

UTILIZAÇÃO DE REDES NEURAIIS PARA PREVISÃO DE VENTOS NO
HORIZONTE DE 24 HORAS

Guilherme Camargo Rodrigues

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM
ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. Alexandre Pinto Alves da Silva, Ph.D.

Profa. Carmen Lucia Tancredo Borges, D. Sc.

Prof. Marcus Theodor Schilling, D. Sc.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2007

CAMARGO RODRIGUES, GUILHERME

Utilização de Redes Neurais para
Previsão de Ventos no Horizonte de 24 Horas
[Rio de Janeiro] 2007

XI, 108 p. 29,7 cm (COPPE/UFRJ, M.Sc.,
Engenharia Elétrica, 2007)

Dissertação – Universidade Federal do
Rio de Janeiro, COPPE.

1. Energia Eólica
2. Previsão de Ventos
3. Redes Neurais Artificiais

I. COPPE/UFRJ II. Título (série)

Para minha amada esposa Flávia
e meu amado filho Gabriel,
inspirações da minha vida

AGRADECIMENTOS

Primeiramente, agradeço a Deus que me deu a oportunidade e a capacidade de estar fazendo as coisas que gosto e me guiou para a realização deste trabalho.

Ao Doutor Alexandre Pinto Alves da Silva, pela orientação, paciência e incentivo para desenvolvimento do trabalho.

Aos membros da banca, Doutora Carmen Lucia Tancredo Borges e Doutor Marcus Theodor Schilling, pelas contribuições positivas para o trabalho.

A meus pais Paulo e Alda e minha irmã Paula pelo apoio dedicado por todos os anos de minha vida e incentivo aos estudos que me levaram onde estou.

A todos os colegas da Eletrobrás, em especial da DPTQ, que tiveram compreensão e deram apoio total durante todo o período do curso.

A família e amigos que sempre me incentivaram e me apoiaram.

E a todos aqueles que de alguma forma contribuíram para este trabalho.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

UTILIZAÇÃO DE REDES NEURAIIS PARA PREVISÃO DE VENTOS NO
HORIZONTE DE 24 HORAS

Guilherme Camargo Rodrigues

Junho / 2007

Orientador: Alexandre Pinto Alves da Silva

Programa: Engenharia Elétrica

Este trabalho desenvolve um modelo computacional de previsão de ventos no horizonte de 24 horas utilizando Redes Neurais Artificiais. As modelagens foram feitas utilizando redes Perceptron Multi-Camadas, treinamento de retro-propagação e diversas configurações de redes. Foram realizadas simulações com uma série real de velocidade de vento da região Sul do Brasil e os resultados obtidos apresentaram ganhos em relação a métodos de persistência.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

APPLICATION OF NEURAL NETWORKS TO WIND FORECASTING FOR A
HORIZON OF 24 HOURS

Guilherme Camargo Rodrigues

June / 2007

Advisors: Alexandre Pinto Alves da Silva

Department: Electrical Engineering

This work develops a computer model based on artificial neural networks for wind forecasting considering a horizon of 24 hours. Multi-Layer Perceptrons have been employed, with back-propagation training, and several configurations of networks. Simulations have been performed with real series of wind velocity of the Brazilian south region, presenting better results compared with the ones from methods of persistence.

Capítulo 1 INTRODUÇÃO	1
1.1 Energia Eólica	1
1.1.1 Recurso Eólico	2
1.1.2 Turbina Eólica	6
1.1.3 Componentes do Sistema Eólico	8
1.1.4 No Brasil	11
1.2 Estado da arte na previsão de vento	14
1.2.1 Considerações gerais	14
1.2.2 NWP – Numerical Weather Prediction	15
1.2.3 Métodos estatísticos tradicionais para previsão de vento e potência eólica	16
1.2.4 Métodos estatísticos utilizando sistemas inteligentes	17
1.2.5 Outros Previsores	20
1.2.6 Ferramentas de previsão de vento	21
1.2.7 Resumo dos Principais Trabalhos	23
1.3 Motivação e Objetivo	24
Capítulo 2 ANÁLISE EXPLORATÓRIA DAS SÉRIES DE VENTO	26
2.1 Base de Dados	26
2.1.1 Apresentação	26
2.1.2 Descrição dos dados	27
2.1.3 Mínimos, máximos e médias	27
2.1.4 Histogramas	27
2.1.5 Desvio padrão, variância, simetria e curtose	28
2.1.6 Gráficos de entrada x saída	29
2.1.7 Autocorrelação da variável – velocidade do vento	30
2.1.8 Correlação cruzada	31
2.2 Análise dos Dados	31
Capítulo 3 REDES NEURAS PARA PREVISÃO DE VENTO	33
3.1 Considerações Gerais	33
3.2 Topologia da rede neural	33
3.2.1 Perceptron Multi-Camadas (MLP)	33
3.2.2 Metodologia para Definição da Arquitetura	34
3.2.3 Algoritmo de Retro-Propagação	36
3.2.4 Pré-Processamento dos Dados	38
3.2.5 Rede Inicial dos Testes de Previsão de Vento	40
Capítulo 4 TESTES E RESULTADOS	42

4.1	Testes iniciais	43
4.1.1.	Persistência – 144 passos à frente defasados de 10 minutos	44
4.1.2.	Metodologia Box-Jenkins – 144 passos à frente defasados de 10 minutos	45
4.1.3.	1 Rede – 1 saída 10 minutos à frente	45
4.1.4.	24 Redes – uma rede para cada hora à frente	47
4.1.5.	1 Rede – 144 saídas à frente defasadas de 10 minutos	49
4.1.6.	1 Rede – 6 saídas à frente defasadas de 10 minutos	50
4.1.7.	1 Rede – 24 saídas à frente (horas cheias)	52
4.2	Testes com modelo combinado	53
4.2.1.	Combinado da rede de 24 saídas na base de horas cheias com a rede de 1 saída na base de 10 minutos	54
4.2.2.	Combinado da rede de 24 saídas na base de horas cheias com a rede de 6 saídas na base de 10 minutos	56
4.3	Comparação dos resultados	58
Capítulo 5 CONCLUSÕES		59
5.1	Conclusões Gerais	59
5.2	Trabalhos Futuros	61
Referências Bibliográficas		64
Anexo A MODELOS DE PREVISÃO		71
Considerações Gerais		71
Séries Temporais		72
	Análise de Séries Temporais	72
	Decomposição de Séries Temporais	74
Técnicas de Previsão		75
Erros de Previsão		77
Técnicas Tradicionais de Previsão		78
	Modelos de Suavização Exponencial	78
	Metodologia Box-Jenkins	80
	Modelos auto-regressivos (AR)	84
	Modelos de médias móveis (MA)	85
	Modelos auto-regressivos de médias móveis (ARMA)	86
	Modelos auto-regressivos integrados de médias móveis (ARIMA)	87
	Modelos sazonais (SARIMA)	88
Técnicas Inteligentes		89

Computação Genética e Evolucionária _____	89
Sistemas Neuro <i>Fuzzy</i> _____	92
Redes Neurais Artificiais (RNA) _____	95
Comparação entre CGE - Neuro- <i>Fuzzy</i> - RNA _____	107

Figura 1-1 – Turbina Darrieus de duas lâminas _____	7
Figura 1-2 – Turbina Horizontal _____	8
Figura 1-3 – Componentes de um sistema eólico [4] _____	10
Figura 2-1 – Histograma da Velocidade do Vento _____	28
Figura 2-2 – Histograma da Direção do Vento _____	28
Figura 2-3 – Histograma da Temperatura do Ar _____	28
Figura 2-4 – Gráfico de Direção do Vento (entrada 2) x Velocidade do Vento (saída) _____	29
Figura 2-5 – Gráfico de Temperatura do Ar (entrada 3) x Velocidade do Vento (saída) _____	29
Figura 2-6 – Gráfico de Auto-Correlação da Velocidade do Vento _____	30
Figura 2-7 – Gráfico de Auto-Correlação Parcial da Velocidade do Vento _____	30
Figura 2-8 – Zoom do Gráfico de Auto-Correlação Parcial da Velocidade do Vento _____	30
Figura 2-9 – Gráfico de Correlação Cruzada da Direção do Vento com Velocidade do Vento ____	31
Figura 2-10 – Gráfico de Correlação Cruzada da Temperatura do Ar com Velocidade do Vento _	31
Figura 3-1 – Topologia de Rede [35] _____	35
Figura 3- 2 – Mínimos locais e Globais [37] _____	38
Figura 4- 1 – Previsão 24 horas à frente utilizando o método de persistência (2 casos de testes) __	44
Figura 4- 2 – Previsão 24 horas à frente utilizando a metodologia Box-Jenkins (2 casos de testes)	45
Figura 4- 3 – Previsão 24 horas à frente utilizando rede neural com 143 recursões – (a) sem direção do vento e (b) com direção do vento _____	47
Figura 4- 4 – Previsão 24 horas à frente utilizando 24 redes – (a) sem direção do vento e (b) com direção do vento _____	49
Figura 4- 5 – Previsão 24 horas à frente utilizando rede neural com 144 saídas – (a) sem direção do vento e (b) com direção do vento _____	50
Figura 4- 6 – Previsão 24 horas à frente utilizando rede neural com 6 saídas – (a) sem direção do vento e (b) com direção do vento _____	52
Figura 4- 7 – Esquema utilizado no modelo combinado _____	54
Figura 4- 8 – Previsão 24 horas à frente utilizando combinação de rede neural com 24 saídas para horas cheias e 1 saída para 10 minutos á frente (2 casos de testes) _____	55
Figura 4- 9 – Previsão 24 horas à frente utilizando combinação de rede neural com 24 saídas para horas cheias e 6 saída para 10 minutos (4 casos de testes) _____	57
Figura A-1 – Processo iterativo da metodologia Box-Jenkins [52] _____	80
Figura A-2 – Séries Temporais Estacionárias e Não-Estacionárias [54] _____	82
Figura A-3 – Arquitetura do Sistema ANFIS _____	94
Figura A-4 – Arquitetura do modelo simplificado de Sistemas Neuro Fuzzy _____	95
Figura A-5 – Constituição da célula neural _____	96
Figura A-6 – Representação do Neurônio Artificial _____	98
Figura A-7 – Exemplo de RNA _____	99
Figura A-8 – Exemplos de Funções de Ativação _____	101

Tabela 1-1 – Energia Eólica do PROINFA _____	12
Tabela 1-2 – Usinas do PROINFA _____	12
Tabela 2-1 – Tabela de Mínimo, Máximo e Média – São Martinho da Serra _____	27
Tabela 2-2 – Tabela de desvio padrão, skewness, kurtosis – São Martinho da Serra _____	29
Tabela 4- 1 – Erros obtidos nos testes executados. _____	58

1.1 Energia Eólica

Um dos grandes tormentos do mundo de hoje é a questão relativa à energia. O desafio energético mundial é satisfazer a crescente demanda de energia, proteger as fontes e, ao mesmo tempo, afrontar a ameaça igualmente urgente da mudança climática.

O aproveitamento de energia ainda não atingiu um nível satisfatório, visto que a imensa maioria de energia utilizada no planeta é de origem não renovável, seja de fonte mineral, atômica ou térmica. A energia pode ser utilizada de forma mais civilizada e menos dispendiosa, por meio de fontes renováveis como a energia eólica, solar, das marés, geotérmica, das águas e outras mais. As energias renováveis prometem ser fundamentais para a humanidade. Elas são seguras, limpas e abundantes. Ao contrário dos combustíveis convencionais, as energias renováveis têm disponibilidade em quase todos os países do mundo, sendo a energia eólica a de maior interesse na atualidade. [1]

Adicionalmente, com a crescente preocupação em torno das questões ambientais e devido aos impactos causados pelas formas tradicionais de geração de energia, vários países vêm investindo na complementação e transformação de seus parques energéticos com a introdução de fontes alternativas de energia. O desenvolvimento da energia eólica no mundo apresenta-se como uma das mais importantes e promissoras tecnologias na geração complementar de energia limpa. Dessa forma, vários governos estão traçando novas estratégias de fornecimento de energia elétrica a curto e a longo prazos devido à preocupação com o aumento do consumo de eletricidade nos últimos anos. Esta preocupação justifica um planejamento mais eficaz e rigoroso para essas estratégias, de forma a suprir as necessidades da população. Neste contexto, inserem-se as fontes renováveis de energia, as quais têm aumentado sua participação nos mercados e também deixando de se limitar a comunidades isoladas, seu principal nicho de aplicação no passado.

Nesse contexto, a energia eólica tem se tornado uma das fontes de energia renovável que mais se explora no mundo. Com o sensível crescimento de mercado a favor da energia eólica, nota-se queda nos preços dos aerogeradores ao longo das últimas décadas, tornando-a ainda mais competitiva com outras fontes de geração devido à evolução da tecnologia, das características operacionais aplicadas à energia eólica e não somente às questões de custo. O custo “zero” de seu combustível (ventos), baixo custo de manutenção, o curto espaço de tempo necessário para sua instalação e operação, entre outros fatores, vêm consolidando o espaço da energia eólica entre as demais fontes de energia. [2]

O desenvolvimento da humanidade através da utilização cada vez maior de fontes renováveis de energia minimizará os impactos ambientais. Em particular, melhorar a eficiência na produção de eletricidade significa melhorar o aproveitamento da energia disponível nos ventos para a produção de eletricidade e isto é de suma importância para a maioria dos países desenvolvidos e em desenvolvimento.

Embora o mercado de usinas eólicas ainda esteja vivenciando a primeira onda de crescimento no Brasil, ele já movimentava 2 bilhões de dólares no mundo. Considerando o grande potencial eólico do Brasil, confirmado através de estudos recentes, é possível produzir eletricidade a custos competitivos com centrais termoelétricas, nucleares e hidroelétricas [3].

1.1.1 Recurso Eólico

Energia eólica é uma forma de energia solar. Os ventos aliviam a temperatura atmosférica e as diferenças de pressão causadas pelo aquecimento irregular da superfície da Terra. Enquanto o sol aquece o ar, água e terra de um lado do planeta, o outro lado é resfriado por radiação térmica. Diariamente, a rotação da Terra espalha esse ciclo de aquecimento e resfriamento sobre sua superfície. Entretanto, nem toda superfície da Terra responde ao aquecimento da mesma forma. Por exemplo, um oceano se aquecerá mais lentamente que as terras adjacentes porque a água tem uma capacidade maior de “estocar” calor. Dessa diferente taxa de aquecimento e resfriamento são criadas enormes massas de ar com temperatura, mistura e características de massas de ar oceânicas ou

terrestres, ou quentes e frias. A colisão destas duas massas de ar, quente e fria, geram os ventos do planeta.

Uma estimativa da energia total disponível dos ventos ao redor do planeta pode ser feita a partir da hipótese de que, aproximadamente, 2% da energia solar absorvida pela Terra é convertida em energia cinética dos ventos. Este percentual embora pareça pequeno, representa centenas de vezes a potência anual instalada nas centrais elétricas do mundo. [4]

De uma forma geral, os movimentos das massas de ar na atmosfera (vento) processam-se em regime turbulento. Sendo assim, a velocidade instantânea do vento V é descrita simplesmente como um valor médio acrescido de um desvio a partir da média (flutuação), de acordo com a equação (1.1):

$$V = \bar{V} + v' \quad (1.1)$$

onde \bar{V} é a velocidade média do vento e v' é a flutuação. Na prática, para algumas aplicações, leva-se em consideração apenas a intensidade da velocidade média \bar{V} . A maioria dos instrumentos de medição, devido a sua configuração, “filtra” as flutuações e fornece somente o valor da velocidade média.

A velocidade do vento decresce à medida que se aproxima da superfície da terra devido à fricção entre o ar e o solo. A quantidade de decréscimo depende da rugosidade do solo; por exemplo, áreas florestais têm menor escoamento de ar que áreas descampadas. Medições em estações meteorológicas são geralmente tomadas em duas alturas-padrão: 2 metros (para propósitos agrícolas) e 10 metros (o padrão internacional para medições meteorológicas). Locais perto da costa geralmente têm velocidades do vento maiores do que as de uma ilha; a velocidade do vento numa ilha é cerca de 2/3 daquela próxima à costa.

As turbinas eólicas são máquinas que utilizam a energia cinética dos ventos, denominada energia eólica, permitindo a rotação de suas pás, e transformando essa energia em potência mecânica ou elétrica. Uma classificação básica de tais turbinas é feita segundo a posição do eixo do rotor. As denominadas Turbinas Eólicas de Eixo Horizontal possuem pás que giram num plano perpendicular à direção principal do vento. As Turbinas Eólicas de Eixo Vertical possuem suas pás girando num plano paralelo à direção do vento.

A turbina eólica é composta pelo rotor e pela torre que o sustenta, pela transmissão/multiplicação e pelo conversor. Ela pode extrair energia cinética somente do ar que passa através da área interceptada pelas pás rotativas. Embora combinada com a eficiência do modelo, a área varrida pelo rotor circular é um fator crucial na determinação da energia entregue pela turbina eólica. A energia cinética bruta por unidade de tempo, potência, do vento passando por uma área A perpendicular ao seu vetor velocidade instantânea V , é dada pela equação (1.2).

$$P = C_p \frac{1}{2} \rho \cdot A \cdot V^3 \quad (1.2)$$

onde:

ρ = densidade do ar, que varia com a latitude e as condições atmosféricas;

C_p = é o coeficiente da performance que se relaciona com a energia cinética de saída e depende do modelo e na relação entre a velocidade do rotor e a velocidade do vento e

V = velocidade do vento em m/s.

De acordo com a equação 1.2, pode-se observar que a energia potencial da turbina eólica depende do cubo da velocidade do vento; isto significa, por exemplo, que se a velocidade do vento em um local dobrar, a energia potencial de saída de uma turbina eólica é multiplicada por 8 (2^3). Esta sensibilidade da energia com a velocidade do vento mostra a importância na obtenção dos dados do vento para a estimativa da energia disponível.

Diversos fatores contribuem na complexidade do campo de escoamento das turbinas eólicas, com características acentuadamente não estacionárias. Entre os fatores mais importantes pode-se assinalar os seguintes:

- efeitos da camada limite atmosférica modificando a magnitude e direção da velocidade de corrente livre;
- giro num plano inclinado em relação ao vento principal, produzindo variações de ângulo de ataque;
- perturbações do fluxo de suporte e eixo do rotor;
- deformação estrutural das pás originando velocidades induzidas de translação e rotação dos elementos da pá;

- perdas aerodinâmicas por efeitos tridimensionais;
- formação da esteira do rotor (na parte de trás da turbina forma-se uma turbulência no vento com velocidade reduzida relativa ao vento incidente) e interação com as pás.

A direção do vento também é um importante parâmetro a ser analisado, pois mudanças de direção freqüentes indicam situações de rajadas de vento. Além disso, a medida da direção do vento auxilia na determinação da localização das turbinas em um parque eólico. Devido à existência do problema de “sombra”, isto é, a interferência das esteiras das turbinas, é fundamental o conhecimento da direção predominante.

Do ponto de vista do aproveitamento da energia eólica, é importante distinguir os vários tipos de variações temporais da velocidade dos ventos, a saber: variações anuais, sazonais, diárias e de curta duração. [4]

- **Variações Anuais** - Para se obter um bom conhecimento do regime dos ventos não é suficiente basear-se na análise de dados de vento de apenas um ano; o ideal é dispor de dados referentes a vários anos. À medida que uma maior quantidade de dados anuais é coletada, as características levantadas do regime local dos ventos tornam-se mais confiáveis.
- **Variações Sazonais** - O aquecimento não uniforme da superfície terrestre resulta em significativas variações no regime dos ventos, resultando na existência de diferentes estações do ano. Considerando que, em função da relação cúbica entre a potência eólica e a velocidade do vento (na altura do eixo da turbina), como pode ser observado na equação (1.2), em algumas faixas de potência, uma pequena variação na velocidade implica numa grande variação na potência. Sendo assim, a utilização de médias anuais (ao invés de médias sazonais) pode levar a resultados que se afastam da realidade.
- **Variações Diárias** - As variações diárias na velocidade do vento (brisas marítimas e terrestres, por exemplo) também são causadas pelo aquecimento não uniforme da superfície da Terra. Essas variações são importantes quando, após a escolha de uma região, procura-se o local mais adequado para a instalação do sistema eólico dentro dessa área. Ao

comparar a evolução da velocidade média ao longo do dia percebe-se que há uma significativa variação de um mês para os outros. Com esse tipo de informação pode-se projetar melhor o sistema eólico. Por exemplo, nos locais em que os ventos no período do dia são mais fortes do que os ventos no período da noite e a carga de pico ocorre durante o dia, a carga base pode ser fornecida pelo sistema existente e a carga adicional pelo sistema eólico. Entretanto, se a carga de pico ocorre durante a noite, provavelmente a demanda será maior que a geração disponível e um sistema de estocagem pode se fazer necessário.

- **Variações de Curta Duração** - As variações de curta duração estão associadas tanto às pequenas flutuações quanto às rajadas de vento. Num primeiro momento, essas variações não são consideradas na análise do potencial eólico de uma região, desde que não assumam grandes proporções. As flutuações e a turbulência do vento podem afetar a integridade estrutural do sistema eólico, devido à fadiga que ocorre especialmente nas pás da turbina. Por outro lado, as rajadas, caracterizadas por aumentos bruscos de curta duração da velocidade do vento, geralmente acompanhadas por mudanças de direção, merecem maior atenção, pois a previsão de rajadas em tempo real não se revela eficaz no controle da potência das turbinas eólicas.

1.1.2 Turbina Eólica

Acredita-se que foram os egípcios os primeiros a fazer uso prático do vento. Em torno do ano 2800 AC, eles começaram a usar velas para ajudar a força dos remos dos escravos. Eventualmente, as velas ajudavam o trabalho da força animal em tarefas como moagem de grãos e bombeamento de água. Com o passar dos anos, diversas civilizações utilizaram-se da energia do vento para diversas atividades. Logo as forças do vento e da água tornaram-se a fonte primária da energia mecânica medieval inglesa e holandesa para bombeamento de água, moagem de grãos e operações de serraria.

A geração de eletricidade pelo vento começou em torno do início do século XX, com alguns dos primeiros desenvolvimentos creditados aos dinamarqueses. Pelo ano de 1930, em torno de uma dúzia de firmas americanas estavam fazendo e

vendendo esses primitivos geradores eólicos, na maior parte aos fazendeiros. Tipicamente, estas máquinas poderiam fornecer até 1000 watts de corrente contínua quando o vento estava soprando.

Muitos países europeus começaram a construir desenhos avançados de geradores eólicos, durante os anos 1950 e 1960. Uma das mais memoráveis máquinas de vento foi construída perto de Rutland, Vermont – USA. Esta máquina de Smith-Putman com lâminas de 50 m foi desenhada para fornecer 1250 kW para a malha elétrica de Vermont.

O engenheiro francês Darrieus inventou a turbina de vento de eixo vertical, incluindo uma convencional de duas lâminas. Diferente das turbinas convencionais, que são reorientadas de acordo com o vento, esta é unidirecional, isto é, aceita o vento de qualquer direção vinda. Como o seu rotor e suas partes elétricas são na parte inferior da turbina, sua manutenção é muito mais prática, além de permitir uma variabilidade de aplicações elétricas e mecânicas maior que as demais. Estas lâminas curvadas são de maior durabilidade que as lâminas verticais, conforme pode ser observado na Figura 1-1

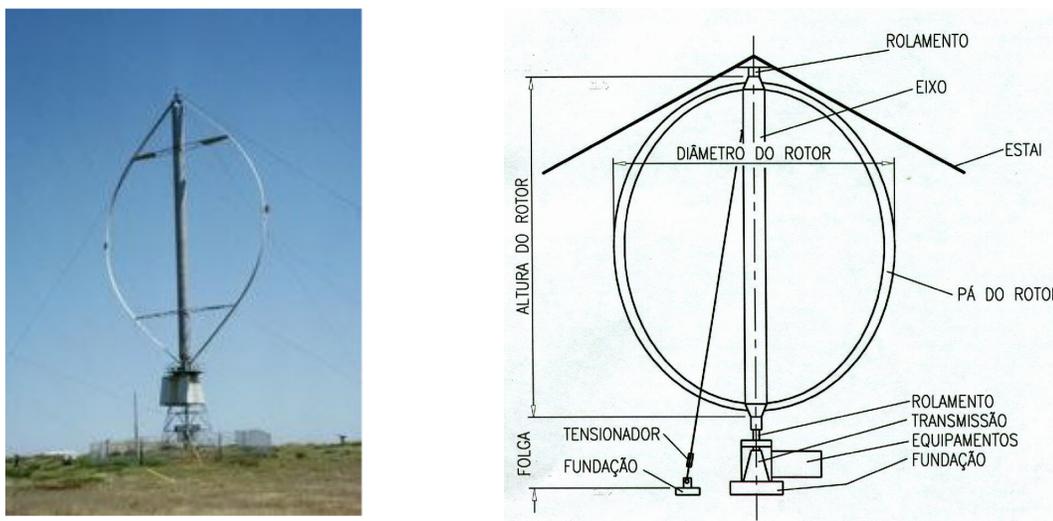


Figura 1-1 – Turbina Darrieus de duas lâminas

As modernas turbinas eólicas de eixo horizontal tiveram o seu advento, nas primeiras décadas do século XX, associado ao desenvolvimento da aerodinâmica dos aviões e, especialmente, dos hélices para a sua propulsão. Assim apareceram pequenas turbinas eólicas para carregamento de baterias e outros fins, que se

assemelhavam já às modernas turbinas eólicas de eixo horizontal com pequeno número de pás, como pode-se observar na Figura 1-2.

A primeira grande turbina eólica de eixo horizontal foi construída na Rússia em 1931, junto ao Mar Negro. Tinha um rotor de três pás, com um diâmetro de 30 m e uma potência nominal de 100 kW, e funcionou durante cerca de dois anos ligada à rede de CA.

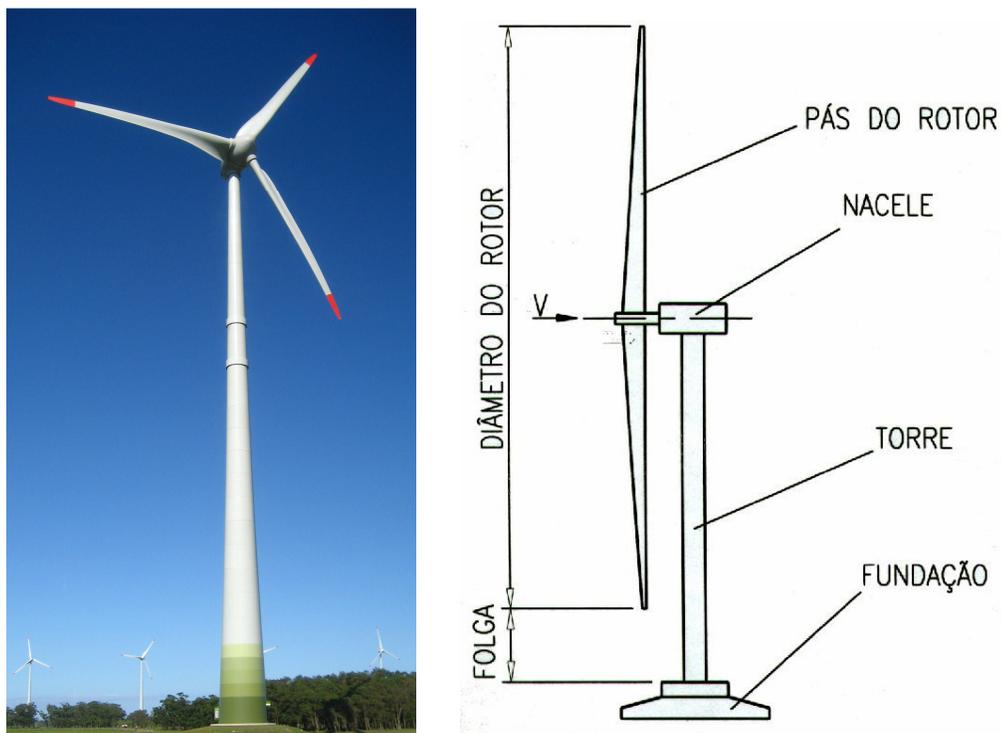


Figura 1-2 – Turbina Horizontal

Atualmente, a Dinamarca é o país que mais investiu em energia eólica. O país é responsável por 60% de toda demanda mundial de turbinas. Nos EUA, apenas 1% de toda energia produzida no país é eólica, mas espera-se que nos próximos 15 anos o vento possa ser responsável por 10% de toda energia norte-americana. [1]

1.1.3 Componentes do Sistema Eólico

O rendimento global do sistema eólico relaciona a potência disponível do vento com a potência final que é entregue pelo sistema. Os rotores eólicos, ao extraírem

a energia do vento reduzem a sua velocidade; ou seja, a velocidade do vento frontal ao rotor (velocidade não perturbada) é maior do que a velocidade do vento atrás do rotor (na esteira do rotor). Uma redução muito grande da velocidade do vento faz com que o ar circule em volta do rotor, ao invés de passar através dele. [4]

Existe uma regra que mostra a potência gerada pelos cata-ventos e turbinas de vento. A condição de máxima extração de energia verifica-se para uma velocidade na esteira do rotor 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 pode ser teoricamente extraída por uma turbina eólica.

Uma fórmula importante para se conhecer o aproveitamento da energia eólica é a potência (P) que é igual ao trabalho (W) dividido pelo tempo (Δt), e como o trabalho realizado pelo vento (W), é igual a sua energia cinética (E_c), a potência (P) fica:

$$W = E_c = \frac{mV^2}{2} \Rightarrow P = \frac{mV^2}{2 \cdot \Delta t} \quad (1.3)$$

e como

$$\frac{m}{\Delta t} = \dot{m} = \rho VA \Rightarrow P = \frac{\rho V^3 A}{2} \quad (1.4)$$

onde ρ é a densidade do ar, V é a velocidade do vento e A é a área varrida pelas hélices do rotor.

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). Além disso, o fato do rotor eólico funcionar em uma faixa limitada de velocidade de vento também irá contribuir para reduzir a energia por ele captada, que é necessária para vencer algumas perdas. Quando o sistema atinge a chamada velocidade de corte, um mecanismo de proteção é acionado com a finalidade de não causar riscos ao rotor e à estrutura do vento. Um sistema eólico tem o seu rendimento máximo a uma dada velocidade do vento (chamada de velocidade de projeto ou velocidade nominal). Nos sistemas eólicos, a velocidade de rotação ótima do rotor varia com a velocidade do vento. Projetar um sistema eólico, para um determinado tamanho de rotor e para uma carga pré-fixada, supõe trabalhar no intervalo ótimo

de rendimento do sistema com relação a curva de potência disponível do vento local. Isto requer encontrar uma relação de multiplicação, de maneira que se tenha um bom acoplamento rotor/carga. É necessário também, ter mecanismos de controle apropriados para melhorar o rendimento em outras velocidades de vento e aumentar o intervalo de funcionamento do sistema eólico.

Um exemplo de mecanismo de controle é a utilização de rotores com ângulo de passo variável. Com este controle, a medida que a velocidade do vento varia, as pás mudam de posição, variando o rendimento do rotor. Com isto, pode-se aumentar o intervalo de funcionamento do sistema eólico e ainda manter uma determinada velocidade de rotação, correspondente a eficiência máxima do gerador. Como uma primeira aproximação, o rendimento global de um sistema eólico simples pode ser estimado em 20%.

A Figura 1–3 abaixo apresenta os componentes de um sistema eólico.

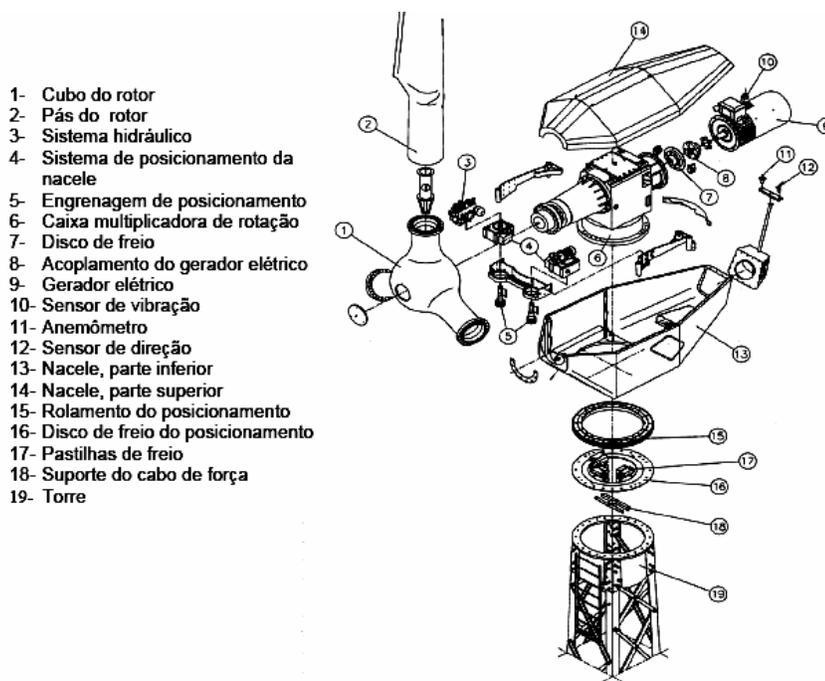


Figura 1–3 – Componentes de um sistema eólico [4]

1.1.4 No Brasil

No Brasil, embora o aproveitamento dos recursos eólicos tenha sido feito tradicionalmente com a utilização de cataventos multipás para bombeamento d'água, algumas medidas precisas de vento, realizadas recentemente em diversos pontos do território nacional, indicam a existência de um imenso potencial eólico ainda não explorado.

Um passo pioneiro no estudo da energia eólica no Brasil foi a elaboração do atlas eólico do nordeste, publicado pelo Centro Brasileiro de Energia Eólica (CBEE) com o apoio da Agência Nacional de Energia Elétrica (ANEEL), em 1998. Outro marco foi o Atlas do Potencial Eólico Brasileiro, lançado pelo Centro de Pesquisas Elétricas (CEPEL), órgão filiado a ELETROBRÁS [5]. Vários esforços vêm sendo empregados no sentido de ampliar o conhecimento sobre a capacidade eólica do país, com a confecção de atlas eólicos por alguns Estados como, por exemplo, o Rio Grande do Sul (2002), Ceará (2001), Bahia (2001), Rio de Janeiro (2003). [6]

O alto potencial eólico do Brasil [5] estimulou a criação do PROINFA (Programa de Incentivo às Fontes Alternativas de Energia) através da Lei 10.438 de 2002, que atualmente estabelece a instalação de parques eólicos com potências de aproximadamente 454 MW no Sul, 483 MW no Nordeste e 163 MW no Sudeste do Brasil, para atingir, em um prazo de 20 anos na 1ª Etapa do Programa, 10% de penetração de energia alternativa no sistema elétrico através de fontes de energia eólica, pequenas centrais hidrelétricas e biomassa e na 2ª Etapa do Programa, 1% da demanda incremental de energia no Brasil também por fontes alternativas. [7][8]

Antes do PROINFA, a capacidade instalada no Brasil era de 20,3 MW, com instalações eólicas de nos estados do Ceará, Pernambuco, Minas Gerais e Paraná. Em junho de 2007, 5 novas usinas já somavam mais 210 MW na potência instalada no Brasil. Até o final de 2008, espera-se a entrada de mais 51 empreendimentos somando uma potência em torno de 1.200 MW, sendo que apenas um empreendimento já começou com as obras, conforme Tabela 1-1 e Tabela 1-2. [9]

Tabela 1-1 – Energia Eólica do PROINFA

	Usinas (UEE)	Potência (MW)
Contratada	54	1.422,92
Operação	5	208,30
Construção	1	10,20

junho/2007

Tabela 1-2 – Usinas do PROINFA

	Status	Potência (MW)	Localidade
Rio do Fogo	Operação	49,30	RN
Osório	Operação	50,00	RS
Sangradouro	Operação	50,00	RS
Dos Índios	Operação	50,00	RS
Água Doce	Operação	9,00	SC
Millennium	Construção	10,20	PB

junho/2007

A razão pela qual a geração eólica é a fonte de energia renovável de maior crescimento é a baixa relação custo/benefício de exploração, em relação a outras fontes de energia renovável como a hidrelétrica. Diversos fatores contribuem com a redução desta relação. Dentre os mais importantes, podem ser citados o avanço tecnológico e o aumento de investimentos (proporcionando ganhos de escala na fabricação dos equipamentos); a crescente preocupação com o meio ambiente; e principalmente, as políticas governamentais de incentivos à geração de energia elétrica renovável e desenvolvimento da tecnologia como é o caso do PROINFA. [2]

Contudo, o grande problema que existe na realização de pesquisas com energia eólica é a falta de dados adequados, uma vez que o ideal é se obter dados a partir de torres eólicas situadas em locais adequados. Estes dados devem consistir de, no mínimo, intensidade e direção do vento em uma determinada altura. Como a instalação de torres eólicas demanda tempo e dinheiro, e como é inviável instalá-las e mantê-las em alta densidade em todo o território brasileiro, tornou-se necessário utilizar produtos de modelos numéricos que representam com alguma aproximação a topografia, as feições da superfície, os processos atmosféricos e assim fornecem valores em pontos de grade, desta forma suprimindo um pouco a falta das torres eólicas.

Atualmente, as vantagens mais relevantes das usinas eólicas são: [10][11][12]

- fonte nativa e renovável;
- não contaminante ao contrário da nuclear, pois não utiliza combustível e não produz emissões de gases de dióxido de carbono;
- licenças ambientais facilitadas ao contrário da hidrelétrica;
- rapidez de implantação em grande escala, pois são modulares e de rápida instalação;
- compatível junto a outros usos da terra (agricultura ou indústria);
- os recursos eólicos do mundo, viáveis de serem utilizados, são maiores que a demanda mundial de energia;
- complementaridade a energia hidráulica;
- ampliação do desenvolvimento sócio-econômico local;
- redução de perdas de transmissão.

Ademais de vantagens, notadamente as desvantagens da energia eólica são:

- emissão de ruídos (devido ao funcionamento mecânico e ao efeito aerodinâmico);
- impacto visual (efeito de sombras em movimento e reflexões intermitentes);
- impacto ambiental (alguns parques podem estar localizados em zonas de migração de aves);
- interferências eletromagnéticas (reflexões de ondas);
- custo ainda não totalmente competitivo;
- o aproveitamento desta tecnologia ainda não é satisfatoriamente elevado;
- geração de harmônicos que dificultam a conexão com a rede interligada.

1.2 Estado da arte na previsão de vento

Previsão é uma ferramenta vital para o planejamento no ambiente competitivo dos dias atuais, assim como a utilização de fontes alternativas para diversificação da matriz energética brasileira. A principal fonte alternativa em crescimento é a que utiliza a energia proveniente do vento. Todavia, a usina eólica é a que apresenta as maiores dificuldades de previsão de potência gerada devido às características dos ventos.

A principal característica da série temporal das medições de vento (velocidade e direção) é sua grande variabilidade, e é exatamente essa característica que pode dificultar o planejamento, a operação e a estabilidade do Sistema Interligado Nacional (SIN).

Para minimizar estas dificuldades, faz-se necessário criar modelos de previsão de vento que sejam compatíveis com as necessidades do setor elétrico. Hoje ainda não existe um sistema de previsão que seja apropriado para a previsão de ventos.

1.2.1 Considerações gerais

Diversas técnicas são aplicadas para a previsão de séries temporais. As mais usadas são os modelos estatísticos como regressão linear, persistência (método que realiza uma previsão simples em que o valor previsto é calculado através do último valor da série) e outros. No entanto, alguns autores já vem apresentando estudos que visam a previsão de vento utilizando modelos baseados em sistemas inteligentes como redes neurais artificiais (RNA) [13][14][15][16][17] e lógica *fuzzy* [18][19][20], já apresentando melhores resultados.

Os estudos de previsão de vento vêm sendo obtidos juntamente com os de previsão de geração eólica, que depende principalmente do vento, e estes estudos são realizados tanto para o curto prazo [21] (algumas horas adiante) como para o longo prazo (até alguns dias adiante). A grande maioria dos trabalhos apresentados encontra-se na Europa, que já está bem avançada em relação à geração eólica. Esses trabalhos podem ser divididos de acordo com o horizonte de previsão e os métodos de previsão utilizados.

Os horizontes de previsão são descritos por Potter [18] e [19] como: curto prazo – algumas horas até alguns dias adiante e curtíssimo prazo – alguns minutos até uma hora adiante, e são apresentadas três classes de técnicas identificadas para previsão de vento, que são explicitadas nos itens 1.2.2, 1.2.3 e 1.2.4c, respectivamente:

- NWP – Numerical Weather Prediction;
- Métodos estatísticos tradicionais e;
- Métodos baseados em RNA – Redes Neurais Artificiais

1.2.2 NWP – Numerical Weather Prediction

O método NWP predomina na literatura meteorológica e é baseado em modelos matemáticos da mecânica de fluidos. O NWP é o modelo mais utilizado para previsão de vento. Porém, os métodos estatísticos tradicionais (ANEXO A) e RNA baseados em observação de desempenho já estão apresentando bons resultados para previsões em horizontes muito curto (alguns minutos), além de serem mais simples que o NWP.

O NWP trabalha com soluções numéricas de equações de massa, momento, calor, entre outras, em determinadas localizações. O mesmo utiliza-se de modelos complexos e demora muitas horas para obter a solução mesmo em computadores de grande porte. O comportamento da atmosfera é previsto utilizando condições atuais e passadas. De acordo com essas características, o NWP é utilizado por laboratórios meteorológicos tanto na Europa como nos EUA e sua precisão está relacionada com a resolução do *grid* de medições de condições do ambiente. A resolução do *grid* para previsões do vento é muito maior do que as usadas para previsão meteorológica e dependendo do local, a complexidade do terreno afeta os dados do vento.

As principais vantagens para utilização do NWP são:

- precisão para previsão de diversos dias à frente;
- podem ser utilizados para diversas localizações;
- procedimentos bem estabelecidos;

e as desvantagens são:

- sistema complexo para operar;
- pouca precisão para horizontes curtos (de minutos até uma hora).

O que faz o método NWP não funcionar para tempos curtos são as altas variações de velocidade do vento em espaço de tempo bem pequeno. Na verdade, este nível de variação é o que dificulta a precisão nos diversos modelos de previsão.

1.2.3 Métodos estatísticos tradicionais para previsão de vento e potência eólica

Na literatura encontra-se a clássica análise de séries temporais para previsão, utilizando a metodologia de Box-Jenkins (ANEXO A) para modelos ARIMA(p,d,q). Estes são modelos auto-regressivos (AR), integrado (I) e de média móvel (MA) onde p, d e q são as ordens destes modelos.

Tantareanu [22] relata que o modelo ARMA (ANEXO A) tem uma performance 30% melhor que o método de persistência para previsões para minutos à frente que utilizam médias de 4 segundos. Schwartz e Milligan [23] apresentam modelos ARMA para previsões até 6 horas a frente e concluem que a performance dos modelos são altamente dependentes do período de treinamento.

Nielsen [24] apresenta que, para previsões de horizonte curto (menos de quatro horas), o modelo estatístico ARX (auto regressivo com entrada *exogenous*) ajustado a partir de medidas *on-line* de potência gerada e velocidade do vento combinados com previsões meteorológicas realizam uma boa predição de produção de energia em uma fazenda eólica.

Para a previsão de horizonte muito curto (de minutos), os métodos estatísticos que utilizam os dados atuais de vento apresentam melhor precisão do que os NWP. Estes métodos também são indicados para previsões de até algumas horas, porém os mesmos se apresentam muito simples para períodos longos, começando a produzir resultados mais pobres para previsões que passam de 5 horas.

As principais vantagens para utilização de métodos estatísticos são:

- precisão para tempos curtos (de minutos até uma hora);

- adaptação da situação atual através de algoritmos recursivos;
- previsão de médias e picos em curto prazo;

e as desvantagens são:

- imprecisão para longos períodos;
- precisam da ajuda de um especialista para cada local específico.

1.2.4 Métodos estatísticos utilizando sistemas inteligentes

Atualmente, nenhum método de previsão de vento a horizonte muito curto tem recebido o aceite da indústria. Especialistas das indústrias afirmam que os modelos estatísticos são impraticáveis de implementar devido a modelos individualizados para cada usina eólica. Por isso, o estudo de previsão de vento é uma área em crescimento e tem-se envolvido cada vez mais o uso de sistemas inteligentes nestas pesquisas.

Na literatura, encontram-se muitos trabalhos visando a previsão de vento envolvendo sistemas inteligentes e os principais métodos são:

a. Sistemas *FUZZY*

Damousis [20] apresenta um sistema *fuzzy* para modelos de correlação espacial para previsão de vento e potência.

Esta previsão utiliza dados de dois locais vizinhos com distância de até 30 km e é feita a previsão de até duas horas adiante utilizando um sistema *fuzzy*, obtendo resultados muito melhores do que os de persistência para terrenos “*flats*”. Já para terrenos complexos, o desempenho do sistema cai um pouco, mas mesmo assim fica em torno de 10-25% melhor do que o método de persistência.

b. Sistemas Neuro-*Fuzzy* (ANFIS)

Atualmente, além de não existirem modelos de previsão de tempo em horizonte muito curto na indústria, existe também pouquíssima literatura sobre este assunto. Tem-se usado Redes Neurais Artificiais (RNA) para intervalos de previsão menores que 10 minutos. Porém para o gerenciamento de potência eólica é

necessária a previsão de 2-3 minutos para gerenciar a saída de potência devido a rajadas. Potter [19] apresenta um artigo que mostra uma previsão de 2,5 minutos a frente utilizando o modelo híbrido ANFIS do “Matlab *Fuzzy Toolbox*”. Este modelo combina o baixo nível computacional da rede neural com o alto nível do sistema de inferência *fuzzy*.

O modelo ANFIS proposto atua da seguinte forma: primeiramente, o sistema funciona como uma rede neural realizando um treinamento com um grande conjunto de dados de entrada para, então, operar como um sistema *fuzzy*. São utilizados dados de meio mês para treinamento e de meio mês para teste medidos a cada 2,5 minutos. Após consulta à indústria os dados de velocidade e direção foram convertidos em um vetor (u-v), considerado somente um vetor em certa altura da torre. Os resultados das simulações utilizando o método ANFIS (erro médio de 3%) supracitado apresentaram grande ganho quando comparando com o método de persistência (erro médio de 40%).

As principais vantagens do ANFIS são:

- usar a habilidade da rede neural para classificar dados e identificar padrões;
- desenvolver um sistema com menor propensão a memorizar dados;
- manter as vantagens do sistema *fuzzy* sem precisar de um grande especialista.

Uma desvantagem é o grande número de dados necessários para se ter um sistema preciso.

c. Redes Neurais Artificiais

Alexiadis [14] apresenta modelos de correlação espacial para previsão de vento e potência utilizando redes neurais. Dados de dois locais vizinhos de até 40 km de distância são usados para se obter uma previsão através de redes neurais e dessa forma, se obter resultados de previsões de alguns minutos até algumas horas 20-40% melhores que os do método de persistência.

Shuhui Li [16] utiliza dados coletados numa fazenda eólica dos EUA e desenvolve um modelo em redes neurais para prever a potência gerada em cada turbina de uma fazenda eólica. Como o vento sofre diversas variações devido à localização, a previsão para turbinas de uma mesma fazenda varia bastante e apresenta grande

dificuldade de previsão. Os dados utilizados foram obtidos em duas torres meteorológicas com média de velocidades e direção do vento a cada 10 minutos. A geração de energia de cada turbina também foi disponibilizada para o mesmo período. A usina eólica desta simulação apresenta doze turbinas e foi construída uma rede neural para cada turbina, diminuindo o tamanho e a complexidade de cada rede. As redes neurais foram treinadas com 1500 pares de Março de 1996 e os erros de teste foram em torno de 1% para o mês de Março e em torno de 2% para o mês de Abril na realização de previsões de 10 minutos à frente. Nos resultados obtidos, observou-se que os erros utilizando o modelo tradicional ficaram acima de 3% nos dois meses.

As principais vantagens para utilização de métodos de RNA são:

- precisão para horizontes curtos;
- aprendem padrões históricos para prever padrões futuros;
- previsão de médias e picos em curto prazo;
- requerem pouco entendimento da dinâmica das variáveis de tempo;

e as desvantagens são:

- imprecisão para longos períodos;
- requerem longos períodos na base de dados;
- requerem redes individuais para cada local de previsão.

Barbounis [8] observa que previsões na faixa de alguns segundos são usadas para controle de turbinas eólicas e previsões de vento na faixa de minutos até algumas horas são usadas para programação do sistema de energia. Porém, para ambos os casos prevê a utilização de modelos de Redes Neurais Artificiais (RNA). Modelos similares vêm sendo aplicados para previsões diárias, semanais e até mensais. Barbounis apresenta uma previsão de 3 dias à frente com dados de direção e velocidade de vento em 4 locais vizinhos, utilizando 3 modelos de redes neurais, a saber:

- IIR-MLP: consiste de neurônios onde os pesos da sinapse são substituídos por filtros lineares de respostas ao impulso infinito (IIR), que também se referem aos modelos ARMA;
- LAF-MLN: a saída do neurônio é filtrada através de um filtro auto-regressivo (AR) antes de alimentar a função de ativação;

- DRNN: consiste em uma rede de duas camadas, onde a camada escondida contém neurônios “*self-recurrents*” enquanto que a camada de saída é composta de neurônios lineares.

Nesta simulação, utilizou-se dados de direção e velocidade do vento e dados de pressão e temperatura do ar como entradas das redes e a previsão foi realizada para o horizonte 72 horas à frente. Foram utilizados conjuntos de 3264 pares para treinamento e 960 para validação. Para se avaliar a performance de cada modelo de previsão foram usados os métodos erro de média absoluta (*mae – mean absolute error*) e raiz do erro médio quadrático (*rmse – root mean square error*). Para se ter convergência mais rápida foi empregado um algoritmo de aprendizado ótimo: o algoritmo de identificação de erro de predição recursivo (RPE). Dois novos algoritmos foram apresentados, o RPE global (GRPE), onde todos os pesos são simultaneamente atualizados, e o RPE desacoplado (DRPE) que divide o problema do GRPE em pequenos grupos. Após as simulações, os resultados conseguidos utilizando GRPE como treinamento apresentaram melhor performance para as redes locais tendo os menores erros para a rede IIR-MLP. Os resultados utilizando o método DRPE apresentaram uma performance um pouco melhor. Os resultados gerais foram os mesmos: melhores resultados para as redes locais, sendo a IIR-MLP a rede com menores valores de erros.

1.2.5 Outros Previsores

Outras previsões foram encontradas na literatura, entretanto estas focam outros objetivos que não a geração de energia elétrica.

Huang [25] utiliza o modelo auto-regressivo (AR) usando filtro de Kalman para estimar os parâmetros. Este algoritmo é usado para prever ventos de uma hora até algumas horas. O objetivo do estudo é desenvolver um método para prever velocidade de ventos que poderá ser usado para o controle ótimo em tempo real do aquecimento de uma estufa. O conjunto de dados contém 2024 valores horários de velocidade do vento na Inglaterra e cobre o período de inverno entre 1987 e 1988. Sendo o processo de velocidade de vento não estacionário, é razoável que se utilize o modelo auto-regressivo (AR) variável no tempo para simular a velocidade do vento. Com os resultados obtidos, conclui-se que um modelo AR variante no tempo pode ser usado para prever a velocidade do vento algumas

horas à frente, sendo usado em tempo real para controle do computador da estufa com o objetivo de controle ambiental.

Schlink [26] apresenta um estudo que contempla a previsão utilizando o modelo auto-regressivo (AR) para melhorar a acurácia da previsão dos ventos costais. Este estudo foi motivado para permitir operações seguras durante pousos de aviões após o pouso de grandes aeronaves que geram um redemoinho cujas trilhas são intensas e duráveis. O conjunto de dados foi obtido no aeroporto de Frankfurt em diversas ocasiões entre 1984 e 1996. Neste trabalho, concluiu-se que a análise de autocorrelação se constitui em uma excelente ferramenta para previsão do vento, o que fez tornar-se possível a modelagem AR para previsão do vento e também permitiu-se que se fizesse uma previsão do vento confiável através das 5 últimas medidas da velocidade do vento. Nos resultados, o método AR apresentou uma confiança de 97,5% enquanto o método de persistência apresentou 95%, utilizando o mesmo comprimento do intervalo de confiança de 95%.

1.2.6 Ferramentas de previsão de vento

Algumas ferramentas são usadas comercialmente para a previsão de potência em fazendas eólicas, dentre elas.

a. WPPT – Wind Power Prediction Tool

WPPT [19][21][27][28] é uma ferramenta desenvolvida na Dinamarca e está em operação desde 1996. Este programa é usado para previsões de curto prazo (até 5 dias a frente) de geração de energia eólica e também informa suas incertezas de predições. O sistema é flexível e pode ser configurado para cobrir a geração total de um país (é utilizado na Dinamarca), de uma região ou de uma simples fazenda eólica.

As entradas do WPPT são:

- medidas *on-line* de energia eólica;
- previsões meteorológicas de direção e velocidade do vento e temperatura do ar através de modelos NWP e;
- número de turbinas ativas.

O WPPT é baseado em modelos estatísticos não lineares. Seu conjunto de modelos inclui um modelo de curva de potência semi-paramétrica para fazendas eólicas considerando velocidade e direção do vento.

Esses modelos são auto-calibráveis e adaptáveis. Desta forma, eles levam em consideração automaticamente as mudanças no número de turbinas e nas suas características, e também mudanças não explícitas como rugosidade e sujeiras nas pás e mudanças no modelo NWP.

b. Predictor

Predictor [21][29] é uma ferramenta que utiliza modelos físicos desenvolvidos na Dinamarca e em operação desde 1997. Os padrões de tempo são previstos por um modelo NWP (direção e velocidade do vento e temperatura do ar) de maneira global e, desta forma, se torna necessário que se faça um ajuste utilizando um modelo WAsP. O modelo WAsP consiste em um programa para calcular a influência dos efeitos do local (orografia, rugosidade e obstáculos).

Sabe-se que nenhum modelo pode simular a natureza perfeitamente, então utilizam-se dois filtros MOS (*model output statistics*) para corrigir algumas variações. Os dados de geração de energia de uma fazenda eólica são usados para ajustar os parâmetros destes filtros. A saída deste programa é a geração de energia esperada para uma usina eólica a cada 3 horas para 48 horas a frente.

c. Zephyr

Zephyr [30][31] é uma ferramenta que também está sendo desenvolvida na Dinamarca e consiste uma combinação dos modelos WPPT e Predictor. Os principais motivos que levaram ao desenvolvimento deste novo programa foi combinar dois sistemas existentes de modo a se obter uma melhor performance além de incluir as vantagens de novas tecnologias como a implementação do Java com comunicação via *internet*.

O modelo Zephyr utiliza 4 tipos de dados de entrada: previsões meteorológicas a cada seis horas do instituto meteorológico da Dinamarca, medidas meteorológicas a cada 5 minutos, velocidade e

direção do vento medidas no parque eólico e dados horários de energia do sistema elétrico da área. Este último dado é usado para estimar a curva de potência do parque.

O programa combina os métodos de previsão com medidas *on-line* de geração de energia e entradas NWP (direção e velocidade do vento e temperatura do ar) com medidas *off-line* de um modelo utilizando dados NWP, ajustados pelo modelo WAsP. O modelo final total é calculado a partir de uma média ponderada dos dois resultados acima utilizando ponderação baseado em raiz quadrática (*Root Mean Square*).

1.2.7 Resumo dos Principais Trabalhos

– NWP – Numerical Weather Prediction

- Predomina na literatura meteorológica;
- Baseado em modelos matemáticos de equações de massa, momento, calor, entre outras, em determinadas localizações;
- Modelos complexos e demora muitas horas para obter a solução mesmo em computadores de grande porte;
- Precisão está relacionada com a resolução do grid de medições de condições do ambiente.

– Modelos Estatísticos Tradicionais

- Metodologia de Box-Jenkins para modelos ARIMA (p,d,q). Estes são modelos auto-regressivos (AR), integrado (I) e de média móvel (MA);
- Boa precisão para tempos curtos (de minutos até uma hora);
- Trabalhos desenvolvidos:
 - Previsão de minutos à frente em médias de 4 s, apresentando melhora de 30% em relação ao método de persistência;
 - Previsões até 6 horas à frente, apresentando ganho de 11% em relação à persistência.

– Modelos Estatísticos Inteligentes

- Trabalhos desenvolvidos:
 - 10 % ganho em relação a persistência para 2 horas à frente utilizando sistema fuzzy com correlação espacial;
 - Sistema neuro-fuzzy para previsão 2,5 minutos a frente para gerenciar a saída de potência devido a rajadas – erro de 3% contra 40 % do persistência;
 - RNA para previsão de vento de 1 minuto a 120 minutos com melhora de 5 a 20 % em relação a persistência.

1.3 Motivação e Objetivo

A energia eólica vem apresentando um crescimento significativo no mundo e apesar de ainda estar sendo pouco aproveitada no Brasil, já existem diversos projetos que incentivam o uso desta energia como fator de diversificação na matriz energética brasileira que é essencialmente hidrelétrica e dependente do regime pluviométrico sazonal. Um dos programas mais importantes no incentivo do aumento da produção de energia elétrica através da fonte eólica é o PROINFA (Programa de Incentivo a Fontes Alternativas) que consiste em um programa do governo que incentiva a utilização de fontes alternativas como Biomassa, Pequenas Centrais Elétricas (PCH) e Eólicas que prevê uma instalação até 2008 de 1,1 MW de geração utilizando a energia dos ventos. Com a entrada das usinas, contratadas no âmbito do PROINFA, em funcionamento e a conexão delas com o Sistema Interligado Nacional (SIN), será importante que seja possível realizar uma previsão de potência disponível destas usinas para um despacho otimizado da geração no SIN.

Como no Brasil não existe um banco de dados de histórico de geração de energia eólica e poucos dados de vento medidos em pontos estratégicos para geração de energia eólica, a previsão de vento vem se tornando um desafio. Sabendo-se que estes estudos vêm sendo desenvolvidos com sucesso em países como Dinamarca, Austrália, Portugal, Espanha, Alemanha, entre outros, com a utilização de métodos inteligentes, este trabalho apresenta o desenvolvimento de um algoritmo para realizar a previsão de vento utilizando redes neurais artificiais.

Esta previsão utiliza dados de uma região no Sul do país, de uma área indicada como propensa à geração de energia eólica [5]. Estes dados são disponibilizados pelo Projeto Sonda do INPE (Instituto Nacional de Pesquisas Espaciais) da estação de Referência de São Martinho da Serra – RS [32]. O algoritmo desenvolvido utiliza a ferramenta MATLAB e o resultado é a previsão do vento (velocidade do vento) a cada 10 minutos para 24 horas à frente.

Inicialmente foi apresentada uma breve explanação sobre a potencialidade da energia eólica e o estado da arte destes estudos. Em seguida, uma revisão teórica dos modelos de previsão e de redes neurais aplicadas à previsão de vento será apresentada. Para completar serão mostrados os estudos feitos com a base de dados mencionada e apresentada a simulação do algoritmo desenvolvido com seus resultados e conclusões.

ANÁLISE EXPLORATÓRIA DAS SÉRIES DE VENTO

2.1 *Base de Dados*

A análise exploratória de dados tem como objetivo verificar o comportamento do conjunto de dados para orientar na escolha do modelo de previsão. Nesta análise será verificada a representatividade do conjunto de dados para o problema proposto e fará os ajustes necessários para otimizar a previsão [33].

2.1.1 Apresentação

Para realização deste trabalho, utilizou-se as bases de dados disponibilizada pelo Projeto SONDA - Sistema de Organização Nacional de Dados Ambientais que é um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) para implementação de uma infra-estrutura física e de recursos humanos destinada a levantar e melhorar a base de dados dos recursos de energia solar e eólica no Brasil [32].

Foram usados os dados ambientais da estação de Referência de São Martinho da Serra – RS. Os dados medidos são: direção média do vento (0° a 360° horários), temperatura do ar (°C) e velocidade média do vento (m/s) medidos na altura de 50 metros de 10 em 10 minutos durante o ano todo de 2005 (janeiro a dezembro), totalizando 52.560 registros.

A seguir serão apresentados os resultados da análise dos dados realizadas para saber como se comporta a base de dados utilizada neste trabalho. Para esta análise, utilizou-se a ferramenta computacional MATLAB.

2.1.2 Descrição dos dados

A base de dados está dividida em cinco colunas com as seguintes informações:

- Variável 1: velocidade do vento (m/s)
- Variável 2: direção do vento (0° a 360° em relação ao N geográfico)
- Variável 3: temperatura do ar (°C)
- Variável 4: mês (1 a 12)
- Variável 5: horário do dia (min.)

2.1.3 Mínimos, máximos e médias

Na Tabela 2-1 apresenta-se os mínimos, máximos e médias das variáveis principais utilizadas na previsão.

Tabela 2-1 – Tabela de Mínimo, Máximo e Média – São Martinho da Serra

	Var. 1	Var. 2	Var. 3
Média	6,50 m/s	136,03 °	18,36 °C
Mínimo	0 m/s	0,01 °	1,68 °C
Máximo	22,88 m/s	360,00 °	33,27 °C

2.1.4 Histogramas

Histogramas são diagramas de frequência para um conjunto de dados, onde o eixo das abscissas representa o conjunto dos possíveis valores ou faixas (classes) de valores de uma variável. No eixo das ordenadas temos a informação de frequência dos valores desta variável. Os histogramas são representações gráficas do comportamento de uma variável.

Nas Figura 2-1, Figura 2-2 e Figura 2-3 observam-se os comportamentos das variáveis velocidade do vento, direção do vento e temperatura do ar.

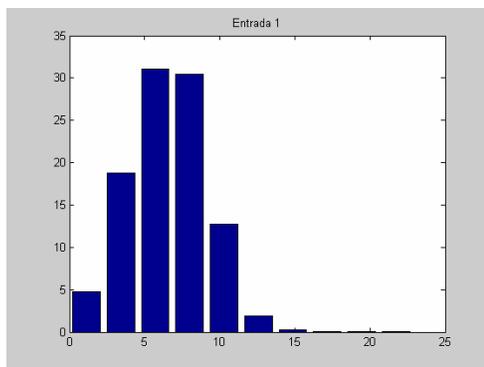


Figura 2-1 – Histograma da Velocidade do Vento

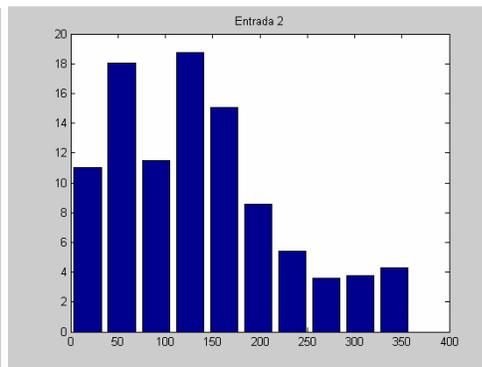


Figura 2-2 – Histograma da Direção do Vento

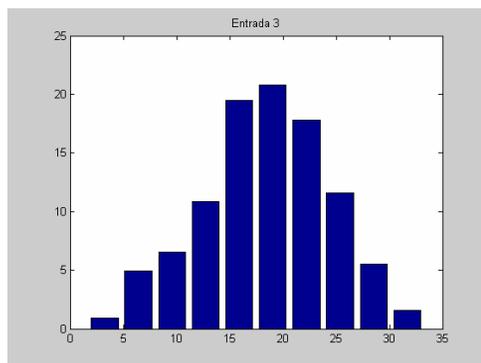


Figura 2-3 – Histograma da Temperatura do Ar

2.1.5 Desvio padrão, variância, simetria e curtose

Na Tabela 2-2, apresenta-se desvio padrão, variância, simetria e curtose das variáveis principais utilizadas na previsão. Estas são medidas que ajudam na análise da distribuição dos dados.

Desvio padrão é a medida mais comum da dispersão estatística, e a variância também é uma medida da dispersão estatística de uma série, indicando quão longe em geral os seus valores se encontram do valor esperado. E a variância é igual ao valor do desvio padrão ao quadrado.

Simetria é uma medida que mostra a simetria de dados da distribuição de probabilidade de uma variável. Uma curva normal apresenta simetria igual a zero, enquanto que um valor negativo indica dados deslocados para a direita (cauda negativa longa) e valores positivos indicam dados deslocados para a esquerda (cauda positiva longa).

Curtose é uma medida de achatamento da distribuição dos dados. Uma medida negativa indica um achatamento em relação à curva normal e uma medida positiva indica picos ou um alongamento em relação à curva normal.

Tabela 2-2 – Tabela de Desvio padrão, simetria, curtose – São Martinho da Serra

	Var. 1	Var. 2	Var. 3
Desvio Padrão	2,5268	86,5217	5,8847
Variância	6,38	7486	34,63
Simetria	0,0903	0,6826	-0,1803
Curtose	2,8677	2,8497	2,6391

2.1.6 Gráficos de entrada x saída

Os gráficos das Figura 2-4 e Figura 2-5, demonstram o comportamento das variáveis direção do vento e temperatura do ar em comparação a saída velocidade do vento. Pode-se observar que as séries são complexas com muitas variações em espaços curtos de tempo.

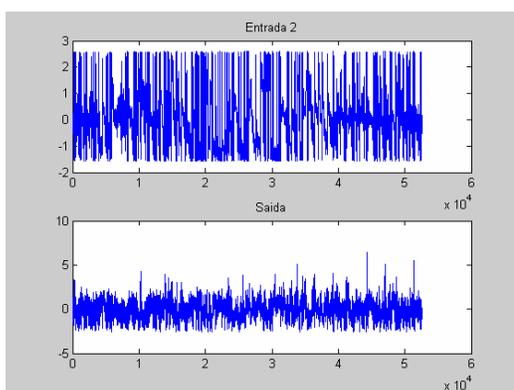


Figura 2-4 – Gráfico de Direção do Vento (entrada 2) x Velocidade do Vento (saída)

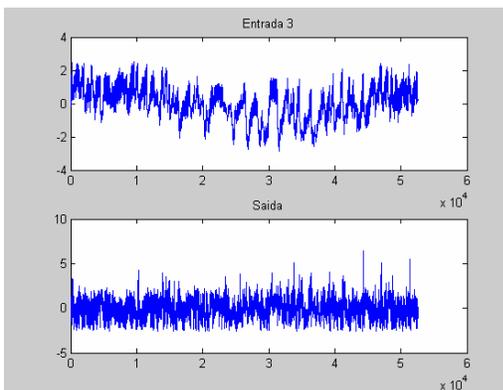


Figura 2-5 – Gráfico de Temperatura do Ar (entrada 3) x Velocidade do Vento (saída)

2.1.7 Autocorrelação da variável – velocidade do vento

Nas Figura 2-6 e Figura 2-7 apresenta-se a autocorrelação e autocorrelação parcial da velocidade do vento. No gráfico de autocorrelação parcial apresenta-se ainda um ponto acima do intervalo de confiança no nono lag como pode-se observado na Figura 2-8.

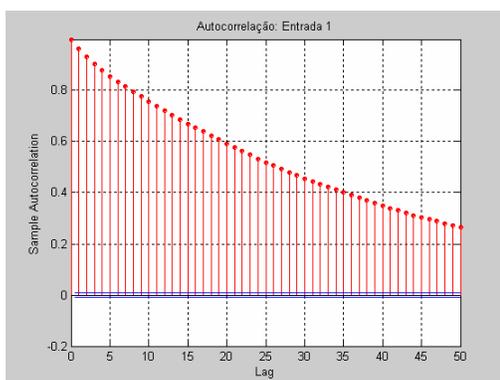


Figura 2-6 – Gráfico de Auto-Correlação da Velocidade do Vento

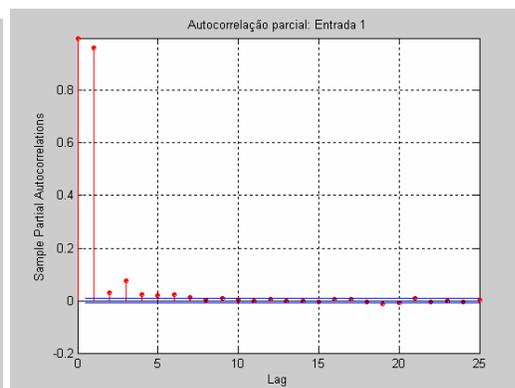


Figura 2-7 – Gráfico de Auto-Correlação Parcial da Velocidade do Vento

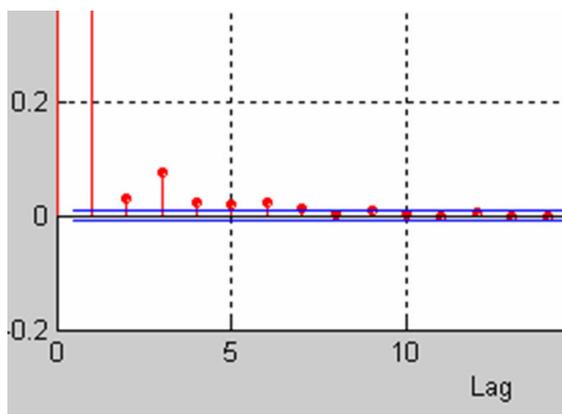


Figura 2-8 – Zoom do Gráfico de Auto-Correlação Parcial da Velocidade do Vento

2.1.8 Correlação cruzada

Nas Figura 2-9 e Figura 2-10 apresenta-se a correlação cruzada das variáveis: direção do vento e temperatura do ar com a velocidade do vento. Para a modelagem de redes neurais neste trabalho, foi considerado como um valor mínimo significativo de correlação, o valor de 0,3. Valores menores que este não terão influência no treinamento da rede.

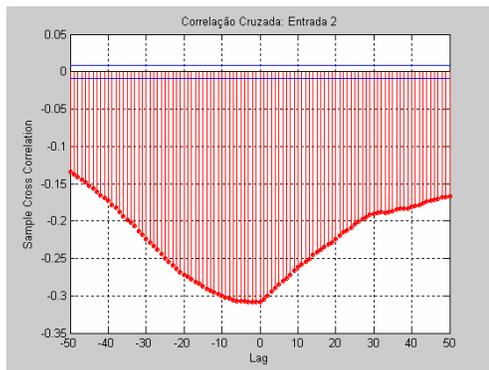


Figura 2-9 – Gráfico de Correlação Cruzada da Direção do Vento com Velocidade do Vento

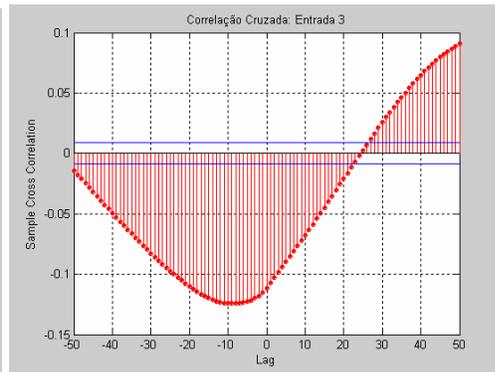


Figura 2-10 – Gráfico de Correlação Cruzada da Temperatura do Ar com Velocidade do Vento

2.2 Análise dos Dados

Nos histogramas das Figura 2-1, Figura 2-2, Figura 2-3 e nas Tabela 2-1 e Tabela 2-2, percebe-se que os dados de velocidade do vento estão concentrados em torno da média com uma pequena concentração pra esquerda (simetria = 0.09). O valor de curtose para uma distribuição normal é 3, e as três variáveis apresentam valores menores, porém próximos de 3.

Nas Figura 2-4 e Figura 2-5 podemos observar a grande variação que a velocidade do vento apresenta.

De acordo com a Figura 2-6 e verifica-se uma forte autocorrelação da velocidade do vento com os *lags* e na Figura 2-7 de autocorrelação parcial apresenta valores significativos até 6 valores passados e ainda percebe-se que no nono *lag* (Figura 2-8), ainda apresenta um valor acima do limite de confiança.

Na Figura 2-9, verifica-se que a correlação dos dados de direção do vento até 9 *lags* passados apresenta valores maiores que 0,3, que foi considerado o valor mínimo de correlação para justificar influência da variável no treinamento da rede neural.

De acordo com a Figura 2-10, percebe-se que a variável de temperatura do ar não tem uma correlação significativa com a variável velocidade do vento (valores menores que 0.3), sendo assim retirada do modelo de previsão.

No próximo capítulo, é apresentado o estudo da rede neural que será utilizada nas simulações da previsão do vento, se baseando nesta análise para montagem da topologia da rede.

REDES NEURAIIS PARA PREVISÃO DE VENTO

3.1 Considerações Gerais

As Redes Neurais apresentam um modelo capaz de realizar previsão de séries temporais. Dessa forma, esses modelos são amplamente utilizados no setor elétrico para previsões de vazões, previsões de demanda e outros. Contudo, no tocante à previsões de vento, ainda encontram-se poucos estudos na literatura mundial e pouquíssimos no Brasil.

O aspecto extremamente motivador para esta dissertação foi o fato da quase inexistência, até então, de um trabalho publicado no Brasil relativo à previsão de ventos a partir de um modelo de Rede Neural Artificial.

3.2 Topologia da rede neural

Para montagem da rede neural utilizada na previsão de tempo, é preciso definir o tipo de rede a ser modelada, para isso é necessário conhecer a topologia da rede neural.

3.2.1. Perceptron Multi-Camadas (MLP)

O MLP com aprendizado baseado no algoritmo de retro-propagação é o modelo mais utilizado em áreas como reconhecimento de padrões, processamento de fala e na previsão de séries temporais, que é objeto desta dissertação [14] [16] [17].

O modelo do perceptron multi-camadas utiliza uma topologia de três ou mais camadas – uma de entrada, uma (ou mais) intermediária e uma de saída. Entre uma camada e outra, existe uma matriz de pesos. A regra de propagação é a combinação entre as saídas de cada unidade e a matriz de pesos. Ela é realizada através da soma ponderada de cada sinal que chega, via conexões, pelo respectivo peso. O estado de ativação assume valores contínuos e devido a isto a regra de ativação das unidades utiliza como função de ativação uma função do tipo sigmóide. A função sigmóide também se faz necessária pela regra de aprendizado

que utiliza uma função de ativação contínua, não-decrescente e diferenciável.

Neste trabalho para a previsão de ventos, foram usadas as redes MLP com aprendizado do tipo retro-propagação onde os pesos são atualizados através da propagação do erro gerado na camada de saída minimizado pela regra do gradiente decrescente.

O aprendizado representado pelo algoritmo de retro-propagação é do tipo supervisionado. Ou seja, apresenta pares de entrada e saída. Utiliza o vetor de entrada e produz sua própria saída, comparando-a com a saída alvo (real). Se não houver diferença, não há mudanças. Caso contrário, os pesos serão modificados com o objetivo de reduzir esta diferença.

3.2.2. Metodologia para Definição da Arquitetura

A metodologia proposta para a modelagem da arquitetura (topologia) da rede neural (Perceptron Multi-Camadas) deve ser capaz de realizar prognósticos confiáveis sobre valores futuros de séries temporais. A questão que se procurou responder foi qual o tamanho ótimo para a rede de treinamento. Neste sentido, são apresentados resumidamente a seguir dois estudos empíricos que se dedicaram a estudar soluções para a questão da topologia da rede [34].

a. Determinação da Camada de Entrada da Rede

Em [35], que trata da previsão de séries mensais, encontra-se uma proposta de metodologia onde se procura modelar a entrada da rede de maneira a captar as componentes da série temporal, sugerindo utilizar as seguintes entradas:

- i) valores passados da série: como foi visto no estudo de correlação apresentado no capítulo 2, para este trabalho foram utilizados nove pontos atrasados de entrada;
- ii) valores passados referentes ao mesmo mês em anos anteriores, visando captar tendências ou ciclos da série: no caso do presente trabalho, a base de dados apresenta somente dados de um ano;

- iii) grupo de doze unidades binárias para captar a sazonalidade da série, tais como 100000000000 para o mês de janeiro, 010000000000 para fevereiro e assim sucessivamente, até 000000000001 para o mês de dezembro: no presente trabalho não só foram utilizados estas doze variáveis binárias, como também mais 24 para identificar a hora do dia em que se faz a previsão, já que entende-se que a força do vento pode variar no decorrer do dia, ou seja, o vento apresenta características durante o dia diferente das apresentadas a noite.

A Figura 3–1 apresenta de forma esquemática a topologia de uma RNA utilizando-se a abordagem de Varsis e Versino [35].

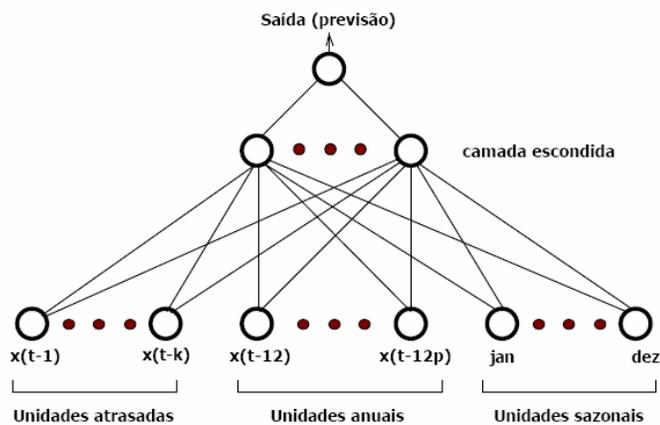


Figura 3–1 – Topologia de Rede [35]

b. Determinação da Camada Escondida de Rede

Muitos autores, como Caudill [36], apresentam o número de unidades das camadas escondidas como incógnita e simplesmente afirmam que o tamanho da camada escondida é escolhido usando o bom senso: se a camada for muito grande, a rede estará memorizando os padrões e com isso perdendo a capacidade de generalização, por outro lado, se a camada for muito pequena, a rede levará muito mais iterações para atingir a precisão desejada. Quando a RNA memoriza um certo conjunto de dados ela vai apresentar pequenos erros de previsão para o período amostral, mas grandes erros para previsões fora da amostra. Em [37], afirma-se que a rede que melhor generaliza os dados é a menor rede apta a realizar o treinamento dos dados.

3.2.3. Algoritmo de Retro-Propagação

O algoritmo de retro-propagação (*backpropagation*) é utilizado para o treinamento do MLP para a realização de prognósticos de valores futuros de séries temporais.

Dentro dos algoritmos de treino supervisionados, o mais popular e mais usado é o algoritmo de retro-propagação ou seus derivados [38]. Este algoritmo prevalece como um marco para a comunidade de RNA, já que constitui um método eficiente de computação para o treino de RNA, procurando o mínimo da função de erro no espaço de procura dos pesos das ligações entre neurônios, baseando-se em métodos de gradiente decrescente. A combinação de pesos que minimiza a função de erro é considerada a solução para o problema de aprendizagem. Dado que este método exige o cálculo do gradiente, torna-se necessário que a função de erro (ξ) seja contínua e diferenciável, o que acontece quando se usam as funções de ativação diferenciáveis [39].

A aplicação do algoritmo de retro-propagação pode ser descrita nos passos a seguir [40]:

- Em frente, onde o vetor de entrada é fornecido aos neurônios de entrada da rede, propagando-se em frente, camada por camada, em que o integrador utiliza a função adição, como na equação 3.1.

$$u_i = \sum_j s_j w_{ij} \quad (3.1)$$

em que $s_0=1$ (valor de entrada da conexão de bias), $s_1=x_1, \dots, s_n=x_n$, para n neurônios de entrada. Em seguida, calcula-se o erro, com base na função de custo, normalmente dada pela equação 3.2.

$$\xi = \frac{1}{2} \sum_{k \in S} (y_{k-n_{ei}} - s_k)^2 \quad (3.2)$$

onde y denota o vetor de saída desejado, S o conjunto de neurônios de saída da rede e n_{ei} o somatório dos neurônios de entrada e intermediários. Durante esse passo, os pesos da rede estão fixos.

- Retro-Propagação: onde o erro é propagado para trás, desde a saída até os neurônios de entrada. Em seguida, os pesos são ajustados segundo a regra de *Widrow-Hoff* [41]. Para um único peso, tem-se como na equação 3.3.

$$\Delta w_{ij}(t) = -\eta * \frac{\delta \xi}{\delta w_{ij}}(t) \quad (3.3)$$

em que t refere-se a uma iteração ou época (do inglês *epoch*) do algoritmo de treino e η denota a taxa de aprendizagem. As derivadas parciais são calculadas segunda as equações 3.4 e 3.5.

$$\frac{\delta E}{\delta w_{ij}} = \frac{\delta \xi}{\delta s_i} \frac{\delta s_i}{\delta w_{ij}} \quad (3.4)$$

onde

$$\frac{\delta s_i}{\delta w_{ij}} = f a'(u_i) s_j \quad (3.5)$$

Para se obter $\frac{\delta \xi}{\delta s_i}$, onde seja, a influência da saída s_i do neurônio i no erro

global ξ , é necessário atender ao tipo de neurônio como na equação 3.6.

$$\frac{\delta \xi}{\delta s_i} = \begin{cases} -(y_{i-n_{ei}} - s_i) & , i \in S \\ \sum_{j \in succ(i)} \frac{\delta \xi}{\delta s_j} f a'(u_j) w_{ji} & , i \notin S \end{cases} \quad (3.6)$$

onde *succ(i)* representa o conjunto dos neurônios j da camada com que o neurônio i se relaciona (ou estabelece ligações).

Antes de se iniciar o treino de uma rede, tem-se que proceder a escolha dos valores iniciais dos pesos associados às ligações entre neurônios, que deverão ser pequenos e gerados de forma aleatória. Pode-se então partir para o treino da rede, começando-se por selecionar um caso de treino, na forma iterativa, ou todos os casos, na forma em lote (do inglês *batch*). Normalmente, convém que esta seleção seja aleatória. Em seguida, calcula-se o gradiente e ajustam-se os pesos. Uma iteração termina quando todos os casos disponíveis tiverem sido considerados.

O processo é dado como terminado pela aplicação de critérios de parada (por exemplo quando as mudanças nos pesos e na função de erro forem insignificantes). Nota-se que o algoritmo pode convergir para um mínimo local (Figura 3– 2). Na prática, porém, constata-se que quando se parte de um número elevado de casos de treino, esta questão não se coloca, ou então não se assume como um problema sério.

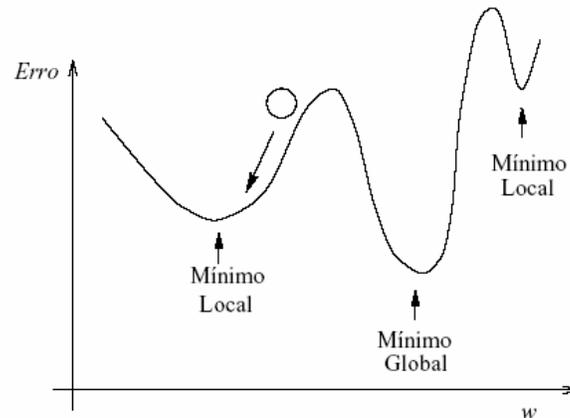


Figura 3– 2 – Mínimos locais e Globais [37]

3.2.4. Pré-Processamento dos Dados

O pré-processamento dos dados deve ser seriamente considerado antes de treinar uma rede. Embora não seja essencial em certos casos, torna-se vital em outros. São várias as operações em que se pode desdobrar o pré-processamento [42] [43].

- Verificação da Integridade dos Dados: Trata-se de um procedimento de validação dos dados, verificando-se se existem erros de alguma espécie. Neste trabalho, esta verificação já foi realizada pelo próprio Projeto Sonda [32];
- Representação dos Dados: Esta fase envolve uma conversão de dados. Dado que as RNA apenas lidam com números, os dados terão que ser codificados, por exemplo, utilizando uma representação binária ou decimal. Para este trabalho não foi necessário, visto que os dados utilizados já são numéricos;

- Escalonamento dos Dados: O objetivo deste procedimento é realizar uma transformação nos dados de modo a acelerar e melhorar o processo de aprendizagem. Este escalonamento depende do tipo de dados:

(i) Entradas: O escalonamento das variáveis de entrada tem diversos efeitos conforme os distintos algoritmos de aprendizagem. De um modo particular, algoritmos de gradiente descendente, como o conhecido RP, são bastante sensíveis ao escalonamento. Assim, cada variável de entrada deve ser escalonada de forma a que a sua média sobre o conjunto de casos de treino esteja à volta do valor zero, pelo que o escalonamento para o intervalo [-1,1] funcionará melhor do que para o intervalo [0,1]. Existem duas formas eficientes de realizar este escalonamento:

- Média 0 e Desvio Padrão 1, como na equação 3.7.

$$y = \frac{x - \bar{x}}{\text{std}(x)} \quad (3.7)$$

onde \bar{x} denota a média de x e $\text{std}(x)$ o desvio padrão de x , isto é,

$$\text{std}(x) = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}, \text{ para } n \text{ exemplos de treino.}$$

- Valor Mínimo -1 e Valor Máximo 1, como na equação 3.8.

$$y = \frac{x - (\text{max} + \text{min})/2}{(\text{max} - \text{min})/2} \quad (3.8)$$

em que min e max representam o mínimo e máximo da variável x .

(ii) Saídas: Existem duas fortes razões para escalonar as saídas. Em primeiro lugar, quando se usa mais de uma saída e se a função de erro é sensível à escala, como acontece no caso da aprendizagem do

gradiente descendente, então a diferença de escalas entre as saídas pode afetar a forma como a rede aprende. Por exemplo, se uma saída tem valores entre 0 e 1 enquanto outra tem valores entre 0 e 1000000, então o algoritmo de treino irá despender a maior parte do seu esforço na aprendizagem da segunda saída. Assim, as saídas que têm a mesma importância devem ser escalonadas para a mesma escala. Neste caso, deve-se executar um escalonamento com a mesma escala ou desvio padrão (usando, por exemplo, a equação 3.7).

Em segundo lugar, pode-se querer ajustar as variáveis de saída aos valores do contradomínio da função de ativação (por exemplo, a função logística produz valores de saída dentro do domínio [0,1]). Neste caso, é importante conhecer os limites máximos e mínimos da variável em vez dos valores máximos e mínimos dos casos de treino. Neste caso pode-se utilizar a equação 3.9 para um escalonamento no domínio [A,B] sendo L_{max} e L_{min} os limites máximo e mínimo da variável. Se a variável de saída tiver limites desconhecidos, então é preferível utilizar a função linear (ou outra não limitada) para os neurônios de saída.

$$y = \frac{(x - L_{min})(B - A)}{L_{max} - L_{min}} + A \quad (3.9)$$

Neste trabalho, tanto as variáveis de entrada como as de saída estão sendo escalonadas com média igual a zero e desvio padrão igual a um, como mostrado na equação 3.7.

3.2.5. Rede Inicial dos Testes de Previsão de Vento

Com base nos estudos feitos com a base de dados disponível, foi modelada a rede neural para iniciar os testes com a seguinte configuração:

- 54 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas binárias (0 ou 1) para identificar a hora do dia, 9 entradas de velocidade do vento e 9 de direção do vento, ambas do instante k até $k-8$;
- 2 saídas: Velocidade e direção do vento no instante $k+1$;

- Tipo de treinamento: traingdx (utiliza o gradiente decrescente para propagar para trás o erro) [44];
- Função de ativação: função de ativação sigmoidal (logsig) para a camada intermediária e puramente linear (purelin) para a camada de saída;
- Neurônios na camada intermediária: quatro;
- Número de épocas: 10.000.

Outras configurações serão estudadas e simuladas para identificação da melhor topologia de rede para execução da rede neural.

Os resultados destes testes estão apresentados no capítulo 4.

TESTES E RESULTADOS

Após os estudos que foram apresentados nos capítulos 2 e 3, pode-se relatar neste capítulo todos os testes realizados para configurar a melhor rede para realização da previsão de 24 horas à frente para uma série temporal de dados do vento.

Diversas configurações foram usadas e se avaliou o tipo de treinamento, o número de neurônios na camada intermediária, a função de ativação e também se os dados de direção do vento eram significantes para a previsão. Para verificação dos modelos, utilizou-se o erro médio absoluto percentual – MAPE (*Mean Absolute Percentage Error*) de acordo com a equação (4.1):

$$\text{MAPE} = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{v_i - p_i}{v_i} \right| \cdot 100\% \quad (4.1)$$

onde N é o número de passos à frente previstos (N=144 para este trabalho),

v_i é o valor medido e

p_i é o valor previsto.

Utilizou-se a base de dados apresentada no capítulo 2 e todos os dados foram utilizados para o treinamento, exceto os 3 últimos dias de cada mês que foram usados para realização dos testes e validação do modelo. Sendo assim, todas as simulações realizadas apresentarão 36 casos de testes.

Os estudos foram realizados para os tipos de treinamento *traingdx* (gradiente decrescente) e *trainbr* (regularização bayesiana) [44] e os resultados com *trainbr* apresentaram “sombra” no treinamento, resultando em previsões ruins, e com tempo de treinamento longos. Este efeito de “sombra” apresenta a curva de previsão exatamente igual à curva de entrada de 10 minutos passados, deslocada um passo à frente, ou seja, nada mais que a repetição do dado anterior como previsão, o que é equivalente ao método de persistência. Sendo assim, a montagem de uma complexa rede neural para se obter resultados idênticos ao método de persistência não se justifica.

Os estudos também variaram a utilização da função de ativação na camada intermediária entre logsig (sigmoidal de logaritmo) e tansig (sigmoidal tangente) e os resultados não apresentaram nenhuma diferença que recomendasse o uso de uma delas em detrimento da outra.

Após estes testes preliminares foram realizadas as simulações para definir a melhor configuração de rede e avaliar a influência dos dados de direção de vento e da variação do número de neurônios na camada intermediária

4.1 Testes iniciais

Inicialmente foram realizados testes com um dos métodos de persistência (descrito a seguir) para comparação de resultados.

Para todos os casos apresentados a seguir, o número de neurônios nas camadas intermediárias indicado faz parte da configuração que apresentou os melhores resultados após diversas simulações. Para se definir a melhor configuração utilizou-se o método de tentativa e erro variando o número de neurônios para valores mais baixos e mais altos.

Na maioria dos casos, o número de 10.000 épocas foi suficiente para que o erro nos testes ficasse praticamente constante. E no caso da rede com 144 saídas, 5.000 épocas já foram suficientes para atingir este ponto, não sendo necessário continuar até 10.000 épocas para não aumentar o tempo de processamento.

O tempo de treinamento dos casos apresentados a seguir variou entre 30 minutos à uma hora. No caso da rede de 144 saídas, o tempo de treinamento da rede ultrapassou às 4 horas. O treinamento para o caso em que se apresenta 24 redes neurais também foi longo, durando em torno de 12 horas, mas isso se deve ao treinamento seqüencial das redes propostas, problema que facilmente seria resolvido por processamento em paralelo, visto que as redes possuem dados que não dependem uma da outra.

4.1.1. Persistência – 144 passos à frente defasados de 10 minutos

Inicialmente, para efeito de comparação, foi realizada a previsão de 144 passos à frente (24 horas) aplicando o método de persistência da seguinte maneira:

- Passo 1: calcular a distância euclidiana entre os 144 pontos do dia anterior ao dia que se deseja prever com os 144 pontos dos dias que estão no arquivo de treinamento.
- Passo 2: ordenar os valores da distância euclidiana e selecionar o de menor valor.
- Passo 3: definir como a previsão desejada os 144 pontos do dia seguinte ao dia selecionado no passo 2.

O erro médio obtido nos 36 casos de testes foi de 58.90 %. A Figura 4- 1 apresenta o resultado da previsão de 144 passos à frente para 2 casos de teste:

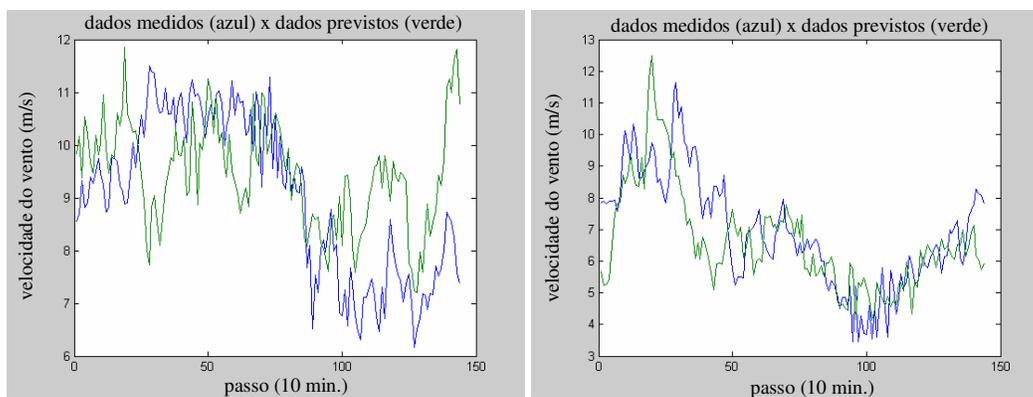


Figura 4- 1 – Previsão 24 horas à frente utilizando o método de persistência (2 casos de testes)

4.1.2. Metodologia Box-Jenkins – 144 passos à frente defasados de 10 minutos

Também para efeito de comparação, foi realizada a previsão de 144 passos à frente (24 horas) aplicando a metodologia Box-Jenkins através do programa comercial Forecast Pro, no modo automático.

O erro médio obtido nos 36 casos de testes foi de 50.45 %. A Figura 4-2 apresenta o resultado da previsão de 144 passos à frente para 2 casos de teste:

Podemos observar que a qualidade dos resultados é muito ruim, pois os resultados variam muito pouco até o sexto ponto e a partir do sétimo ponto, a previsão tende para uma média.

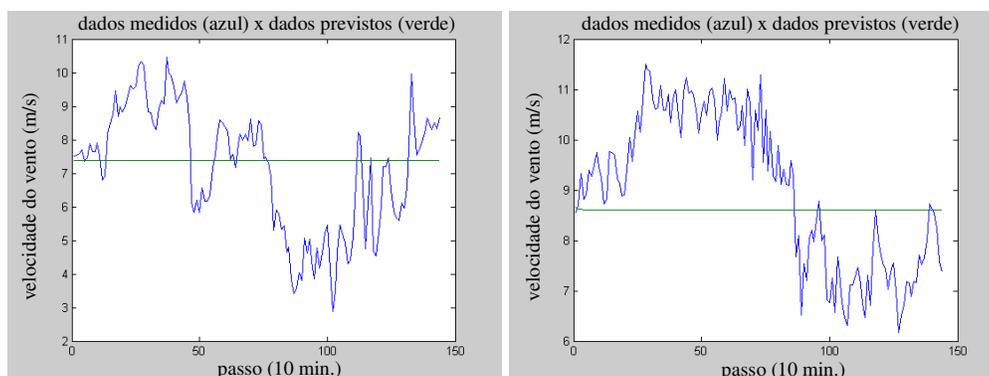


Figura 4- 2 – Previsão 24 horas à frente utilizando a metodologia Box-Jenkins (2 casos de testes)

4.1.3. 1 Rede – 1 saída 10 minutos à frente

O primeiro teste foi realizado com a rede neural treinada para uma saída 10 minutos à frente e o teste foi realizado com 143 recursões da mesma rede. O treinamento apresenta as seguintes configurações:

Entradas	Sem direção do vento - 45 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas binárias (0 ou 1) para identificar a hora do dia, 12 entradas de velocidade do vento do instante k até k-8, k-142, k-143, k-144 (estes 3 pontos cercam o mesmo ponto do dia anterior e ajudam a identificar o comportamento no mesmo instante do dia); Com direção do vento - 54 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas binárias (0 ou 1) para identificar a hora do dia, 12 entradas de velocidade do vento e 12 de direção do vento, ambas do instante k até k-8, k-142, k-143, k-144 (estes 3 pontos cercam o mesmo ponto do dia anterior e ajudam a identificar o comportamento no mesmo instante do dia).
Saídas	Sem direção do vento - 1 saída: Velocidade do vento no instante k+1; Com direção do vento - 2 saídas: Velocidade e direção do vento no instante k+1.
Tipo de treinamento	Traingdx (gradiente decrescente).
Função de ativação	Sigmoidal (logsig) para a camada intermediária e linear (purelin) para a camada de saída.
Neurônios na camada intermediária	4
Épocas	10.000

Os testes foram realizados sem os dados de direção do vento, e depois, foi repetido o teste utilizando-se a direção do vento e o erro médio obtido nos 36 casos de testes foi de 49,78 % para o primeiro e 45,27 % para o segundo.

Neste primeiro modelo, os resultados apresentam uma pequena melhora quando os dados de direção do vento são utilizados. Também observamos nos resultados que a recursão do modelo neural 143 vezes apresenta melhores resultados do que o modelo de persistência.

Os gráficos da Figura 4- 3 mostram casos de testes onde os resultados acompanham a tendência do vento no decorrer do dia.

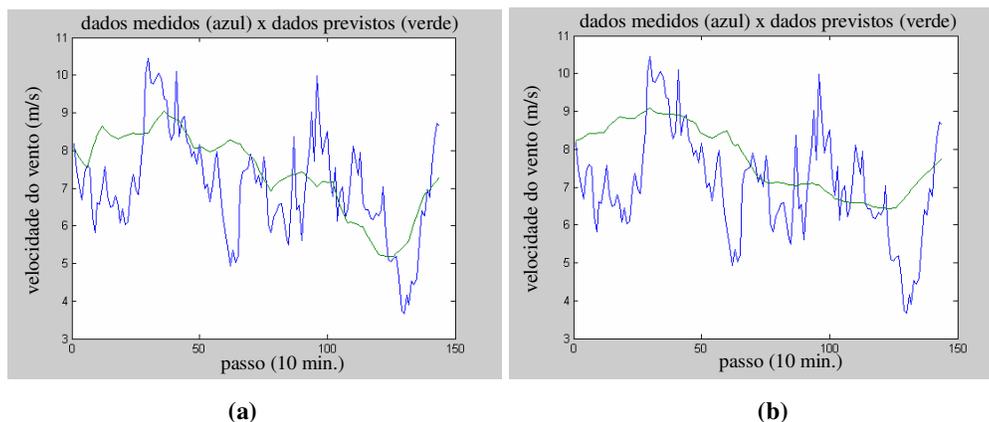


Figura 4- 3 – Previsão 24 horas à frente utilizando rede neural com 143 recursões – (a) sem direção do vento e (b) com direção do vento

4.1.4. 24 Redes – uma rede para cada hora à frente

No teste seguinte, foram criadas 24 redes para realização de previsões do seguinte tipo: a primeira rede prevê a velocidade e a direção do vento para $k + 1$, a segunda rede prevê para $k + 7$, a terceira prevê $k + 13$ e assim por diante até a vigésima-quarta rede que prevê para o instante $k + 139$.

Sendo assim cada rede criada será responsável pela previsão de cada hora à frente, sempre utilizando os mesmos dados de entrada. Como serão realizadas recursões para previsão de todos os 6 passos de uma hora, será necessário atualizar os dados de entrada nas execuções dos testes. Para os testes que foram feitos utilizando os dados de direção do vento, a primeira rede, que prevê os pontos da primeira hora à frente, também prevê os dados de direção do vento para que sejam utilizados na atualização dos dados de entrada durante as recursões.

Desta maneira, os testes realizados foram executados da seguinte maneira:

- inicialmente, realiza-se a primeira previsão de cada rede, obtendo assim, o primeiro valor previsto para cada hora à frente;
- os valores de velocidade de vento e direção de vento obtidos na primeira rede são incorporados no arquivo de entrada;

- realiza-se novamente a previsão de todas as 24 redes, obtendo o segundo valor previsto para cada rede;
- repete o segundo e terceiro passo até se obter os seis valores de cada rede, formando assim os valores previstos para cada hora à frente.

A configuração utilizada é a seguinte:

Entradas	Sem direção do vento - 21 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 9 entradas de velocidade do vento do instante k até k-8. Com direção do vento - 30 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 9 entradas de velocidade do vento e 9 de direção do vento, ambas do instante k até k-8.
Saídas	Sem direção do vento - 1 saída: Velocidade do vento no instante k+1, k+7, k+13, ..., k+139, respectivamente para cada uma das 24 redes. Com direção do vento - a primeira rede apresenta 2 saídas (velocidade e direção do vento) no instante k+1 e as demais redes apresentam somente velocidade do vento nos instantes k+7, k+13, ..., k+139
Tipo de treinamento	Traingdx (gradiente decrescente).
Função de ativação	Sigmoidal (logsig) para a camada intermediária e linear (purelin) para a camada de saída.
Neurônios na camada intermediária	4
Épocas	10.000

A simulação feita sem os dados de direção de vento e o erro médio obtido para os 36 casos de testes foi de 49,45%, enquanto que a simulação com os dados de direção do vento apresentou o erro médio dos testes de 56,21 %. Os resultados mostram que a utilização de dados de direção do vento em redes para prever velocidades mais de uma hora à frente não foi satisfatória. Também observamos que os resultados não são melhores do que o da rede do item 4.1.2.

Os gráficos da Figura 4- 4 apresentam o resultado da previsão de 144 pontos à frente utilizando uma rede para cada hora à frente para 2 casos de teste.

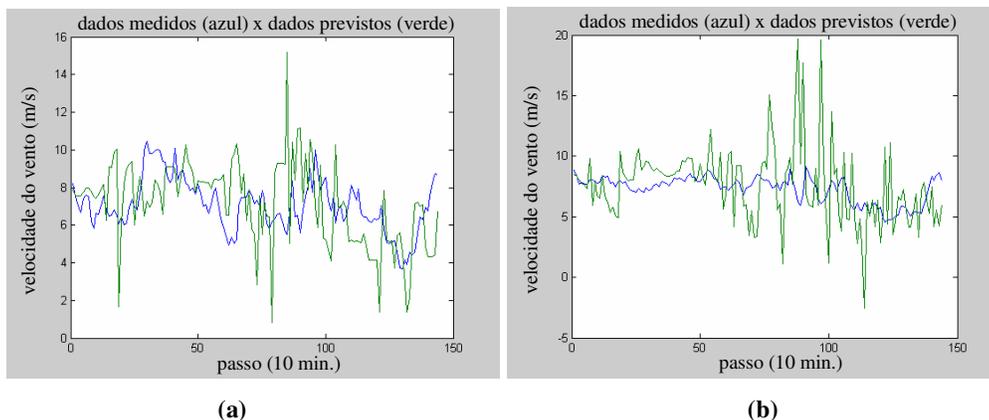


Figura 4- 4 – Previsão 24 horas à frente utilizando 24 redes – (a) sem direção do vento e (b) com direção do vento

4.1.5. 1 Rede – 144 saídas à frente defasadas de 10 minutos

A seguir, foi realizado um teste com uma rede neural com 144 saídas com a seguinte configuração:

Entradas	Sem direção do vento - 156 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 144 entradas de velocidade do vento do instante k até k-143; Com direção do vento - 300 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 144 entradas de velocidade do vento e 144 de direção do vento, ambas do instante k até k-143.
Saídas	Sem e com direção do vento - 144 saídas para a velocidade do vento nas 24 horas seguintes a cada 10 minutos.
Tipo de treinamento	Traingdx (gradiente decrescente).
Função de ativação	Sigmoidal (logsig) para a camada intermediária e linear (purelin) para a camada de saída.
Neurônios na camada intermediária	10
Épocas	5.000

Os testes foram realizados sem e com os dados de direção do vento e os erros médios obtidos para os 36 casos de testes foram de 57,79 % para o primeiro e 55,73 % para o segundo, resultados que estão muito próximos ao obtido com o método de persistência. Resultado que já era esperado, visto que o modelo apresenta um número elevado de parâmetros, o que ocasiona uma dificuldade no treinamento do modelo.

Os gráficos da Figura 4- 5 apresentam o resultado da previsão de 144 passos à frente utilizando uma rede com 144 saídas para 2 casos de testes.

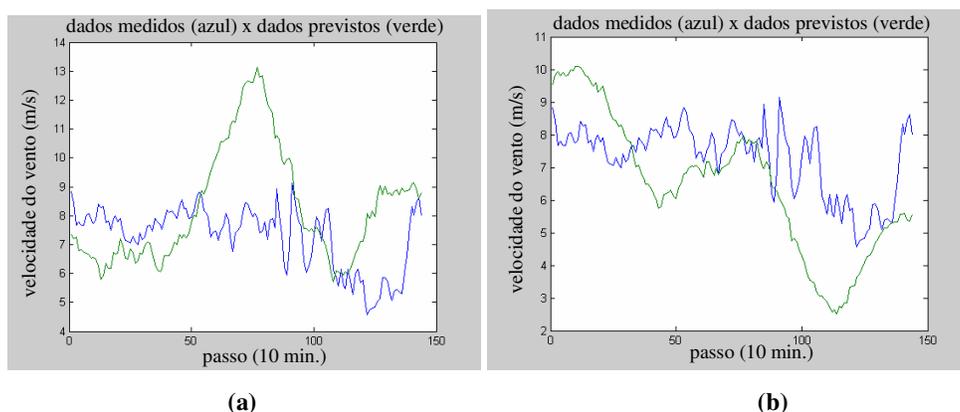


Figura 4- 5 – Previsão 24 horas à frente utilizando rede neural com 144 saídas – (a) sem direção do vento e (b) com direção do vento

4.1.6. 1 Rede – 6 saídas à frente defasadas de 10 minutos

A seguir, foi realizado um treinamento com uma rede neural com 6 saídas com a seguinte configuração:

Entradas	Sem direção do vento - 51 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas binárias (0 ou 1) para identificar a hora do dia, 15 entradas de velocidade do vento do instante k até k-8, k-138 até k-143 (os seis pontos da mesma hora do dia anterior); Com direção do vento - 66 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas binárias (0 ou 1) para identificar a hora do dia, 15 entradas de velocidade do vento e 15 de direção do vento, ambas do instante k até k-8, k-138 até k-143 (os seis pontos da mesma hora do dia anterior).
Saídas	Sem direção do vento - 6 saídas da velocidade do vento no instante k+1 até k+6; Com direção do vento - 12 saídas da Velocidade e direção do vento no instante k+1 até k+6.
Tipo de treinamento	Traingdx (gradiente decrescente).
Função de ativação	Sigmoidal (logsig) para a camada intermediária e linear (purelin) para a camada de saída.
Neurônios na camada intermediária	10
Épocas	5.000

Para os testes foram feitas 23 recursões para a rede de 6 saídas sem utilizar os dados de direção do vento e o mesmo procedimento foi repetido com os dados de direção do vento. O erro médio obtido nos 36 casos de testes obtidos foi de 42,20 % para o primeiro e 45,21 % para o segundo.

Os gráficos da Figura 4- 6 apresentam o resultado da previsão para 144 passos à frente utilizando uma rede com 6 saídas para 2 casos de testes. Observa-se que os resultados são melhores que os anteriores. Porém as curvas previstas, apesar de acertar as tendências do vento durante o dia, não conseguem prever as variações de alta frequência (picos).

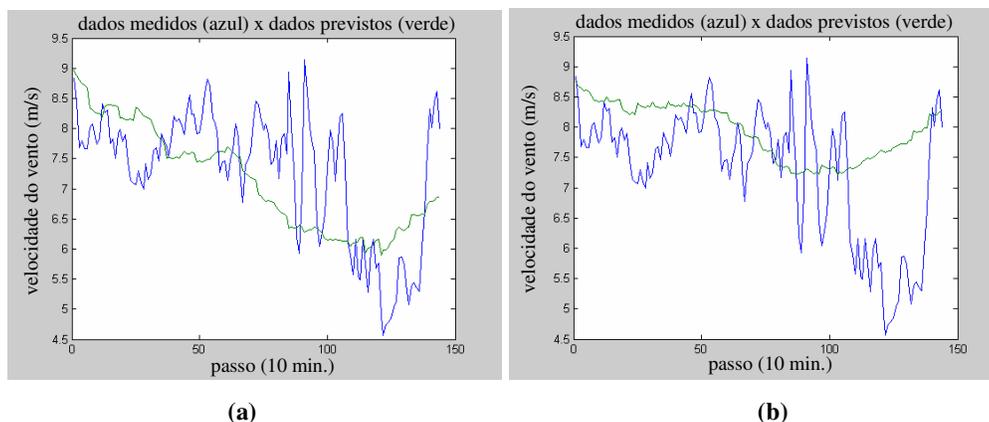


Figura 4- 6 – Previsão 24 horas à frente utilizando rede neural com 6 saídas – (a) sem direção do vento e (b) com direção do vento

4.1.7. 1 Rede – 24 saídas à frente (horas cheias)

Para tentar capturar a reação da rede neural para cada hora do dia seguinte, foi realizado um treinamento utilizando somente os pontos de horas cheias (ou seja, o sexto ponto a cada hora na base de 10 minutos). Para isso foi criada uma nova base de dados somente com valores de horas cheias.

A configuração da rede para treinamento foi a seguinte:

Entradas	Sem direção do vento - 36 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas de velocidade do vento do instante k até k-23; Com direção do vento - 60 entradas: 12 entradas binárias (0 ou 1) para identificar o mês do ano, 24 entradas de velocidade do vento e 24 de direção do vento, ambas do instante k até k-23.
Saídas	Sem e com direção do vento - 24 saídas da velocidade do vento no instante k+1 até k+24 (a cada hora).
Tipo de treinamento	Traingdx (gradiente decrescente).
Função de ativação	Sigmoidal (logsig) para a camada intermediária e linear (purelin) para a camada de saída.

Neurônios na camada intermediária	6
Épocas	10.000

Os testes foram realizados sem e com os dados de direção do vento e o erro médio obtido para os 36 casos de testes foi de 54,09 % para o primeiro e 43,57 % para o segundo. Os resultados apresentam uma excelente melhora quando utiliza-se os dados de direção de vento.

Para efeito de comparação, a mesma previsão de 24 horas à frente na base de horas cheias foi realizada utilizando o mesmo método de persistência adotado para a previsão de 144 pontos à frente visto no item 4.1.1. O erro obtido foi de 63,09 %, mostrando que o método neural apresenta melhores resultados.

4.2 Testes com modelo combinado

Tomando como referência os testes iniciais apresentados no item 4.1, partiu-se para montagem de redes neurais combinadas visando a melhor previsão para 24 horas à frente em base de 10 minutos.

Nestes testes, utilizou-se o modelo de 24 passos à frente na base de horas cheias para melhorar a qualidade da previsão visto que nos testes iniciais, a previsão apresentava piora na medida em que se utilizavam recursões nos modelos. A utilização da previsão de horas cheias ajudou a capturar a tendência do vento no decorrer das 24 horas do dia e as recursões foram realizadas para preencher os valores entre as horas, diminuindo assim a perda de tendência para horas previstas mais a frente.

A Figura 4-7 apresenta esquema da combinação que será realizada nos itens seguintes.

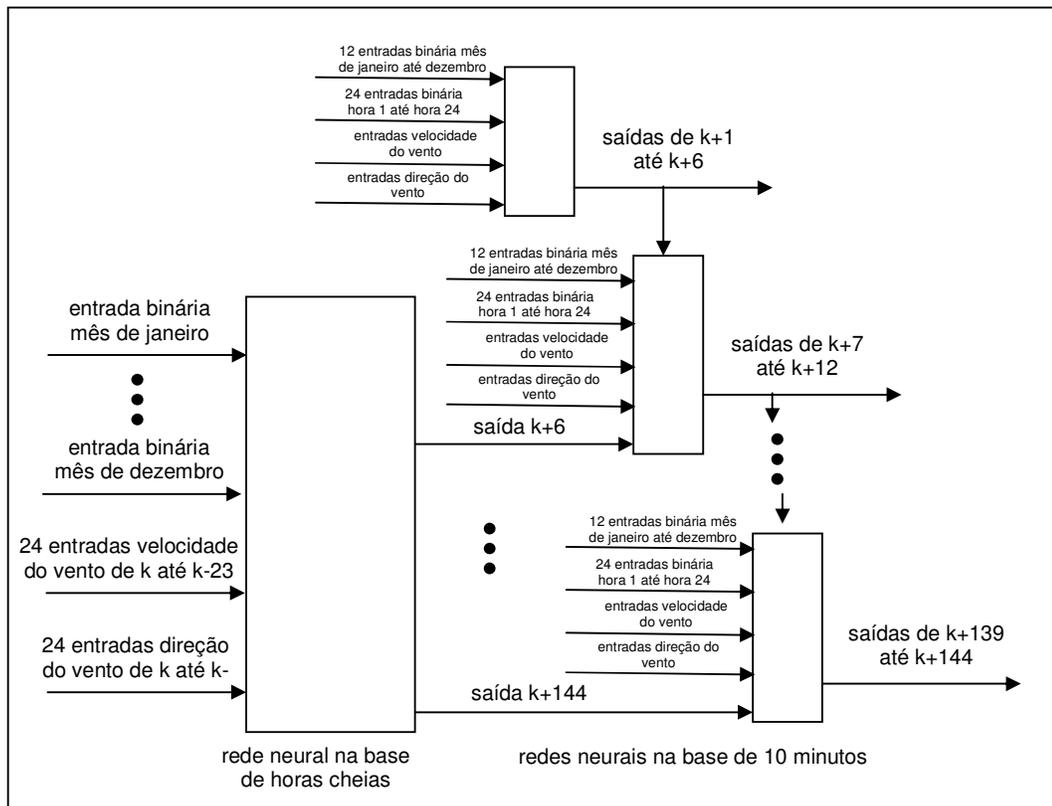


Figura 4- 7 – Esquema utilizado no modelo combinado

4.2.1. Combinado da rede de 24 saídas na base de horas cheias com a rede de 1 saída na base de 10 minutos

Nesta simulação, a previsão é feita da maneira descrita a seguir:

- Executar a rede com a base de dados somente com horas cheias utilizando-se os dados de direção do vento, visto que os resultados apresentados no item 4.1.7 mostram que, para este modelo, a previsão com dados de direção do vento apresentou menor erro do que a previsão sem utilizar os dados de direção do vento.
- Executar a rede de uma saída, utilizando-se os dados de direção do vento que apresentaram melhores resultados no item 4.1.2 e fazendo a recursão 143 vezes.
- Nas recursões em que se prever a velocidade do vento para a hora cheia, substituir com a média dos valores previstos nos dois modelos utilizados,

para se evitar ocorrência de picos decorrente da falta de continuidade dos modelos.

Esta modelagem tem como objetivo fazer com que a previsão acompanhe os picos de variação no decorrer do dia, evitando se ter uma previsão “achatada” conforme observado na Figura 4- 6.

Este modelo apresentou erro médio para os 36 casos de testes de 40,94 %. Este resultado já apresentou um ganho em relação às redes isoladas, mostrando que a previsão da rede de 24 saídas de horas cheias ajudou a previsão dos pontos mais a frente.

Os resultados da previsão observados na Figura 4-7 mostram que a previsão acompanha a tendência da velocidade do vento no dia seguinte.

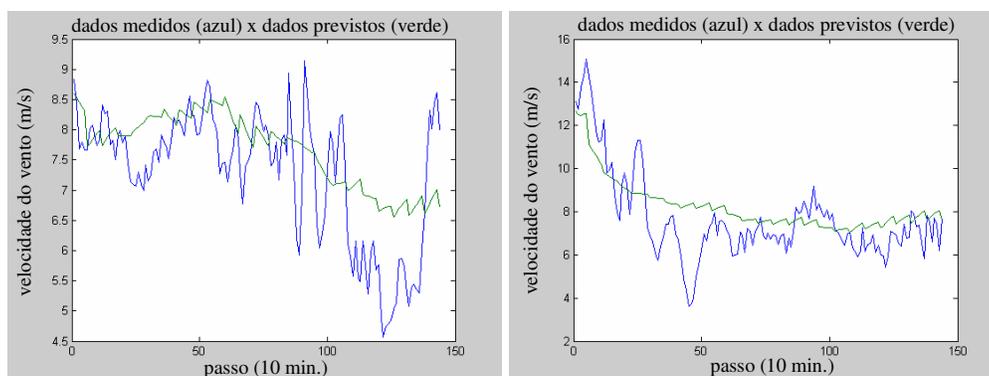


Figura 4- 8 – Previsão 24 horas à frente utilizando combinação de rede neural com 24 saídas para horas cheias e 1 saída para 10 minutos à frente (2 casos de testes)

A mesma simulação foi feita sem utilizar os dados de direção do vento, e obteve-se um erro médio nos 36 casos de testes de 49,99%, o que já era esperado, visto que as redes individuais apresentaram um desempenho melhor com os dados de direção do vento.

4.2.2. Combinado da rede de 24 saídas na base de horas cheias com a rede de 6 saídas na base de 10 minutos

Por último, foi feita uma simulação da rede de 24 saídas na base de horas cheias combinada com a saída da rede com 6 saídas na base de 10 minutos, que foi a que apresentou os melhores resultados para a previsão de 144 passos à frente.

Esta combinação foi feita da seguinte maneira:

- Executar a rede com a base de dados somente com horas cheias utilizando-se os dados de direção do vento, visto que os resultados apresentados no item 4.1.7 mostram que, para este modelo, a previsão com dados de direção do vento possui melhores resultados do que quando não se utiliza os dados de direção do vento.
- Executar a rede de seis saídas, sem utilizar os dados de direção do vento, uma vez que este foi o modelo que apresentou melhores resultados no item 4.1.6, e realizar a simulação desta rede 24 vezes, uma pra cada hora.
- A cada simulação da rede de 6 saídas, substituir a velocidade prevista para a hora cheia com a média dos valores previstos nos dois modelos utilizados, para se evitar ocorrência de picos decorrente da falta de continuidade dos modelos.

Nesta combinação de modelos, o erro médio obtido nos 36 casos de testes foi de 40,11%.

A rede de 6 saídas sem direção do vento foi a que apresentou melhores resultados quando trabalhou-se com redes isoladas. Logo, na combinação com a rede de 24 saídas na base de horas cheias era esperado que se tivesse o menor índice de erro médio, visto que esta combinação de modelos já havia apresentado melhorias nos resultados, conforme apresentado no item 4.2.1.

Nos gráficos da Figura 4-8 apresentam-se previsões de 24 horas à frente para 4 casos de testes onde pode-se observar que a previsão acompanha a tendência da variação da velocidade do vento no decorrer do dia.

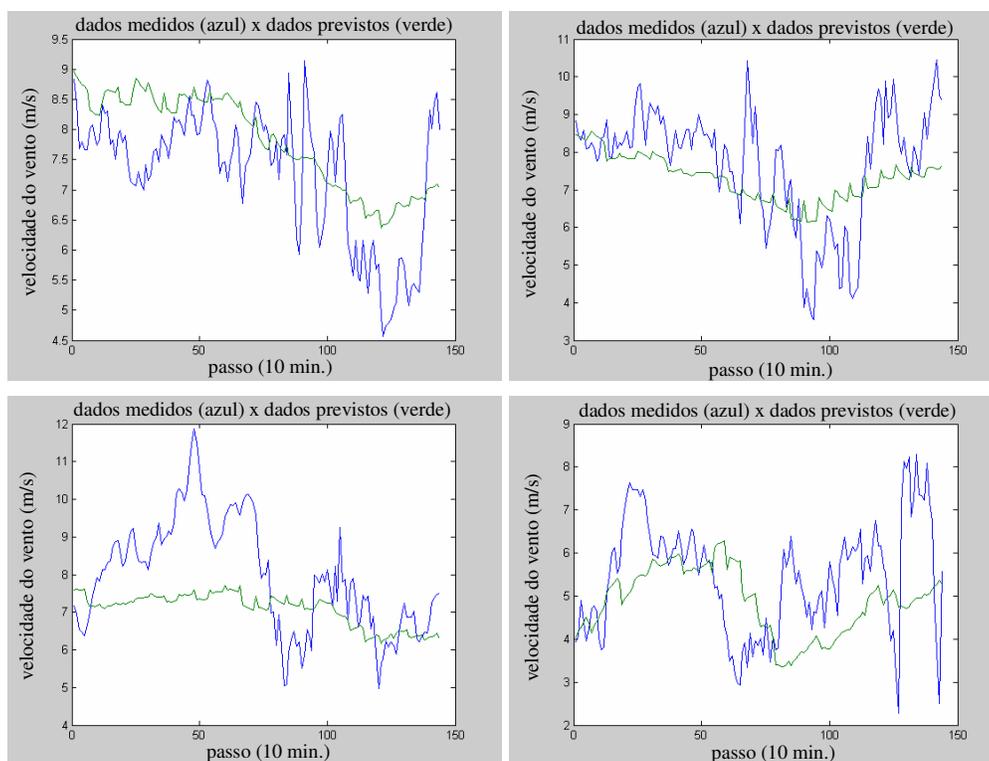


Figura 4-9 – Previsão 24 horas a frente utilizando combinação de rede neural com 24 saídas para horas cheias e 6 saída para 10 minutos (4 casos de testes)

Foram realizadas simulações com a mesma combinação utilizando-se dados de direção do vento nos dois modelos, obtendo-se um erro médio para os 36 casos de testes de 41,21 % e sem utilizar os dados de direção do vento em nenhum dos dois modelos e obtendo-se um erro médio nos 36 casos de testes de 49,26%. Estes resultados já eram esperados que fossem menores do que a combinação proposta anteriormente visto que os modelos isolados apresentaram melhores resultados para uso de direção do vento na rede com 24 saídas na base de horas cheias e sem utilizar direção do vento para a rede de 6 saídas na base de 10 minutos.

4.3 Comparação dos resultados

Na maioria dos testes, os resultados apresentaram-se com menores erros quando foram utilizados os dados de direção do vento, exceto para a rede de 6 saídas e utilizando 24 redes.

A rede de 6 saídas com 23 recursões e sem utilizar os dados de direção do vento foi a que apresentou melhor resultado para os testes utilizando redes isoladas.

O melhor resultado geral foi o apresentado na combinação da rede de 24 saídas utilizando os dados de direção de vento na base de horas cheias com a rede de seis saídas sem utilizar os dados de direção do vento, conforme apresentado na Tabela 4-1.

Tabela 4-1 – Erros obtidos nos testes executados.

Tipo de treinamento		Erro MAPE (%)
Persistência		58,90
Box-Jenkins		50,45
144 saídas	com direção de vento	55,73
	sem direção de vento	57,79
24 redes	com direção de vento	56,21
	sem direção de vento	49,45
143 recursões da rede de uma saída	com direção de vento	45,27
	sem direção de vento	49,78
23 recursões da rede de 6 saídas	com direção de vento	45,21
	sem direção de vento	42,20
combinação da rede de uma saída com a rede de 24 saídas	com direção de vento	40,94
	sem direção de vento	49,99
combinação da rede de 6 saídas com a rede de 24 saídas	com direção de vento	41,21
	sem direção de vento	49,26
	24 saídas com direção do vento e 6 saídas sem direção do vento	40,11

5.1 *Conclusões Gerais*

O presente trabalho teve por objetivo apresentar um estudo de modelagem de redes neurais para realizar uma previsão da velocidade do vento 24 horas à frente com 144 passos em base de 10 minutos. Esta previsão é de extrema importância para a operação de usinas eólicas que representam uma das mais importantes fontes de energia limpa e alternativa que vem se desenvolvendo no Brasil. E hoje em dia, com o mundo dos negócios cada vez mais competitivo, a necessidade de uma previsão bem fundamentada assumiu posição de destaque nas empresas.

O processo de previsão que envolve o estudo de dados históricos com o objetivo de descobrir padrões para os acontecimentos futuros, ou seja, a previsão dependerá da análise dos dados passados, tornando essencial a disponibilidade de bases de dados confiáveis.

Sabe-se da dificuldade na modelagem de uma série temporal bastante irregular, como observado no item 2.1.6 devido às grandes variações apresentadas. Devido à esta dificuldade e à utilização de uma base de dados abrangendo somente os valores de um ano inteiro, os testes foram realizados com os últimos 3 dias de cada mês para garantir que a rede neural pudesse identificar padrões para qualquer época do ano na região estudada.

O trabalho apresentado também foi pioneiro em relação ao horizonte de previsão. Muitos estudos vêm sendo realizados no mundo, conforme visto no item 1.2, mas nenhum deles tem ultrapassado a previsão para 6 horas à frente.

Inicialmente, a idéia era realizar uma rede que fizesse 143 recursões para a previsão de um passo à frente (10 minutos). Porém como mencionado no item 4.1.2, os resultados apresentaram pouquíssimo ganho em relação ao método “ingênuo” de persistência. Isto já era esperado visto que a previsão de um ponto à frente no método de persistência é muito confiável, já que a autocorrelação da velocidade do vento apresenta altos valores para dados de um *lag* (10 minutos de

defasamento) conforme apresentado na Figura 2-15 e na Figura 2-16. No gráfico da Figura 2-15, percebe-se também o pequeno decaimento dos valores de autocorrelação, o que demonstra que o modelo de persistência para prever as 24 horas à frente também apresenta um certo grau de confiabilidade. A metodologia aplicada para o modelo de persistência é original e apresentou resultados melhores do que o esperado para uma previsão no horizonte de 24 horas utilizando a previsão ingênua.

Numa segunda tentativa foram criadas 24 redes neurais com cinco recursões em cada rede, para fazer a previsão dos 144 passos das 24 horas à frente. As redes fazem uma previsões para $t + k + 1$ à frente, sendo $k = 0, 6, 12, 18, \dots, 138$. Os resultados obtidos no item 4.1.4 apresentaram erro médio próximo do valor obtido com o método de persistência.

Posteriormente, os resultados dos testes utilizando uma única rede para prever as 144 saídas à frente foram próximos do obtido através do método de persistência.

Adicionalmente, realizou-se um treinamento com uma rede prevendo 6 saídas defasadas de 10 minutos aplicando-se recursão 23 vezes e obteve-se os melhores resultados de previsão para 24 horas à frente utilizando somente uma única rede.

Finalmente, inseriu-se um modelo de treinamento numa base de horas cheias para se captar a tendência da hora no decorrer do dia e realizar combinações com as redes prevendo um ponto à frente e seis pontos à frente, conforme o item 4.2.

Com os resultados obtidos nos testes com modelo combinado observa-se que a introdução do modelo de 24 saídas na base de horas cheias ajudou a captar a tendência da velocidade do vento no decorrer do dia.

Como apresentado no resumo da Tabela 4-1, o melhor resultado obtido nos testes é o que apresentou erro médio de 40,11% nos 36 casos de testes que foi obtido com o modelo combinado que utilizou as seguintes redes:

- a rede de 24 saídas na base de horas cheias, utilizando os dados de direção do vento, e
- a rede de 6 saídas na base de 10 minutos, sem utilizar os dados de direção do vento.

Com o resultado de todas essas simulações, pode-se concluir que a previsão do vento apresenta uma enorme dificuldade devido à característica não linear da velocidade do vento e também das grandes variações que existem em um espaço pequeno de tempo, conforme observado nas Figuras 2-4 e 2-5.

A modelagem apresentou um ganho de 18,8 % em relação ao método de persistência, o que representa uma melhora significativa para a previsão de 24 horas à frente de uma série temporal com enormes variações como a da velocidade do vento.

Apesar do valor de previsão ainda ser alto – em torno de 40% - é importante ressaltar que os resultados obtidos com a rede neural, mostraram um acompanhamento da tendência da velocidade do vento no decorrer do dia. Quando consideramos a geração de energia eólica, esta tendência é de extrema importância, visto que a série temporal de geração de energia eólica não apresentará os picos e altas variações que apresentam a série de velocidade do vento. Isto ocorre porque existe um vento mínimo e vento máximo para geração eólica e rápidas variações no vento não são sentidas pela máquina. Inclusive para previsão de geração 24 horas à frente, é comum se utilizar as médias horárias, o que também eliminaria as grandes variações em espaço curto de tempo.

Sendo assim, quando esta rede for aplicada para previsão de energia eólica, os erros obtidos tendem a ser bem menores do que os encontrados para a série de velocidade do vento, pois o acompanhamento da tendência será de extrema importância para a previsão sem os picos e as grandes variações.

5.2 *Trabalhos Futuros*

Atualmente, no Brasil, encontram-se poucos trabalhos realizados com o objetivo de previsão de velocidade de vento para 24 horas à frente. Grande parte se deve a escassez de histórico de dados consistentes.

Os históricos de dados de vento que estão disponíveis no Brasil para estudo foram obtidos em regiões não propensas a geração de energia eólica, em alturas não compatíveis e apresentam nas informações faltantes, ou seja, a base de dados

não é contínua. Nestas condições, estes históricos não são aproveitáveis para o estudo de previsão com redes neurais, que é o objetivo desta dissertação, e não puderam ser utilizados.

Com o desenvolvimento da indústria eólica e a iminência do crescimento do mercado no Brasil, os dados com medições completas para geração de energia eólica se tornaram estratégicos, o que se apresentou como o grande obstáculo para obtenção de uma base de dados para estudos.

Visto que este problema vem atrapalhando os estudos realizados no Brasil, alguns projetos já vem sendo apresentados com o intuito de fornecer informações de qualidade para o desenvolvimento de trabalhos nesta área, como o caso do Projeto Sonda [32], de onde foram tirados os dados para este trabalho. É importante ressaltar que somente a obtenção de melhores bases de dados já irá representar um grande avanço para o estudo.

Sendo assim, para dar extensão aos estudos realizados neste trabalho sugere-se:

- Realizar estudos com uma base de dados em um período maior para captar a influência da sazonalidade anual nos dados de treinamento, através da monitoração do avanço destes Projetos que disponibilizam dados para estudo.
- Verificar a influência da utilização de outras grandezas na entrada do modelo de previsão, tais como temperatura, pressão e umidade do ar.
- Atualmente, os estudos com técnicas inteligentes vem evoluindo bastante, inclusive com a combinação de mais de uma técnica para se obter o melhor de cada modelo. Sendo assim, sugere-se a realização da previsão através da combinação das redes neurais com outras técnicas inteligentes como lógica fuzzy (neuro-fuzzy) e algoritmos genéticos evolucionários – AGE (redes neurais evolucionárias – RNE).
- A previsão de velocidade de vento neste trabalho foi com o objetivo de auxiliar estudos voltados para a geração de energia eólica numa região. Sendo assim, uma outra sugestão para avanço deste trabalho é a realização de simulações da rede neural para prever a geração da energia

eólica em determinada localização. Para realização desta previsão, é necessário definir o tipo de turbina eólica a ser utilizada, para, a partir da curva de potência da turbina, determinar os valores da geração de energia eólica. Nesta previsão, os erros dos testes podem apresentar melhoras em relação aos erros obtidos na previsão de velocidade de vento, devido às características da curva de geração eólica não ser complexa como a de velocidade de vento, ou seja, as grandes variações encontradas na velocidade de vento não representam variações de geração de energia eólica.

Referências Bibliográficas

- [1] ALDABÓ R. “Energia Eólica”, Editora ArtLiber, 1ª edição, 2002.
- [2] DUTRA R., SZKLO A., TOLMASQUIM M. “Experiência de Políticas para o Desenvolvimento de Mercados Eólicos, Perspectivas e Transformações no Parque gerador de energia Elétrica no Brasil”, X CBE – Congresso Brasileiro de Energia, Rio de Janeiro, RJ, Outubro de 2004.
- [3] CAMARGO A. S. G., “Análise da Operação das Usinas Eólicas de Camelinho e Palmas e Avaliação do Potencial Eólico de Localidades no Paraná”.
- [4] “Energia Eólica – Princípios e Aplicações”, 2007: <http://www.cresesb.cepel.br>
- [5] DO AMARANTE O.A.C., BROWER M., ZACK J., LEITE DE SÁ A. “Atlas do Potencial Eólico Brasileiro, Camargo-Schubert, TrueWind Solutions, CEPEL, 2001.
- [6] DO AMARANTE O.A.C., DA SILVA F.J.L., FILHO L.G.R. “Atlas Eólico do Rio de Janeiro”, Governo do Estado RJ – Secretaria de Estado de Energia, da Indústria Naval e do Petróleo, 2002.
- [7] Programa de Incentivo a Fontes Alternativas – Eletrobrás – 2007: <http://www.eletrobras.com.br/elb/portal/data/Pages/LUMISABB61D26PTBRIE.htm>
- [8] PORTO L., CARVALHO, C.H., FRANÇA G., OERTEL L. “Política de Energias Alternativas Renováveis no Brasil”, IX Congresso Brasileiro de Energia e IV Seminário Latino-Americano de Energia, Volume II, Rio de Janeiro-RJ, pp.906-911, Maio de 2002.
- [9] Programa de Incentivo a Fontes Alternativas - Ministério de Minas e Energia – 2007: http://www.mme.gov.br/programs_display.do?chn=904
- [10] FILGUEIRAS A., SILVA T. M. “Energia Eólica no Brasil – Presente e Futuro”, Renewable Energy Reviews, Inglaterra, Maio de 2003.

- [11] ROCHA N., AMARANTE, O., SCHULTZ D., SUGAI M., BITTENCOURT R. "Estabilização Sazonal da Oferta de Energia Através da Complementaridade entre os Regimes Hidrológico e Eólico", XV SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica, Foz do Iguaçu, Outubro de 1999.
- [12] CBEE – Centro Brasileiro de Energia Eólica – 2007: www.eolica.com.br
- [13] BARBOUNIS T. G., "Long-Term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models", IEEE Transactions on Energy Conversion, Vol. 21, No 1, pp 273-284, Março 2006.
- [14] ALEXIADIS M.C., "Wind Speed and Power Forecasting based on Spatial Correlation Models", IEEE Transactions on Energy Conversion, Vol. 14, No 3, pp 836-842, Setembro 1999.
- [15] KARINIOTAKIS G.N., "Wind Power Forecasting Using Advanced Neural Networks Models", IEEE Transactions on Energy Conversion, Vol. 11, No 4, pp 762-767, Dezembro 1996.
- [16] LI S., "Using Neural Networks to Estimate Wind Turbine Power Generation", IEEE Transactions on Energy Conversion, Vol. 16, No 3, pp 276-282, Setembro 2001.
- [17] ANURAG M., DEO M.C., "Forecasting Wind With Neural Networks", Marine Structures 16, pp 35-49, 2003.
- [18] POTTER C. W., "Very Short-Term Wind Forecasting for Tasmanian Power Generation", IEEE Transactions on Power Systems, Vol. 21, No 2, pp 965-972, Maio 2006.
- [19] POTTER C. W., "Short-Term Wind Forecasting Techniques for Power Generation", Australasian Universities Power Engineering Conference (AUPEC 2004), 26-29, Brisbane, Australia, Setembro 2004.
- [20] DAMOUSIS I. G., "A Fuzzy Model for Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation", IEEE Transactions on Energy Conversion, Vol. 19, No 2, pp 352-361, Junho 2004.

- [21] GREGOR G., "The State-Of-The-Art in Short-Term Prediction of Wind Power – a Literature Overview", Version 1.1 – Project ANEMOS, Agosto 2003, 2007: <http://anemos.cma.fr>
- [22] TANTAREANU C., "Wind Prediction in Short Term: A first step for a better wind turbine control", Nordvestjysk Folkecenter for Vedvarende Energi, Outubro 1992.
- [23] SCHWARTZ M., MILLIGAN M., "Statistical Wind Forecasting at the U.S. National Renewable Energy Laboratory", Proceedings of the First IEA Joint Action Symposium on Wind Forecasting Techniques, Norrköping, Sweden, pp. 115-124B, Dezembro 2002.
- [24] NIELSEN T. S., MADSEN H., "Statistical methods for predicting wind power", Proceedings of the European Wind Energy Conference, Irish Wind Energy Association, Dublin, Eire, pp. 755-758, 1997.
- [25] HUANG Z., CHALABI Z.S., "Use of time-series analysis to model and forecast wind speed", Journal of Wind Engineering and Industrial Aerodynamics 56 pp 311-322, 1995.
- [26] SCHLINK U., TETZLAFF G., "Wind Speed Forecasting from 1 to 30 Minutes", Theoretical and Applied Climatology 60, pp 191-198, 1998.
- [27] NIELSEN T. S., MADSEN H., T_FTING J., "Experiences with statistical methods for wind power prediction", Proceedings of the European Wind Energy, James & James (Science Publishers), Nice, France, pp. 1066-1069, 1999.
- [28] 2007: http://enfor.eu/wind_power_prediction_tool_wppt.php
- [29] 2007: <http://www.prediktor.dk/>
- [30] NIELSEN T. S., MADSEN H., AA. NIELSEN H., LANDBERG L., LANDBERG G., "Prediction of Regional Wind Power", 2007: <http://www.risoe.dk/zephyr>
- [31] G. Giebel, L. Landberg, "The Zephyr Project – The Next Generation Prediction System", GWEC 2002, Paris, France, Abril 2002.
- [32] Projeto SONDA – INPE, 2007: <http://www.cptec.inpe.br/sonda/index.html>

- [33] LEVENBACH H., CLEAR J. P., "The Beginning Forecaster", Lifetime Learning Publication – Belmont, California, 1981.
- [34] WASSERMAN P. D., Neural Computing: theory and practice, Van Nostrand Reinhold, New York, 1989.
- [35] VARFIS A., VERSINO C., Univariate Economic Time Series Forecasting, Cambridge University Press, Cambridge, 1990.
- [36] CAUDILL M., Neural Network Primer, Miller Freeman Publications, 1990.
- [37] RUMELHART D. E., WEIGEND S. A., "Predicting the Future: A Connectionist Approach", Stanford PDP-90-01, PARC-SSL-90-20, 1990.
- [38] GALLANT S., Neural Network Learning and Expert Systems. MIT Press Cambridge, USA, 1993.
- [39] ROJAS R., Neural Networks – A Systematic Introduction. Springer-Verlag, Germany, 1996.
- [40] RUMELHART D. E., HINTON G. E., WILLIAMS R. J., "Learning Internal Representations by Error Propagation", Parallel Distributed Processing, vol. 1, MIT Press, pgs. 318-362, 1986.
- [41] WIDROW B., HOFF M. E., "Adaptive switching circuits," in 1960 WESCON Convention Record, New York, 1960.
- [42] SARLE W., Stopped Neural Network Frequently Asked Questions. Available form, 2007: <ftp://ftp.sas.com/pub/neural/FAQ.html>.1999.
- [43] AZOFF E., Neural Network Time Series Forecasting of Financial Markets, John Wiley & Sons, 1994.
- [44] Manual Neural Network Toolbox do MATLAB, versão 6.5, Junho, 2002.
- [45] CHATFIELD C., The Analysis of Time Series – An Introduction. Chapman and Hall, UK, 1989.
- [46] HAMILTON J. D., Time Series Analysis, Princeton University Press, Princeton, 1994.

- [47] ENDERS W., Applied econometric time series. New York: John Wiley & Sons, 1995.
- [48] MORRETIN P. A., TOLOI C. M. C., Previsão de séries temporais. 2. ed. São Paulo: Atual Editora, 1987.
- [49] BOX G. E. P. e JENKINS G. M., Time Series Analysis, Forecasting and Control, Holden-Day, San Francisco, USA, 1976.
- [50] MAKRIDAKIS S., WHEELWRIGHT S., HYNDMAN R. J., Forecasting methods and applications. 3. ed. New York: John Wiley & Sons, 1998.
- [51] CORTEZ P.A.R., Modelos Inspirados na Natureza para a Previsão de Séries Temporais. Tese de D. Sc., Universidade do Minho, Portugal, 2002.
- [52] HANKE J., REITSCH, A., "Business Forecasting", Allyn and Bancon Publishing Company Inc., Massachussets, USA, 1989.
- [53] FAVA V. L., "Manual de Econometria: Nível Intermediário", Capítulos 9 e 10, Editora Atlas S.A., 2000.
- [54] BOX G., LUCEÑO A., Statistical control by monitoring and feedback adjustment, John Wiley, New York, 1997.
- [55] ABRAHAM B., LEDOLTER J., Statistical methods for forecasting. New York: John Wiley & Sons, 1983.
- [56] MAKRIDAKIS S., HIBON M., ARMA models and the Box-Jenkins methodology. Journal of Forecasting, v.16, n. 3, p. 147-163, may 1997.
- [57] LUGER G., STUBBLEFIELD W., Artificial Intelligence, Structures and Strategies for Complex Problem Solving. Addison Wesley Longman, Inc., USA, 1998.
- [58] GOLDBERG D., Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley Publishing Company, Inc., NY, USA, 1989.
- [59] AGAPIE A. and AGAPIE A., Forecasting the Economic Cycles Based on an Extension of the Holt-Winters Model. A Genetic Algorithms Approach. In Proceedings of the IEEE Computational Intelligence for Financial Forecasting Engineering, pages 96-99, 1997.

- [60] CHIRAPHADHANAKUL S., DANGPRASERT P., AVARCHANAKORN V., Genetic Forecasting Algorithm with Fiancial Applications. In Proceedings of Intelligent Information Systems – IIS' 97, pages 174-178, 1997.
- [61] CHAI C., CHUCK C., DP M., HUAR T., Time Series Modelling and Forecasting using Genetic Algorithms. In Proccedings of the First International Conference on Knowledge-Based Intelligent Elctronic Systems, volume 1, pages 260-268, Adelaide, Australia, 1997.
- [62] BANZHAF W., NORDIN P., KELLER R., FRANCONI F., Genetic Programming. An Introduction. Morgan Kaufmann Publishers, Inc. USA, 1998.
- [63] KABOUDAN M. A., Genetic Evolution os Regression Models for Business and Ecnomic Forecasting. In Proceedings of the 1999 Congress on Evolutionary Computation – CEC 99, volume 2, pages 1217-1223, 1999.
- [64] LI-XIN WANG, A Course in Fuzzy Systems and Control, by Prentice Hall, Inc, 1997.
- [65] REZENDE S. O., “Sistemas Inteligentes: Fundamentos e Aplicações”, Editora Manole, 2005.
- [66] JANG J-S. R., 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE Trans. on Systems, Man and Cybernetic 23 (3), 665-685, January 1993.
- [67] MÊUSER V., “Aplicando Redes Neurais – Um Guia Aplicado”, Editora Livro Rápido, 2005.
- [68] MCCULLOCH W., PITS W., A Logical Calculus of the Ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics, 5:115-133, 1943.
- [69] HOPFIELD J. J., "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", Proc. Nat. Acad. Science, USA, vol. 79, pgs. 2554-2558, 1982.
- [70] SIMPSON P., Artificial Neural Systems: Foundations, Paradigms, Applications and Implementations, Pergamon Press Inc., 1990.
- [71] BOSE N., LIANG P., Neural Network Fundamentals with Graphs, Algorithms and Applications. McGraw-Hill, USA, 1996.

- [72] ALEXANDER I., MORTON H., An Introduction to Neural Computing, Chapman and Hall, London, 1990.
- [73] CARBONELL J. G. , "Introduction: Paradigms for Machine Learning", Artificial Intelligence, vol, 40, pgs 1-9, 1989.
- [74] LIPPMAN R. P., "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, pgs. 4-22, 1987.
- [75] WHITE H., Artificial Neural Networks: Approximation and Learning Theory, Blackwell Publishers, Oxford, 1992.
- [76] KOHONEN T., Self-organized formation of topologically correct feature maps. Biological Cybernetics, 43:59-69, 1982.
- [77] KOHONEN T., "Clustering Taxonomy and Topological Maps of Patterns", Proc. of the Sixth Intern. Conference on Pattern Recognition, pgs. 114-128, 1982.
- [78] HAYKIN S., Neural Networks – A Comprehensive Foundation. Prentice-Hall, New Jersey, 2nd edition, 1999.

MODELOS DE PREVISÃO

Considerações Gerais

Atualmente, com todo o progresso econômico e científico, a previsão continua a ter extrema relevância. Dessa forma, é natural pressupor que as organizações estão interessadas em conhecimentos fundamentados sobre o futuro.

Os erros de previsão são, como é evidente, inevitáveis, tendo-se como objetivo minimizá-los, isto é, o desejo de compreender o passado e prever o futuro impulsiona a procura de leis que expliquem o comportamento de certos fenômenos ou acontecimentos. Se são conhecidas as equações determinísticas que os explicam, então, em princípio, estas podem ser utilizadas para prever o resultado de uma dada experiência, desde que sejam conhecidas as condições iniciais. No entanto, na ausência de regras que definam o comportamento de um sistema, procura-se determinar o seu comportamento futuro a partir de observações concretizadas no passado. Nestas situações, uma das técnicas mais comuns é a previsão de séries temporais, que se baseia em observações cronologicamente ordenadas da variável em estudo [44].

Durante os anos 50 e 60, houve uma procura por uma teoria unificada de previsão. Em 1976, surgiu a metodologia de Box-Jenkins, que incorporava diversos elementos de tal teoria. Esta metodologia fornecia um procedimento sistemático para a análise de séries temporais que era suficientemente geral para lidar com, virtualmente, qualquer tipo de observações empíricas. A partir da década de setenta, tem sido grande a proliferação de modelos univariados de previsão com aplicação em economia. O objetivo básico destes modelos é a realização de previsões de curto prazo, utilizando apenas os dados referentes à própria série que se deseja prever. Em algumas extensões, outras séries podem ser utilizadas mas, de forma geral, não é necessário a especificação de um modelo econométrico completo. A experiência prática na utilização de modelos univariados para a previsão de curto prazo tem se mostrado bastante satisfatória.

A renovação e o aperfeiçoamento dos modelos tem sido constante. Os modelos ARIMA, que foram largamente utilizados nas décadas de setenta e oitenta, foram rapidamente substituídos pelos chamados modelos estruturais de séries de tempo, de enfoque clássico ou bayesiano. A atração por modelos lineares é justificada pela simplicidade de análise e cálculo. Contudo, existem diversas situações onde o modelo linear se torna inadequado. Mais recentemente, mesmo estes modelos estruturais já começam a ser questionados pelas redes neurais e por outros modelos que utilizam técnicas inteligentes, desenvolvidas originalmente no campo da inteligência artificial, quanto à sua eficiência em gerar previsões de curto prazo por serem incapazes de reconhecer pequenas variações.

O objetivo central deste anexo é explicitar modelos clássicos de previsão e modelos criados por inteligência artificial como as séries neurais. Estes modelos que serão aqui descritos foram escolhidos pela sua já demonstrada capacidade de reconhecer padrões e regularidades em séries de tempo.

Séries Temporais

Análise de Séries Temporais

Uma série temporal, também denominada série histórica, é uma seqüência de dados ($x_1, x_2, x_3, \dots, x_t$) obtidos em intervalos regulares de tempo durante um período específico. Este conjunto pode ser obtido através de observações periódicas do evento de interesse [44].

Se a série histórica for denominada como X , o valor da série no momento t pode ser escrito como X_t ($t=1,2,\dots,n$). Denomina-se trajetória de um processo, a curva obtida no gráfico da série histórica e o conjunto de todas as possíveis trajetórias é denominado como um processo estocástico. Considera-se que uma série temporal é uma amostra deste processo. O conjunto de observações ordenadas no tempo pode ser discreto. Pode-se obter uma série temporal discreta a partir de uma amostra de pontos de uma série contínua ou por meio de um parâmetro como, por exemplo, a média de períodos fixos de tempo [45][46].

Na análise de uma série temporal, primeiramente deseja-se modelar o fenômeno estudado para, a partir daí, descrever o comportamento da série, fazer estimativas e, por último, avaliar quais os fatores que influenciaram o comportamento da série, buscando definir relações de causa e efeito entre duas ou mais séries. Para tanto, há um conjunto de técnicas estatísticas disponíveis que dependem do modelo definido (ou estimado para a série), bem como do tipo de série analisada e do objetivo do trabalho [47].

As séries temporais são compostas basicamente por quatro elementos:

- Tendência: que verifica o sentido de deslocamento da série ao longo de vários anos;
- Ciclo: movimento ondulatório que ao longo de vários anos tende a ser periódico;
- Sazonalidade: movimento ondulatório de curta duração, em geral, inferior a um ano; associada, na maioria dos casos, a mudanças climáticas;
- Ruído aleatório ou erro: compreende a variabilidade intrínseca aos dados e não pode ser modelado.

Um modelo de uma série temporal assume que as observações são dependentes, isto é, padrões passados irão recorrer no futuro, pelo que a série é previsível. Uma série diz-se determinística quando é 100% previsível. Entretanto, a maior parte das séries contém um elemento estocástico, sendo o futuro apenas parcialmente determinado por valores passados, uma vez que previsões exatas são impossíveis de se obter.

A análise de séries temporais possui vários objetivos, quais sejam [48]:

- Descrição: onde se pretende descobrir, com nenhum ou pouco conhecimento à priori, determinadas propriedades fundamentais, como o número de graus de liberdade ou quantidade de ruído;
- Explicação: cujo objetivo é encontrar um modelo que capture características sobre o comportamento de um sistema a longo prazo;
- Previsão: que almeja prever com precisão a evolução de um sistema a curto prazo; e

- Controle: onde se tenta controlar o comportamento de um dado processo, atendendo a certos parâmetros como qualidade, por exemplo.

Os modelos de previsão tratam o sistema não tendo como objetivo determinar os fatores que afetam o comportamento do mesmo. Isso se deve ao fato do sistema não ser totalmente determinado, sendo difícil identificar as relações de causa e efeito em jogo. Adicionalmente, reside o fato de que se deseja prever o que acontece e não como acontece, isto é, existem séries temporais reais impossíveis de axiomatizar, tangíveis à previsão.

Decomposição de Séries Temporais

Em geral, as técnicas tradicionais de análise de séries temporais baseiam-se no processo de decomposição, onde se identificam os fatores que influenciam os valores de uma série temporal, como por exemplo, a tendência e a sazonalidade. A tendência dá uma medida do crescimento ou declínio dos valores de uma série. Uma série que possua este tipo de comportamento é chamada de não estacionária. Para análise de tendências, pode-se ajustar modelos de regressão polinomial baseados na série inteira ou em vizinhança de um determinado ponto. Isso também pode ser realizado com funções matemáticas.

A sazonalidade representa uma flutuação periódica com uma duração. O padrão se repete se, ao longo do tempo, após cada K períodos, sendo K o fator sazonal. Uma série histórica pode ser composta por três componentes não observáveis: tendência (T_t), sazonalidade (S_t) e a variação aleatória denominada de ruído branco (a_t).

Ao analisar uma série histórica, deve-se estudar cada um destes componentes separadamente, retirando-se o efeito dos outros.

Para analisar a tendência os dois métodos mais utilizados são:

- ajuste de uma função polinomial do tempo e
- análise do comportamento da série ao redor de um ponto, estimando a tendência naquele ponto.

Na primeira opção, utilizam-se os modelos de regressão polinomial e, na última, modelos auto-regressivos.

O uso de modelos lineares na previsão de séries temporais, como os modelos baseados na metodologia Box-Jenkins [49], que serão abordados mais a frente, está relacionado com a simplicidade desses modelos, pois os parâmetros destes podem ser determinados por métodos estatísticos tradicionais. Contudo, existem muitas situações do mundo real nas quais se faz necessário um mapeamento não-linear entre as variáveis de entrada e as variáveis de saída, daí a necessidade de novas técnicas que permitam este mapeamento de forma eficiente. Modelos baseados em rede neurais, que serão abordados no item mais a frente, são bastante eficazes e, pode-se dizer, mais eficientes na previsão de séries temporais devido a grande capacidade de generalização.

Uma ferramenta estatística importante para a análise de séries temporais é o coeficiente de autocorrelação, definido como a correlação entre a série e ela própria deslocada de k períodos de tempo[49], como apresentado na Equação A.1.

$$r_k = \frac{\sum_{t=1}^{s-k} (x_t - \bar{x}_t)(x_{t+k} - \bar{x}_t)}{\sum_{t=1}^s (x_t - \bar{x}_t)^2} \quad (\text{A.1}),$$

onde s representa o tamanho da série e \bar{x}_t o valor médio da série temporal. As autocorrelações são úteis para testar se uma dada série é previsível e para decomposição dos principais componentes de uma série, como a tendência e a sazonalidade.

Técnicas de Previsão

A tomada de decisões é um fato cotidiano que desempenha um papel relevante dentro das empresas. Atualmente, o alto grau de competitividade no meio empresarial exige a capacidade de se tomar decisões rápidas e precisas. A qualidade da tomada de decisão tem relação direta com os dados disponíveis para o responsável pela decisão e com sua habilidade em extrair destes dados informações relevantes.

Através das técnicas de previsão é possível se extrair dos dados passados disponíveis sobre um processo, informações que permitem a modelagem matemática de seu comportamento. A suposição de uma continuidade nesse

comportamento permite a realização de previsões, cuja qualidade e precisão são muito superiores às das previsões feitas intuitivamente, baseadas unicamente na experiência dos decisores. Adicionalmente, os modelos uma vez atualizados, passam de imediato, a refletir as alterações do processo, fornecendo prontamente subsídios a novas tomadas de decisão.

A elaboração de um sistema de previsão requer conhecimento e habilidade em 4 áreas básicas [50]:

- (i) identificação e definição dos problemas a serem tratados na previsão;
- (ii) aplicação dos métodos de previsão;
- (iii) procedimentos para seleção do método apropriado a situações específicas; e
- (iv) suporte para adaptar e usar os métodos de previsão requeridos.

A aplicabilidade de um sistema de previsão depende de três condições [50]:

- (i) Disponibilidade de informações históricas;
- (ii) Possibilidade da transformação das informações históricas em dados numéricos; e
- (iii) Suposição da repetição de padrões observados em dados passados no tempo futuro.

Esta última consideração é conhecida como suposição de continuidade. Tal condição é uma premissa básica para a utilização de métodos de previsão, bem como de diversos métodos qualitativos.

As técnicas de previsão variam consideravelmente, tendo sido desenvolvidas com vários propósitos distintos. Cada técnica tem sua característica própria, grau de precisão e custo de utilização, os quais devem ser considerados na escolha de um método específico. De modo geral, os critérios para escolha de um sistema de previsão compreendem às seguintes etapas:

- definição do problema;
- coleta de informações
 - montagem do Banco de Dados;
 - classificação dos produtos;

- definição dos Níveis de Agregação;
- seleção do Pacote Computacional;
- análise preliminar;
- escolha e validação dos modelos
 - aspectos que influenciam os dados a serem analisados;
 - características da série temporal;
 - agregação temporal dos dados;
 - intervalos das previsões;
- verificação do Sistema.

Erros de Previsão

O erro de previsão é dado pela diferença entre o valor atual da série e o que foi previsto, na forma da Equação A.2 [51].

$$e_t = x_t - \bar{x}_t \quad (\text{A.2})$$

Para avaliar o desempenho global de um modelo de previsão, torna-se necessário utilizar uma medida de erro, sendo que uma das formas mais utilizadas recorre ao quadrado do erro. Os principais métodos de cálculo de erro para avaliação do desempenho da previsão são:

- Soma dos Quadrados dos Erros (SQE)

$$SQE = \sum_{i=1}^L e_i^2 \quad (\text{A.3})$$

onde L denota o número de previsões a se efetuar.

- Erro Médio Quadrático (EMQ)

$$EMQ = \frac{SQE}{L} \quad (\text{A.4})$$

- Raiz do Erro Médio Quadrático (REMQU)

$$REMQU = \sqrt{EMQ} \quad (\text{A.5})$$

- Média Normalizada do Quadrado dos Erros (MNQE)

$$\text{MNQE} = \frac{\text{SQE}}{\sum_{i=1}^L (x_t - \bar{x}_t)^2} \quad (\text{A.6})$$

Técnicas Tradicionais de Previsão

Os métodos de previsão podem ser agrupados de forma simplificada em duas grandes categorias: modelos univariados e modelos multivariados. Os modelos são denominados univariados quando eles se baseiam numa única série temporal. Por outro lado, os modelos multivariados envolvem mais de uma série temporal.

A seguir são apresentados os principais modelos univariados e multivariados que são utilizados como metodologia oficial por diversas empresas, como é o caso do setor elétrico brasileiro, onde previsões de vazões, geralmente são baseadas na metodologia Box-Jenkins [67].

Modelos de Suavização Exponencial

Os modelos de suavização exponencial são utilizados para previsão de séries temporais devido à sua simplicidade, facilidade de ajuste e boa previsão. Esses métodos usam uma ponderação distinta para cada valor observado na série temporal, de modo que valores mais recentes recebam pesos maiores. Assim, os pesos formam um conjunto que decai exponencialmente a partir de valores mais recentes.

O modelo de Holt-Winters consiste em um método de suavização exponencial e se centra em determinadas características da série, como a existência de fatores de tendência e sazonalidade, que são distinguidas do ruído através de uma média sobre os valores passados. É vantajoso por ser simples de usar, requerer pouco esforço computacional e ser eficaz em previsões de curto prazo em particular com séries sazonais.

O modelo base obedece às equações (A.7) a (A.10) [50].

$$F_t = \alpha \frac{x_t}{S_{t-K}} + (1-\alpha)(F_{t-1} + T_{t-1}) \quad (\text{A.7})$$

$$T_t = \beta(F_t - F_{t-1}) + (1-\beta)T_{t-1} \quad (\text{A.8})$$

$$S_t = \gamma \frac{x_t}{F_t} + (1-\gamma)S_{t-K} \quad (\text{A.9})$$

$$\hat{x}_t = (F_{t-1} + T_{t-1}) * S_{t-K} \quad (\text{A.10})$$

em que F_t denota a suavização exponencial para o período t , T_t a estimativa para tendência, S_t a estimativa sazonal e K o fator sazonal.

Esse método exige que certos parâmetros sejam inicialmente avaliados como as constantes do modelo (α , β e γ) e as estimativas iniciais de cada componente. As constantes são normalmente determinadas através de processos de tentativa e erro em que a minimização do erro é o objetivo perseguido. Uma abordagem diferente é utilizada para as estimativas iniciais dos componentes. Para as séries não-sazonais, normalmente utilizam-se os valores $F_1=x_1$ e $T_1=0.0$. No caso de séries sazonais, é aconselhado um esquema mais elaborado de acordo com as seguintes equações (A.11) a (A.13):

$$F_{K+1} = x_{K+1} \quad (\text{A.11})$$

$$T_{K+1} = \frac{1}{K} \frac{(x_{K+1} - x_1) + (x_{K+2} - x_2) + \dots + (x_{K+K} - x_K)}{K} \quad (\text{A.12})$$

$$\begin{aligned}
 S_1 &= \frac{\frac{X_1}{\text{med}_1} + \frac{X_{K+1}}{\text{med}_2} + \dots + \frac{X_{KY-K+1}}{\text{med}_Y}}{Y} \\
 S_2 &= \frac{\frac{X_2}{\text{med}_1} + \frac{X_{K+2}}{\text{med}_2} + \dots + \frac{X_{KY-K+2}}{\text{med}_Y}}{Y} \\
 &\dots \\
 S_K &= \frac{\frac{X_K}{\text{med}_1} + \frac{X_{K+K}}{\text{med}_2} + \dots + \frac{X_{KY}}{\text{med}_Y}}{Y}
 \end{aligned}
 \tag{A.13}$$

onde $\text{med}_e = \sum_{i=(e-1)K+1}^{(e-1)K+K} \frac{X_i}{K}$ denota a média dos valores para a estação e, sendo Y o

número máximo de estações consideradas. Ressalta-se que para a estimativa inicial da tendência, convém existir pelo menos duas estações completas.

Metodologia Box-Jenkins

A metodologia Box-Jenkins (BJ) baseia-se num processo iterativo para a síntese de padrões a partir de dados históricos, exigindo etapas como a caracterização formal do sistema (obtenção de um modelo), estimação dos parâmetros a ele associados e a sua posterior validação (Figura A-1).

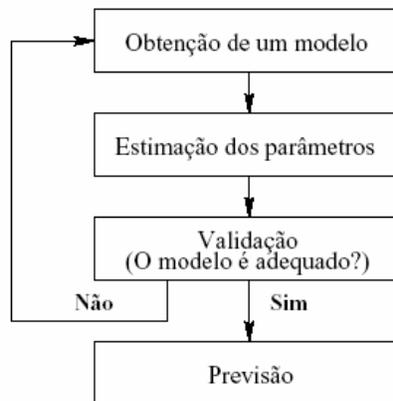


Figura A-1 – Processo iterativo da metodologia Box-Jenkins [52]

A metodologia de BJ tem como vantagem principal o fato de ser bastante precisa sob uma gama alargada de séries temporais. No entanto, torna-se difícil conciliar os parâmetros com o modelo inicialmente criado à medida que novos dados são

adquiridos, isto é, o modelo deve ser periodicamente revisto, ou, até mesmo, um novo modelo deve ser criado. Por outro lado, a construção de um modelo exige o uso de um especialista, sendo também mais exigente em termos computacionais.

Os modelos baseados na metodologia Box-Jenkins, genericamente conhecidos por ARIMA (*Auto Regressive Integrated Moving Averages*) e na literatura em português por Auto-regressivos Integrados de Médias Móveis, foram propostos por George Box e Gwilym Jenkins no início dos anos 70.

Estes são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões. Os modelos de Box-Jenkins partem da idéia de que os valores de uma série temporal são altamente dependentes, ou seja, cada valor pode ser explicado por valores prévios da série.

Segundo [53], os modelos ARIMA resultam da combinação de três componentes denominados “filtros”: o componente auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em vários modelos abordados a seguir.

Modelos Estacionários

Modelos estacionários são aqueles que assumem que o processo está em “equilíbrio”, onde a família de variáveis se mantém a um nível constante médio. Um processo é considerado fracamente estacionário se suas médias e variância se mantêm constantes ao longo do tempo e a função de autocovariância depende apenas da defasagem entre os instantes de tempo. Um processo é fortemente estacionário se todos os momentos conjuntos são invariantes a translações no tempo.

Séries estacionárias e não-estacionárias são representadas graficamente na Figura A-2. Os gráficos (a) e (b) na Figura A-2 mostram séries temporais exibindo variação estacionária. Tais séries variam de maneira estável no tempo, sobre um valor de média fixo. O gráfico (c) mostra uma série temporal não-estacionária, a qual não se desloca no tempo sobre uma média fixa. A série da Figura A-2 (a) é

uma série de ruído aleatório. Em tais séries, as diferenças entre as observações e a média são estatisticamente independentes, seguindo alguma distribuição de probabilidade. A propriedade chave em uma série de ruído aleatório é que a ordem na qual as observações ocorrem não informa nada a respeito da série. Assim, valores passados da série não podem ser utilizados na previsão de valores futuros. A série da Figura A-2 (b) também é estacionária, mas apresenta ruídos autocorrelacionados. Nesse caso, diferenças entre observações e a média não são estatisticamente independentes entre si. Dependência estatística implica na probabilidade de uma diferença qualquer ser influenciada pela magnitude das demais diferenças na série. Na série da Figura A-2 (b), diferenças positivas tendem a seguir diferenças positivas e vice-versa. Finalmente, a Figura A-2 (c) ilustra uma variação não-estacionária.

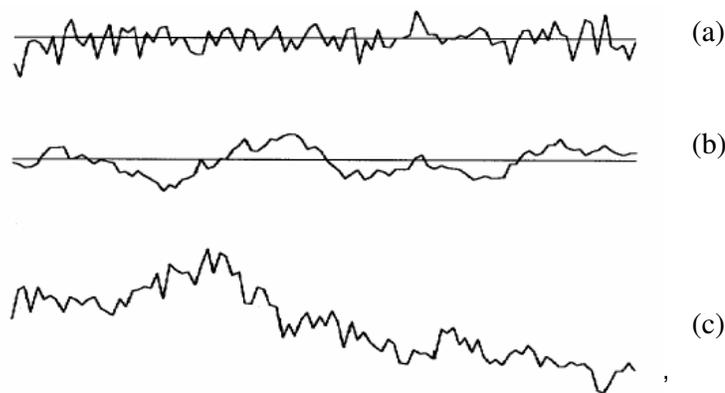


Figura A-2 – Séries Temporais Estacionárias e Não-Estacionárias [54]

São modelos estacionários o modelo Auto Regressivo de Média Móvel (ARMA) e o somente AR e somente MA

Modelos não-estacionários

Quando uma série temporal apresenta média e variância dependentes do tempo, é porque ela não é estacionária. A não-estacionariedade de uma série implica que:

- há inclinação nos dados e eles não permanecem ao redor de uma linha horizontal ao longo do tempo e/ou

- a variação dos dados não permanece essencialmente constante sobre o tempo, isto é, as flutuações aumentam ou diminuem com o passar do tempo, indicando que a variância está se alterando.

Para detectar a não-estacionariedade de uma série, o comportamento temporal pode ser analisado graficamente, buscando os padrões acima ou, então, aplicando os testes estatísticos de raiz unitária. O teste de raiz unitária mais usado é o de Dickey- Fuller. Outros detalhes sobre esse teste podem ser vistos em [50][46].

São modelos não-estacionários o modelo Auto Regressivo Integrados de Média Móvel (ARIMA) e os modelos sazonais (SARIMA).

Etapas da metodologia Box-Jenkins

Segundo [48], a construção dos modelos Box-Jenkins é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com base nos próprios dados. Segundo [49], são três as etapas para construção do modelo:

- 1) Identificação: consiste em descobrir qual dentre as várias versões dos modelos de Box-Jenkins, sejam elas sazonais ou não, descreve o comportamento da série. A identificação do modelo a ser estimado ocorre pelo comportamento das funções de autocorrelações (ACF) e das funções de autocorrelações parciais (PACF). Outros detalhes referentes à obtenção dessas funções e a quais comportamentos representam os modelos anteriormente abordados podem ser pesquisados em [50].
- 2) Estimação: consiste em estimar os parâmetros do componente auto-regressivo, os do componente de médias móveis e a variância de ϵ .
- 3) Verificação: consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação.

Um procedimento muito utilizado é identificar não só um único modelo, mas alguns modelos que serão então estimados e verificados. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de Box-Jenkins, que constitui o objetivo principal da metodologia: realizar previsões.

Modelos auto-regressivos (AR)

Um modelo estocástico útil na representação de um grade de séries temporais é o modelo auto-regressivo

Em um modelo auto-regressivo, a série de dados históricos Z_t é descrita por seus valores passados regredidos e pelo ruído aleatório ε_t .

Assim, um modelo AR(p) é dado por [56]:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t \quad (\text{A.14})$$

em que:

$$\tilde{Z}_t = Z_t - \mu ; \quad (\text{A.15})$$

ϕ_i é o parâmetro que descreve como \tilde{Z}_t se relaciona com o valor \tilde{Z}_{t-i} para $i=1,2,\dots,p$.

O modelo AR(p) dado pela equação A.14 pode ser reescrito conforme apresentado na equação A.16, utilizando o operador de defasagem L (aplicando o operador de defasagem em Z_{t-3} temos L^{3Z_t}).

$$\begin{aligned} (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \tilde{Z}_t &= \\ = \phi(L) \tilde{Z}_t &= \varepsilon_t \end{aligned} \quad (\text{A.16})$$

O modelo auto-regressivo de ordem 1 ou AR(1) é a versão mais simples dessa classe de modelos.

Sua apresentação algébrica é dada pela equação A.17:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \varepsilon_t \quad (\text{A.17})$$

Para o modelo ser estacionário é necessário que $|\phi_1| < 1$ (condição de estacionariedade) e que as autocovariâncias (γ_k) sejam independentes. No caso do modelo AR(1), as autocovariâncias são dadas pela equação A.18:

$$\gamma_k = \phi_1^k \gamma_0 \quad (\text{A.18})$$

e as autocorrelações ρ_k são dadas pela equação A.19:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \phi_1^k \quad k = 0, 1, 2, \dots \quad (\text{A.19})$$

A função de autocorrelação decai exponencialmente quando ϕ_1 é positivo; quando ϕ_1 é negativo, a função de autocorrelação também decai exponencialmente, mas apresenta alternância de sinais positivos e negativos.

Modelos de médias móveis (MA)

Em um modelo de médias móveis (*moving average*), a série Z_t resulta da combinação dos ruídos brancos ε do período atual com aqueles ocorridos em períodos anteriores. Assim, um modelo de médias móveis de ordem q ou MA(q) é dado pela equação A.20 [53][52]:

$$\tilde{Z}_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (\text{A.20})$$

em que:

$$\tilde{Z}_t = Z_t - \mu; \quad (\text{A.21})$$

θ_i é o parâmetro que descreve como Z_t se relaciona com o valor ε_{t-i} para $i = 1, 2, \dots, q$.

O modelo MA(q) dado pela equação A.20 pode ser reescrito, como em A.22, utilizando o operador de defasagem L .

$$\begin{aligned} (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t &= \\ &= \theta(L) \varepsilon_t = \tilde{Z}_t \end{aligned} \quad (\text{A.22})$$

O modelo MA(1) é a versão mais simples dessa classe de modelos. Sua apresentação algébrica é dada pela equação A.23:

$$\tilde{Z}_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (\text{A.23})$$

As autocorrelações ρ_k , que nada mais são do que as autocovariâncias divididas pela variância, são dadas pela equação A.24:

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{-\theta_1 \sigma_\varepsilon^2}{(1 + \theta_1^2) \sigma_\varepsilon^2} = \frac{-\theta_1}{(1 + \theta_1^2)} \quad (\text{A.24})$$

$$\rho_k = 0 \quad k > 1$$

A função de autocorrelação do modelo MA(1) apresenta apenas a primeira autocorrelação não nula e as demais iguais a zero. A primeira autocorrelação será positiva se 1 for menor que zero e negativa se θ_1 for maior que zero.

Segundo [55], uma propriedade importante da MA(1), proveniente da função de autocorrelação, é que sua “memória” é de somente um período. Uma dada observação, por exemplo Z53, está correlacionada apenas a seu antecessor Z52 e a seu sucessor Z54, mas não a qualquer outro membro da série. Para obter a condição de invertibilidade, isto é, para transformar um modelo MA(1) em um modelo AR(∞), é preciso impor a restrição de que $|\theta_1| < 1$. Para que um processo MA(q) se torne inversível, é necessário que as raízes da equação A.25 sejam maiores que um.

$$\theta(L) = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) = 0 \quad (\text{A.25})$$

Modelos auto-regressivos de médias móveis (ARMA)

Em alguns casos, pode ser necessário utilizar um grande número de parâmetros em modelos puramente AR ou puramente MA. Nesses casos, é vantajoso misturar os componentes de um modelo AR como os componentes de um modelo MA, gerando, assim, um modelo ARMA. O modelo ARMA(p,q) exigirá um número menor de termos e pode ser expresso conforme a equação A.26 [56]:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (\text{A.26})$$

O modelo ARMA mais simples é o ARMA(1,1), dado pela equação A.27:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (\text{A.27})$$

A função de autocorrelação do modelo ARMA(1,1) é dada por:

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 + 2\phi_1 \theta_1} \quad (\text{A.28})$$

$$\rho_k = \phi_1 \rho_{k-1} \text{ para } k > 1$$

A função de autocorrelação do modelo ARMA(p,q) apresenta características da função MA(q) para as defasagens $k < q$, pelo fato de a “memória” do componente de médias móveis durar apenas q períodos. Para defasagens maiores que $k + 1$ as características são iguais às de um modelo AR(p).

Modelos auto-regressivos integrados de médias móveis (ARIMA)

Como a maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, será necessário transformá-las caso ainda não sejam. Segundo [48], a transformação mais comum consiste em tomar diferenças sucessivas da série original até obter uma série estacionária.

A primeira diferença de Z_t é definida por A.29:

$$\Delta Z_t = Z_t - Z_{t-1} \quad (\text{A.29})$$

a segunda é dada por A.30:

$$\begin{aligned} D^2 Z_t &= D [D Z_t] = D[Z_t - Z_{t-1}] = \\ &= Z_t - 2Z_{t-1} - Z_{t-2} \end{aligned} \quad (\text{A.30})$$

Em situações normais, ainda segundo os autores citados, será suficiente tomar uma ou duas diferenças para que a série se torne estacionária. O número d de diferenças necessárias para tornar a série estacionária é denominado ordem de integração. A inclusão do termo de ordem de integração permite que sejam utilizados os modelos ARIMA(p,d,q) dados pela equação A.31:

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (\text{A.31})$$

em que: $w_t = \Delta^d \cdot Z_t$.

O modelo ARIMA(p,d,q) dado pela equação A.31 pode ser reescrito, como em A.32, utilizando o operador de defasagem L .

$$(1 - \phi_1 L - \dots - \phi_p L^p) w_t = (1 - \theta_1 L - \dots - \theta_q L^q) \varepsilon_t \quad (\text{A.32})$$

e com $w_t = (1 - L)^d \cdot Z_t$, tem-se:

$$\phi(L) (1 - L)^d Z_t = \theta(L) \varepsilon_t \quad (\text{A.33})$$

Modelos sazonais (SARIMA)

Os modelos ARIMA exploram a autocorrelação entre os valores da série em instantes sucessivos, mas quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidade s . Os modelos que contemplam as séries que apresentam autocorrelação sazonal são conhecidos como SARIMA.

Os modelos SARIMA contêm uma parte não sazonal, com parâmetros (p,d,q), e uma sazonal, com parâmetros (P,D,Q). O modelo mais geral é dado pela equação A.34.

$$(1 - \phi_1 L - \dots - \phi_p L^p) (1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps}) (1 - L)^d (1 - L^s)^D Z_t = (1 - \theta_1 L - \dots - \theta_q L^q) (1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs}) \varepsilon_t \quad (\text{A.34})$$

em que:

$(1 - \phi_1 L - \dots - \phi_p L^p)$ é a parte auto-regressiva não-sazonal de ordem p ;

$(1 - \Phi_1 L^s - \dots - \Phi_p L^{ps})$ é a parte auto-regressiva sazonal de ordem p e estação sazonal s ;

$(1 - L)^d$ é parte de integração não-sazonal de ordem d ;

$(1 - L^s)^D$ é parte de integração sazonal de ordem D e estação sazonal s ;

$(1 - \theta_1 L - \dots - \theta_q L^q)$ é a parte não-sazonal de médias móveis de ordem q ;

$(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs})$ é a parte sazonal de médias móveis de ordem Q e estação sazonal s .

Técnicas Inteligentes

O objetivo das pesquisas em Inteligência Artificial é capacitar o computador a executar funções que são desempenhadas pelo ser humano usando conhecimento e raciocínio. Os Sistemas Inteligentes podem manipular símbolos que representam entidades do mundo real. Por isso, eles são capazes de trabalhar eficazmente com conhecimento. A seguir serão apresentados alguns modelos de inteligência artificial.

Computação Genética e Evolucionária

Existe todo um conjunto de estratégias de resolução de problemas que foram influenciadas por processos de evolução das espécies, em particular pelas descobertas de Charles Darwin. A famosa Teoria da Evolução das Espécies de Charles Darwin é definida pela seguinte sinopse:

- Os organismos variam naturalmente em alguns dos atributos que apresentam;

- Tal variação pode levar a diferenças em termos de taxas de sobrevivência ou de reprodução;
- Em todos os organismos existe um excesso de número de progenitores, o que cria uma competição entre si, de modo a produzirem descendência;
- Se a variação que origina diferenças for hereditária, então os indivíduos que produzirem mais descendentes terão também mais filhos que se lhes assemelham, originando uma evolução de espécies, num processo chamado de seleção natural;
- Novas espécies surgem a partir de antigas, por mudanças (lentas) nos atributos (incluindo também os de comportamento) e tais mudanças são guiadas pela força estocástica da evolução natural.

A Teoria de Evolução das Espécies teve impacto imediato para o surgimento da Computação Genética e Evolucionária (CGE), em meados dos anos sessenta. Desde então, vários algoritmos que aplicam os princípios da evolução natural foram propostos para a resolução de problemas de otimização.

A CGE não resolve problemas via um processo de raciocínio lógico-matemático, do tipo dedutivo, isto é, são antes geradas populações de soluções, candidatas à resolução do problema, que competem entre si. A CGE é movida por um processo evolutivo, que à semelhança ao que ocorre no meio natural, e não sendo aleatório, progride de modo estocástico. As piores soluções tendem a serem descartadas, enquanto que as que se mostram promissoras na resolução de problemas tendem a sobreviver e a reproduzir-se, contribuindo para a geração de novas soluções [57].

Pode-se agrupar a CGE em quatro grandes categorias:

- Algoritmos Genéticos (AGEs);
- Programação Evolucionária;
- Estratégias Evolutivas;
- Programação Genética.

Desde o seu surgimento, a CGE foi essencialmente voltada para a resolução de problemas de otimização, onde o objetivo é maximizar (ou minimizar) uma dada

função. Dentro desse contexto, a CGE apresenta certas diferenças em relação aos métodos convencionais de procura, nomeadamente [58]:

- Parte para a procura de uma solução para um dado problema com base num conjunto de possíveis soluções e não a partir de uma única solução. Assim, a CGE comporta-se como um método de otimização global, capaz de escapar a ótimos locais, sendo indicada para funções multimodais. Além disso, o cálculo destes conjuntos de soluções é facilmente traduzido em processos de computação paralela;
- Utiliza a informação que apenas provém de uma função-objetivo e não de informação auxiliar. Ao contrário das técnicas convencionais de procura, a CGE não necessita de derivada das funções a otimizar, podendo ser aplicada a uma gama mais vasta de problemas;
- Usa regras probabilísticas de transição de estado.

Estas diferenças, quando tomadas em conjunto, contribuem para que a CGE encontre soluções onde outros métodos parecem falhar. Assim, a CGE tem sido usada largamente na resolução de diversos tipos de problemas, em que sobressaem os de:

- Otimização numérica de funções;
- Otimização Combinatória;
- Aprendizagem.

Apesar de sua juventude, a CGE já produziu um conjunto variado de técnicas que se tornaram particularmente úteis para problemas de otimização, quer numérica quer combinatória. Sendo assim, é surpreendente constatar que a aplicação destas técnicas no domínio da previsão seja escasso. De fato, a previsão via a CGE apenas surgiu nos anos noventa, sendo o número de aplicações diminuto e com pouco destaque.

Seguem algumas referências históricas a trabalhos de previsão no campo da CGE:

- No estudo de [59], foram utilizados AGE para otimizar o modelo de Holt-Winters, obtendo-se resultados encorajadores para séries sazonais curtas;

- O mesmo tipo de AGE também foi utilizado com sucesso para previsões financeiras por [60] onde foram codificados os coeficientes do modelo auto-regressivo;
- Chai e seus colaboradores [61], otimizaram os parâmetros do modelo ARMA, defendendo que os AGE conseguem melhores soluções do que as técnicas estatísticas convencionais.

Recentes desenvolvimentos na CGE, como o uso de AGE com Representações de Valores Reais e a Programação Genética [62] alargaram a aplicabilidade de CGE à previsão. Por exemplo, [63] aplicou a Programação Genética, com um alfabeto de símbolos terminais pertencendo ao conjunto {+, -, *, %, exp, sqrt, ln, sin, cos}, para a previsão de séries temporais.

Sistemas Neuro *Fuzzy*

Os conjuntos *fuzzy* são importantes para a representação de conceitos vagos, imprecisos ou incertos. Um sistema *fuzzy* pode ser utilizado como sistema de apoio à decisão, podendo representar o conhecimento de especialistas sobre um determinado domínio e interpolar decisões a partir de entradas contaminadas com incertezas. O formalismo matemático dos sistemas *fuzzy* permite a representação de algumas características do raciocínio humano [64].

Os sistemas *fuzzy* possuem modelos de inferência *fuzzy* onde são processados os antecedentes, quais serão os indicadores de disparo das regras e quais os operadores utilizados sobre os conjuntos *fuzzy* existentes, para executar o processamento do conhecimento. Tipicamente, utilizam-se modelos de inferência *fuzzy* específicos de acordo com as propriedades sintáticas definidas, ou seja, o modelo de processamento definido para o sistema depende basicamente da forma de armazenamento de informações escolhidas.

Seguindo essa linha de conhecimento, na década de oitenta, foi proposta uma estrutura de inferência também baseada na teoria de conjuntos *fuzzy* [65]. Essa estrutura é denominada sistema de inferência de Sugeno, modelo de inferência *fuzzy* paramétrico ou simplesmente modelo TSK. Estes modelos funcionam como bons aproximadores para sistemas que podem ser completa ou satisfatoriamente representados apenas por meio de suas relações de entrada e saída.

Os modelos *fuzzy* TSK são baseados na utilização de uma base de regras condicionais de inferência. Os consequentes da regras em vez de serem formados por relações *fuzzy*, compõem-se de equações paramétricas relacionando as entradas e as saídas do processo.

As Redes Neurais Artificiais (RNA), por meio da interconexão de unidade de processamento simples, realiza classificações de padrões permitindo a generalização de conhecimento contido no chamado conjunto de treinamento. Uma RNA é, na verdade um modelo não-linear generalizado cujos parâmetros são identificados a partir de um conjunto de dados e por meio de algoritmos eficientes.

Tendo em vista as características destes dois importantes paradigmas, a partir de meados da década de oitenta, diversos autores têm procurado reunir as potencialidades de sistemas *fuzzy* e as Redes Neurais nos chamados Sistemas Neuro-Fuzzy. Esses sistemas poderiam incorporar conhecimento empírico e ter seus parâmetros adaptados por meio de algoritmos eficientes.

O sistema ANFIS [66] consiste em implementar um modelo *fuzzy* do tipo TSK numa rede neural. Nesse modelo, as unidades na mesma camada têm funções similares, como descrito abaixo e apresentado na Figura A-3:

- Camada 1 – as saídas das unidades desta camada são os valores de pertinência das entradas em relação aos termos (conjuntos *fuzzy*);
- Camada 2 – as saídas das unidades desta camada são os valores de ativação das regras. Haverá tantas unidades na camada 2 quanto o número de regras;
- Camada 3 – as saídas das unidades desta camada são os valores normalizados dos valores de ativação das regras;
- Camada 4 – as saídas das unidades desta camada representam a contribuição de cada regra na saída total;
- Camada 5 – nesta camada, a saída parcial de cada regra é somada para o cálculo da saída total.

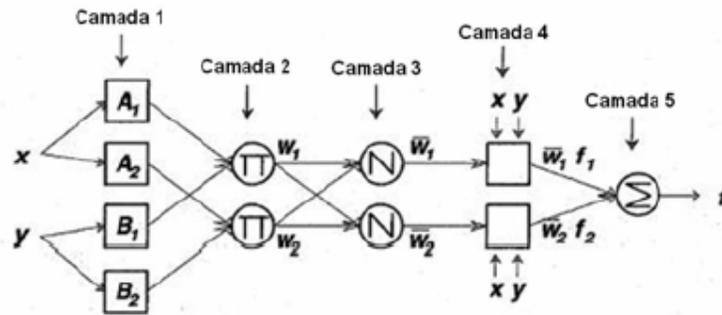


Figura A-3 – Arquitetura do Sistema ANFIS

A adaptação dos parâmetros no ANFIS é feita em duas etapas: na primeira os parâmetros (lineares) dos conseqüentes das regras são adaptados pela solução de um problema de mínimos quadrados; na segunda etapa, os parâmetros das premissas que definem as funções gaussianas (funções de pertinência do modelo TSK) são adaptados por meio de algoritmos do gradiente.

A arquitetura geral de Sistema Neuro-Fuzzy que preservam a interpretação das funções de pertinência é mostrada na Figura A-4. O sistema é composto de dois módulos: um módulo de fuzzificação, responsável pelo cálculo das funções de pertinência e um módulo de inferência que é uma RNA cuja entrada é definida pelo vetor de ativação $u(t)$ e saída é dada pelo vetor $y(t)$, cujos componentes são os valores de pertinência a cada uma das classes.

Tendo em vista que as unidades de entrada do módulo de inferência aproximam funções de base radial, as funções de ativação das unidades da camada de saída do módulo de inferência podem ser lineares, não havendo necessidade de unidade polarização (bias).

Para o módulo de fuzzificação, duas soluções são possíveis de acordo com a montagem do vetor de ativação $u(t)$. No modelo concatenado, o vetor $u(t)$ é formado pela concatenação dos vetores de pertinência obtidos pelas discretizações *fuzzy* associadas a cada variável. Esse modelo não permite a separação de classe não-linearmente separável mas pode levar em consideração um grande número de variáveis. No modelo combinado, o vetor $u(t)$ é montado pela combinação dos vetores de pertinência associados a cada variável.

Potter [18][19] apresentou trabalhos que visam a previsão de ventos utilizando o Sistema ANFIS como descrito no item 1.2.4.

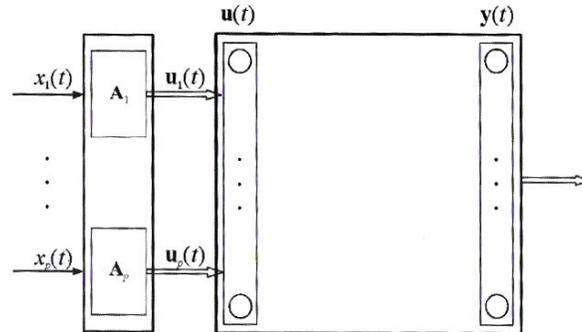


Figura A-4 – Arquitetura do modelo simplificado de Sistemas Neuro *Fuzzy*

Redes Neurais Artificiais (RNA)

O uso de modelos lineares na previsão de séries temporais, como os modelos clássicos de Box-Jenkins, está relacionado à simplicidade desses modelos, pois os parâmetros destes podem ser determinados por métodos estatísticos tradicionais. Entretanto, existem muitas situações nas quais se faz necessário um mapeamento não-linear entre as variáveis de entrada e as variáveis de saída, daí a necessidade de novas técnicas que permitam esse mapeamento de forma eficiente.

Desta forma, são apresentados modelos de redes neurais que são construídas através do uso de um algoritmo de abordagem construtiva de modo que as redes neurais se apresentem como uma abordagem alternativa dos métodos estatísticos tradicionais na solução de problemas de previsão de séries temporais [67].

Conceitos Básicos

As Redes Neurais Artificiais fundamentam-se nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar informação. Alguns estudos da neurofisiologia consideram que a riqueza computacional do cérebro humano está associada ao grande número de neurônios, interconectados por uma rede complexa de sinapses (Figura A-5) [68][67].

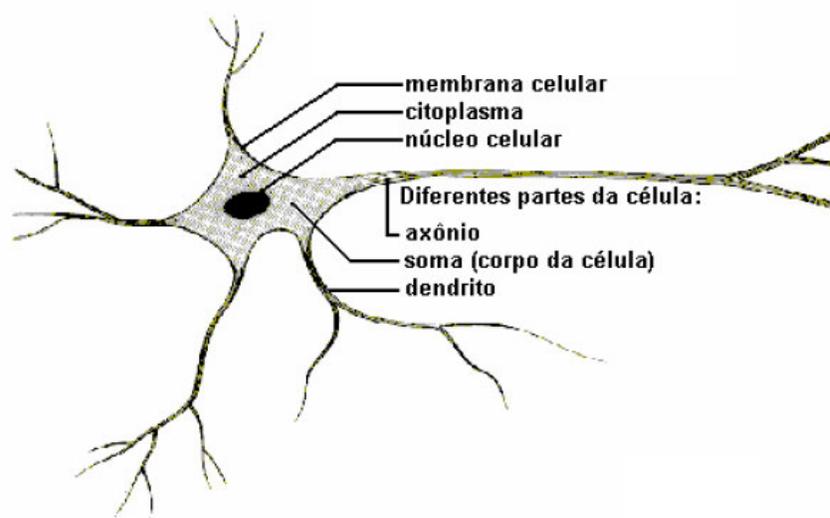


Figura A-5 – Constituição da célula neural

Estima-se que a quantidade de neurônios existentes no cérebro humano esteja na casa dos bilhões. Contudo, a velocidade de processamento destes componentes é relativamente baixa, quando comparada aos computadores tradicionais. Esta deficiência na velocidade de processamento dos neurônios é superada pela imensa quantidade de neurônios existentes operando de forma paralela. Estima-se que existam cerca de 10^{11} a 10^{14} neurônios operando em paralelo no cérebro humano e que cada um destes está conectado através de 103 a 104 sinapses, em média [69].

Tais características permitem ao cérebro humano executar rapidamente certas funções (por exemplo, reconhecer fisionomias e sons) que os computadores convencionais não conseguem realizar com o mesmo desempenho.

Uma definição possível de modelos conexionistas de computação, também chamados de redes neurais artificiais (RNA), redes neurais ou sistemas de processamento paralelo distribuído (PDP), consiste em encará-los como "uma estrutura de processamento de informação distribuída e paralela". Ela é formada por unidades de processamento, comumente chamada de nós, neurônios ou células, interconectadas por arcos unidirecionais, também chamados de ligações, conexões ou sinapses. Os neurônios possuem memória local e podem realizar operações de processamento de informação localizada. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada

ramificação possuindo o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula

Os principais elementos utilizados na descrição de RNA são a representação distribuída, as operações locais e o processamento não-linear. Estes atributos especificam duas aplicações básicas das RNA: situações onde poucas decisões têm que ser tomadas a partir de uma grande quantidade de dados, e situações onde um complexo mapeamento não-linear deve ser aprendido [70].

Componentes das RNA

De acordo com [37], um modelo conexionista pode ser descrito por oito elementos principais:

- um conjunto de unidades de processamento;
- um estado de ativação;
- uma função saída;
- um padrão de interconexão;
- uma regra de propagação;
- uma regra de ativação;
- uma regra de aprendizado;
- um ambiente onde o sistema deve funcionar.

i) Unidade de Processamento

A unidade de processamento (neurônio) é o componente básico das RNA e corresponde ao neurônio humano. Na Figura A-6, é apresentada uma ilustração de um neurônio como unidade que representa um limite a ser ultrapassado. As entradas que chegam a ele representam os dendritos. Cada dendrito possui um sinal (x) que é adicionado. Depois da adição, este sinal é processado através da função que representa o limite ou função de ativação, a qual produz um sinal de saída. Nesta figura, o neurônio pode ser considerado como uma representação simplificada dos neurônios biológicos.

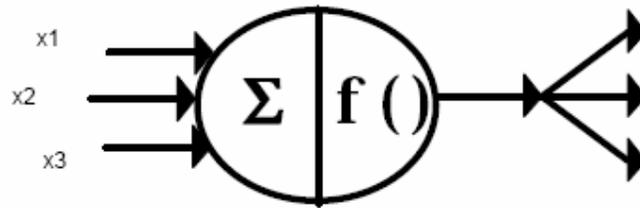


Figura A-6 – Representação do Neurônio Artificial

Cada neurônio da rede calcula um estado de ativação, que é um valor numérico líquido de saída. O cálculo desta ativação é realizado a partir dos sinais das saídas dos demais neurônios conectados diretamente a este neurônio, dos correspondentes pesos destas conexões e da função de ativação [37][71].

ii) Estado de Ativação

O estado de ativação de todos os neurônios da rede, ou seja, o estado de ativação do sistema, especifica o que está sendo representado na rede em um determinado instante t qualquer. Os valores das ativações existentes na rede podem ser discretos, por exemplo assumindo os valores $\{0,1\}$ ou $\{-1,0,1\}$, como também podem ser contínuos, assumindo valores no intervalo $[0,1]$ ou $[-1,1]$, que são calculados pela regra de ativação.

iii) Função de Saída

Os neurônios interagem entre si através de um valor que é transmitido pelas conexões. Este valor é determinado pela ativação do neurônio estimulador. A função de saída é o mapeamento do estado de ativação num sinal de saída. A função de saída pode ser a função identidade, isto é, o sinal de saída é igual ao estado de ativação. Em muitos casos, a função de saída é uma função porteira (patamar, limiar) que só emite sinal quando o seu estado ultrapassa um certo limite.

iv) Padrão de Interconexão

Pode-se representar o padrão de interconexão da rede por uma matriz de pesos w , onde um elemento $w_{i,j}$ corresponde à influência do neurônio i sobre o neurônio j . Conexões com pesos positivos, chamadas de excitatórias, indicam o reforço na ativação do neurônio. Conexões com pesos negativos, chamadas de inibitórias, indicam inibição na ativação do neurônio. O conjunto das ligações excitatórias e inibitórias existentes na rede, determina o comportamento da mesma.

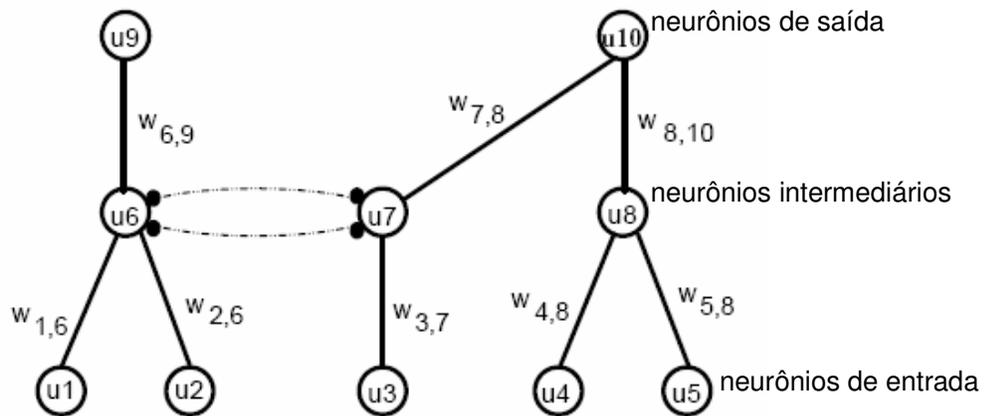


Figura A-7 – Exemplo de RNA

As RNA podem ser organizadas em camadas. A camada de entrada da rede não re-computa suas saídas, ela é usada somente para a entrada dos dados. Portanto, não existem arcos de entrada em suas células. Os valores resultantes das células pertencentes à camada de saída são considerados os resultados finais da rede como um todo. Na Figura A-7, os neurônios u_9 e u_{10} são considerados as saídas da rede. Os neurônios que não pertencem nem à camada de entrada e nem à de saída são chamadas de intermediários ou ocultos.

Observando a Figura A-7 quando u_{10} é ativado o valor de sua ativação é determinado pelas ativações de u_3 , u_4 , u_5 , u_7 e u_8 e os pesos $w_{4,8}$, $w_{5,8}$, $w_{3,7}$, $w_{7,8}$ e $w_{8,10}$. Podem existir conexões que ligam neurônios da mesma camada, sendo chamados de sinapses intra-camadas.

As ligações inter-camadas conectam células de camadas diferentes. No caso da Figura A-7, as conexões que unem os neurônios u_6 e u_7 são sinapses intra-camadas inibitórias. A ligação que conecta o neurônio u_7 ao u_{10} é uma inter-camada excitatória.

Com relação às conexões que ligam os neurônios u_6 e u_7 elas são chamadas de ligações recorrentes. Estas conexões formam um ciclo, voltando para o neurônio de origem (aquele que foi ativado primeiro). Podem existir conexões que liguem os neurônios de diferentes camadas de modo a formar ciclos entre as mesmas. Por exemplo, uma ligação que conectasse o neurônio u_{10} a u_5 formaria um outro ciclo

na rede da Figura A-7. Portanto, as RNA podem ser classificadas em redes cíclicas ou acíclicas, em função da existência ou não de ligações cíclicas.

v) *Regra de Propagação*

Cada neurônio calcula sua nova ativação através de uma regra de propagação. Em geral, ela é definida como sendo uma função somatória da entrada líquida dos pesos dos neurônios que estão diretamente conectados. Isto é feito através da multiplicação do estado do j -ésimo neurônio (u_j) pelo peso da conexão w_{ij} , do i -ésimo para o j -ésimo neurônio, para cada um dos j neurônios que estão conectados à entrada do neurônio i . A regra de propagação se completa através do limite que deve ser ultrapassado pelo somatório explicado acima. Este limiar, que pode ser nulo inclusive, deve ser superado para que ocorra a ativação da célula.

vi) *Regra de Ativação*

É necessária uma regra que calcule o valor de ativação de um neurônio no instante t . É preciso uma função f que calcule a nova ativação utilizando as entradas líquidas. Esta função de ativação, também chamada de função limiar, mapeia os neurônios de entrada para um intervalo pré-especificado de saída. As quatro funções de ativação mais utilizadas são linear, rampa, degrau e sigmóide, representadas na Figura A-8, nas letras A, B, C e D, respectivamente [72].

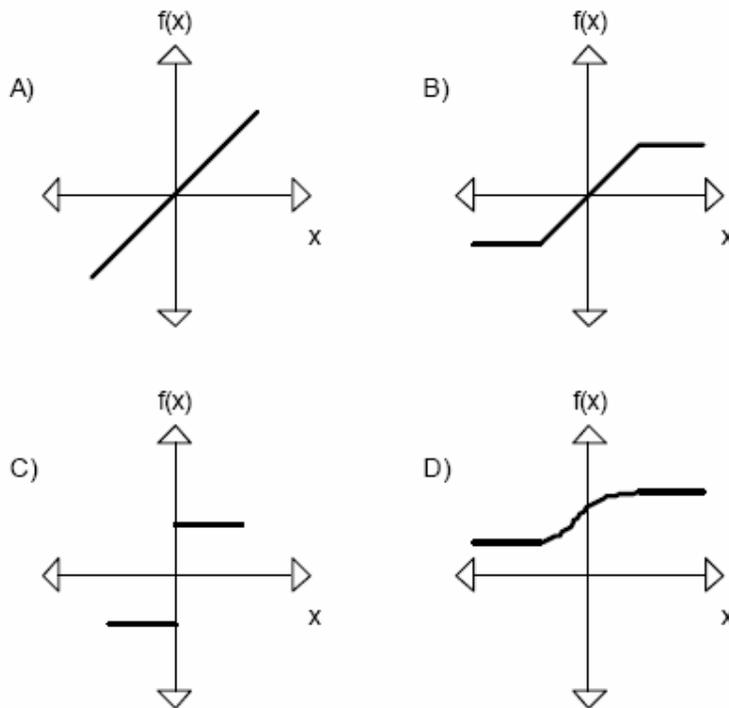


Figura A-8 – Exemplos de Funções de Ativação

vii) Regra de Aprendizado

A modificação do processamento ou da estrutura de conhecimento de uma rede neural envolve a alteração do seu padrão de interconexão. Em princípio, isto pode ser feito de três maneiras:

- desenvolvimento de novas conexões;
- perda de conexões existentes na rede;
- modificação dos pesos das conexões já existentes.

Quando o padrão de interconexão for uma matriz de pesos W , os dois primeiros itens podem ser simulados através do último. Tomando-se uma ligação com peso zero, e modificando-a para um valor positivo ou negativo, equivale a desenvolver esta conexão. Da mesma forma, alterar o peso de uma conexão para zero significa desconectá-la. Portanto, as regras de aprendizado alteram os pesos das conexões das redes através da experiência.

Em geral, as regras de aprendizado podem ser consideradas como uma variante da Regra de Hebb, que estabelece o princípio da alteração da eficiência das

conexões como base do aprendizado. Segundo o postulado, "quando o neurônio A se encontra próximo do neurônio B de forma a poder excitá-lo, e o faz repetidas vezes, algum processo desconhecido provoca o crescimento de conexões entre as células A e B, facilitando assim a excitação de B por A".

viii) Ambiente

O último componente de RNA é o ambiente onde a rede deve funcionar. É necessário especificar a natureza do ambiente, estabelecendo os possíveis padrões de entrada e saída. Em alguns modelos, por exemplo o PDP de Rumelhart, o ambiente é representado como uma função estocástica que varia ao longo do tempo sobre um espaço de padrões de entrada. Geralmente, o ambiente é caracterizado como uma distribuição de probabilidade estável sobre um conjunto de padrões de entrada. Esta distribuição pode ser independente, ou não, de entradas ou de respostas passadas do ambiente.

Aprendizado em Redes Neurais

Na sua essência, o conceito de aprendizado envolve mudança associada a aperfeiçoamento. Carbonell [73] define o conceito de aprendizado, dentro do campo da inteligência artificial, como a habilidade de realizar tarefas novas que não podiam ser realizadas anteriormente, ou melhorar a realização de tarefas antigas, como resultado de mudanças produzidas pelo processo de aprendizado.

Uma classificação, apresentada por Lippman [74], relacionou as redes quanto ao tipo de controle realizado durante o aprendizado (supervisionado ou não-supervisionado). No supervisionado existem, basicamente, rótulos que especificam a classe correta para os padrões de entrada, enquanto que no aprendizado não-supervisionado não existem tais rótulos.

Diversas técnicas de aprendizado podem ser utilizadas nas RNA, entre elas destaca-se as mais relevantes [75]:

- Correção de Erros: aprendizado supervisionado que ajusta os pesos das conexões entre neurônios, na proporção da diferença entre os valores desejados e computados de cada neurônio da camada de saída;

- Reforço: aprendizado supervisionado onde os pesos são recompensados quando o sistema executa ações apropriadas, e punidos, caso contrário;
- Regra de Hebb: aprendizado onde o ajuste dos pesos das conexões é realizado em função da relação de valores dos dois neurônios que ela conecta. Pode ser aplicado tanto ao aprendizado supervisionado quanto ao aprendizado não-supervisionado.

Principais Modelos de Redes Neurais

Existem muitos modelos conexionistas, e uma quantidade razoável de publicações que se dedicam a classificá-los. Dentre estes modelos, foram selecionados cinco que são apresentados a seguir em conjunto com os pesquisadores que os desenvolveram.

- Perceptron - proposto por F.Rosenblatt em 1957;
- Perceptron de Multi-Camadas (retro-propagação) - proposto por P.Werbos, D.Parker, D.Rumelhart em 1974;
- Classificador de Carpenter-Grossberg (Sistema ART) - proposto por G.Carpenter, S.Grossberg em 1978;
- Rede de Kohonen - proposto por T.Kohonen em 1980;
- Rede de Hopfield - proposto por J.Hopfield em 1982.

i) Perceptron

O perceptron de duas camadas que pode ser usado com valores contínuos foi o primeiro modelo conexionista desenvolvido. Suas principais características são:

- Classe de tarefas: reconhecimento de padrões (ex.: caracteres impressos);
- Propriedades dos neurônios: possuem entradas binárias e saídas que assumem os valores +1 ou -1. A função de ativação é a função degrau;
- Propriedades das redes: rede acíclica de duas camadas;
- Aprendizado: utiliza a técnica de Reforço.

Esta rede gerou muito interesse pela habilidade de aprender a reconhecer padrões linearmente separáveis. Contudo, como a grande maioria dos problemas práticos relevantes não é linearmente separável, o perceptron não tem uso generalizado.

ii) Perceptrons Multi-Camadas (retro-propagação)

Foram desenvolvidos no começo da década de setenta, são redes acíclicas com uma ou mais camadas de neurônios intermediários entre as camadas de entrada e saída. Um algoritmo capaz de treinar os *perceptrons* multi-camadas é o retro-propagação. Suas principais características são:

- Classe de tarefas: reconhecimento de padrões (ex.: controle adaptativo de braços de robôs) e processamento de fala;
- Propriedades dos neurônios: são do tipo perceptron e possuem valores contínuos. A função de ativação é a sigmóide;
- Propriedades das redes: rede acíclica de três camadas, no mínimo;
- Aprendizado: utiliza técnica de Correção de Erros com o uso da regra delta generalizada.

O algoritmo retro-propagação foi testado em uma série de problemas clássicos, e em problemas relacionados com reconhecimento de padrões visuais. Na maioria dos casos, ele encontrou boas soluções para os problemas propostos, apesar do algoritmo, às vezes, fornecer uma configuração de pesos correspondente a um mínimo local da função erro. Isto é devido ao fato do retro-propagação utilizar o método do gradiente e, a princípio, a superfície de erro possuir uma forma qualquer.

iii) Classificador de Carpenter-Grossberg (Sistema ART)

No final da década de setenta, Carpenter e Grossberg projetaram uma rede capaz de formar aglomerados de informações (*clusters*), e de ser treinada sem supervisão, chamada de sistema ART. Suas principais características são:

- Classe de tarefas: reconhecimento de padrões (ex.: reconhecimento de sinais de radar ou sonar) e processamento de imagens;
- Propriedades dos neurônios: possuem entradas binárias, podendo assumir valores contínuos. A função de ativação é a sigmóide;
- Propriedades das redes: rede cíclica de três camadas;

- Aprendizado: utiliza técnica de aprendizado Competitivo e Cooperativo que foi introduzida pelo próprio Grossberg.

No sistema ART, o algoritmo principal seleciona a primeira entrada como um exemplo para o primeiro aglomerado. A entrada seguinte é comparada com este primeiro exemplo. Ela é agrupada com o mesmo, se a distância para o primeiro for menor que um certo limite, chamado de limiar de vigilância. Caso contrário, este exemplo formará um novo aglomerado. Este processo se repete para todas as entradas existentes. O número de aglomerados cresce em função do limiar e da métrica da distância usada para comparar os exemplos de entrada dos aglomerados.

iv) Rede de Kohonen

No começo da década de oitenta, Kohonen propôs uma rede onde se corroborou o estudo teórico sobre a organização dos caminhos de sensoriamento na mente. Suas principais características são [76][77]:

- Classe de tarefas: reconhecimento de padrões (ex.: reconhecimento da fala) e aprendizado da distribuição de probabilidades dos dados (ex.: auto-organização de mapas de características);
- Propriedades dos neurônios: possuem entradas contínuas. A função de ativação é a sigmóide;
- Propriedades das redes: rede cíclica de duas camadas;
- Aprendizado: utiliza técnica, que foi introduzida pelo próprio Kohonen.

Segundo esta teoria, o cérebro humano foi considerado como uma coleção estruturada de neurônios. Com isto, foi admitida uma ordem espacial das unidades de processamento que permitiu elaborar uma rede neural dotada de mecanismos que permitem formar representações estruturadas dos estímulos de entrada. Após o aprendizado, as unidades respondem a diferentes estímulos de maneira ordenada, formando um sistema de coordenadas de características sobre a rede.

v) Rede de Hopfield

Também na década de oitenta, o trabalho de Hopfield contribuiu substancialmente para o ressurgimento das pesquisas em RNA. As redes de Hopfield são mais apropriadas quando representações binárias permitem modelar a situação desejada. Por exemplo, imagens em preto e branco, onde os elementos de entrada

podem ser representados pelos valores de cada ponto da imagem (0 = branco, 1 = preto). Suas características são [69]:

- Classe de tarefas: reconhecimento de padrões (ex.: reconhecimento de dados ou imagens completas a partir de fragmentos) e memória associativa;
- Propriedades dos neurônios: possuem entradas binárias e saídas que assumem os valores +1 ou -1. A função de ativação é a sigmóide;
- Propriedades das redes: rede cíclica de uma camada;
- Aprendizado: os padrões são armazenados no começo.

A Rede de Hopfield possui duas limitações quando usada como memória de acesso por conteúdo. Primeiro, apesar dos padrões armazenados, a rede pode convergir para um novo padrão diferente dos padrões exemplo existentes. Isto pode produzir uma situação em que a rede não casa com um padrão já existente. Uma segunda limitação é que o padrão exemplo será considerado instável se ele compartilhar muitos bits com outros padrões exemplo, o que pode ocasionar uma convergência da rede para este outro exemplo.

Benefícios das RNA

O poder computacional de uma RNA se baseia em dois aspectos fundamentais: numa topologia que apresenta o paralelismo e, por outro lado, na sua capacidade de aprendizagem e generalização, isto é, conseguir responder de modo adequado a novas situações que tornam possível a resolução de problemas que, de outra forma, seriam intratáveis.

Isto não quer dizer que as RNA sejam caixas mágicas que consigam por si dar resposta a qualquer problema. Em vez disso, precisam não raras vezes de ser integradas com outros sistemas para a resolução de problemas. Convém, ainda reconhecer que se está ainda muito longe de atingir uma arquitetura que simule o cérebro humano [78].

No entanto, as RNA apresentam características únicas, que não se encontram em outros mecanismos ou técnicas [78][43]:

- Aprendizagem e generalização; isto é, conseguem descrever o todo a partir de algumas partes, constituindo-se como formas eficientes de aprendizagem e armazenamento de conhecimento;
- Processamento maciçamente paralelo, isto é, permitindo que tarefas complexas sejam realizadas num curto espaço de tempo;
- Não linearidade, isto é, atendendo a que a maioria dos problemas reais a equacionar e resolver são de natureza não linear;
- Adaptabilidade, isto é, podendo adaptar a sua topologia de acordo com mudanças de ambiente;
- Robustez e degradação suave, isto é, permitindo processar o ruído ou informação incompleta de forma eficiente, assim como sendo capazes de manter o seu desempenho quando há desativação de algumas de suas conexões e/ou neurônios; e
- Flexibilidade, isto é, com um grande domínio de aplicabilidade.

Comparação entre CGE - Neuro-Fuzzy - RNA

A aplicação de modelos computacionais inspirados nos processos de evolução natural próprio dos seres vivos para a previsão de séries temporais ainda é recente, tendo-se iniciado nos fins dos anos 80 [43].

As RNA são candidatas naturais para a previsão de séries temporais, devido a capacidades como aprendizagem não linear e tolerância ao ruído. Por outro lado, espera-se que o uso da CGE para a previsão cresça, motivado por vantagens como uma representação explícita dos modelos e uma procura adaptativa global, que permite escapar de mínimos locais indesejáveis. O uso de técnicas combinadas como o Neuro-Fuzzy também está sendo destacada por aproveitar as vantagens de cada modelo (neural e fuzzy).

Uma das dificuldades, que resulta no uso das RNA para a resolução de problemas, reside no tempo para a procura do melhor tipo de rede ou topologia. Presentemente, a maior parte do uso de RNA para a previsão de séries temporais ainda se baseia num conjunto de heurísticas que, dependem um pouco da arte do investigador.

Outra dificuldade relacionada com a adoção dos modelos inspirados na natureza, surge no processo de aprendizagem, que exigem elevados requisitos computacionais.