

Utilizando Redes Neurais para Previsão de Velocidade do Vento

Trabalho de Conclusão de Curso

Engenharia da Computação

Lorena Graciely Neves Tablada

Orientador: Prof. Dr. Mêuser Jorge Silva Valença



UNIVERSIDADE
DE PERNAMBUCO

Lorena Graciely Neves Tablada

**Utilizando Redes Neurais para Previsão
de Velocidade do Vento**

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

Recife, Maio de 2010.

*Dedico este trabalho a meus pais,
Pedro e Alaneide Tablada, incansáveis
incentivadores de meus estudos e a
meu namorado Saulo, por participar
de seu desenvolvimento e da minha vida.*

Agradecimentos

Agradeço, em primeiro lugar, aos meus pais, Pedro Edgardo Tablada Corrales e Alaneide Maria Neves Tablada e a minha irmã Thatiany Carolina Neves Tablada por todo o esforço aplicado em me tornar uma pessoa de bem, com um futuro promissor.

Agradeço, também, ao meu namorado, Saulo Medeiros de Oliveira Corrêa dos Santos, que participou ativamente de todo meu processo de graduação enquanto também se graduava no mesmo curso.

Agradeço a minha prima Thallyta por trazer alegria sempre que estava presente.

Agradeço igualmente ao resto da minha família e aos meus amigos pelo incentivo aos estudos que sempre recebi e por terem compreendido a privação parcial de meu convívio enquanto não pude exercê-lo.

Agradeço a todos os que foram um dia meus professores, em especial ao meu orientador, o Prof. Dr. Mêuser Jorge Silva Valença, por todo o tempo que dedicou a me auxiliar no desenvolvimento desse projeto, mesmo tendo tantos outros a orientar.

Finalmente, agradeço a Deus por ter me presenteado com todas as pessoas acima citadas e por ter me dado a oportunidade de estudar e de depender apenas de mim para alcançar meus objetivos.

Resumo

Atualmente, um dos grandes problemas do mundo trata de uma questão relativa à energia. O desafio energético mundial é satisfazer sua crescente demanda, proteger as fontes diversificando a matriz energética mundial e, ao mesmo tempo, afrontar a ameaça da mudança climática. A energia pode ser utilizada de forma mais civilizada e menos dispendiosa através da utilização de fontes renováveis, como a energia eólica. As fazendas eólicas tem seu potencial diretamente ligado à velocidade do vento da região onde atuam, por isso, ter boas estimativas da velocidade do vento futura é fundamental para a construção de um planejamento seguro. Entretanto, essa tarefa apresenta grandes dificuldades devido às complexas características do vento, como a alta variabilidade de sua velocidade e direção. Esse trabalho tem como objetivo desenvolver um sistema que utilize uma técnica de computação inteligente, conhecida como Rede Neural Artificial, para obter previsões de velocidade do vento mais precisas e, assim, beneficiar financeira e ecologicamente o planeta.

Abstract

At present, one of the world's biggest problems is energy. The challenge the world faces is to satisfy the growing demand for energy and protect its sources, diversifying the world's energy matrix and, simultaneously, confronting the threat of climate change. Energy can be used in a more civilized and less wasteful way through the use of renewable sources, such as wind energy. Wind farms' potential is directly linked to the speed of the wind in the region where they function. Consequently, obtaining accurate estimates of future wind speed is fundamental to safe planning. Such a task, however, presents great difficulties due to the complex characteristics of the wind, such as its speed and direction. The purpose of this study is to develop a system which uses an intelligent computing technique known as the Artificial Neural Network to get more accurate prediction of wind speed and, in turn, help the planet both financially and economically.

Sumário

Resumo	v
Abstract	vi
Sumário	vii
Índice de Figuras	ix
Índice de Tabelas	x
Tabela de Símbolos e Siglas	xi
Capítulo 1 Introdução	12
1.1 Motivação	12
1.2 Objetivos	13
1.2.1 Objetivo Geral	13
1.2.2 Objetivos Específicos	14
1.3 Estrutura da Monografia	14
Capítulo 2 Revisão Bibliográfica	15
2.1 Energia Eólica	15
2.1.1 O Recurso Eólico	15
2.1.2 Turbina Eólica	17
2.1.3 No Brasil	22
2.2 Redes Neurais Artificiais	23
2.2.1 Neurônio Biológico	23
2.2.2 Neurônio Artificial	24
2.3 <i>Multi-Layer Perceptron</i>	26
2.3.1 Introdução	26
2.4 <i>Back-propagation</i>	27
2.4.1 Critério de Parada	29
	vii

Capítulo 3 Metodologia	31
3.1 Base de Dados	31
3.2 Método de Seleção de Variáveis	33
3.3 Pré-processamento	37
3.4 Predizendo Velocidade do Vento com a RNA MLP	39
Capítulo 4 Resultados	44
4.1 Variação dos Parâmetros	45
4.2 Resultados	47
4.2.1 Primeira Arquitetura – 1 Rede com 144 Saídas	47
4.2.2 Segunda Arquitetura – 3 Redes com 48 Saídas Cada	47
4.2.3 Terceira Arquitetura – 24 Redes com 6 Saídas Cada	48
4.3 Comparação dos Resultados	49
Capítulo 5 Conclusão e Trabalhos Futuros	50
Bibliografia	51

Índice de Figuras

Figura 2.1. Turbina Darrieus de duas lâminas.....	21
Figura 2.2. Turbina horizontal.....	21
Figura 2.3. Neurônio biológico.....	24
Figura 2.4. Modelo matemático de um neurônio biológico.....	24
Figura 2.5. Exemplo de uma Rede Neural Artificial de múltiplas camadas.....	26
Figura 2.6. Exemplo ilustrativo de cálculo do erro σ para um neurônio de saída (em azul) e um escondido (em vermelho).....	29
Figura 2.7. Época de parada da validação cruzada.....	30
Figura 3.1. Gráfico da Velocidade do vento em função do tempo para a Estação Meteorológica de São Martinho da Serra.....	32
Figura 3.2. Primeira arquitetura da RNA aplicada ao problema de previsão de velocidade do vento.....	40
Figura 3.3. Segunda arquitetura da RNA aplicada ao problema de previsão de velocidade do vento.....	41
Figura 3.4. Terceira arquitetura da RNA aplicada ao problema de previsão de velocidade do vento.....	42
Figura 4.1. Valores ótimos dos parâmetros configuráveis do MLP para a primeira arquitetura.....	46

Índice de Tabelas

Tabela 1. Amostra da base de dados da EM de São Martinho da Serra	33
Tabela 2. Correlação linear e coeficiente de determinação entre a velocidade do vento e a mesma variável em tempos anteriores	35
Tabela 3. Correlação linear e coeficiente de determinação entre a velocidade do vento e a temperatura do ar em tempos anteriores.....	35
Tabela 4. Correlação linear e coeficiente de determinação entre a velocidade do vento e a direção do vento em tempos anteriores.....	36
Tabela 5. Descrição da base de dados utilizada	38

Tabela de Símbolos e Siglas

- **RNA:** Redes Neurais Artificiais
- **MLP:** *Multi-Layer Perceptron*
- **CI:** Computação inteligente
- **CBEE:** Centro Brasileiro de Energia Eólica
- **ANEEL:** Agência Nacional de Energia Elétrica
- **CEPEL:** Centro de Pesquisas Elétricas
- **PROINFA:** Programa de Incentivo às Fontes Alternativas de Energia
- **AS:** *ActionScript*
- **EM:** Estação Meteorológica
- **SONDA:** Sistema de Organização Nacional de Dados Ambientais
- **EPMA:** Erro Percentual Médio Absoluto

Capítulo 1

Introdução

Esse capítulo se inicia com a descrição da motivação para o desenvolvimento deste trabalho. Posteriormente, são expostos os principais objetivos a serem atingidos. Finalmente, seu encerramento enumera o conteúdo abordado nos capítulos seguintes.

1.1 Motivação

Atualmente, um dos grandes problemas do mundo trata de uma questão relativa à energia. O desafio energético mundial é satisfazer a crescente demanda de energia, proteger as fontes diversificando a matriz energética mundial e, ao mesmo tempo, afrontar a ameaça 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, como por exemplo, fonte mineral, atômica ou térmica. [1] A energia pode ser utilizada de forma mais civilizada e menos dispendiosa através da utilização de fontes renováveis como a energia eólica, solar, das marés, geotérmica, das águas e outras. As energias renováveis estão se tornando fundamentais para a humanidade. Elas são seguras, limpas e abundantes. Ao contrário dos combustíveis convencionais, têm disponibilidade em quase todos os países do mundo, sendo a energia eólica a de maior interesse na atualidade. [2]

Além disso, 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, segundo TERCIOTE [3], 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 deixado de se limitar a comunidades isoladas, seu principal nicho de aplicação no passado.

Devido à previsão de energia eólica depender principalmente da velocidade do vento, a previsão dessa última tornou-se um importante objeto de estudo há alguns anos. Apesar de a eólica ser a principal e mais promissora fonte de energia alternativa em crescimento, essa vem apresentando grandes dificuldades na previsão de potência gerada devido às suas complexas características, como a alta variabilidade de sua velocidade e direção e dificuldade na modelagem de uma série temporal bastante irregular.

Dessa maneira, o principal desafio encontrado para realizar essa medição está no fato de encontrar o modelo que melhor consiga prever a velocidade do vento considerando sua arquitetura e variáveis que influem em seu resultado.

1.2 Objetivos

Esta seção expõe, primeiramente, o objetivo geral e, em seguida, os objetivos específicos deste estudo.

1.2.1 Objetivo Geral

De maneira geral, o objetivo do projeto proposto é desenvolver uma aplicação que utilize uma Rede Neural Artificial (RNA) e seja capaz de prever a velocidade do

vento nas próximas 24 horas de 10 em 10 minutos, ou seja, 144 previsões, de maneira satisfatória.

1.2.2 Objetivos Específicos

Especificamente, serão seguidos os seguintes passos:

- Definir as variáveis que mais influem no valor da velocidade do vento;
- Construir uma Rede Neural Artificial que receba tais variáveis como suas entradas e produza os valores das velocidades do vento previstos para as próximas 24 horas.
- Realizar uma comparação com outros trabalhos realizados na mesma área.

1.3 Estrutura da Monografia

O Capítulo 2 constitui-se do conteúdo teórico essencial para se compreender o trabalho proposto, a saber: energia eólica e RNAs. Em seguida, o Capítulo 3 mostra todas as abordagens desenvolvidas para atingir o objetivo geral do projeto, tais como o uso de MLPs, incluindo algoritmos de seleção de atributos e ajuste de suas principais propriedades. Após isso, o Capítulo 4 mostra todos os resultados obtidos a partir das aplicações e simulações das técnicas desenvolvidas. Por fim, o Capítulo 5 resume o trabalho final, reúne dificuldades encontradas, discussões geradas e as conclusões obtidas, além de melhorias e trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

Este capítulo pormenoriza todo conteúdo teórico utilizado como base na tentativa de resolver o problema descrito no capítulo 1. A seção 2.1 faz considerações a respeito da energia eólica. Em seguida, a seção 2.2 discorre sobre RNAs, uma técnica de Computação Inteligente (CI) que vem mostrando ser uma alternativa mais precisa em problemas de previsão e classificação. A seção 2.3 aborda, especificamente, o conceito e modo de utilização de MLPs. E, por fim, a última seção (2.4) discorre sobre o algoritmo *back-propagation*.

2.1 Energia Eólica

Nesta seção, está localizado todo o conteúdo teórico relativo a energia eólica: definição, componentes necessários para sua geração, parte de sua história e sua situação no Brasil.

2.1.1 O Recurso Eólico

Segundo RODRIGUES [1], a energia eólica é uma forma de energia solar. A justificativa dessa afirmação pode ser o seguinte fato: Enquanto o sol aquece o ar, água e terra de um lado do planeta, o outro lado é resfriado através da radiação térmica. A rotação do planeta faz com que esse ciclo de aquecimento e resfriamento de sua superfície aconteça diariamente. Porém, regiões diferentes da superfície terrestre respondem desigualmente a esse aquecimento. Exemplificando, os oceanos se aquecerão mais lentamente do que as terras porque a água tem uma

capacidade maior de “estocar” calor. Dessa diferente taxa de aquecimento e resfriamento são criadas desmedidas 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. A energia eólica é aquela obtida pelo movimento do ar (vento). É uma abundante fonte de energia, renovável, limpa e disponível em todos os lugares. [4]

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. [5]

De modo geral, os movimentos das massas de ar na atmosfera acontecem de forma turbulenta. Dessa maneira, 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 (2.1):

$$V = \bar{V} + \Delta V \quad (2.1)$$

onde \bar{V} representa a velocidade média do vento e ΔV , a flutuação. Porém, na prática, para algumas aplicações, leva-se em consideração apenas a intensidade da velocidade média do vento. A maior parte dos instrumentos de medição possui configurações parametrizáveis capazes de filtrar as flutuações e fornecer somente o valor da velocidade média do vento.

Sabe-se ainda que a velocidade do vento decresce à medida que se aproxima da superfície da terra devido à fricção entre o ar e o solo. Portanto, quanto maior a aspereza do solo, maior o decréscimo da velocidade. Por exemplo, áreas florestais têm menor escoamento de ar que áreas descampadas. Por isso, as 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). No Brasil, é também de costume se realizar medições em alturas de 25 e 50 metros.

2.1.2 Turbina Eólica

Turbinas eólicas são máquinas que utilizam a energia eólica, também chamadas de energia cinética dos ventos, para que suas pás rotacionem e transformem 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 em um plano perpendicular à direção principal do vento. As turbinas eólicas de eixo vertical possuem suas pás girando em um 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 somente pode extrair energia cinética do ar que passa através da área interceptada pelas pás rotativas. 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 (2.2).

$$P = C_p \cdot \frac{1}{2} \cdot \rho \cdot A \cdot V^3 \quad (2.2)$$

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 da relação entre a velocidade do rotor e a velocidade do vento e

V = velocidade do vento em m/s.

De acordo com a equação 2.2, pode-se observar que a energia potencial da turbina eólica depende do cubo da velocidade do vento; isto significa que, por exemplo, 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

relacionada à velocidade do vento mostra a importância na obtenção precisa dos dados do vento para a estimativa da energia disponível.

Segundo [1], diversos fatores contribuem na complexidade do campo de escoamento das turbinas eólicas, com características acentuadamente não estacionárias. Entre os fatores mais importantes, os seguintes podem ser destacados:

- Efeitos da camada limite atmosférica modificando a magnitude e direção da velocidade de corrente livre;
- Giro em um 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;
- Perdas aerodinâmicas por efeitos tridimensionais; e
- Formação da esteira do rotor (na parte de trás da turbina forma-se uma turbulência no vento com velocidade reduzida relativa ao vento incidente).

A direção do vento também é um importante parâmetro a ser analisado, pois mudanças frequentes de direção 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. [1]

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 de uma região não é suficiente basear-se na análise de dados de vento referentes a apenas um ano. O ideal é dispor de dados de 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 grandes 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, como foi observado na equação (2.2), uma pequena variação na velocidade implica em uma grande variação na potência. Sendo assim, a utilização de médias anuais (em vez 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 irregular 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 às pequenas flutuações e às rajadas de vento. Em um primeiro momento, essas variações não são consideradas na análise do potencial eólico de uma região, desde que não assumam grandes proporções.

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 nos Estados Unidos. Essa máquina de Smith-Putman com lâminas de 50 metros 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. Diferentemente das turbinas convencionais, que são reorientadas de acordo com o vento, esta é unidirecional, o que significa que ela é capaz de aceitar o vento de qualquer direção. Como o seu rotor e suas partes elétricas são na parte inferior da turbina, sua manutenção é muito mais prática, além de que permite uma variabilidade de aplicações elétricas e mecânicas maior do que as demais. A turbina citada pode ser observada na Figura 2.1.

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, das hélices para a sua propulsão. Assim surgiram 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 2.2

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 diâmetro de 30 metros e uma potência nominal de 100 KW e funcionou cerca de 2 anos.

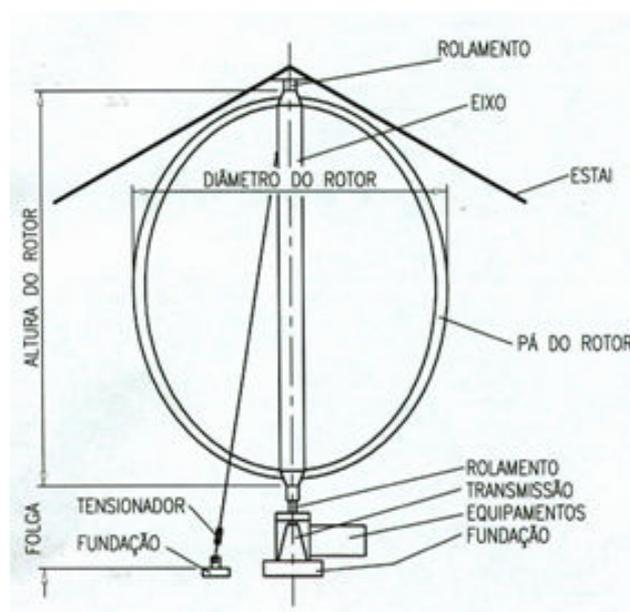


Figura 2.1. Turbina Darrieus de duas lâminas

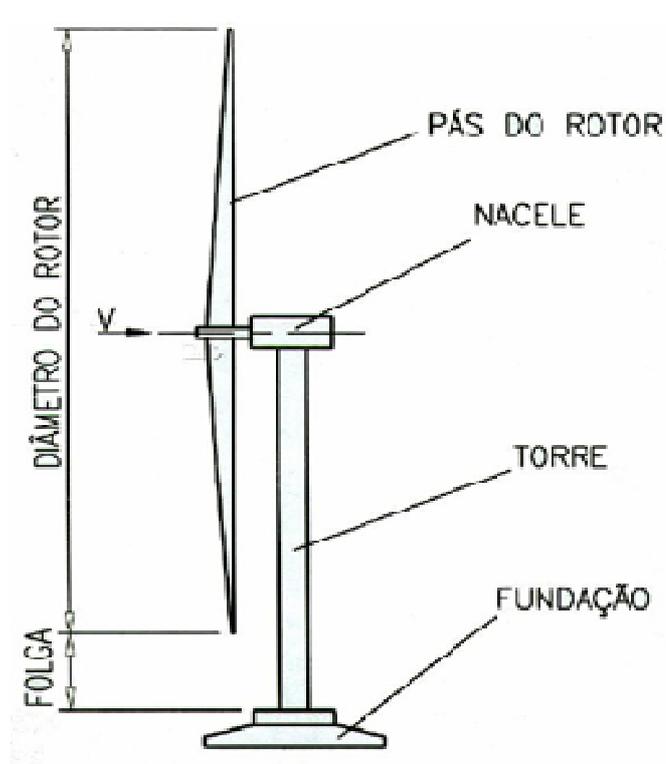


Figura 2.2. Turbina horizontal

Até os dias atuais, a Dinamarca é o país que mais investiu em energia eólica. Ela 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. [2]

2.1.3 No Brasil

Algumas medidas precisas de vento, realizadas recentemente em diversos pontos do território nacional, indicam a existência de um imenso potencial eólico ainda não explorado no Brasil.

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 [6]. Grandes 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) e Rio de Janeiro (2003). [7]

O alto potencial eólico do Brasil impulsionou a criação do Programa de Incentivo às Fontes Alternativas de Energia (PROINFA) através da Lei 10.438 de 2002. Essa lei 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. A intenção é 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. [8][9]

Desde a criação da PROINFA até Junho de 2007, 5 novas usinas somaram 210 MW na potência instalada no Brasil.

2.2 Redes Neurais Artificiais

Redes Neurais Artificiais é uma técnica de CI inspirada no funcionamento do cérebro humano e, como tal, é composta por unidades básicas de processamento (os neurônios artificiais). [10] Entretanto, para entender significativamente a formação e o funcionamento do neurônio artificial, é importante conhecer, de modo geral, os neurônios biológicos.

2.2.1 Neurônio Biológico

Segundo VALENÇA [11], o cérebro humano é composto por cerca de 10 bilhões de neurônios interconectados capazes de processar trilhões de informações simultaneamente. O neurônio biológico (Figura 2.3) é, então, a unidade básica do sistema nervoso humano. Eles recebem sinais de outros neurônios através de seus dendritos utilizando-se de ligações sinápticas (Figura 2.3). Essa informação é processada no corpo celular e, em seguida, propagada até os terminais axônicos (Figura 2.3). No entanto, ela é transmitida para outros neurônios apenas se a intensidade do sinal for maior que o limiar excitatório (Lei do Tudo ou Nada). Dessa forma, os neurônios se conectam e formam um conjunto de grandes e poderosas cadeias de processamento paralelo, entre elas, o cérebro humano. [12]

A simplicidade do funcionamento de um neurônio e o quão poderosos podem se tornar, quando conectados, motivou o desenvolvimento do primeiro modelo matemático que simula o seu comportamento: o neurônio artificial.

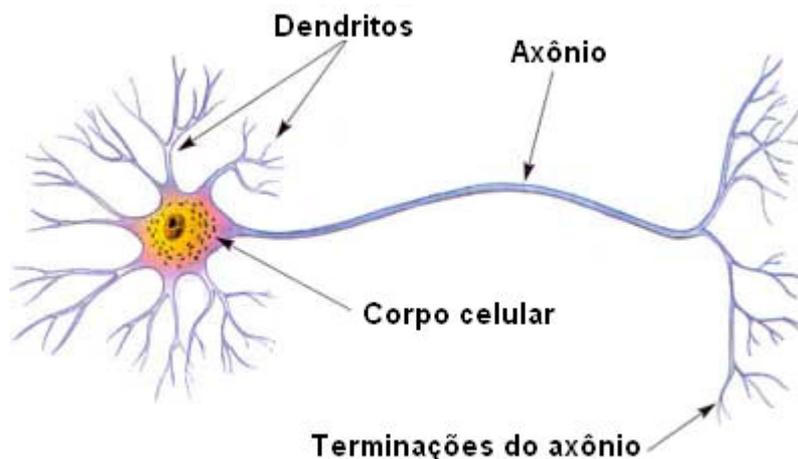


Figura 2.3. Neurônio biológico

2.2.2 Neurônio Artificial

A primeira proposta de modelo matemático do neurônio biológico foi feita por Mc-Culloch Pitts em 1943 (Figura 2.4). [13] O modelo é bastante simples, formado por um conjunto de entradas, uma unidade de processamento e uma ou mais unidades de saídas, que correspondem, respectivamente, aos dendritos, corpo celular e os terminais axônicos do neurônio biológico [10].

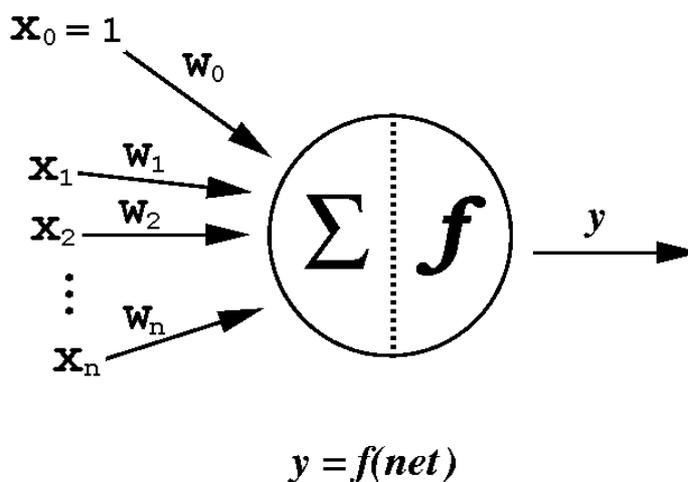


Figura 2.4. Modelo matemático de um neurônio biológico

Como pode ser visto na Figura 2.4, as entradas, nesse tipo de neurônio, são formadas apenas por números. Cada entrada (x_i) é multiplicada por um peso (w_i), o que representa a relevância daquela entrada para o neurônio. A soma do produto acima mencionado, dado pela equação Equação 2.1, é usada como parâmetro para função de ativação $f(\text{net})$, a qual retorna o valor de saída do neurônio (y). Nota-se que o valor de x_0 é predefinido e, quando multiplicado por seu peso, representa o valor do limiar excitatório do neurônio. [11]

Os pesos do neurônio devem ter valores, de forma que, para cada entrada, a saída do neurônio se aproxime ao máximo da saída desejada, ou seja, a inteligência nesse modelo de neurônio artificial está nos pesos que o constitui. [14]

$$\text{net}_i = \sum_{i=0}^n x_i \cdot w_i \quad (2.3)$$

Alguns dos primeiros modelos neurais propostos foram o *Perceptron* e o *Adaline*. A diferença entre eles é que o primeiro lida apenas com saídas discretas, e o segundo permite respostas no universo contínuo. Essa diferença se dá na escolha da função de ativação do neurônio. As Equações 2.4 e 2.5 são exemplos de funções de ativação dos neurônios Perceptron e Adaline, respectivamente. [15]

$$y_i = \begin{cases} 1, & \text{para } \text{net}_i \geq 0 \\ 0, & \text{para } \text{net}_i < 0 \end{cases} \quad (2.4)$$

$$y_i = \frac{1}{1 + e^{-\text{net}_i}} \quad (2.5)$$

Logo, a partir da união de neurônios artificiais, em uma ou mais camadas, constroem-se as chamadas Redes Neurais Artificiais. Existem vários tipos de RNAs, uma das mais famosas e utilizadas é a *Multi-layer Perceptron* (MLP), que quer dizer perceptron com múltiplas camadas. [16]

2.3 Multi-Layer Perceptron

2.3.1 Introdução

Uma rede neural Adaline é constituída de um conjunto de neurônios Adaline conectados, com apenas uma camada de entrada e uma de saída. As redes MLP podem ser consideradas uma extensão desse tipo de rede, pois permitem a existência de múltiplas camadas (Figura 2.5). A existência de múltiplas camadas provoca um fato importante: a rede adquire a capacidade de resolver problemas que não são linearmente separáveis, ou seja, permite a aproximação de qualquer função, operação impossível de ser realizada por redes de apenas uma camada. No entanto, existe uma grande dificuldade dentro do contexto de redes de múltiplas camadas: o aprendizado. [10]

Toda RNA tem a capacidade de aprender, o que acontece em sua fase de treinamento. Nesse momento, os pesos que conectam os neurônios de uma camada com os neurônios da camada subsequente da rede são modificados, de acordo com algum algoritmo de treinamento, de forma a melhor se adequar ao problema. Existem três tipos de aprendizado: supervisionado, não-supervisionado e por reforço. [10] A RNA MLP aprende de forma supervisionada.

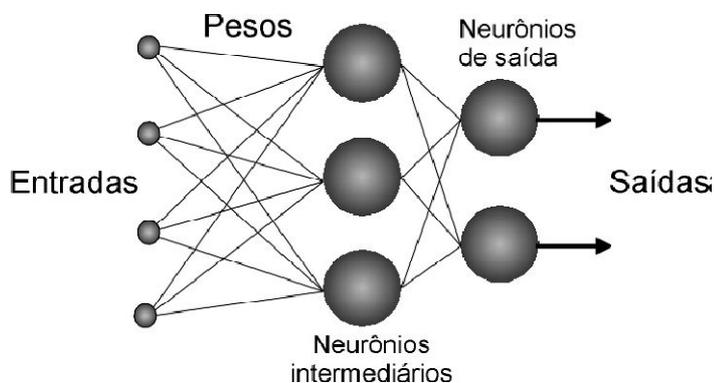


Figura 2.5. Exemplo de uma Rede Neural Artificial de múltiplas camadas.

No aprendizado supervisionado existe o papel do “professor”, que conhece as respostas corretas para cada instância da rede. Dessa maneira, pode-se calcular o erro na saída da rede e, a partir dele, corrigir os pesos de forma que a rede se adeque melhor ao problema proposto. A dificuldade em redes de múltiplas camadas está em corrigir os pesos dos neurônios que não se encontram na camada de saída. [10]

No entanto, já existem algoritmos de aprendizado supervisionado com essa capacidade. Um dos mais bem sucedidos e utilizados em redes MLP é o *Back-Propagation*, que quer dizer propagação recursiva. [16]

2.4 *Back-propagation*

O algoritmo *Back-Propagation* corrige os pesos da rede na ordem inversa da propagação do sinal, ou seja, da camada de saída para camada de entrada. [17] Dois dos mais importantes parâmetros dessa correção são a taxa de aprendizado e o momento.

A taxa de aprendizado revela o quão grande é o tamanho do passo na direção da correção do erro. Já o momento é utilizado para acelerar a convergência da rede e diminuir a incidência de mínimos locais. [14]

A fórmula geral que atribui um novo valor a um determinado peso pode ser vista na equação 2.6, onde $w_{i,j}(t + 1)$ é o novo valor atribuído ao i -ésimo peso do neurônio j , $w_{i,j}(t)$ é o valor corrente do i -ésimo peso do neurônio j (instante t), α é a taxa de aprendizado, δ_j mede a sensibilidade do neurônio ao qual o peso em questão liga o neurônio j , x_i é o sinal de entrada do i -ésimo neurônio, β é a taxa de momento e $w_{i,j}(t - 1)$ é o valor do i -ésimo peso do neurônio j no instante $t - 1$. [10]

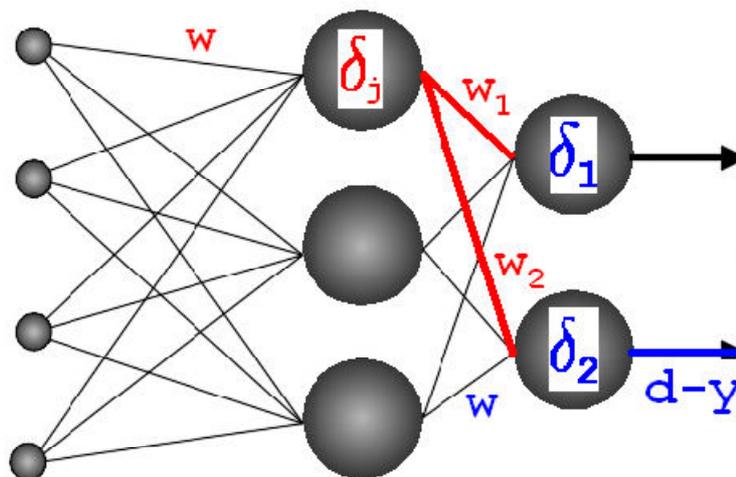
$$w_{j,i}(t + 1) = w_{j,i}(t) + \alpha\delta_jx_i + \beta(w_{j,i}(t) - w_{j,i}(t - 1)) \quad (2.6)$$

Se o neurônio de índice j for de saída, a sensibilidade δ_j é obtida pela Equação 2.7, onde d_j é a saída desejada, y_j é a saída da rede e $f'(net_j)$ é a derivada da função de ativação. Caso contrário, δ_j é dado pela Equação 2.8, onde δ_l é a sensibilidade propagada pelo l -ésimo neurônio da camada imediatamente a frente e $w_{l,j}$, o peso j do neurônio l . [10] A figura 2.6 ilustra o cálculo da sensibilidade δ_j para um neurônio de saída (em azul) e um neurônio escondido (em vermelho), usado na atualização do peso w de cor correspondente.

$$\delta_j = (d_j - y_j)f'(net_j) \quad (2.7)$$

$$\delta_j = f'(net_j) \sum_l \delta_l w_{l,j} \quad (2.8)$$

No processo de aprendizagem supervisionada, o conjunto de padrões é, normalmente, mostrado a RNA várias vezes, determinando o número de épocas do treinamento. Esse número de épocas é bastante variável, dependendo intrinsecamente do problema. Os pesos podem ser modificados a cada amostra, ou a cada época. Encontrar o momento de parada ideal não é uma tarefa tão simples, pois pode causar duas reações indesejadas: se treinada demasiadamente, a RNA decora os padrões, perdendo sua capacidade de generalização. A esse acontecimento dá-se o nome de *overfitting*. Se treinada menos do que o necessário, a rede simplesmente não aprende ou generaliza o suficiente. Um dos mais usados critérios de parada é o de validação cruzada.



$$\delta_j = (w_1 \delta_1 + w_2 \delta_2) f'(\text{net})$$

$$\delta_2 = (d - y) f'(\text{net})$$

Figura 2.6. Exemplo ilustrativo de cálculo do erro σ para um neurônio de saída (em azul) e um escondido (em vermelho)

2.4.1 Critério de Parada

O critério de parada de validação cruzada divide o conjunto de padrões em três partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para correção dos pesos da rede, segundo o algoritmo de treinamento. Depois de cada época, a rede treinada é testada utilizando o conjunto de validação cruzada de forma a verificar a diferença entre a saída calculada e a desejada. Como o conjunto de validação cruzada nunca é utilizado para corrigir os pesos, eles são sempre inéditos para rede. Por isso, enquanto o erro de validação cruzada estiver diminuindo, a rede continua generalizando.

Entretanto, a partir no momento em que o erro de validação cruzada começa a aumentar seguidamente, enquanto, simultaneamente, ainda que o erro de treinamento diminui, é sinalizado que a rede pode estar decorando os padrões de treinamento. Esse é o momento em que o treinamento deve ser parado, como

mostra a figura 2.7. Posteriormente, a rede é submetida ao conjunto de teste, onde se calcula a avaliação final da precisão da rede. Vale observar que o cálculo do erro no conjunto no teste é realizado com as variáveis desnormalizadas. [16]

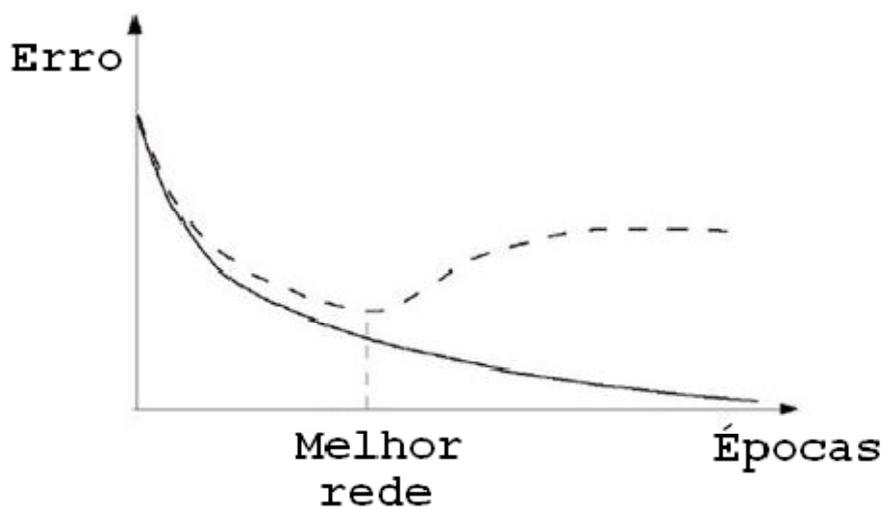


Figura 2.7. Época de parada da validação cruzada

Capítulo 3

Metodologia

Este capítulo descreve como se deu o desenvolvimento do projeto de acordo com a aplicação das teorias apresentadas no capítulo antecedente. A implementação do software foi realizada na linguagem *ActionScript* (AS) 3.0 nos ambientes de desenvolvimento Adobe Flash CS4 Professional e Flash Develop 3.0.0 Beta 7.

Inicialmente, na Seção 3.1, são descritas as características das bases de dados às quais se aplicam as técnicas. Em seguida, a Seção 3.2 discorre o método de seleção de variáveis. A seção 3.3 aborda o pré-processamento dos dados. Já a última seção deste capítulo explica como a RNA foi aplicada ao problema de predição de velocidade do vento.

3.1 Base de Dados

A base de dados utilizada nos experimentos deste projeto é constituída de dados anemométricos da Estação Meteorológica (EM) de São Martinho da Serra e foi contruída a partir de outras de propriedade do Sistema de Organização Nacional de Dados Ambientais (SONDA). A rede SONDA de dados nasceu de um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) para implementação de infraestrutura física e de recursos humanos destinada a levantar e melhorar a base de dados dos recursos de energia solar e eólica no Brasil. [18]

A rede SONDA de dados, antes de disponibilizar os dados de suas estações, submete-os a um processo de qualificação cujo foco é a identificação de dados suspeitos. É válido ressaltar que a rede SONDA não altera sua base de dados original. A execução do processo de controle de qualidade não corrige os dados, apenas sinaliza aqueles suspeitos de estarem incorretos, gerando um código de

qualificação para cada dado coletado. Esses códigos são armazenados em arquivos a parte que podem ser obtidos e consultados pelos usuários, ficando a seu critério a utilização ou não do dado suspeito. Através desse processo é possível permitir que os usuários de tais dados decidam quando garantir a confiabilidade dos dados. Foi notado que a quantidade de dados suspeitos em comparação com a quantidade total de dados é muito pequena, então, para o projeto em questão, todos os dados, incluindo os suspeitos, foram utilizados.

Através do gráfico abaixo é possível ter uma exposição sumária dos valores da velocidade do vento desde o dia 01 de Janeiro de 2007 às 00:00 até o dia 31 do mesmo mês e ano às 23:50 medidos a cada 10 minutos. O eixo vertical representa a velocidade do vento em metros por segundo e o eixo horizontal representa o minuto em que foi medida a velocidade de modo que 1 significa 00:00 do dia 01 de Janeiro de 2007 e 4464 significa 23:50 do dia 31 de Janeiro de 2007.

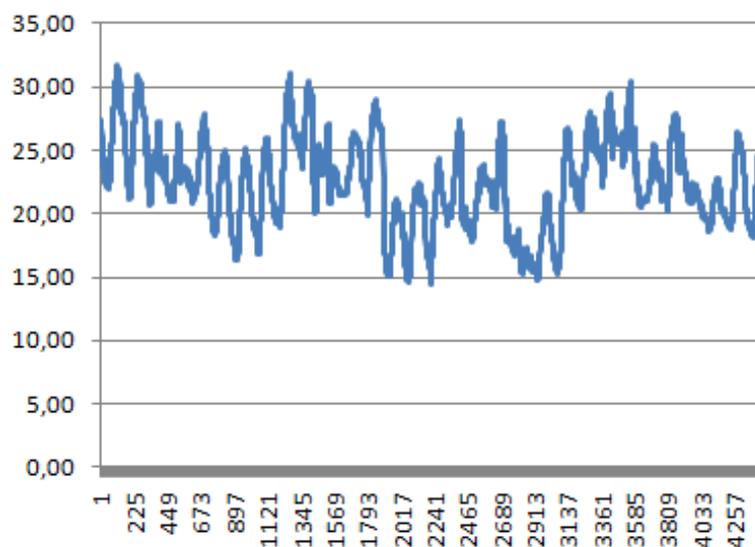


Figura 3.1. Gráfico da Velocidade do vento em função do tempo para a Estação Meteorológica de São Martinho da Serra

A tabela 1 encontrada abaixo apresenta uma amostra da base de dados da Estação Meteorológica de São Martinho da Serra. Tal tabela exhibe os dados da primeira hora do dia 01 de Janeiro de 2007.

Tabela 1. Amostra da base de dados da EM de São Martinho da Serra

Ano	Dia	Data	Minuto	VV a 25 m (m/s)	DV a 25 m (°)	TA a 25 m (°C)	VV a 50 m (m/s)	DV a 50 m (°)	TA a 50 m (°C)
2007	1	01/01/2007	0	5.235	121.80	24.37	7.880	121.70	26.94
2007	1	01/01/2007	10	5.069	123.90	24.10	8.000	121.60	27.04
2007	1	01/01/2007	20	5.368	121.30	23.53	8.330	119.90	26.87
2007	1	01/01/2007	30	6.355	117.80	25.54	8.890	119.50	27.36
2007	1	01/01/2007	40	6.567	115.90	24.87	8.750	116.70	27.33
2007	1	01/01/2007	50	6.517	116.60	25.25	8.790	116.90	27.32

onde,

- VV representa a velocidade do vento;
- DV representa a direção do vento; e
- TA representa a temperatura atmosférica.

3.2 Método de Seleção de Variáveis

Foi notado que, no projeto proposto, era necessário descobrir se existia alguma relação entre a velocidade do vento e qualquer outra variável anemométrica disponível na base da rede SONDA, isto é, saber se as alterações sofridas por alguma(s) variável(eis) da rede SONDA são acompanhadas por alteração na variável de saída.

Com o intuito de solucionar esse problema, fez-se o uso de uma métrica conhecida como correlação linear. O termo correlação significa relação em dois sentidos (co + relação) e é usado em estatística para designar a força que mantém unidos dois conjuntos de valores. A verificação da existência e do grau de relação entre as variáveis é o objeto de estudo da correlação.

A correlação entre duas variáveis x e y pode ser medida de acordo com a seguinte fórmula:

$$r = \left(\frac{\sum \frac{(x-\bar{x})(y-\bar{y})}{S_x S_y}}{n-1} \right) \quad (3.1)$$

onde,

- r = correlação linear;
- x = valor da variável x ;
- y = valor da variável y ;
- \bar{x} = valor médio de x ;
- \bar{y} = valor médio de y ;
- S_x = soma dos valores de x ;
- S_y = soma dos valores de y ;
- n = quantidade de valores.

A correlação linear mínima existente entre duas variáveis é dada pelo valor -1 e a correlação linear máxima é dada pelo valor 1. O quadrado da correlação é conhecido como coeficiente de determinação e tem seu valor entre 0 e 1, sempre positivo.

A tabela 3 abaixo apresenta as correlações lineares existentes entre a velocidade do vento no tempo t e a mesma variável nos tempos: $t - 10$ minutos, $t - 20$ minutos, $t - 30$ minutos, $t - 40$ minutos, $t - 50$ minutos e $t - 60$ minutos para todos os dados recolhidos pelo projeto SONDA para o ano de 2005.

Através da análise da tabela 2, pode-se perceber que existe uma grande dependência linear entre a velocidade do vento para o tempo t e os seus 6 valores anteriores, medidos de 10 em 10 minutos.

A seguir, a tabela 3 mostra as correlações lineares existentes entre a velocidade do vento no tempo t e a temperatura do ar em 6 tempos anteriores para a mesma base de dados e no mesmo período de tempo.

Tabela 2. Correlação linear e coeficiente de determinação entre a velocidade do vento e a mesma variável em tempos anteriores

	<i>t - 60 min</i>	<i>t - 50 min</i>	<i>t - 40 min</i>	<i>t - 30 min</i>	<i>t - 20 min</i>	<i>t - 10 min</i>	<i>t</i>
<i>t - 60 min</i>	1,000						
<i>t - 50 min</i>	0,963	1,000					
<i>t - 40 min</i>	0,930	0,963	1,000				
<i>t - 30 min</i>	0,903	0,930	0,963	1,000			
<i>t - 20 min</i>	0,879	0,903	0,930	0,963	1,000		
<i>t - 10 min</i>	0,856	0,879	0,903	0,930	0,963	1,000	
<i>t</i>	0,835	0,856	0,879	0,903	0,930	0,963	1,000
<i>Coeficiente de determinação</i>	0,696	0,732	0,772	0,816	0,865	0,928	1,000

Tabela 3. Correlação linear e coeficiente de determinação entre a velocidade do vento e a temperatura do ar em tempos anteriores

	<i>t - 60 min</i>	<i>t - 50 min</i>	<i>t - 40 min</i>	<i>t - 30 min</i>	<i>t - 20 min</i>	<i>t - 10 min</i>	<i>t</i>
<i>t - 60 min</i>	1,000						
<i>t - 50 min</i>	0,999	1,000					
<i>t - 40 min</i>	0,997	0,999	1,000				
<i>t - 30 min</i>	0,995	0,997	0,999	1,000			
<i>t - 20 min</i>	0,993	0,995	0,997	0,999	1,000		
<i>t - 10 min</i>	0,990	0,993	0,995	0,997	0,999	1,000	
<i>t</i>	-0,086	-0,090	-0,094	-0,099	-0,103	-0,107	1,000
<i>Coeficiente de determinação</i>	0,007	0,008	0,009	0,010	0,011	0,011	1,000

Nesse caso, nota-se que a dependência linear entre essas variáveis é bastante baixa. É importante ressaltar que entre essas variáveis ainda pode existir uma dependência não linear, pois essa não é mostrada através do cálculo da correlação linear.

Já a tabela 4 apresenta as correlações lineares existentes entre a velocidade do vento no tempo *t* e a direção do vento nos mesmos tempos anteriores, base de dados e período de tempo.

Tabela 4. Correlação linear e coeficiente de determinação entre a velocidade do vento e a direção do vento em tempos anteriores

	<i>t - 60 min</i>	<i>t - 50 min</i>	<i>t - 40 min</i>	<i>t - 30 min</i>	<i>t - 20 min</i>	<i>t - 10 min</i>	<i>t</i>
<i>t - 60 min</i>	1,000						
<i>t - 50 min</i>	0,891	1,000					
<i>t - 40 min</i>	0,850	0,891	1,000				
<i>t - 30 min</i>	0,822	0,850	0,891	1,000			
<i>t - 20 min</i>	0,799	0,822	0,850	0,891	1,000		
<i>t - 10 min</i>	0,775	0,799	0,822	0,850	0,891	1,000	
<i>t</i>	-0,281	-0,285	-0,289	-0,295	-0,300	-0,305	1,000
<i>Coeficiente de determinação</i>	0,079	0,081	0,084	0,087	0,090	0,093	1,000

A tabela 4 mostra que a dependência linear entre a velocidade do vento e valores anteriores da direção do vento é também baixa, mas um pouco maior do que o caso anterior. Nesse caso também pode existir dependência não linear.

De acordo com o que foi concluído através da análise das tabelas 2, 3 e 4, decidiu-se que a base de dados a ser utilizada no projeto conteria as seguintes entradas:

- Velocidade do vento no tempo $t - 50$ minutos;
- Velocidade do vento no tempo $t - 40$ minutos;
- Velocidade do vento no tempo $t - 30$ minutos;
- Velocidade do vento no tempo $t - 20$ minutos;
- Velocidade do vento no tempo $t - 10$ minutos; e
- Velocidade do vento no tempo t .
- Direção do vento no tempo t ;
- Temperatura do ar no tempo t ;

As saídas da base serão 144 valores da velocidade do vento ($t + 10$ minutos até $t + 1440$ minutos).

3.3 Pré-processamento

Dado que t representa uma hora qualquer do dia; x , um dia do ano; VV , a velocidade do vento; DV , a direção do vento; TA , a temperatura do ar, a base de dados utilizada no projeto pode ser descrita através da tabela 5.

A primeira etapa do pré-processamento é transpor os dados do formato original da rede SONDA (Tabela 1) para a forma padrão do problema (Tabela 5). O padrão de entrada é formado por 1 valor atual e 5 valores passados consecutivos da velocidade do vento (nos tempos t , $t - 10$ minutos, $t - 20$ minutos, $t - 30$ minutos, $t - 40$ minutos e $t - 50$ minutos), e pelos valores atuais da direção do vento e da temperatura do ar (no tempo t). O padrão de saída é formado por 144 valores da velocidade do vento nos tempos que variam de $t + 10$ minutos até $t + 1440$ minutos.

A etapa seguinte é a de normalização dos valores. A função dessa etapa é evitar que valores altos influenciem demasiadamente nos cálculos da RNA enquanto que valores baixos passem despercebidos. Além disso, as variáveis devem ter seus valores proporcionais aos limites da função de ativação usada nas camadas de saída da RNA. [11]

A normalização é feita no intervalo $[0,15, 0,85]$. Em alguns casos os valores são normalizados no intervalo $[0; 1]$, no entanto, alguns algoritmos de treinamento, como o *Back-propagation*, não se comportam muito bem com valores muito próximos de zero. Além disso, é também deixada uma margem de tolerância para que valores inéditos e fora do intervalo dos dados presentes na base possam, ainda, ser representados pelo sistema. [11] Dessa forma, a normalização é feita através da fórmula descrita na Equação 3.1.

Após estruturar a base de acordo como é descrito pela tabela 5 e normalizar os dados, a base está pronta para ser usada no MLP.

Tabela 5. Descrição da base de dados utilizada

	Variáveis	Unidade
Entradas	VV no tempo t do dia x	m/s
	VV no tempo t – 10 minutos do dia x	m/s
	VV no tempo t – 20 minutos do dia x	m/s
	VV no tempo t – 30 minutos do dia x	m/s
	VV no tempo t – 40 minutos do dia x	m/s
	VV no tempo t – 50 minutos do dia x	m/s
	TA no tempo t – 10 minutos	°C
	DV no tempo t – 10 minutos	Graus
Saídas	VV no tempo t + 10 minutos do dia x	m/s

	VV no tempo t + 1440 minutos do dia x	m/s

$$y = \left[\frac{0,70(x_i - x_{min})}{x_{max} - x_{min}} \right] + 0,15 \quad (3.1)$$

3.4 Predizendo Velocidade do Vento com a RNA MLP

Embora MLPs já tenham sido usados em diversas pesquisas, sua utilização é bastante dificultada pela quantidade de parâmetros configuráveis que possui. Abaixo, seguem os principais parâmetros do MLP e do *Back-propagation*, conteúdos teóricos vistos nas Seções 2.3 e 2.4, respectivamente:

- Número de neurônios na camada de entrada;
- Número de neurônios na camada escondida (apenas uma camada escondida);
- Número de neurônios na camada de saída;
- Forma de inicialização dos pesos da rede;
- Função de ativação;
- Número máximo de ciclos;
- Critério de parada;
- Taxa de aprendizado; e
- Momento.

Dentre os parâmetros mencionados acima, o único que não variou ao longo da simulação foi a função de ativação.

As previsões para 1 dia a frente são feitas baseando-se na velocidade do vento de 1 hora atrás. Como as medições foram feitas de 10 em 10 minutos, a RNA recebe 6 valores de velocidade do vento passadas, além dos últimos valores da direção do vento e da temperatura do ar. A quantidade de entradas foi escolhida de acordo com os resultados de correlações lineares realizados entre essas variáveis e a velocidade do vento de saída. Os experimentos são feitos para a estação meteorológica de São Martinho da Serra. Serão testadas 3 diferentes arquiteturas de

RNA de forma a se descobrir que arquitetura é capaz de chegar ao resultado mais satisfatório e qual seria esse resultado. As 3 arquiteturas podem ser observadas através das figuras 3.2, 3.3 e 3.4.

Para as 3 arquiteturas apresentadas, as variáveis de entrada não variam, pois são 6 valores de velocidade do vento, 1 de temperatura do ar e um de direção do vento. A figura 3.2 representa a primeira arquitetura de RNA a ser testada. Suas saídas são 144 valores de velocidade do vento, ou seja, a previsão para 24 horas a frente.

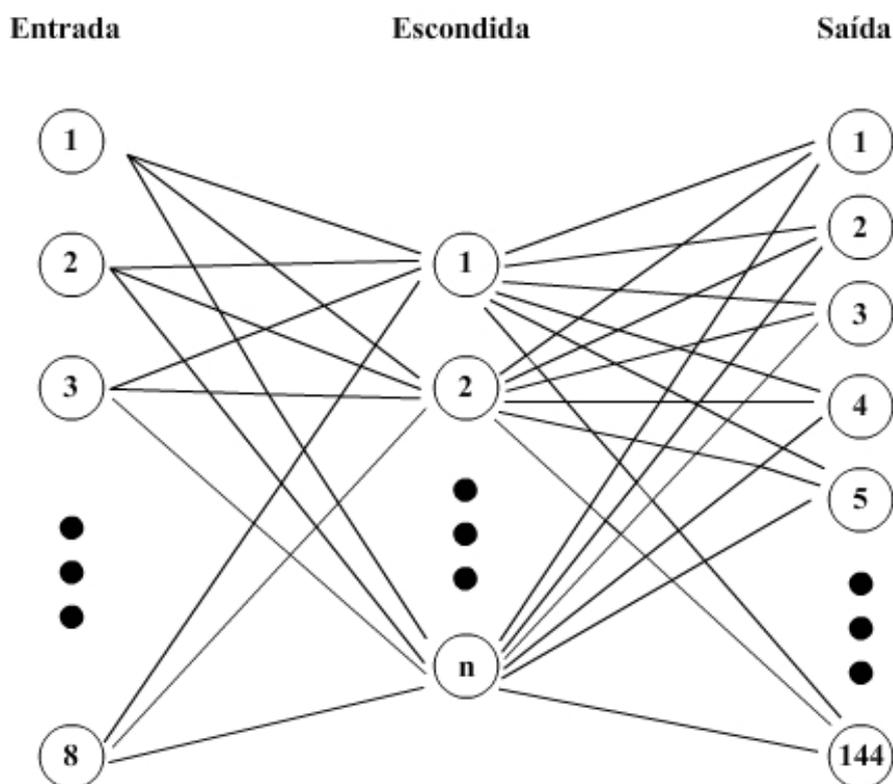


Figura 3.2. Primeira arquitetura da RNA aplicada ao problema de previsão de velocidade do vento

A segunda arquitetura (figura 3.3) possui apenas 48 saídas, ou seja, 8 horas de previsão. Para este caso, serão utilizadas 3 redes com essa arquitetura para que se tenha, na totalidade, 24 horas a frente de previsão. Para essa arquitetura, as entradas das 3 redes são as mesmas, mas as saídas variam. Para a primeira rede,

as 48 saídas correspondem as 8 horas seguintes; para a segunda rede, as saídas correspondem à 9^a até a 16^a hora; e, para a terceira rede, as saídas correspondem a 17^a até a 24^a hora seguinte.

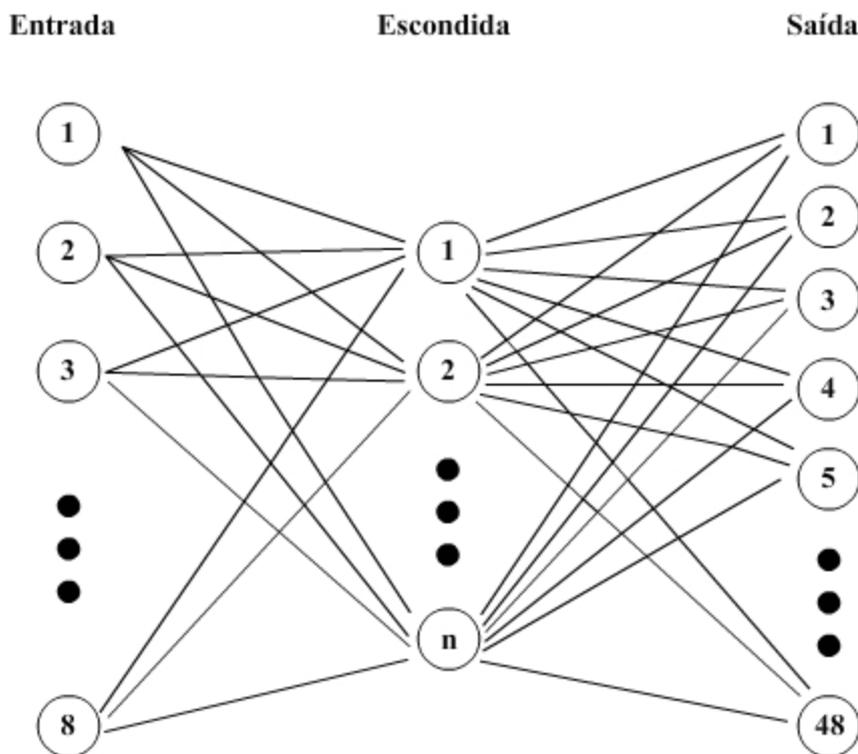


Figura 3.3. Segunda arquitetura da RNA aplicada ao problema de previsão de velocidade do vento.

A terceira arquitetura (figura 3.3) possui apenas 6 saídas, o que representa 1 hora de previsão. Para este caso, serão utilizadas 24 redes com essa arquitetura para que também se tenha, na totalidade, 24 horas a frente de previsão.

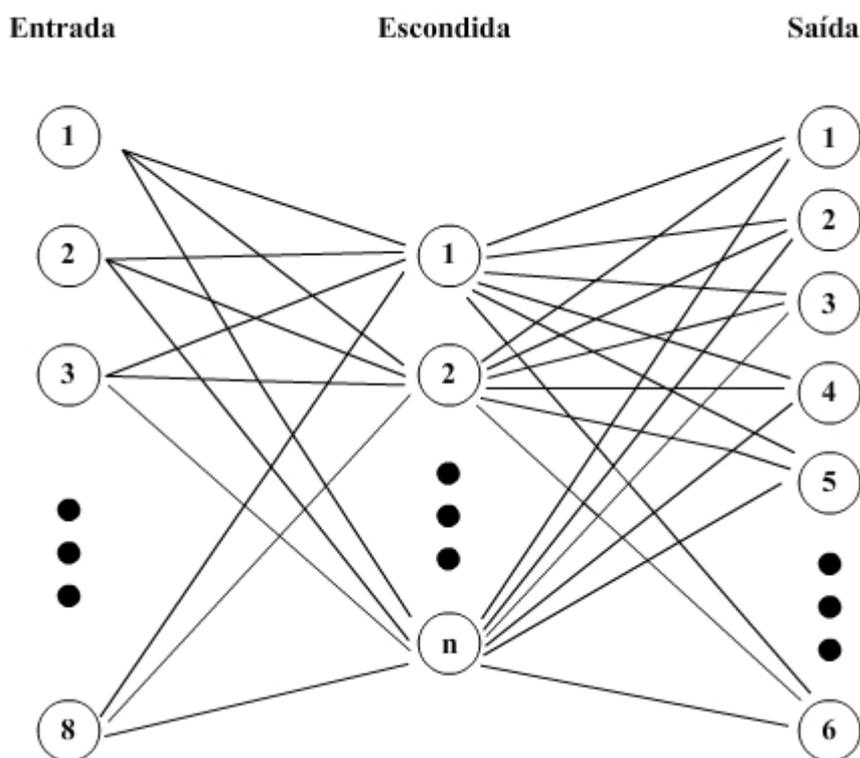


Figura 3.4. Terceira arquitetura da RNA aplicada ao problema de previsão de velocidade do vento.

O algoritmo de treinamento utilizado é o *Backpropagation* (seção 2.4). A função de ativação escolhida é a Sigmoidal Logística, descrita na equação 3.2, onde y e net_i são, respectivamente, a saída e a média ponderada dos pesos com as entradas do i -ésimo neurônio. Tal função retorna valores dentro do intervalo $[0; 1]$.

$$y = \frac{1}{1 + e^{-net_i}} \quad (3.2)$$

Já o critério de parada adotado é o de validação cruzada, com 50% do conjunto de padrões para treinamento, 25% para validação cruzada e os outros 25% para teste. A rede tem seu treinamento interrompido quando o erro da base de validação cruzada permanecer alterando pouco durante 30 vezes seguidas, ou quando atingir o número máximo de ciclos.

Os pesos da rede são inicializados com valores no intervalo $[-0,5; 0,5]$ por um gerador aleatório intrínseco à linguagem AS 3.0.

Capítulo 4

Resultados

Este capítulo mostra os resultados alcançados através da aplicação da metodologia explicada no Capítulo 3. Os valores utilizados nas simulações foram escolhidos baseados em simulações prévias, que determinaram a faixa de valores que permitiram as técnicas convergirem.

Para avaliar as arquiteturas e valores dos parâmetros configurados, foi feito uso do chamado Erro Percentual Médio Absoluto (EPMA), dado pela Equação 4.1 abaixo:

$$EPMA = \frac{\sum_{i=1}^n \left| \frac{d_i - y_i}{d_i} \right| \cdot 100}{n} \%$$

Onde:

- n = número de previsões realizadas;
- d_i = saída desejada para a i -ésima predição; e
- y_i = saída obtida para a i -ésima predição.

A análise dessa fórmula mostra que quando o EPMA for 0 (zero), todas as saídas desejadas são iguais às obtidas. Outros valores do EPMA representam a média do percentual da saída desejada que é a diferença das saídas. Por exemplo, se o EPMA for 50% então, em média, $y_i = (d_i - y_i/2)$ ou $y_i = (d_i + y_i/2)$.

4.1 Variação dos Parâmetros

Redes MLP possuem diversos parâmetros configuráveis que variaram ao longo das simulações para as 3 diferentes arquiteturas de MLP utilizadas.

O número de neurônios na camada de entrada variou de 6 a 8. Os seis primeiros referem-se a valores anteriores e atual da velocidade do vento. Como essas variáveis se mostraram correlacionadas linearmente aos próximos valores da velocidade do vento (tabela 2), foram sempre utilizadas nas simulações. Os dois últimos neurônios referem-se a valores anteriores da direção do vento e temperatura do ar. As tabelas 3 e 4 mostram que a correlação linear entre essas variáveis e a velocidade do vento era muito baixa, então foram realizadas previsões com e sem essas variáveis, pois elas ainda poderiam estar correlacionadas de forma não-linear. Os melhores resultados foram obtidos com a utilização dos 8 neurônios.

O número de neurônios na camada escondida é uma variável bastante difícil de ser definida. Uma fórmula que defina seu valor ótimo para qualquer tipo de problema ainda não é conhecida, então foram feitos testes com valores aleatórios como 4, 9 e 12. Os melhores resultados foram obtidos para 4 e 12 neurônios.

O número de neurônios na camada de saída variou de acordo com a arquitetura da rede. Como já foi explicado, para a primeira arquitetura, a camada de saída possuía 144 neurônios; para a segunda arquitetura, 48 neurônios; e, para a terceira arquitetura, 6 neurônios.

A forma de inicialização dos pesos da rede é aleatória. Eles variam no intervalo de -0,5 e 0,5, então, para cada simulação, os pesos iniciais assumem valores diferentes.

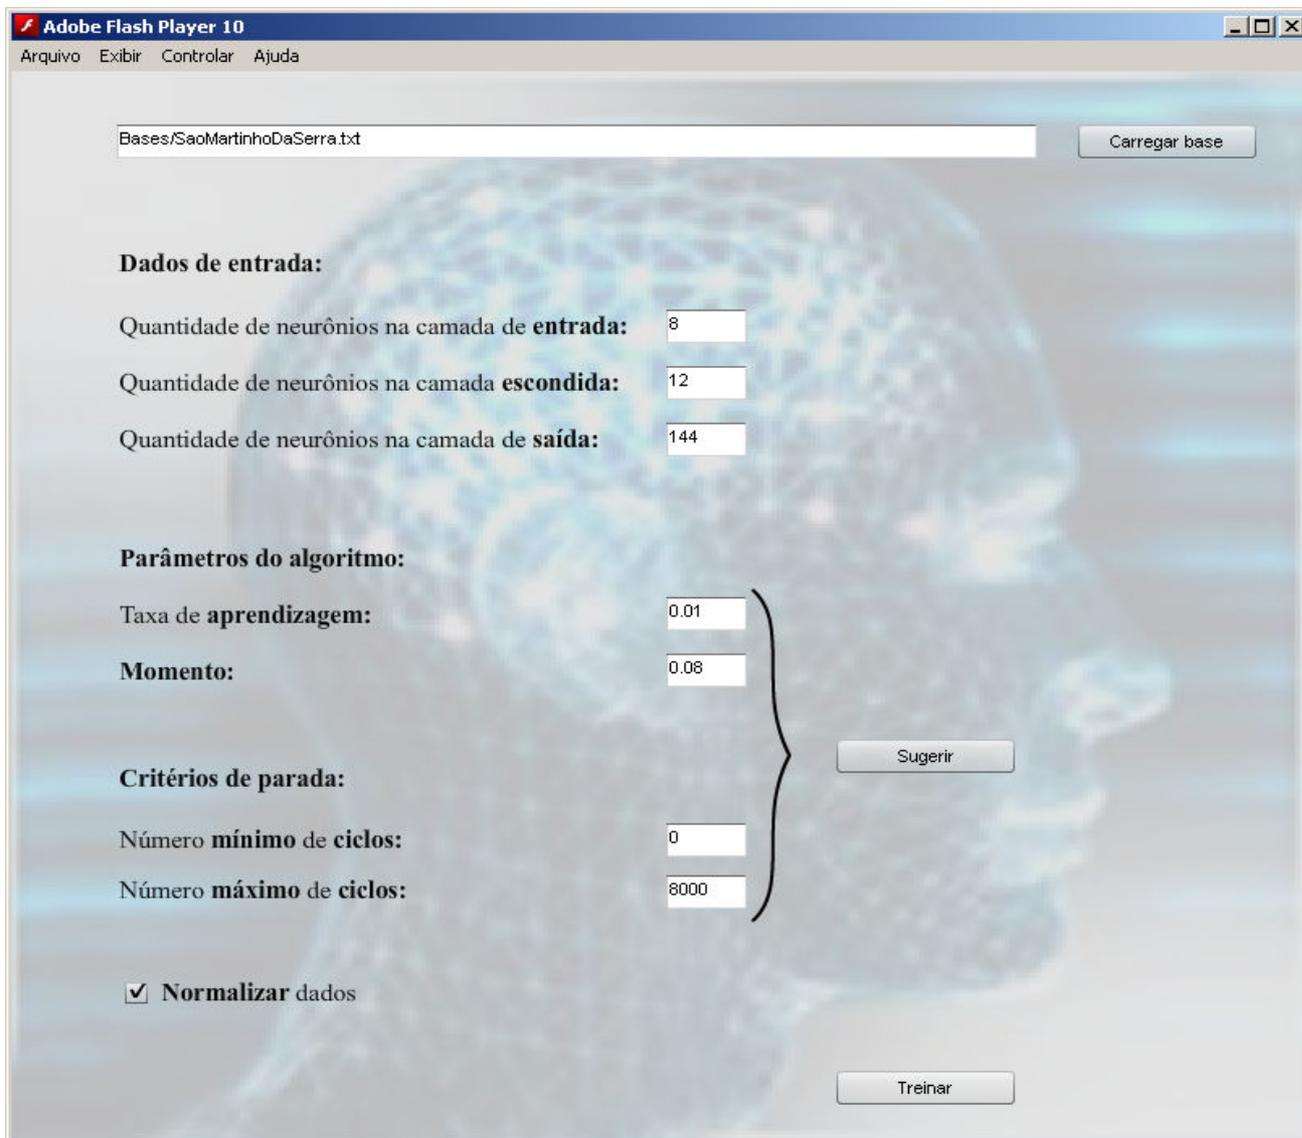
O número máximo de ciclos é, também, uma variável que depende muito do problema onde está inserido. No estudo em questão, seu valor ótimo encontrado após alguns teste foi de 8000 para a primeira arquitetura e 5000 para a segunda e terceira arquiteturas.

O critério de parada utilizado foi a validação cruzada ou quando o número máximo de ciclos fosse atingido. A parada por validação cruzada ocorre quando o erro de validação cruzada permanece crescendo durante 30 ciclos seguidas.

A taxa de aprendizado variou entre os valores 0,1 e 0,01. Seu valor ótimo encontrado, para o problema em questão, foi de 0,01.

O momento variou entre os valores 0,08 e 0,15. Seu valor que mais ajudou na convergência da rede foi 0,08.

A figura 4.1 mostra o sistema desenvolvido para este estudo configurado para setar os parâmetros da rede com os valores ótimos para a primeira arquitetura.



Adobe Flash Player 10

Arquivo Exibir Controlar Ajuda

Bases/SaoMartinhoDaSerra.txt Carregar base

Dados de entrada:

Quantidade de neurônios na camada de **entrada:** 8

Quantidade de neurônios na camada **escondida:** 12

Quantidade de neurônios na camada de **saída:** 144

Parâmetros do algoritmo:

Taxa de **aprendizagem:** 0.01

Momento: 0.08

Critérios de parada:

Número **mínimo** de **ciclos:** 0

Número **máximo** de **ciclos:** 8000

Normalizar dados

Sugerir

Treinar

Figura 4.1. Valores ótimos dos parâmetros configuráveis do MLP para a primeira arquitetura

4.2 Resultados

Nesta seção, serão apresentados os resultados para as diferentes arquiteturas de redes desenvolvidas.

4.2.1 Primeira Arquitetura – 1 Rede com 144 Saídas

As simulações para a primeira arquitetura foram feitas variando-se todos os parâmetros citados na seção 4.1. De modo geral, cada simulação durava cerca de 15 horas, o que tornou bastante árduo o trabalho de encontrar um resultado satisfatório. Após diversas tentativas de se diminuir o EPMA, o melhor resultado obtido foi o de EPMA = 45%, quando seus parâmetros estavam configurados da seguinte maneira:

- Número de neurônios na camada de entrada = 8;
- Número de neurônios na camada escondida = 12;
- Número de neurônios na camada de saída = 144;
- Número máximo de ciclos = 8000;
- Taxa de aprendizado = 0,01;
- Momento = 0,08.

4.2.2 Segunda Arquitetura – 3 Redes com 48 Saídas Cada

Neste caso, o tempo de simulação das 3 redes somados foi de aproximadamente de 14 horas, tornando este trabalho tão árduo quanto o anterior. Apesar de serem feitas diversas simulações, não foi possível encontrar um EPMA satisfatório. Seu menor valor encontrado foi de aproximadamente 65%, quando seus parâmetros estavam configurados da seguinte forma:

- Número de neurônios na camada de entrada = 8;
- Número de neurônios na camada escondida = 4;
- Número de neurônios na camada de saída = 48;
- Número máximo de ciclos = 5000;
- Taxa de aprendizado = 0,01;
- Momento = 0,08.

4.2.3 Terceira Arquitetura – 24 Redes com 6 Saídas Cada

Para a terceira arquitetura, o tempo de simulação das 24 redes somados foi de aproximadamente de 20 horas, portanto, essa foi a arquitetura mais difícil de se trabalhar. Muitas simulações foram feitas, variando-se todos os parâmetros, mas o EPMA insistiu em um valor alto. Seu menor valor encontrado foi de aproximadamente 81%, quando seus parâmetros estavam configurados da seguinte forma:

- Número de neurônios na camada de entrada = 8;
- Número de neurônios na camada escondida = 4;
- Número de neurônios na camada de saída = 6;
- Número máximo de ciclos = 5000;
- Taxa de aprendizado = 0,01;
- Momento = 0,08.

4.3 Comparação dos Resultados

Como foi observado, o melhor resultado encontrado, analisando-se todas as simulações realizadas utilizando as 3 diferentes arquiteturas de rede, foi a que obteve o EPMA = 45%, caso ocorrido com a primeira arquitetura.

O mesmo tipo de estudo pode ser encontrado em [1]. Nesse projeto, o EPMA variou na maioria das vezes, dependendo da arquitetura utilizada, entre 50% e 55%. Em um caso isolado, chegou-se a obter um EPMA de aproximadamente 45%, quando a arquitetura consistia de 144 redes de 1 saída.

Através da comparação dos resultados anteriormente mencionados, pode-se observar que os EPMA mínimos encontrados nos dois estudos foram praticamente iguais.

Capítulo 5

Conclusão e Trabalhos Futuros

O principal objetivo desta monografia foi aplicar algumas arquiteturas de redes neurais para tentar melhorar a precisão das previsões de velocidade do vento para 24 horas a frente. Então, para tanto, foi implementada uma RNA MLP, que se utilizou do algoritmo de treinamento *Back-propagation*. Uma base de dados da rede SONDA foi utilizada, a de São Martinho da Serra.

O melhor resultado obtido no projeto foi o de EPMA de 45% aproximadamente, valor muito próximo de outro obtido para a mesma base e utilizado aqui para fins de comparação.

A maior dificuldade encontrada ao longo de todo o projeto foi o tempo de simulação bastante elevado. Como a base de dados utilizada e o número de ciclos exigidos para convergência dos algoritmos eram muito grandes, uma simulação para previsão de 24 horas a frente nunca durava menos do que 14 horas.

Como trabalhos futuros, uma série de técnicas podem ser testadas com a finalidade de diminuir o EPMA, tais como:

- A utilização de outras funções de ativação;
- A aplicação da Transformada de Wavelet nos dados da base utilizada, o que eliminaria ruídos causados por medições imprecisas;
- Utilização de Redes Neurais Construtivas;
- Utilização de outras técnicas de CI, desenvolvendo-se um sistema híbrido, como por exemplo, um sistema NeuroFuzzy; e
- Migração do sistema para a linguagem C++.

Bibliografia

- [1] RODRIGUES, Guilherme. **Utilização de Redes Neurais para Previsão de Ventos no Horizonte de 24 Horas**. 2007. 119 f. Dissertação de Mestrado do Curso de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- [2] ALDABÓ, Ricardo. **Energia Eólica**. 1. ed. São Paulo: Editora ArtLiber. 2002. 156 p.
- [3] TERCIOTE, Ricardo. **Eficiência Energética de um Sistema Eólico Isolado**. 7 f. Trabalho de Conclusão de Curso de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas.
- [4] **Ambiente Brasil**. Disponível em:
<<http://www.ambientebrasil.com.br/composer.php3?base=./energia/index.html&contedo=./energia/artigos/eolica.html>> Último acesso em: 04 de Maio de 2010.
- [5] **“Energia Eólica – Princípios e Aplicações”**. Disponível em:
<<http://www.cresesb.cepel.br>> Último acesso em 04 de Maio de 2010.
- [6] DO AMARANTE O.A.C., BROWER M., ZACK J., LEITE DE SÁ A. **“Atlas do Potencial Eólico Brasileiro”**, Camargo-Schubert, TrueWind Solutions, CEPEL, 2001.
- [7] 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.
- [8] Programa de Incentivo a Fontes Alternativas – Eletrobrás. Disponível em:
<<http://www.eletobras.com.br/elb/portal/data/Pages/LUMISABB61D26PTBRIE.htm>> Acesso em 05 de Maio de 2010.
- [9] 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.
- [10] BRAGA, A. de P.; CARVALHO, A. P. de Leon Filho de; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.

- [11] VALENÇA, Mêuser. **Fundamentos das redes Neurais**. 2. ed. rev. ampl. Pernambuco: Livro Rápido, 2009. 384 p.
- [12] BERNE; LEVY. **Fisiologia**. Porto Alegre: Artmed, 2003.
- [13] MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin os Mathematical Biophysics, p. 115 133, 1943.
- [14] HAYKIN, S. **Redes Neurais: Princípios e Práticas**. Recife: Bookman, 2007.
- [15] VALENÇA, M. J. S. **Aplicando Redes Neurais: Um Guia Completo**. Recife: Livro Rápido, 2005.
- [16] PONTES, T. **Utilizando Informações de Tendência Fuzzy para Previsão de Vazões com Redes Neurais**. 2009. 64 f. Trabalho de Conclusão de Curso de Engenharia da Computação, Universidade de Pernambuco, Recife.
- [17] WIDROW, B.; HOFF, M. **A logical calculus of the ideas immanent in nervous activity**. Bulletin os Mathematical Biophysics, p. 115 133, 1943.
- [18] SONDA. **Sistema Nacional de Organização de Dados Ambientais**. Disponível em: <<http://sonda.cptec.inpe.br/infos/qualificacao.html>> Acesso em: 27 de Maio de 2010