coiflets		95,54
Biorotogonal		95,71
Meyer		97,66

Tabela 8. Resultados para marcha Parkinsoniana.

O grande mérito da transformada wavelet de Meyer foi apresentar taxas adequadas na reconstrução das marchas e principalmente pela sua larga vantagem em relação a marcha parkinsoniana, cujo sinal apresenta certas particularidades que reduziram as taxas para as outras wavelets. A tabela 9 mostra os resultados na classificação geral.

Wavelet	Grau de similaridade com o sinal original (%)
Haar	97,03
Daubechies	97,30
Symlets	97,73
Coiflets	97,24
Biorotogonal	97,50
Meyer	98,03

Tabela 9. Média geral dos resultados.

Os coeficientes que foram obtidos pela aplicação da wavelet de Meyer são as entradas da RNA para verificar o grau de acerto na classificação das marchas apenas utilizando estes valores.

4.2 Classificação dos padrões de marcha com RNA

Depois de obtidos os coeficientes médios para a melhor Wavelet (Meyer), uma rede neural de arquitetura MLP, com 1 neurônio na camada de entrada, 10 neurônios na camada escondida e 3 neurônios na camada de saída, foi treinada e na média obteve os seguintes resultados:

1. Porcentagem de acerto na classificação: 64.28%
2. Porcentagem de erro na classificação: 35.72%

Ao todo foram utilizados 25 exemplos, 5 para cada tipo de marcha e ao final de 18 ciclos, o critério de parada foi ativado com um EMQ de aproximadamente 0,20 que foi conseguido no décimo segundo ciclo e após mais 6 ciclos a rede neural encerrou o seu treinamento.

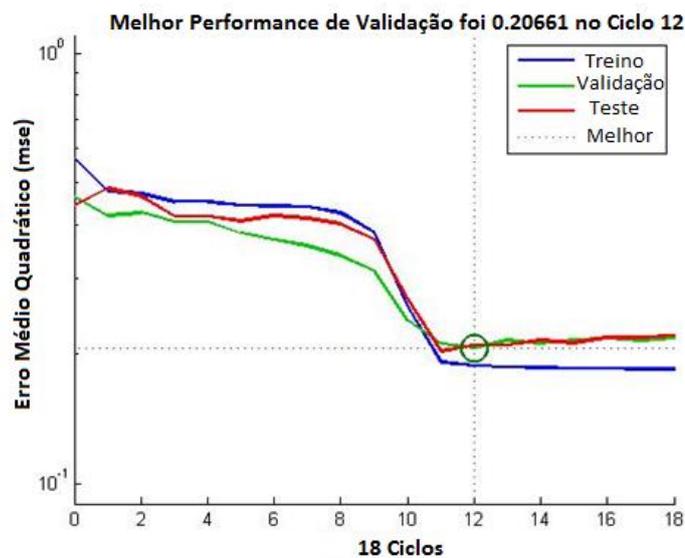


Figura 26. Evolução do erro no treinamento da RNA

Capítulo 5

Considerações Finais

5.1 Conclusões

O principal objetivo da fisioterapia é melhorar a qualidade de vida do paciente e o acompanhamento de suas atividades é uma forma adicional de quantificar isso. A comparação proposta visa mostrar a importância do uso de transformada wavelets no processo de classificação de sinais comumente gerando por movimentos fisioterápicos.

Os smartphones são capazes de gravar os movimentos da pessoa, simplificando o estudo pela comunidade médica. É claro que indivíduos com deficiências motoras merecem atenção especial em abordagens que analisam os padrões de movimento.

A partir de uma base de dados construída pelo aluno de Mestrado da Escola Politécnica de Pernambuco, Rafael Caldas. Durante a realização do trabalho foram encontradas algumas limitações que podem ameaçar a validade dos resultados.

A rede neural que foi treinada alcançou uma taxa de classificação aceitável porém se houvesse um maior número de exemplos para treinamento, validação e teste, os resultados poderiam ser mais enfáticos.

Este resultado mostra que é completamente plausível o emprego da combinação entre a extração de características de um determinado sinal pela transformada wavelet e o uso dessas características pela RNA para classificar os padrões adotados. Seria muito difícil classificar qualquer sinal bruto de maneira eficiente sem encontrar características marcantes para o mesmo.

Por fim, conclui-se que será possível fornecer um meio de rastreamento objetivo, conveniente e relativamente barato, à medida que aproveitar essas qualidades podem melhorar e permitir novas abordagens nas pesquisas dessa área e também demonstrar que é possível utilizar técnicas de inteligência computacional

combinadas com um “microscópio matemático” capaz de interpretar sinais não-triviais para uma plataforma de desenvolvimento mobile na classificação de movimentos do corpo humano.

5.2 Trabalhos futuros

Como trabalhos futuros pretende-se testar a eficiência de outras famílias wavelet no processo de extração de características de sinais, além do uso de outros sensores do smartphone para novos testes com outros tipos de movimentos característicos do corpo humano.

É válido ressaltar também o uso de outras técnicas de classificação de padrões, a fim de se obter resultados cada vez melhores e encontrar a combinação mais eficiente entre o uso de uma transformada e o emprego de meio de classificação.

Bibliografia

- [1] DERNBACH, STEFAN; DAS, B; KRISHNAN, NARAYANAN C., THOMAS, B.L.; COOK, D.J, “Simple and Complex Activity Recognition through Smart Phones.,” *8th International Conference*, pp. 214-221, 2012.
- [2] “Android Sensors Overview,” [Online]. Available: http://developers.android.com/guide/topics/sensors/sensors_overview.html. [Acesso em 16 setembro 2014].
- [3] ALBERT, MARK. V; TOLEDO, SANTIAGO; SHAPIRO, MARK; KORDING, KONRAD, “Using mobile phones for activity recognition in Parkinson’s patients.,” *Frontiers in Neurology*, vol. 3, Nov. 2012.
- [4] S. KAITWANIDVILAI, C. POTHISARN, C. JETTANASEN, P. CHIRADEJA AND A. NGAOPITAKKUL, “Discrete Wavelet Transform and Back-propagation Neural Networks Algorithm for Fault Classification in Underground Cable.,” *Proceedings of the International MultiConference of Engineers and Computer Scientists*, vol. 2, 2011.
- [5] A. HAAR, ZUR, *Theorie der Orthogonalen Funktionen-Systeme*, 1910, pp. 331-371.
- [6] J. V. D. BERG, “Wavelets in Physics,” *Cambridge Press*, 1999.
- [7] I. DAUBECHIES, “Ten Lectures on Wavelets,” em *Regional Conference Series in Applied Mathematics*, 1992.
- [8] SALENO, RAMON. YURE, COSTA E SILVA., “Determinação de patologias estruturais usando modelagem única e transformadas de wavelet,” 2011.

- [9] “Android Sensors Overview,” [Online]. Available: http://developers.android.com/guide/topics/sensors/sensors_overview.html. [Acesso em 16 setembro 2014].
- [10] UGULINO, W. CARDADOR, D. VEGA, K. VELLOSO, E. MILIDIU, R. FUKS, H., “Wearable Computing: Accelerometers’ Data Classification of Body Postures and Movements,” *Proceedings of 21st Brazilian Symposium on Artificial Intelligence.* , 2012. 0.
- [11] M. VALENÇA, Fundamentos das Redes Neurais, 2ª Ed. ed., 2010.
- [12] S. POUNGPONSRI, “An Approach Based on Wavelet Decomposition and Neural Network for ECG Noise Reduction,” 2009.
- [13] K. HORNIK, “Approximation capabilities of multilayer feedforward networks,” *Neural Networks*, vol. 4, nº 2ª Ed., pp. 251-257, 1990.
- [14] GOMES, G. S. S. AND LUDERMIR, T. B., “Complementary log-log and probit: activation functions implemented in artificial,” em *Eighth International Conference on Hybrid Intelligent Systems*, Barcelona, Spain, 2008.
- [15] WALTER, H. DELASHMIT AND MICHAEL T. MANRY, “Recent Developments in Multilayer Perceptron Neural Networks,” em *Proceedings of the 7th Annual Memphis Area Engineering and Science Conference*, 2005.
- [16] “Microsoft Developer Network,” Microsoft, [Online]. Available: <http://msdn.microsoft.com/pt-br/library/kx37x362.aspx>. [Acesso em 20 Novembro 2014].
- [17] “Android Sensor Manager,” [Online]. Available: <http://developer.android.com/reference/android/hardware/SensorManager.html>. [Acesso em 11 Novembro 2014].

