

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**SISTEMAS INTELIGENTES E WAVELETS PARA  
PREVISÃO DE VENTO E GERAÇÃO EÓLICA**

**JOSINALDO BEZERRA DE OLIVEIRA**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da  
Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de  
Mestre em Engenharia Elétrica.

**ORIENTADOR: RONALDO RIBEIRO DE BARBOSA AQUINO, D.Sc.**

**CO-ORIENTADORA: MILDE MARIA DA SILVA LIRA, D.Sc.**

Recife, Junho de 2008.

© Josinaldo Bezerra de Oliveira, 2008

**O48s Oliveira, Josinaldo Bezerra de.**

Sistemas inteligentes e wavelets para previsão de vento e geração eólica / Josinaldo Bezerra de Oliveira. – Recife: O Autor, 2008.

vi, 82 f.; il., tabs.


Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2008.

Inclui Referências Bibliográficas.

**1. Engenharia Elétrica. 2. Previsão de Ventos. 3. Previsão Geração Eólica. 4. Redes Neurais Artificiais. 5. Transformadas Wavelets. I. Título.**

**621.3 CDD (22.ed.)**

**UFPE/BCTG/2008-164**



**Universidade Federal de Pernambuco**

***Pós-Graduação em Engenharia Elétrica***

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE  
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

**JOSINALDO BEZERRA DE OLIVEIRA**

TÍTULO

**“SISTEMAS INTELIGENTES E WAVELETS PARA  
PREVISÃO DE VENTOS E GERAÇÃO EÓLICA”**

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEESP/UFPE, MILDE MARIA DA SILVA LIRA, DEESP/UFPE, GERALDO LEITE TORRES, DEESP/UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFCG sob a presidência do primeiro, consideram o candidato **JOSINALDO BEZERRA DE OLIVEIRA APROVADO.**

Recife, 20 de junho de 2008.

**EDUARDO FONTANA**  
Coordenador do PPGEE

**RONALDO RIBEIRO BARBOSA DE AQUINO**  
Orientador e Membro Titular Interno

**MILDE MARIA DA SILVA LIRA**  
Co-Orientador e Membro Titular Externo

**GERALDO LEITE TORRES**  
Membro Titular Interno

**BENEMAR ALENCAR DE SOUZA**  
Membro Titular Externo

*Dedico aos meus pais, José Braz e Edinalva, que sempre fizeram de tudo para viabilizar minhas conquistas.*

## AGRADECIMENTOS

Agradeço a Deus por sempre estar presente em minha vida, iluminando meus caminhos e realizando o impossível quando tudo parece estar perdido.

Agradeço ao José Braz e à Edinalva que sempre priorizaram a minha educação, mesmo em tempos difíceis, e que me ensinaram a encarar a vida com dignidade e esperança.

Agradeço à Edneuzza, minha tia, que me recebeu como um filho em sua casa, possibilitando minha estada durante boa parte da minha vida acadêmica.

Agradeço ao Prof. Ronaldo Aquino por ser o primeiro a acreditar no meu potencial e por estar sempre presente, auxiliando-me a evoluir intelectualmente e como pessoa. Tornando-se um verdadeiro amigo.

Agradeço à Prof<sup>a</sup> Milde pela paciência e dedicação para ajudar-me a elaborar este trabalho, especialmente durante o desenvolvimento desta redação.

Agradeço ao Prof. Manoel Afonso, que além de facilitar o aprendizado dos alunos, ensinava-nos verdadeiras lições de vida, que ajudaram a tornar-me um ser humano melhor.

Agradeço à minha irmã, Ise, e aos meus primos e primas que me aturaram, com minhas chatices, tentando sempre me animar.

Agradeço à GabiS, amiga e companheira do mestrado; que tive oportunidade de conviver com maior proximidade, dividindo sala, trabalhos e orientador durante o mestrado; e que me ajudou enxergar o mundo com outros olhos.

Agradeço aos meus amigos do mestrado, especialmente Gustavo e Milton, que sempre foram solidários com as preocupações e que sempre estiveram dispostos a ajudar-me.

Agradeço aos meus amigos, Cadu, Dani e Léo, que sempre me incentivaram e acreditaram na minha capacidade, mesmo quando eu demonstrava insegurança.

Agradeço ainda, a todas as pessoas que de alguma forma contribuíram para a conclusão desta dissertação.

Resumo da Dissertação apresentada à UFPE como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

## **Sistemas Inteligentes e Wavelets para Previsão de Ventos e Geração Eólica**

**Josinaldo Bezerra de Oliveira**

Junho/2008

Orientador: Prof. Ronaldo Ribeiro de Barbosa Aquino, D.Sc.

Co-orientadora: Milde Maria da Silva Lira, D.Sc.

Área de Concentração: Processamento de Energia.

Palavras-chave: Previsão de Ventos, Previsão de Geração Eólica, Redes Neurais Artificiais, Transformadas Wavelets.

Número de Páginas: 92

**RESUMO:** Vários estudos já comprovaram que o potencial eólico brasileiro, principalmente no nordeste, onde os ventos têm uma importante característica de complementaridade em relação às vazões do rio São Francisco, pode contribuir significativamente para o suprimento de energia elétrica. O aproveitamento deste potencial eólico aumentaria a capacidade de geração e a diversificação da matriz energética nacional e, conseqüentemente, diminuiria os riscos de desabastecimento de energia elétrica. Entretanto, o uso das forças dos ventos para produção de energia produz alguns inconvenientes, tais como, a incertezas na geração e a dificuldade no planejamento e operação do sistema elétrico. Portanto, é imprescindível à aplicação de ferramentas ou técnicas capazes de prever a energia a ser fornecida por estas fontes. No Brasil, os investimentos em fontes alternativas iniciaram-se de forma tímida e tardia, inclusive em geração eólica. Do ponto de vista de modelos de previsões de ventos e geração eólica, isto não é diferente. Sendo assim, este trabalho propõe e desenvolve vários modelos de previsões a partir de técnicas de Redes Neurais Artificiais; Análise de Multiresolução de sinais usando Transformada Wavelet; e Modelos Estatísticos. Os modelos aqui propostos foram ajustados para realizar previsões com horizontes variáveis de até vinte e quatro horas. Estes serviram para uma análise comparativa através dos resultados encontrados durante os testes dos mesmos, que ajudou a identificar as vantagens e desvantagens de cada técnica. Além disto, estes poderão ser implementados e desenvolvidos para operação, mitigando alguns dos inconvenientes da geração eólica de energia.



Abstract of Dissertation presented to UFPE as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

## **Intelligent Systems and Wavelets for Forecast Winds and Wind Energy**

**Josinaldo Bezerra de Oliveira**

July/2008

Supervisor(s): **Prof. Ronaldo Ribeiro de Barbosa Aquino, D.Sc.** and **Milde Maria da Silva Lira, D.Sc.**

Area of Concentration: Energy Processing

Keywords: Wind Forecasting, Wind Energy Forecasting, Artificial Neural Network, Wavelets Transforms.

Number of Pages: 92

**ABSTRACT:** Several studies have showed that Brazilian wind power can contribute significantly to the supply of electricity, mainly in the northeast, where the winds have an important feature of complementarily with the flow of São Francisco River. The use of the wind power can increase generation of the Brazil capacity and diversify the energy matrix (or kind of the energy). Thus, the risk of shortage electrical power is decreasing. However, wind power generation produces some drawbacks, such as uncertainties and difficulty in the scheduling and operation of the electric system. Therefore, it is extremely important to develop tools and techniques of forecast able to predict the energy to be provided by this source. In Brazil, investments in alternative sources began late, including in wind power. From the standpoint of the forecast model of winds and generation, this is not different. Therefore, this paper proposes and develops several forecast models using Artificial Neural Networks techniques, Analysis of Multiresolution of signals by the Wavelet Transform, and Statistical models. The proposed models were adjusted to achieve varying period of forecasts up to twenty-four hours ahead. They were used to permit a comparative analysis of results, which helped to identify the advantages and disadvantages of each techniques or models. Furthermore, they may be implemented and developed for operation, decreasing some of the drawbacks of the wind energy generation.



## SUMÁRIO

CAPÍTULO 1 .....	1
1 Introdução.....	1
1.1 Motivação.....	1
1.2 Objetivos.....	2
1.3 Estrutura da dissertação.....	3
 CAPÍTULO 2 .....	 5
2 Potencial Eólico e Revisão Bibliográfica.....	5
2.1 Potencial Eólico.....	5
2.2 Características da Energia Eólica.....	7
2.2.1 Aspectos para integração da energia eólica.....	8
2.3 Produção de Energia Eólica.....	8
2.4 Revisão Bibliográfica.....	12
2.4.1 Modelos de previsão de velocidade de ventos.....	12
2.4.2 Escalas de tempo de previsão.....	13
2.4.3 Modelos físicos.....	13
2.4.4 Modelos estatísticos e de redes neurais.....	14
2.4.5 Modelos de correlação espacial.....	15
2.4.6 Modelos Mistos.....	16
 CAPÍTULO 3 .....	 17
3 Base Teórica.....	17
3.1 Estudos de Séries Temporais.....	17
3.2 Análise estatística.....	17
3.2.1 Valor Médio da Amostra.....	17
3.2.2 Desvio Padrão da Amostra.....	18
3.2.3 Autocorrelação e Correlação.....	18
3.3 Métodos Estatísticos de Previsão.....	19
3.3.1 Modelo Média Móvel Integrada Auto-Regressivo (ARIMA).....	19

3.3.2	Auto-Regressivo Média Móvel (ARMA).....	20
3.3.3	Modelo Auto-Regressivo.....	20
3.3.4	Persistência.....	21
3.4	Transformada Wavelet.....	21
3.4.1	Tranformada Wavelet Contínua.....	23
3.4.2	Transformada Wavelet Discreta.....	24
3.5	Análise de Multiresolução.....	26
3.5.1	Codificação em Sub-Bandas.....	26
3.5.2	Decomposição em Múltiplos Níveis.....	27
3.6	Redes Neurais.....	28
3.6.1	Neurônio Artificial.....	28
3.6.2	Função de Ativação.....	30
3.6.3	Processo de Aprendizagem.....	30
3.6.4	Redes Perceptron Múltiplas Camadas.....	33
3.6.5	Algoritmo de Treinamento.....	33
CAPÍTULO 4.....		37
4	Procedimentos de Desenvolvimentos dos Modelos de Previsões.....	37
4.1	Aquisição dos Dados.....	37
4.2	Processamento dos Dados.....	38
4.2.1	Normalização.....	38
4.2.2	Análise de Multiresolução.....	39
4.2.3	Conversão das previsões das velocidades em geração.....	39
4.3	Avaliação de Desempenho.....	40
4.4	Treinamento e ajuste dos modelos.....	41
4.4.1	Treinamentos dos modelos inteligentes.....	41
4.4.2	Ajustes dos modelos estatísticos.....	45
CAPÍTULO 5.....		48
5	Resultados dos Modelos de Previsões.....	48
5.1	Modelos Inteligentes com Horizonte de até Quatro Horas.....	48
5.1.1	Modelo Neural.....	49

5.1.2	Modelo Neural com Análise de Multiresolução Através da Transformada Wavelet. ....	53
5.2	Modelos Inteligentes de Previsões com Horizonte de até Vinte Quatro Horas.	57
5.2.1	Modelo Neural.....	57
5.2.2	Modelo Neural com Análise de Multiresolução através de Transformada Wavelet. ....	61
5.2.3	Modelo Neural Sazonal .....	65
5.3	Resultados dos modelos estatísticos.....	70
5.3.1	Modelo ARMA para o horizonte de quatro horas.....	71
5.3.2	Modelo ARMA para horizonte de vinte e quatro horas .....	72
5.4	Síntese dos Testes dos Modelos de Previsões Desenvolvidos .....	74
CAPÍTULO 6 .....		76
6	Conclusões e Trabalhos Futuros.....	76
6.1	Conclusões.....	76
6.2	Trabalhos Futuros .....	78
REFERÊNCIAS .....		79

## LISTA DE FIGURAS

Figura 2.1 - Potencial Eólico Brasileiro.....	6
Figura 2.2 - Histórico de Vazão do Rio São Francisco e dos Ventos do Interior e do Litoral. .....	7
Figura 2.3 - Curva de Potência da Turbina.....	10
Figura 3.1 - Esquema de um Plano Tempo x Frequência.....	22
Figura 3.2 - Senoide e Wavelet (db10).....	22
Figura 3.3 - Decomposição: (a) senoidal do sinal em diferentes frequências; (b) Wavelet do sinal em diferentes escalas e deslocamentos. ....	23
Figura 3.4 - Passo 2 da Transformada Wavelet Contínua. ....	23
Figura 3.5 - Passo 3 da Transformada Wavelet Contínua. ....	24
Figura 3.6 - Passo 4 da Transformada Wavelet Contínua. ....	24
Figura 3.7 - Reticulado .....	25
Figura 3.8 - Bancos de Filtros .....	27
Figura 3.9 - Árvore de Decomposição do Sinal em 3 Níveis .....	27
Figura 3.11 - Funções de ativações. ....	30
Figura 3.12 - Diagramas de Blocos da Aprendizagem com Professor.....	31
Figura 3.13 - Aprendizado não supervisionado.....	32
Figura 3.14 - Rede MLP.....	33
Figura 4.1 - Correlograma da Série de Velocidades.....	37
Figura 4.2 - Fluxograma do desenvolvimento dos modelos estatísticos. ....	46
Figura 5.1 - Modelo neural de previsão com horizontes de até quatro horas. ....	49
Figura 5.2 - Histograma do erro de teste para o modelo neural com horizonte de até quatro horas. ....	51
Figura 5.3 - Avaliação horária do teste para o modelo neural com horizonte de até quatro horas. ....	52
Figura 5.4 - Modelo neural com análise de multiresolução com horizontes de até quatro horas. ....	53
Figura 5.5 - Histograma do erro de teste para o modelo neural com análise de multiresolução com horizonte de até quatro horas. ....	55
Figura 5.6 - Avaliação horária do teste para o modelo neural com análise de multiresolução de horizonte de até quatro horas. ....	56

Figura 5.7 - Histograma do erro de teste para o modelo neural com horizonte de até vinte e quatro horas. ....	59
Figura 5.8 - Avaliação horária e diária do teste para o modelo neural com horizonte de até vinte quatro horas .....	60
Figura 5.9 - Histograma do erro de teste para o modelo neural com análise de.....	63
Figura 5.10 - Avaliação horária e diária do teste para o modelo neural com análise de	64
Figura 5.11 - Modelo neural sazonal com horizontes de até vinte e quatro horas. ....	67
Figura 5.12 - Histograma do erro de teste para o modelo neural sazonal com horizonte de até vinte e quatro horas.....	68
Figura 5.13 - Avaliação horária e diária do teste para o modelo neural sazonal com horizonte de até vinte quatro horas.....	69
Figura 5.14 - Histograma do erro de teste para o modelo ARMA(1,0) com horizonte de quatro horas .....	72
Figura 5.15 - Histograma do erro de teste para o modelo ARMA(7,9) com horizonte de vinte e quatro horas .....	73
Figura 5.16 - Histograma do erro de teste para o modelo ARMA(1,0) com horizonte de vinte e quatro horas .....	74

## LISTA DE TABELAS

Tabela 2.1 - Coeficientes de Rugosidades.....	12
Tabela 4.1 - Experimento utilizados no método de validação cruzada. ....	45
Tabela 5.1 - Seleção da arquitetura do modelo neural de até quatro horas. ....	50
Tabela 5.2 - Validação cruzada para o modelo neural com horizonte de até quatro horas. 51	
Tabela 5.3 - Seleção da arquitetura do modelo neural com análise de multiresolução de até quatro horas. ....	54
Tabela 5.4 - Validação cruzada para o modelo neural com análise de multiresolução de até quatro horas ..... 55	
Tabela 5.5 - Seleção arquitetura do modelo neural de até vinte e quatro horas ..... 58	
Tabela 5.6 - Validação cruzada para o modelo neural com horizonte de até vinte e quatro horas. ....	59
Tabela 5.7 - Seleção arquitetura do modelo neural com análise de ..... 62	
Tabela 5.8 - Validação cruzada para o modelo neural com análise de multiresolução..... 62	
Tabela 5.9 - Validação cruzada para o modelo neural sazonal com horizonte de até vinte e quatro horas. ....	68
Tabela 5.10 - Resultados no conjunto de teste dos Especialistas ..... 70	
Tabela 5.11 - Resultados dos modelos ARMA para o horizonte de quatro horas..... 71	
Tabela 5.12 - Resultados dos modelos ARMA para o horizonte de vinte e quatro horas... 73	
Tabela 5.13 - Resultados de Teste dos Modelos de Previsões desenvolvidos ..... 75	

# CAPÍTULO 1

## 1 Introdução

Este capítulo apresenta a motivação, os objetivos e uma descrição da organização da dissertação.

### 1.1 Motivação

A previsão de ventos e geração eólica é de extrema importância para auxiliar nos estudos de planejamento e programação da operação da geração do sistema hidrotérmico e eólico. Além disso, os modelos de previsão de ventos podem ser utilizados nos estudos climáticos. A previsão eficiente de ventos e geração eólica pode contribuir nos seguintes casos:

- O estudo do potencial eólico e as previsões das velocidades dos ventos facilitam no mercado de comercialização de energia elétrica;
- Subsidiar na solução do problema de otimização do despacho da geração do sistema hidrotérmico e eólico
- Os sistemas de controles dos parques eólicos de geração podem ser auxiliados por sistemas de previsões robustos e eficientes, de modo a melhorar suas repostas ou facilitar o controle;
- As mudanças ocorridas na estrutura do setor elétrico brasileiro solicitam sistemas de previsões cada vez mais eficientes para poderem suprir a necessidade das empresas distribuidoras e geradoras garantindo a competitividade do sistema.
- Com relação aos estudos climáticos, os modelos de previsão de ventos fornecem uma estimativa futura para uma determinada localidade. Desta forma, permite identificar o agravamento ou não de alguns fatores ambientais.

Além dos benefícios citados acima, a previsão de ventos tem sido objeto de pesquisa de diversos autores. Inicialmente, os modelos desenvolvidos eram focados em estudos meteorológicos [2]. Contudo, o aumento significativo das fontes alternativas de energia, principalmente a geração eólica, despertou o interesse no desenvolvimento de modelos de previsão capaz de prever a geração eólica.



Existem diversas modelagens que realizam a previsão de ventos. Para os estudos meteorológicos, os modelos geralmente são numéricos (*numeric weather prediction - NWP*) e modelados a partir de variáveis físicas.

Já os modelos desenvolvidos para aplicação na geração eólica, tradicionalmente, utilizam métodos estatísticos de análise de série temporais como: os modelos desenvolvidos por Box Jenkis [3], principalmente o modelo auto-regressivo média móvel.

Porém, atualmente, com a consolidação da aplicação de redes neurais artificiais em diversas áreas de previsões, tais como: previsão de carga, previsão de séries e índices econômicos despertaram o interesse para aplicação na área de previsão de ventos e geração eólica [4, 5].

Os modelos neurais de previsões têm se destacado pelas suas características de não linearidade, robustez e capacidade de generalização do aprendizado. Além disso, o conhecimento é incorporado através de padrões de entrada e saída durante a etapa de treinamento sem a necessidade de conhecimento prévio do problema para parametrizar o modelo.

Existem ainda modelos mistos (híbridos) que combinam diversas técnicas, como por exemplo, redes neurais, lógica fuzzy, algoritmo genético e até mesmo NWP [2, 6, 7, 8] na composição dos modelos de previsão.

No Brasil, a estimativa do potencial da geração eólica é extremamente considerável [9, 10]. Este tipo de geração encontra-se na fase incipiente. No entanto, as perspectivas são animadoras, principalmente, com objetivo de aumentar o potencial energético e a diversificação da matriz energética, possibilitando o crescimento econômico e diminuindo o risco de desabastecimento de energia elétrica.

Portanto, o desenvolvimento de modelos de previsões de gerações eólicas para o Brasil é indispensável para integração desta energia ao sistema de geração, de maneira confiável e eficaz.

## 1.2 Objetivos

Visto que a geração eólica no Brasil encontra-se no estágio inicial, pouco são os modelos de previsão desenvolvidos neste sentido. Muitas vezes, as previsões da geração eólica para estudos e planejamentos consideram as gerações realizadas em períodos anteriores. Sendo assim, o objetivo principal deste trabalho é desenvolver vários modelos de previsão a partir de métodos estatísticos, redes neurais artificiais e análise de

multiresolução de dados via transformada wavelet para aplicação nos parques geradores de energia eólica brasileiro.

Quanto ao horizonte de previsão, os modelos desenvolvidos neste trabalho estão divididos basicamente em dois grupos: previsão com horizontes de até quatro horas (curtíssimo prazo) e previsão de até vinte quatro horas (curto prazo).

A variedade dos modelos desenvolvidos neste trabalho tem a finalidade de explorar e identificar as qualidades de cada modelo ou técnica de desenvolvimento dos mesmos, viabilizando uma análise qualitativa e quantitativa dos modelos através dos resultados dos testes.

O método estatístico avaliado será o auto-regressivo média móvel (ARMA), o qual tem sido tradicionalmente aplicado à previsão de ventos e geração eólica. Quanto as redes neurais avaliadas, as redes do tipo Perceptron Múltiplas Camadas, foram selecionadas devido a sua consolidação na solução de problemas de previsão em diversas áreas.

As redes neurais Perceptrons também serão usadas para desenvolver o modelo que realiza uma análise de multiresolução. Esta análise é fornecida pela decomposição dos dados usando a transformada wavelet (TW) que decompõe a série original em coeficientes de aproximação e detalhes.

Este trabalho também tem a finalidade de avaliar a modelagem de modelos univariados de previsão (a grandeza de interesse é dependente dela mesma) aplicados à velocidade de ventos e geração eólica, uma vez que grande parte dos modelos desenvolvidos no mundo são multivariados [4, 6, 7, 8].

A modelagem univariada foi escolhida devido à escassez de dados relacionados à geração eólica no Brasil. Os modelos multivariados utilizam diversas variáveis, tais como: temperatura, rugosidades (variação do vento com altura do solo) e até mesmo velocidades de ventos em outros pontos de medições.

### **1.3 Estrutura da dissertação**

Esta dissertação está dividida, além desta introdução, em cinco capítulos, ordenados na mesma seqüência em que os estudos foram realizados e desenvolvidos. Estes capítulos estão dispostos da seguinte maneira:

- **Capítulo 2 – Potencial Eólico e Revisão Bibliográfica:** Nesse capítulo, é descrito um breve resumo sobre a geração e potencial eólico, principalmente no Brasil.

Além disto, é descrito sucintamente as principais técnicas de previsão de ventos e geração eólica utilizadas pelos pesquisadores.

- **Capítulo 3 – Base Teórica:** é apresentado nesse capítulo um resumo teórico das principais ferramentas utilizadas no desenvolvimento dos modelos de previsões propostos.
- **Capítulo 4 – Procedimentos de Desenvolvimentos dos Modelos de Previsões:** Nesse capítulo são apresentados os procedimentos, como também a modelagem utilizadas na elaboração dos modelos de previsões propostos. Primeiramente, é descrito todo processo de ajustes dos modelos que utilizam as redes neurais. A segunda parte descreve os procedimentos para seleção dos parâmetros para os modelos estatísticos.
- **Capítulo 5 – Resultados dos Modelos de Previsões:** Apresentam-se inicialmente neste capítulo todas as fases dos desenvolvimentos dos modelos. Além disso, apresentam-se também os resultados dos testes realizados.
- **Capítulo 6 – Conclusões e Trabalhos Futuros:** Nesse capítulo, é concluída a dissertação, fazendo um breve resumo dos resultados e contribuições. Além disso, são apresentadas propostas para trabalhos futuros com objetivo de dar continuidade às pesquisas no contexto aqui desenvolvido.

## CAPÍTULO 2

### 2 Potencial Eólico e Revisão Bibliográfica

#### 2.1 Potencial Eólico

A avaliação do potencial eólico de uma região requer trabalhos sistemáticos de coleta e análise de dados sobre a velocidade e o regime de ventos. Geralmente, uma avaliação rigorosa requer levantamentos específicos.

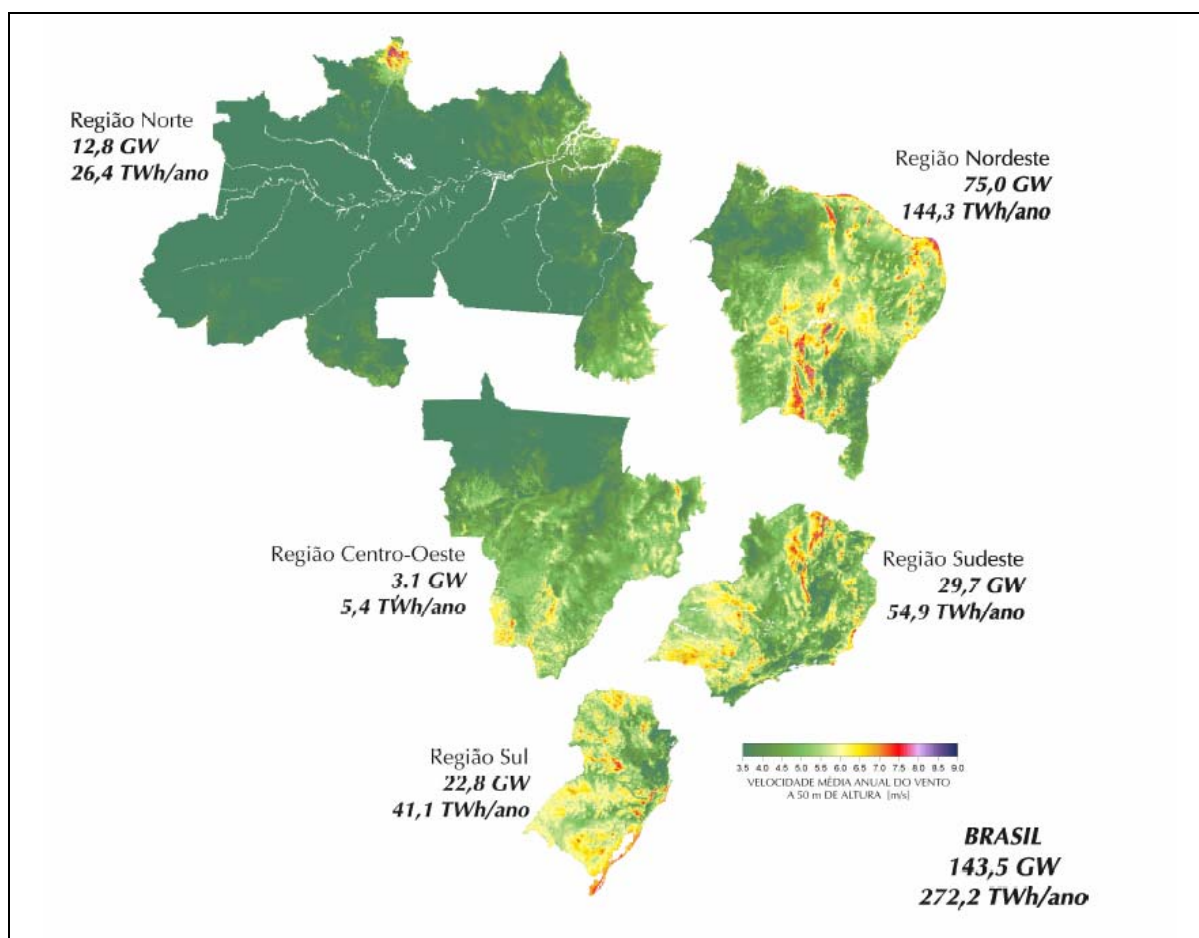
Alguns estudos estimam que o potencial eólico bruto mundial seja da ordem de 500.000 TWh por ano. Porém, devido a restrições sócio-ambientais, apenas 53.000 TWh (cerca de 10%) são considerados tecnicamente aproveitáveis [9]. Ainda assim, esse potencial líquido corresponde a cerca de quatro vezes o consumo mundial de eletricidade. Este número justifica o crescente aumento de investimentos em fontes de gerações eólicas em toda parte do mundo, inclusive no Brasil.

Com o ritmo atual de investimentos em energia eólica, principalmente pelos países Europeus, Asiáticos e os Estados Unidos, estima-se que a capacidade instalada mundial, que só em 2007 cresceu mais de 25%, passando de 74.000 MW para 94.000MW, alcance o patamar de 240.000 MW em 2012, conforme o GWEC 2007 (*Global Wind Energy Council*) em [11]. Contudo, aqui no Brasil, estes investimentos começaram de maneira tardia e tímida por causa de políticas energéticas equivocadas que levaram o país a crise do “Apagão elétrico” em 2001 em comparação com outros países, como por exemplo, Dinamarca, Espanha e Alemanha, principais geradores de eletricidade através desta fonte de energia.

Os primeiros anemógrafos computadorizados e sensores especiais para monitoramento da energia eólica foram instalados no Ceará e em Fernando de Noronha (PE), somente no início dos anos 90. Os resultados dessas medições possibilitaram a determinação do potencial eólico local e a instalação das primeiras turbinas eólicas do Brasil.

Atualmente, embora haja ainda divergências entre especialistas e instituições na estimativa do potencial eólico brasileiro, vários estudos indicam valores extremamente consideráveis. Até poucos anos, as estimativas eram da ordem de 20.000 MW. Hoje a maioria dos estudos indica valores maiores que 60.000 MW. Essas divergências decorrem principalmente da falta de informações e das diferentes metodologias empregadas. Um dos

estudos, realizados pelo Centro de Referência para Energia Solar e Eólica – CRESESB/CEPEL, denominado de Atlas do Potencial Eólico Brasileiro [10], estimou um potencial eólico da ordem de 143.000MW, conforme apresentado na Figura 2.1. Esta mesma figura ilustra também o potencial eólico em cada região brasileira, destacando-se a região Nordeste com quase 50 % de todo potencial estimado no Brasil por este estudo. Outros estudos preliminares já apontavam a vocação desta região para uso da energia proveniente da força dos ventos, como por exemplo, o estudo realizado pela Companhia Hidroelétrica do São Francisco (CHESF) em 1987 [12].



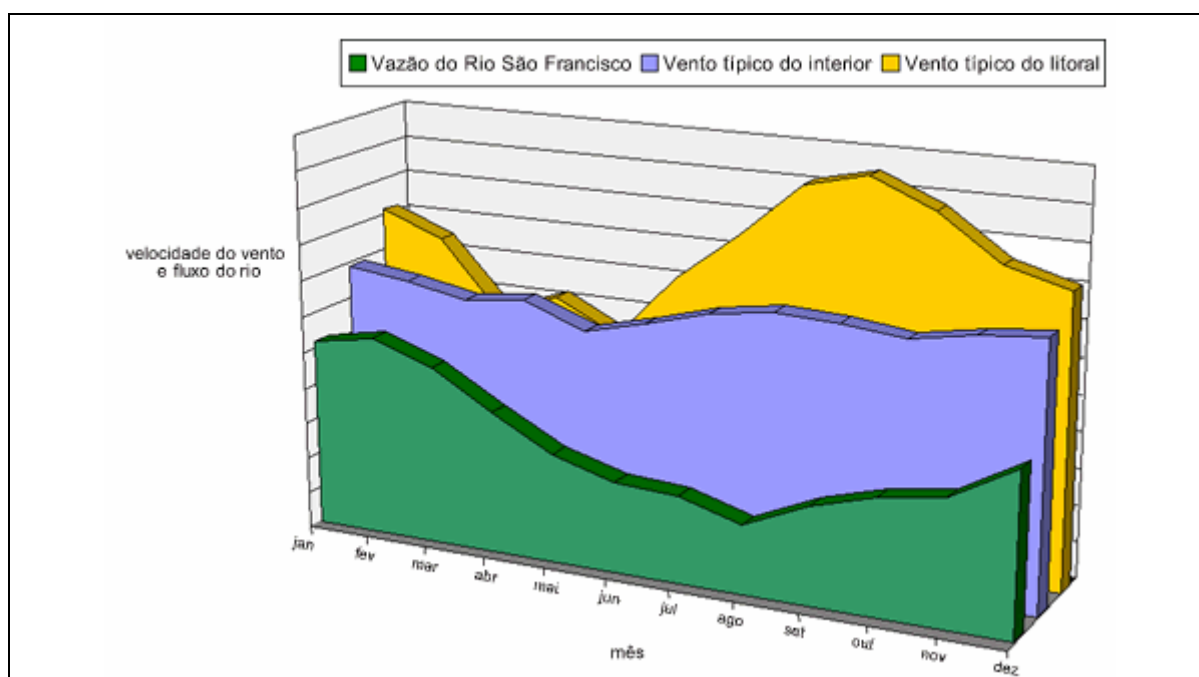
**Figura 2.1** - Potencial Eólico Brasileiro.

*Fonte: Atlas do potencial eólico brasileiro*

Apesar dos estudos comprovarem o potencial eólico brasileiro, o investimento em energia eólica só se intensificou no Brasil após o racionamento de energia em 2001 (“Apagão Elétrico”), quando a ELETROBRÁS criou o Programa de Incentivo de Fontes Alternativas de Energia Elétrica (PROINFA). Neste programa, estava previsto na primeira fase a instalação de 3.300MW em energia renovável a partir de diversas fontes de energias primárias, tais como, fontes eólica, pequenas centrais hidrelétricas e biomassa. Dentre estas

fontes alternativas, destaca-se a energia eólica, que segundo dados da Agência Nacional de Energia Elétrica (ANEEL) e do PROINFA contribuirá com 1.400 MW de potência para ser integrada ao sistema elétrico brasileiro até o ano de 2008. A maior parte desta potência deverá ser instalada no Nordeste, pois conforme relatado anteriormente esta região detém quase que 50 % do potencial brasileiro.

Além de contribuir para o aumento do potencial elétrico do país, a instalação de parques eólicos no Nordeste tem uma característica de permitir um melhor aproveitamento hídrico anual, diminuindo os riscos de um novo desabastecimento de energia elétrica. Pois, conforme pode ser visto na Figura 2.2, nos períodos em que o Rio São Francisco, onde estão instaladas as principais usinas hidroelétricas da CHESF, tem menores vazões, as velocidades dos ventos são mais intensas.



## 2.2 Características da Energia Eólica

A energia eólica apresenta algumas características que dificulta sua integração, tais como, a intermitência e a variabilidade dos ventos. Estas características requerem uma avaliação detalhada de sua interação, no momento da operação com o sistema gerador convencional, a fim de que se possa definir no momento do planejamento da expansão qual o montante de geração eólica que poderá ser inserido na matriz energética da região, sem

comprometer a eficiência e o desempenho do sistema gerador convencional atual e futuro, como mostrado em [13, 14, 15].

### 2.2.1 Aspectos para integração da energia eólica

Como principais pontos de diferenciações dos recursos eólicos sobre as outras fontes de gerações convencionais, tais como hidrelétricas e térmicas, podem-se destacar vários aspectos:

- Aspectos do Planejamento Elétrico-Energético;
- Operacionais;
- Comerciais;
- Regulatórios.

Todos estes aspectos tornam a integração da energia eólica nos sistemas elétricos de potência um desafio e são oriundos de certas características dos ventos, tais como incerteza, incontrolabilidade e variabilidade das velocidades.

Portanto, para mitigar essas dificuldades, faz-se necessário à integração de modelos eficientes de previsões de velocidades de ventos no planejamento e operação do sistema elétrico.

## 2.3 Produção de Energia Eólica

A energia eólica é produzida através da energia cinética dos ventos. Atualmente esta fonte de energia tem sido usada, alternativamente, para produção de energia elétrica no mundo.

O aproveitamento da energia cinética dos ventos para produção de eletricidade se dá através de um processo de conversão de energia que utiliza as turbinas eólicas acopladas aos geradores elétricos.

Neste processo de conversão, a interação entre o vento e o rotor da turbina produz o torque eletromecânico que é transferido ao gerador, visto que a energia eólica é produzida através da energia cinética, a qual é calculada através da Equação (2.1).

$$E = \frac{1}{2}mv^2 \quad (2.1)$$



Desta forma, combinando a Equação (2.1) com a definição de potência, que é definida pela razão de energia por unidade de tempo, deduz-se que:

$$P = \frac{E}{t} = \frac{mv^2}{2t} \quad (2.2)$$

Definindo a taxa do fluxo de massa ( $\dot{m}$ ) como sendo a massa por unidade de tempo. Esta taxa pode ainda ser explicitada pelo produto da densidade do ar ( $\rho$ ) e pela vazão de ar ( $Q$ ), conforme apresentado abaixo:

$$\dot{m} = \rho Q \quad (2.3)$$

Entretanto, a vazão ( $Q$ ) pode ser calculada através do produto da velocidade do vento ( $v$ ) pela área no qual o fluxo de ar atravessa as pás do rotor da turbina ( $A$ ),.

$$Q = vA \quad (2.4)$$

Sendo  $A$  é área varrida pelo rotor da turbina, que é diretamente proporcional ao quadrado do diâmetro, calculado a partir da Equação (2.5).

$$A = \frac{\pi D^2}{4} \quad (2.5)$$

Combinando as Equações (2.2), (2.3) e (2.4), chega-se a seguinte Equação para o cálculo da potência:

$$P = \frac{1}{2} \rho A v^3 \quad (2.6)$$

O valor de potência calculado pela Equação (2.6) é a potência contida no vento. Entretanto, as turbinas não capturam toda energia disponível nos ventos. Além disso, a condição de máxima extração de energia verificada para uma velocidade na esteira do rotor é igual a 1/3 da velocidade não perturbada. Em condições ideais, o valor máximo da energia captada por um rotor eólico é limitado pela eficiência de Betz dada pelo fator 16/27 ou 0,593. Em outras palavras, 59,3% da energia contida no fluxo de ar podem ser teoricamente extraídas por uma turbina eólica.

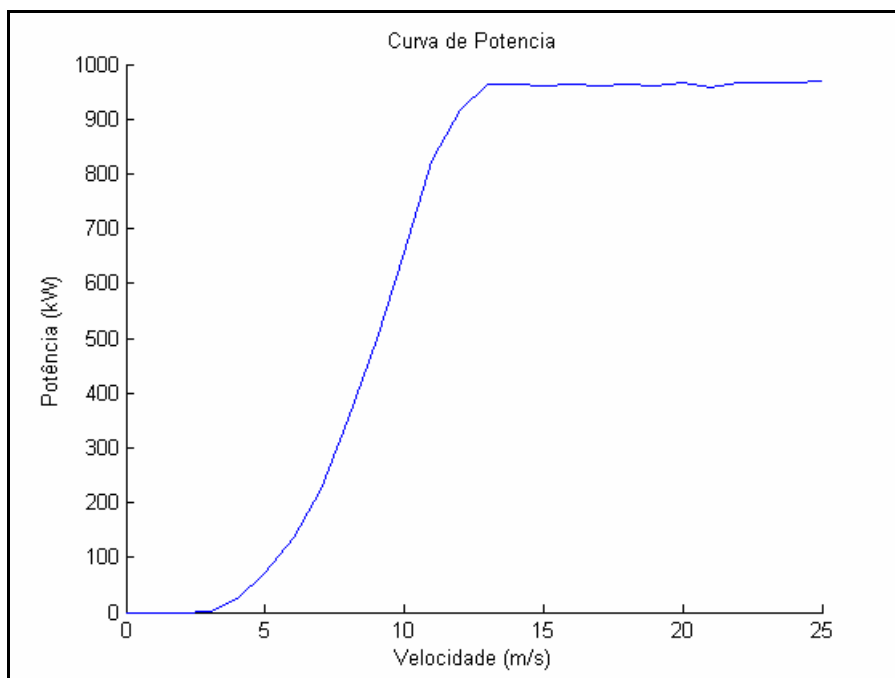
Na prática, entretanto, o rendimento aerodinâmico das pás reduz ainda mais este valor. Para um sistema eólico, existem ainda outras perdas, relacionadas com cada componente (rotor, transmissão, caixa multiplicadora e gerador). Fora isso, o fato do rotor eólico funcionar em uma faixa limitada de velocidade de vento também irá contribuir para reduzir a energia por ele captada, de acordo com a curva de potência da turbina.

Sendo assim, a energia líquida obtida por uma turbina eólica é calculada através da Equação (2.7).

$$P = \frac{1}{2} \rho A v^3 C_p \quad (2.7)$$

O coeficiente de potência ( $C_p$ ) é obtido através do produto da eficiência mecânica ( $\eta_m$ ), eficiência elétrica ( $\eta_e$ ) e da eficiência aerodinâmica da turbina eólica. Todos os três fatores dependem da velocidade do vento e da potência gerada.

A maneira mais fácil de estimar a produção de energia através da geração eólica é utilizando a curva de potência. Esta curva relaciona a potência extraída pela turbina com a velocidade.



**Figura 2.3** - Curva de Potência da Turbina.

A Figura 2.3 apresenta a curva de potência da turbina ENERCON E-58/10.58, conforme [16] especificada para os seguintes parâmetros:

- Potência nominal 1000kW
- Altura do eixo do rotor 70m
- Diâmetro do rotor 58.6 m
- Área do disco do rotor 2696m<sup>2</sup>
- Regulador de potência Pitch
- Número de pás 3

Caso a medição das velocidades do vento seja realizada a uma altura diferente daquela na qual será posicionado o centro do rotor da turbina, neste caso 70 m, as velocidades terão que ser corrigidas para esta altura. Esta correção pode ser realizada através de fatores de conversão.

Atualmente são utilizados dois métodos para determinar o fator de conversão. O primeiro é o Método da Lei de Potência, usado nos EUA, e o segundo é o Método Logarítmico, mais comumente usado na Europa, conforme [17].

A primeira aproximação deriva empiricamente das medidas atuais americanas e a segunda, usada no Atlas de Vento Europeu, provém matematicamente da teoria de como o vento se move na superfície da terra. A Equação (2.8) mostra a extrapolação logarítmica:

$$\frac{v}{v_0} = \frac{\log\left(\frac{H}{z_0}\right)}{\log\left(\frac{H_0}{z_0}\right)} \quad (2.8)$$

onde  $v$  representa a velocidade desejada,  $v_0$  a velocidade conhecida na altura  $H_0$ ,  $H$  a altura desejada para velocidade  $v$ ,  $H_0$  a altura de referência e  $z_0$ , o comprimento da rugosidade.

A Equação (2.9) representa a Lei da Potência. Nas Equações (2.8) e (2.9) é observado que a velocidade aumenta com o aumento da altura.

$$\frac{v}{v_0} = \left(\frac{H}{H_0}\right)^\alpha \quad (2.9)$$

Na Equação (2.9), o coeficiente  $\alpha$  representa as características de rugosidades dos diversos tipos de terrenos. A Tabela 2.1 apresenta diversos valores do coeficiente  $\alpha$  para diversos tipos de terrenos.

**Tabela 2.1** - Coeficientes de Rugosidades.

<b>Tipo de Terreno</b>	<b>Coeficiente</b>
Lago, oceano e solo liso	0,10
Florestas	0,15
Cercas vivas e arbustos	0,20
Pequenas cidades com poucas árvores e arbustos	0,25
Grandes cidades com altos edifícios e construções	0,30

## **2.4 Revisão Bibliográfica**

### **2.4.1 Modelos de previsão de velocidade de ventos**

O interesse no desenvolvimento de modelos de previsão de velocidades de ventos e geração eólica tem aumentado substancialmente, não só no mundo como também no Brasil. Este interesse tem sido despertado pelo aumento de produção de energia elétrica a partir das forças dos ventos e ainda para acompanhamento meteorológico, no caso dos estudos climáticos.

As velocidades dos ventos dependem de vários fatores, por exemplo: aspectos topográficos e atmosféricos, que fazem com que as velocidades variem muito ao longo dos períodos dos dias e dos anos. Esta variabilidade dos ventos provoca certo grau de dificuldade nos desenvolvimentos dos modelos de previsão. Portanto, existem vários modelos em estudo.

Dependendo da aplicação e do horizonte de previsão (escala) a serem estudados existem modelos de previsões mais apropriados, conforme será descrito nos tópicos a seguir. Estes modelos são divididos em:

- Físicos;
- Estatísticos e de Redes Neurais;
- Modelos de Correlação Espacial;
- Mistos.

## 2.4.2 Escalas de tempo de previsão

Até recentemente, as previsões das velocidades dos ventos eram realizadas apenas em dois horizontes de previsão de influência planetária e sinóptica (local). A escala planetária foi desenvolvida para horizonte de previsão extremamente longo de meses até anos que influenciam o planeta de modo geral. A escala sinóptica também é desenvolvida para tempos longos de previsão, variando de dias a meses, contudo tem um caráter mais local, que pode influenciar características temporais das regiões analisadas.

No entanto, estas escalas realizam previsões mais grosseiras sem muito detalhamento para extrair tendências climáticas do planeta e das regiões. Porém, as previsões das velocidades dos ventos para aplicação nos sistemas eólicos de geração exigem mais precisões. Desta forma, deu-se origem a novas escalas de previsão conhecidas como mesoescalas (microescalas). De acordo com o horizonte de previsão as mesoescalas dividem-se em:

- Alpha 2 dias a 6 horas
- Beta 6 horas a 30 minutos
- Gamma 30 minutos ou menos

## 2.4.3 Modelos físicos

A classe de modelo físico mais conhecido é o modelo de predição numérica do tempo (*numeric weather prediction - NWP*). Este modelo foi desenvolvido por pesquisadores da área meteorológica, os quais enfocam as escalas planetária ou sinóptica. Para estas escalas o modelo NWP oferece bom desempenho, contudo, para as mesoescalas este modelo tem sido preterido pelos métodos estatísticos ou de RNA, conforme [2].

Este modelo é baseado em modelos físicos que resolvem equações dinâmicas através de métodos numéricos para um determinado espaço tridimensional, representado no modelo a partir subdivisões do espaço total em grades (zonas).

O uso dos modelos NWP para horizonte de previsões menores (mesoescalas), é limitado por quatro fatores, ver [2]:

- Variabilidade dos ventos
- Resolução do modelo de elevação digital (*digital elevation models - DEM*)
- Espaçamento da grade

- Tempo computacional

A variabilidade dos ventos ao longo das horas e do dia é um fato que não pode ser evitado. Isto exige um maior detalhamento na modelagem e na resolução do modelo NWP, que pode ser obtido através do DEM e do espaçamento da grade. Contudo, isto pode incorrer no aumento do tempo computacional do modelo, já que este resolve Equações dinâmicas, que dependendo da precisão exigida requer mais tempo para resolvê-las. Sendo assim, a precisão exigida para previsão com horizonte nas mesoescalas, tornam o modelo NWP muitas vezes inviável nesta aplicação.

#### **2.4.4 Modelos estatísticos e de redes neurais**

Visto que a essência da ciência estatística é a observação e que seu objetivo básico é a inferência onde esta pode ser dedutiva (argumentam das premissas as conclusões) ou indutiva (através da qual vai do específico ao geral), é possível desenvolver modelos de previsão através das séries temporais

Define-se série temporal como sendo um conjunto de observações (dados) de uma determinada grandeza durante um espaço de tempo. Os intervalos de observações são quase sempre regulares, ou seja, igualmente espaçados.

Estes modelos de previsões podem ser: univariados ou multivariados. Diz-se que o modelo é univariado quando utiliza apenas a grandeza de interesse como variável explicativa. E multivariados quando se utiliza outras grandezas além da própria variável de interesse como variável explicativa.

Fundamentado nos modelos de séries temporais univariados, existem duas técnicas mais aplicadas a previsão de ventos e geração eólica, são elas:

- Métodos estatísticos;
- Redes neurais artificiais.

Estes métodos de previsão são, geralmente, utilizados para horizontes de previsões pequenos (mesoescalas). Pois nestes horizontes a correlação entre as velocidades dos ventos, e conseqüentemente a geração, são maiores.

Os modelos estatísticos mais disseminados pelos pesquisadores é modelo Auto-Regressivo Média Móvel. Este o modelo foi desenvolvido por Box-Jenkins em [18]. Estes métodos são ajustados por regressão linear, conforme será visto posteriormente.

Recentemente, os pesquisadores da área de previsão de ventos e geração eólica têm utilizado as redes neurais artificiais no desenvolvimento dos modelos de previsão. As redes são utilizadas em modelos de previsões, devido sua alta capacidade de generalização. Geralmente estas são desenvolvidas através de um processo de aprendizagem supervisionado, ou seja, aprendizado com professor. Além disso, quase sempre o tipo de rede escolhida para o desenvolvimento do modelo são as redes do tipo Perceptron Múltiplas Camadas (*Multi Layer Perceptron - MLP*).

Estas redes neurais têm facilidade de aprender a partir do mapeamento de entrada e saída durante a etapa de treinamento. Isto permite que os modelos neurais tenham bons desempenhos, mesmo sem conhecimento do problema por parte dos pesquisadores.

Os modelos de previsão de ventos e geração eólica citados acima (método ARMA, redes MLP e os Modelos híbridos) também podem desenvolver modelos multivariados de previsão, desde que se tenham outras séries temporais de grandezas que influenciem nas velocidades dos ventos do ponto de interesse.

#### **2.4.5 Modelos de correlação espacial**

Estes tipos de modelo são utilizados para horizontes de previsões curtos (mesoescalas). Estes são desenvolvidos a partir de modelos de série temporais multivariadas, isto é, utilizam outras séries como variáveis explicativas.

No caso da previsão de ventos e geração eólica, são utilizadas séries de velocidades e direção dos ventos dos parques eólicos vizinhos ao parque de onde se queiram realizar as previsões. Os desempenhos destes modelos dependem de quão correlacionado são as velocidades dos parques vizinhos.

A principal dificuldade deste modelo é devido à complexidade do terreno e da vegetação da localidade, pois quanto maior a complexidade menor será a correlação entre as velocidades dos ventos dos parques vizinhos.

Sendo assim, este modelo tem aplicabilidade, geralmente, para localidades com poucos desníveis e obstáculos. Nestes casos, os desempenhos destes modelos podem superar os outros métodos, conforme [4, 7].

Estes modelos também podem ser desenvolvidos a partir dos métodos estatísticos de previsão e de rede neurais, já que se pode ajustar (treinar) os parâmetros a partir das séries de velocidades do próprio parque eólico e dos parques vizinhos de onde se deseja realizar as previsões.



### 2.4.6 Modelos Mistos

Existem ainda modelos de previsão de velocidades dos ventos e de geração eólica que utilizam os modelos numéricos de previsão (NWP), os modelos estatísticos, as redes neurais e lógica fuzzy de maneira combinada na composição dos modelos de previsão, aproveitando as vantagens de cada um dos métodos [2, 6, 7, 8].

Geralmente estes modelos são aplicados para localidades onde se têm um modelo NWP, que não tenha resolução adequada para o horizonte de previsão desejado. Desta forma, a saída do modelo NWP é usada como entrada dos modelos estatísticos ou de RNA.

A lógica fuzzy é utilizada para avaliar a qualidade das previsões realizadas a partir dos modelos numéricos, com a finalidade de filtrar as informações antes de serem repassadas para os ajustes dos modelos estatísticos e de redes neurais.

Sendo assim, os modelos mistos são usados, quase sempre, em horizontes de previsões curtos (mesoescalas) para ajustar os resultados encontrados através dos modelos NWP.

## CAPÍTULO 3

### 3 Base Teórica

#### 3.1 Estudos de Séries Temporais

A série temporal representa um conjunto de observações ordenadas no tempo, que exibe dependência serial e que pode ser modelado por um processo estocástico aleatório. A variável é observada em pontos discretos de tempo, normalmente espaçada igualmente. A análise e modelagem de séries temporais buscam descrever uma determinada seqüência da grandeza observada para caracterizar as suas características mais importantes.

Quando se analisa uma série temporal,  $X(t)$ , expressa pela seqüência  $X(t_1), \dots, X(t_n)$ , observada nos instantes  $t_1, \dots, t_n$ , os objetivos em mente são os mais variados possíveis. Em aplicação de modelos de previsão, a análise da série é realizada para extrair as seguintes características:

- Modelagem sob o fenômeno em observação;
- Obtenção de conclusões em termos estatísticos;
- Avaliação da adequação do modelo em termos de previsão;
- Sumários dos dados.

As técnicas de predições utilizadas, tais como os métodos convencionais baseados métodos em estatísticos, e os métodos baseado em inteligência artificial; requerem familiaridade com os dados de trabalho. Desta forma, a análise das séries temporais para adquirir sensibilidade e ajustar melhor os modelos é indispensável.

#### 3.2 Análise estatística

No desenvolvimento de modelos de previsão é necessário analisar estatisticamente a série temporal, visando caracterizar as grandezas observadas de modo a identificar as sazonalidades e tendências que poderão subsidiar os projetos dos modelos de previsões.

##### 3.2.1 Valor Médio da Amostra

Esta grandeza é utilizada para verificar o patamar (nível) da série em análise e seu valor é calculado através da Equação (3.1).

$$\bar{X} = \frac{\sum_{t=1}^N X(t)}{N} \quad (3.1)$$

Onde:

- $X$  - Série Temporal da grandeza observada
- $N$  - Número de dados da série
- $\bar{X}$  - valor médio da amostra

### 3.2.2 Desvio Padrão da Amostra

O desvio padrão serve para evidenciar o quão variável são os dados das séries. Seu valor é calculado conforme a Equação **Erro! Fonte de referência não encontrada.**

$$\sigma = \sqrt{\frac{\sum_{t=1}^N (X(t) - \bar{X})^2}{N}} \quad (3.2)$$

### 3.2.3 Autocorrelação e Correlação

A análise adequada dos coeficientes de autocorrelação e correlação serial permite ao usuário obter informações sobre a série temporal de interesse. Os coeficientes de autocorrelação da série podem ser determinados através da Equação (3.3), já a correlação entre as séries diferentes, é calculado pela Equação (3.4). Nestas equações  $i$  representa a janela de regressão.

$$C_i = \frac{\sum_{t=1}^{N-i} (X(t) - \bar{X})(X(t+i) - \bar{X})}{\sum_{t=1}^N (X(t) - \bar{X})^2} \quad (3.3)$$

$$\rho_i = \frac{\sum_{t=1}^{N-1} (X(t) - \bar{X})(Y(t) - \bar{Y})}{\left[ \sum_{t=1}^{N-1} (X(t) - \bar{X})^2 \cdot \sum_{t=1}^{N-1} (Y(t) - \bar{Y})^2 \right]^{1/2}} \quad (3.4)$$

A partir destes valores espera-se poder inferir a dependência que os dados da série têm entre si e com outras séries, as quais ajudam a explicar a grandeza de interesse, o que facilitará a determinação da ordem de regressão dos dados usados como entradas dos modelos de previsão.

Além disso, a precisão e a aplicabilidade dos modelos de previsão dependem dos coeficientes de autocorrelações e correlação, pois estes representam a dependência dos dados das grandezas a ser prevista com sua própria série e com outras séries que ajudam a explicar a sua formação.

### **3.3 Métodos Estatísticos de Previsão**

Uma das formas de se tratar séries temporais é através do uso de modelos estatísticos. Tais modelos foram utilizados antes dos métodos de inteligência artificial para desenvolver estudos e modelos de previsões no âmbito da geração eólica. Os modelos mais conhecidos são os desenvolvidos Box e G. M. Jenkins [18]. A seguir são listados os modelos mais utilizados no âmbito das previsões de ventos e geração eólica:

- Média Móvel Integrado Auto-Regressivo (ARIMA);
- Média Móvel Auto-Regressivo (ARMA);
- Auto-Regressivo (AR).
- Persistência;

Uma vez definido as ordens destes modelos, eles estimam os seus coeficientes através de regressão múltipla da série temporal ( $X$ ) utilizando técnicas de otimização para minimizar o erro encontrado durante o ajuste do modelo.

#### **3.3.1 Modelo Média Móvel Integrada Auto-Regressivo (ARIMA)**

O modelo mais utilizado e conhecido entre os estatísticos para previsões de séries temporais é o ARIMA [18]. Este modelo desenvolvido por Box e Jenkins foi o mais popularizado por seu alto grau de generalidade, ele pode lidar com qualquer série, estacionária ou não, com ou sem elementos sazonais. Este modelo de previsão geralmente é aplicado a séries que não apresentam a condição de estacionariedade, nelas deverá ser

aplicado o operador diferença, o que efetuará uma segunda filtragem, que poderá ser repetida quantas vezes se julgarem necessárias, até sua estacionarização.

O processo de diferenciação ( $\Delta X$ ) consecutiva de  $d$  vezes é realizado conforme apresentado na Equação (3.5), até que se obtenha uma série ( $\Delta^d X$ ) estacionária e que possa ser modelada por um modelo ARMA( $p,q$ ), que será descrito a seguir.

$$\begin{cases} \Delta X(t) = X(t) - X(t-1) \\ \Delta^2 X(t) = \Delta X(t) - \Delta X(t-1) \\ \vdots \\ \Delta^d X(t) = \Delta^{d-1} X(t) - \Delta^{d-1} X(t-1) \end{cases} \quad (3.5)$$

A notação do modelo é ARIMA( $p,d,q$ ), onde  $p$  é a ordem do modelo auto-regressivo;  $q$  é a média móvel do modelo e  $d$  representa a ordem do modelo integrado, que é definido pelo grau de diferenciação selecionado. Geralmente estas ordens são determinadas empiricamente.

### 3.3.2 Auto-Regressivo Média Móvel (ARMA)

Este modelo é um caso particular do modelo ARIMA, no qual a ordem do modelo integrado é nula. Este é aplicado para séries consideradas estacionárias, ou seja, série que apresenta média e variância constante ao longo do tempo. Este modelo é representado analiticamente pela Equação (3.6). Nesta Equação, o coeficiente  $a$  representa os coeficientes de autocorrelação, já o  $b$  representa o coeficiente de correlação da série com erros cometidos nas previsões anteriores.

$$X_t = \sum_{j=1}^p a_j X(t-j) + \sum_{k=0}^q b_k e(t-k) \quad (3.6)$$

Neste modelo, além de considerar os valores passados da série,  $X(t-1)$ , ...,  $X(t-p)$ , também é considerado os valores dos erros cometidos na previsão em instantes anteriores como variáveis de entrada.

### 3.3.3 Modelo Auto-Regressivo

Esse modelo é chamado de auto-regressivo de ordem  $p$ , porque a observação corrente,  $X(t)$ , depende de realizações anteriores como  $X(t-1)$ ,  $X(t-2)$ , ...,  $X(t-p)$  da mesma

série temporal. Este modelo também é um caso particular do modelo ARIMA, no qual as ordens dos modelos integrado e média móvel são nulas.

$$X_t = \sum_{j=1}^p a_j X(t-j) \quad (3.7)$$

### 3.3.4 Persistência

Um dos modelos de previsão mais utilizados é o modelo persistência. Este modelo é baseado nos valores mais recentes da série  $X$ , como pode ser observado na Equação (3.8). O modelo de persistência só é utilizado para horizonte de previsão curto.

$$X_t = \frac{1}{N} \sum_{i=1}^N X(t-1) \quad (3.8)$$


O método de persistência é considerado o método de previsão mais simples, visto que realiza a previsão com base nos últimos valores da série. No Brasil, devido à insuficiência de dados relacionados à medição de velocidades de ventos, o método de persistência é bastante utilizado. No caso particular, em que  $N$  é igual a 1, o método persistência se confundi com o método ARIMA (0,1,0).

## 3.4 Transformada Wavelet

A transformada wavelet (TW) é uma transformada linear que pode ser utilizada na análise de sinais não estacionários para extrair informações das variações em frequência desses sinais e para detectar suas estruturas temporalmente ou espacialmente localizadas.

Para a TW, os dados são representados via superposição de wavelets com diferentes posições e escalas, cujos coeficientes essencialmente quantificam a força da contribuição das wavelets naquelas posições e escalas.


A Figura 3.1 mostra as funções de base wavelet de *Daubechies*, os ladrilhos e o plano *tempo*  $\times$  *freqüência* de cobertura. Para freqüências mais altas tem-se uma alta resolução no tempo e baixa na freqüência, e para freqüências mais baixa tem-se uma resolução freqüencial alta e temporal baixa. Isto devido ao fato de sinais com componentes em alta freqüência terem rápidas alterações no domínio temporal e sinais com componentes de baixa freqüência apresentarem alterações mais lentas no domínio temporal.



**Figura 3.1** - Esquema de um Plano Tempo x Freqüência.

As wavelets são transformações matemáticas que separam dados em suas diferentes componentes freqüenciais, e extraem cada componente com uma resolução adequada à sua escala. Elas têm vantagens em relação à análise de Fourier, pois esta última analisa o sinal como um todo, acarretando numa representação mais pobre para sinais que contêm descontinuidades e variações bruscas.


Comparando as wavelets com as ondas senoidais, que são as bases da análise de Fourier, pode ser observado na Figura 3.2 que as senoides não possuem duração limitada – elas se estendem de menos a mais infinito. Além disso, as senoides são suaves e previsíveis, as wavelets tendem a ser irregulares e assimétricas com relação ao eixo das ordenadas.



**Figura 3.2** - Senoide e Wavelet (db10).

A análise de Fourier consiste em decompor o sinal em ondas senoidais de várias freqüências. Da mesma forma, a análise wavelet decompõe o sinal em versões escalonadas e deslocadas de sua wavelet original (wavelet mãe). Graficamente, o processo para análise de Fourier e Wavelet tem o seguinte aspecto:

Observando apenas o formato das wavelets e das senoides, apresentadas na Figura 3.3 (a) e (b), pode-se intuitivamente verificar que sinais com mudanças bruscas parecem ser mais bem analisados com wavelets irregulares do que com senoides suaves. Assim, faz sentido pensar que características locais são mais bem representadas por wavelets, que possuem extensão local.



**Figura 3.3** - Decomposição: (a) senoidal do sinal em diferentes frequências; (b) Wavelet do sinal em diferentes escalas e deslocamentos.

Matematicamente, a Transformada Wavelet têm duas versões distintas:


- Transformada Wavelet Contínua;
- Transformada Wavelet Discreta.

### 3.4.1 Transformada Wavelet Contínua

A Transformada Wavelet Contínua é calculada fazendo translações e escalonamentos contínuos de uma função, Wavelet Mãe (WM), sobre um sinal, calculando uma correlação entre eles.

Para melhor entendimento do funcionamento das TW contínua é exemplificado abaixo cinco passos desta análise:


- Definir a WM a ser utilizada e compará-la a parte inicial do sinal em análise;
- Calcular a correlação ( $C$ ) entre a parte inicial do sinal e WM;



**Figura 3.4** - Passo 2 da Transformada Wavelet Contínua.




- Transladar a Wavelet para direita e repetir as etapas de 1 a 2 até que tenha varrido todo sinal;



**Figura 3.5** - Passo 3 da Transformada Wavelet Contínua.

- Aumentar a escala da Wavelet e repetir os passos de 1 a 3;



**Figura 3.6** - Passo 4 da Transformada Wavelet Contínua.

- Repita os passos de 1 a 4 até que varra toda as escalas definidas.

Na prática uma transformada assim não seria muito útil, pois seriam requeridas infinitas translações e escalonamentos, necessitando muito tempo e recursos computacionais, ainda assim, gerando muita redundância.

### 3.4.2 Transformada Wavelet Discreta

As Transformadas Wavelet Discretas foram introduzidas com o intuito de proporcionar uma descrição mais eficiente. Elas não são transladadas nem escalonadas continuamente, mas sim em intervalos discretos. Isto pode ser feito com uma pequena modificação na Wavelet Contínua, conforme apresentado na Equação (3.9), em que o coeficiente  $a$  representa a escala e o coeficiente  $b$  representa a translação.


$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \Rightarrow \psi_{m,n}(t) = \frac{1}{\sqrt{|a_0^m|}} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (3.9)$$

Sendo  $m$  e  $n$  inteiros,  $a_0 > 1$  é um parâmetro de dilatação (escala) fixo,  $b_0$  é o fator de translação (deslocamento) que depende do fator de dilatação e  $\Psi$  representa a WM.

Os coeficientes no domínio da transformada correspondem a pontos em um reticulado bidimensional no plano *escala x translação*. A grade é indexada por dois inteiros  $m$  e  $n$ , sendo o primeiro associado aos passos na escala discreta e o segundo aos passos das translações discretas, conforme apresentado no exemplo abaixo:

- Escala discreta (logarítmica):  $a = a_0^m \quad m = 1, 2, 3, \dots$
- Translações discretas:  $b = nb_0a_0^m \quad n = 1, 2, 3, \dots$  fixado  $m$ .
- No caso diádico, fazendo  $a_0 = 2$  e  $b_0 = 1$ , tem-se:

$$\Delta_{a_0b_0} = \{(2^m, n2^m)\}_{m,n \in \mathbb{Z}}$$



**Figura 3.7** - Reticulado

Assim, o cálculo TW é realizado conforme apresentado na Equação (3.10)

$$TW(a,b) = CTWS(m,n) := \frac{1}{\sqrt{|a_0^m|}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t - nb_0a_0^m}{a_0^m}\right) dt \quad (3.10)$$

Note que o sinal  $f(t)$  e a Wavelet Mãe são definidos em tempo contínuo, porém os coeficientes discretos das Séries Wavelet de Tempo Contínuo  $CTWS(m,n)$  são definidos em valores discretos num reticulado.

De modo geral, as transformadas contínuas são primordialmente empregadas na dedução de propriedades das transformadas. Formas discretas são atraentes do ponto de vista de implementação e do ponto de vista computacional.

### 3.5 Análise de Multiresolução

Análise multiresolução é uma técnica originada na área de processamentos de sinais, que no contexto das wavelets, constitui-se na forma padrão de construção das bases de wavelets e da implementação da transformada wavelets ortonormais.

Uma forma de programar a transformada wavelet diádica ortonormal pode ser obtida através do algoritmo baseado na representação multiresolução de sinais que, assim como a transformada wavelet, decompõe o sinal em escalas com diferentes resoluções no tempo e na frequência [19].

As wavelets estão associadas a uma filtragem passa-faixa interativa na qual a banda passante dos filtros consecutivos adjacentes é a metade de seu antecessor. Entretanto, para se evitar um número infinito de filtros analisadores é usado um único filtro para baixas frequências, quando a faixa de frequência é suficientemente pequena [20]

A função escala (LPF – Low Pass Filter), denotada geralmente por  $\phi(t)$ , foi introduzida por Mallat [21]. O princípio fundamental é analisar o sinal através de uma combinação de uma função escala  $\phi(t)$  (passa-baixa) e wavelet  $\psi(t)$  (passa-faixa). Esta idéia é essencial na codificação em sub-bandas e na análise de multiresolução.

#### 3.5.1 Codificação em Sub-Bandas

Quando se usa wavelets discretas para analisar um sinal, o resultado é uma série de coeficientes wavelet, também chamada de série de decomposição de wavelet. É possível implementar uma TW sem implementar explicitamente as wavelets.

A solução para este obstáculo é simplesmente não cobrir o espectro até a origem. Cobre-se o espectro até que a banda não coberta pelos filtros wavelets seja suficientemente pequena. Com este valor calcula-se o limite inferior para o escalonamento, único parâmetro restante conforme [20].

A idéia de se analisar um sinal via um banco de filtros já vem sendo adotada há vários anos e é conhecida como Codificação em Sub-bandas (*Subband Coding*). Este princípio é usado no cálculo da Transformada Discreta de Wavelet. O banco de filtros usado na codificação em sub-bandas pode ser projetado de diversas maneiras.

O modo mais usado na análise para wavelets discreta consiste em projetar filtros passa-alta (High-Pass) e passa-baixa (Low-Pass), conforme ilustra na Figura 3.8 de modo a dividir o espectro do sinal exatamente ao meio.




Figura 3.8 - Bancos de Filtros

Este processo de filtros consecutivos, conhecido como algoritmo piramidal, possibilita obter “aproximações” e “detalhes” de um dado sinal de interesse. Uma aproximação é uma representação de baixa frequência do sinal, enquanto que um detalhe é a diferença entre duas representações sucessivas de baixa resolução do sinal original ( $cD3=cA2-cA3$ , Figura 3.9). Uma aproximação contém a tendência geral do sinal original, enquanto que um detalhe exhibe os componentes de alta frequência do sinal de entrada.

### 3.5.2 Decomposição em Múltiplos Níveis

O processo de decomposição é iterado com sucessivas aproximações sendo decompostas a cada nível conforme o algoritmo piramidal, de modo que cada sinal é quebrado em varias componentes de baixa resolução. Isto é chamado de árvore de decomposição wavelet. A Figura 3.9 mostra um exemplo de decomposição de um dado sinal  $S$  em três níveis através de sua árvore de decomposição.




Figura 3.9 - Árvore de Decomposição do Sinal em 3 Níveis

## 3.6 Redes Neurais

As Redes Neurais Artificiais (RNA) são sistemas paralelos distribuídos compostos por unidade de processamento, chamados de nodos (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não lineares). Esta forma de computação não-algorítmica é caracterizada por sistema que, assemelham-se a estrutura do cérebro humano. O grande apelo destes modelos está em sua capacidade de “aprender”, generalizar ou extrair regras automaticamente de conjuntos de dados complexos [22].

As RNA se constituem em uma técnica de inteligência artificial cuja utilização prática está se tornando cada vez mais presente no nosso dia-a-dia. Aplicações realizadas com RNA têm apresentado desempenho satisfatório em diversas áreas de pesquisas, tais como: classificação, reconhecimento de padrão, aproximação de funções, processamento de séries temporais, otimização, etc.

Atualmente as redes neurais apresentam-se como uma abordagem alternativa aos métodos estatísticos de previsão de série temporal. O emprego desta técnica é atrativo em uma grande variedade de problemas que envolvem relacionamentos complexos entre as variáveis de entrada e de saída, uma vez que para utilização não se faz necessário o conhecimento prévio das relações matemáticas entre estas.

### 3.6.1 Neurônio Artificial

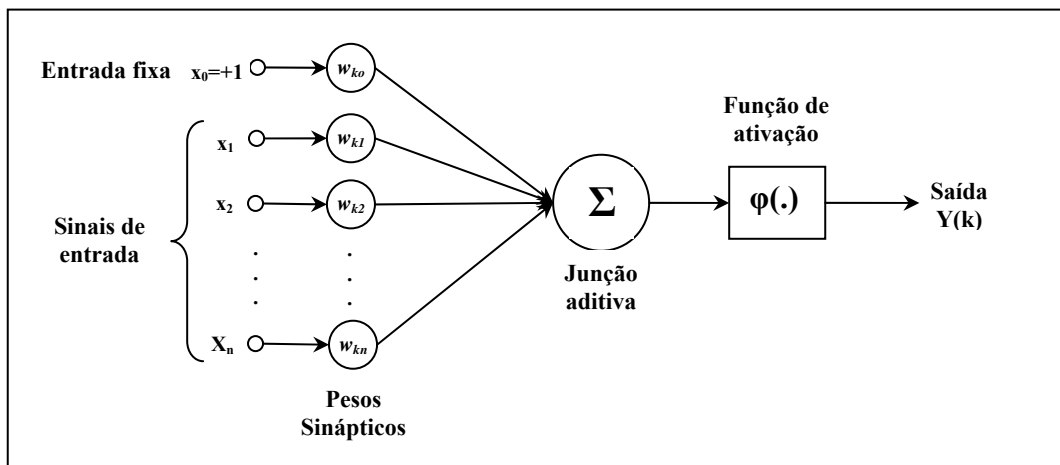
Em 1943, Warren McCulloch e Walter Pitts [23] publicaram um trabalho pioneiro no qual introduziram a idéia de redes neurais como máquinas computacionais. O neurônio de McCulloch e Pitts foi proposto com pesos fixos, isto é, não-ajustáveis, e só conseguem implementar funções linearmente separáveis, limitando sua utilização.

Após várias pesquisas chega-se a uma rede neural artificial constituída de vários neurônios artificiais que estão altamente conectados [22, 24].

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. A Figura 3.10 mostra o modelo de um neurônio, de onde se identificam três partes básicas do modelo neuronal:

- Um conjunto de sinapse ou elos de conexões, onde cada um é caracterizado por um peso ou força própria. Especificamente, um sinal  $x_j$  na entrada da sinapse  $j$  conectadas ao neurônio  $k$  é multiplicado pelo peso sináptico  $W_{kj}$ .

- Um somador para somar os sinais de entradas, ponderados pelas respectivas sinapses.
- Uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que pode restringir (limitar) o intervalo admissível de amplitude do sinal de saída de um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo fechado  $[0 \ 1]$  ou alternativamente  $[-1 \ 1]$ .



**Figura 3.10** - Neurônio Artificial

O modelo neural da Figura 3.10 inclui também um bias aplicado externamente, representado por  $w_{k0}$ . O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo.

Em termos matemáticos podemos descrever um neurônio  $k$  conforme as seguintes Equações (3.11) e (3.12).

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (3.11)$$

$$y_k = \varphi(v_k) \quad (3.12)$$

Onde sinais  $x_1, x_2, x_3 \dots x_n$  são os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{kn}$  são os pesos sinápticos associado ao neurônio  $k$ . Definido um campo local induzido  $v_k$ , como sendo à saída do combinador linear que será aplicado à função de ativação  $\varphi(\cdot)$  e assim obter a saída do neurônio  $k$  ( $y_k$ ).

### 3.6.2 Função de Ativação

A partir do modelo proposto por McCulloch e Pitts [23], em que a saída do neurônio assume apenas valores binários 0 ou 1, foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente sendo 0 ou 1, e com diferentes funções de ativação, onde estas podem ser lineares ou não, conforme apresentado na Figura 3.11

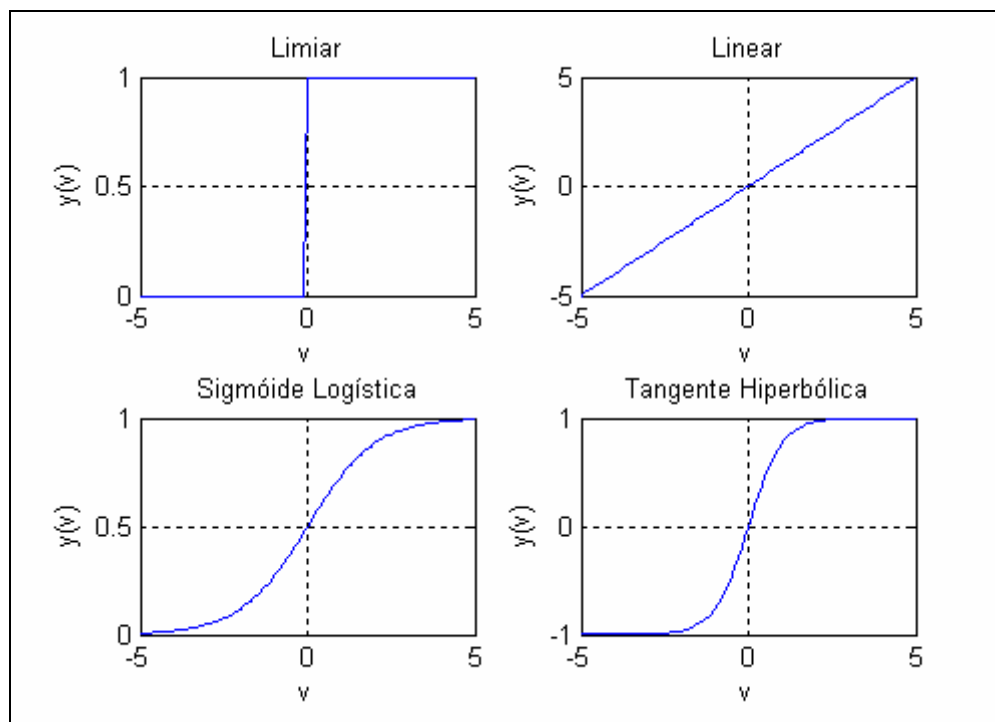


Figura 3.11 - Funções de ativações.

### 3.6.3 Processo de Aprendizagem

A utilização de uma RNA na solução de uma tarefa passa inicialmente por uma fase de aprendizagem. Segundo [25]: “Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando”.

O objetivo principal do processo de aprendizado é conceder a RNA a capacidade de generalizar os resultados do treinamento. Esta capacidade da RNA é conhecida como processo de generalização.

O processo de aprendizagem das RNA é realizado basicamente a partir de dois grandes paradigmas: aprendizado supervisionado, também conhecido como aprendizado

com um professor, e aprendizado não supervisionado. O paradigma a ser utilizado na solução do problema depende do tipo de problema e do tipo de RNA.

### 3.6.3.1 Aprendizado Supervisionado

Este paradigma de aprendizagem também conhecido como aprendizagem com um professor é o mais comum nos treinamentos das RNAs. Neste paradigma as entradas e saídas desejadas são fornecidos por um supervisor externo (professor).

Suponha que o professor e a rede neural sejam expostos ao conjunto de treinamento retirado do ambiente. Em virtude do seu conhecimento prévio, o professor é capaz de fornecer à rede neural a resposta desejada para o conjunto de treinamento. Na verdade, a resposta desejada representa a ação ótima a ser realizada pela rede.

Desta forma, os parâmetros livres das redes neurais, pesos sinápticos e bias, são ajustados conforme a regra definida pelo algoritmo de aprendizagem sobre a influência combinada do vetor de treinamento e do sinal de erro, que é calculado pela diferença entre o valor de saída da rede e valor apresentado pelo professor. Estes ajustes são realizados passo a passo com o objetivo de a rede emular o professor até atingir a melhor precisão. A Figura 3.12 representa o esquema em digrama de blocos da aprendizagem supervisionada.

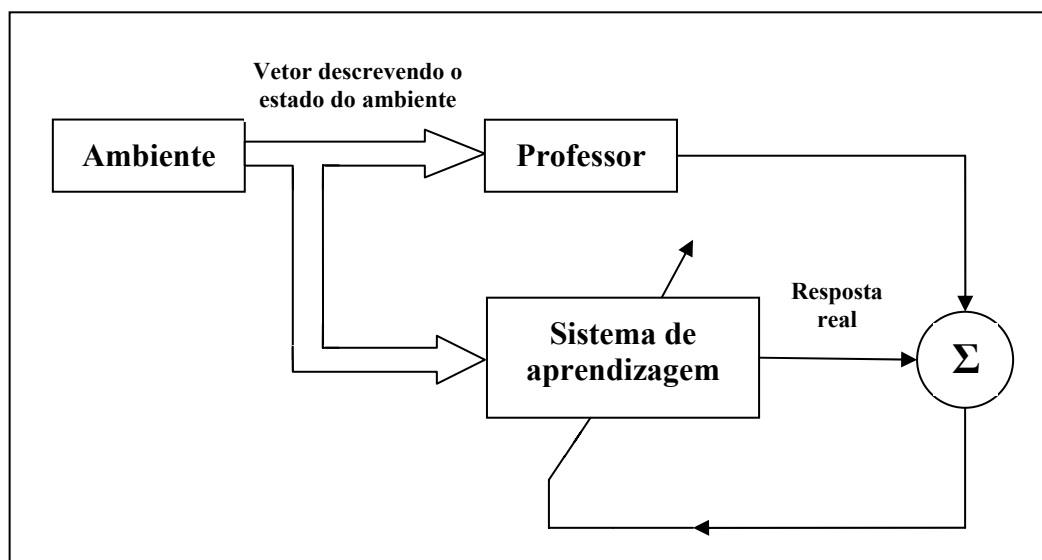


Figura 3.12 - Diagramas de Blocos da Aprendizagem com Professor.

O Aprendizado supervisionado pode utilizar várias regras ou algoritmo de aprendizagem com o objetivo de minimizar os erros, ou seja, corrigi-los. A forma genérica para alteração dos parâmetros livres por correção de erro é dada pela Equação (3.13). Esta




expressão é a base para os principais algoritmos de aprendizagem que utilizam este paradigma [26, 27, 28], conforme será mostrado posteriormente.

$$w_i(t+1) = w_i(t) + \eta e(t)x_i(t) \quad (3.13)$$

A maioria das aplicações de redes neurais utiliza redes que requerem este tipo de paradigma, como por exemplo, as redes Perceptrons Múltiplas Camadas (MLP) e redes Função Base Radial (RBF).

### 3.6.3.2 Aprendizado não Supervisionado

Neste paradigma, o aprendizado ocorre sem a tutela do professor. Isto significa que não há exemplos rotulados do problema a ser resolvido pela rede. Este paradigma é ilustrado pelo diagramas de blocos da Figura 3.13.



**Figura 3.13** - Aprendizado não supervisionado

O processo de aprendizagem através deste paradigma, consiste em modificar repetidamente os parâmetros livres das redes neurais em resposta as entradas de acordo com a regra ou algoritmo de aprendizagem.

Como exemplo de regra de aprendizagem que utiliza este paradigma, tem-se o aprendizado por competição. A idéia neste processo de aprendizagem consiste em fazer com que os neurônios das unidades de saída disputem entre si para serem ativadas. Durante a etapa de treinamento (ajuste dos parâmetros livres) os neurônios que vão se tornando ativos com um determinado padrão de entrada têm seus pesos ajustados, de maneira que este tenha uma maior probabilidade de se torna ativo quando for estimulado por um padrão semelhante. Já os neurônios que não foram ativados, podem ser ajustados ou não, de acordo com seu grau de vizinhança do neurônio vencedor (ativo).

Os tipos de redes neurais, mais conhecidas, que utilizam estas regras são as Redes Mapas Auto-Organizáveis (SOM – Self-Organizing Maps) desenvolvidas por Teuvo Kohonen [29].

### 3.6.4 Redes Perceptron Múltiplas Camadas

São redes do tipo *feed-forward*, ou seja, o processamento da informação se dá no sentido progressivo. Tipicamente, a rede consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camada oculta de nós computacionais (neurônios) e camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede camada por camada. A Figura 3.14 ilustra a rede MLP.

As redes do tipo Perceptrons de Múltiplas Camadas (MLP) têm sido aplicadas com sucesso para resolver diversos problemas difíceis. Inicialmente, o que alavancou o uso das redes MLP foi o desenvolvimento do algoritmo de treinamento de retropropagação do erro (*back-propagation*), o qual permite estimar o erro cometido pelos os neurônios das camadas intermediárias e, conseqüentemente, determinar os devidos ajustes dos pesos em todos os neurônios da rede, a fim de minimizar o erro durante o treinamento da mesma.




Figura 3.14 - Rede MLP

### 3.6.5 Algoritmo de Treinamento

Conforme dito anteriormente, boa parte das aplicações de RNA realiza seus treinamentos a partir de algoritmo supervisionado. Aqui será descrito o desenvolvimento de dois algoritmos, são eles: o algoritmo *back-propagation*, que foi o algoritmo que possibilitou o avanço das pesquisas de RNA na década 80; e o algoritmo Resilient

Propagation, que é o algoritmo mais utilizado em aplicações que, o número de parâmetros livres a serem ajustados é elevado.

### 3.6.5.1 Retropropagação do erro

Este algoritmo é composto por duas fases: a fase *forward*, na qual um padrão de dados é apresentado à rede e esta processa os dados, produzindo respostas, e a fase *backward*, que utiliza o erro obtido entre o resultado da execução forward e o resultado desejado (conhecido), para determinar os ajustes a serem feitos nos pesos das conexões sinápticas dos neurônios da rede. O algoritmo de retropropagação é apresentado a seguir:

Seja o sinal de erro na saída do neurônio  $k$ , na iteração  $n$ , definido pela Equação (3.14), onde,  $d_k(n)$  é a saída desejada e  $y_k(n)$  é a saída apresentada na saída do neurônio.

$$e_k(n) = d_k(n) - y_k(n) \quad (3.14)$$

A função de custo  $\varepsilon$  é a energia total do erro, obtida somando o quadrado dos erros de todos os neurônios da camada de saída, Equação (3.15).

$$\varepsilon(n) = \frac{1}{2} \sum_{k=1}^m e_k^2(n) \quad (3.15)$$

onde  $m$  é o número de neurônios da camada de saída da rede e  $e_k$  é o erro do neurônio  $k$ , na iteração  $n$ .

O cálculo dos deltas para a correção dos pesos depende da posição da camada. Considere o neurônio da camada de saída  $k$ , sendo estimulado por um conjunto de ativações produzido por uma camada de neurônios à sua esquerda. A saída  $v(n)$  do neurônio  $k$  é, portanto:

$$v_k(n) = \sum_{j=0}^{m_2} w_{kj}(n) y_j(n) \quad (3.16)$$

Representando a Função de ativação  $y_k(n)$  que aparece na saída do neurônio  $k$  na iteração  $n$  é:

$$y_k(n) = \varphi_k(v_k(n)) \quad (3.17)$$

O algoritmo de retropropagação aplica uma correção  $\Delta w_{kj}$  ao peso sináptico  $w_{kj}$ , que é proporcional à derivada parcial  $\partial \varepsilon(n) / \partial w_{kj}(n)$ . De acordo com a regra da cadeia do cálculo, se expressa este gradiente como:

$$\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} = \frac{\partial \varepsilon(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial y_k(n)} \frac{\partial y_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial w_{kj}(n)} \quad (3.18)$$

Após manipulações algébricas obtém:

$$\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} = -e_k(n) \varphi_k'(v_k(n)) y_j(n) \quad (3.19)$$

A correção  $\Delta w_{kj}(n)$  aplicada a  $w_{kj}(n)$  é definida pela regra delta:

$$\Delta w_{kj}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} \quad (3.20)$$

onde  $\eta$  é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação. O uso do sinal negativo na Equação (3.19) indica a descida do gradiente no espaço de pesos, ou seja, busca uma direção para a mudança de peso que reduz o valor de  $\varepsilon(n)$ .

Finalmente, temos a atualização dos pesos realizada por:

$$w_{kj}(t+1) = w_{kj}(t) - \eta \frac{\partial \varepsilon}{\partial w_{kj}}(t) \quad (3.21)$$

onde  $w_{kj}$  é o valor do peso da conexão k do neurônio j a ser atualizado.

### 3.6.5.2 Algoritmo Resilient Propagation (Rprop)

O algoritmo Resilient Propagation desenvolvido em [30] apresenta um eficiente esquema de aprendizagem, tem uma adaptação direta do peso baseada na informação do gradiente local. A adaptação do Rprop não é interferida pelo comportamento da magnitude do gradiente da função erro.

No processo de otimização deste algoritmo cada peso será alterado individualmente através de um valor adaptativo  $\Delta_{ij}$ , conforme apresentado abaixo:

$$\Delta \omega_{ij}^{(t)} = \begin{cases} -\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial \omega_{ij}} > 0 \\ +\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial \omega_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (3.22)$$

A atualização dos pesos é realizada conforme Equação (3.23)

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \Delta \omega_{ij}^{(t)} \quad (3.23)$$

Pode ser observado que quando a derivada é positiva, o peso é diminuído do seu valor de atualização, caso contrário, o valor será adicionado.

Durante o processo de aprendizagem,  $\Delta_{ij}$  é baseado na função do erro de acordo com a seguinte regra de aprendizagem:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial \omega_{ij}} \frac{\partial E^{(t)}}{\partial \omega_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial \omega_{ij}} \frac{\partial E^{(t)}}{\partial \omega_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (3.24)$$

sendo:  $0 < \eta^- < 1 < \eta^+$

Quando a derivada parcial da função erro em relação ao peso  $w_{ij}$  muda de sinal indica que a última atualização foi muito grande, fazendo o erro da função ultrapassar o mínimo local, então o valor  $\Delta_{ij}$  é decrementado pelo fator  $\eta^- \Delta_{ij}$ . No caso da derivada manter seu sinal  $\Delta_{ij}$  permanecerá o mesmo com o objetivo de acelerar o processo de convergência.

Este algoritmo é definido como resiliente, devido a sua capacidade de restaurar o ponto de partida, caso a direção escolhida para atualizações do peso seja inadequada, isto é, a derivada do erro em relação ao peso foi positiva.

## CAPÍTULO 4

### 4 Procedimentos de Desenvolvimentos dos Modelos de Previsões

#### 4.1 Aquisição dos Dados

A série de velocidades utilizada no presente trabalho é constituída dos valores médios horários coletados, na central eólica de Olinda-PE, entre Dezembro de 1996 a Julho de 1998. A partir das características estatísticas desta série, analisada conforme estatística descrita na seção 3.2, verificou-se que esta é bastante oscilatória com valores variando de 0,27 m/s a 12,62 m/s, apresentando média e desvio padrão de 5.185 m/s e 1.77, respectivamente. Estas características tornam o problema de previsão de ventos e geração eólica de difícil ajuste.

A Figura 4.1 apresenta o correlograma da série de ventos utilizado neste trabalho. A partir dos coeficientes de autocorrelações entre os elementos da série dos ventos plotados neste correlograma, é possível identificar quais são os mais relevante. Quanto maior a autocorrelação dos coeficientes, maior sua relevância. Sendo assim, com base nesta Figura, pode-se esperar que os modelos de previsões com horizontes pequenos deverão ter um desempenho melhor que os modelos com horizontes longos. Visto que os coeficientes de autocorrelação decrescem com o aumento da janela de regressão (intervalo).




Figura 4.1 - Correlograma da Série de Velocidades

Observando ainda o correlograma da Figura 4.1, é observado que nas proximidades de vinte e quatro horas os coeficientes voltam a aumentar. Esta característica demonstra que existe uma sazonalidade, mesmo que pequena, durante os períodos do dia.

## 4.2 Processamento dos Dados

Nesta etapa são definidos os procedimentos básicos de processamentos dos dados da série de velocidades que serão realizados ao longo do trabalho para desenvolver os modelos de previsões.

### 4.2.1 Normalização

No desenvolvimento dos modelos de previsões de cada técnica, RNA e estatística, exigem um tratamento adequado dos dados para garantir o desempenho e a correta aplicação das mesmas. Em geral o tratamento mais simples e eficaz para os dados é a normalização.

No caso das RNA, a normalização é realizada para assegurar que todas as variáveis usadas nos modelos tenham igual atenção durante o treinamento. Os neurônios artificiais, geralmente, são compostos de funções de ativação que são limitadas. Assim, a normalização deve limitar os valores dos dados utilizados nos extremos das funções de ativação. Neste projeto os dados foram normalizados de acordo com Equação (4.1), apresentada em [31], que limita os valores no intervalo de [0.1, 0.9].

$$\bar{X}(t) = \frac{0,1 \cdot (X_{\max} - X(t)) - 0,9 \cdot (X_{\min} - X(t))}{X_{\max} - X_{\min}} \quad (4.1)$$

Nos modelos estatísticos desenvolvidos neste trabalho, a normalização dos dados tem a finalidade de tornar a série de trabalho em uma série estacionária, ou seja, média e variância constante ao longo do tempo. No algoritmo utilizado para desenvolver os modelos estatísticos, esta normalização é realizada pela Equação (4.2)

$$\bar{X}(t) = \log\left(\frac{X(t+1)}{X(t)}\right) \quad (4.2)$$

Nas equações de normalizações (4.1) e (4.2), as variáveis representam:

- $X$  - Série temporal
- $\bar{X}$  - Grandeza normalizada
- $X_{\max}$  - Maior valor absoluto da grandeza
- $X_{\min}$  - Menor valor absoluto da grandeza

#### 4.2.2 Análise de Multiresolução

A análise de multiresolução decompõe o sinal em escalas com diferentes resoluções em tempo e escala. Esta análise é realizada através do algoritmo piramidal, o qual torna o cálculo das TW eficientes. Este algoritmo possibilita obter “aproximações” e “detalhes” de um dado sinal de interesse.

Conforme visto anteriormente a série de velocidades de ventos é muito oscilatória, conseqüentemente, a mesma é de difícil aplicabilidade para o desenvolvimento de modelos de previsões, pois a extração de informações torna-se mais complicada com a variabilidade da série.

Para tentar mitigar os efeitos da variabilidade da série das velocidades, é proposta nesta dissertação uma análise de multiresolução via TW. Esta análise permitirá decompor a série original em vários níveis de aproximações e detalhes, que poderá facilitar os ajustes ou treinamentos dos modelos de previsão, conforme apresentado em [32].

Após testes preliminares de decomposição utilizando as wavelets de várias famílias para identificar a que melhor apresentava o sinal original da série, constatou-se que as TW da família *Daubechies* apresentou melhor desempenho. Uma vez definida a família da TW a ser utilizada foi realizado uma análise para definir até que nível de decomposição seria aplicado ao sinal. Nesta análise, concluiu-se que o sinal da série deveria ser decomposto até o terceiro nível, pois para níveis maiores os coeficientes de detalhes não apresentavam informações significativas.

#### 4.2.3 Conversão das previsões das velocidades em geração

Neste trabalho a turbina de referência selecionada foi a ENERCON E-58/10.58 conforme visto no Capítulo 2. Esta turbina é projetada para operar a uma altura de 70 m, sua curva de potência está representada na Figura 2.3.



No entanto a série de velocidade utilizada foi obtida a partir de medições a uma altura de 20m. Desta forma os padrões de entrada e saída utilizados para ajustar e ou treinar os modelos de previsões aqui desenvolvidos são referentes à altura de 20m. Logo estes realizam previsões de velocidades na mesma altura, 20 m, conforme será visto no capítulo subsequente.

Portanto, antes de aplicar a transformação para se obter as previsões da geração diretamente a partir da curva de potência, será necessário compatibilizar a altura para a altura de instalação da turbina. Esta compatibilização será realizada usando a Equação (2.9), fazendo o coeficiente  $\alpha$  igual a 0.30, conforme apresentado na Tabela 2.1.

### 4.3 Avaliação de Desempenho

O objetivo principal dos sistemas de previsões que serão criados é aprender a partir de amostras de valores conhecidos e generalizar para novos casos. Os desempenhos dos sistemas foram medidos durante os treinamentos pela porcentagem de erro médio quadrático (MSE), conforme em [40], expresso pela Equação (4.3).

$$MSE = 100 \frac{L_{\max} - L_{\min}}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N (L_{pi} - T_{pi})^2 \quad (4.3)$$

Durante as simulações (testes) dos modelos aqui desenvolvidos, os desempenhos serão medidos a partir de duas grandezas: a velocidade dos ventos e a potência gerada. As Equações (4.4) e (4.5) calcularão os erros cometidos ao se realizar as previsões das potências. Estas equações representam as relações entre a potência média gerada e erro médio absoluto ( $MAE_{avg}$ ) e a potência instalada e o erro médio absoluto ( $MAE_{cap}$ ).

$$MAE_{AVG} = \frac{1}{N \cdot P \cdot Pot_{\text{média}}} \sum_{p=1}^P \sum_{i=1}^N |L_{pi} - T_{pi}| \times 100 \quad (4.4)$$

$$MAE_{CAP} = \frac{1}{N \cdot P \cdot Cap} \sum_{p=1}^P \sum_{i=1}^N |L_{pi} - T_{pi}| \times 100 \quad (4.5)$$

Já o erro sobre as previsões de velocidades é calculado através da Equação (4.6). Esta calcula o erro médio absoluto percentual (MAPE).

$$MAPE(\%) = \frac{1}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N \frac{|L_{pi} - T_{pi}|}{T_{pi}} \times 100 \quad (4.6)$$

Nas Equações (4.3), (4.4), (4.5) e (4.6), as variáveis representam:

- $N$  Número de neurônios de saída;
- $P$  Números de padrões;
- $L_{max}$  Valor máximo da grandeza de saída;
- $L_{min}$  Valor mínimo da grandeza de saída;
- $L$  Valor da grandeza obtida pelo modelo;
- $T$  Valor alvo da grandeza;
- $Cap$  Capacidade instalada da turbina eólica;
- $Pot_{media}$  Potência média gerada.

## 4.4 Treinamento e ajuste dos modelos

Os treinamentos ou ajustes dos modelos de previsões propostos neste trabalho estão divididos, basicamente, em dois grupos: os treinamentos dos modelos inteligentes e os ajustes dos modelos estatísticos.

### 4.4.1 Treinamentos dos modelos inteligentes

As redes neurais aprendem a partir de exemplos e são projetadas para serem capazes de generalizar o conhecimento adquirido durante os treinamentos. Uma estratégia adequada utilizada no poder de generalização da rede que influencia substancialmente seu desempenho é descrita de forma simplificada a seguir.

#### 4.4.1.1 Partição da base de dados

A base de dados do trabalho foi dividida em três conjuntos distintos, são eles:

- **Conjunto Treinamento:** O conjunto de treinamento deve ser constituído pela maior parte dos dados, pois é a partir deste conjunto que os pesos dos neurônios

serão ajustados durante os treinamentos com objetivo de passar o conhecimento para as redes. Neste trabalho este conjunto é constituído de 60% da base de dados.

- **Conjunto de Validação:** Este conjunto é usado paralelamente com o conjunto de treinamento. Entretanto, o mesmo não é usado para ajustes dos pesos, mais sim para verificar a capacidade de generalização da rede neural durante o treinamento. Logo este conjunto é utilizado como critério de parada do treinamento, conforme será descrito. Aqui, este detém 30% da base de dados.
- **Conjunto de Teste:** Assim como o conjunto de validação, este conjunto não é utilizado para ajustes dos pesos durante o treinamento, ele só é apresentado à rede para estimar o desempenho das mesmas quando estas estiverem em operação. Este é constituído do restante da base de dados, ou seja, 10%.

#### 4.4.1.2 Algoritmo de treinamento

Os treinamentos realizados no desenvolvimento dos modelos inteligentes aqui desenvolvidos têm o objetivo de aumentar a capacidade de generalização das RNA. Para isto foi escolhido o algoritmo Rprop, desenvolvido em [30] e descrito no CAPÍTULO 3. Todas as redes foram treinadas utilizando o Matlab® 7.0.019920 (R14), com os seguintes parâmetros:

- Número máximo de épocas: 2500;
- Taxa de aprendizado: 0,01;
- Incremento para alteração dos pesos ( $\eta^+$ ): 1,2;
- Decremento para alteração dos pesos ( $\eta^-$ ): 0,5;
- Valor inicial para alteração dos pesos ( $\Delta_o$ , delta0): 0,07;
- Valor máximo para alteração dos pesos ( $\Delta_{\max}$ ): 50,0.

O algoritmo Rprop foi selecionado devido sua eficiência e rapidez, já comprovada em outras aplicações [33, 34, 35]. A eficiência e a rapidez são muito importantes nos desenvolvimentos dos modelos inteligentes de previsões aqui propostos, pois os critérios de ajustes e seleções destes modelos envolvem vários treinamentos e testes, conforme será descrito posteriormente.

#### 4.4.1.3 Critérios de parada

Em geral, não se pode demonstrar que o algoritmo de treinamento convergiu e não existem critérios bem definidos para encerrar a sua operação. Em vez disso, há vários métodos particulares, cada um com o seu mérito que podem ser usados para finalizar os treinamentos das redes neurais.

Todos os critérios de parada tem objetivo de evitar sobre-ajustes (*overfitting*) dos pesos e bias para o conjunto de treinamento, em outras palavras, para evitar que as redes percam a capacidade de generalizar os resultados para dados distintos dos utilizados durante os treinamentos. Para isto, foram adotados os seguintes critérios de parada de treinamentos:

- **Número de épocas:** Este critério de parada de treinamento estipula um número máximo de épocas que pode ser realizadas para treinamento. Neste trabalho, o número de épocas de treinamento ficou limitado a 2500 épocas. Uma época é definida como sendo a unidade que representa o número de vezes que todos os dados do conjunto de treinamento são utilizados para ajustes dos parâmetros livres da rede durante o treinamento.
- **Parada antecipada (*Early Stopping*):** Esta técnica é embasada no monitoramento do erro do conjunto de validação durante a etapa de treinamento. Na fase inicial do treinamento o erro do conjunto de validação segue a mesma tendência do erro do conjunto de treinamento, isto é, o erro vai decaindo a cada época de treinamento. No entanto, quando começa a ocorrer sobre-ajuste dos parâmetros livres da rede, o erro do conjunto de treinamento ainda continua a cair, mas o erro do conjunto de validação passa a aumentar. Desta forma, o critério de parada antecipada é implementado de tal forma que permita que erro do conjunto de validação aumente durante um número específico de épocas seguintes. Neste trabalho este número é 20, o que possibilita verificar a tendência de crescimento do erro do conjunto de validação para finalizar o treinamento. Uma vez finalizado o treinamento por este critério, os pesos e bias da rede são atualizados para condição de mínimo erro encontrado sobre o conjunto de validação durante o treinamento.
- **Desempenho mínimo de treinamento:** Neste critério, a parada do treinamento é determinada quando erro sobre o conjunto de treinamento atingir o limite de erro especificado. Neste trabalho o limite adotado foi do erro médio quadrado (MSE)

igual à zero. Este valor foi escolhido para permitir que as redes treinem o máximo possível, desde que não infrinja os outros dois critérios.

Estes critérios são utilizados simultaneamente durante os treinamentos. Devendo o treinamento ser encerrado caso qualquer um dos critérios seja atingido.

#### **4.4.1.4 Seleção de arquitetura**

No projeto de RNA existe uma dependência entre o número de padrões usados no conjunto de treinamento, a dificuldade do problema a ser tratado, o número de parâmetros livres (pesos e bias) e o processo de aprendizagem, conforme [22, 24]. No entanto, não existe nenhuma regra determinística que relacione estas variáveis, apesar de alguns pesquisadores citarem certas regras práticas. Neste trabalho estas variáveis são restringidas ao número de parâmetros livres, ou melhor, a arquitetura da RNA, pois o número de padrões de treinamento está limitado pelo tamanho da base de dados, já a dificuldade do problema é inerente à aplicação.

Desta forma, para se selecionar a arquitetura da RNA foi adotado a regra utilizada nos trabalhos [33, 38, 39]. Estes, estabelecem que as arquiteturas são definidas mediante a variação do número de neurônios na camada escondida, sendo selecionada a que apresentar o melhor desempenho durante os treinamentos.

No desenvolvimento dos modelos neurais aqui adotados, para cada rede com número de neurônios ocultos, determinado entre a faixa de variação de seleção, as redes são inicializadas dez vezes com pesos aleatórios. No final de cada processo de dez inicializações é anotado o erro médio MSE de validação. Este erro é utilizado como balizador na definição da arquitetura, pois a arquitetura selecionada deverá ser a que apresentar o menor erro médio MSE.

#### **4.4.1.5 Validação cruzada múltipla**

Nesta etapa já foi determinado o número de neurônios na camada oculta o que nos dá a arquitetura final da rede, porém falta ainda descobrir uma rede que seja a melhor para resolver o problema abordado. Buscando este objetivo este trabalho aplica a técnica de validação cruzada múltipla.

O método de validação cruzada também conhecido como *k-fold cross-validation*, onde  $k$  representa o número de partições geradas aleatoriamente a partir da amostra de exemplos para treinar, testar e validar as redes. Nesse método as amostras são divididas em

$k$  partições mutuamente exclusivas. A cada iteração uma partição diferente é utilizada para testar o sistema e todas as outras  $k - 1$  partições são utilizadas para treinar e validar o treinamento das redes.

O método de validação cruzada aplicado neste trabalho está representado na Tabela 4.1. Esta tabela descreve a formação dos conjuntos de treinamento, validação e teste, bem como identifica as redes, ou seja, a inicialização de cada experimento, que utilizaram os respectivos conjuntos.

Espera-se com aplicação da técnica de validação cruzada que os valores médios de MSE e MAPE, obtidos em cada experimento no conjunto de teste, sejam considerados como o resultado esperado para redes MLP conforme [22, 33, 34].

**Tabela 4.1-** Experimento utilizados no método de validação cruzada.

Exp.	Rede	Treinamento	Validação	Teste
1	De 1 a 10	5, 6, 7, 8, 9, 10	2, 3, 4	1
2	De 11 a 20	1, 6, 7, 8, 9, 10	3, 4, 5	2
3	De 21 a 30	1, 2, 7, 8, 9, 10	4, 5, 6,	3
4	De 31 a 40	1, 2, 3, 8, 9, 10	5, 6, 7	4
5	De 41 a 50	1, 2, 3, 4, 9, 10	6, 7, 8	5
6	De 51 a 60	1, 2, 3, 4, 5, 10	7, 8, 9	6
7	De 61 a 70	1, 2, 3, 4, 5, 6	8, 9, 10	7
8	De 71 a 80	2, 3, 4, 5, 6, 7	9, 10, 1	8
9	De 81 a 90	3, 4, 5, 6, 7, 8	1, 2, 10	9
10	De 91 a 100	4, 5, 6, 7, 8, 9	1, 2, 3	10

#### 4.4.2 Ajustes dos modelos estatísticos

Apesar dos modelos estatísticos de previsões ajustarem seus parâmetros através de regras matemáticas bem definidas, não existe nenhuma regra determinística que determine a melhor ordem para os modelos. Desta forma, neste tópico, são descritas as técnicas utilizadas nos desenvolvimentos dos modelos estatísticos, com a finalidade de melhorar o desempenho dos mesmos.

##### 4.4.2.1 Partição da base de dados

A base de dados do trabalho foi dividida em dois conjuntos distintos, são eles:

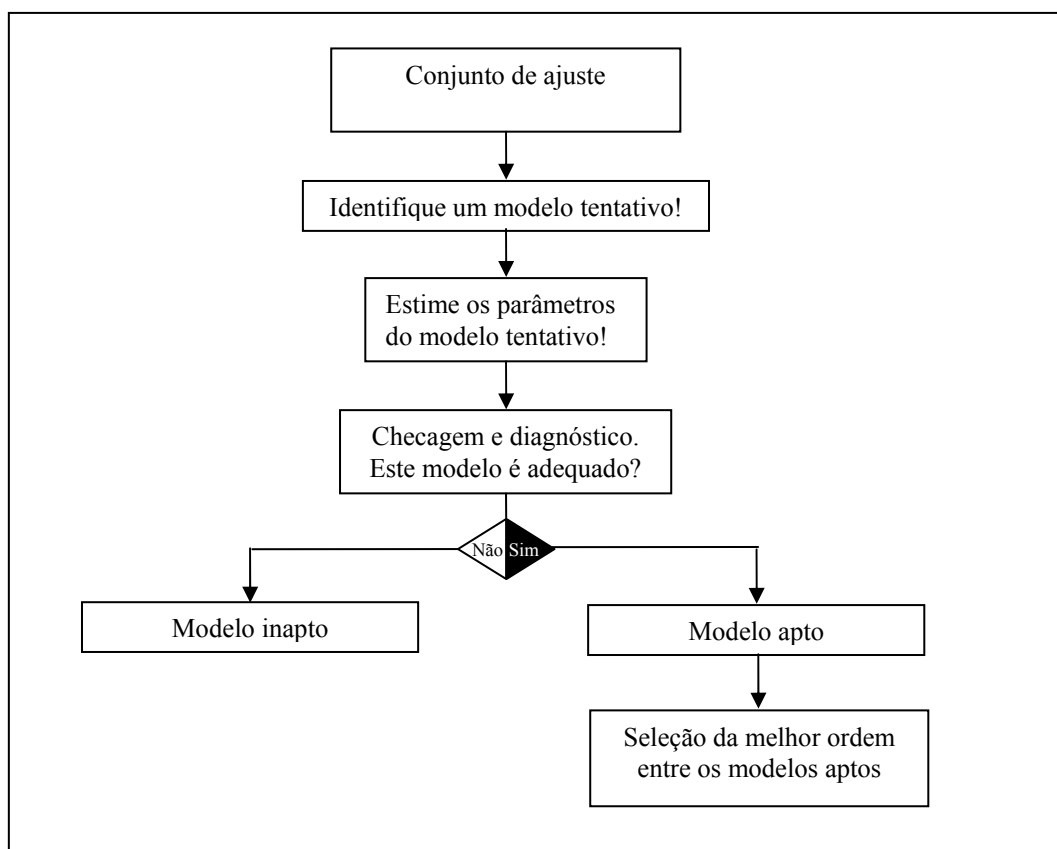
- **Conjunto de ajuste:** Como o próprio nome já sugere, este conjunto é utilizado para ajustar os parâmetros e coeficientes dos modelos. Os ajustes destes modelos são realizados mediante regras de otimização, que tem como objetivo minimizar o erro encontrado para o conjunto de ajuste.

- **Conjunto de teste:** Este conjunto tem a mesma finalidade do conjunto de teste dos modelos inteligentes, ou seja, este é utilizado para se estimar o erro do modelo estatístico quando ele estiver realizando previsões de dados inéditos aos utilizados no conjunto de ajustes.

#### 4.4.2.2 Seleção das ordens dos modelos

O modelo estatístico utilizado para originar alguns dos modelos de previsões desenvolvidos neste trabalho foi o ARMA. Para este modelo é necessário especificar duas ordens: a ordem do modelo responsável pela parte auto-regressiva ( $p$ ) e a ordem responsável pela parte média móvel ( $q$ ). Estas ordens serão selecionadas basicamente através de um processo semelhante de seleção de arquitetura dos modelos neurais.

Elas são determinadas mediante a criação de vários modelos de ordens diferentes (modelos tentativos), sendo escolhido aquele que obtiver melhor desempenho sobre o conjunto de teste e seja mais estável, isto é, menos tendencioso.



**Figura 4.2** - Fluxograma do desenvolvimento dos modelos estatísticos.

O critério de seleção das ordens segue as fases do fluxograma apresentado na Figura 4.2. Na fase inicial é apresentado o conjunto de ajuste; em seguida são estimadas as

ordens do modelo para compor um modelo tentativo; posteriormente este modelo ajusta seus parâmetros; depois o modelo passa pelo processo de diagnóstico através de uma análise estatística obtida em cima dos resultados encontrados para o conjunto de teste; passando no teste a ordem proposta torna-se apta a compor o modelo final, esperando apenas os resultados das demais ordens a serem propostas; no final do processo será selecionada, dentre os modelos aptos, a ordem que obtiver melhor desempenho aferido em cima do conjunto de teste.

Os modelos são considerados aptos, quando os resultados dos testes são não tendenciosos. Aqui, neste trabalho o critério para indicar se o modelo é apto ou não será realizado através de uma análise do histograma dos erros de cada modelo tentativo criado.



## CAPÍTULO 5

### 5 Resultados dos Modelos de Previsões

Neste trabalho foram desenvolvidos vários modelos de previsões de ventos e geração eólica com técnicas de inteligência artificiais e métodos estatísticos para horizonte de até vinte quatro horas. As previsões da geração são obtidas a partir da transformação das velocidades dos ventos previstas pelos modelos desenvolvidos conforme metodologia descrita no capítulo anterior.

Os modelos desenvolvidos a partir de técnicas de inteligência artificial, também chamado aqui de modelos inteligentes, dão origem a modelos que usam técnicas de redes neurais e modelos combinados que utilizam análise de multiresolução e redes neurais. Já os modelos estatísticos foram desenvolvidos com base no método auto-regressivo médio móvel, ARMA, descrito na seção 3.3.2.

Do ponto de vista dos horizontes de previsões, os modelos aqui desenvolvidos, são constituídos de dois grupos: o primeiro, realiza previsões com horizonte de até quatro horas; enquanto o segundo, foi desenvolvido para realizar previsões de até vinte e quatro horas.

O objetivo de avaliar e desenvolver várias técnicas para modelar o problema de previsão aqui proposto é identificar o melhor ajuste e a melhor técnica de abordagem para o problema.

Estes modelos foram avaliados com base na medida dos erros encontrados durante a fase de testes. Estes foram calculados para um conjunto de teste totalmente distinto daqueles usados durante a etapa de ajuste ou treinamentos dos modelos criados.

#### 5.1 Modelos Inteligentes com Horizonte de até Quatro Horas.

Os modelos desenvolvidos para este horizonte fornecem as previsões da velocidade média horária e da potência, no horizonte de até quatro horas. Isto é, as previsões das velocidades e potências nos instantes  $t + 1$ ,  $t + 2$ ,  $t + 3$  e  $t + 4$ .

Este modelo foi desenvolvido a partir das redes do tipo *Multi Layer Perceptron*, com três camadas: camada de entrada; camada oculta, a qual usa a função de ativação *tansig*; e a camada de saída que usa a função de ativação *logsig*. O algoritmo de treinamento usado foi o *Rprop*, descrito no Capítulo 3.

As entradas para os modelos deste horizonte foram modeladas de duas maneiras distintas, dando origem a dois modelos inteligentes de classificação.

O primeiro modelo deste horizonte possui quatro entradas, as quais correspondem às quatro horas de velocidades médias que antecedem a previsão. Já o segundo modelo, utiliza uma análise de *multiresolução* a partir de *Transformada Wavelet* (TW), a qual permite modelar as entradas através de coeficientes de aproximações e de detalhes até o terceiro nível de decomposição das *wavelets*, segundo visto no Capítulo 4.

Ambos os modelos tiveram seus desempenhos avaliadas para o conjunto de teste, a fim de identificar o erro esperado para aplicação destes quando em operação. O conjunto de teste foi constituído de 297 padrões aleatórios de entrada-saída (10 % da base de dados). Além disso, como os conjuntos são aleatórios, eles são distintos nos dois modelos.

Já os conjuntos de treinamentos e validação são constituídos de 1782 e 891 padrões aleatórios de entrada-saída, respectivamente. Ou seja, o equivalente a 60 % da base de dados para treinamento e 20 % para validação, conforme descrito na seção 4.2.5.1.

### 5.1.1 Modelo Neural

Os padrões de entrada e saída utilizados neste modelo são constituídos de quatro entradas que antecedem o horizonte de previsão, e de quatro saídas que representam as previsões nos tempos  $t + 1$ ,  $t + 2$ ,  $t + 3$  e  $t + 4$ , conforme ilustrado na Figura 5.1.

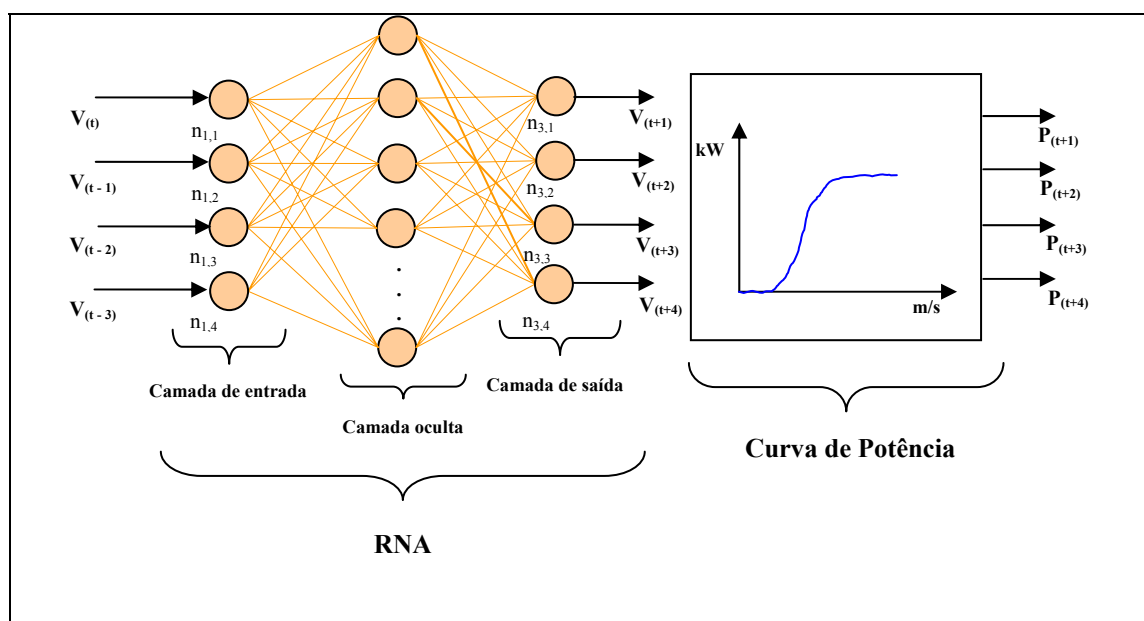


Figura 5.1 - Modelo neural de previsão com horizontes de até quatro horas.

O número de neurônios na camada oculta, que melhor se adapta aos conjuntos de dados, foi selecionado através do treinamento de dezesseis arquiteturas distintas, as quais possuíam de cinco a vinte neurônios ocultos. Além disso, cada uma destas arquiteturas foi treinada dez vezes com inicializações de pesos aleatórias, como descrito anteriormente.

A Tabela 5.1 apresenta os erros médios quadráticos nos conjuntos de treinamento, validação e teste calculados nas dez inicializações de cada arquitetura, treinadas segundo determinado pelo processo de seleção de arquitetura. A partir desta Tabela, verifica-se que a arquitetura com quatorze nodos ocultos obteve menor erro sobre o conjunto de validação durante os treinamentos, com MSE igual a 0.6839 %. Portanto, a arquitetura selecionada ficou com quatro entradas, quatorze neurônios ocultos e quatro saídas.

**Tabela 5.1** - Seleção da arquitetura do modelo neural de até quatro horas.

<b>Seleção Arquitetura</b>			
<b>Nodos ocultos</b>	<b>MSE(%) treinamento</b>	<b>MSE(%) validação</b>	<b>MSE(%) Teste</b>
5	0.6929	0.7068	0.6643
6	0.7088	0.7202	0.6752
7	0.6881	0.6998	0.6598
8	0.6826	0.7009	0.6576
9	0.6756	0.6934	0.655
10	0.6748	0.6931	0.6555
11	0.688	0.708	0.6601
12	0.673	0.6958	0.6522
13	0.6804	0.7013	0.654
14	0.6655	0.6839	0.6459
15	0.6621	0.6864	0.6485
16	0.6654	0.6911	0.6504
17	0.6618	0.6879	0.6457
18	0.6637	0.6916	0.6513
19	0.6571	0.6846	0.6415
20	0.6597	0.6877	0.6501

Após determinado a arquitetura da RNA para este modelo, foram realizados dez experimentos baseados no processo de validação cruzada múltipla. Este procedimento tem a finalidade de melhor distribuir os dados sobre os conjuntos de treinamento, validação e teste conforme [22].

Os resultados médios destes experimentos encontram-se na Tabela 5.2, onde se verifica que o desempenho do 8º experimento foi o melhor, de acordo com o critério descrito no capítulo anterior.

Tabela 5.2 - Validação cruzada para o modelo neural com horizonte de até quatro horas.

Validação cruzada múltipla						
Experimento	Treinamento		Validação		Teste	
	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)
1	0.662	0.892	0.685	0.900	0.642	0.887
2	0.655	0.885	0.668	0.885	0.700	0.934
3	0.663	0.894	0.665	0.894	0.665	0.860
4	0.659	0.887	0.680	0.903	0.680	0.905
5	0.666	0.889	0.639	0.875	0.667	0.898
6	0.677	0.906	0.662	0.885	0.653	0.887
7	0.657	0.893	0.683	0.897	0.700	0.921
8	0.659	0.889	0.684	0.901	0.591	0.837
9	0.646	0.878	0.698	0.923	0.679	0.888
10	0.658	0.891	0.682	0.906	0.772	0.963

No experimento 8, que obteve MSE médio sobre o conjunto de teste igual a 0.591%, a melhor rede ajustada forneceu MAPE igual 24.0650 % para o teste. Os resultados dos testes para esta rede podem ser mais bem avaliados através do gráfico da Figura 5.2.

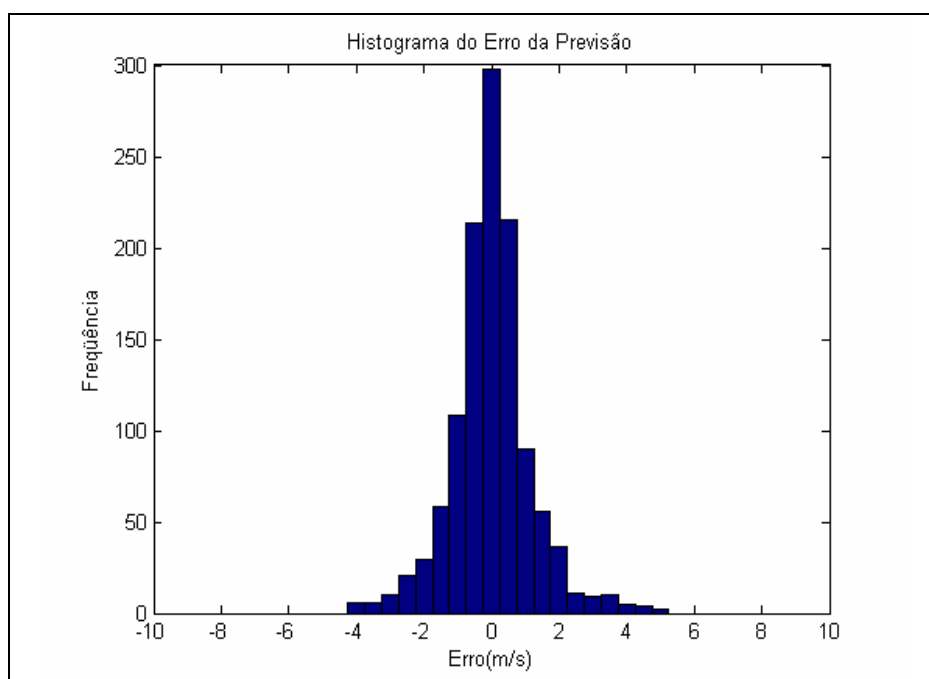
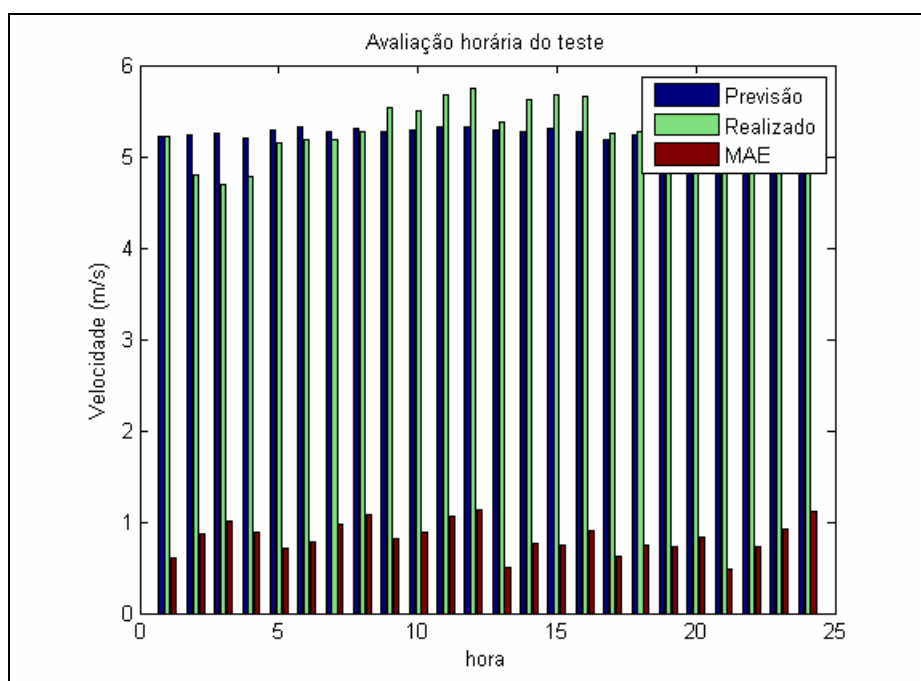


Figura 5.2 - Histograma do erro de teste para o modelo neural com horizonte de até quatro horas.

O gráfico da Figura 5.2 apresenta o desempenho do modelo neural para previsão das velocidades dos ventos com horizonte de até quatro horas. Através deste, observa-se que boa parte dos erros cometidos encontra-se próximo à zero. Além disso, observa-se que o modelo ajustado não é tendencioso, isto é, o erro médio durante os testes é quase zero.

O gráfico da Figura 5.3 apresenta as velocidades médias horárias previstas e realizadas dos dados utilizados para o conjunto de teste; mas também, os erros médios absolutos horários (MAE) para o conjunto de teste.

O erro médio absoluto horário (MAE) obtido com este modelo foi 0.8365 m/s para a altura de 20m. Quando se analisa o gráfico da Figura 5.3, verifica-se ainda que o maior erro médio absoluto horário - MAE cometido foi de 1.128 m/s na hora 12; enquanto o menor, foi de 0.4816 m/s, este na hora 21.



**Figura 5.3** - Avaliação horária do teste para o modelo neural com horizonte de até quatro horas.

Compatibilizando os valores das velocidades previstas para altura de referência da turbina, conforme descrito no CAPÍTULO 2, é possível estimar o erro da geração eólica, calculando-se os erros médios absolutos da capacidade ( $MAE_{CAP}$ ) e da potência média gerada ( $MAE_{AVG}$ ), através das Equações (4.5) e (4.4), respectivamente. Do ponto de vista da geração, este modelo obteve os seguintes resultados:

- $MAE_{CAP}$  12.6906 (%)
- $MAE_{AVG}$  33.7586 (%)

### 5.1.2 Modelo Neural com Análise de Multiresolução Através da Transformada Wavelet.

No desenvolvimento deste modelo, foi utilizada a rede do tipo MLP de uma única camada oculta, exatamente como no modelo anterior. Entretanto, os dados de entradas foram tratados de maneira diferenciada, a partir de uma análise de multiresolução, usando Transformadas wavelets.

Esta análise possibilita transmitir as informações de maneira separada através de coeficientes de aproximações e detalhes. Este modelo usa a wavelet da família *daubechies db1* até o terceiro nível de decomposição, para realizar a análise de multiresolução dos dados de ventos.

A análise de multiresolução implica no aumento dos números de entradas das redes neurais em relação ao modelo anterior, já que as entradas serão os coeficientes de aproximação e detalhes.

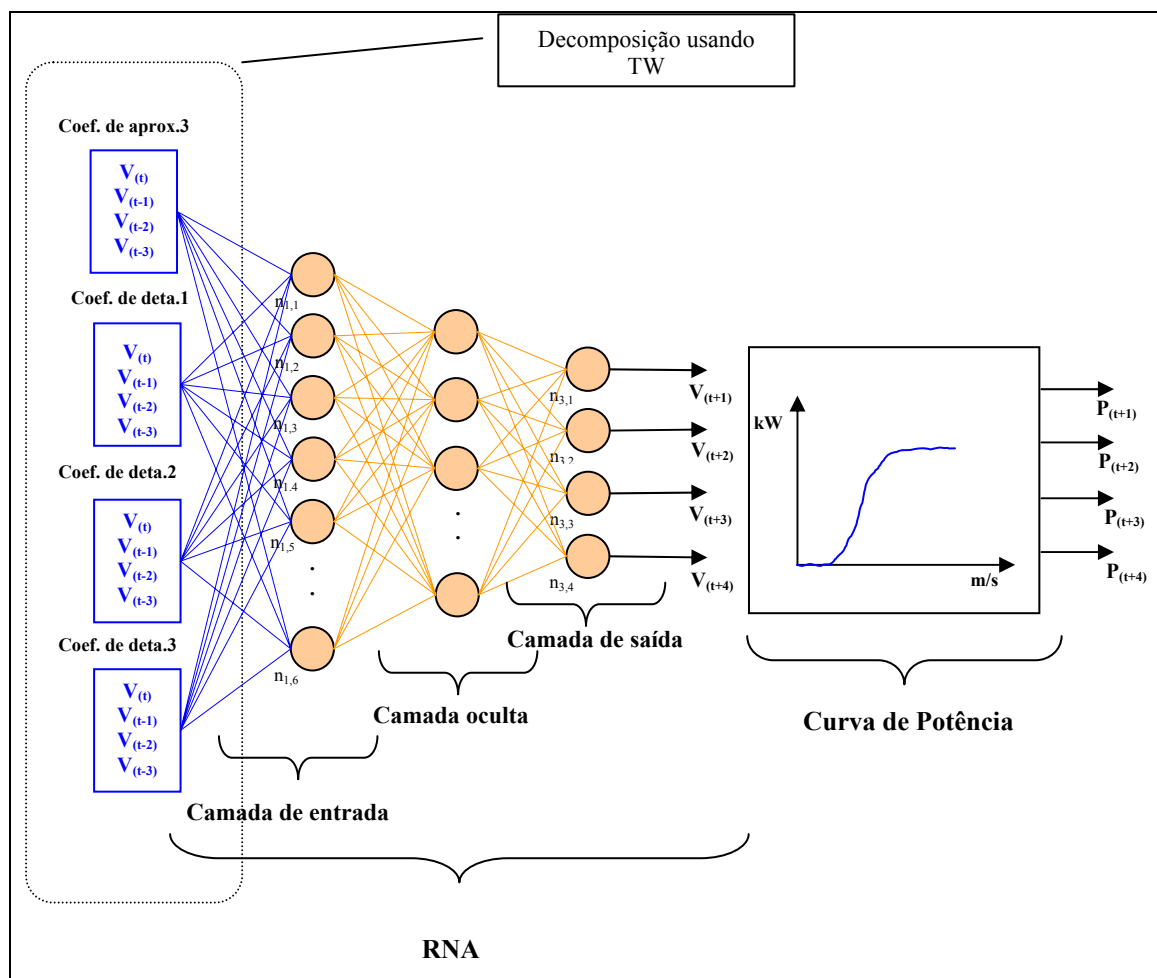


Figura 5.4 - Modelo neural com análise de multiresolução com horizontes de até quatro horas.

Sendo assim, os padrões de entrada deste modelo são configurados a partir de dezesseis entradas, ou seja, cada velocidade nos instantes de tempo  $t$ ,  $t-1$ ,  $t-2$  e  $t-3$ , que antecedem a previsão, são representadas pelo sinal de aproximação do terceiro nível e pelos sinais de detalhes do primeiro, segundo e terceiro nível de decomposição, conforme apresentado Figura 5.4.

O número de neurônios na camada oculta foi determinado através de vários treinamentos de arquiteturas diferentes, similar ao modelo anterior. A Tabela 5.3 apresenta os erros médios quadráticos dos conjuntos de treinamento, validação e teste, das dez inicializações de cada arquitetura, treinadas conforme determinado pelo processo de seleção de arquitetura. A partir desta Tabela, verifica-se que a arquitetura com dezenove nodos ocultos obteve menor erro sobre o conjunto de validação durante os treinamentos, com MSE igual a 0.5819%. Portanto a arquitetura selecionada ficou com dezesseis entradas, dezenove neurônios ocultos e quatro saídas.

**Tabela 5.3** - Seleção da arquitetura do modelo neural com análise de multiresolução de até quatro horas.

<b>Seleção Arquitetura</b>			
<b>Nodos ocultos</b>	<b>MSE treinamento</b>	<b>MSE validação</b>	<b>MSE teste</b>
5	0.5664	0.5874	0.5025
6	0.5667	0.589	0.5045
7	0.5627	0.5855	0.506
8	0.562	0.5861	0.5008
9	0.5611	0.5835	0.5024
10	0.5613	0.5862	0.4986
11	0.5558	0.5821	0.4939
12	0.559	0.5871	0.5019
13	0.5553	0.5834	0.4964
14	0.5565	0.5873	0.4976
15	0.5508	0.5847	0.4924
16	0.5517	0.5858	0.4932
17	0.5545	0.5861	0.4996
18	0.5513	0.5872	0.4993
19	0.5487	0.5819	0.492
20	0.5478	0.5844	0.4962

Após determinado a arquitetura da RNA, foram realizados também dez experimentos baseados no processo de validação cruzada múltipla. Os resultados destes experimentos estão apresentados na Tabela 5.4. Nesta Tabela, pode-se observar através do erro MSE do conjunto de teste, que o experimento 1 foi o mais consistente, isto é, menor erro médio MSE das dez redes criadas durante o processo de validação cruzada.

Tabela 5.4 - Validação cruzada para o modelo neural com análise de multiresolução de até quatro horas

Validação cruzada múltipla						
Experimento	Treinamento		Validação		Teste	
	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)
1	0.553	0.799	0.589	0.830	0.506	0.769
2	0.533	0.784	0.599	0.831	0.552	0.798
3	0.527	0.782	0.614	0.846	0.590	0.829
4	0.533	0.784	0.567	0.806	0.620	0.860
5	0.551	0.798	0.554	0.804	0.588	0.818
6	0.551	0.802	0.543	0.786	0.624	0.853
7	0.557	0.807	0.574	0.805	0.508	0.767
8	0.561	0.812	0.565	0.797	0.568	0.821
9	0.559	0.809	0.551	0.794	0.566	0.781
10	0.556	0.802	0.557	0.801	0.607	0.829

No experimento 1, a melhor rede ajustada forneceu MAPE igual 21.515% para o conjunto de teste. Os resultados desta rede podem ser mais bem avaliados através do histograma da Figura 5.5.


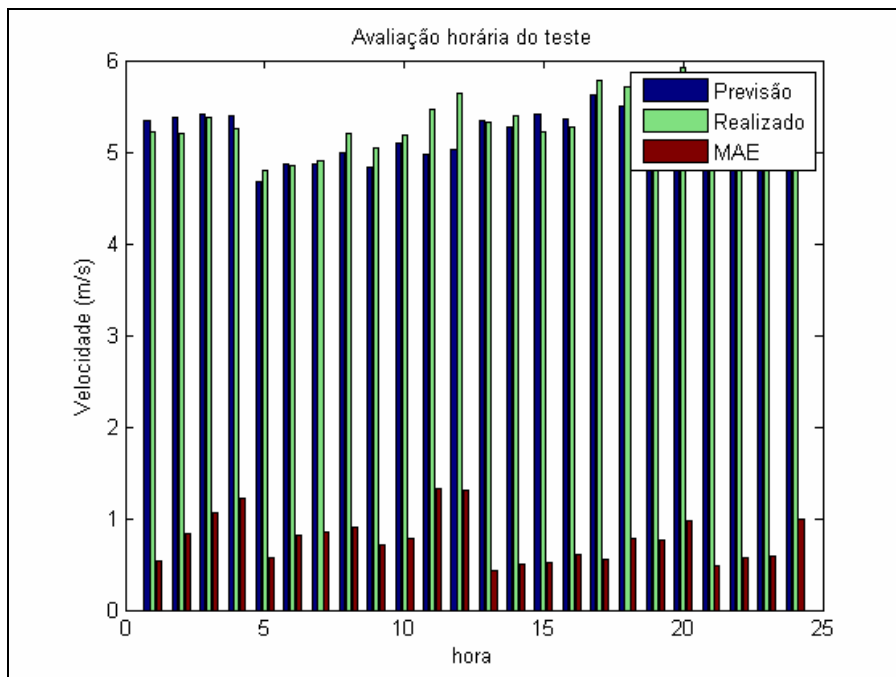


Figura 5.5 - Histograma do erro de teste para o modelo neural com análise de multiresolução com horizonte de até quatro horas.

No Gráfico da Figura 5.5, que apresenta o desempenho deste modelo, observa-se que boa parte dos erros cometidos encontra-se próximos à zero.





**Figura 5.6** - Avaliação horária do teste para o modelo neural com análise de multiresolução de horizonte de até quatro horas.

Além disso, através do gráfico da Figura 5.6 que apresenta as velocidades médias horárias previstas e realizadas dos dados utilizados no conjunto de teste e os erros médios absolutos horários (MAE) cometidos durante o teste, foi observado que o maior erro médio absoluto horário foi de 1.3310 m/s na hora 11; já o menor, foi de 0.4237 m/s, este na hora 13. Quanto ao erro médio absoluto (MAE) para todo conjunto de teste, foi igual a 0.7658 m/s.

Compatibilizando os valores das velocidades previstas para altura de referência da turbina foi possível estimar o erro da geração eólica. Calculando-se os erros médios absolutos da capacidade ( $MAE_{CAP}$ ) e da potência média gerada ( $MAE_{AVG}$ ), através das Equações (4.5) e (4.4), respectivamente. Sendo assim, do ponto de vista da geração este modelo obteve os seguintes resultados:

- $MAE_{CAP}$  11.3543 (%)
- $MAE_{AVG}$  29.5753 (%)

## 5.2 Modelos Inteligentes de Previsões com Horizonte de até Vinte Quatro Horas.

Todos os modelos desenvolvidos nesta seção usam rede do tipo *Multi-Layer Perceptron* com três camadas: camada de entrada; camada oculta, a qual usa a função de ativação *tangente hiperbólica*; e a camada de saída, que usa a função de ativação *sigmóide logística*. Assim como os modelos para o horizonte de quatro horas, no horizonte de 24 horas as redes MLP foram treinadas usando o algoritmo de treinamento *Rprop*.

Para este horizonte de previsão, foram desenvolvidos três modelos de previsões, de modo a identificar ou extrair a melhor maneira de modelar este problema de previsão.

O primeiro modelo possui vinte quatro entradas, as quais correspondem às vinte quatro horas das velocidades médias que antecedem a previsão. O segundo modelo utiliza uma análise de *multiresolução* a partir de *Transformada Wavelet*, de forma similar ao segundo modelo do horizonte de até quatro horas. Já o terceiro modelo tenta realizar as previsões usando redes especialistas através de três redes MLP, onde cada uma é responsável pela previsão de uma determinada faixa de tempo do dia.

Os três modelos tiveram seus desempenhos avaliados para o conjunto de teste, a fim de identificar o erro esperado na aplicação destes quando em operação. O conjunto de teste foi constituído de 49 padrões diários (10 % da base de dados) aleatórios. Além disso, como os conjuntos são aleatórios, eles são distintos nos três modelos.

Já os conjuntos de treinamentos e validação, são constituídos de 294 e 147 padrões diários aleatórios de entrada-saída, respectivamente. Ou seja, o equivalente a 60 % da base de dados para treinamento e 20 % para validação, conforme descrito na seção 4.2.5.1.

### 5.2.1 Modelo Neural

Os padrões de entrada-saída deste modelo estão organizados a partir dos valores médios horários das velocidades dos ventos que antecede o dia de previsão e do dia a ser previsto. Isto é, vinte quatro entradas, que fornecem informação do dia anterior a ser previsto, e vinte quatro saídas, que representa a previsão horária.

A configuração deste modelo é similar à configuração do modelo neural com horizonte de quatro horas segundo apresentado na Figura 5.1, diferindo apenas no número de entradas e saídas, já que neste são vinte e quatro.

Como este modelo foi desenvolvido através de redes MLP, se fez necessário encontrar a arquitetura que melhor se adapta aos dados. Desta forma, foram testadas

algumas redes variando o número de neurônios na camada escondida conforme descrito anteriormente.

**Tabela 5.5** - Seleção arquitetura do modelo neural de até vinte e quatro horas

<b>Seleção Arquitetura</b>			
<b>Nodos ocultos</b>	<b>Mse treinamento</b>	<b>Mse validação</b>	<b>Mse teste</b>
10	1.0206	1.208	1.0198
11	1.0193	1.1972	1.0119
12	1.0107	1.199	1.004
13	1.0026	1.2062	0.9991
14	1.0057	1.1954	1.0167
15	1.0032	1.1907	1.0009
16	0.989	1.207	1.0169
17	0.9868	1.199	1.0149
18	0.9924	1.2092	1.0209
19	0.9839	1.1986	1.0136
20	0.9778	1.1932	1.0129
21	0.9741	1.1969	1.0245
22	0.9769	1.2071	1.0356
23	0.9907	1.2097	1.0219
24	0.9758	1.2115	1.0166
25	0.9536	1.1997	1.0276
26	0.9515	1.1849	1.0242
27	0.9646	1.2029	1.0211
28	0.9508	1.2004	1.0286
29	0.9559	1.2082	1.0249
30	0.9608	1.2128	1.0326

A Tabela 5.5 apresenta os erros médios quadráticos dos conjuntos de treinamento, validação e teste das dez inicializações de cada arquitetura treinadas conforme determinado pelo processo de seleção de arquitetura. A partir desta Tabela verifica-se que a arquitetura com vinte seis nodos ocultos obteve menor erro no conjunto de validação durante os treinamentos, com MSE igual 1.1849 %. Portanto, a arquitetura selecionada ficou com vinte e quatro entradas, vinte e seis neurônios ocultos e vinte e quatro saídas.

Para esta arquitetura foram montados dez experimentos usando o processo de validação cruzada múltipla descrito anteriormente. A Tabela 5.6 apresenta os resultados destes experimentos. Nesta tabela, de acordo com critério estabelecido anteriormente, observa-se que o experimento 6 foi mais consistente durante os testes, pois este obteve menor erro MSE sobre o conjunto de teste.

Tabela 5.6 - Validação cruzada para o modelo neural com horizonte de até vinte e quatro horas.

Validação cruzada múltipla						
Experimento	Treinamento		Validação		Teste	
	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)
1	0.966	1.146	1.191	1.279	0.999	1.179
2	0.957	1.149	1.242	1.283	1.111	1.215
3	0.985	1.166	1.188	1.248	1.102	1.248
4	0.957	1.149	1.143	1.224	1.400	1.411
5	1.012	1.178	1.070	1.212	1.283	1.242
6	0.994	1.159	1.138	1.245	0.908	1.109
7	0.996	1.163	1.117	1.220	1.239	1.306
8	1.012	1.174	1.082	1.205	1.043	1.211
9	0.993	1.166	1.036	1.180	1.185	1.254
10	1.010	1.171	1.063	1.202	1.043	1.180

O experimento 6 que apresentou MSE médio no conjunto de teste igual a 0.908 %, a melhor rede ajustada forneceu MAPE igual 29.725 % para o conjunto de teste. Os resultados desta rede podem ser mais bem avaliados através dos gráficos das Figura 5.7 e Figura 5.8.


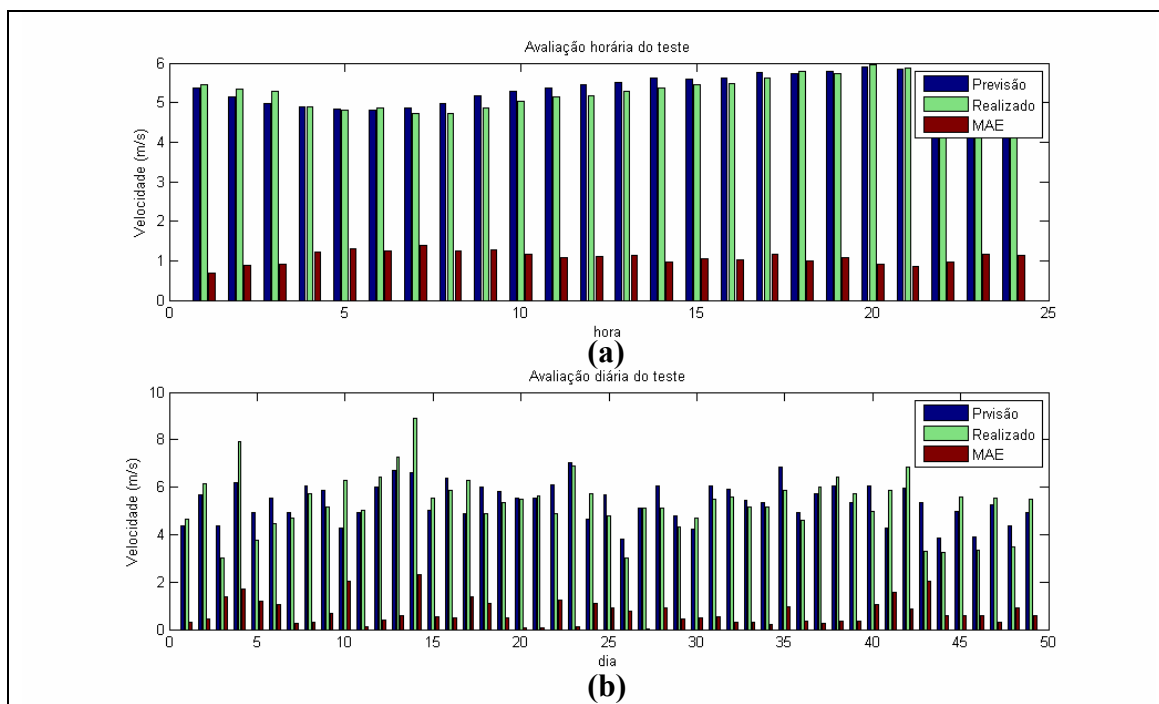


Figura 5.7 - Histograma do erro de teste para o modelo neural com horizonte de até vinte e quatro horas.

O gráfico da Figura 5.7 apresenta o desempenho do modelo neural para previsão das velocidades dos ventos com horizonte de até vinte e quatro horas. Neste gráfico, observa-se que boa parte dos erros cometidos encontra-se na faixa de 1 m/s.

O primeiro gráfico da Figura 5.8 apresenta a avaliação horária do teste através dos valores das velocidades médias horárias previstas e realizadas dos dados e os erros médios absolutos horários.



**Figura 5.8** - Avaliação horária e diária do teste para o modelo neural com horizonte de até vinte quatro horas.

O erro médio absoluto horário (MAE) obtido com este modelo foi 1.0815 m/s. Ao se analisar o gráfico da Figura 5.8(a), verifica-se que o maior erro médio absoluto horário cometido foi de 1.3872 m/s na hora 7; já o menor, foi de 0.6892 m/s na hora 1.

Já o gráfico da Figura 5.8(b) apresenta uma avaliação diária dos testes. Neste gráfico é mostrado o valor da velocidade média diária prevista e realizada, e ainda o erro médio absoluto da previsão média diária dos dias utilizados no conjunto de teste.

Neste modelo, o erro médio absoluto diário no teste foi de 0.7268 m/s. Além disso, observa-se ainda, através do gráfico da Figura 5.8(b) que durante os testes o maior erro médio diário cometido foi no 14º dia, com MAE igual a 2.3 m/s; já o menor erro foi no 27º dia em que o MAE foi de 0.0033 m/s.

Compatibilizando os valores das velocidades previstas para altura de referência da turbina, é possível estimar o erro da geração eólica, calculando-se os erros médios absolutos da capacidade ( $MAE_{CAP}$ ) e da potência média gerada ( $MAE_{AVG}$ ) através das Equações (4.5) e (4.4), respectivamente. Portanto, do ponto de vista da geração, este modelo obteve o seguinte desempenho:

- $MAE_{CAP}$  17.5564 (%)
- $MAE_{AVG}$  47,269 (%)

### 5.2.2 Modelo Neural com Análise de Multiresolução através de Transformada Wavelet.

No desenvolvimento deste modelo os padrões de entradas são modelados através de uma análise de multiresolução dos dados, usando Transformada Wavelet da família *daubschi* até o terceiro nível de decomposição. As RNA deste modelo são do tipo MLP, treinadas com o algoritmo *Rprop*.

Este modelo é desenvolvido a partir da mesma filosofia do modelo com horizonte de quatro horas que utiliza a análise de multiresolução, diferenciando-se apenas no número de entradas e saídas do modelo.

As redes neurais destes modelos são formadas de noventa e seis entradas. Com relação às saídas, estas são constituídas de vinte quatro neurônios compostos da função de ativação *sigmóide logísticas*, os quais representam as previsões das velocidades nos instantes  $t+1$ ,  $t+2$ , ...,  $t+24$ . Os neurônios da camada oculta são formados pela função de ativação *tangente hiperbólica*.

A Tabela 5.7 apresenta os erros médios quadráticos dos conjuntos de treinamento, validação e teste das dez inicializações de cada arquitetura, treinadas conforme determinado pelo processo de seleção de arquitetura. A partir desta Tabela, verifica-se que a arquitetura com quinze nodos ocultos obteve menor erro no conjunto de validação durante os treinamentos com MSE igual 1.3344 %. Portanto, a arquitetura selecionada ficou com noventa e seis entradas, quinze neurônios ocultos e vinte quatro saídas.

**Tabela 5.7** - Seleção arquitetura do modelo neural com análise de multiresolução de até vinte e quatro horas


<b>Seleção Arquitetura</b>			
<b>Nodos ocultos</b>	<b>Mse treinamento</b>	<b>Mse validação</b>	<b>Mse teste</b>
10	0.9907	1.3778	1.374
11	0.968	1.3723	1.3817
12	0.9633	1.3374	1.3617
13	0.9647	1.356	1.373
14	0.9353	1.3559	1.3627
15	0.9383	1.3344	1.3744
16	0.9363	1.3736	1.3806
17	0.9355	1.3529	1.3746
18	0.9447	1.3771	1.3839
19	0.9337	1.3787	1.3937
20	0.9192	1.3805	1.3984
21	0.9136	1.38	1.409
22	0.9099	1.3872	1.4062
23	0.9032	1.3747	1.3866
24	0.9092	1.3903	1.3877
25	0.9064	1.3807	1.3943
26	0.9021	1.3894	1.4124
27	0.9046	1.3863	1.4161
28	0.8999	1.3954	1.3946
29	0.9057	1.4215	1.4243
30	0.8895	1.4115	1.4404

Para esta arquitetura foram montados dez experimentos usando o processo de validação cruzada múltipla. A Tabela 5.8 apresenta os resultados destes experimentos. Nesta tabela, de acordo com critério estabelecido anteriormente, observa-se que o experimento 9 foi mais consistente durante os testes, pois este obteve menor erro MSE sobre o conjunto de teste.

**Tabela 5.8** - Validação cruzada para o modelo neural com análise de multiresolução com horizonte de até vinte e quatro horas

<b>Validação cruzada múltipla</b>						
<b>Experimento</b>	<b>Treinamento</b>		<b>Validação</b>		<b>Teste</b>	
	<b>MSE (%)</b>	<b>MAE (m/s)</b>	<b>MSE (%)</b>	<b>MAE (m/s)</b>	<b>MSE (%)</b>	<b>MAE (m/s)</b>
1	0.929	1.129	1.372	1.355	1.377	1.380
2	0.957	1.145	1.223	1.288	1.310	1.313
3	1.004	1.172	1.143	1.231	1.322	1.367
4	1.044	1.203	1.155	1.235	1.245	1.306
5	1.046	1.209	1.170	1.236	1.156	1.256
6	1.055	1.217	1.148	1.219	1.077	1.197
7	1.026	1.203	1.222	1.263	1.141	1.254
8	0.964	1.153	1.264	1.296	1.288	1.283
9	0.973	1.169	1.397	1.362	1.011	1.139
10	0.906	1.127	1.351	1.345	1.491	1.424

O experimento 9 que obteve MSE médio sobre o conjunto de teste igual a 1.011%, a melhor rede ajustada forneceu MAPE igual 27.568 % para o teste. Os resultados desta rede podem ser mais bem avaliados através dos gráficos da Figura 5.9.



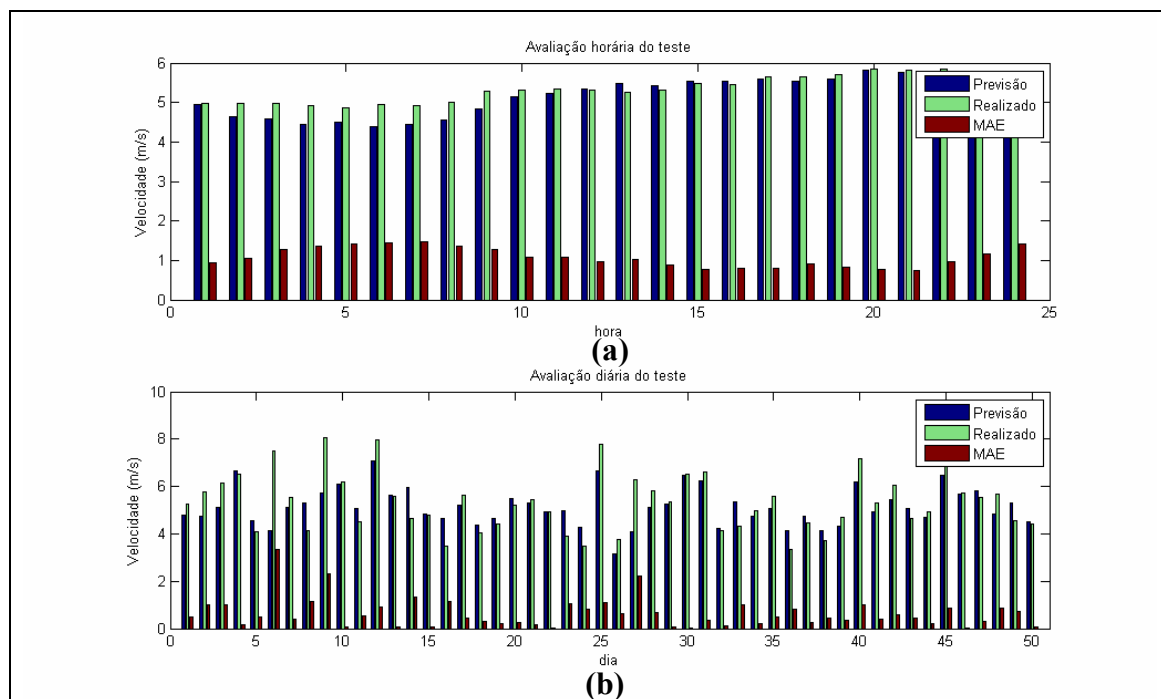
**Figura 5.9** - Histograma do erro de teste para o modelo neural com análise de multiresolução com horizonte de até vinte e quatro horas

O gráfico da Figura 5.9 apresenta a distribuição do erro cometido para teste deste modelo. Neste é observado que apesar de apresentar erros de até 8 m/s, boa parte dos erros cometidos encontra-se na faixa de 1 m/s. Além disso, observa-se que o modelo ajustado não é tendencioso.

O gráfico da Figura 5.10(a) apresenta a avaliação horária no conjunto de teste através dos valores das velocidades médias horárias previstas e realizadas dos dados e os erros médios absolutos horários.

O erro médio absoluto horário (MAE) obtido com este modelo foi 1.0737 m/s. Além disso, quando se observa o gráfico da Figura 5.10(a), verifica-se que o maior erro médio absoluto horário cometido foi de 1.4622 m/s na hora 7; já o menor, foi de 0.7349 m/s na hora 21.





**Figura 5.10** - Avaliação horária e diária do teste para o modelo neural com análise de multiresolução com horizonte de até vinte quatro horas

Já o gráfico da Figura 5.10(b), apresenta uma avaliação diária dos testes. Neste gráfico é mostrado o valor da velocidade média diária prevista e realizada e ainda o erro médio absoluto da previsão média diária dos dias utilizados no conjunto de teste.

Neste modelo o erro médio absoluto diário durante o teste foi de 0.6401 m/s. Além disso, observa-se através do gráfico da Figura 5.10(b) que durante os testes, o maior erro médio diário cometido foi no 6º dia com MAE igual a 3.3487 m/s; já o menor erro foi no 30º dia em que o MAE foi de 0.0171 m/s.

Visto que a previsão das velocidades médias horárias foi feita para uma altura de 20m, faz-se necessário converter os valores para estimar o erro da geração a uma altura de 70m, conforme descrito no Capítulo anterior, calculando-se os erros médios absolutos da capacidade ( $MAE_{CAP}$ ) e da potência média gerada ( $MAE_{AVG}$ ) através das Equações (4.5) e (4.4), respectivamente. Este modelo apresentou o seguinte resultado:

- $MAE_{CAP}$       16.9241 (%)
- $MAE_{AVG}$       45.6557 (%)

### 5.2.3 Modelo Neural Sazonal

O desenvolvimento deste modelo visa aproveitar alguma característica de similaridade durante as horas dos dias, criando redes neurais especialistas em previsões de um determinado período do dia. Esta similaridade é comprovada a partir do correlograma da Figura 4.1, em que os coeficientes de correlação voltam a aumentar nas proximidades de vinte e quatro horas do intervalo do tempo de regressão.

Este modelo está configurado para realizar previsões das velocidades médias horárias, com horizonte variando de dezessete a vinte quatro horas, conforme apresenta a Figura 5.11.

Para o desenvolvimento deste modelo a série de velocidades de ventos foi dividida em três séries distintas:

- **Série 1** – constituída das velocidades médias horárias das horas 1 a 8;
- **Série 2** – constituída das velocidades medias horárias das horas 9 a 16;
- **Série 3** – constituída das velocidades médias horárias das horas 17 a 24.

Desta forma, para formulação deste modelo foram usadas três RNAs, em que cada uma desta é especialista em previsões das velocidades médias horárias de uma das faixas determinadas pela divisão da série. Conseqüentemente, neste modelo foi necessário realizar os treinamentos em separado das três RNAs, conforme descrito asseguir.

Cada especialista é formado por uma RNA do tipo perceptron múltiplas camadas, com três camadas: a camada de entrada; a oculta, a qual utiliza a função de ativação *tangente hiperbólica*; e a camada de saída, que utiliza a função de ativação *sigmóide logística*. Além disso, os especialistas são configurados da seguinte maneira:

- **Especialista 1** – Constituído de oito entradas e oito saídas, onde as entradas correspondem às velocidades medias horárias das horas um a oito do dia que antecede a previsão; já as saídas correspondem às previsões das velocidades médias horárias das horas um a oito;
- **Especialista 2** – Constituído de oito entradas e oito saídas, onde as entradas correspondem às velocidades medias horárias das horas nove a dezesseis do dia que antecede a previsão; já as saídas correspondem às previsões das velocidades médias horárias das horas nove a dezesseis;

- **Especialista 3** – Também é constituído de oito entradas e oito saídas, onde as entradas correspondem às velocidades medias horárias das horas dezessete a vinte e quatro do dia que antecede a previsão; já as saídas correspondem às previsões das velocidades médias horárias das horas dezessete a vinte quatro.

Os padrões de entra-saídas dos especialistas foram definidos desta forma com base no comportamento das características climáticas da região ao longo dos períodos dos dias.

As RNA deste modelo foram treinadas com o algoritmo *Rprop*. Quanto às arquiteturas dos especialistas, ou melhor, os números de neurônios ocultos, foram definidos através do critério de seleção de arquitetura, que estabelece o uso do MSE do conjunto validação como balizador, conforme [33, 36, 40]. Neste modelo cada um dos três especialistas foi treinado para arquitetura variando de cinco a vinte nodos ocultos. Após estes treinamentos, selecionou-se o seguinte número de neurônios ocultos para cada especialista:

- Especialista 1 – quinze neurônios;
- Especialista 2 – dezenove neurônios;
- Especialista 3 – dezoito neurônios.

Após definir as arquiteturas de cada especialista presente neste modelo, foram criados dez experimentos usando o processo de validação cruzada múltipla. A Tabela 5.9 apresenta os resultados destes experimentos. Nesta tabela, de acordo com critério estabelecido anteriormente, observa-se que o experimento 9 foi mais consistente durante os testes, pois este obteve menor erro MSE sobre o conjunto de teste.

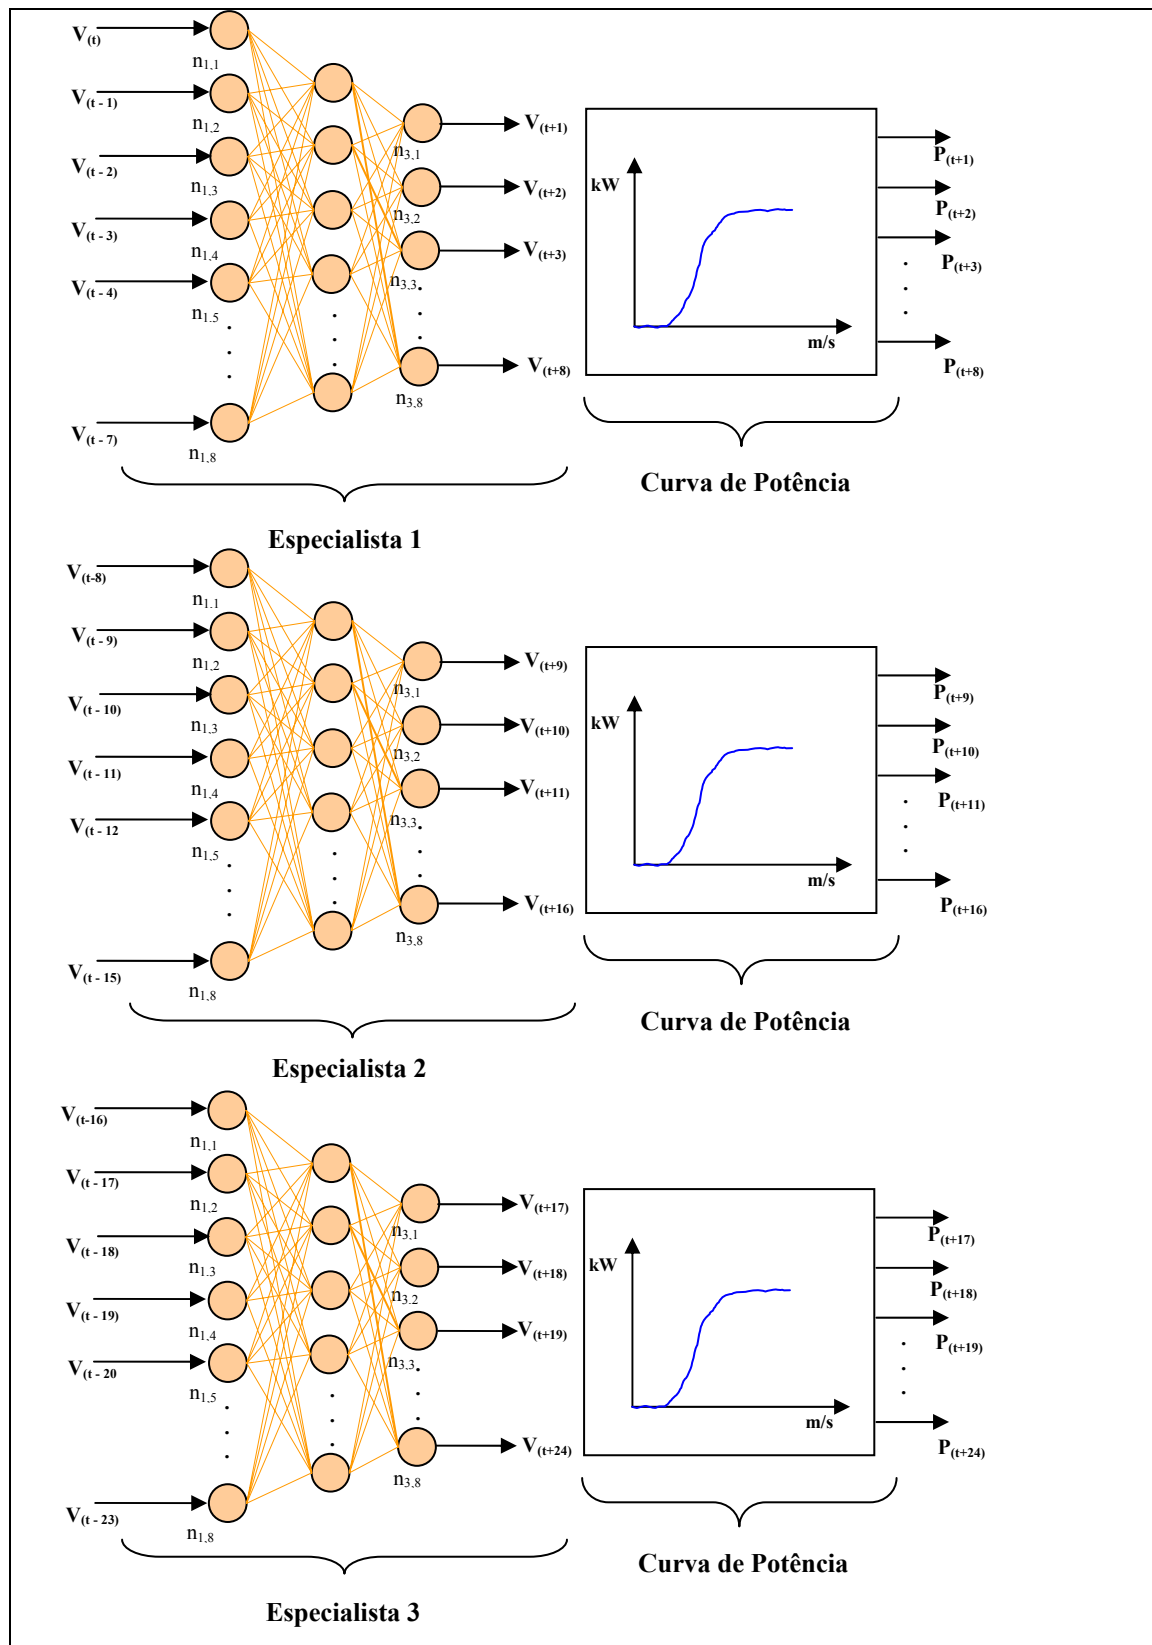


Figura 5.11 - Modelo neural sazonal com horizontes de até vinte e quatro horas.

Tabela 5.9 - Validação cruzada para o modelo neural sazonal com horizonte de até vinte e quatro horas.

Validação cruzada múltipla						
Experimento	Treinamento		Validação		Teste	
	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)	MSE (%)	MAE (m/s)
1	1.266	1.335	1.529	1.467	1.586	1.514
2	1.299	1.359	1.480	1.453	1.402	1.389
3	1.326	1.370	1.360	1.388	1.595	1.517
4	1.353	1.389	1.313	1.351	1.556	1.495
5	1.373	1.403	1.369	1.376	1.295	1.360
6	1.389	1.417	1.334	1.353	1.226	1.309
7	1.330	1.384	1.398	1.393	1.441	1.405
8	1.317	1.365	1.429	1.416	1.415	1.409
9	1.320	1.367	1.529	1.468	1.170	1.247
10	1.268	1.331	1.506	1.461	1.628	1.527

O experimento 9 que obteve MSE médio sobre o conjunto de teste igual a 1.170 %; a melhor rede ajustada forneceu MAPE igual 35.658% para o teste. Os resultados desta rede podem ser mais bem avaliados através dos gráficos das Figura 5.12.

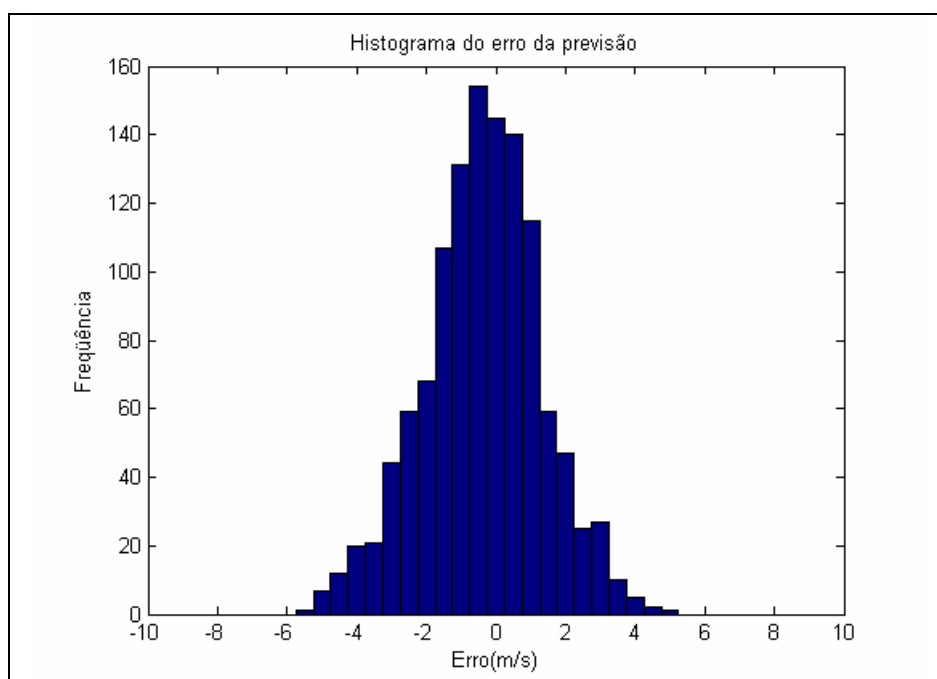
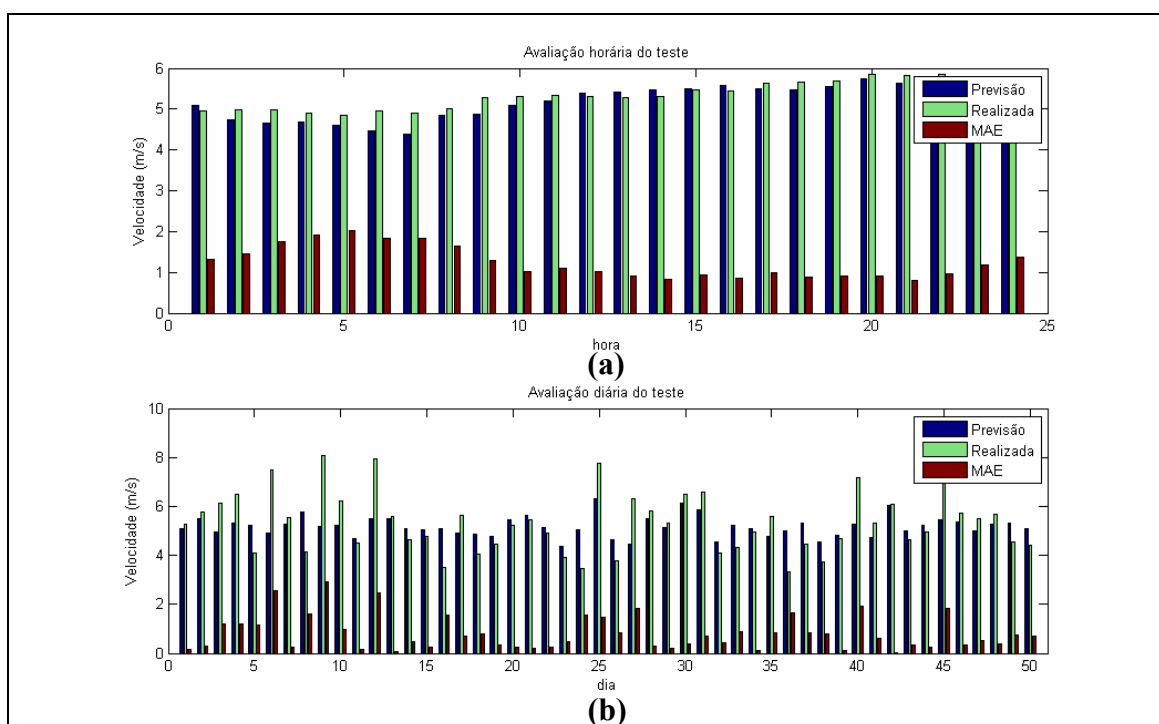


Figura 5.12 - Histograma do erro de teste para o modelo neural sazonal com horizonte de até vinte e quatro horas

O gráfico da Figura 5.12 apresenta o histograma do erro de previsão das velocidades dos ventos com horizonte de vinte e quatro horas para o modelo sazonal. Através deste observa-se que boa parte dos erros cometidos encontra-se na faixa de 1,5 m/s.

O gráfico da Figura 5.13(a) apresenta a avaliação horária do teste através dos valores das velocidades médias horárias previstas e realizadas dos dados e os erros médios absolutos horários.

O erro médio absoluto horário (MAE) obtido com este modelo foi igual a 1.239 m/s. Além disso, observando o gráfico da Figura 5.13(a) verifica-se que o maior erro médio absoluto horário cometido foi de 2.035 m/s na hora 5; já o menor, foi de 0.8099 m/s na hora 21.



**Figura 5.13** - Avaliação horária e diária do teste para o modelo neural sazonal com horizonte de até vinte quatro horas

Já o gráfico da Figura 5.13(b) apresenta uma avaliação diária dos testes. Neste gráfico é mostrado o valor da velocidade média diária prevista e realizada e ainda o erro médio absoluto da previsão média diária dos dias utilizados no conjunto de teste.

Para este modelo o erro médio absoluto diário durante o teste foi de 0.819 m/s. Além disso, observa-se através do gráfico da Figura 5.13(b) que durante os testes, o maior erro médio diário cometido foi no 9º dia com MAE igual a 2.9048 m/s; já o menor erro foi no 42º dia em que o MAE foi de 0.0135 m/s.

A Tabela 5.10 apresenta os resultados de teste para cada especialista em separado. Nesta pode-se observar que o Especialista 1 deteve o pior desempenho com MAE igual a

1,719. Isto significa que a RNA teve mais dificuldade para modelar o problema de previsão das horas um a oito. Já o especialista 2 obteve melhor desempenho com MAE igual 0,992.

**Tabela 5.10** – Resultados no conjunto de teste dos Especialistas

<b>Desempenho do Teste dos Especialistas</b>			
	Especialista 1	Especialista 2	Especialista 3
<b>MAPE %</b>	61,57	20,86	24,54
<b>MAE</b>	1,719	0,992	1,006

Compatibilizando os valores das velocidades previstas para altura de referência da turbina, é possível estimar o erro da geração eólica, calculando-se os erros médios absolutos da capacidade ( $MAE_{CAP}$ ) e da potência média gerada ( $MAE_{AVG}$ ) através das Equações (4.5) e (4.4), respectivamente. Portanto, do ponto de vista da geração, este modelo apresentou os seguintes resultados:

- $MAE_{CAP}$  19.640 (%)
- $MAE_{AVG}$  52.984 (%)

Apesar do Modelo Neural Sazonal ter apresentado o pior desempenho no conjunto de teste dentre os modelos de previsões com horizonte de até vinte e quatro, vale salientar que este é o que realiza previsões com maior horizonte efetivamente. Pois o horizonte de previsão deste é de dezessete a vinte e quatro horas. Uma vez que os padrões de entrada-saída de cada especialista são compostos de oito entradas de velocidades de um determinado período do dia e oito saídas de velocidades do mesmo período do dia seguinte. Enquanto os outros dois modelos anteriores o horizonte de previsão é de uma a vinte e quatro horas, conforme visto anteriormente.

### 5.3 Resultados dos modelos estatísticos

Nesta etapa do trabalho foi utilizado o modelo auto-regressivo media móvel para desenvolver dois modelos de previsão da velocidade de ventos e de geração eólica.

Assim como os modelos desenvolvidos a partir das redes neurais, os modelos estatísticos foram ajustados utilizando a série de velocidade de ventos a uma altura de 20 m.

No desenvolvimento dos modelos estatísticos a série temporal foi dividida em duas sub-partições. A primeira partição, constituída de 90 % da série foi utilizada para ajuste do modelo; já a segunda partição, 10 % da série, foi utilizada como conjunto de teste.

Nos modelos estatísticos, para estimar os erros cometidos na geração, também foi necessário converter estas velocidades para a altura de referência da turbina especificada no projeto (70m).

Os modelos estatísticos aqui utilizados foram ajustados para dois horizontes de previsão diferentes: horizontes de quatro horas e horizontes de vinte e quatro horas. Estes modelos foram ajustados avaliando o desempenho de vários modelos ARMA com diferentes ordens auto-regressiva e média móvel.

As ordens do modelo média móvel foram variadas de 0 a 10; enquanto as ordens do modelo auto-regressivo foram variadas de 1 a 10. Logo, para cada horizonte de previsão, de quatro ou vinte quatro horas, foram testados 110 modelos.

### 5.3.1 Modelo ARMA para o horizonte de quatro horas


A Tabela 5.11 apresenta os resultados dos 110 modelos criados para o horizonte de quatro horas através dos erros MAPE. Os valores apresentados nesta tabela foram utilizados para selecionar dentre os modelos aptos o de melhor desempenho. Pois todos os 110 modelos, inicialmente, são apenas modelos tentativos conforme previamente descrito na seção 4.2.5.2, sendo necessário que eles sejam aptos para estar habilitado a ser selecionado. .

**Tabela 5.11** - Resultados dos modelos ARMA para o horizonte de quatro horas

MA \ AR	1	2	3	4	5	6	7	8	9	10
0	41,92	42,65	43,34	44,01	44,15	44,53	45,03	45,33	45,61	46,09
1	50,10	49,94	49,72	49,73	49,52	49,68	49,72	49,72	49,77	49,78
2	49,93	49,84	49,73	49,76	49,76	49,74	49,74	49,71	49,72	49,81
3	49,74	49,74	49,84	49,66	49,72	49,71	49,74	49,69	49,25	49,82
4	49,74	49,78	49,95	49,94	49,68	49,76	49,74	49,78	49,79	49,81
5	49,47	49,57	49,68	49,69	49,68	49,75	47,64	49,73	49,72	49,80
6	49,63	49,73	49,67	49,77	49,78	48,58	48,34	49,75	49,59	49,76
7	49,68	49,68	49,63	49,77	49,77	49,81	48,82	49,83	48,11	49,69
8	49,68	49,68	49,64	49,79	49,76	49,76	47,85	48,09	47,97	49,68
9	49,72	49,68	49,67	49,67	49,81	49,76	49,76	48,10	48,12	49,70
10	49,82	49,80	49,79	49,76	49,76	49,79	49,80	49,74	49,84	50,17

Ao observar a Tabela 5.11 verifica-se que o modelo ARMA(1,0) obteve melhor desempenho para conjunto de teste. Como este conjunto de teste não foi utilizado durante a etapa de ajuste do modelo, espera-se que este desempenho seja próxima daquele quando o modelo estiver em operação real.





**Figura 5.14** - Histograma do erro de teste para o modelo ARMA(1,0) com horizonte de quatro horas

A Figura 5.14 apresenta o histograma do erro do modelo ARMA(1,0) para o horizonte de quatro horas. Ao observar esta Figura verifica-se que este modelo satisfaz o critério de estabilidade, pois o modelo é não tendencioso.

Compatibilizando as velocidades previstas para a altura de referencia da turbina selecionada, a fim de obter uma estimativa dos erros da geração, chegou-se a:

- $MAE_{CAP}$       21.8221 (%)
- $MAE_{AVG}$      42.1273 (%)

### 5.3.2 Modelo ARMA para horizonte de vinte e quatro horas

A Tabela 5.12 apresenta os resultados dos 110 modelos criados para o horizonte de vinte e quatro horas através dos erros MAPE. Os valores apresentados nesta tabela foram utilizados para selecionar dentre os modelos aptos e o de melhor desempenho, segundo descrito anteriormente na seção 4.2.5.2.

Tabela 5.12 - Resultados dos modelos ARMA para o horizonte de vinte e quatro horas

AR MM	1	2	3	4	5	6	7	8	9	10
0	63,32	63,63	63,84	63,97	64,04	64,28	64,56	64,75	65,00	66,99
1	66,25	66,19	66,06	66,07	66,25	66,60	66,69	66,70	66,88	66,89
2	66,18	66,12	66,06	66,05	66,80	66,75	66,67	66,70	66,70	66,85
3	66,06	66,07	66,10	66,08	66,00	66,26	66,76	66,74	66,77	66,82
4	66,09	66,07	66,07	66,09	66,91	66,76	66,78	66,75	66,83	66,59
5	66,23	66,08	66,77	61,76	66,06	66,79	66,74	66,74	66,82	66,83
6	66,47	66,63	66,72	66,80	66,80	65,34	61,62	61,58	61,50	66,72
7	66,53	66,52	66,74	66,80	66,81	66,80	61,76	64,52	61,48	66,75
8	66,54	66,54	66,53	66,73	66,72	63,90	66,89	62,36	61,56	66,80
9	66,64	66,54	66,64	66,45	66,74	66,82	61,45	61,63	65,49	66,82
10	66,70	66,69	66,66	66,63	66,63	66,48	66,92	66,78	66,94	66,48

Ao observar a Tabela 5.12 verifica-se que o modelo ARMA(7,9) obteve melhor resultado para conjunto de teste. Entretanto este modelo demonstrou ser tendencioso conforme histograma do erro de teste mostrado na Figura 5.15.





Figura 5.15 - Histograma do erro de teste para o modelo ARMA(7,9) com horizonte de vinte e quatro horas

Ao analisar criteriosamente os modelos ARMA criados para este horizonte, selecionou-se o modelo ARMA(1,0), visto que este foi o modelo apto que apresentou menor erro MAPE sobre o conjunto de teste. Apesar de terem outros modelos de menor MAPE, estes não foram considerados aptos devido suas instabilidades.



**Figura 5.16** - Histograma do erro de teste para o modelo ARMA(1,0) com horizonte de vinte e quatro horas

Compatibilizando as velocidades previstas para a altura de referência da turbina selecionada, a fim de obter uma estimativa dos erros da geração, chegou-se a:

- $MAE_{CAP}$       34.3941
- $MAE_{AVG}$       66.3974

## 5.4 Síntese dos Testes dos Modelos de Previsões Desenvolvidos

A Tabela 5.13 **Erro! Fonte de referência não encontrada.** apresenta os resultados obtidos nos testes dos modelos de previsões desenvolvidos ao longo deste trabalho. Os resultados estão divididos em dois grandes grupos: modelos de previsões com horizontes de até quatro horas e até vinte e quatro horas. Além disso, os modelos de previsão desenvolvidos são apresentados através de abreviações, onde:

- RNA – Modelos Neurais;
- RNA + TW – Modelos Neurais com Análise de Multiresolução através de Transformada Wavelet;
- Estatísticos – Modelos ARMA;
- Sazonal – Modelo Neural Sazonal.

**Tabela 5.13** - Resultados de Teste dos Modelos de Previsões desenvolvidos

<b>Resultados de Teste dos Modelos de Previsões desenvolvidos</b>							
	Horizontes de até quatro horas			Horizontes de até vinte quatro horas			
	RNA	RNA + TW	Estatístico	RNA	RNA + TW	Sazonal	Estatístico
MAPE (%)	24,065	21,515	41,92	29,725	27,568	35,658	63,32
MAE <sub>AVG</sub>	33,759	29,573	42,127	47,262	45,656	52,984	66,397
MAE <sub>CAP</sub>	12,691	11,573	21,822	17,536	16,924	19,64	34,39

## CAPÍTULO 6

### 6 Conclusões e Trabalhos Futuros

#### 6.1 Conclusões

Vários modelos de previsões com técnicas e horizontes diferentes foram desenvolvidos, a fim de avaliar e desenvolver ferramentas para previsões de ventos e geração eólica de curto prazo.

Os vários horizontes de previsões aqui explorados têm a finalidade de subsidiar o planejamento da operação dos sistemas hidrotérmico e eólico, uma vez que a entrada em operação de uma termoelétrica precisa ser definida com antecedência, que varia de uma planta para outra. Além disso, ao se explorar vários modelos foi possível avaliar topologias de entradas diferentes.

Analisando os resultados encontrados e as técnicas utilizadas no desenvolvimento dos modelos de previsões, é possível concluir que:

- Apesar dos modelos estáticos serem utilizados tradicionalmente no desenvolvimento dos modelos de previsões de ventos, sua parametrização, de modo a obter modelos não serem tendenciosos foi difícil. Além disso, ficou evidenciado através dos resultados obtidos com estes modelos, tanto no caso do horizonte de quatro como para horizonte de vinte e quatro horas, que seus desempenhos estão fortemente relacionados com os coeficientes de auto-correlação serial, visto que as previsões são realizadas com base nestes coeficientes. Isto é explicado pelo fraco desempenho obtido durante os testes para estes modelos e pelo correlograma apresentado na Figura 4.1.
- A capacidade de modelar problemas não lineares dos modelos inteligentes, baseados em redes neurais do tipo MLP, os possibilitou se adaptarem melhor aos dados da série temporal das velocidades de ventos. Já os modelos estatísticos, não tiveram a mesma facilidade.
- Os resultados dos modelos inteligentes desenvolvidos a partir de redes neurais artificiais constataam a aplicabilidade desta técnica para previsões de ventos e geração eólica. Estes modelos tiveram resultados satisfatórios quando comparados com os modelos desenvolvidos no âmbito mundial [6]. Os bons resultados

encontrados, dar-se ao uso de estratégias adequadas para a seleção da arquitetura e seleção dos dados para compor os conjuntos de treinamentos, validação e testes obtidos pelo processo de validação cruzada. Além de garantir bons resultados, estas estratégias foram fundamentais para se obter resultados mais confiáveis estatisticamente, ou seja, sem tendências.

- Os modelos inteligentes que utilizaram uma análise de multiresolução para tratamento dos dados de entradas, tiveram desempenhos um pouco superior aos modelos desenvolvidos somente através de redes neurais. Estas diferenças de desempenho podem ser explicadas pelo fato da análise de multiresolução separar os dados de entradas em sinais de aproximações e de detalhes. Esta metodologia ainda possibilitou que as redes neurais tivessem uma melhor capacidade de generalizar os resultados durante os testes, porque a Transformada Wavelet foi implementada semelhante aos bancos de filtros que separam os dados de altas e de baixas frequências a serem apresentados às redes neurais.
- No modelo criado através de redes especialistas que buscavam explorar a capacidade das sazonalidades durante os períodos dos dias, não foi obtido nenhuma melhora significativa, pelo contrário, os resultados dos testes foram até um pouco pior que os encontrados para o modelo neural com horizonte de até vinte e quatro horas. No entanto, os horizontes de previsões destes modelos são um pouco diferentes: enquanto um faz previsão com horizonte de um a vinte quatro horas, o outro realiza previsões com horizontes de dezessete a vinte quatro horas.
- Os resultados obtidos neste trabalho, também comprovou a dificuldade de realizar previsão de ventos e geração eólica a medida que o horizonte de previsão é aumentado. Visto que em todos os modelos desenvolvidos, o desempenho diminuía com aumento do horizonte de previsão.

## 6.2 Trabalhos Futuros

Apesar dos bons resultados, a perspectiva de melhorá-los é uma realidade. Sendo assim, propõem-se os seguintes trabalhos futuros:

- Com crescente aumento dos dados relacionados à geração eólica no Brasil, desenvolver modelos de previsões multivariados.
- Desenvolver modelos de previsões de ventos e geração eólica com horizontes maiores para estudos no Brasil.
- Estudar outros tipos de redes neurais para desenvolver os modelos de previsões, como por exemplo, as redes RBF.
- Desenvolver modelos mistos de previsões, que utilizem lógica fuzzy e redes neurais.
- Desenvolver modelos especialistas que levem em consideração, além da sazonalidade durante os períodos dos dias, a sazonalidade dos ventos durante os períodos dos anos.
- Utilizar as redes de kohonen para identificar as sazonalidades dos dados de ventos, uma vez que esta é capaz de identificar características de semelhanças no espaço de entradas através de mapas auto-organizáveis.
- Desenvolver pesquisas com outras bases de dados e avaliar modelos de correlação espacial.

## REFERÊNCIAS

- [1] AQUINO, RONALDO, ROSAS, PEDRO A. C., SOUZA, LEONARDO T. A., FERREIRA, AIDA A.; NEVES, FRANCISCO . S., Recurrent artificial neural network: an application to optimal dispatch of hydro, thermal and wind power plants. *XXV CILAMCE 25th Iberian Latin-American Congress On Computational Methods In Engineering*, p. 1-6, 2004.
- [2] POTTER, W. C. and NEGNEGVITSKY, M, Very Short-Term Wind Forecasting for Tasmanian Power Generation, *IEEE Transactions on Power Systems*, Vol. 21, No. 2, p 965-972, May 2006
- [3] MILIGAN, M., SCHWARTZ, M., WAN, Y. Statistical Wind power Forecasting Models: Results for U.S Wind Farms. *National Renewable Energy Laboratory*, 2003, CP 500-33956.
- [4] ALEXIADIS, M.C., DOKOPOULOS, P.S., SAHSAMANOGLU, H.S., Wind Speed and Forecasting based on Spatial Correlation Models. *IEEE Transactions on Energy conversion*, vol.14, no.3, p 836-842, Sep. 1999.
- [5] KARINIOTAKIS, G.N., STAVRAKAKIS, G.S., NOGARET, E.F. “Wind Power Forecasting Using Advanced Neural Networks Models”. *IEE Transactions on Energy Conversion*, , vol.11, no.4, p 885-869, 1996
- [6] SIDERATOS, G., HATZIARGYRIOU, N.D., Application of Radial Basis Function Networks for Wind Power Forecasting . *Lecture Notes in Computer Science, ICANN Greece*, v. 4132, p. 726-735, set/ 2006.
- [7] DAMOUSIS, I.G., ALEXIADIS, M.C. and THEOCHARIS, J.B. A Fuzzy Model for Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation. *IEE Transactions on Energy Conversion*, vol.19, no.2, p 352-360, Jun.2004
- [8] ERNST, B., ROHRIG, K.. Online-Monitoring and Prediction of Wind Power in German Transmission System Operation Center. *World Wind Energy Conference*, [http://www.iset.uni-kassel.de/abt/FB-I/publication/03-11-01\\_WWEC2003.pdf](http://www.iset.uni-kassel.de/abt/FB-I/publication/03-11-01_WWEC2003.pdf). Nov. 2003.
- [9] Atlas de Energia Elétrica do Brasil/ Agência Nacional de Energia Elétrica – ANEEL, 2 edição 2005.
- [10] CRESESB, *Atlas do Potencial Eólico Brasileiro*, 2001.
- [11] Global Wind Energy Coencil, *Global Wind 2007 Report*, 2007
- [12] CHESF, *Fontes Energéticas Brasileiras: Inventario / Tecnologias*, 1987.



- [13] CAVALCANTI, J. A., MELO, P. A., PINTO, M. S. L., NETO, P. B. C., 2004. “*Planejamento de Redes Elétricas com Alto Grau de Penetração Eólica*”, IX SEPOPE- Symposium of Specialists in Electric Operational and Expansion Planning. mai/2004,, Cd Rom- SP-176, Rio de Janeiro- RJ- Brasil
- [14] GUIMARÃES, A. S. L., NEVES, F. A. S., CARVALHO JR., M. A., CAVALCANTI, M. C., AQUINO, R.R.B. “*Modeling Wind generation Systems based on Induction Machines*”, IX SEPOPE- Symposium of Specialists in Electric Operational and Expansion Planning. Cd Rom- SP-171, Rio de Janeiro- RJ- Brasil, 2004
- [15] ROSAS, PEDRO; AQUINO, RONALDO R. B., PEREIRA, ALEXANDRE; GUIMARÃES, RODRIGO. “*Study of impacts of a large penetration of wind power and distributed power generation as a whole on the Brazilian power system*” In: EUROPEAN WIND ENERGY CONFERENCE & EXHIBITION, 2004, Londres. 2004 EWEC. 2004. v. 1, pp. 1-6.
- [16] Petersen, Helge , Evaluation of wind turbine performance , Copenhagen , April 2001.
- [17] SALLES, Ana. *Metodologias de Análise de Risco para Avaliação Financeira de Projetos de Geração Eólica*. Rio de Janeiro - RJ, 2004. Dissertação de Mestrado - UFRJ
- [18] Box, G. E. P.; Jenkins, G. M.; 1970. *Time series analysis: forecasting and control*. 1. ed. San Francisco : CA: Holden-Day.
- [19] SANTOSO, S.; POWER, E. J.; GRANDY, W. M. *Power Quality Disturbance Data Compression Using Wavelet Transform Methods*. IEEE Trans. on Power Delivery, v. 12, n. 3, p. 1250-1257, Jul. 1997.
- [20] LIRA, Milde. *Classificação automática de distúrbios em sistemas de potência*. Recife – PE, 2004. Tese de Doutorado, UFPE.
- [21] MALLAT, S. *A Theory for Multiresolution Signal Decomposition: The Wavelet Representation*. IEEE Trans. Pattern Analysis and Machine Intelligence, v. 11, p. 674-693, July 1989.
- [22] HAYKIN, S. *Redes neurais: princípios e prática* . Porto Alegre – RS: 2 edição BOOKMAN Editora S.A, 2001.
- [23] MCCULLOCH, W. S. e Pitts, W. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, vol. 5, pp.115-133,1943.
- [24] BRAGA, Antônio; CARVALHO, André; LUDERMIR, Teresa. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro - RJ: LTC, 2000.
- [25] MENDEL, J.M. and MCLAREN, R. W., *Adaptive, Learning, and Patten , Learning, and Patten Recognition; Theory and application*, chapter reinforcement-learning control and pattern recognition systems, pages 287-318. New York: Academic press, 70.

- [26] ROSENBLATT, Frank, *The Perceptron: A probabilistic model for information storage and organization in the brain*. Psychological Review, v65, No. 6, pp. 386-408, 1958.
- [27] WINDROW, Bernard and HOFF JR., Marcian.Edward. *Adaptive switching circuits*. Institute of radio engineers, Western electronic show and convention, 1960.
- [28] RUMELHART, David Everett, HINTON, Geoffrey E., and WILLIAMS, Ronald J. *Learning representations by back-propagating errors*. Nature, 323:533-536,1986.
- [29] KOHONEN, Tuevo, *Self-organized formation of topologically correct feature maps*, Biological Cybernetics, 43, 1982.[
- [29] RIEDMILLER, Martin; BRAUN, Heinrich *A Direct adaptive Method for faster Backpropagation Learning: The RPROP Algorithm*, IEEE International Conference on Neural Networks, vol.1, April 1993, pp.586-591.
- [30] VALENÇA, Mêuser. *Aplicando Redes Neurais: Um Guia Completo*. Olinda – PE: Livro Rápido, 2005.
- [31] REIS, Agnaldo; SILVA, Alexandre. *Previsor Neural de Carga baseado em análise de Multiresolução via Wavelets*. VIII Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, IP 052, 2002.
- [32] AQUINO, Ronaldo; OLIVEIRA, Josinaldo; NÓBREGA, Otoni; LIRA, Milde; SILVA, FERREIRA, Aida; ROSAS, Pedro; SANTOS, GABRIELA. *Avaliação de métodos convencionais e de inteligência artificial para previsão de ventos e geração eólica*. XIX Seminário Nacional de Produção e Transmissão de Energia Elétrica. Rio de Janeiro- RJ- Brasil, 2007
- [33] NÓBREGA, Otoni. *Aplicação de redes neurais artificiais e algoritmos genéticos na previsão de carga elétrica em médio prazo*. Recife – PE, 2006 Dissertação de mestrado, UFPE.
- [34] AQUINO, Ronaldo; NÓBREGA, Otoni; LIRA, Milde; FERREIRA, Aida; Santos, Katyusco F. *Using Genetic Algorithm to Develop a Neural-Network-Based Load Forecasting*. Lecture Notes in Computer Science, v. 4669, p. 738/1611-3349-747, 2007
- [35] FERREIRA, AIDA A. *Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais*. Recife – PE, 2004 Dissertação de mestrado, UFPE.
- [36] SILVA, Geane. *Sistema híbrido de previsão de carga elétrica em curto prazo utilizando redes neurais e lógica fuzzy*. Recife – PE, 2004 Dissertação de mestrado, UFPE.

- [37] AQUINO, Ronaldo; NÓBREGA, Otoni; LIRA, Milde; FERREIRA, Aida; CARVALHO JR, Manoel; SILVA, Geane; OLIVEIRA, Josinaldo. *Development of an Artificial Neural Network by Genetic Algorithm to Mid-Term Load Forecasting*. In: Proceedings of International Joint Conference on Neural Networks, August 12-17, 2007, 2007, Orlando, Florida, USA,. IJCNN 2007 Conference Proceedings. Florida : IEEE Catalog Number: 07CH37922C, 2007. p. 1-6
- [38] AQUINO, Ronaldo; SILVA, Geane; LIRA, Milde; FERREIRA, Aida; CARVALHO JR, Manoel; OLIVEIRA, Josinaldo. *Combined Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System for Improving a Short-Term Electric Load Forecasting*. Lecture Notes in Computer Science, v. 4669, p. 779/1611-3349-788, 2007.
- [39] PRECHELT, L. *Proben1 – A Set of Neural Network Benchmark Problems and Benchmarking Rules*. Technical Report, 1994, pp. 21-94.
- [40] AQUINO, Ronaldo; FERREIRA, Aida; LIRA, Milde; SILVA, Geane; NÓBREGA, Otoni; OLIVEIRA, Josinaldo; DINIZ, Carlos; FIDELIS, Juclar. *A Hybrid Intelligent System for Short and Mid-term Forecasting for the CELPE Distribution Utility*. In: IEEE World Congress on Computational Intelligence / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 2556-2661.
- [41] AQUINO, Ronaldo; BEZERRA, José Maurício;; SANTOS, Gabriela; NÓBREGA Otoni ; LIRA, Milde; FERREIRA, Aida ; OLIVEIRA, Josinaldo. *Aplicação de redes neurais para diagnóstico de poluição em isoladores de alta tensão*. In: XIX SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 2007, Rio de Janeiro. XIX SNPTEE. Rio de Janeiro : Cigre-Brasil, 2007. v. GMI19.