



Universidade Federal de Campina Grande

Centro de Engenharia Elétrica e Informática

Curso de Graduação em Engenharia Elétrica

Pablo Bezerra Vilar

**DESENVOLVIMENTO DE REDES NEURAIS
AUTO-ASSOCIATIVAS PARA CLASSIFICAÇÃO DE
RUÍDO ACÚSTICO EMITIDO POR ISOLADORES CERÂMICOS**

Campina Grande, Paraíba
Fevereiro de 2011

PABLO BEZERRA VILAR

DESENVOLVIMENTO DE REDES NEURAIIS
AUTO-ASSOCIATIVAS PARA CLASSIFICAÇÃO DE
RUÍDO ACÚSTICO EMITIDO POR ISOLADORES CERÂMICOS

*Relatório de Trabalho de conclusão de curso
submetido à Unidade Acadêmica de Engenharia
Elétrica da Universidade Federal de Campina
Grande como parte dos requisitos necessários
para a obtenção do grau de Bacharel em
Ciências no Domínio da Engenharia Elétrica.*

Área de Concentração: Processamento de Energia

Orientador:

Professor Tarso Vilela Ferreira, M. Sc.

Campina Grande, Paraíba
Fevereiro de 2011

PABLO BEZERRA VILAR

DESENVOLVIMENTO DE REDES NEURAIS
AUTO-ASSOCIATIVAS PARA CLASSIFICAÇÃO DE
RUÍDO ACÚSTICO EMITIDO POR ISOLADORES CERÂMICOS

*Trabalho de Conclusão de Curso submetido à
Unidade Acadêmica de Engenharia Elétrica da
Universidade Federal de Campina Grande como
parte dos requisitos necessários para a obtenção do
grau de Bacharel em Ciências no Domínio da
Engenharia Elétrica.*

Área de Concentração: Processamento de Energia

Aprovado em / /

Professor Avaliador
Universidade Federal de Campina Grande
Avaliador

Professor Tarso Vilela Ferreira, M. Sc.
Universidade Federal de Campina Grande
Orientador, UFCG

*“Nunca tenha medo de tentar algo novo.
Lembre-se de que um amador solitário construiu a Arca.
Um grande grupo de profissionais construiu o Titanic.”*

Luís Fernando Vérissimo.

RESUMO

Este trabalho visou o desenvolvimento de um algoritmo de Redes Neurais Auto-Associativas para o reconhecimento de padrões de ultrassom emitido por isoladores elétricos, e comparar o desempenho do algoritmo desenvolvido, com o de uma Rede Neural pré-existente, dedicada à mesma função. Os resultados iniciais lançaram bases para o desenvolvimento de um algoritmo que permite o aprimoramento da taxa de acerto da Rede Neural Auto-Associativa desenvolvida, ao custo de um maior esforço computacional durante a fase de treinamento. Os resultados deste algoritmo mostram-se promissores, sobretudo levando em consideração vários fatores que influenciam o desempenho de uma Rede Neural Auto-Associativa, como o método de treinamento, não foram avaliados. Considerando que o esforço computacional envolvido concentra-se prioritariamente na fase de treinamento, o algoritmo pode ser aplicado em áreas onde a taxa de acerto obtida com os métodos tradicionais não seja suficiente. Todos os Algoritmos foram desenvolvidos com o Software MatLab.

Palavras-chave: Redes Neurais, Redes Neurais Auto-Associativas, Isoladores, Ruído ultrassônico.

ABSTRACT

This work aimed to develop an algorithm of an Auto-Associative Neural network to recognize patterns of ultra-sound emitted by an electric insulator, as well as to compare the performance of the developed algorithm with an existing Neural Network, dedicated to the same task. The preliminary results promoted the development of an advanced algorithm that is capable of improving the match rate at the expense of higher computational effort during the training phase. The results achieved with this algorithm are promising, especially considering that various factors that influence the performance of an Auto-Associative Neural Network were not analyzed, like the algorithm used to train the Network. Considering that the computational effort involved is mainly in the train phase this algorithm might be useful in areas where the match rate obtained with the traditional methods are not enough. All the algorithms were developed and tested use the MatLab Software.

Keywords: Neural Networks, Auto-Associative Neural Network, Insulators, Ultrasound noise.

SUMÁRIO

1	Introdução	1
1.1.	Delimitação do tema.....	1
1.2.	Motivação.....	2
1.3.	Objetivos	3
2	Isoladores cerâmicos	4
2.1.	Introdução	4
2.1	Métodos de Monitoramento	5
3	Redes neurais artificiais	7
3.1.	Introdução	7
3.2.	Desenvolvimento histórico das RNA.....	7
3.3.	O neurônio artificial	8
3.4.	<i>Perceptron</i> de múltiplas camadas.....	10
3.5.	<i>Treinamento de uma RNA</i>	11
3.6.	<i>O Algoritmo Resilient Propagation (RPROP)</i>	12
3.7.	<i>RNA auto-associativas</i>	14
3.8.	<i>Extração de atributos e a base de dados</i>	15
4	Algoritmos propostos	17
4.1.	<i>Algoritmo 1 – RNAA sem definição de taxa de acertos mínima</i>	17
4.1.1.	<i>Testes de desempenho</i>	19
4.2.	<i>Algoritmo 2 – RNAA com taxa de acertos mínima</i>	21
4.2.1.	<i>Testes de desempenho</i>	23
5	Conclusões	24
	Referências Bibliográficas	25
	ANEXO A – Extração de Atributos. Vetores de Energia dos Centróides de Sub-bandas Espectrais	27

1 INTRODUÇÃO

1.1. DELIMITAÇÃO DO TEMA

A nossa sociedade a cada dia que passa torna-se mais e mais dependente do uso da energia elétrica. Garantir um fornecimento confiável de energia é fundamental para a manutenção da realidade que conhecemos. Assim é preciso gerar, transmitir e distribuir energia elétrica ininterruptamente.

Os isoladores são equipamentos presentes em todo processamento da energia, desde a geração nas usinas até a entrega ao consumidor final, têm por função básica segregar regiões em diferentes potenciais, mantendo com um escoamento mínimo de corrente e provendo suporte mecânico.

Dada a importância dos isoladores, existem hoje diversos estudos que visam determinar as condições dos isolamentos elétricos para que se possa aumentar sua vida útil e antecipar possíveis defeitos. Um ramo de estudo particularmente promissor é a análise da emissão de ruído ultrassônico por parte dos isoladores visando estimar suas condições.

O método de avaliar os isoladores com base no ruído emitido apresenta a vantagem de que não há necessidade de um contato direto com o equipamento a ser avaliado, uma vez que é preciso somente amostras do ruído por ele emitido.

No entanto, a classificação dos ruídos ultrassônicos esbarra no fato de que eles não apresentam um padrão lógico. Contudo, segundo Ferreira (2010), é possível classificar o nível de poluição dos isoladores com base no ruído ultrassônico por ele emitido utilizando-se uma Rede Neural Artificial.

As redes neurais artificiais se fundamentam nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar informações. Apesar de se desconhecer a maneira pela qual o cérebro manipula informações complexas (BEALE & JACKSON, 1990), sabe-se que a modelagem do conhecimento contido em um problema específico pode ser representada através de interconexões entre células nervosas. Estruturalmente, a rede neural artificial, também conhecida por

modelo conexionista de computação, se assemelha à rede neural biológica pela composição de seus neurônios e pela conexão entre eles(WASSERMAN, 1989).

1.2. MOTIVAÇÃO

As RNA permitem classificar padrões que não apresentam separabilidade aparente ou simples aos olhos humanos, como características extraídas dos ruídos ultrassônicos emitidos por isoladores. No entanto, existem diversas arquiteturas de RNA, e cada uma responde de forma diferente a diferentes padrões.

Assim, é preciso avaliar um mesmo problema com diversas arquiteturas diferentes antes de definir qual RNA é mais adequada sob vários aspectos, como precisão, exatidão, confiabilidade e tempo de resposta.

Outro aspecto importante é que nas arquiteturas usuais de RNA os parâmetros da rede são determinados visando atingir um nível ótimo da taxa de acertos, de modo que caso a taxa de acerto de uma rede não atenda as necessidades do problema é preciso buscar ajustes, muitas vezes empíricos, na arquitetura da rede.

Fica claro então que a busca da arquitetura adequada não é um processo fácil. É claro também que uma arquitetura genérica de rede que possibilite traçar uma taxa de acerto mínima como alvo poderia substituir o processo de busca pela arquitetura ótima.

1.3. OBJETIVOS

Este trabalho busca o desenvolvimento de uma RNA com arquitetura Auto-Associativa para ser aplicada na classificação de ruídos ultrassônicos registrados em isolamentos elétricos, e comparar seu desempenho com o de uma rede *Perceptron* de Múltiplas Camadas (MLP) usual, como a apresentada por Ferreira (2010).

Além disso, neste trabalho apresenta-se uma adaptação do processo de treinamento das RNA, que ao custo de um aumento no esforço computacional permite traçar uma taxa de acertos mínima, permitindo uma solução de compromisso entre taxa de acertos e custo computacional.

2 ISOLADORES CERÂMICOS

2.1. INTRODUÇÃO

Em qualquer sistema elétrico existe a necessidade de segregar regiões com diferentes potenciais elétricos. Para tanto, são empregados materiais isolantes de diversas naturezas, de acordo com a necessidade. São estes materiais que constituem as partes essenciais dos isolamentos elétricos. Entende-se por isolador o equipamento utilizado para isolar cabos energizados de regiões em outro potencial elétrico, bem como prover sustentação mecânica para o cabo.

Isoladores de vários formatos e constituídos de diversos materiais são encontrados atualmente nos sistemas elétricos. De maneira geral, podem ser divididos em orgânicos, que apresentam carbono em sua constituição, e cerâmicos que baseiam-se em materiais cerâmicos como vidro e porcelana. Existem ainda os isolamentos híbridos, que possuem tanto partes cerâmicas quanto orgânicas, a fim de explorar as vantagens de ambas as tecnologias.

Nos últimos 30 anos o emprego dos isoladores poliméricos vem crescendo, no entanto, devido à experiência acumulada nos mais de noventa anos de uso de isolamentos cerâmicos, as técnicas de diagnóstico destes equipamentos são muito mais difundidas que as técnicas de diagnóstico de isolamentos orgânicos e híbridos, estas últimas muitas vezes consideradas não-confiáveis. Assim, isolamentos cerâmicos ainda são preferidos por muitas empresas.

Comparados com outros equipamentos de um sistema elétrico, como transformadores, por exemplo, os isoladores apresentam um custo muito baixo, mas, os prejuízos acarretados devido à falha dos mesmos podem ser bastante significativos. Por isso, a inspeção e a lavagem periódica destes equipamentos se fazem necessárias, a fim de que unidades defeituosas sejam trocadas e de que a poluição acumulada sobre os discos cerâmicos não reduza a capacidade de isolamento a níveis perigosos.

A forma mais simples de inspeção é a inspeção visual a distância, porém, os isoladores de porcelana, são difíceis de diagnosticar por este método, por que podem apresentar trincas sutis, perda da camada vitrificada e perfurações entre o pino e a

campânula, defeitos pouco perceptíveis visualmente, mas que tem efeitos significativos na redução da capacidade de isolamento da peça. Por outro lado, os isoladores de vidro temperado comumente estilhaçam-se ao sofrer algum tipo de agressão mecânica ou térmica mais severa, permitindo a pronta detecção visual, tendo sua troca providenciada.

A poluição, no entanto, não é de tão simples detecção visual, especialmente à distância em que são realizadas as inspeções. Conforme se depositam sobre os isolamentos os poluentes diminuem a resistência superficial, permitindo a evolução de mecanismos que levam à ruptura do isolamento: elevação da corrente de fuga, a formação de bandas secas quando há umidade ambiente suficiente, a formação de arcos voltaicos superficiais, etc. Portanto, lavagens periódicas devem ser executadas nas cadeias de isoladores cerâmicos.

2.1 MÉTODOS DE MONITORAMENTO

Em isoladores constituídos de vidro ou porcelana, mesmo íntegros, quando a poluição se deposita sobre sua superfície, há redução da sua capacidade de isolamento. Para a detecção de poluição, a inspeção visual normalmente é imprecisa dependendo de vários fatores como: tipo de poluição, umidade, configuração de campo elétrico, etc.

Neste contexto, outras técnicas de inspeção, periódicas ou em tempo real, foram propostas. Dentre essas técnicas, as mais difundidas são a medição do acúmulo equivalente de sal, condutividade superficial, corrente de fuga, medição de poluição do ar, medições ópticas e medição de acúmulo de partículas não-solúveis (Cigrè Task Force 33.04.03, 1994).

Vários destes métodos de inspeção têm aplicação pouco viável em campo. Os métodos que se baseiam no acúmulo equivalente de sal, partículas não-solúveis ou mesmo medição de condutividade superficial requerem análise laboratorial do material recolhido ou de amostras. O monitoramento da corrente de fuga pode ser realizado em campo, mas requer transdutores de corrente de alta qualidade e custo; além disso, a interferência eletromagnética das redondezas pode reduzir significativamente a confiabilidade das medições de corrente (Pei C. , Shu, Li, Wang, & Li, 2008).

Assim, para medições em campo, as inspeções acústicas apresentam algumas vantagens frente a outros métodos de inspeção. A imunidade ao ruído eletromagnético, a distância segura na qual são realizadas as medições e a rápida inspeção de várias

unidades isolantes são algumas destas vantagens. Existem várias aplicações envolvendo detecções acústicas, tal qual inspeções de isoladores externos, equipamentos isolados a gás, capacitores, etc. (Lundgaard, Partial discharge XIII: Acoustic partial discharge detection-fundamental considerations, 1992a).

A inspeção de isolamentos empregando ruídos acústicos baseia-se em um efeito mecânico das descargas elétricas. As descargas corona que ocorrem nas redondezas de isoladores poluídos resultam em liberação localizada e praticamente instantânea de energia. Esta energia produz calor, ruído acústico e ruído eletromagnético. A amplitude de uma onda acústica criada por uma única descarga é proporcional à raiz quadrada da energia mecânica liberada na descarga (Lundgaard, Partial discharge XIV: Acoustic partial discharge detection - Practical application, 1992b).

Por outro lado, alguns especialistas consideram a inspeção de isolamentos baseada em ruídos acústicos pouco confiável (Gorur, Burnham, & Cherney, 1999). Esta desconfiança baseia-se majoritariamente na subjetividade humana inerente à realização do diagnóstico, uma vez que o indivíduo incumbido de fazer o julgamento acerca do estado do isolamento pode não ser suficientemente treinado ou experiente. Além disso, o método mais amplamente empregado nas inspeções baseava-se deterministicamente na amplitude do ruído, parâmetro fortemente dependente da distância, da incidência do vento, etc. Desta forma, os diagnósticos baseados em RU, quando do uso apenas do julgamento humano e sem o emprego de uma análise mais detalhada do sinal, permitem a ocorrência de falsos positivos e falsos negativos. Esta ocorrência, em geral, é alta o suficiente para desencorajar o emprego da técnica.

Uma das alternativas para o aumento da confiabilidade das técnicas envolvendo emissões acústicas em equipamentos de alta tensão é reduzir a atuação humana na tomada de decisão, empregando, para isso, algoritmos de extração de atributos especializados e técnicas de reconhecimento de padrões para apoio a tomada de decisão, como por exemplo as redes neurais.

3 REDES NEURAIS ARTIFICIAIS

3.1. INTRODUÇÃO

Podemos definir uma RNA como um sistema de processamento de informações cujo funcionamento é inspirado na estrutura física natural do cérebro humano (Haykin S. , 1994). As RNA são aplicadas majoritariamente no reconhecimento de padrões, em problemas de otimização e na previsão de sistemas complexos. Sua capacidade de formar mapeamentos não lineares as torna particularmente atrativas nesses campos.

Através de um processo de treinamento baseado na apresentação de exemplos, as RNA passam a ser capazes de responder a estímulos de entrada. Conforme o aprendizado, a rede se torna capaz de reconhecer padrões classificando então as entradas, ou seja, quando uma entrada é aplicada à rede, esta fornece uma resposta de saída indicando a classe a qual a entrada pertence.

A habilidade de manipular dados imprecisos, similares aos apresentados no treinamento porém não necessariamente iguais, faz com que as RNA sejam extremamente eficazes em tarefas onde especialistas não estão à disposição ou onde um conjunto de regras não pode ser facilmente formulado. Esta capacidade das RNA é geralmente conhecida por generalização (Haykin S. , 2001).

3.2. DESENVOLVIMENTO HISTÓRICO DAS RNA

A idéia de mimetizar o raciocínio e aprendizagem humana, embrião das RNA, recebeu sua primeira abordagem matemática na década de 40, no trabalho desenvolvido pelo neurofisiologista McCulloch e pelo matemático Walter Pitts da Universidade de Illinois, que fizeram uma analogia entre células nervosas vivas e o processo eletrônico num trabalho publicado sobre os neurônios formais. O trabalho consistia num modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio (Haykin S. , 1994).

Posteriormente o psicólogo Donald Hebb explicou o que ocorre, em nível celular, durante o processo de aprendizagem no cérebro. Isso serviu de base para o desenvolvimento dos métodos de treinamento de RNA. Em 1959, foi apresentada a rede Adaline e, em 60, a rede *Perceptron*, por Frank Rosenblatt (Haykin S., 1994).

No entanto, naquela época os sistemas de processamento de dados ainda não estavam preparados para o esforço computacional que uma RNA com aplicação prática exige. Isso ficou claro quando em 69, Marvin Minsky e Seymour Papert, publicaram um livro chamado “*Perceptron*”, no qual, resumiram e criticaram seriamente a pesquisa neste ramo da inteligência artificial, apresentando exemplos de limitação do uso dessas redes (Haykin S., 1994).

Isto levou a uma retração na evolução de pesquisas sobre RNA e só então em 1982 com novas propostas lançadas por Rumelhart e McClelland, as pesquisas voltaram a aparecer (Haykin S., 1994).

Desde então, diversos modelos de RNA têm surgido com o propósito de aperfeiçoar e aplicar esta tecnologia a diversas áreas diferentes. Algumas destas propostas tendem a aperfeiçoar mecanismos internos da RNA para aplicação na indústria e negócios, outras procuram aproximá-las ainda mais dos modelos biológicos originais.

3.3. O NEURÔNIO ARTIFICIAL

O neurônio é a unidade de processamento fundamental da RNA. O modelo de um neurônio artificial é apresentado na Figura 1.

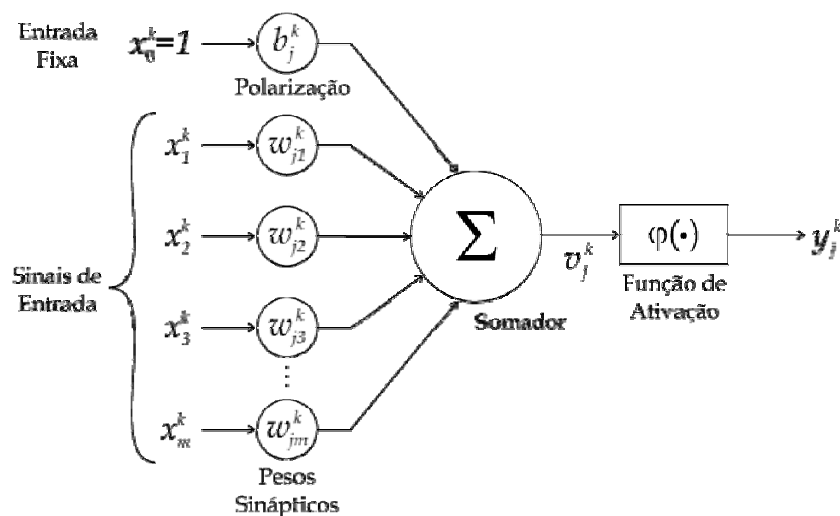


Figura 1: Modelo de Neurônio Artificial (Silva, 2005)

Pode-se identificar no modelo de neurônio artificial um conjunto de sinapses ou conexões, caracterizadas individualmente por um peso sináptico w_{ji}^k , cada elemento do vetor de entrada x^k será multiplicado pelo peso w_{ji}^k correspondente.

O elemento somador, tem a função de realizar uma combinação linear dos sinais de entrada, ponderados pelos respectivos pesos sinápticos de suas ligações. O resultado dessa combinação é passado à função de ativação φ_j^k .

Na maioria das aplicações, as redes neurais são utilizadas para realizar mapeamentos não-lineares, pois existem ferramentas mais adequadas para análises lineares. Para que um neurônio seguindo o modelo apresentado possa realizar um mapeamento não-linear, a função de ativação precisa ser não-linear, geralmente apresenta um intervalo de saída normalizado entre $[0,1]$ ou $[-1,1]$.

O modelo do neurônio também inclui um termo denominado de polarização (também conhecido por *Bias*) representado por b_j^k , cujo efeito é modificar a entrada da função de ativação, através da aplicação de um sinal de entrada com valor fixo em $+1$, a inserção de um termo livre confere um grau de liberdade a mais ao neurônio.

Em termos matemáticos, um neurônio j localizado na camada k é descrito através do seguinte par de equações:

$$v_j^k = b_j^k + \sum_{i=1}^{I^k} w_{ij}^k x_i^k, \quad (1)$$

$$y_j^k = \varphi_j^k(v_j^k), \quad (2)$$

nas quais I^k representa o número de entradas da camada; $x_0^k, x_1^k, \dots, x_{I^k}^k$, os sinais de entrada; $w_{j1}^k, w_{j2}^k, \dots, w_{jm}^k$, os pesos sinápticos; b_j^k , a polarização; v_j^k , o potencial de ativação; $\varphi_j^k(\cdot)$, a função de ativação e y_j^k o sinal de saída.

A função de ativação, $\varphi_j^k(\cdot)$, define a saída de um neurônio j em termos de um potencial de ativação v_j^k , limitando o resultado a um intervalo conhecido. Isto evita que informações propaguem-se pelas camadas da RNA sem limite numérico de crescimento, o que pode ocasionar a saturação dos neurônios e a perda de eficiência da rede (Silva, 2005).

Dentre as funções de ativação, destacam-se as funções sigmoidais, como a função sigmóide (Conjunto Imagem = [0, 1]):

$$\varphi_j^k(v_j^k) = \frac{1}{1 + e^{-av_j^k}}, \quad (3)$$

Outra função de ativação sigmoidal amplamente empregada é a tangente hiperbólica (Conjunto Imagem = [-1,1]):

$$\varphi_j^k(v_j^k) = \frac{1 - e^{-av_j^k}}{1 + e^{-av_j^k}}, \quad (4)$$

Tanto na Equação (3), quanto na Equação (4), o parâmetro a , cujo valor é sempre maior que zero, representa a suavidade da função.

3.4. *PERCEPTRON* DE MÚLTIPLAS CAMADAS

Dentre as arquiteturas de RNA, a mais conhecida é certamente a chamada rede *Perceptron* de Múltiplas Camadas (MLP), que consiste numa generalização da rede *Perceptron* de Camada Única (Haykin S., 2001).

Pode-se definir como camada de uma rede um conjunto de neurônios em paralelo. Uma MLP consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, todas conectadas, conforme mostrado na Figura 2.

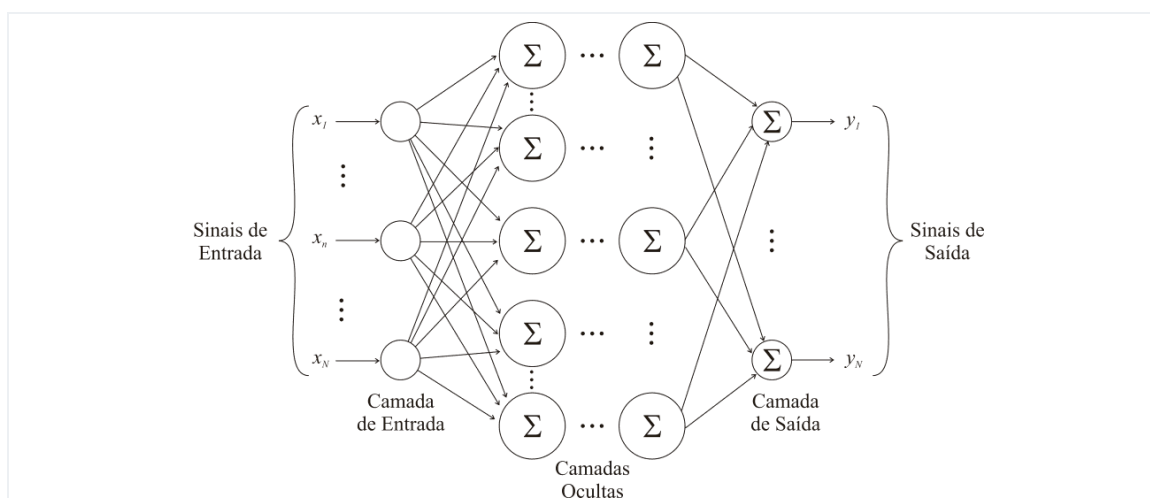


Figura 2 : RNA com Arquitetura MLP (Silva, 2005).

Geralmente a camada de entrada tem a função apenas de distribuir o sinal, não sendo neurônios propriamente ditos. O sinal de entrada se propaga através da rede, camada a camada, a partir das equações (3) e (4), até que um sinal de saída seja computado (Haykin S., 1994).

3.5. *TREINAMENTO DE UMA RNA*

Para que uma RNA possa exercer alguma função útil ela deve ser treinada. Entende-se por treinamento o processo de ajuste dos pesos de todos os neurônios da rede até que a resposta da mesma atenda as especificações desejadas.

Com base no tipo de aprendizado utilizado, definem-se duas categorias distintas de redes: supervisionadas e não-supervisionadas. As primeiras são redes que utilizam um treinamento, a partir de um conjunto definido de entradas e saídas desejadas. Por outro lado, as não-supervisionadas realizam o agrupamento dos padrões em classes a partir de suas semelhanças, medidas através de métricas como a norma euclidiana, não sendo necessária a indicação da saída desejada.

Designa-se por padrão toda entrada de uma RNA, seja durante o treinamento ou depois de treinada. Cada padrão apresentado a uma RNA é classificado em uma dada classe, de acordo com o treinamento da rede, de modo que analogamente aos padrões, que são entradas da rede, as classes são as saídas.

O método mais simples e tradicional de treinar uma RNA é o chamado *Backpropagation* (Rumelhart & McClelland, 1986). Neste método, o treinamento da rede consiste em apresentar uma base de dados de entrada à mesma, e a partir das saídas obtidas, calcular o erro entre estas e a saída esperada. Então utiliza-se esta informação para atualizar os pesos sinápticos da rede. Este processo se repete em várias iterações, conhecidas como épocas, até que a RNA apresente um desempenho adequado (erro inferior à uma tolerância pré-estabelecida).

Assim espera-se que a rede possa responder não só aos elementos presentes na base de dados de treinamento como também em casos similares desconhecidos.

O algoritmo *Backpropagation* tem como essência a propagação do erro de saída entre as camadas ocultas. No processo de aprendizado de uma RNA costuma-se dividir a base de dados em três grupos distintos:

- **Treinamento:** Responsável por passar efetivamente o conhecimento sobre a aplicação em questão. Durante a etapa de treinamento todos os padrões de treinamento são apresentados sucessivas vezes à RNA, em iterações chamadas épocas.
- **Validação:** O conjunto de validação é utilizado para supervisionar o desenvolvimento da capacidade de generalização da rede durante a fase de aprendizagem. Ao fim de cada época o conjunto de dados de validação é apresentado à RNA, permitindo-se verificar se a rede consegue tomar decisões corretas a partir de dados que não compõem o conjunto de treinamento.
- **Teste:** o conjunto de teste só é aplicado ao final da etapa de aprendizagem, para verificar a qualidade do aprendizado da rede.

A maior parte da base de dados, cerca de 70%, é utilizada para o treinamento. Os demais são divididos igualmente entre validação e teste. É importante frisar que sempre que uma rede for preparada para reconhecer C classes em seu treinamento, devem ser apresentados um mesmo número de n padrões de cada uma das C classes. Com isso, evita-se que o treinamento torne-se tendencioso a uma classe.

Outro algoritmo mais sofisticado, chamado de *Resilient Propagation* (Riedmiller & Braun, 1993), será apresentado posteriormente.

3.6. O ALGORITMO RESILIENT PROPAGATION (RPROP)

Proposto em 1993 por Riedmiller e Braun, este algoritmo se presta a treinar RNA de múltiplas camadas. De maneira geral, o RPROP é uma modificação do algoritmo já citado *backpropagation* (Rumelhart & McClelland, 1986).

Ao contrário do algoritmo *backpropagation*, que ajusta os pesos com base no erro propriamente dito, este método faz sucessivos incrementos ou decrementos crescentes nos pesos e analisa a taxa de variação do erro. Quando houver uma mudança no sinal do gradiente da função erro, significa que houve um salto sobre um extremo local, no melhor caso o mínimo global, então o sistema deve retroceder um passo e então realizar incrementos mais sutis. Este processo se repete até que seja atingido algum critério de parada previamente definido.

Em termos quantitativos o incremento dos pesos pode ser expresso segundo a Equação (6).

$$\Delta_{ji}^k(m) = \begin{cases} \eta^+ \cdot \Delta_{ji}^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) > 0 \\ \eta^- \cdot \Delta_{ji}^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) < 0 \\ \Delta_{ji}^k(m-1), & \text{caso contrário} \end{cases} \quad (6)$$

em que $\eta^- = 0,5$; $\eta^+ = 1,2$ ¹; e $\mathcal{E}_{med}(m)$ é a função energia de erro média de uma época m definida como:

$$\mathcal{E}_{med}(m) = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n), \quad (7)$$

em que, N é o número total de padrões do conjunto de treinamento e $\mathcal{E}(n)$ é função energia de erro para um padrão de entrada n pertencente ao conjunto de treinamento.

O gradiente local $\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)$ avaliado para uma época de treinamento é dado

por:

$$\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) = \frac{1}{N} \sum_{n=1}^N \frac{\partial \mathcal{E}}{\partial w_{ji}^k}(n). \quad (8)$$

Assim, calculado o gradiente da função erro utilizando a Equação (8) o incremento de pesos é definido segundo a Equação (6). Caso não haja mudança no gradiente, o próximo passo será η^+ vezes o anterior; caso haja uma mudança de sinal no gradiente, a configuração anterior deve ser retomada e o próximo passo será η^- vezes o passo anterior.

É importante notar que a mudança nos pesos da RNA depende apenas do sinal de $\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)$, independentemente do seu valor absoluto. Esse artifício permite com que o algoritmo seja muito eficiente mesmo em situações onde o gradiente é muito pequeno, que é o caso em que a superfície de erro tem uma forma plana.

¹ Valores típicos recomendados pelos autores do algoritmo.

Reduzir o esforço computacional do treinamento é possível, com uma boa estimativa do valor inicial dos pesos. No entanto, não foi empregado neste trabalho nenhum método que proporcionasse isto, de modo que os pesos são inicializados com valores aleatórios. Como não há nenhuma forma de prioridade entre os padrões, estes também devem ser apresentados a rede em ordem aleatória.

3.7. RNA AUTO-ASSOCIATIVAS

Proposta por Kramer (1991), uma Rede Neural Auto-Associativa (RNAA) pode ser definida como uma Rede *feedforward*, ou seja, durante o processo de classificação de padrões os dados se propagam em sentido único, da entrada para saída (Haykin S., 1994) com uma estrutura que atenda os requisitos de auto-associatividade (Ikbâl, Hemant, & Yegnanarayana, 1999), permitindo que a saída possa ser uma réplica da entrada.

A estrutura geral de uma RNAA pode ser visualizada na Figura 3.




Figura 3 - Estrutura Geral de Uma RNAA.

A estrutura de uma RNAA apresentada na Figura 3 consiste numa camada de entrada, uma camada de saída e uma ou mais camadas escondidas, sendo que o número de neurônios na camada de saída deve ser igual ao número de neurônios na camada de entrada. Para aplicações em compactação de dados, o número de neurônios em pelo menos uma das camadas escondidas deve ser menor que o número de neurônios nas camadas de entrada e saída. Esta camada de dimensionalidade inferior é geralmente chamada de camada de compressão de dimensão ou camada de gargalo (Dong, Lin, & Watanabe, 2009).

Num mapeamento auto-associativo a saída alvo é a própria entrada, assim a função transferência entre a camada escondida e a camada de saída será o inverso da função de transferência entre a camada de entrada e a camada escondida, ao menos no caso ideal.

De modo geral, quando se busca um mapeamento não linear, a função tangente hiperbólica deve ser utilizada como função de ativação das camadas escondidas (Ikbal, Hemant, & Yegnanarayana, 1999). O algoritmo *backpropagation*, e aqueles baseados nele podem ser utilizados com sucesso no treinamento de RNAA da mesma forma que são aplicados no treinamento de RNA (Rumelhart, Hinton, & Williams, 1998).

As RNAA são aplicadas com sucesso em vários problemas de reconhecimento de padrões, como reconhecimento de voz e problemas de compressão de dados (Kramer, 1991).

Quando aplicada em problemas de compressão, o funcionamento da RNAA consiste em obter os dados da camada escondida, que tem uma dimensão inferior e portanto representa compressão de dados. O processo de descompressão consiste em passar os dados comprimidos pela camada de saída, uma vez que esta deve reproduzir a entrada, os dados serão então recuperados.

Quando aplicada para reconhecimento de padrões, uma RNAA deve replicar na saída o sinal de entrada. No entanto, isto só acontecerá se este sinal se adequar aos padrões para os quais a RNAA foi treinada, caso contrário a saída não será igual a entrada. Assim, a rede pode ser interpretada como um filtro que permite somente a passagem dos sinais que se encaixem nos moldes estabelecidos durante o treinamento da rede.

Para fins de reconhecimento de padrão não há, portanto, necessidade de uma camada de gargalo. No entanto, o uso de camadas escondidas com mais neurônios que as camadas de entrada e saída acarreta num elevado esforço computacional, de modo que o ideal é sempre utilizar o menor número possível de neurônios de forma a atender as especificações de projeto.

3.8. EXTRAÇÃO DE ATRIBUTOS E A BASE DE DADOS

Um problema fundamental em reconhecimento de padrões é a definição das características dos dados os quais são realmente importantes para os processos

posteriores de classificação e verificação de padrões, ou seja, a chamada Extração de Atributos ou Extração de Características.

O principal objetivo desta seleção é transformar amostras de entrada em um novo espaço, onde a informação acerca das amostras é retida, mas a ordem de dimensão é reduzida. Esta redução possibilita uma redução considerável no número de neurônios de todas as camadas da RNA, notadamente em RNAA onde o número de neurônios de saída deve ter a mesma dimensão da camada de entrada, que por sua vez coincide com o número de elementos constituintes dos vetores de entrada (padrões das classes).

Existem vários procedimentos viáveis para a extração de atributos, deve-se sempre buscar o método que retrate melhor o problema em questão.

Como a RNAA desenvolvida neste trabalho deve reconhecer padrões de ultrassom emitidos por isolamentos elétricos, seria inviável uma análise sem uma extração de atributos eficiente, devido ao elevado esforço computacional. Com o intuito de comparar esta rede com uma RNA pré-existente, foi utilizada a base de dados desenvolvida por Ferreira (2010). Maiores informações a cerca do processo de extração de atributos na construção dessa base de dados podem ser encontrados no apêndice A.

4 ALGORITMOS PROPOSTOS

A análise do algoritmo desenvolvido neste trabalho pode ser dividida em duas etapas: num primeiro momento, analisar-se-á o algoritmo de uma RNAA treinada através do já descrito algoritmo RPROP, porém sem a capacidade de definir uma porcentagem de acertos mínima; em seguida será analisado o algoritmo que dota a RNAA desta capacidade.

Os dados a serem reconhecidos pela rede consistem em emissões de ultrassom em 5 diferentes classes de poluição, previamente tratadas pelo processo de extração de atributos descrito no Apêndice A.

Todos os algoritmos aqui citados foram desenvolvidos no ambiente do Software MatLab.

4.1. ALGORITMO 1 – RNAA SEM DEFINIÇÃO DE TAXA DE

ACERTOS MÍNIMA

Uma RNAA treinada para reconhecer n Classes diferentes pode ser compreendida como um conjunto de n RNAs, cada uma treinada para reconhecer apenas uma classe, doravante estas redes serão chamadas sub-redes (SR). Assim, uma vez treinada a rede, cada vetor de entrada é apresentado às n sub-redes e aquela que apresentar a menor energia de erro será considerada como vencedora.

Em muitos casos este método de classificação permite uma maior flexibilidade na análise dos resultados, uma vez que podemos analisar o resultado da saída em função do erro e fazer uma avaliação qualitativa de como se situa o sinal, por exemplo: Num universo de três classes, digamos A,B e C, uma rede pode ser apresentada a um padrão muito próximo de B e C, por consequência as sub-redes B e C apresentaram erros muito menores que a sub-rede A. Assim, muito embora um dos erros, B ou C, seja menor do que o outro, o usuário será alertado da proximidade dos sinais, indicando uma possível imprecisão na resposta, que pode demandar uma análise mais profunda. Caso este

mesmo padrão fosse apresentado a uma RNA MLP comum, seria apenas oferecida uma resposta qualquer ou inconclusiva, sem qualquer forma de alerta ao usuário.

Outra vantagem da abordagem das sub-redes se mostra quando ocorre o surgimento de uma nova classe. Primeiramente nenhuma das sub-redes apresentaria uma energia de erro baixa, indicando ao usuário a possibilidade de que a resposta da RNAA não esteja adequada. Após a detecção do problema, seria necessário apenas o treinamento de uma nova sub-rede sem alterar as demais. No caso de uma MLP, não só a detecção do problema seria mais difícil como seria necessário um novo treinamento completo.

Para o treinamento e funcionamento do Algoritmo da RNAA desenvolvida, devem ser fornecidos os seguintes dados:

- Base de dados, composta de 1600 vetores, divididos em 5 classes diferentes. Cada vetor apresenta 29 elementos, mesmo número de neurônios na camada de entrada da RNA;
- Número máximo de Épocas de Treinamento, arbitrariamente definido como 5000;
- Critérios de Parada:
 - Tolerância de Precisão de erro;
 - Tolerância de Diferença entre erro de Treinamento e Validação.

O parâmetro, tolerância de precisão de erro, corresponde à diferença entre dois erros de treinamento consecutivos. Caso o treinamento de uma RNA, seja terminado por atingir o número máximo de épocas é possível que o treinamento tenha sido incompleto ou insuficiente.

Por isso, usualmente o treinamento é encerrado quando uma das duas citadas tolerâncias é ultrapassada, de modo que o número máximo de épocas serve apenas para impedir que o algoritmo que treina a rede neural não fique preso em um laço infinito.

Inicialmente a base de dados fornecida deve ser fracionada em duas partes, dados para treinamento e dados para testes. Neste trabalho, utiliza-se 85% da base de dados, escolhidos aleatoriamente, para treinamento. Posteriormente a rotina que implementa o algoritmo de treinamento (RPROP) subdivide o grupo de treinamento, retirando 10% dos padrões para uso na validação. Além disso, do total, 15% das amostras são empregadas na etapa de teste.

Assim, de cada classe constituinte da base de dados extrai-se uma parcela para treinamento, totalizando 5 grupos de treinamento. Estes grupos são repassados à rotina RPROP separadamente, que aplica os critérios de tolerância designados, para realizar o treinamento e devolve ao programa principal os vetores de pesos das duas camadas de cada sub-rede.

Já na fase de teste todos os dados designados para teste são processados por cada sub-rede, e é devolvido ao programa principal o erro associado a cada vetor de entrada. Naturalmente, a sub-rede com a menor energia de erro será definido como vencedora. Este resultado obtido pela rede é então comparado com a matriz de respostas, e a taxa de acerto da rede é então calculada como sendo a razão entre os acertos da rede e o número total de padrões empregados no teste.

A figura 4 apresenta um fluxograma do funcionamento do Algoritmo 1.

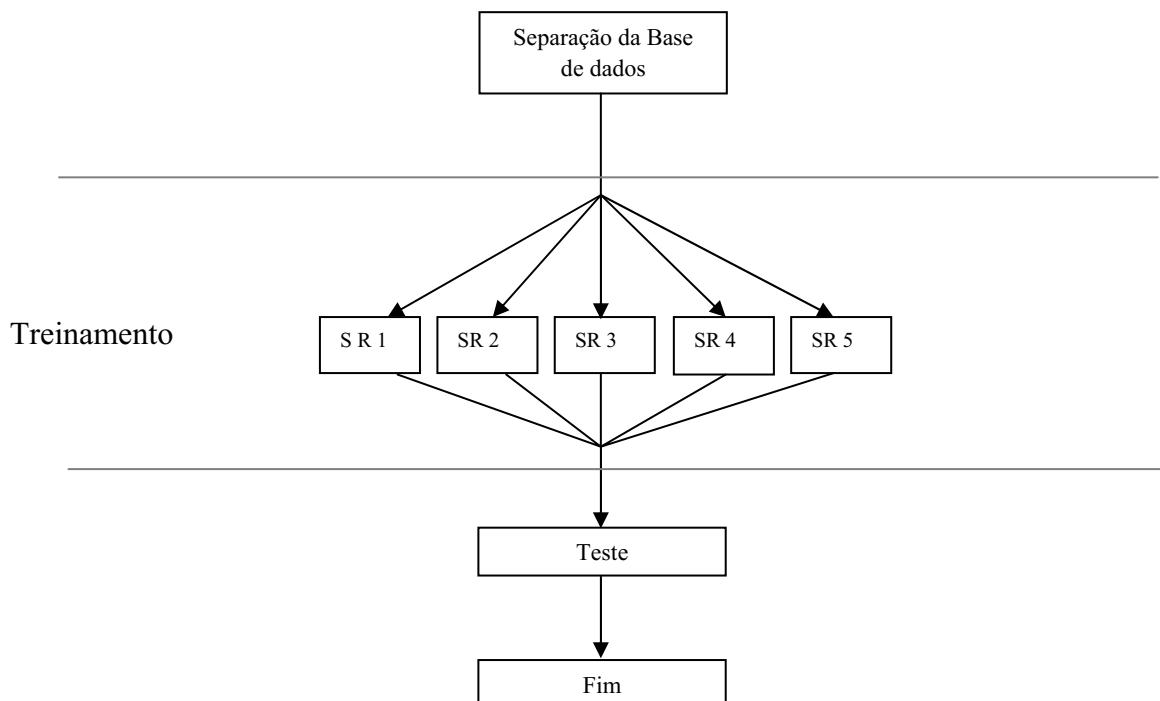


Figura 4 : Fluxograma do funcionamento do Algoritmo 1.

4.1.1. TESTES DE DESEMPENHO

Com o intuito de avaliar este algoritmo ele foi comparado com uma RNA MLP, desenvolvida por Ferreira (2010). Ambas as redes foram treinadas com a mesma base de dados, utilizando o algoritmo RPROP, com 10^{-6} de tolerância na precisão do erro e 0,5 de tolerância na diferença entre Treino e Validação.

Para calcular a taxa de acertos média, foram realizados sucessivos testes e então calculou-se a média dos resultados. A partir de dez testes o valor da taxa de acerto média não apresenta mais variações apreciáveis, por isso o resultado apresentado neste e nos demais testes de desempenho são o valor médio de dez testes. Já o tempo total é aquele decorrido durante os dez testes. Os resultados podem ser visualizados na Tabela 1.

Tabela 1: Comparação entre uma MLP e uma RNAA com o Algoritmo 1.

Rede	Resultados	
	Taxa de Acertos Média (%)	Tempo de Teste (s)
RNA MLP	98,91	47,41
RNA Auto-Associativa	98,20	667,77

Os dados da Tabela 1 mostram que embora as taxas de acertos sejam próximas, o tempo de teste para a RNAA foi 14,08 vezes maior, indicando que o esforço computacional envolvido neste algoritmo é muito maior. Realizou-se então um segundo teste com uma tolerância de precisão do erro igual a 1, com o intuito de reduzir o esforço computacional e avaliar o impacto sobre a taxa de acertos das redes. A Tabela 2 mostra o resultado deste segundo teste.

Tabela 2: Segunda Comparação entre uma MLP e uma RNAA com o Algoritmo 1.

Rede	Resultados	
	Taxa de Acertos Média (%)	Tempo de execução do Teste (s)
RNA MLP	96,50	8,98
RNA Auto-Associativa	94,75	32,27

Comparando os resultados apresentados nas Tabelas 1 e 2 pode-se perceber que, tanto o tempo de teste quanto a taxa de acerto caíram, porém notadamente no caso da RNAA o tempo de teste, indicativo do esforço computacional, caiu muito mais do que a taxa de acertos.

Outros testes foram realizados com diversos valores de tolerância na precisão do erro, mas foram menos significativos. Valores inferiores a 10^{-6} apresentavam maior esforço computacional sem aumento na taxa de acerto e valores superiores a 1 apresentavam deterioração da taxa de acerto sem redução aparente do esforço computacional.

Realizou-se então um novo teste, no qual dez RNAA diferentes foram treinadas e então testadas com toda a base de dados, incluindo os dados de treinamento,

totalizando assim 1600 vetores. Foram então registrados quais vetores (padrões) de entrada levaram cada rede ao erro, e estes serão referidos pela a que foram apresentados às RNA.. A Tabela 3 no conjunto de redes treinadas.

Tabela 3: Vetores de entrada que levam as redes ao erro.

RNAA	Vetores de entrada que levaram a rede a errar
RNAA 1	31,180,182,376,377,734,748
RNAA 2	32,734,735,797,851,868,881,884,935,939
RNAA 3	31,33,34,43,44,143,735,851,886,954,1211,1266,1267,1268
RNAA 4	248,851,1199,1210,1217,1262
RNAA 5	32,492,493,494,747,748,982,1211,1262,1266,1267
RNAA 6	747,748
RNAA 7	426,1222,1227,1266
RNAA 8	55,747,748,851,1250
RNAA 9	886,887,1237, 1266,1267
RNAA 10	362,363,606,747,748,937,938

Como era esperado, já que as redes foram treinadas de modo idêntico, elas apresentaram taxas de acertos iguais ou próximas. Todavia, as entradas que levam as redes a errar não são as mesmas. Embora alguns vetores sejam classificados erroneamente com mais frequência do que outros, como é o caso do vetor 851, que aparece em três redes diferentes, nenhum vetor foi classificado erroneamente pela maioria das redes. Com base neste fato, foi concebido o Algoritmo 2.

4.2. ALGORITMO 2 – RNAA COM TAXA DE ACERTOS MÍNIMA

Dado um grupo de k RNAA diferentes, treinadas com um mesmo algoritmo, para uma mesma base de dados de treinamento, espera-se que tenham desempenhos similares quando submetidas a uma mesma base de dados de teste. Porém, os resultados apresentados na Tabela 3 indicam que ainda que as taxas de acertos sejam iguais ou próximas, as RNAA terão cometido seus erros para diferentes entradas.

Pode-se então inferir que, a probabilidade de que a maioria das RNAA cometa erros nos mesmos vetores de entrada diminui com o aumento de k . Assim, se para um dado padrão o resultado da maioria absoluta das k redes for tomado como resposta, a probabilidade desta resposta estar correta aumenta com o aumento de k .

Assim o Algoritmo 1 apresentado pode ser adaptado para receber um novo parâmetro, a taxa de acertos mínima. Ao fim do teste a rotina deverá verificar se a taxa de acertos é menor do que a mínima e, se for, treinam-se duas novas redes. Toma-se

como resposta aquela que for maioria absoluta das redes, diminuindo a probabilidade de erros. Esse procedimento pode então ser repetido até que a RNAA atinja o valor desejado de taxa de acertos.

O fato de serem treinadas inicialmente duas novas redes, reduz a possibilidade de ocorrerem empates, que levariam a novas indecisões.

A Figura 5 Apresenta um fluxograma do algoritmo 2.

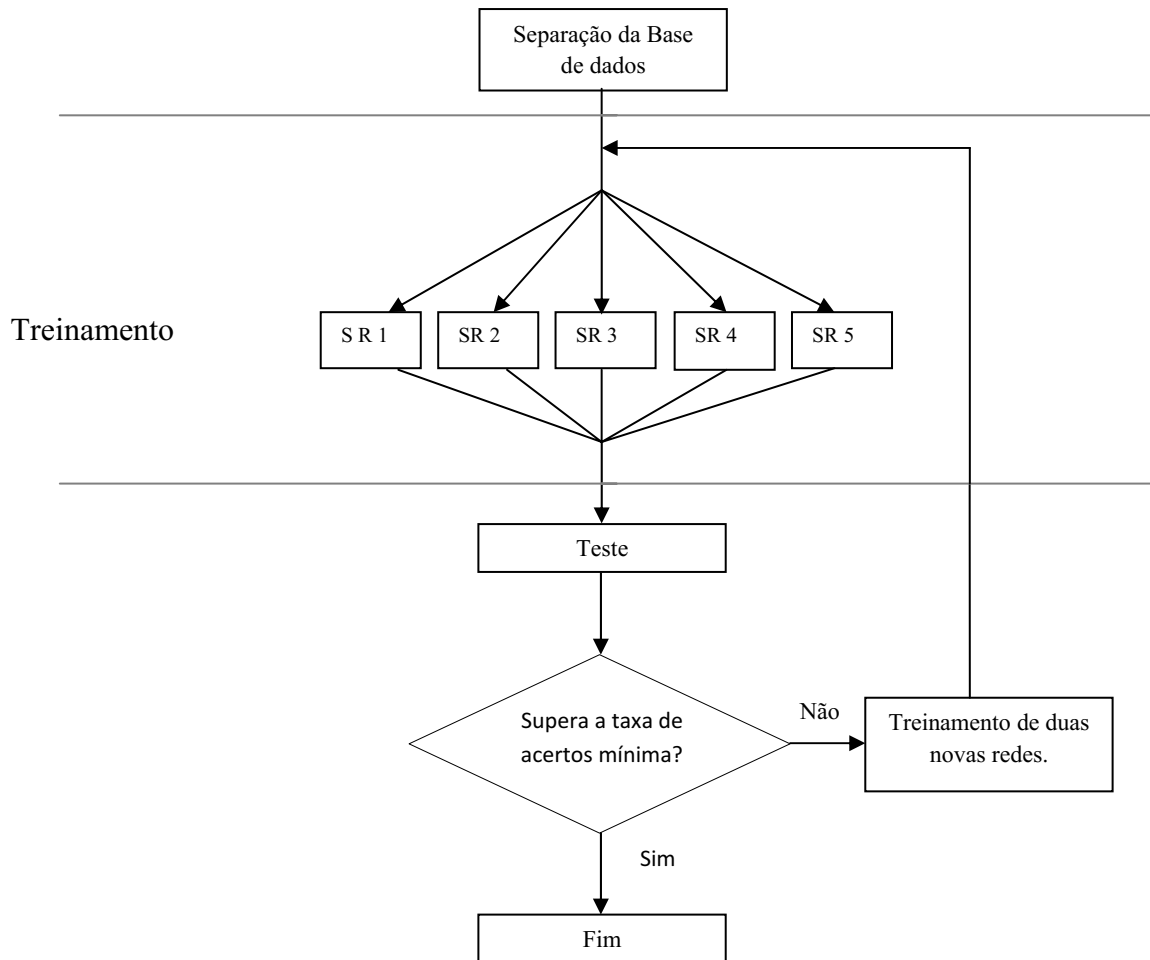


Figura 5: Fluxograma do Algoritmo 2.

Claramente há um crescente aumento no esforço computacional, porém como mostra a Tabela 2, uma redução na tolerância de precisão do erro pode reduzir este esforço, amenizando o problema. Por isso o Algoritmo 2 usa sempre 1 como tolerância na precisão do erro.

4.2.1. TESTES DE DESEMPENHO

Com o intuito de verificar o funcionamento do algoritmo foram realizados testes semelhantes aos anteriores, para diferentes valores de taxa de acerto mínima. Conforme a Tabela 2, uma RNAA obteve pouco mais de 94% de acerto para a base de dados utilizada, assim foram realizados testes para 95, 97,5 e 100%.

A Tabela 4 apresenta as taxas de acerto médias, mínimas e máximas obtidas nestes testes bem como o tempo gasto nos mesmos e o número médio de RNAA necessárias para atingir a taxa desejada.

Tabela 4: Desempenho do Algoritmo II para diferentes taxas de acertos desejadas.

Tx. acerto mín. desejado	Resultados				
	Tx. Acertos Média (%)	Tx. de Acertos Mínima (%)	Tx. de acertos Máxima (%)	Nº. médio de Redes	Tempo de execução do Teste (s)
95%	98,41	95,00	99,58	2,8	90,07
97,5%	99,42	97,5	99,58	5,1	206,68
100%	100	100	100	11,3	457,12

Os resultados mostram que não só o algoritmo consegue manter sempre a taxa de acerto acima da taxa desejada, como o esforço computacional no pior caso é inferior ao esforço para uma RNAA simples com uma tolerância de precisão de erro de 10^{-6} . Fica claro também para uma mesma taxa de acertos a RNA apresenta um menor esforço computacional, de modo que este método só deve ser empregado em casos que a taxa de acerto de uma RNA não seja satisfatória.

5 CONCLUSÕES

O Algoritmo 1 de RNAA atendeu a seus propósitos, porém seu desempenho foi inferior ao de uma RNA MLP em todos os aspectos, de modo que seu uso para reconhecimento de padrões não se justifica, a não ser em casos em que haja muita dificuldade no reconhecimento, onde a propriedade da RNAA de apresentar erros para as diferentes classes ganha mais importância. Apesar disso, os resultados obtidos com o Algoritmo 1 mostram que ele poderia ser modificado de modo a aumentar a taxa de acertos tanto quanto se quera, ao custo de um aumento no esforço computacional, habilidade inexistente nas RNA usuais. É possível que este algoritmo seja adaptável para RNA, estudos mais aprofundados para definir se isto é viável são necessários.

Este trabalho não avaliou diversos parâmetros que podem influenciar o desempenho da rede, como a extração de atributos e o algoritmo de treinamento. Assim, estudos mais aprofundados no sentido de reduzir o esforço computacional, aliados ao algoritmo aqui apresentado, têm potencial para criar uma rede com alto desempenho e taxa de acerto controlável.

É importante comentar que a parte realmente significativa do esforço computacional que está sendo discutido reside no treinamento sucessivo de novas RNAA, porém em aplicações de campo as redes são treinadas apenas uma vez, e depois disso o processo de reconhecimento de padrões é semelhante à fase de testes, o que leva um tempo muitas vezes inferior.

Assim, uma alta taxa de acerto é mais relevante do que um alto esforço, de modo que mesmo que não haja resultados promissores na otimização deste algoritmo ele ainda é potencialmente útil em áreas onde o reconhecimento de padrões careça de confiabilidade.

Referências Bibliográficas

(Maio de 2003). *Revista Lumière edição 61* .

Almeida, A. R. (2005). Redes Neurais. UFES- Programa de Pós Grad. Eng. Elétrica.

Andrade Jr, G. V. (2007). *Estudo de Variações Momentâneas do Valor Eficaz da Tensão no Sistema Saelpa/Celb - SCL*. Campina Grande.

Araujo, A. (13 de 10 de 2010). *Retalhos Históricos de Campina Grande*. Acesso em 10 de 01 de 2011, disponível em <http://cgretalhos.blogspot.com/2009/10/o-hospital-pedro-i.html>

BEALE, R., & JACKSON, T. (1990). *Neural Computing : an Introduction*. Bristol: Adam Hilger.

Cadernos Temáticos ANEEL. (2005). *Tarifas de Fornecimento de energia elétrica* . Brasília, DF, Brasil.

Cigrè Task Force 33.04.03. (1994). *Cigrè Task Force 33.04.03*. Cigrè. Electra.

Costa, E. G., Moreira, V. D., & Ferreira, T. V. (2008). Guia do laboratório de instalações elétricas, UFCG. *Guia Experimental de Fotometria* . Campina Grande, PB.

Dong, Y., Lin, Z., & Watanabe, T. (2009). High Performance Autoassociative Neural Network. *IEEE* .

Ferreira, T. V. (Janeiro de 2010). ESTIMAÇÃO INTELIGENTE DA POLUIÇÃO DE ISOLAMENTOS ELÉTRICOS BASEADA NOS VECSE DO RUÍDO ULTRASSÔNICO. Campina Grande, PB, Brasil.

Gorur, R. S., Burnham, J. T., & Cherney, E. A. (1999). *Outdoor Insulators* (1ª Edição ed.). Phoenix, Arizona, Estados Unidos da América: Ravi S. Gorur Inc.

Haykin, S. (1994). *Neural Networks*. New York: Macmillan.

Haykin, S. (2001). *Redes neurais, princípios e prática* (2ª Edição ed.). Porto Alegre: Bookman.

Ikbal, M. S., Hemant, M., & Yegnanarayana, B. (1999). Analysis of Autoassociative Mapping. *IEEE* .

International Electrotechnical Commission. (1991). *IEC 507: Artificial Pollution Test on high voltage insulators to be used on AC system*.

Kramer, M. A. (1991). "Nonlinear principal component analysis using autoassociative". *Journal of AICHE*, vol. 37, no. 2 , pp. pp. 233–243.

Leão, R. P. (2010). *HARMÔNICOS EM SISTEMAS ELÉTRICOS DE POTÊNCIA*. Fortaleza.

- Lundgaard, L. E. (1992a). Partial discharge XIII: Acoustic partial discharge detection-fundamental considerations. *IEEE Electrical Insulation Magazine* , 8, 25-31.
- Lundgaard, L. E. (1992b). Partial discharge XIV: Acoustic partial discharge detection - Practical application. *IEEE Electrical Insulation Magazine* , 8, 34-43.
- Manual de tarifação de energia. (Maio de 2001). Brasil.
- NBR 5382. (1985). *Verificação de iluminância de interiores* . Rio de janeiro , Brasil: ABNT.
- NBR 5413 . (1992). *Iluminância de Interiores* . Rio de Janeiro, Brasil: ABNT.
- NBR IEC 61000-4-30. (2011). *Compatibilidade eletromagnética Parte 4-30: Técnicas de medição e ensaio - Métodos de medição de qualidade da energia* . Rio de janeiro, Brasil: ABNT.
- Pei, C. P., Shu, N. Q., Li, L., Wang, D., & Li, Z. P. (2008). An acoustic emission method for on-line monitoring of insulator contamination causing flashover based on acoustic emission. *Proceedings of the Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, (pp. 1667-1671). Nanjing.
- Pei, C., Shu, N., Li, L., Wang, D., & Li, Z. (2008). An acoustic emission method for on-line monitoring the contamination-causing flashover of insulator. *Proceedings of the International Conference on Electrical Machines and Systems, 2008. ICEMS 2008.*, (pp. 817-822). Wuhan.
- PowerXplorer™ PX5 User's Guide. (2005). Edison, New jersey, United States: Dranetz-BMI.
- (2007). *Relatório Técnico- Análise de Energia*. Porto Alegre: Power Service.
- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *Proceedings of the IEEE International Conference on Neural Networks*, (pp. 586-591). São Francisco.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. T. (1998). Learnin internal representations by error propagation. *Parallel distnbuted processing: Explorations in the microstructure of cognition* , pp. 318-362.
- Rumelhart, D., & McClelland, J. (1986). *Parallel distributed processing: exploration in the microstructure of cognition*. Cambridge: MIT Press.
- Silva, K. M. (2005). *Diagnóstico de Falhas em Linhas de Trasmissão Baseado em Redes Neurais Artificiais e Transformada Wavelet*. Campina Grande, Paraíba, Brasil: Departamento de Engenharia Elétrica, Universidade Federal da Paraíba.
- WASSERMAN, P. D. (1989). *Neural Computing : Theory and Practice*. New York: Van Nostrand Reinhold.
- Wong, K. L., & Shihab, S. (2002). Radiating signal model for broadband acoustic emission from high voltage equipment. *Proceedings of the International Conference on Power System Technology*, 3, pp. 1859-1862. Kunming.

ANEXO A – EXTRAÇÃO DE ATRIBUTOS. VETORES DE ENERGIA DOS CENTRÓIDES DE SUB-BANDAS ESPECTRAIS

O texto contido neste anexo foi retirado da Proposta de Tese de Doutorado de Tarso Vilela Ferreira (2010).

VETORES DE ENERGIA DOS CENTRÓIDES DE SUB-BANDAS

ESPECTRAIS

A escolha de atributos acústicos apropriados é a tarefa mais importante na implementação de um sistema de reconhecimento de padrões de áudio, como a fala, por exemplo. Tais atributos devem ser escolhidos de maneira que contenham o máximo de informação relevante ao sistema de reconhecimento, mas ao mesmo tempo, descartem informações redundantes ou irrelevantes, como sotaques ou ruído.

Historicamente, coeficientes *cepstrais* são os atributos mais comumente empregados nos sistemas de reconhecimento da fala (Rabiner & Juang, 1993). Estes parâmetros provêm um desempenho satisfatório e tem servido bem às aplicações de reconhecimento de fala durante as últimas três décadas. Todavia, os métodos baseados em coeficientes *cepstrais* são muito sensíveis às distorções causadas por ruído aditivo. Além disso, como o cálculo dos coeficientes *cepstrais* requer a uma transformada de Fourier e uma transformada inversa de Fourier para cada amostra de áudio, sua execução pode ser computacionalmente onerosa, especialmente quando se utilizam sinais com taxas de amostragem elevadas. Neste contexto, métodos baseados em centróides de sub-bandas espectrais figuram como uma alternativa eficiente, mesmo com a presença de ruído aditivo, além de demandarem esforços computacionais equiparáveis aos demandados pelos métodos baseados em componentes *cepstrais* (Gajić & Paliwal, 2001).

O processo de definição de centróides de sub-bandas espectrais (CSE) requer a divisão da banda de frequência do sinal em um número fixo de sub-bandas, e o cálculo do centróide de cada uma delas (Paliwal, 1998). Cada uma destas etapas requer a definição de parâmetros como:

- Número de sub-bandas no qual a banda total do sinal será dividida;
- Frequências centrais e frequências de corte dos filtros;
- Formato dos filtros: retangulares, triangulares, etc.;
- Percentual de sobreposição dos filtros.

Como na grande maioria das vezes o sinal de áudio analisado não possui uma formulação matemática analítica, escolher os supracitados parâmetros pode requerer bastante experimentação prática.

O método dos Vetores de Energia dos Centróides de Sub-bandas Espectrais (VECSE) baseia-se no algoritmo dos CSE, originalmente proposto para o reconhecimento da fala. A diferença entre os dois métodos é que o VECSE leva em consideração a energia dos centróides representada na forma de um vetor.

A grande vantagem dos métodos baseados em CSE é a robustez ao ruído aditivo, o que é uma característica bastante providencial dado o tipo de ruído analisado neste trabalho. O diagrama de blocos apresentado na Figura 1 resume o algoritmo empregado para a estimação dos VECSE.




Figura 1. Diagrama de blocos do algoritmo VECSE.

Os passos para a estimação dos VECSE são descritos em detalhes a seguir:

- Inicialmente, é realizada a estimação do espectro de potência do sinal em questão através de uma transformada rápida de Fourier (TRF);
- Aplica-se um banco de filtros passa-faixa retangulares sobrepostos, a fim de dividir o espectro em um número de sub-bandas de frequências sobrepostas. A escolha de filtros retangulares permite a localização mais fiel dos centróides.
- A localização dos centróides espectrais de cada sub-banda no espectro estimado pode ser matematicamente expressa como:

$$C_H = \frac{\sum_{k=0}^{N-1} H_m(k) \cdot P(k)}{\sum_{k=0}^{N-1} P(k)} \quad (1)$$

em que, $P(k)$ é a fatia do espectro de potência estimado que foi limitado pelo filtro (sub-banda); $H_m(k)$ é o vetor de frequências; e N é o número de amostras disponíveis na sub-banda.

- A estimativa de energia associada a cada centróide pode ser matematicamente apresentada como:

$$E_c = \sum_{k=C_H-\delta \cdot N}^{C_H+\delta \cdot N} P(k) \quad (2)$$


em que, C_H é a localização do centróide da sub-banda em questão; e δ é o parâmetro que definirá a largura da faixa em torno do centróide que será utilizada para o cálculo da energia média.

O número de filtros, suas larguras e o percentual de sobreposição definirão a taxa de compressão do método. Um número reduzido de filtros que possuem larga faixa passante e baixo percentual de sobreposição proporcionará alta compressão, mas permitirá que detalhes do espectro passem despercebidos. O percentual de sobreposição baixo resultará numa baixa correlação entre sub-bandas adjacentes, o que influenciará diretamente o cálculo de localização dos centróides, uma vez que regiões espectrais próximas à sub-banda em questão não serão contempladas no cálculo. O resultado serão poucas sub-bandas, conseqüentemente, menor esforço computacional e baixo detalhamento.


Por outro lado, muitos filtros estreitos com alto percentual de sobreposição resultarão em uma compressão menor, proporcionando um alto detalhamento espectral. O percentual de sobreposição alto resultará numa alta correlação entre sub-bandas adjacentes, e a influência das regiões espectrais próximas à sub-banda em que se calcula um determinado centróide será computada. Resultam muitas sub-bandas, conseqüentemente, maior detalhamento e esforço computacional. Este tipo de configuração é requerida em problemas com menor grau de separabilidade das classes, onde os detalhes serão decisivos para o sucesso da classificação.

A Figura 2 apresenta os resultados de dois cálculos para estimação dos VECSE de um mesmo sinal, registrado em uma cadeia de isoladores de uma torre de transmissão do sistema Chesf. Variando-se o número filtros, suas larguras e o percentual de sobreposição, pode-se perceber a influência no VECSE de saída.


A Figura 2a apresenta um segundo (1 s) do sinal adquirido em campo, e na Figura 2b uma parcela de 16,67 ms (duração de um ciclo industrial) deste mesmo sinal é mostrada em detalhe. Para a realização da TRF, foi tomada uma parcela equivalente a de dez períodos de ciclo industrial, ou seja, aproximadamente 166,67 ms, e o resultado é mostrado na Figura 2c. Após o processamento pelo algoritmo VECSE, pode-se observar na Figura 2d o resultado obtido com 10 filtros sobrepostos a 10%, o que resultou em 12 sub-bandas e uma curva suave. Ainda na Figura 2d, apresenta-se o resultado obtido com 20 filtros sobrepostos a 50%, resultando em 40 sub-bandas e uma curva mais acidentada. Conforme descrito anteriormente, o número de filtros e percentual de sobreposição tem impacto direto na taxa de compressão do algoritmo.



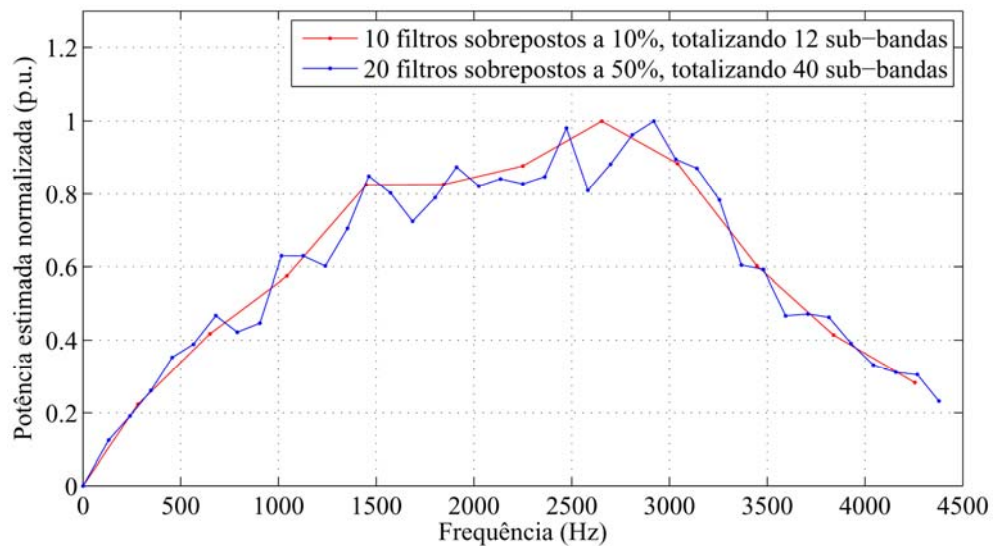
(a)



(b)



(c)



(d)

Figura 2. (a) Plotagem de 1 s do sinal no tempo;
 (b) Plotagem de 1/60 s do sinal no tempo; (c) Espectro estimado do sinal;
 (d) VECSE obtidos com 10 filtros sobrepostos a 10%, e com 20 filtros sobrepostos a 50%.

No terceiro passo do algoritmo, pode-se constatar que o resultado da Equação (1) tem grandeza de Hertz, ou seja, apenas localiza os centróides dentro das sub-bandas e, conseqüentemente, no espectro. Assim, para que se caracterize totalmente o VECSE, necessita-se que lhe seja atribuída a informação relativa à energia presente naquela sub-banda. Para tanto, poder-se-ia simplesmente calcular a média dos valores de potência espectral compreendidos na sub-banda em questão. Todavia a região da sub-banda mais próxima ao centróide possui mais energia que as demais dentro daquela sub-banda, logo, é menos susceptível ao ruído. Assim, pode ser mais vantajoso efetuar o

cálculo de uma média de energia da sub-banda junto ao centróide, e o parâmetro δ ($0,5 > \delta > 0$) quantifica este ajuste. Quando δ é máximo, tem-se que a energia da sub-banda será calculada numa região com largura equivalente àquela sub-banda, e o centro desta região coincide com o centróide. Se δ é zero, o valor de energia para a sub-banda em questão será o valor na frequência do centróide daquela sub-banda. A Figura 3 apresenta os resultados de dois cálculos para estimação dos VECSE do sinal apresentado na Figura 2, variando-se δ , e mantendo-se os demais parâmetros iguais.




Figura 3. VECSE obtidos com $\delta = 0,05$ e com $\delta = 0,5$.

Pode-se observar na Figura 3 que a variação de δ tem influência direta na suavidade da curva obtida. Todavia, como não modifica o número final de elementos que compõem o VECSE, δ não repercute na taxa de compressão do método.

Por se basear no domínio da frequência, o método dos VECSE apresenta como resultado vetores que não trazem informações acerca da fase do sinal medido. No domínio do tempo, esta informação pode ser detectada pela RNA e tornar a tomada de decisão tendenciosa, uma vez que a fase do sinal ultrassônico capturado é aleatória e a RNA prontamente usará a informação de fase na tarefa de classificação. Todavia, a informação de fase não informa nada relativo ao grau de poluição do isolamento. A aleatoriedade da fase no RU ocorre porque não há sincronismo entre o início da captura do sinal e a fase da senóide da rede, que por sua vez está intimamente ligada aos gradientes de campo elétrico e à geração do ruído.

A extração de atributos baseada em CSE é amplamente utilizada tanto no reconhecimento da fala quanto do locutor(Jin & Yoo, 2007). Todavia, os vários parâmetros ajustáveis no método estão presentes na literatura para sistemas de reconhecimento de voz, com características distintas dos sinais analisados neste trabalho.

Uma vez definidos os vetores de energia, quando a base de dados está pronta para ser apresentadas à RNA a informação espectral pode ser descartada. Isto é possível porque todos os vetores da base de dados necessariamente tem o mesmo número de elementos, e a RNA tomará como fator classificatório o nível de energia do conjunto de elementos do vetor, a taxa de variação entre eles, etc.

ANEXO A -BIBLIOGRAFIA

Gajić, B., & Paliwal, K. K. (2001). Speech parameterization for automatic speech recognition in noisy conditions. *Proceedings of the Norwegian Symposium on Signal Processing*. Trondheim.

Jin, M., & Yoo, C. (2007). Temporal Dynamics for Spectral Sub-Band Centroid Audio Fingerprints. *Proceedings of the 2007 IEEE International Conference on Multimedia and Expo*, (pp. 180-183). Beijing.

Paliwal, K. (1998). Spectral subband centroid features for speech recognition. *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing*, 2, pp. 617-620. Seattle.

Rabiner, L., & Juang, B. H. (1993). *Fundamentals of Speech Recognition*. Upper Saddle River, New Jersey, Estados Unidos da América: Prentice-Hall.