



**UNIVERSIDADE FEDERAL RURAL DO SEMIÁRIDO  
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO  
NORTE  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**



**PABLO LUIZ BRAGA SOARES**

**APLICAÇÃO DE REDES NEURAIIS EM CONJUNTO COM WAVELETS NA  
DETECCÃO E ATENUAÇÃO DE RUÍDOS EM IMAGENS DIGITAIS E SÍSMICAS**

**MOSSORÓ – RN**

**2013**

**PABLO LUIZ BRAGA SOARES**

**APLICAÇÃO DE REDES NEURAIIS EM CONJUNTO COM WAVELETS NA  
DETECCÃO E ATENUAÇÃO DE RUÍDOS EM IMAGENS DIGITAIS E SÍSMICAS**

Dissertação de Mestrado submetida ao Programa de Pós-graduação em Ciência da Computação – associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semi-árido, como parte dos requisitos necessários para obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Sc. José Patrocínio da Silva – UFERSA.

**MOSSORÓ – RN**

**2013**

**Ficha catalográfica preparada pelo setor de classificação e catalogação da Biblioteca “Orlando Teixeira” da UFERSA**

S676a Soares, Pablo Luiz Braga.

Aplicação de redes neurais em conjunto com wavelets na detecção e atenuação de ruídos em imagens digitais e sísmicas. / Pablo Luiz Braga Soares. -- Mossoró, 2013.

79 f.: il.

Dissertação (Mestrado em Ciências da Computação) -  
Universidade Federal Rural do Semi-Árido.  
Orientador: Prof<sup>o</sup>. José Patrocínio da Silva.

1. Redes Neurais Artificiais. 2. Transformadas Wavelet. 3. Ruído Ground Roll. 4. Ruído Impulsivo. 5. Imagens Sísmicas e Digitais. I.Título.

CDD: 006.32

Bibliotecária: Vanessa de Oliveira Pessoa

CRB15/453

**PABLO LUIZ BRAGA SOARES**

**APLICAÇÃO DE REDES NEURAIIS EM CONJUNTO COM WAVELETS NA  
DETECÇÃO E ATENUAÇÃO DE RUÍDOS EM IMAGENS DIGITAIS E SÍSMICAS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

APROVADA EM: \_\_\_ / \_\_\_ / \_\_\_\_.

**BANCA EXAMINADORA**

---

**Prof. José Patrocínio da Silva, D.Sc.**

Orientador

Universidade Federal Rural do Semi-Árido - UFERSA

---

**Prof<sup>ª</sup>. Angélica Félix de Castro, D.Sc.**

Membro Interno

Universidade Federal Rural do Semi-Árido - UFERSA

---

**Prof. Moisés Dantas dos Santos, D.Sc.**

Membro Externo

Universidade Federal da Paraíba - UFPB

*A toda minha família, em especial aos meus pais Francisco Soares e Rita Braga.*

## AGRADECIMENTOS

A Deus por está sempre me escutando e apoiando nos momentos difíceis da minha vida;

A Francisco Soares (Ticão), meu pai, que apesar de distante nunca deixou faltar nada para minha formação;

A Rita Braga, minha mãe, que assumiu o papel de mãe e pai ao mesmo tempo desde que passamos a morar em Mossoró. Pelo seu amor, carinho, apoio e confiança. A ela dedico todo o mérito e minha educação e formação;

A Larissa Braga, minha irmã, pelos cuidados com a minha alimentação;

A José Soares (Zé Raul), meu avô de Janduís, porque herdei dele, a capacidade de ver sempre o lado bom das coisas apesar de tudo;

A Francisca Soares (Neném Raul), minha avó de Janduís, que sempre me recebeu de braços abertos em todos os momentos;

Ao meu orientador, Prof. José Patrocínio da Silva, que apesar de uma pequena desavença ocorrida no início (episódio engraçado), me convidou para ser bolsista de iniciação científica. Foi onde comecei a vida de pesquisador;

A minha amiga/namorada Luana Rafaela Gomes do Nascimento, pelo carinho, amor, dedicação, cuidado, zelo e compreensão;

A Elânia Moura e Priscila Jácome, duas grandes amigas que sempre me apoiaram nos momentos difíceis da vida;

Aos amigos de computaria por proporcionar muitos momentos de diversão, alegria e felicidade;

Finalmente, a toda minha família (tias, tios, primos e primas), que de uma forma ou de outra estão sempre me apoiando e ajudando.

*"O primeiro passo para a sabedoria é o silêncio; o segundo, a escuta."*

***Provérbios 1:5***

## RESUMO

Recentemente, muitas pesquisas com Redes Neurais Artificiais (RNAs) têm sido desenvolvidas na área de Produção de Petróleo e Gás, inclusive no Brasil. Mesmo com tantos trabalhos publicados na área de Petróleo e Gás, esta área ainda requer e permite o desenvolvimento de várias pesquisas. Nesse sentido os sismogramas apresentam uma boa aproximação de uma estrutura geológica. No entanto, as imagens mostradas por eles são geralmente contaminadas com informações irrelevantes. O ruído de rolamento superficial (*ground roll*) contido nestas imagens pode contribuir de forma significativa para a distorção dos dados presentes na informação desejada, devido à dispersão das ondas em regiões mais profundas das camadas geológicas. Nesta Dissertação, foi utilizado um método baseado em wavelet de Haar e Daubechie aplicada em conjunto com RNA para atenuar esse tipo de ruído em imagens sísmicas. Além disso, esta Dissertação apresenta um segundo método, que serve para detecção e remoção de ruído impulsivo (Sal e Pimenta) de imagens digitais baseado na combinação de duas RNA. O segundo método apresentando é comparado com alguns métodos da literatura em termos de julgamento visual e também usando uma medida quantitativa *Peak Signal To Noise Ration* (PSNR). Os resultados obtidos demonstram que os métodos são viáveis e que podem ser utilizados como ferramentas no tratamento de imagens sísmica e digitais.

**Palavras-Chave:** Redes Neurais Artificiais. Transformadas Wavelet. Ruído *Ground Roll*. Ruído Impulsivo. Imagens Sísmicas e Digitais.

## ABSTRACT

Recently, many research Artificial Neural Networks (ANNs) have been developed in the field of Oil and Gas, including Brazil. Even with so many published works in the field of Oil and Gas, this area still requires and allows the development of multiple searches. In this sense the seismograms exhibit a good approximation of a geological structure. However, the images showed by them are generally contaminated by irrelevant information. The noise ground roll in these images can contribute significantly to the distortion of the data present in the desired information due to the scattering of waves in deeper regions of geological layers. In this Dissertation, we used a method based on Haar and Doubechie wavelet applied in conjunction with artificial neural networks to reduce the noise ground roll. Furthermore this Dissertation presents a second method for detecting and removing impulse noise from digital images based on the combination of two ANNs. The second method is compared with other methods on literature in terms of visual judgment and also using a quantitative measure of PSNR - Peak Signal To Noise Ratio. The results demonstrate that the methods are viable and, both can be used as tools in seismic and digital images

**Keywords:** Artificial Neural Network. Wavelet Transforms. Ground Roll Noise. Impulse Noise. Seismic and Digital Images.

## **LISTA DE TABELAS**

Tabela 1 – Média PSNR x densidade de ruído.....	68
---	----

## LISTA DE FIGURAS

Figura 1 – Representação dos Neurônios e Conexões.....	21
Figura 2 – Neurônio biológico.....	23
Figura 3 – Modelo não-linear de neurônio artificial.....	24
Figura 4 – Rede de alimentação direta com uma única camada de neurônios .....	26
Figura 5 – Rede com alimentação direta com 1 camada oculta e 1 camada de saída .....	27
Figura 6 – Exemplo de uma rede Recorrente .....	27
Figura 7 – Representação de uma MLP.....	29
Figura 8 – Quadro com classificação das RNAs .....	31
Figura 9 – Ilustração de dois sinais, a propagação (entradas) e a retropropagação (erro).....	33
Figura 10 – Representações de uma imagem. (a) Graficamente como uma superfície. (b) Como uma matriz de intensidade visual. (c) Como uma matriz numérica 2-D .....	36
Figura 11 – (a) Vizinhança-4 $N_4(p)$ . (b) Vizinhança diagonal $N_d(p)$ . (c) Vizinhança -8 $N_8(p)$ .....	37
Figura 12 – Esquema da aquisição terrestre e marítima de dados sísmicos .....	38
Figura 13 – Representação para os traços sísmicos. (a) traço sísmico em seu formato original (série temporal) onde na horizontal têm-se as amplitudes e na vertical a quantidade de amostras (temporal). Esse traço é o número 20 do sismograma representado na Figura 14. Em (b) tem-se a representação para os traços 20 a 22 para o mesmo sismograma.....	40
Figura 14 – Registro sísmico 2D terrestre. O eixo vertical está definido em unidades de tempo (ms). Na horizontal representa o afastamento entre geofones (m) e cada geofone representa um traço. Em (a) tem-se o local onde ocorreu a geração das ondas sísmicas (fonte). Em (b) "cone" de ruído <i>ground roll</i> .....	40
Figura 15 – Sismograma, onde <b>A</b> é uma região contaminada pelo ruído de rolamento superficial, <b>B</b> é a região contaminada pela onda de choque aérea e <b>C</b> são os refletores de interesse. ....	42
Figura 16 – Homem (a) Sem ruído. (b) com 30% de ruído.....	43
Figura 17 – Representação do algoritmo: (a) de análise e decomposição rápida com filtros $h$ e $g$ seguida por uma decimação de $(\downarrow 2)$ e (b) de análise e reconstrução rápida com filtros $\tilde{h}$ e $\tilde{g}$ seguida por uma inserção $(\uparrow 2)$ . ....	48
Figura 18 – Diagrama de blocos da sequência de passos utilizados para atenuação do ruído de rolamento.....	51
Figura 19 – Representação, em três níveis de resolução, através do método de decomposição em wavelets para o sismograma da Figura 15 fibras por interação de campos.....	53
Figura 20 – Vizinhança-8 de $x_C$ .....	54
Figura 21 – Procedimento para formar dados de entrada/saída.....	54
Figura 22 – Estrutura da Rede Neural .....	55

Figura 23 – Desempenho da rede neural durante o treinamento .....	56
Figura 24 – Comparação entre sinais: (a) Imagem original contendo o <i>ground roll</i> e (b) Imagem com atenuação do <i>ground roll</i> através da decomposição em multiescala utilizando wavelet de Haar .....	57
Figura 25 – Comparação entre sinais: (a) Imagem original contendo o <i>ground roll</i> e (b) Imagem com atenuação do <i>ground roll</i> através da decomposição em multiescala utilizando wavelet de Daubechie. ....	57
Figura 26 – Resíduo removido através da wavelet de Daubechie.....	58
Figura 27 – Atenuação do <i>Ground Roll</i> usando rede neural .....	58
Figura 28 – Imagem apresentada à rede neural para validação.....	59
Figura 29 – Resposta da rede neural para a imagem de validação .....	59
Figura 30 – Esquema Geral do método proposto. ....	60
Figura 31 – Exemplo de um bloco 2 x 2 composto de 4 <i>pixels</i> com mesmo nível de cinza ....	61
Figura 32 – (a) Imagem base. (b) Imagem de entrada. (c) Imagem Alvo .....	61
Figura 33 – Estrutura do detector de Ruído.....	62
Figura 34 – Desempenho da RNA-1 durante o treinamento .....	64
Figura 35 – (a) Imagem Elaine (saída). (b)Imagem Elaine com 40% de ruído(entrada) .....	65
Figura 36 – Estrutura do estimador de ruído (RNA-2).....	65
Figura 37 – Desempenho da RNA-2 durante o treinamento .....	66
Figura 38 – Média PSNR x densidade de ruído % dos Métodos: Proposto, NNBID, Yüskel, TONF, MPVF, AFSF, TBF e PSMF .....	68
Figura 39 – Imagem Baboon recuperada pelos métodos com 25% de densidade de ruído. (a) Imagem Baboom. (b) Porção da imagem em zoom. (c) PSMF. (d) TBF. (e) AFSF. (f) MPVF. (g) TONF. (h) Yüskel. (i) NNBID. (j) Proposto.....	69

## LISTA DE ABREVIATURAS

BP – *Back-Propagation* (Retropropagação);

IA – Inteligência Computacional;

MLP – *Multi-Layer Perceptron* (Perceptron Multi Camadas);

RNA – Rede Neural Artificial;

SN – Sistema Nervoso;

JPEG 2000 – (*Joint Photographic Experts Group*);

WFT – *Windowed Fourier Transform* (Transformada de Fourier em Janelas).

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	16
1.1 CONTEXTUALIZAÇÃO.....	16
1.1 MOTIVAÇÃO E OBJETIVO.....	18
1.1 ORGANIZAÇÃO DA DISSERTAÇÃO.....	19
<b>2 REDES NEURAIS ARTIFICIAIS</b> .....	21
2.1 INTRODUÇÃO.....	21
2.2 INSPIRAÇÃO BIOLÓGICA.....	22
2.3 NEURÔNIOS BIOLÓGICOS.....	22
2.4 NEURÔNIOS ARTIFICIAIS.....	23
2.5 ARQUITETURA DAS RNAs.....	26
2.6 <i>PERCEPTRON</i> MULTI CAMADAS ( <i>MULTILAYER PERCEPTRON</i> )..	28
2.7 GENERALIZAÇÃO EM UMA RNA.....	29
2.8 PARADIGMAS DE APRENDIZAGEM.....	30
2.9 ALGORITMO DA RETROPROPAGAÇÃO ( <i>BACKPROPAGATION</i> ).....	32
<b>2.9.1 Algoritmo <i>Levenberg-Marquardt</i></b> .....	33
<b>3 PROCESSAMENTO DE IMAGENS DIGITAIS</b> .....	35
3.1 INTRODUÇÃO CONTEXTUALIZAÇÃO.....	35
3.2 FUNDAMENTOS DAS IMAGENS DIGITAIS.....	36
3.3 PROPRIEDADES BÁSICAS ENTRE PIXELS.....	37
<b>3.3.1 Vizinhos de um pixel</b> .....	37
3.4 SONDAÇÃO SÍSMICA.....	37
3.5 PROSPECÇÃO SÍSMICA.....	38
3.6 RUÍDO DE ROLAMENTO SUPERFICIAL ( <i>GROUND ROLL</i> ).....	41
3.7 RUÍDO IMPULSIVO (SAL E PIMENTA).....	42
3.8 INTRODUÇÃO À TEORIA DAS WAVELETS.....	43
<b>3.8.1 Introdução Histórica</b> .....	44
<b>3.8.2 Transformada de Fourier</b> .....	45
<b>3.8.3 Transformada Wavelet</b> .....	46
<b>3.8.4 Método da Multiresolução</b> .....	47
<b>3.8.5 Transformada Wavelet de Haar</b> .....	48

<b>3.8.6 Transformada Wavelet de Daubechies</b> .....	49
<b>4 METODOLOGIA</b> .....	51
4.1 MÉTODO PARA ATENUAÇÃO DO RUÍDO <i>GROUND ROLL</i> .....	51
<b>4.1.1 Obtenção da Imagem (1º Passo)</b> .....	52
<b>4.1.2 Transformada Wavelet (2º Passo)</b> .....	52
<b>4.1.3 Conjunto entrada/saída (3º Passo)</b> .....	53
<b>4.1.4 Arquitetura e Treinamento da Rede (4º Passo)</b> .....	55
<b>4.1.5 Obtenção dos Resultados (5º Passo)</b> .....	56
4.2 MÉTODO PARA ATENUAÇÃO DO RUÍDO IMPULSIVO.....	60
<b>4.2.1 Obtenção das Imagens de Treinamento</b> .....	60
<b>4.2.2 Detector de Ruído (1ª Fase)</b> .....	62
<b>4.2.3 Estimador de Ruído (2ª Fase)</b> .....	64
<b>4.2.4 Obtenção dos Resultados</b> .....	66
<b>4.2.5 Discussão dos Resultados</b> .....	69
<b>5 CONCLUSÕES</b> .....	71
5.1 OBJETIVO 1.....	71
5.2 OBJETIVO 2.....	71
5.3 TRABALHOS FUTUROS .....	71
<b>6 REFERÊNCIAS</b> .....	73
<b>APÊNDICE PUBLICAÇÕES RELACIONADAS À DISSERTAÇÃO</b> .....	79

# Capítulo 1

## INTRODUÇÃO

### 1.1 CONTEXTUALIZAÇÃO

Há muito tempo têm-se imaginado máquinas com capacidade de compreender ideias e tomar decisões de forma semelhante ao ser humano, ou em outras palavras, máquinas que pensam. Apesar de todos os esforços aplicados a essa tarefa, ainda é extremamente difícil fazer um computador reconhecer elementos e padrões com a mesma facilidade que o ser humano.

Ao longo dos anos, grandes avanços têm sido alcançados na área da Inteligência Computacional (IA). É cada vez mais comum encontrar equipamentos eletrônicos que reproduzem algumas características humanas, tais como: visão, fala, memória, etc. e que atuam de forma autônoma, raramente necessitando da intervenção do usuário para exercer sua funcionalidade. Parte desse progresso, rumo às máquinas inteligentes, é atribuído às Redes Neurais Artificiais (RNA).

Inúmeras áreas têm se beneficiado do uso das redes neurais artificiais, como por exemplo: Engenharia Elétrica (processamento de sinais, teoria do controle, telecomunicações), Computação (otimização, robótica), Matemática (modelagem de problemas com variáveis desconhecidas), Medicina (diagnóstico de doenças), Linguística (reconhecimento e sintetização de voz), Negócios (reconhecimento de padrões, previsão de riscos), entre outras.

Recentemente, muitas pesquisas com RNAs têm sido desenvolvidas na área de Produção de Petróleo e Gás, inclusive no Brasil, que é um dos países que realizam grandes investimentos em tecnologias para exploração de reservatórios, perfuração de poços e extração de óleo e gás natural. Dentre os trabalhos recentes nessa área, apontam-se os seguintes: No trabalho de XING-YAO *et al.*, (1996) as redes neurais foram usadas para estimar a espessura dos reservatórios de petróleo. Os autores usaram vinte atributos para o treinamento da rede neural que foram conseguidos através de dados sísmicos. Em ESSENREITER *et al.*, (1998) as redes neurais foram treinadas para reconhecer e remover reflexões múltiplas (considerada um ruído) que impedem o mapeamento correto de subsuperfícies geológicas do mar. DELVRATE e SALVATORI (2004) usaram redes neurais

para detectar se as manchas encontradas nas imagens do mar captadas por satélite são de um derramamento de óleo ou não. MA *et al.*, (2009) usaram redes neurais artificiais, que utilizam o tempo acústico, raios gama e profundidade de indução para estimar a permeabilidade da rocha a partir de perfis de poços geofísicos. SAMPAIO (2009) utilizou uma aplicação de redes neurais artificiais como metamodelos para ajustar o histórico dos reservatórios e minimizar as diferenças entre os dados observados no campo e os previstos pela simulação.

Outra ferramenta que tem se destacado nos últimos anos em várias aplicações envolvendo métodos numéricos, a chamada Transformada de Wavelet. Trata-se de um desenvolvimento matemático que permite a análise de sinais em várias escalas temporais. Esta ferramenta tem sido amplamente utilizada pela comunidade científica e pela indústria, inclusive com aplicações no tratamento de imagem digitais, e tem sido considerada por muitos pesquisadores uma tendência sem precedentes na história da matemática aplicada MISITI *et al.*, 2007.

Com relação às Wavelets e sua aplicação em análise de imagens, apontam-se os seguintes: CORSO *et al.*, (2003) usaram transformada wavelet gaussiana como filtro para remover localmente o *ground roll*, da sísmica terrestre, mantendo a média do espectro da frequência. Já em PROCHAZKA *et al.*, (2005), as transformadas de wavelets discretas foram aplicadas para extração de características, e ruídos de imagens microscópicas de cristais com diferentes formas e tamanhos. MILLER (2007) propôs um método para remoção do ruído gaussiano aditivo em imagens digitais, usando dois tipos de modelagem para os coeficientes wavelet. Assim conseguindo melhor desempenho em remover ruído e preservar outras áreas de interesse.

Mesmo com tantos trabalhos publicados na área de Petróleo e Gás, esta área ainda requer e permite o desenvolvimento de várias pesquisas. Como por exemplo, a descoberta de uma nova jazida de petróleo em uma nova área é uma tarefa que envolve um longo e dispendioso estudo e análise de dados geofísicos e geológicos das bacias sedimentares. Somente após exaustivo prognóstico do comportamento de diversas camadas do subsolo, os geólogos e geofísicos decidem propor a perfuração de um poço, que é a etapa que exige mais investimento em todo o processo de prospecção.

Um programa de prospecção tem fundamentalmente dois objetivos: (i) localizar dentro de uma bacia sedimentar as situações geológicas que tenham condições para a acumulação de petróleo; (ii) verificar qual, dentre essas situações, qual possui maior chance de conter petróleo. Portanto não se pode prever onde existe petróleo e sim os locais mais favoráveis para sua ocorrência.

Tendo isso em vista, o uso de técnicas que possam auxiliar os geofísicos e geológicos a decidirem com certa precisão se determinadas regiões do solo são mais favoráveis ou não de se encontrar petróleo tornou-se muito importante. Uma vez que a perfuração de poços é uma manobra de alto custo e às vezes não se encontra petróleo. O uso de métodos de prospecção, tais como as sísmicas de reflexão, que fornecem alta definição das feições geológicas em subsuperfícies propícias à acumulação de hidrocarbonetos, a um custo relativamente baixo tem se tornado bastante promissor. No entanto esse método possui uma desvantagem, que na maioria das vezes as imagens sísmicas são contaminadas com um tipo de ruído denominado rolamento superficial (*ground roll*). Esse tipo de ruído tem a característica de um cone que por sua vez dificulta a visualização concreta de áreas de interesse da imagem sísmica.

Outro tipo de ruído presente em imagens é o ruído impulsivo, ou sal e pimenta. Frequentemente uma imagem é contaminada com esse tipo de ruído no momento em que a mesma é capturada ou quando está sendo transmitida por algum tipo de canal. Algumas aplicações, tais como detecção de borda em imagens, faz-se necessário a remoção desse tipo de ruído para que se possa observar detalhes mínimos de identificação da imagem.

Diferentes algoritmos têm sido propostos para remover o ruído impulsivo. Dentre os algoritmos mais utilizados estão o filtro da mediana SUN e NUEVO (1994), o filtro da mediana adaptativo ABREU (1997), técnicas *fuzzy* ZHANG e WANG (1997), operador laplaciano ZHANG e KARIM (2002) dentre outros. Outros métodos existentes utilizam um detector de ruído impulsivo para determinar se um *pixel* deve ou não ser modificado e em seguida o filtro é aplicado somente nos *pixels* identificados como ruidosos. Esse processo é conhecido como técnica de comutação e apresenta a vantagem de ser simples e ainda mais eficaz do que os métodos uniformemente aplicados CHEN *et al.*, (1999). KALIRAJ e BASKAR (2010) treinaram uma RNA para determinar se um *pixel* é ou não um ruído. Porém, para removê-los, utilizou dois algoritmos baseados na média como forma de estimar o valor do *pixel* ruidoso.

Diante desse fato o uso de técnicas como a transformadas wavelet e rede neurais se tornam interessante, pois nos últimos anos muitas pesquisas nessas áreas têm sido desenvolvidas no que diz respeito à remoção e atenuação de ruídos em imagens.

## 1.2 MOTIVAÇÃO E OBJETIVO

Há algumas décadas, o Brasil vem se tornando um grande produtor de petróleo, tendo adquirido sua autonomia, com relação às reservas nacionais no ano 2006. A cidade de

Mossoró-RN tem sido um importante polo petrolífero do Nordeste brasileiro e sua economia recebe grande influência da atividade de extração do petróleo e gás natural, atraindo muitas empresas do setor, tanto nacionais quanto multinacionais. Com os recentes incentivos do Governo Federal no tocante à extração de petróleo, devido à descoberta do Pré-Sal, novos investimentos em pesquisa e treinamento de mão de obra estão despontando, mostrando que esta área é um campo promissor a ser explorado.

Aproveitando os atuais avanços da tecnologia de hardware e das pesquisas na área de inteligência computacional (redes neurais artificiais), bem como nas transformadas wavelets. O trabalho tem dois objetivos gerais. O primeiro consiste em estudar a aplicação das Transformadas Wavelets em conjunto com as Redes Neurais Artificiais para atenuar o ruído de rolamento superficial encontrando em imagens sísmicas. Dessa forma o trabalho visa contribuir com o melhoramento das imagens sísmicas, conseqüentemente auxiliando os geofísicos e geólogos no reconhecimento de regiões mais favoráveis para a ocorrência de hidrocarbonetos.

O segundo objetivo consiste em estudar a aplicação conjunta de duas RNAs. Uma RNA para detectar se um pixel é ou não ruidoso, assim como fizeram KALIRAJ e BASKAR (2010) e a segunda RNA para atenuar somente os *pixels* que foram classificados como ruído impulsivo em imagens digitais.

### 1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

O restante desta Dissertação contém quatro capítulos e está organizado da seguinte forma:

**Capítulo 2** aborda conceitos sobre as Redes Neurais Artificiais, incluindo uma breve descrição de seu desenvolvimento, arquiteturas, paradigmas de aprendizagem, bem como o algoritmo *backpropagation* que será utilizado para compor a estrutura das RNAs.

**Capítulo 3** apresenta uma pequena introdução sobre imagens digitais no que diz respeito a propriedades entre pixels. Ainda no Capítulo 3 é apresentando uma breve descrição sobre os tipos de ruído (*ground roll* e impulsivo), bem como uma pequena introdução sobre a teoria das wavelets de Haar e Daubechie no tocante da utilização do método de multiresolução.

**Capítulo 4** traz a metodologia, passos e etapas, utilizados nesta dissertação para desenvolver os métodos que serão usados para detectar e atenuar os tipos de ruídos (*Ground roll* e Impulsivo).

**Capítulo 5** é a conclusão deste trabalho. Nele serão enfatizados os principais resultados sobre os objetivos propostos e, levando em consideração a capacidade de melhorar o desempenho dos métodos, também serão apresentadas propostas para trabalhos futuros.

**Apêndice** contém os trabalhos publicados e submetidos relacionados com esta Dissertação.

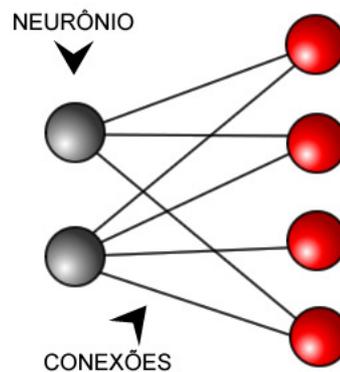
# Capítulo 2

## REDES NEURAIS ARTIFICIAIS

### 2.1 INTRODUÇÃO

As redes neurais são sistemas paralelos distribuídos, compostos por dois tipos de componentes básicos: as unidades de processamento, dispostos em uma ou mais camadas, e interligados por conexões entre eles (BRAGA *et al.*, 2007). As unidades de processamento são chamadas neurônios e as ligações entre eles são conhecidas como conexões ou sinapse, como ilustrado na Figura 1. Cada conexão possui um peso ou parâmetro livre associado. Este peso é usado para amplificar ou atenuar o sinal que chega à conexão. Os neurônios recebem estímulos a partir dos outros neurônios conectados a eles. Os que recebem sinais de fora da rede são chamados neurônios de entrada, os que fornecem sinais para fora da rede são chamados neurônios de saída e os que recebem estímulos de outros neurônios são conhecidos como neurônios ocultos.

Figura 1 - Representação dos Neurônios e Conexões.



**Fonte:** Autoria Própria.

Basicamente, Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neuronal de organismos inteligentes e que adquirem conhecimento através da experiência. Apesar de nem todas as características das RNAs possuírem uma inspiração na biologia existem duas que possuem esta origem:

- O conhecimento é adquirido pela rede neural a partir de seu ambiente através de um processo de aprendizagem;

- O armazenamento de conhecimento é feito entre os neurônios, no caso nas sinapses.

Outras características importantes das RNAs:

- São modelos adaptativos fáceis de treinar;
- Podem representar domínios complexos (não lineares);
- São capazes de generalização diante de informações incompletas;
- São capazes de fazer armazenamento associativo de informações.

## 2.2 INSPIRAÇÃO BIOLÓGICA

Originalmente, o paradigma das Redes Neurais Artificiais surgiu em consequência da busca por conhecimento a respeito da mente humana. Nesse sentido, houve um grande interesse em pesquisar o papel do funcionamento de estruturas do Sistema Nervoso (SN), principalmente o cérebro, o qual motivou a construção de modelos matemático-computacionais que pudessem auxiliar na elucidação de aspectos neurobiológicos envolvidos em diversas atividades cognitivas.

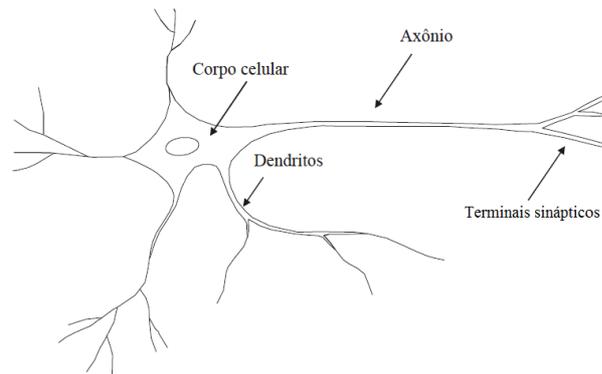
O cérebro humano contém cerca de 10 bilhões de neurônios interconectados, que formam uma rede capaz de processar milhões de informações e realizar em torno de 60 trilhões de conexões sinápticas (VALENÇA e LUDEMIR, 1999). Além disso, sua rede de neurônios tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência.

As RNAs tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento funcional e sua dinâmica. Acredita-se, portanto, que o futuro da neurocomputação possa se beneficiar ainda mais do desenvolvimento de modelos que tenham apelo biológico (BRAGA *et al.*, 2007).

## 2.3 NEURÔNIOS BIOLÓGICOS

Os neurônios biológicos são divididos, de maneira simplificada, em quatro seções: o corpo celular, os dendritos, o axônio e os terminais sinápticos, cada um com funções específicas, porém complementares (Figura 2).

Figura 2 – Neurônio biológico.



Fonte: Adaptado de Ferneda (2006).

O corpo celular de um neurônio é a parte central da célula onde estão contidos o núcleo e o citoplasma celular. Projetando-se a partir do corpo celular estão os dendritos, que têm por função receber as informações (ou impulsos nervosos) originárias de outro neurônio e conduzi-las até o corpo celular. Aqui, a informação é processada e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios, passando através do axônio até os terminais sinápticos que se ligam aos dendritos dos neurônios seguintes. O ponto de contato entre os terminais sinápticos de um neurônio e o dendrito de outro é chamado de sinapse (BRAGA *et al.*, 2007).

As sinapses são os locais onde os impulsos nervosos são transmitidos de uma célula pré-sináptica (o neurônio) para uma célula pós-sináptica (outro neurônio). Assim, as sinapses permitem que os neurônios se comuniquem uns com os outros (GARTNER e HIATT, 1997).

O neurônio que transmite o impulso pode controlar a frequência do mesmo aumentando ou diminuindo a polaridade na membrana pós-sináptica. Os impulsos são transferidos a centros superiores para processamento e interpretação de sensações ou para início de respostas motoras (GARTNER e HIATT, 1997). A capacidade de realizar funções complexas surge com a operação em paralelo de todos os neurônios do nosso sistema nervoso (BRAGA *et al.*, 2007).

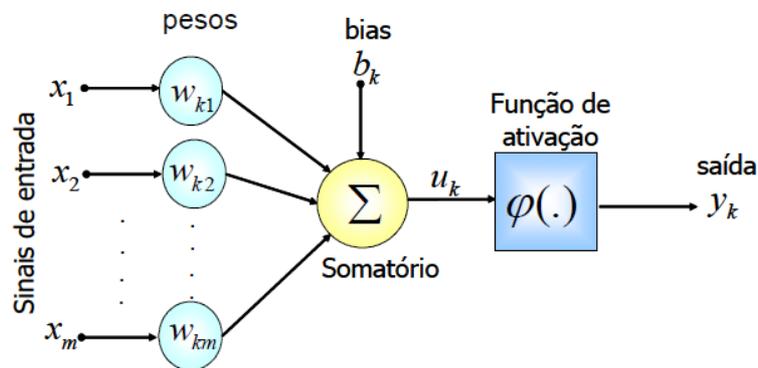
## 2.4 NEURÔNIOS ARTIFICIAIS

O modelo inicial para um neurônio artificial foi proposto por MCCULLOCH e PITTS (1943) e posteriormente aprimorado por ROSENBLATT (1958), que nomeou de *perceptron* (Figura 3). Ele representa uma aproximação extremamente simplificada sob ótica

neurofisiológica, no entanto conserva algumas das características básicas do neurônio biológico e viabiliza a sua implementação computacional.

Os neurônios artificiais, assim como os neurônios biológicos, possuem conexões de entrada (dendritos) e de saída (axônios). Adicionalmente, assim como os neurônios reais, possuem uma forma de processamento interno que gera um sinal de saída em função do sinal de entrada. Entretanto, enquanto a saída de um neurônio biológico está em constante alteração no tempo, a de um neurônio artificial muda somente em intervalos discretos no tempo, isto é, quando os dados de entrada mudam (BATTISTELLA, 2004).

Figura 3 - Modelo não-linear de neurônio artificial



Fonte: Adaptada de Haykin (2001).

A partir da estrutura acima se pode formular um modelo matemático do neurônio artificial descrito pelas Equações 1 e 2, que é composto basicamente pelos elementos:

- sinais de entrada ( $x_1, x_2, \dots, x_m$ );
- conjunto de pesos ( $w_{k1}, w_{k2}, \dots, w_{km}$ );
- somatório ( $\Sigma$ );
- função de ativação [ $\varphi(\cdot)$ ];
- saída ( $y_k$ ).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(v_k + b_k) \quad (2)$$

Onde  $(x_1, x_2, \dots, x_m)$  são as entradas, quem podem ser estímulos do sistema ou saídas de outros neurônios. Cada entrada é multiplicada por um peso correspondente  $(w_{k1}, w_{k2}, \dots, w_{km})$ , gerando entradas ponderadas. Logo após, todas as entradas ponderadas são somadas e o valor de saída do combinador linear  $(u_k)$  será comparado com um valor limite para ativação do neurônio. Caso o valor da soma alcance o valor limite para ativação, o neurônio será ativado, caso contrário, ficará inativo. A saída  $y_k$  é o valor processado pela função de ativação  $\varphi(\cdot)$ .

As conexões possuem pesos sinápticos associados a elas e pode-se dizer que é neles que reside todo o conhecimento adquirido pela rede. Os pesos é que são os parâmetros ajustáveis e que mudam e se adaptam à medida que o conjunto de treinamento é apresentado à rede.

O bias  $(b_k)$  é um parâmetro externo ao neurônio, tem o efeito do acréscimo ou decréscimo da função de ativação na entrada da rede, além de evitar erros quando os dados de entrada são nulos.

A função de ativação também conhecida como *função de transferência* ou *função restritiva* já que restringe (limita) o intervalo normalizado permissível de amplitude do sinal de saída a um valor finito. Tipicamente, a ordem de amplitude normalizada da saída do neurônio está no intervalo  $[0, 1]$  ou alternativamente  $[-1, 1]$  (HAYKIN, 2001). Cada neurônio possui a sua função de ativação, responsável pela intensidade do sinal a ser transmitido para as camadas seguintes (VALENÇA e LUDEMIR, 1999). Entre as funções de ativação mais utilizadas citam-se a degrau, linear e a sigmóide:

- a) **Função degrau:** Neste tipo de função, a saída de um neurônio assume valor 1, se o campo local induzido daquele neurônio é não-negativo, e 0 caso contrário.
- b) **Função linear:** é a função que não limita a saída da rede e é usada para armazenar entrada e saída de dados. Os neurônios que possuem esta função atuam como aproximadores lineares.
- c) **Função Sigmóide:** A função sigmóide, é de longe, a forma mais utilizada de função de ativação utilizada na construção de redes neurais (BRAGA *et al.*, 2007). Ela é definida como uma função estritamente crescente que exhibe um balanceamento adequado entre comportamento linear e não-linear. Existem dois tipos possíveis de implementação para funções sigmóides: a sigmoidal logística (*Logsig*) e a tangente hiperbólica (*Tansig*). A diferença fundamental entre essas funções é que enquanto a função *Logsig* gera saídas em num intervalo de 0 a 1, a função *Tansig* assume valores de saída de -1 a 1.

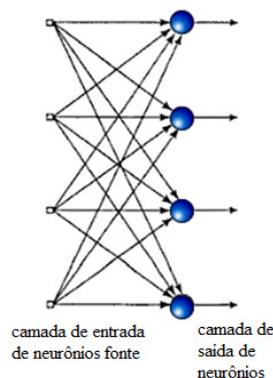
## 2.5 ARQUITETURA DAS RNAs

A arquitetura da rede, também conhecida como topologia, refere-se à maneira como os neurônios da rede estão organizados. Existem várias estruturas que diferem umas das outras em função do número de camadas e neurônios, bem como pela forma como seus neurônios interagem (SILVA *et al.*, 2004).

Quanto à alimentação ou a forma na qual as entradas são apresentados à rede, as redes neurais podem ser subdivididas em três classes de arquiteturas: redes recorrentes (*feedback*) e redes de alimentação direta (*feedforward*), sendo que esta última divide-se em duas classes, camada única e múltiplas camadas (*Multilayer Feedforward*).

As redes de alimentação direta com camada única ou acíclica se caracterizam pela propagação dos sinais em apenas uma direção a partir da camada de entrada até a camada de saída e não vice-versa (HAYKIN, 2001). Esse tipo de rede está ilustrado na Figura 4. O termo camada única refere-se à camada de saída de nós computacionais (neurônios), não se conta a camada de entrada de nós da fonte, pois lá não é realizada nenhuma computação.

Figura 4 - Rede de alimentação direta com uma única camada de neurônios.

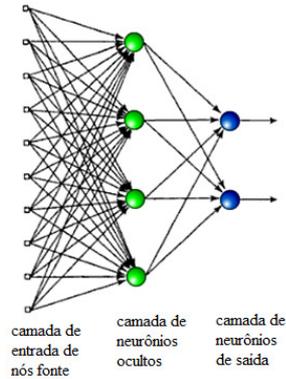


**Fonte:** Adaptada de Haykin (2001).

As redes neurais com alimentação direta ou múltiplas camadas se diferenciam pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas (HAYKIN, 2001). A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede neural de uma maneira útil, tornando a mesma capaz de extrair estatísticas de ordem elevada. A Figura 5 mostra um exemplo de rede de alimentação direta, com uma camada oculta.

As redes com alimentação direta de múltiplas camadas (*Multilayer Feedforward*) comumente denominadas de MLP (*Multilayer Perceptron*) são as redes mais difundidas na literatura e que serão utilizadas neste trabalho.

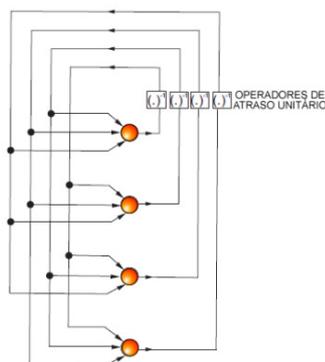
Figura 5 - Rede com alimentação direta com 1 camada oculta e 1 camada de saída



**Fonte:** Adaptada de Haykin (2001)

As redes recorrentes se distinguem das redes neurais alimentadas adiante por ter pelo menos um laço de realimentação (HAYKIN, 2001). Outra característica nessas redes é que os sinais de saída dependem não somente dos sinais de entrada, mas também do seu valor atual (BRAGA *et al.*, 2007). Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, como ilustrado na Figura 6.

Figura 6 - Exemplo de uma rede Recorrente



**Fonte:** Adaptada de Haykin (2001)

A definição do número de camadas e neurônios em cada camada é realizada através da inspeção prévia dos dados e da complexidade do problema. Após a seleção da arquitetura

inicial da rede, refinamentos sucessivos são realizados de forma a se obter uma estrutura final mais adequada.

Pesquisadores como HECHT-NIELSEN (1989), afirmam que com apenas uma camada intermediária na rede neural, já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. Segundo CYBENKO (1989), uma camada intermediária é suficiente para aproximar qualquer função contínua e duas camadas intermediárias aproximam qualquer função matemática.

Em XUEPING MA *et al.*, (2009) os autores afirmam que uma rede neural típica possui três ou mais camadas (entrada, meio ou oculta e saída), como mostra a Figura 5. Já KALIRAJ e BASKAR (2010) afirmaram que não existe método analítico para escolher o número de camadas e neurônios ocultos de uma rede neural, uma vez que estes dependem da complexidade do problema, sendo então determinados experimentalmente por tentativa e erro.

## 2.6 PERCPETRON MULTI CAMADAS (*MULTILAYER PERCEPTRON*)

O modelo proposto por Rosenblatt em 1958, conhecido com *Perceptron* é o modelo mais simples de RNA. Sua estrutura básica consiste em um nível de entrada e saída de unidades de processamento, como pesos e *bias* ajustáveis. Em 1969, Minsky e Papert provaram matematicamente que esse tipo de estrutura apresenta limitações, ou seja, o *perceptron* é capaz de resolver apenas problemas linearmente separáveis.

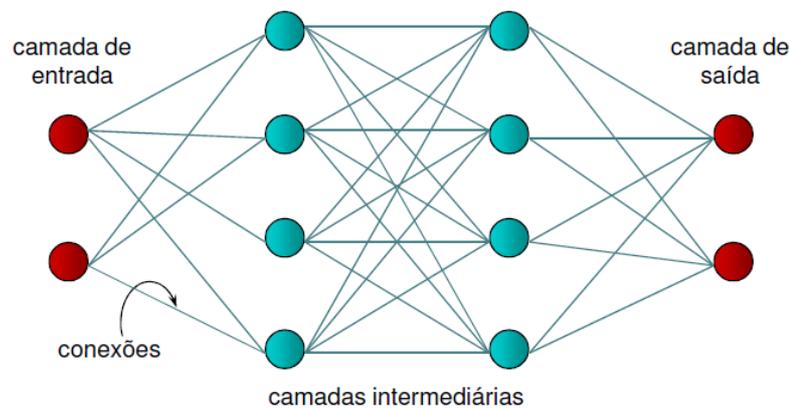
Segundo SARLE (1994), ao introduzir-se na rede uma camada extra de neurônios, chamada de intermediária ou camada oculta e se o modelo inclui pesos, estimados entre a camada de entrada e a camada oculta, e a camada oculta usa função de ativação não linear, tal como a função logística, o modelo torna-se genuinamente não linear. O modelo resultante é chamado de *Multilayer Perceptron* ou MLP (Figura 7). Com a MLP muitas limitações encontradas pelo *perceptron* deixam de existir. Este avanço foi possível através da utilização de, pelo menos, uma camada entre a camada de entrada e a camada de saída. Estas camadas intermediárias trabalham como um reconhecedor de características, que ficam armazenadas nos pesos sinápticos.

Uma MLP possui três características distintas:

- I- O modelo de cada neurônio da rede inclui uma função de ativação não-linear.
- II- A rede contém uma ou mais camadas de neurônios ocultos, que não fazem parte da entrada ou da saída da rede.
- III- A rede exibe um alto grau de conectividade, determinado pelas sinapses da rede.

É através da combinação destas características, juntamente com a habilidade de aprender da experiência do treinamento, que a MLP apresenta um poder computacional maior do que aquele apresentado pelas redes neurais sem camadas intermediária, podendo implementar qualquer função seja ela linearmente separável ou não (SILVA *et al.*, 2004). Estas mesmas características, entretanto, são também responsáveis pelas deficiências no estado atual de nosso conhecimento sobre o comportamento da rede. Primeiro, a presença de uma forma distribuída de não-linearidade e alta conectividade da rede tornam difícil a análise teórica de um *perceptron* de múltiplas camadas. Segundo, a utilização de neurônios ocultos torna o processo de aprendizagem mais difícil de ser visualizado.

Figura 7 - Representação de uma MLP



**Fonte:** Adaptada de Haykin (2001)

## 2.7 GENERALIZAÇÃO EM UMA RNA

Capacidade de generalização em RNA é a capacidade desta, devidamente treinada, responder coerentemente a padrões desconhecidos. Ao termo "padrões desconhecidos" fica subentendido que seja um conjunto de padrões extraídos da mesma população dos conjuntos dos dados de treinamento, ou seja, dados com mesma características dos padrões de treinamento (BRAGA *et al.*, 2007).

Não existe uma regra para escolher o tamanho do conjunto de treinamento. Cada problema abordado requer uma quantidade de amostra capaz de representá-lo. A complexidade do problema bem como a escolha da arquitetura adequada é um dos desafios no estudo da capacidade de generalização.

A priori, quanto mais camadas de neurônios, melhor seria o desempenho da rede neural, pois aumenta a capacidade de aprendizado, melhorando a precisão com que ela

delimita regiões de decisão. Mas, na prática, aumentar o número de camadas intermediárias, às vezes, se torna inviável devido ao trabalho computacional.

Modelos com arquiteturas muito grandes elevam sua complexidade. Quando a complexidade do modelo é maior que a necessária para modelar o problema, a rede tende a ficar super-ajustada aos dados de treinamento, respondendo erroneamente aos padrões de validação e teste.

Uma rede que é projetada para generalizar bem produzirá um mapeamento correto da entrada → saída mesmo quando as entradas forem um pouco diferentes dos exemplos utilizados para o treinamento da rede. Se uma rede é treinada em excesso, ela perde a habilidade de generalizar entre padrões de entrada → saídas similares (HAYKIN, 2001).

## 2.8 PARADIGMAS DE APRENDIZAGEM

A propriedade que é de importância primordial para uma rede neural é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. Uma rede neural aprende acerca do seu ambiente através de um processo interativo de ajustes aplicados a seus pesos sinápticos e níveis de bias.

HAYKIN (2001) definiu aprendizagem como um processo pelo qual os parâmetros da rede e os pesos das conexões são ajustados através de um processo de estimulação pelo ambiente no qual a rede está inserida, e que no final do processo o conhecimento que a rede adquiriu é armazenado.

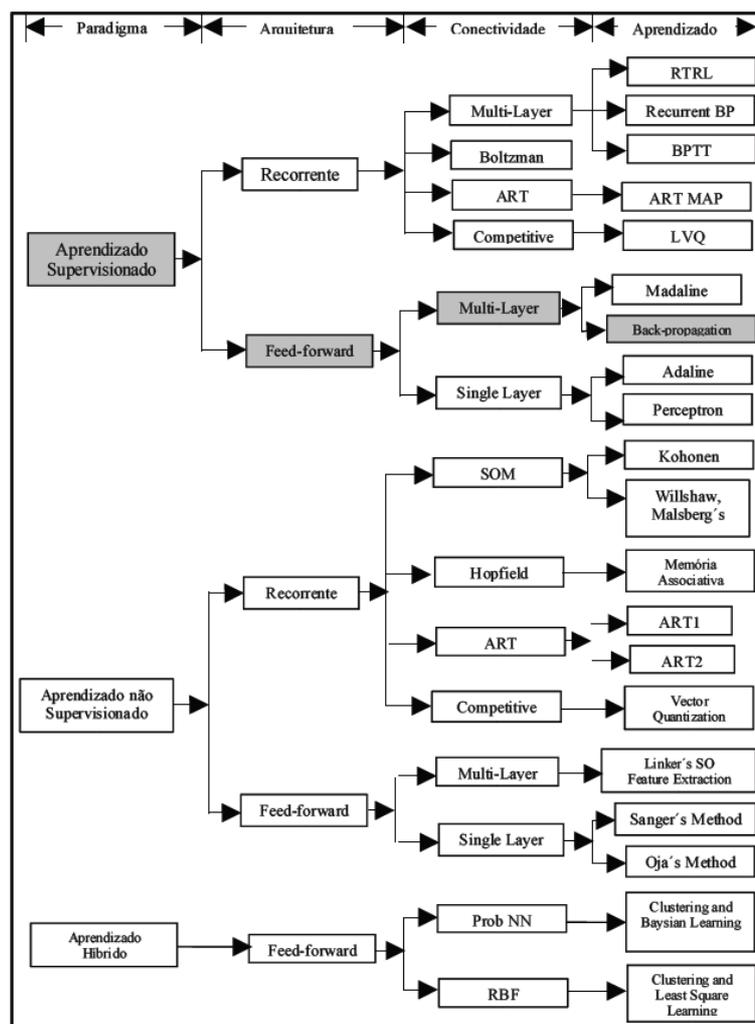
Apesar de existirem diversos métodos (regras como p.ex., correção do erro, aprendizagem *hebbiana*, aprendizagem competitiva e aprendizagem *boltzmann*) para o treinamento de redes neurais, estes podem ser agrupados em dois paradigmas principais: aprendizagem supervisionado e aprendizagem não-supervisionado (SILVA *et al.*, 2004).

- a) **Aprendizagem supervisionada:** este aprendizado que é também denominado aprendizagem com um professor, é um método implementado através da disponibilização de um professor que verifique os desvios da rede a um determinado conjunto de dados de entrada e saída. Toda vez que for apresentado à rede uma entrada, deverá ser verificado se a saída obtida confere com a saída desejada para aquela entrada. Sendo diferente a rede deverá ajustar os pesos de forma que fique armazenado o conhecimento desejado. O processo é repetido com todo o conjunto de treinamento, até que a taxa de acerto esteja dentro de um valor considerado.

- b) aprendizagem não-supervisionada:** este aprendizado não há um professor externo para supervisionar o processo de aprendizado, onde somente os padrões de entradas são fornecidos a rede. A rede trabalha essas entradas e se organiza de modo que acabe classificando-as, usando, para isso, os seus próprios critérios. Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entradas como elementos para classificação.

Um quadro retirado de MENDONÇA (2004) mostrado pela Figura 8, mostra de forma resumida como as redes neurais podem ser classificadas quanto a sua topologia e forma de treinamento. Neste trabalho serão consideradas apenas as redes *feedforward* Multicamadas treinadas com algoritmos que utilizam o *backpropagation*.

Figura 8 – Quadro com classificação das RNAs



Fonte: Mendonça (2004).

## 2.9 ALGORITMO DA RETROPROPAGAÇÃO (*BACKPROPAGATION*)

O algoritmo de aprendizagem de rede MLP mais popular é o *backpropagation* (ou retropropagação de erros) (PATNAIK e MISHRA, 2000). Por ser supervisionado, utiliza pares de entrada e saída para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede.

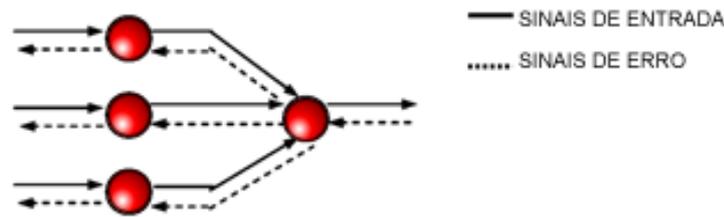
O ajuste dos pesos realizado pelo algoritmo de retropropagação de erros é baseado na regra delta, proposto por Widrow e Hoff, e é utilizada para o treinamento de redes *Adaline*. A generalização desse algoritmo para redes de múltiplas camadas é conhecida como regra delta (BRAGA *et al.*, 2007) e consiste na aplicação do gradiente descendente (VALENÇA e LUDERMIR, 1999).

O gradiente descendente tem como objetivo a determinação de um mínimo global, através de incrementos dos valores dos pesos por uma quantidade que é proporcional a primeira derivada (gradiente) do erro entre o valor desejado e o valor calculado pela rede (SILVA *et al.*, 2004). O mínimo local é a solução teórica ideal que apresenta o menor erro possível. No entanto, a rede pode apresentar mínimos locais, o que pode ocasionar uma parada durante o treinamento num desses mínimos que não correspondem à solução ótima (VALENÇA e LUDERMIR, 1999).

O treinamento através do algoritmo de retropropagação de erros consiste em dois passos através das diferentes camadas da rede: um passo para frente, *Feed-forward* (a propagação), e um passo para trás, *Feed-backward* (retropropagação) (HAYKIN, 2001). A Figura 9 ilustra esses dois passos.

- a) ***Feed-forward*** → um padrão de atividade (vetor de entrada) se propaga pela rede, da camada de entrada até a camada de saída e finalmente um conjunto de saídas é produzido como resposta real da rede, durante esse passo os pesos sinápticos da rede são todos fixos;
- b) ***Feed-backward*** → a resposta real é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. O erro se propaga na direção contrária ao fluxo de dados, indo da camada de saída até a primeira camada escondida, ajustando os pesos sinápticos das camadas.

Figura 9 - Ilustração de dois sinais, a propagação (entradas) e a retropropagação (erro).



Fonte: Adaptada de Haykin (2001).

O algoritmo *backpropagation* padrão é lento para várias aplicações, principalmente em problemas com alto índice de complexidade. Em função dessa limitação, várias modificações têm sido propostas visando tanto acelerar seu tempo de treinamento quanto a melhorar seu desempenho. A literatura apresenta diversas variações do algoritmo da *backpropagation*, desenvolvidos em sua grande maioria, para tentar minimizar a perda de desempenho. Dentre as várias variações dos algoritmos da *backpropagation* ou algoritmo da retropropagação, podemos destacar: o *backpropagation* com *momentum*, *Quickprop*, *Levenberg-Marquardt*, *momentum* de segunda ordem, *Newton* e *Rprop* (*resilient backpropagation*) (BRAGA *et al.*, 2007). Uma dessas variações, o algoritmo *Levenberg-Marquardt*, é discutido a seguir por ser o algoritmo de treinamento usado nesse trabalho.

### 2.9.1 Algoritmo *Levenberg-Marquardt*

Ao contrário do algoritmo de treinamento *backpropagation*, que é baseado no método do gradiente descendente, o algoritmo *Levenberg-Marquardt* é uma aproximação do método de Newton. Ele melhora o método de Gauss-Newton por meio de utilização de uma taxa de atualização variável.

Proposto para ajuste de pesos da rede por ciclo. O algoritmo *Levenberg-Marquardt* é uma técnica de otimização numérica que demanda uma grande quantidade de memória e eleva a complexidade computacional, o que tornar sua utilização ineficiente para redes muito grande (BRAGA *et al.*, 2007). Quando esse algoritmo é utilizado, os pesos da rede são ajustados de acordo com a Equação 3:

$$\Delta w_{ij}(t) = - \left[ \nabla^2 E(w_{ij}(t)) + \mu I \right]^{-1} \nabla E(w_{ij}(t)) \quad (3)$$

Onde,  $\nabla^2 E(w_{ij}(t))$  é uma matriz *Hessiana* e  $\nabla E(w_{ij}(t))$  é o gradiente. O parâmetro  $\mu$  é multiplicado por um fator  $\beta$  quando um ajuste tem por objetivo o aumento de  $E(w_{ij}(t))$ . Quando o objetivo é reduzir o valor de  $E(w_{ij}(t))$  a cada passo,  $\mu$  é dividido por  $\beta$ . Quando é utilizado um valor grande para  $\mu$ , o algoritmo se torna gradiente descendente (com passo  $1/\mu$ ). Quando o valor escolhido para  $\mu$  é baixo, o algoritmo é equivalente ao algoritmo Gauss-Newton (BRAGA *et al.*, 2007).

# Capítulo 3

## PROCESSAMENTO DIGITAL DE IMAGENS

### 3.1 INTRODUÇÃO

O interesse em métodos de processamento digital de imagens decorre de duas áreas principais de aplicações: melhoria de informação visual para a interpretação humana e o processamento de dados de imagens para armazenamento, transmissão e representação, considerando a percepção automática por máquinas.

De 1964 aos dias atuais, a área de processamento digital de imagens vem apresentando crescimento expressivo e suas aplicações permeiam praticamente todas as áreas de empreendimento técnico da atividade humana. As áreas de aplicação do processamento digital de imagens são tão variadas que requerem alguma forma de organização para que todo seu escopo seja incluído. De acordo com GONZALEZ e WOODS (2010) uma forma básica de desenvolver uma compreensão da extensão das aplicações do processamento de imagens é categorizar as imagens de acordo com sua fonte, como por exemplo:

1. O espectro eletromagnético;
2. Eletrônica;
3. Ultrassônica;
4. Geradas por computador (Imagem Sintética);
5. Acústica

Em Medicina, o uso de imagens no diagnóstico médico tornou-se rotineiro e os avanços em processamento de imagens vêm permitindo tanto o desenvolvimento de novos equipamentos quanto a maior facilidade de interpretação de imagens produzidas por equipamentos mais antigos, como por exemplo, os de raios-X (eletromagnético). Em Biologia, a capacidade de processar automaticamente imagens obtidas de microscópios, por exemplo, contando o número de células de certo tipo presentes em uma imagem, facilita sobremaneira a execução de tarefas laboratoriais com alto grau de precisão e repetibilidade (eletrônica). Na obstetrícia, imagens ultrassônicas são usadas para descobrir o sexo de um bebê além do seu desenvolvimento e saúde. A geração de padrões é uma das formas mais simples de gerar uma imagem artificial no computador, que são usadas na modelagem 3-D. A

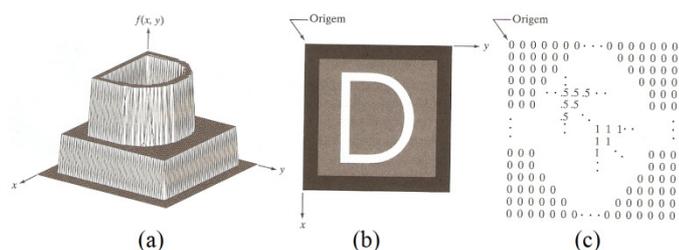
aquisição de imagens (sísmicas) a partir da superfície do solo tem aplicações comerciais muito importantes no que diz respeito à exploração de minérios e petróleo (Acústica). A seção 3.3 aborda um pouco mais sobre sísmica de reflexão, tendo em vista que esse trabalho é desenvolvido em cima de imagens sísmicas.

### 3.2 FUNDAMENTOS DAS IMAGENS DIGITAIS

Uma imagem monocromática pode ser descrita matematicamente por uma função bidimensional  $f(x, y)$ , em que  $x$  e  $y$  são coordenadas espaciais (plano), e a amplitude de  $f$  em qualquer par de coordenadas  $(x, y)$  é chamada de *intensidade* ou *nível de cinza* da imagem nesse ponto. Quando  $x$ ,  $y$  e os valores de intensidade de  $f$  são quantidades finitas e discretas, temos uma *imagem digital*. Observa-se que uma imagem digital é composta de um número finito de elementos, cada um com uma localização e valor específico. Esses elementos são chamados de *elementos pictóricos*, *elementos de imagem*, *pels* e *pixels*.

Como mostra a Figura 10, há três formas básicas de representar  $f(x, y)$ . A Figura 10(a) é uma representação gráfica da imagem, com dois eixos determinando a localização espacial e o terceiro eixo representando os valores de  $f$  (intensidades) como uma função das duas variáveis espaciais  $x$  e  $y$ . Já a representação da Figura 10(b) é a mais comum. Ela mostra  $f(x, y)$  como uma imagem seria visualizada em um monitor ou uma fotografia. Nela, o nível de cinza de cada ponto é proporcional ao valor da intensidade  $f$  desse ponto. Na Figura 10(b) a intensidade está sendo representado por 3 valores igualmente espaçados e normalizados no intervalo  $[0, 1]$ . Sendo eles 0; 0,5 ou 1 que representam o preto, cinza e branco respectivamente. A terceira representação, Figura 10(c), são os valores numéricos de  $f(x, y)$  em forma de uma matriz. Nesse exemplo, o tamanho de  $f$  é de  $600 \times 600$  elementos, ou 360.000 números (*pixels*).

Figura 10 – Representações de uma imagem. (a) Graficamente como uma superfície. (b) Como uma matriz de intensidade visual. (c) Como uma matriz numérica 2-D.



Fonte: Adaptada de Gonzalez e Woods (2010).

### 3.3 PROPRIEDADES BÁSICAS ENTRE PIXELS

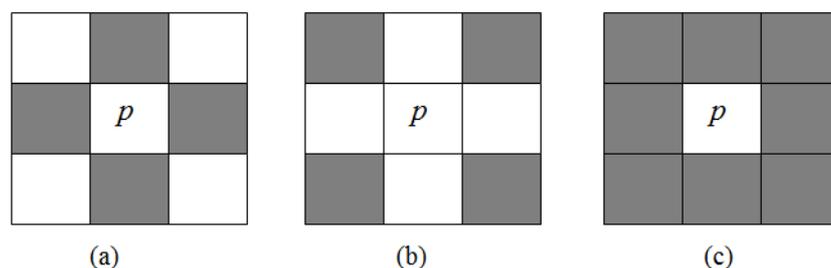
Existem algumas relações importantes entre *pixels* em uma imagem digital. Como por exemplo, adjacência, conectividade, regiões e fronteiras e vizinhança de um *pixel*. No entanto, esse trabalho abordará apenas as propriedades de vizinhança de um *pixel*. Para mais detalhes a respeito das outras propriedades veja GONZALEZ e WOODS (2010) e MARQUES FILHO e VIEIRA NETO (1999).

#### 3.3.1 Vizinhos de um pixel

Nesta seção, ao referir-se a um *pixel* em particular, as letras minúsculas  $p$  e  $q$  serão usadas. Um *pixel*  $p$  na coordenada  $(x, y)$  tem quatro vizinhos, sendo 2 horizontais e 2 verticais cujas as coordenadas são dadas por:  $(x+1, y)$ ,  $(x-1, y)$ ,  $(x, y+1)$ ,  $(x, y-1)$ . Esse conjunto de *pixels* é chamado de "vizinhança-4" de  $p$  e é expresso por  $N_4(p)$ . Cada *pixel* é uma unidade de distância de  $(x, y)$ , e alguns vizinhos de  $p$  ficarão para fora da imagem se  $(x, y)$  estiver na borda.

Os quatro vizinhos diagonais de  $p$  têm coordenadas:  $(x+1, y+1)$ ,  $(x+1, y-1)$ ,  $(x-1, y+1)$ ,  $(x-1, y-1)$  que são expressas por  $N_d(p)$ . Esses pontos, junto com a vizinhança-4, são chamados de vizinhança-8 de  $p$ , expresso por  $N_8(p)$ . Os três tipos de vizinhança são representados pela Figura 11.

Figura 11 – (a) Vizinhança-4 ( $N_4(p)$ ). (b) Vizinhança diagonal  $N_d(p)$ . (c) Vizinhança-8  $N_8(p)$ .



**Fonte:** Adaptada de Marques Filho e Vieira Neto (1999).

### 3.4 SONDAGEM SÍSMICA

O ambiente geológico onde o petróleo é gerado e armazenado é um meio poroso aleatório e complexo, possuindo heterogeneidade em largo espectro de escalas. Este ambiente

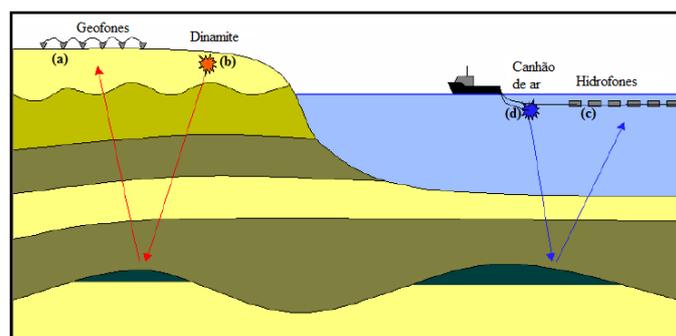
está localizado, em geral, a milhares de metros de profundidade na crosta terrestre, estendendo-se por uma grande área e com algumas dezenas de metros de espessura.

A sondagem sísmica é um método de exploração do subsolo terrestre, onde se faz uso de aparelhos e técnicas especiais, visando o seu reconhecimento para uma caracterização. Este método tem sido comumente utilizado pelo fato de ser capaz de "cobrir" áreas enormes e economicamente viáveis, caracterizando-se, assim, por uma observação cautelosa do meio terrestre. Nesse sentido, é empregada na localização de jazidas de petróleo e na detecção de falhas geológicas. A sondagem é uma atividade rotineira na indústria do petróleo e tem por objetivo a obtenção de uma representação da geologia de subsuperfície. A obtenção de dados desse ambiente é feita através da sondagem, que pode ser conduzida por métodos diretos, como a perfuração de um poço, que tem um custo bastante elevado ou aplicar métodos indiretos (como a sísmica de reflexão), que tem um custo bastante moderado e fornecem informações detalhadas do subsolo, embora sujeitas a interpretações e visualização (YILMAZ (2003) e THOMAS (2001)).

### 3.5 PROSPECÇÃO SÍSMICA

Na prospecção de petróleo, há uma preocupação em obtê-lo de forma economicamente viável. Por isso, antes de perfurar um poço, deve-se garantir uma probabilidade alta de acúmulo de petróleo na região a ser explorada. No entanto, faz-se necessário um estudo elaborado das propriedades dessa área, pois as estruturas geológicas associadas com um reservatório são muito complexas e, uma alternativa que não requer a perfuração de um poço, que é uma operação bastante onerosa, consiste na sondagem das camadas do subsolo (representada na Figura 12).

Figura 12 – Esquema da aquisição terrestre e marítima de dados sísmicos.



Fonte: Adaptada de Oliveira (2009).

Esse processo inicia-se com a geração de ondas sísmicas<sup>1</sup> as quais são geradas artificialmente por explosões na superfície ou em pequenas profundidades (representada por (b) na Figura 12). Essas ondas se propagam em todas as direções. Portanto, propagam-se para o interior da Terra. Devido à heterogeneidade do meio, essas ondas sofrem fenômenos de refração e reflexão, retornando-as à superfície, ondas são captadas por um arranjo de receptores previamente distribuídos uniformemente (representado por (a) na Figura 12).

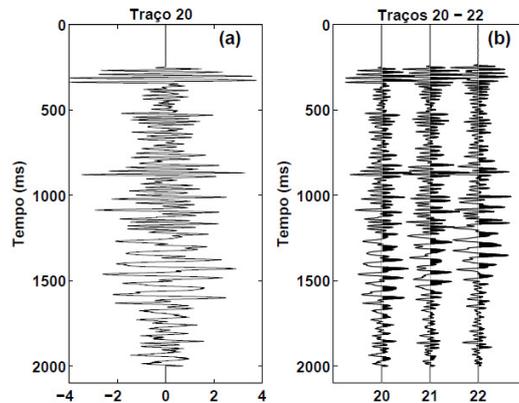
A sísmica empregada na exploração de hidrocarbonetos, em geral, está compreendida em três etapas (YILMAZ, 2003): (i) aquisição dos dados sísmicos que compreende ao levantamento (registro das medidas - dados) dos dados, (ii) processamento sísmico com vista na obtenção das imagens e (iii) interpretação sísmica que compreende a interpretação destas imagens para efetivamente localizar feições de interesse. A aquisição sísmica diz respeito à obtenção dos dados durante um levantamento sísmico, que pode ser terrestre ou marítimo, como ilustrado na Figura 12. Esse processo envolve a geração de ondas sísmicas para levantamentos terrestres e marítimos. Esse processo envolve a geração da onda sísmica (região (b) e (d) da Figura 12) e sua captação na superfície por uma formação previamente ordenada de receptores (geofonemas para levantamentos terrestres (a) e hidrofones para marítimos (c)). As fontes de ondas sísmicas mais convencionais são a explosão de dinamite, para um levantamento terrestre, e disparos de canhões de ar comprimido, para levantamentos marítimos. Na modelagem inicial, é preciso definir a geometria de aquisição onde se deve estabelecer a quantidade de receptores, distância entre a fonte e o primeiro receptor bem como a distância entre os demais. Os receptores fazem uma leitura simultânea que transformam as vibrações do solo em sinais elétricos. Em intervalos de tempo  $dt$  os receptores verificam se existem sinais retornando à superfície. Cada receptor registra um traço sísmico. Cada traço é uma função do tempo de ida e volta da onda, e o conjunto de traços gravados (pelo arranjo de geofones) forma um sismograma.

O sismograma pode ser definido como uma matriz de dados em que os receptores representam as colunas e as linhas são os instantes de tempo, e em seu conteúdo, tem-se armazenamento das amplitudes das ondas capturadas. Na Figura 13(a) tem-se a representação de um traço sísmico como sendo uma série temporal. Já na Figura 13(b) tem-se uma sequência de três traços (20 – 22 do sismograma da Figura 14).

---

<sup>1</sup> São ondas de natureza mecânica que transportam energia de deformação elástica que se propagam no meio em que foram geradas. A velocidade dessas ondas depende das propriedades elásticas e da densidade do meio.

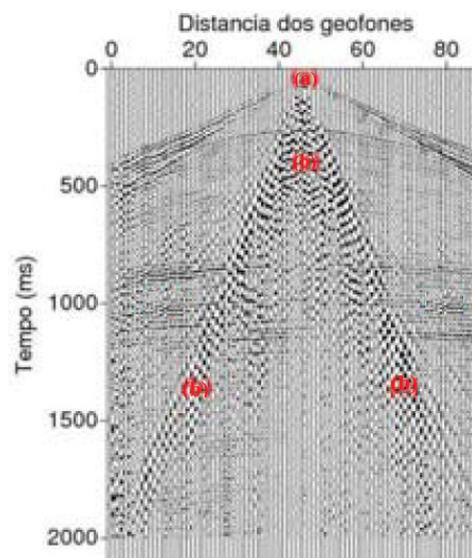
Figura 13 – Representação para os traços sísmicos. (a) traço sísmico em seu formato original (série temporal) onde na horizontal têm-se as amplitudes e na vertical a quantidade de amostras (temporal). Esse traço é o número 20 do sismograma representado na Figura 14. Em (b) tem-se a representação para os traços 20 a 22 para o mesmo sismograma.



Fonte: Leite (2007).

A Figura 14 está representando o aspecto (família de traços originados de um único ponto de tiro – Figura 14(a)) de um sismograma em geometria 2D. Esse termo se refere ao arranjo formado por receptores e fonte em uma mesma linha reta. O registro sísmico da Figura 14 foi obtido em terra e corresponde ao registro 25 como está descrito na referência (YILMAZ, 2003) e disponível em (STOCKWELL, 2000).

Figura 14 – Registro sísmico 2D terrestre. O eixo vertical está definido em unidades de tempo (ms). Na horizontal representa o afastamento entre geofones (m) e cada geofone representa um traço. Em (a) tem-se o local onde ocorreu a geração das ondas sísmicas (fonte). Em (b) "cone" de ruído *ground roll*.



Fonte: Adaptado de Stockwell (2000).

Os dados registrados em levantamento sísmico contém uma quantidade de trajetórias possíveis que correspondem a sequências de eventos. Então, o processamento sísmico compreende um conjunto de técnicas que atuam sobre os dados de forma a retirar ou minimizar eventos indesejáveis de forma que as imagens visualizadas sejam uma "fidelidade" máxima possível das camadas geológicas. A visualização é realizada adequando-se as trajetórias possíveis das características de atributos sísmicos aos seus posicionamentos com o objetivo último de facilitar a interpretação. A interpretação sísmica consiste na representação de um modelo geológico (ou mapas estruturais) compatível com as feições geológicas dos registros sísmicos (sismogramas). É um problema difícil, uma vez que, por natureza, os dados obtidos são não lineares e possuem uma concentração enorme de informações num espaço bem definido. Isto é, diversas configurações geológicas podem ser observadas simultaneamente nos dados e, nesse sentido, há uma dependência enorme do observador (observador humano) em associar estruturas geológicas de interesse com estruturas espúrias. O objetivo principal é determinar a posição e a altitude dos refletores e inferir um modelo para as estruturas geológicas.

### 3.6 RUÍDO DE ROLAMENTO SUPERFICIAL (*GROUND ROLL*)

O sismograma, em sua formação traço-a-traço, apresenta certa variedade de estruturas regulares classificadas como coerentes. E é exatamente nessa quantidade variada de estruturas que se pode revelar informações a respeito da geologia da área explorada. Na Figura 15, pode ser observado, visualmente, algumas estruturas. Dentre essas, é bem visível na região A o ruído de rolamento superficial (*ground roll*). Este sinal está sempre presente nos levantamentos terrestres e representa o principal tipo de ruído coerente.

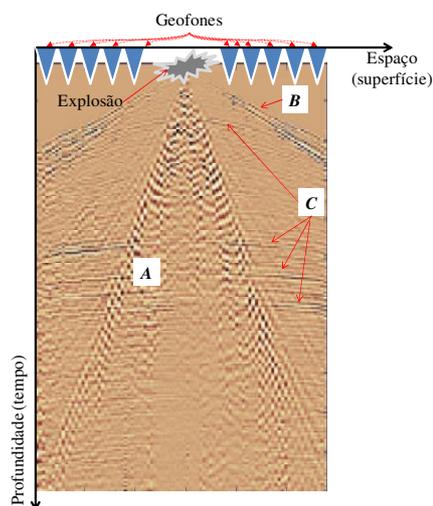
Por definição, considera-se ruído qualquer tipo de informação indesejada que obstrui a aquisição e o processamento da informação desejada (MARQUES FILHO e VIEIRA NETO, 1999).

Durante a obtenção dos dados sísmicos, cerca de dois terços da energia produzida corresponde a este tipo de ruído de rolamento, também conhecido por ondas de "Rayleigh" (LEITE, 2008). Estas formas de onda se propagam na superfície como ondas rolantes e são caracterizadas pela baixa frequência, baixa taxa de decaimento e alta amplitude (YILMAZ, 2003). Dessa forma, as amplitudes que constituem o *ground roll*, não carregam informações sobre as estruturas geológicas mais profundas, tornado-se um sinal indesejável, se sobrepondo nas camadas de interesse, mascarando as informações relevantes para a interpretação das

imagens. Nos sismogramas, ele aparece, geometricamente, na forma de um "cone" devido à formação dos geofones com o tiro (ponto de energia onde são geradas as ondas sísmicas) (YILMAZ, 2003).

Na Figura 15, pode-se verificar o cone formado pelo ruído de rolamento superficial (região **A**), o qual atrapalha a visualização dos eventos de interesse, que são as reflexões relativas às diferentes camadas da subsuperfície (região **C**). Observe que o ruído mascara o sinal de interesse ou dificulta a interpretação da continuidade das estruturas de subsuperfície. Na região **B**, temos um mergulho de menor profundidade causado pelas ondas aéreas que são ondas de choque que também contaminam a imagem.

Figura 15 – Sismograma, onde **A** é uma região contaminada pelo ruído de rolamento superficial, **B** é a região contaminada pela onda de choque aérea e **C** são os refletores de interesse.



Fonte: Adaptada de Oliveira (2009).

### 3.7 RUÍDO IMPULSIVO (SAL E PIMENTA)

O ruído impulsivo pode ocorrer devido a defeitos no sistema de geração de imagens. *Pixels* ruidosos brancos são chamados de sal e os *pixels* de ruído preto são chamados de pimenta. Nesse trabalho os valores de sal e pimenta são 255 e 0 respectivamente.

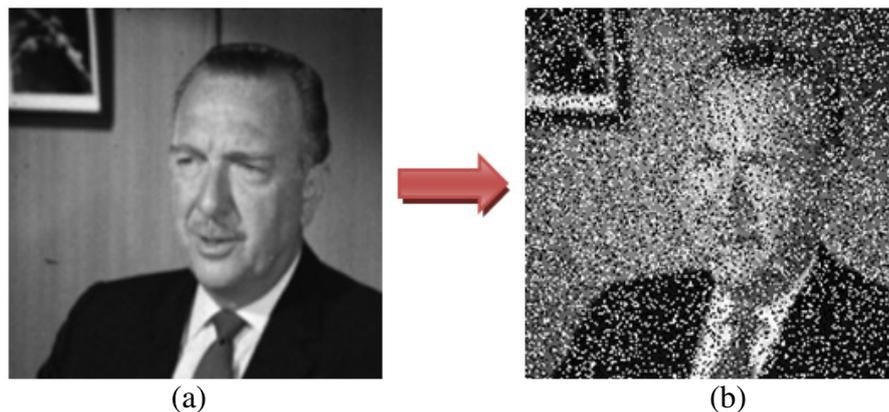
Existem duas maneiras pelas quais uma imagem pode ser corrompida por ruído. A primeira é chamada ruído aditivo, na qual simplesmente é adicionado algum tipo de ruído a uma imagem até então livre de ruído. A segunda maneira é denominada ruído multiplicativo, que consiste em multiplicar cada *pixel* da imagem por um termo de ruído aleatório. Nesse trabalho, vamos trabalhar com a primeira maneira, ou seja, nas simulações realizadas, as

imagens são corrompidas por uma simulação de ruído feito em um canal de dados, onde o ruído será adicionado em termos de porcentagem nas imagens da seguinte forma:

1. Escolha a imagem que deseja trabalhar;
2. Em uma imagem de ordem 256, significa que a mesma possui 65.536 *pixels*;
3. Escolha a porcentagem de ruído impulsivo do canal, por exemplo, 30% significam que 19.661 *pixels* foram escolhidos aleatoriamente para serem corrompidos;
4. Dos *pixels* escolhidos, os mesmos vão ter 50% de probabilidade de ser 0 ou 255.

A Figura 16 ilustra a imagem de homem livre de ruído, bem como a imagem corrompida com 30% de ruído impulsivo após passar pelo canal simulado.

Figura 16 – Homem (a) Sem ruído. (b) com 30% de ruído.



Fonte: Autoria Própria.

### 3.8 INTRODUÇÃO À TEORIA DAS WAVELETS

A todo o momento estamos nos deparando com sinais, como por exemplo: sinais sísmicos, sinais de rádio, áudio, fala humana, dados financeiros, imagens médicas etc. Esses sinais, para seu processamento e análise, contam com uma série de ferramentas, onde talvez a mais conhecida seja a transformada de Fourier, que representa um sinal através de funções senoidais de diferentes frequências. Através da transformada de Fourier, um sinal representando o espaço do tempo é transformado no espaço frequência.

A transformada Wavelet apresenta-se como uma ferramenta alternativa para o processamento de sinais, mudando o paradigma de representação dos mesmos, ao utilizar

funções base de wavelets (em vez de senoidais de Fourier) para transformar um sinal no espaço de tempo-escala.

Wavelets é uma ferramenta matemática desenvolvida a princípio para aplicações em processamento de sinais, por permitir a análise em várias escalas temporais de propriedades locais aplicadas em sinais complexos que podem apresentar zonas não estacionárias (MISITI *et al.*, 2007). Conhecida como Transformadas de Wavelets, elas têm sido amplamente utilizadas pela comunidade científica e pela indústria, devido às inúmeras possibilidades de aplicações, tanto teóricas quanto práticas, em diversas áreas como telecomunicações, geofísica e codificação de imagem e vídeo.

Pode-se definir basicamente três categorias de aplicação para as wavelets: análise de dados, compressão e remoção de ruídos. Com relação à análise de dados, as wavelets permitem a definição de funções de análise com translação de tempo e dilatação de escala que auxiliam a verificação de singularidades em uma escala refinada, como se fosse um zoom matemático.

A compressão (de imagens, principalmente) tem-se destacado devido à capacidade que as wavelets oferecem de representar a informação, reduzindo o volume de dados a serem codificados. Um exemplo de aplicação deste método é o formato de imagem JPEG 2000 (*Joint Photographic Experts Group*) que usa wavelets na codificação e reconstrução da imagem.

Na remoção de ruídos, é possível recuperar um sinal útil mesmo quando observada uma versão ruidosa deste, de maneira mais simples que os tradicionais métodos de estimação de função. Os ruídos em imagens surgem devido a problemas do equipamento de captura, ou se o ambiente é naturalmente ruidoso, ou ainda devido a características do canal de comunicação. Filtros lineares e operações de suavização são de fácil aplicação e tem sido amplamente utilizados, entretanto possuem limitações por se basearem na premissa de que o sinal que forma a imagem é estacionário e formado por um sistema linear, o que não ocorre na prática (GHAZEL, 2004).

### **3.8.1 Introdução Histórica**

As wavelets são conhecidas dos matemáticos há muito tempo, mas a formalização desta teoria foi realizada na década de 80 (GROSMANN e MORLET, 1984), (MALLAT, 1989) e (DAUBECHIES, 1990). O livro de Yves Meyer (MEYER, 1993) aborda aspectos

históricos das wavelets, desde Fourier 1807 até as contribuições recentes de A. Grossman, J. Morlet, S. Mallat e outros.

A primeira menção que poderia se chamar de wavelet é aquela que foi apresentada no anexo da tese de Alfred Haar em 1909 e que agora é chamada de base de Haar. O termo "wavelets" é atribuído a Norman Ricker no seu trabalho de sismologia, mas foi introduzido por J. Morlet em 1984. Os dados sísmicos estudados por Morlet exibiam conteúdos de frequência que mudavam rapidamente ao longo do tempo, além disso, mostrou que qualquer tipo de sinal pode ser analisado em termos de escala e translações de uma simples função wavelet mãe. MEYER (1993) e MALLAT (1988) desenvolveram esta ideia em uma teoria denominada por análise de multiresolução. Em 1989, Mallat mostrou que a análise de multiresolução pode ser vista simplesmente como uma forma de algoritmos de pirâmide usados no processamento de imagens.

### 3.8.2 Transformada de Fourier

Uma das técnicas mais populares no processamento de sinais é a transformada de Fourier, que tem como objetivo transformar um sinal (função) do domínio de espaço para o domínio da frequência (WANG (2001) e GONZALEZ e WOODS (2010)).

A função responsável pela transformada é dada pela Equação 4:

$$F[u] = \int f[t] e^{-i2\pi ut} dt \quad (4)$$

Esta equação corresponde à transformada de Fourier de um sinal contínuo  $f(t)$ , a qual apresenta algumas deficiências, entre elas o fato de que esta transformação não está localizada no domínio do espaço, então ela não pode representar adequadamente as mudanças que acontecem no sinal no espaço. Isto é devido ao fato de que a transformada está baseada na integração de toda a função para o cálculo de toda frequência. Esse não seria um problema se o sinal não mudasse durante o tempo (sinais estacionários), mas acontece que muitos sinais interessantes contêm muitas características não estacionárias ou transitórias (fluxo, tendências, mudanças repentinas, início e final de um evento). Essas características geralmente são partes mais importantes do que sinal.

Para solucionar esse problema Dennis Gabor adaptou a transformada de Fourier para analisar só pequena porção do sinal em um tempo, introduzindo a chamada transformada de

janelas de Fourier (*Windowed Fourier Transform - WFT*). Neste caso, uma janela de observação é deslocada no domínio do tempo e a transformada de Fourier da porção "visível" do sinal é calculada para cada posição da janela. Considerando  $j(t)$  a função que cumpre o papel de janela, pode-se definir a transformada por janelas de Fourier de um sinal contínuo  $f(t)$  pela Equação 5:

$$F(u, b) = \int j(t - b) f[t] e^{-i2\pi ut} dt \quad (5)$$

O problema é que uma vez que foi definido o tamanho para a janela de tempo, esta janela permanece constante para todas as frequências. Pode acontecer que alguns sinais precisem de um enfoque mais flexível, onde o tamanho da janela possa mudar com o objetivo de detectar o conteúdo local da frequência (DAUBECHIES (1992) e GOMEZ *et al.*, (1997)).

### 3.8.3 Transformada Wavelet

Depois da transformada por janelas de Fourier, a utilização das wavelets é o passo lógico seguinte. Logo, pode-se interpretá-la como uma técnica por janelas com regiões de dimensão variável, onde as wavelets, diferentemente de Fourier, têm como base uma função de duração limitada, isto é, de suporte compacto, que é uma propriedade na qual seu domínio é diferente de zero em uma extensão finita e igual a zero em todo o resto. Isto torna interessante a utilização das wavelets no caso específico da análise de imagens, pois a mudança de regiões pode ser detectada mais facilmente.

A definição de uma transformada wavelet considerando um sinal contínuo é dada pela Equação 6:

$$F(a, b) = \int f(t) \psi_{a,b}(t) dt \quad (6)$$

Nesta equação os parâmetros  $a$  e  $b$  variam continuamente em  $\mathfrak{R}$ , sendo que as funções  $\psi_{a,b}$  são denominadas wavelets e definidas pela Equação 7:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (7)$$

A transformada wavelet para sinais discretos é definida pela Equação 8:

$$F_{m,n}(a,b) = a_0^{-m/2} \int f(t) \psi(a_0^{-m}t - nb_0) \quad (8)$$

Pode-se ver que o comportamento desta função está baseada em dilatações e translações a partir de uma wavelet mãe  $\psi$ . Em ambos os casos, essa wavelet mãe, deve satisfazer a propriedade:

$$\int \psi(t) dt = 0 \quad (9)$$

Observando a Equação 6, percebe-se que a transformada wavelet depende de dois parâmetros  $a$  e  $b$ , que correspondem às informações de escala e tempo, respectivamente (DAUBECHIES (1992), GOMEZ *et al.*, (1997) e MISITI *et al.*, (2001)).

Obter os coeficientes de wavelets em cada escala possível requer uma grande quantidade de cálculo, tornando tedioso o trabalho (transformada contínua de wavelets). Devido a este fato, é que a transformada discreta de wavelets escolhe um subconjunto de escalas e locações os quais vão realizar os cálculos.

De acordo com DAUBECHIES (1992), dentro da transformada discreta de wavelets distinguem-se duas vertentes: sistemas redundantes discretos (*frames*) e ortonormal (e outras) bases de wavelets. A segunda vertente será considerada nesse trabalho, pois a mesma considera a estratégia de análise de multiresolução, desenvolvida por MALLAT (1989).

### 3.8.4 Método da Multiresolução

A estrutura da Análise Multiresolução foi formulada em trabalhos desenvolvidos por Mallat onde ele estudou as propriedades de um operador que decompõe uma imagem (ou função) em resoluções diferentes. Mostrou que a diferença de informação entre as aproximações nas resoluções pode ser extraída por decompor o sinal em uma base ortonormal formada por funções wavelets. Esta decomposição define uma representação multiresolução e é calculada por um algoritmo baseado na convolução com filtros de reconstrução perfeita.

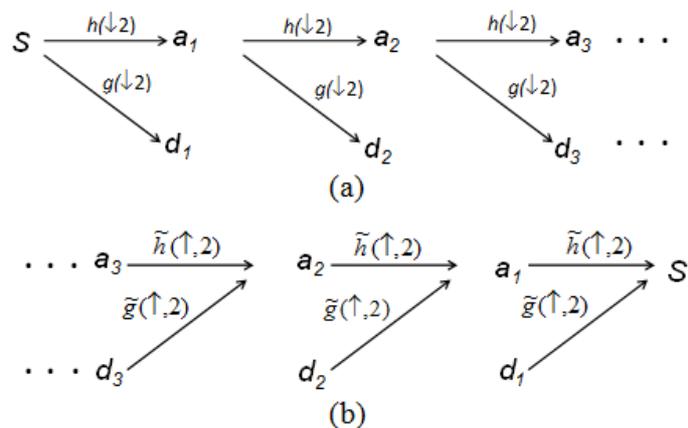
A multiresolução fornece um referencial onde bases de wavelets são naturalmente compreendidas, bem como permite a construção de novas bases. Quando Mallat trabalhou com wavelets de Meyer pela primeira vez, ele estava trabalhando com análise de imagens,

onde a ideia de se estudar imagem em várias escalas simultaneamente era popular. Isto o estimulou a ver bases ortonormais de wavelets como uma ferramenta para descrever matematicamente o "incremento na informação" necessário para ir de uma aproximação grosseira para uma aproximação com maior resolução (DAUBECHIES, 1992).

Uma decomposição multiresolução permite obter uma interpretação invariante de escala em imagem. A escala de uma imagem muda em razão da distância entre a cena e o centro ótico da câmera. Quando a escala da imagem é modificada, a interpretação da imagem não deveria mudar.

O procedimento de multiresolução baseia-se na decomposição e reconstrução das imagens em várias escalas como ilustrado nas Figuras 17a e 17b. Através desta técnica, podem-se obter as características presentes na imagem em cada um dos níveis presentes na mesma. Detalhes sobre multiresolução pode ser encontrada em MALLAT (1989) e MEYER (1993).

Figura 17 – Representação do algoritmo: (a) de análise e decomposição rápida com filtros  $h$  e  $g$  seguida por uma decimação de  $(\downarrow 2)$  e (b) de análise e reconstrução rápida com filtros  $\tilde{h}$  e  $\tilde{g}$  seguida por uma inserção  $(\uparrow 2)$ .



Fonte: Leite (2007).

### 3.8.5 Transformada Wavelet de Haar

A análise com wavelets pode estar baseada no enfoque desenvolvido por Haar (MEYER, 1993). Em 1909, A. Haar descreveu uma base ortonormal de wavelets definida sobre o domínio  $[0, 1]$ , ou seja,  $h_0(x), h_1(x), \dots, h_n(x), \dots$ , outras bases, além das de Fourier, tal que para qualquer função contínua  $f(x)$  sobre o intervalo  $[0, 1]$ , a série dada pela Equação 10:

$$\sum_{j=1}^{\infty} \langle f, h_j \rangle h_j(x) \quad (10)$$

converge a  $f(x)$  de forma uniforme sobre  $[0, 1]$ . Aqui,  $\langle u, v \rangle$  denota o produto interno de  $u$  e  $v$ , dado pela Equação 11:

$$\langle u, v \rangle = \int_0^1 u(x) \overline{v(x)} dx \quad (11)$$

onde  $\overline{v}$  é o conjugado complexo de  $v$  o qual é igual a  $v$  se a função é real.

Uma versão da construção de Haar é dada pela Equação 12 seguinte:

$$h(x) := \begin{cases} 1 & , \quad x \in [0, 0.5) \\ -1 & , \quad x \in [0.5, 1) \\ 0 & , \quad \text{caso contrario} \end{cases} \quad (12)$$

$$h_n(x) = 2^{j/2} h(2^j x - k)$$

onde  $n = 2^j + k$ ,  $k \in [0, 2^j)$ ,  $x \in [k2^{-j}, (k+1)2^{-j})$ .

Existem limitações no uso da construção de Haar. Como as funções de base de Haar são funções de passos descontínuos, não são muito adequados para a análise de funções estáveis com derivações contínuas. Visto que as imagens geralmente contêm regiões estáveis, a transformada wavelets de Haar não provê resultados satisfatórios em muitas aplicações com imagens (WANG, 2001).

### 3.8.6 Transformada Wavelet de Daubechies

Outro tipo de base para a wavelets é a proposta por DAUBECHIES (1992). Para cada inteiro  $r$ , a base ortonormal para  $L^2(\mathfrak{R})$  está definida pela Equação 13:

$$\phi_{r,j,k}(x) = 2^{j/2} \phi_r(2^j x - k), j, k \in \mathbf{Z} \quad (13)$$

onde a função  $\phi_r(x)$  em  $L^2(\mathfrak{R})$  tem a propriedade que  $\phi_r(x-k) \mid k \in \mathbf{Z}$  é uma base sequencial ortonormal em  $L^2(\mathfrak{R})$ . Aqui,  $j$  é o índice de escala,  $k$  é o índice de translação e  $r$  é o índice de filtragem.

Então a tendência  $f_j$  na escala  $2^j$  de uma função  $f \in L^2(\mathfrak{R})$  está definida pela Equação 14:

$$f_j(x) = \sum_k \langle f, \phi_{r,j,k} \rangle \phi_{r,j,k}(x) \quad (14)$$

Os detalhes ou flutuações são definidos pela Equação 15:

$$d_j(x) = f_{j+1}(x) - f_j(x) \quad (15)$$

Para analisar estes detalhes em uma dada escala, define-se uma base ortonormal  $\psi_r(x)$  com propriedades similares às de  $\phi_r(x)$  descritas anteriormente.

As funções  $\phi_r(x)$  e  $\psi_r(x)$ , denominadas por wavelet pai e wavelet mãe respectivamente, são as funções wavelets protótipo, necessárias para a análise de wavelets. As famílias de wavelets, como aquelas definidas na Equação 13, são geradas a partir de wavelet pai ou mãe mudando a escala de translação no tempo (ou espaço em processamento de imagens).

A base ortonormal de Daubechies tem as seguintes propriedades:

- $\psi_r$  tem o intervalo de suporte compacto  $[0, 2r + 1]$ ;
- $\psi_r$  tem ao redor de  $r/5$  derivações contínuas;
- $\int_{-\infty}^{\infty} \psi_r(x) dx = \dots = \int_{-\infty}^{\infty} x^r \psi_r(x) dx = 0$ .

As wavelets de Daubechies obtêm excelentes resultados no processamento de imagens devido às propriedades acima indicadas (WANG, 2001). As funções wavelets com suporte compacto podem ser implementadas mediante um filtro de longitude finita. Além disso, o suporte compacto permite a localização no domínio espacial. Devido ao fato que as funções base de wavelets têm derivações contínuas, é possível decompor a função contínua mais eficientemente com os objetos da borda previsto. As wavelets mãe são utilizadas para determinar os detalhes de um sinal e a informação de tendência é armazenada nos coeficientes obtidos pelas wavelets pai.

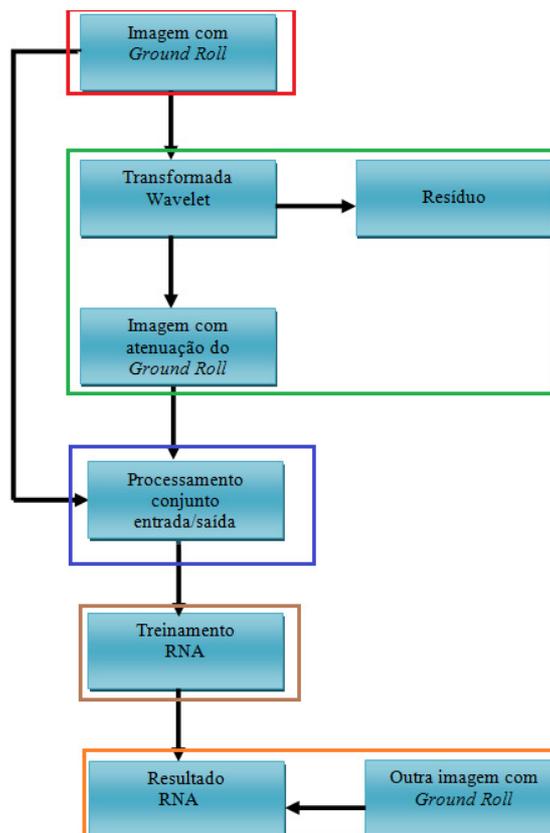
# Capítulo 4

## METODOLOGIA

### 4.1 MÉTODO PARA ATENUAÇÃO DO RUÍDO *GROUND ROLL*

Nesse capítulo é apresentando a sequência de passos, ilustrada pelo diagrama de blocos da Figura 18, utilizados para desenvolvimento do primeiro objetivo desse trabalho, que é a atenuação do ruído *ground roll*. Já na seção 4.2 é apresentado o método proposto para atenuar o ruído impulsivo de imagens digitais.

Figura 18 – Diagrama de blocos da sequência de passos utilizados para atenuação do ruído de rolamento.



Fonte: Autoria Própria.

O diagrama de blocos está dividido nos seguintes passos:

1. Obtenção de uma imagem (imagem padrão) que contenha o ruído *ground roll*, representado pela cor vermelha;
2. Utilizar as transformadas wavelet de Haar e Daubechie em conjunto com método da multiresolução na imagem padrão para atenuar o *ground roll*. Analisar qual wavelet obteve melhor desempenho no que diz respeito à atenuação e escolher sua imagem (imagem atenuada) como opção, representando pela cor verde;
3. Utilizar a imagem padrão e a imagem atenuada do item 2 para formar o conjunto de entrada/saída, respectivamente, para treinar a rede neural, representado pela cor azul;
4. Montar a arquitetura da rede neural e treiná-la com o conjunto de dados das imagens, representado pela cor marrom;
5. Após o treinamento da rede neural, outra imagem (imagem de validação) será apresentada à rede neural para que a mesma possa efetuar a atenuação do ruído e obter o resultado, representado pela cor laranja.

#### **4.1.1 Obtenção da Imagem (1º Passo)**

Para testar a eficiência das técnicas utilizadas neste trabalho, foi usada uma imagem padrão ou conjunto de dados conhecido como Oz 25, disponível em YILMAZ (2003), e ela pode ser visualizada em sua forma adaptada na Figura 15.

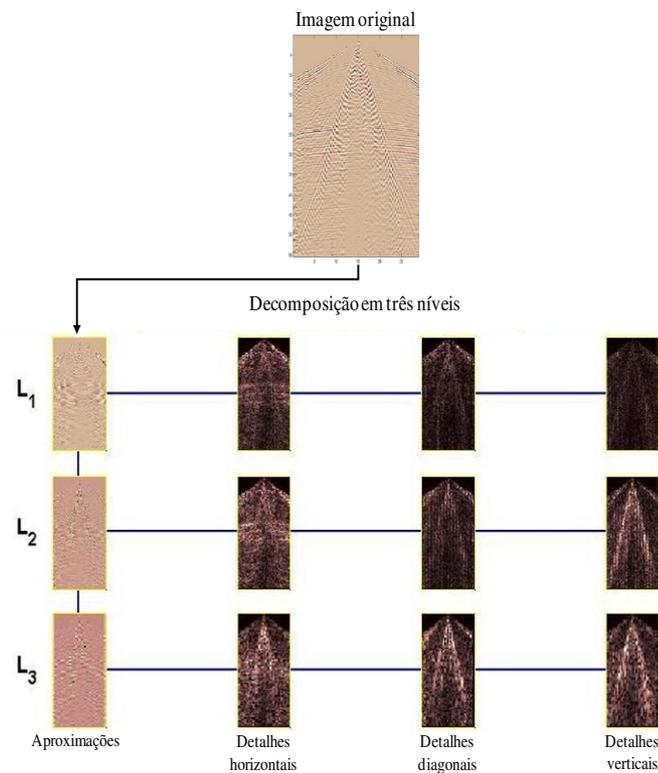
A análise da imagem padrão pela transformada wavelet foi realizada com funções obtidas pelo Toolbox Wavelet do software MATLAB<sup>®</sup> 7.11.

#### **4.1.2 Transformada Wavelet (2º Passo)**

Para analisar a imagem padrão foram utilizadas wavelets do tipo ortogonais de Haar e Daubechie em conjunto com os algoritmos de análise e decomposição proposto por Mallat, ilustrado pela Figura 19.

No processo de decomposição em multiescala, o ruído presente na imagem fica restrito aos coeficientes das escalas maiores, ou seja, ruídos de baixa frequência que podem ser visualmente localizados. Desta forma, o procedimento de filtragem consiste em atenuar os coeficientes da wavelet na região que corresponde à energia do ruído.

Figura 19 – Representação, em três níveis de resolução, através do método de decomposição em wavelets para o sismograma da Figura 15.



Fonte: Autoria Própria.

Utilizando essas técnicas no processamento das imagens, torna-se possível fazer uma análise em diferentes níveis de resolução para que se tenha uma estimativa da contribuição que cada tipo de wavelet oferece para redução do ruído de rolamento superficial.

#### 4.1.3 Conjunto entrada/saída (3º Passo)

O conjunto de treinamento é formado com o auxílio da janela de ordem 3, ilustrado pela Figura 20, onde  $x_1, x_2, \dots, x_8$  representa a 8-vizinhança de  $x_C$ . O procedimento para obtenção dos dados de treinamento ocorre da seguinte forma: a janela faz uma varredura completa nas imagens com e sem *Ground roll*, imagem padrão e imagem atenuada, respectivamente. Os dados de entrada para o treinamento são retirados da imagem padrão e os dados de saída são retirados da imagem atenuada.

A Figura 21 mostra como o procedimento é realizado para capturar os dados de entrada e saída para um exemplo de imagem 3x3. Na medida em que a janela faz a varredura sobre as imagens, a vizinhança-8 de cada *pixel* da imagem padrão é armazenada para formar o

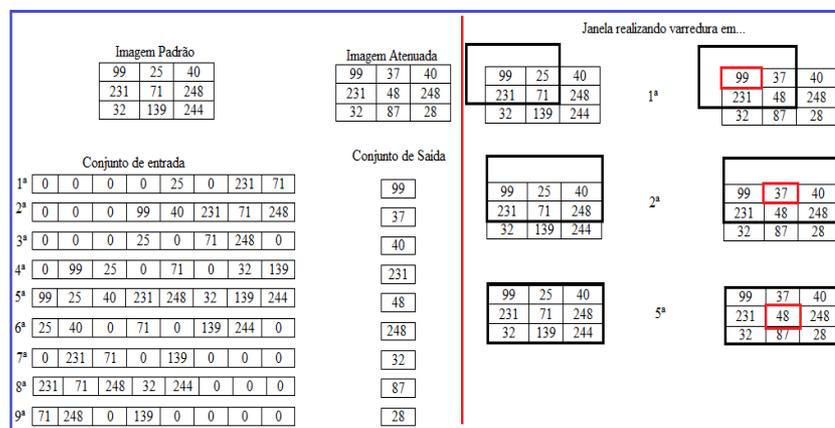
conjunto de entrada da rede, assim como o *pixel* central da imagem com atenuação do *ground roll* é armazenado para formar o conjunto de saída. Com a utilização desse procedimento, os dados de entrada da rede são capturados da imagem padrão, ou seja, com ruído, enquanto que a saída desejada é capturada a partir da imagem cujo ruído de rolamento foi atenuado através de wavelets. Dessa forma, com o treinamento, espera-se que a rede adquira a capacidade de mapear qualquer imagem com ruído *ground roll* em uma imagem que contenha esse ruído atenuado.

Figura 20 – Vizinhança-8 de  $x_C$

$x_1$	$x_2$	$x_3$
$x_4$	$x_C$	$x_5$
$x_6$	$x_7$	$x_8$

Fonte: Autoria Própria.

Figura 21 – Procedimento para formar dados de entrada/saída



Fonte: Autoria Própria.

A imagem padrão utilizada nesse trabalho possui dimensões de 191 x 370 largura e altura respectivamente, contabilizando um total de 70.670 *pixels* (dados de entradas) para a rede neural. Desse total 70% dos dados serão usadas para o treinamento propriamente dito, 15% para teste e 15% para validação da rede neural. Essa divisão em 3 etapas é feita para que a rede neural possa ser testada e validada com dados que ainda não foram vistos na etapa de treinamento. As funções utilizadas para criar os dados de entrada e saída foram criadas e implementadas no ambiente MATLAB<sup>®</sup> 7.11.

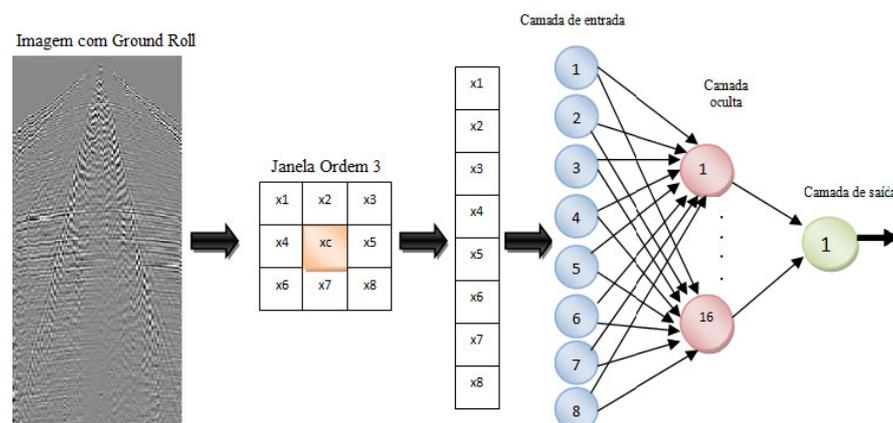
#### 4.1.4 Arquitetura e Treinamento da Rede (4º Passo)

A rede neural MLP escolhida nesse trabalho foi do tipo *Feed-forward*, usando o paradigma de aprendizagem supervisionada. Para montar a arquitetura da rede neural deve-se levar em consideração a quantidade de neurônios e camadas, funções de ativação, algoritmos de treinamento, quantidade de épocas<sup>2</sup> (interações) e taxa de aprendizagem.

A configuração da rede neural usada neste objetivo ficou da seguinte forma: a camada de entrada com oito neurônios que correspondem à vizinhança-8 de cada *pixel*. A camada de saída possui apenas um neurônio que corresponde ao novo valor de *pixel* central mapeado pela rede. O número de dezesseis neurônios foi utilizado na camada oculta e esse número foi obtido por alguns experimentos. Assim a arquitetura da rede neural que obteve o melhor desempenho em termos de erro desejado, possui a seguinte estrutura: 8-16-1. A estrutura proposta é mostrada na Figura 22.

Para o treinamento da rede neural foram utilizadas as funções de ativação sigmóide (logsig) e linear (purelin) na camada oculta e saída, respectivamente. A rede neural foi treinada usando o algoritmo *backpropagation*, mais especificamente o algoritmo *Levenberg-Marquardt* com um número máximo de 100 épocas, taxa de aprendizado de 0,47 e erro desejado de  $10^{-3}$ .

Figura 22 – Estrutura da Rede Neural

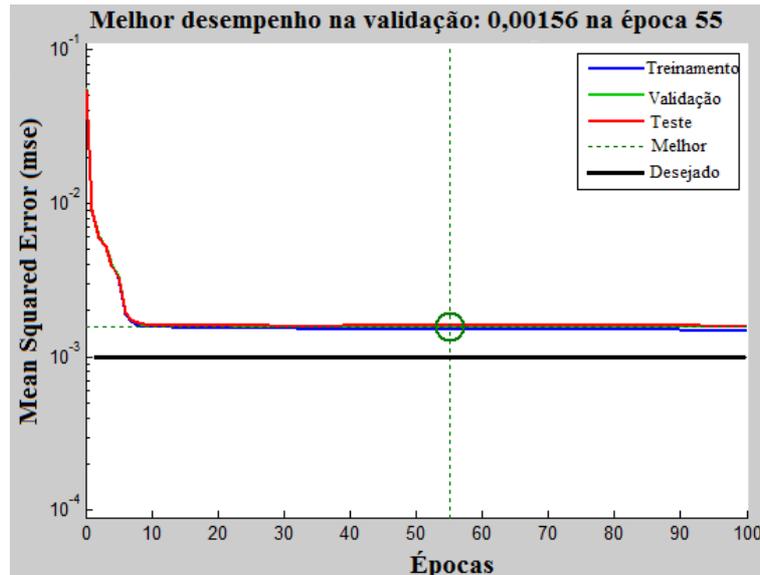


Fonte: Autoria Própria.

<sup>2</sup> Época significa que os pesos são ajustados pelo algoritmo apenas depois da apresentação de todos os padrões (entradas), ou seja, depois de um ciclo completo (após cada época) na apresentação dos padrões.

A Figura 23 mostra o desempenho obtido em MSE (*Mean Squared Error*) pela rede neural em cada época durante as três etapas, treinamento, validação e teste. O treinamento da rede neural terminou quando o número de 100 épocas foi atingido e obteve como o erro final de treinamento e validação de 0,00149 e 0,00156, respectivamente.

Figura 23 – Desempenho da rede neural durante o treinamento



Fonte: Autoria Própria.

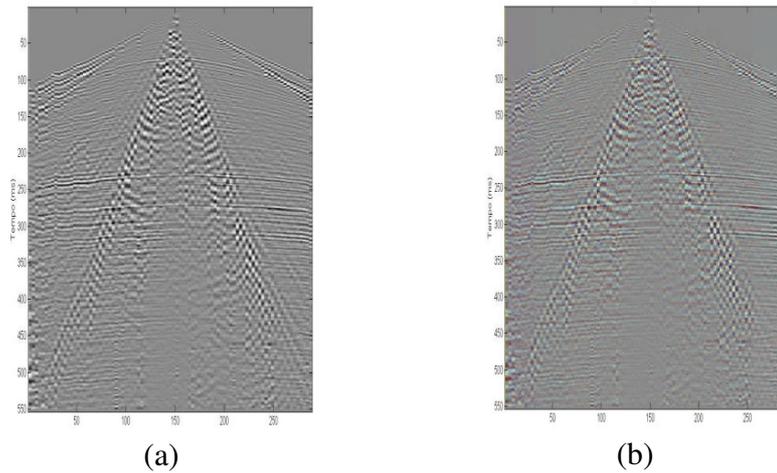
#### 4.1.5 Obtenção dos Resultados (5º Passo)

Para viabilizar o processo de filtragem, define-se um limiar de corte dos coeficientes das wavelets, para maximizar a remoção do ruído a partir de inspeções visuais da imagem. A escolha do limiar depende da quantidade visual do ruído presente no dado sísmico. A Figura 24 mostra uma comparação entre a imagem padrão semelhante a um sismograma contendo o *ground roll*, e a imagem após a filtragem do *ground roll* utilizando a wavelet de Haar no oitavo nível de resolução. Observa-se que as características originais da imagem são preservadas nas regiões de interesse e uma porção quase imperceptível do ruído foi removido.

A seguir, a wavelet de Daubechie é utilizada na imagem padrão para filtragem do ruído. A Figura 25 mostra uma comparação entre a imagem padrão e a imagem após a filtragem do *ground roll* utilizando a wavelet de Daubechie no oitavo nível de resolução. Pode-se observar, visualmente, que a através desta transformada wavelet houve uma remoção significativa do ruído, preservando principalmente as características originais da imagem nas

linhas horizontais onde, são fornecidas as informações de maior interesse para análise de registros sísmicos em reservatórios de petróleo. A Figura 26 mostra o resíduo removido através da wavelet de Daubechie.

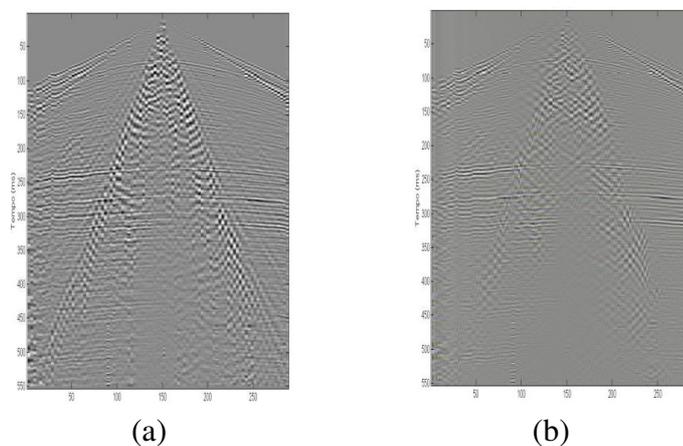
Figura 24 – Comparação entre sinais: (a) Imagem original contendo o *ground roll* e (b) Imagem com atenuação do *ground roll* através da decomposição em multiescala utilizando wavelet de Haar.



**Fonte:** Autoria Própria.

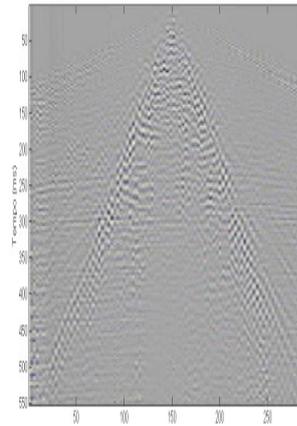
Em observação, destaca-se que para maior eficiência da técnica utilizada, este processo pode ser repetido considerando apenas sub-blocos da matriz associada à imagem, ou seja, consideram-se partes desta imagem onde exista maior presença do ruído.

Figura 25 – Comparação entre sinais: (a) Imagem original contendo o *ground roll* e (b) Imagem com atenuação do *ground roll* através da decomposição em multiescala utilizando wavelet de Daubechie.



**Fonte:** Autoria Própria.

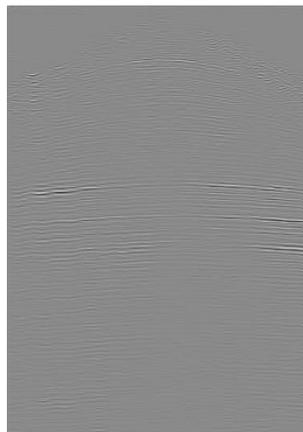
Figura 26 – Resíduo removido através da wavelet de Daubechie.



**Fonte:** Autoria Própria.

Após a utilização das wavelet de Haar e Daubechie, percebe-se de forma visual que a wavelet de Daubechie obteve melhor desempenho na atenuação o ruído *ground roll*. Assim as imagens da Figura 25(a) e Figura 25(b) foram utilizadas para compor o conjunto de entrada e saída (seção 4.1.3), respectivamente, para o treinamento da rede neural especificada na seção 4.1.4. Após a etapa de treinamento, com o intuito de verificar a atuação da rede como filtro para o ruído *ground roll*, a imagem padrão foi novamente usada como entrada da rede, e como resposta obteve-se a imagem mostrada na Figura 27.

Figura 27 – Atenuação do *Ground Roll* usando rede neural.



**Fonte:** Autoria Própria.

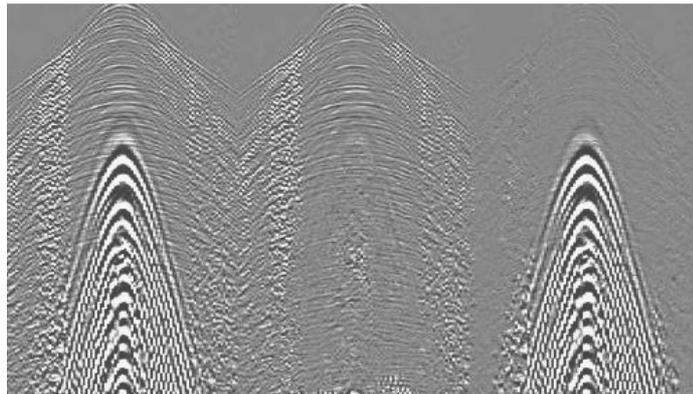
Observa-se claramente que a rede neural conseguiu atenuar boa parte do ruído presente na imagem padrão preservando os detalhes horizontais, que são as áreas de interesse. Esse bom resultado deve-se ao fato de que a imagem da Figura 25(b), que teve o *ground roll*

atenuado através da wavelets de Daubeche, foi usada como saída desejada no treinamento inicial da rede.

Para efeito de validação da técnica de atenuação do ruído *ground roll*, a imagem de validação disponível em ENSIKLOPEDI SEISNIK ONLINE (2012), mostrada na Figura 28, foi apresentada à rede neural. É importante salientar que essa imagem tem como característica um alto grau de ruído do tipo *ground roll*.

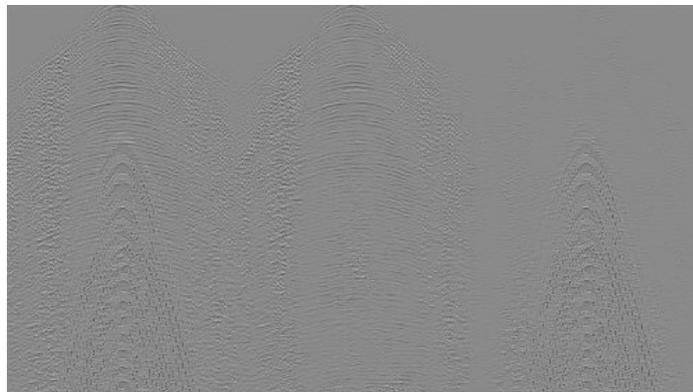
A rede neural obteve como saída para a entrada da imagem de validação a imagem mostrada Figura 29. Observa-se o bom desempenho da rede na atenuação do ruído *ground roll*. Essa atenuação é visível devido à manutenção e uma melhor percepção das linhas horizontais, que representam as áreas de interesse. Em adição, é importante colocar que a atenuação que ocorre nas linhas horizontais é desprezível, não contribuindo, portanto, para qualquer tipo de perda na informação contidas nos dados presentes nestas linhas.

Figura 28 – Imagem apresentada à rede neural para validação.



**Fonte:** Ensiklopedi 2012.

Figura 29 – Resposta da rede neural para a imagem de validação.



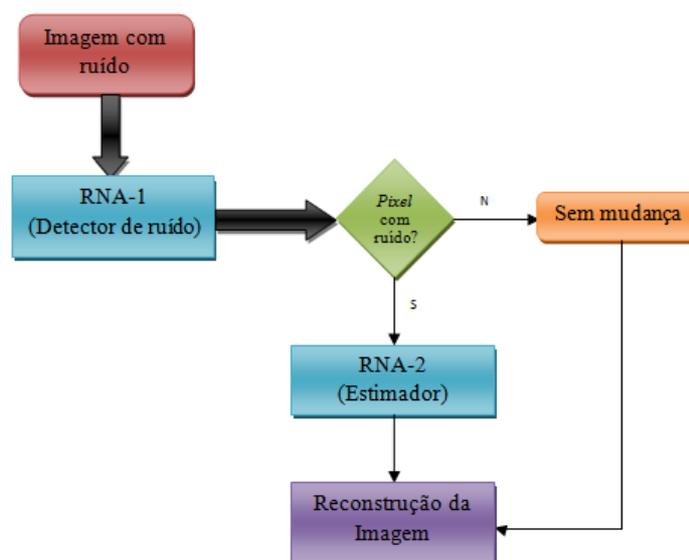
**Fonte:** Autoria Própria.

## 4.2 MÉTODO PARA ATENUAÇÃO DO RUÍDO IMPULSIVO

Nessa seção é apresentada a sequência de passos, ilustrada pelo diagrama de blocos da Figura 30, utilizados para desenvolver o segundo objetivo desse trabalho, que é a utilização de duas redes neurais artificiais para detectar e atenuar o ruído impulsivo de imagens digitais.

O método aqui aplicado está baseado em duas fases. Cada fase é processada por uma rede neural artificial, sendo referenciada nesse trabalho como (RNA-1 e RNA-2). A primeira fase funciona como um detector de ruído impulsivo, ou seja, decidirá se um determinado *pixel* é corrompido ou não, mais detalhes na seção 4.2.2. Na segunda fase, o valor para o novo *pixel* considerado ruído é estimado usando os valores dos *pixels* vizinhos como entrada para a segunda (RNA-2), os detalhes da segunda fase na seção 4.2.3. O esquema geral do método proposto é mostrado na Figura 30.

Figura 30 – Esquema Geral do método proposto.



Fonte: Autoria Própria.

### 4.2.1 Obtenção das Imagens de Treinamento

Para efeito de generalização da RNA-1, a escolha adequada das imagens para o treinamento é uma tarefa importante, pois de acordo com YÜKSEL (2006) e KALIRAJ e BASKAR (2010) as imagens geradas artificialmente têm maior capacidade de generalização. O processo para gerar as imagens de treinamento (entrada/saída) ocorre da seguinte forma:

1 – Cria-se uma imagem base de tamanho  $100 \times 100$  *pixels*, onde ela consiste de blocos quadrados de tamanho  $2 \times 2$  *pixel*, como ilustrado na Figura 31, para esse exemplo a imagem terá 2.500 blocos. Todos os *pixels* de um determinado bloco devem possuir o mesmo valor em escala de cinza, os quais são escolhidos aleatoriamente entre  $[0 - 255]$ . A imagem base é ilustrada na Figura 32(a) e a partir dela criam-se as imagens que servirão como entrada e saída para a RNA-1;

2 – A imagem de entrada é obtida ao corromper a imagem base com 50% de ruído impulsivo (ver seção 3.7). A imagem de entrada é ilustrada na Figura 32(b);

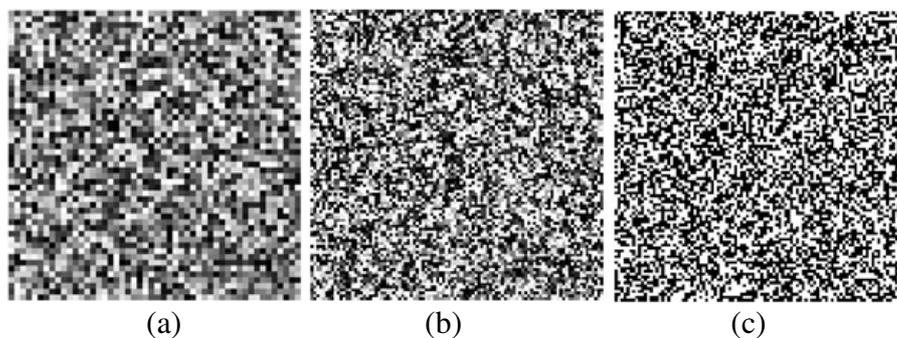
3 – E por fim o processo de criação da imagem alvo (saída) ocorre da seguinte forma: Cria-se uma imagem do mesmo tamanho que a imagem base com todos os valores de *pixels* iguais a zero, ou seja, uma imagem totalmente preta. Em seguida, no mesmo momento em que a imagem base estiver sendo corrompida pelo ruído impulsivo, a imagem alvo também será. A diferença é que a imagem preta receberá somente o valor 255 (pontos brancos), os quais vão denotar a presença de ruído. Assim a imagem alvo terá a forma preta e branca como mostra a Figura 32(c).

Figura 31 – Exemplo de um bloco  $2 \times 2$  composto de 4 *pixels* com mesmo nível de cinza.



Fonte: Autoria Própria.

Figura 32 – (a) Imagem base. (b) Imagem de entrada. (c) Imagem Alvo

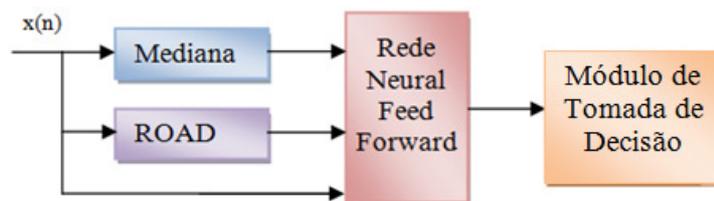


Fonte: Autoria Própria.

#### 4.2.2 Detector de Ruído (1ª Fase)

A estrutura do detector de ruído proposto é mostrada na Figura 33, no qual consiste de uma rede neural MLP (RNA-1), e um módulo de tomada de decisão. A rede neural utiliza como entrada três valores obtidos da Figura 32(b) pela janela que representa a Vizinhança-8 do *pixel* central, mostrada na Figura 11(c), constituída pelo valor do *pixel* central, valor da mediana e o valor das Diferenças Absolutas Ordenada por *Rank*, do inglês *Rank-Ordered Absolute Differences* (ROAD), ambos calculados sobre o *pixel* central. ROAD foi proposto por GARNETT *et al.*, (2005) e é considerado uma boa medida para avaliar *pixels*. A saída da rede neural é enviada para o módulo de tomada de decisão que converte o valor da saída em números binários, 1 ou 0 para verificar e classificar o estado do *pixel*. Ou seja, se a saída for o 1, o *pixel* está corrompido, se for 0, o *pixel* não está corrompido.

Figura 33 – Estrutura do detector de Ruído.



Fonte: Autoria Própria.

O processo para obtenção dos dados de entrada/saída para a RNA-1 ocorre da seguinte forma: a janela faz uma varredura sobre as imagens da Figura 32(b) e (c), tomando como base  $n = (i, j)$ , que determina a localização do *pixel* central na janela, aqui considerada como  $W_n$ . A vizinhança-8 ( $W_n$ ) do *pixel* central da imagem de entrada é armazenada e com base neles a mediana é calculada. Desta forma, o filtro da mediana é dado pela Equação 16. Os dados que formam o conjunto de saída para a RNA-1 é a própria imagem 32(c) em forma de um vetor linear.

$$m(n) = \text{mediand}(W_n) \quad (16)$$

O valor de ROAD, utilizado no detector de ruído, é usado para distinguir os *pixels* ruidosos dos *pixels* não ruidosos, atribuindo um fator de ROAD alto para *pixels* com ruído e baixo para *pixels* que não apresentam ruído. Deste modo, o valor de ROAD é calculado dentro da mesma janela, da seguinte forma:

- 1) Cálculo da diferença absoluta entre o *pixel* central e os outros *pixels*, de acordo com a Equação 17:

$$d_n = |W_n - n(i, j)| \quad (17)$$

- 2) Ordenação dos valores de  $d_n$  em ordem crescente e armazenando-os na variável  $r_n$ , Equação 18;

$$r_n = \text{ordena}(d_n) \quad (18)$$

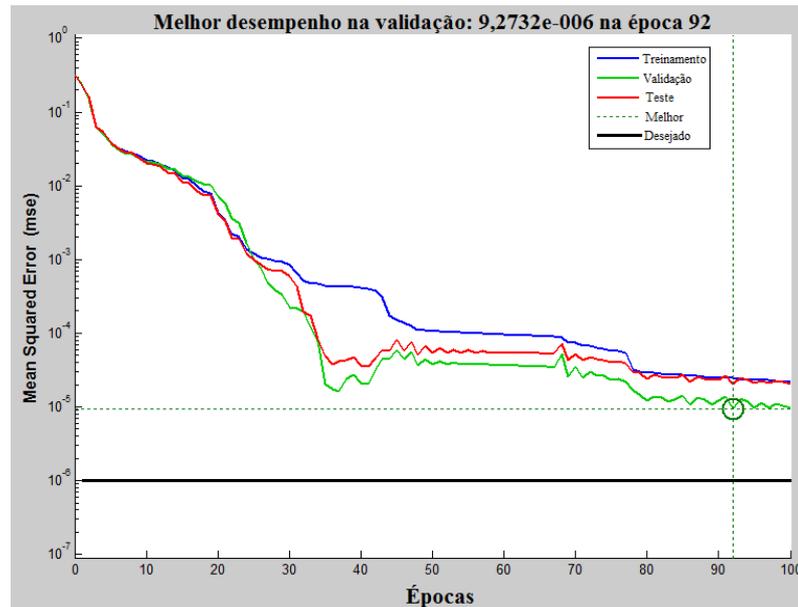
- 3) Finalmente, o valor de ROAD é calculado como sendo a soma dos quatro primeiros valores de  $r_n$ .

O módulo de tomada de decisão arredonda os valores gerados da saída da RNA-1 com um limite em 0,5. Ou seja, a saída  $y(n) = 0$  se a saída da RNA-1  $< 0,5$  e  $y(n) = 1$  se a saída da RNA-1  $\geq 0,5$ . Desta forma, o tomador de decisão verifica se um *pixel* é ruidoso ou não.

A configuração da RNA-1 usada no segundo objetivo desse trabalho ficou da seguinte forma: a camada de entrada com três neurônios que correspondem ao valor do *pixel* central, valor da mediana e ROAD. A camada de saída com apenas um neurônio. O número de sete neurônios foi utilizado na camada oculta e esse número foi obtido por alguns experimentos. Assim a arquitetura da rede neural que obteve o melhor desempenho em termos de erro desejado, possui a seguinte estrutura: 3-7-1. Para o treinamento da rede neural foi utilizada a função de ativação tangente hiperbólica (*tansig*) nas camadas oculta e saída, respectivamente. A rede neural foi treinada usando o algoritmo *backpropagation*, mais especificamente o algoritmo *Levenberg-Marquardt* com um número máximo de 100 épocas, taxa de aprendizado de 0,05 e erro desejado de  $10^{-7}$ .

A Figura 34 mostra o desempenho obtido em MSE (*Mean Squared Error*) pela RNA-1 em cada época durante as três etapas, treinamento, validação e teste. O treinamento da rede neural terminou quando o número de 100 épocas foi atingido e obteve como o erro final de treinamento e validação de  $2,19 \times 10^{-5}$  e  $9,2732 \times 10^{-6}$ , respectivamente.

Figura 34 – Desempenho da RNA-1 durante o treinamento.



Fonte: Autoria Própria.

#### 4.2.3 Estimador de Ruído (2ª Fase)

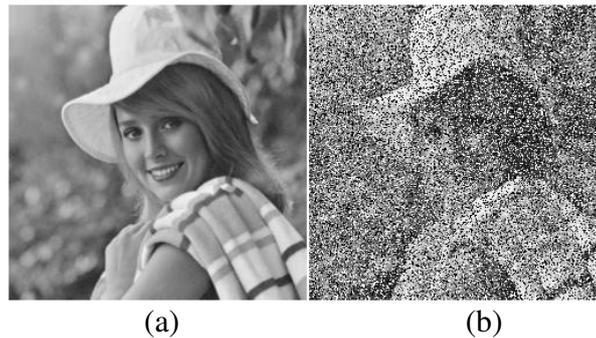
Na segunda fase o *pixel* detectado como ruído é substituído por um valor calculado pelo estimador de ruído (RNA-2). Esse estimador de ruído, diferentemente de alguns métodos tradicionais encontrados em YLI-HARJA *et al.*, (1991), GABBOUJ *et al.*, (1992) e CHEN e WU (2001), mantém o valor dos *pixels* não corrompidos inalterados. A RNA-2 calcula o novo valor usando os *pixels* vizinhos ao *pixel* corrompido, como ilustrado na Figura 20.  $x_C$  é o *pixel* corrompido e  $x_1, x_2, \dots, x_8$  são os vizinhos, chamados de "vizinhança-8" de  $x_C$ , utilizados pela RNA-2 como entrada para calcular o novo valor de  $x_C$ .

Em YÜKSEL e BASTÜRK (2003) e YILDIRIM *et al.*, (2007), para treinamento da rede neural, os autores usaram imagens artificiais iguais as que foram utilizadas na Figura 32. Porém os autores acreditam que, baseado no Teorema da Correlação (GONZALEZ e WOODS, 2010), esse método não é razoável. Em REZVANIAN *et al.*, (2008), os autores compararam o desempenho de uma rede neural utilizando imagens reais e artificiais para o treinamento, e melhores resultados foram obtidos usando imagens reais.

Assim para o treinamento da RNA-2 foram utilizadas imagens reais da Figura 35, que possuem o tamanho de uma matriz de ordem 256, onde a Figura 35(b) (entrada) foi obtida corrompendo a imagem da Figura 35(a) (saída) com 40% de ruído impulsivo. Os dados de entrada/saída para a RNA-2 são obtidos da seguinte forma: a janela faz uma varredura

completa sobre a imagem de entrada e calcula para cada *pixel* a vizinhança-8 para formar os dados de entrada. Os dados que formam a saída é a própria imagem da Figura 35(a) em forma de um vetor linear. Dessa forma, a RNA-2 após o treinamento terá capacidade de mapear um conjunto de pixels (corrompidos ou não) em valores próximos aos valores de *pixels* reais para determinada imagem.

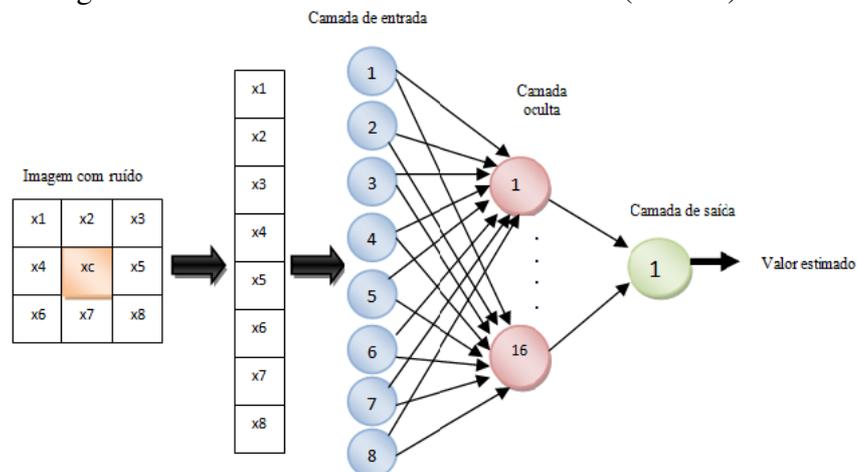
Figura 35 – (a) Imagem Elaine (saída). (b) Imagem Elaine com 40% de ruído (entrada)



Fonte: Autoria Própria.

A RNA-2 usada neste trabalho possui três camadas, a camada de entrada com oito neurônios que correspondem à vizinhança-8 do *pixel* considerado ruidoso da Figura 35(b). A camada de saída possui apenas um neurônio que corresponde ao novo valor estimado pela RNA-2. O número de 16 neurônios foi utilizado na camada oculta e esse número foi obtido por alguns experimentos. Assim a arquitetura da RNA-2 que obteve o melhor desempenho para estimar o novo valor do *pixel* ruidoso apresenta a estrutura 8-16-1, conforme mostra a Figura 36.

Figura 36 – Estrutura do estimador de ruído (RNA-2)

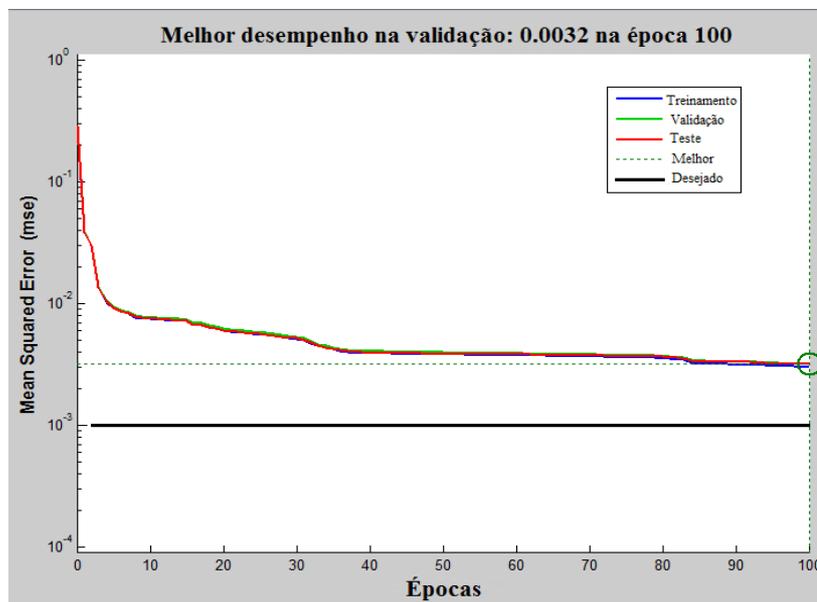


Fonte: Autoria Própria.

A camada oculta e de saída foram configuradas com as funções de ativação do tipo sigmoide (logsig) e linear (purelin), respectivamente. A RNA-2 foi treinada usando o algoritmo *backpropagation* com um número máximo de 200 épocas, taxa de aprendizado de 0,47 e erro desejado de  $10^{-3}$ .

A Figura 37 mostra o desempenho obtido em MSE (*Mean Squared Error*) pela RNA-2 em cada época durante as três etapas, treinamento, validação e teste. O treinamento da rede neural terminou quando o número de 100 épocas foi atingido e obteve como o erro final de treinamento e validação de 0,0030 e 0,0032, respectivamente.

Figura 37 – Desempenho da RNA-2 durante o treinamento.



Fonte: Autoria Própria.

#### 4.2.4 Obtenção dos Resultados

O desempenho do método é analisado quantitativamente usando o *Peak Signal To Noise Ratio* – (PSNR) em decibéis (dB) como medida de desempenho, pois quanto maior o PSNR melhor o desempenho de recuperação do método, bem como qualitativamente através de observações visuais. O valor de PSNR é definido pela Equação 19.

$$PSNR = 10 \log \frac{MAX(X(i, j))^2}{\frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (X(i, j) - Y(i, j))^2} \quad (19)$$

onde  $X(i, j)$  é a imagem original,  $Y(i, j)$  é a imagem recuperada e  $N \times M$  é o tamanho da imagem.

O desempenho do método é testado em dez imagens da literatura sobre várias condições de ruído, sendo elas: *Baboon*, *Blood*, *Boats*, *Bridge*, *Cameraman*, *Goldhill*, *Lena*, *Pentagon*, *Peppers* e *Rice* disponíveis em SIGNAL AND IMAGE PROCESSING INSTITUTE (2012). As imagens utilizadas para obter o desempenho do método são geradas por corromper as imagens originais citadas com alguma densidade de ruído. Para efeito de comparação, as imagens corrompidas são filtradas por outros métodos encontrados na literatura, sendo eles: *The progressive switching median filter* (PSMF) (WANG e ZANG , 1999), *the modified peak and valley filter* (MPVF) (ALAJLAN, 2004), *the two-output nonlinear filter* (TONF) (RUSSO, 2004), *the threshold boolean filter* (TBF) (AIZENBERG, 2005), *the adaptive fuzzy switching filter* (AFSF) (XU, 2004), Yüksel filter (YÜKSEL, 2006) e NNBD (KALIRAJ e BASKAR, 2010).

O procedimento realizado para avaliar o desempenho dos métodos citados bem como o método proposto ocorre da seguinte forma: dez imagens são corrompidas com densidades de ruídos que variam de 5% – 90%. Dessa forma, para cada densidade de ruído as dez imagens são corrompidas. As dez imagens são recuperadas usando um método, e o valor de PSNR é calculado para cada imagem recuperada. Assim são calculados dez valores diferentes de PSNR, a média sobre esses valores é obtida representando assim o desempenho do método para aquela densidade de ruído. Esse procedimento é realizado para todas as densidades de ruído que variam de 5% – 90%. Finalmente todo o procedimento é executado individualmente para cada método.

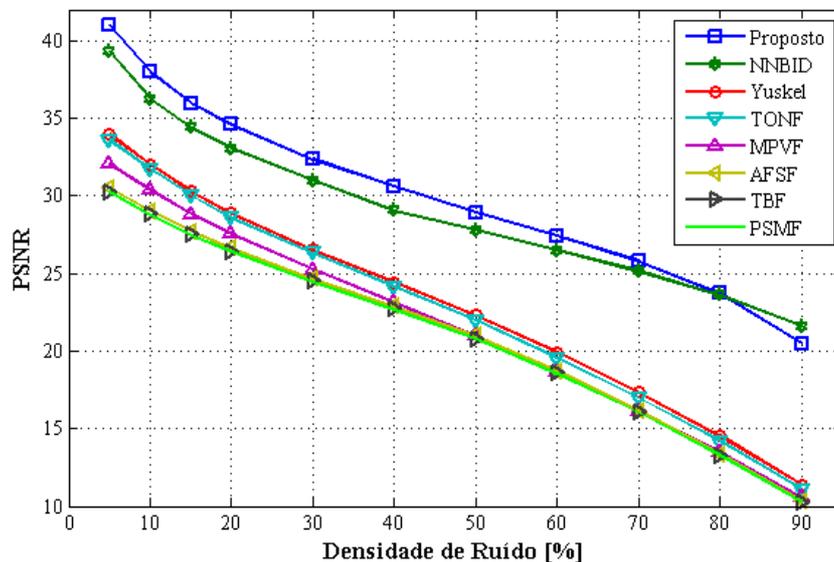
A Tabela 1 mostra os valores médios de PSNR em função da densidade de ruído obtido por cada método. O desempenho dos métodos citados foi retirado de YÜKSEL (2006), pois ele executou o mesmo procedimento descrito usando o mesmo conjunto de imagens.

Da Tabela 1 pode-se observar que os valores médios de PSNR obtidos pelo método proposto são maiores em comparação com os outros métodos. De forma a melhorar a percepção dos resultados, a Figura 38 mostra o gráfico da densidade de ruído em relação aos valores de PSNR obtidos. O gráfico indica que o valor de PSNR obtido pelo método proposto é maior em comparação com o de Yüskel e NNBD.

**Tabela 1 – Média PSNR x densidade de ruído.**

	Método	NNBID	Yüskel	TONF	MPVF	AFSF	TBF	PSMF
5%	40,98	39,30	33,96	33,58	32,06	30,50	30,26	29,15
10%	37,99	36,25	32,03	31,72	30,40	29,02	28,80	27,77
15%	35,97	34,40	30,30	30,03	28,86	27,69	27,49	26,51
20%	34,62	33,05	28,87	28,62	27,55	26,62	26,41	25,50
30%	32,35	30,99	26,54	26,37	25,29	24,64	24,46	23,84
40%	30,63	29,05	24,45	24,15	23,16	22,90	22,70	22,30
50%	28,95	27,81	22,32	21,98	21,00	20,98	20,78	20,58
60%	27,41	26,48	19,92	19,57	18,64	18,72	18,54	18,50
70%	25,78	25,13	17,35	16,99	16,14	16,18	16,05	16,14
80%	23,71	23,61	14,53	14,21	13,49	13,34	13,28	13,48
90%	20,48	21,63	11,37	11,12	10,58	10,31	10,28	10,40

Figura 38 – Média PSNR x densidade de ruído % dos Métodos: Proposto, NNBID, Yüskel, TONF, MPVF, AFSF, TBF e PSMF.

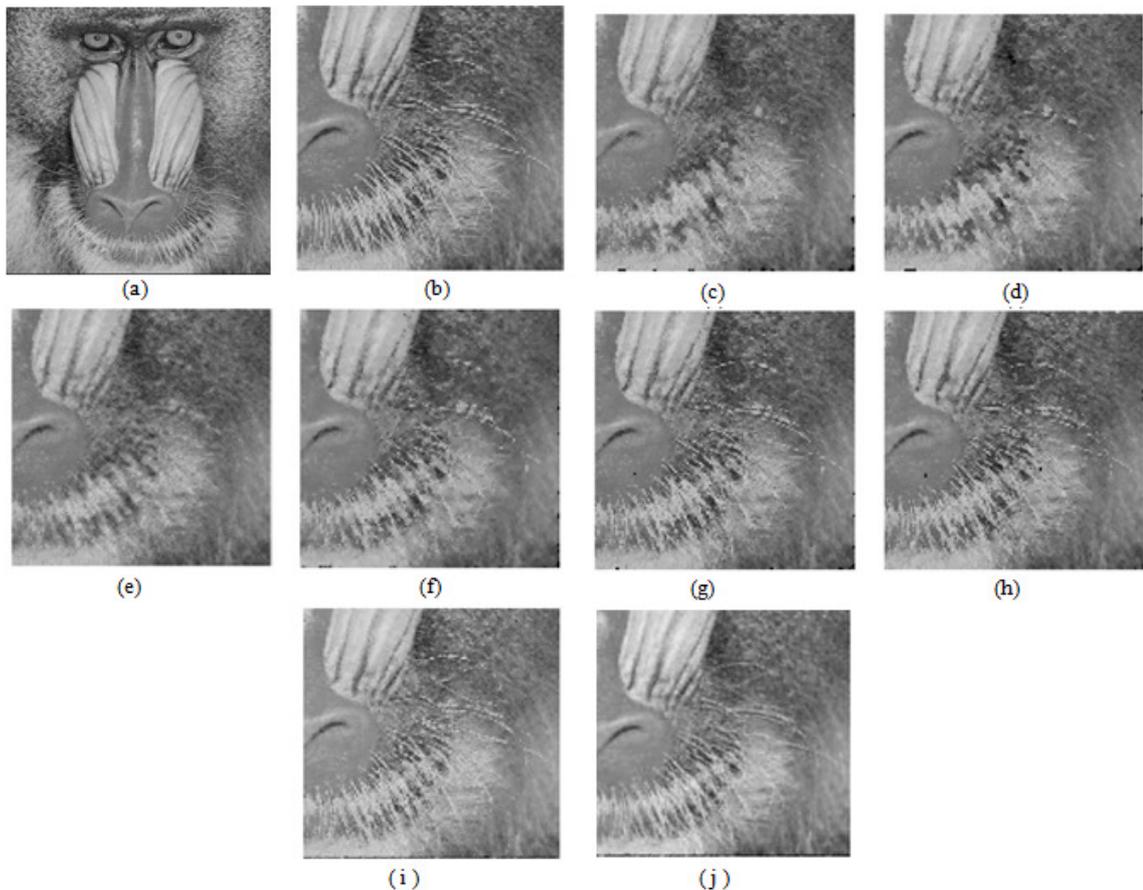


Fonte: Autoria Própria.

A análise qualitativa foi realizada através de observações visuais. Para essa análise, a imagem Baboon, mostrada na Figura 39(a), foi corrompida com 25% de ruído e restaurada pelos métodos. Essa imagem foi escolhida em especial por apresentar ricos detalhes e textura. A Figura 39(b) mostra uma porção da imagem Baboon em zoom, exatamente onde se

encontra os detalhes interessados. A Figura 39(c), (d), (e), (f), (g), (h), (i) e (j) representa a porção em zoom da imagem Baboon recuperada pelos métodos PSMF, TBF, AFSF, MPVF, TONF, Yüskel, NNBID e do método proposto, respectivamente.

Figura 39 – Imagem Baboon recuperada pelos métodos com 25% de densidade de ruído. (a) Imagem Baboom. (b) Porção da imagem em zoom. (c) PSMF. (d) TBF. (e) AFSF. (f) MPVF. (g) TONF. (h) Yüskel. (i) NNBID. (j) Proposto.



Fonte: Autoria Própria.

#### 4.2.5 Discussão dos Resultados

Os resultados do método foram comparados com outros métodos da literatura usando uma medida numérica PSNR e observações visuais. Pôde ser observado de acordo com o gráfico da Figura 38 que o método proposto alcançou melhores resultados em comparação com os métodos da literatura citados. Isto é observado, pois o método proposto possui uma forma diferente de tratar os pixels ruidosos, isto é, ele usa duas redes neurais artificiais para detectar e estimar o valor do pixel ruidoso.

Analisando o gráfico percebe-se que o método NNBID possui uma curvatura similar com a do método proposto, isso ocorre, pois ambos os métodos usam a mesma RNA-1 na primeira fase que é a detecção dos pixels ruidosos. No entanto a forma de filtrá-los é diferente, pois NNBID usa algoritmos baseados na média dos pixels vizinhos enquanto que o método proposto usa uma RNA-2 treinada com base na vizinhança-8 do pixel ruidoso. Assim, o método proposto que usa uma segunda rede neural obteve melhorias significantes em relação ao método NNBID nas densidades de ruído que variam de 5% - 80%. As vantagens do método são sumarizadas a seguir:

1. O treinamento da RNA-1 é facilmente alcançado por usar imagens artificiais geradas em computador. A RNA-2 pode ser usada eficientemente em imagens corrompidas com ruído impulsivo para qualquer densidade de ruído;
2. Um melhor desempenho pode ser alcançado por repetir o treinamento das RNAs alterando os parâmetros (taxa de aprendizado, quantidade de neurônios e camadas ocultas, bem como funções de ativação), tendo em vista que não foi usado nenhum método para a escolha dos parâmetros.

Por outro lado, a complexidade computacional do método proposto é maior em relação aos métodos citados da literatura. A complexidade é de fato maior graças à propriedade inerente das RNAs que é a necessidade de treinamento. No entanto a etapa de treinamento ocorre até que os parâmetros da mesma sejam ajustados. Uma vez os parâmetros ajustados e fixados, o tempo de resposta para simular novas entradas é relativamente curto.

# Capítulo 5

## CONCLUSÕES

### 5.1 OBJETIVO 1

Como objetivo 1 desse trabalho, o método de decomposição em multiescala, utilizando as wavelets de Haar e Daubechie foram aplicados com sucesso em conjunto com as redes neurais artificiais, na análise de registros sísmicos semelhantes aos encontrados em reservatórios de petróleo. Os resultados obtidos mostram que através da wavelet de Daubechie é possível treinar uma rede neural para obter uma melhor visualização da imagem após a retirada do *ground roll*. A partir do estudo apresentado neste trabalho, pode-se perceber claramente, que a escolha da wavelet adequada é de fundamental importância para o treinamento da rede neural e otimização do processo de filtragem para retirada ou remoção do *ground roll*. Apesar da complexidade, o método apresentado é mais uma ferramenta à disposição do geólogo para auxiliá-lo na atenuação de ruído e identificação de fraturas, de modo a integrar a informação de novos poços de petróleo.

### 5.2 OBJETIVO 2

O segundo objetivo desse trabalho apresentou um método baseado em duas redes neurais artificiais para detecção e remoção de ruído impulsivo de imagens digitais. Os resultados obtidos através das simulações demonstram a viabilidade do método, especialmente através das adaptações das RNAs para evitar destruir pixels não corrompidos. A partir desse estudo, conclui-se que o método proposto pode ser usado como uma ferramenta poderosa para remover eficientemente o ruído impulsivo de imagens digitais graças à característica das RNAs que é o reconhecimento de padrões.

### 5.3 TRABALHOS FUTUROS

O desempenho das redes neurais artificiais está intimamente relacionado à arquitetura e aos pesos iniciais, principalmente no que se refere à sua capacidade de generalização. No entanto, a definição de tais parâmetros é inerente ao problema em questão, sendo que uma

rede neural próxima do ideal é uma rede com parâmetros específicos e escolhidos adequadamente para resolver um determinado problema, tendo uma estrutura melhor e com desempenho final superior ao de uma rede neural encontrada por tentativa e erro. Como proposta de trabalhos futuros: a introdução de algoritmos evolucionários (Algoritmos Genéticos etc) para a otimização dos parâmetros das redes neurais, tais como, definição da arquitetura, pesos iniciais, regra de aprendizado, funções de ativação, quantidade de camadas e neurônios ocultos entre outros, pois tal abordagem permitem adaptar estes parâmetros para diferentes tarefas sem intervenção humana, fornecendo, portanto, uma abordagem de design automático de redes neurais.

# REFERÊNCIAS

ABREU, E.; LIGHTSTONE, M.; MITRA, S. K.; ARAKAWA, K. “A new efficient approach for the removal of impulse noise from highly corrupted images,” **IEEE Trans. Image Process.** v. 5, no. 6, pp. 1012–1025, Jun. 1996.

AIZENBERG, I.; BUTAKOFF, C.; PALIY, D. Impulsive noise removal using threshold boolean filtering based on the impulsive detecting functions. **IEEE Signal Process. Lettrs.** v. 10, n. 1, p 63 – 66, 2005.

ALAJAN, N.; KAMEL, M.; JERNIGAN, E. Detail preserving impulse noise removal. **Signal Processing: Image Communication.** v. 19, n. 10, p 993 – 1003, 2004.

BATTISTELLA, E. **Extração de regras de redes neurais aplicadas ao problema de previsão da estrutura secundária de proteínas.** 2004. 119f. Dissertação (Mestrado em Computação Aplicada) – Centro de Ciências Exatas e Tecnológicas, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2004.

BRAGA, A.; CARVALHO, A. P. L. F.; LUDEMIR, T. R. **Redes neurais artificiais: teoria e aplicação.** 2 ed. Rio de Janeiro: LTC, 2007. 226p.

CHEN, T.; WU, H. R. “Adaptive impulse detection using center weighted median filters”, **IEEE Signal Proc. Letters**, v. 8, n. 1, p. 1–3, 2001.

CHEN, T.; MA, K.; CHEN, L. “Tri-state median filter for image denoising”, **IEEE Trans. Image Process.**, v. 8, n. 12, p. 1834–1838, Dec. 1999.

CORSO, G. et al. Seismic ground roll time-frequency filtering using the gaussian wavelet tranform. **Physical A: Statistical Mechanics and its Applications.** v. 318, n. 3–4, p. 551–561, 2003.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **The Canadian journal for Chemical Engineering**, Illinois, v. 69, n. 4, p. 997-1009, 1989.

DAUBECHIES, I. Ten lectures on wavelets. **Regional Conference Series in Applied Mathematics**, Rutgers University and AT&T Bell Laboratories, 1992.

DAUBECHIES, I. The wavelet transform, time frequency localization, and signal. **IEEE Transactions on Information Theory**. v. 36, n. 5, p. 961-1005. 1990.

ENSIKLOPEDI SEISNIK ONLINE. **Seismic Processing with Seismic Unix - Part2**. Disponível em: <[http://ensiklopediseismik.blogspot.com.br/2010/11/seismic-processing-with-seismic-unix\\_22.html](http://ensiklopediseismik.blogspot.com.br/2010/11/seismic-processing-with-seismic-unix_22.html)>. Acesso em: 20 nov. 2012

ESSENREITER, R.; KARRENBACH, M.; TREITEL, S. Multiple reflection attenuation in seismic data using backpropagation. **IEEE Transactions on Signal Processing**. v. 46, n. 7, p. 2001 – 2011, 1998.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação da informação. **Ciência da Informação**. Brasília, v. 35, n. 1, p. 25-30, jan. 2006.

GABBOUJ, M.; COYLE, E. J.; GALLAGER, N. C. “An overview of median and stack filtering”, **Circuit Syst. and Signal Processing**, v. 11, n. 1, p. 7–45, 1992.

GARNETT, R.; HUEGERICH, T; CHUI, C. A Universal Noise Removal Algorithm with an Impulse Detector, **IEEE Trans. Image Processing**. v. 14, p. 1747–1754, nov. 2005.

GARTNER, L.; HIATT, J. **Tratado de histologia**. Rio de Janeiro: Guanabara-Koogan, 1999. 425p.

GHAZEL, M. **Adaptative fractal and wavelet image denoising**. 2004. 276f. A thesis (Doctor of Philosophy in Electrical and Computer Engineering) - University of Waterloo, Waterloo, Ontario, 2004.

GOMEZ, J.; VELHO, L.; GOLDENSTEIN, S. **Wavelets: teoria, software e aplicações**. 21 Colóquio Brasileiro de Matemática. Instituto de Matemática Pura e Aplicada, Rio de Janeiro – Brasil, 1997.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. 3 ed. São Paulo: Pearson Prentice Hall, 2010. 624p.

GROSSMANN, A.; MORLET, J. **Decomposition of hardy function into square integrable wavelets of constant shape**. SIAM, Journal of Mathematical Analysis, v. 15, n. 4, p. 723-736. 1984.

GUPTA, M.; JIN, L.; HOMMA, N. **Static and dynamic neural networks**: from fundamentals to advanced theory. John Wiley & Sons, Inc., 2003. 722p.

HAYKIN, S. **Redes neurais**: princípios e prática. 2 ed. Porto Alegre: Bookman, 2001. 900p.

HECHT-NIELSEN, R. **Neurocomputing**. Boston: Addison-Wesley Longman, 1989.

KALIRAJ, G.; BASKAR, S. **An efficient approach for the removal of impulse noise from the corrupted image using neural network based impulse detector**, Image and Vision Computing, v. 28, no. 3, p. 458–466, mar. 2010.

LEITE, F. E. A. **Análise estatística de padrões sísmicos: decomposição em multiescala**. 2007. 135 f. Tese (Doutorado em Física) - Departamento de Física Teórica e Experimental, Universidade Federal do Rio Grande do Norte, Natal, RN, 2007.

LEITE, F. E. A.; MONTAGNE, R.; CORSO, G.; VASCONCELOS, G. L.; LUCENA, L. S. Optimal wavelet filter for suppression of coherent noise with an application to seismic data. **Physical A: Statistical Mechanics and its Applications**. v. 387, n. 7, p. 1439–1445, 2008.

MACCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity, **Bulletin of Mathematical Biophysics**, [S.l.], v. 5, p. 115-133, 1943.

MALLAT, S. G. A Theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transaction on Pattern analysis and Machine Intelligence**, v. 11, n. 7, p. 674-693. 1989.

MALLAT, S. G. **Multiresolution representation and wavelets**. Ph.d. thesis, University of Pennsylvania, 1988.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**, Rio de Janeiro: Brasport, 1999. 320p.

MENDONÇA, C. E. L. R. **Um sistema computacional para otimização através de algoritmos genéticos**. 2004. 135f. Tese (Doutorado em Ciência em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2004.

MEYER, Y. **Wavelets: algorithms and applications**. Society for Industrial and Applied Mathematics, Philadelphia, first edition. 1993.

MILLER, M. Image denoising using derotated complex wavelet coefficients. **IEEE Transactions on Image Processing**, v. 17, n. 9, p. 1500 – 1511, set. 2008.

MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J. **Wavelets and their applications**. John Wiley & Sons, 2007. 330 p.

OLIVEIRA, N. R. **Supressão do ruído de rolamento superficial utilizando a transformada curvelet**. 2009. 67f. Dissertação (Mestrado em Ciência e Engenharia de Petróleo) – Universidade Federal do Rio Grande do Norte, Natal, RN, 2009.

PROCHAZKA, A.; GAVLASOVA, A.; VOLKA, K. Wavelet transform in image recognition. **47th International Symposium**, p. 95-98, jun. 2005.

REZVANIAN, A.; FAEZ, K.; MAHMOUDI, F. A Two-Pass Method to Impulse Noise Reduction from Digital Images Based on Neural Networks, **International Conference on Electrical and Computer Engineering – (ICECE)**, Dhaka, p. 400-405, 20-22 Dec. 2008.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, n. 6, p. 386-408, 1958.

RUSSO, F. Impulse noise cancellation in image data using a two-output nonlinear filter. **Measurement**, v. 36, n. 3-4, p. 205-213, out. 2004.

SAMPAIO, T. P. **Ajuste de histórico de produção usando redes neurais artificiais**. 2009. 75f. Monografia (Graduação em Engenharia de Petróleo) – Escola Politécnica da Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2009.

SIGNAL AND IMAGE PROCESSING INSTITUTE. **The USC-SIPI Image Database**. Disponível em : <<http://sipi.usc.edu/database/database.php>>. Acesso em: 20 nov. 2012.

SILVA, A. N. R.; RAMOS, R. A. R.; SOUZA, L. C. L.; RODRIGUES, D. S.; MENDES, J. F. G. **SIG. uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transporte: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, rede neurais artificiais**. São Carlos: EdUFSCar, 2004. 221p.

STOCKWELL, J. **Seismic unix release 34**. Center for Wave Phenomena, Colorado School of Mines. Disponível em: <<http://www.cwp.mines.edu/cwpcodes/index.html>>, 2000.

SUN, T.; NUEVO, Y. “Detail-preserving median based filters in image processing” *Pattern Recognit. Lett.*, v. 15, p. 341–347, Apr. 1994.

THOMAS, J. E. **Fundamentos de engenharia de petróleo**. 2 ed. Rio de Janeiro: Interciência: PETROBRAS, 2001. 271p.

VALENÇA, M. J. S.; LUDEMIR, T. B. Introdução às redes neurais. In: GALVÃO, Carlos de Oliveira; VALENÇA, Mêuser jorge Silva (Org.). **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: UFRGS/ABRH, 1999. 246p.

WANG, J. Z. Methodological review – wavelets and imaging informatics: a review of the literature. **Journal of Biomedical Informatics**, v. 34, n. 2, p. 129-141. 2001.

WANG, Z.; ZANG, D. Progressive switching median filter for removal of impulse noise from highly corrupted images. **IEEE Transaction on Circuits and Systems II: Analog and Digital Signal Processing**. v. 46, n. 1, p. 78-80, jan. 1999.

XING-YAO, Y.; GUO-CHEN, W.; FENG-LI, Y. Predicting oil and gas reservoir and calculating thickness of reservoir from seismic data using neural network. **3rd International Conference on Signal Processing**. v. 2, p. 1601 – 1604, 1996.

XU, H.; ZHU, G.; PENG, H.; WANG, D. Adaptive fuzzy switching filter for images corrupted by impulse noise. **Pattern Recognition Letters**. v. 25, n. 15, p 1657 – 1663, 2004.

XUEPING MA; ZHANG, J.; SONG, A. **3D reservoir modeling with the aid of artificial neural networks**. **International Colloquium on Computing, Communication, Control, and Management**. v. 4, n. ?, p. 8–9, aug. 2009.

YILDIRIM, M.T.; BASTURK, A.; YÜKSEL, M. E. “A Detail-Preserving Type-2 Fuzzy Logic Filter for Impulse Noise Removal from Digital Images”, **Fuzzy Systems Conference IEEE**, London, p. 1-6, 23-26 July. 2007.

YILMAZ, O. **Seismic data processing**. Society of Exploration Geophysicists. Tulsa, Oklahoma. 526p. 2003.

YLI-HARJA, O.; ASTOLA, J.; NEUVO, Y. “Analysis of the properties of median and weighted median filters using threshold logic and stack filter representation”, **IEEE Trans. on Signal Proc.**, v. 39, n. 2, p. 395–410, 1991.

YÜKSEL, M. E. A hybrid neuro-fuzzy filter for edge preserving restoration of images corrupted by impulse noise, **IEEE Trans. Image Process.** v. 15, n. 4, p. 928–936, Apr. 2006.

YÜKSEL, M. E.; BASTÜRK, A. “Efficient removal of impulse noise from highly corrupted digital images by a simple neuro-fuzzy operator”, **AEU Internat. J. Electron. Comm.**, v. 57, n. 3, p. 214–219, 2003.

ZHANG, D.; WANG, Z. “Impulse noise detection and removal using fuzzy techniques” **Electron. Lett.**, v. 33, n. 5, p. 378–379, 1997.

ZHANG, S.; KARIM, M. A. “A new impulse detector for switching median filters,” **IEEE Signal Process. Lett.**, v. 9, n. 11, p. 360–363, Nov. 2002.

# APÊNDICE

## PUBLICAÇÕES RELACIONADAS À DISSERTAÇÃO

- **Artigos aceitos para publicação**

SOARES, P. L. B.; da SILVA, J. P. Neural networks applied for impulsive noise reduction from digital images. In: INFOCOMP – Journal of Computer Science. 2013. Lavras, MG. **Anais...**, Lavras, MG, 2013.

SOARES, P. L. B.; da SILVA, J. P. Redes neurais aplicadas na redução de ruído impulsivo de imagens digitais. In: RBCA – Revista Brasileira de Computação Aplicada. 2013. Passo Fundo, RS. **Anais...**, Passo Fundo, RS, 2013.

- **Artigos submetidos**

SOARES, P. L. B.; da SILVA, J. P.; SANTOS, M. D. Neural networks applied in conjunction with wavelet for image seismic analysis in oil reservoirs. In: Journal of Petroleum Science and Engineering. 2012.