



UTILIZAÇÃO DE REDES NEURAIS NA PREVISÃO DA VELOCIDADE DO VENTO

Trabalho de Conclusão de Curso

Engenharia da Computação

Marcelo Luiz Pereira Freire
Orientador: Mêuser Jorge Silva Valença



UNIVERSIDADE
DE PERNAMBUCO

**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

MARCELO LUIZ PEREIRA FREIRE

**UTILIZAÇÃO DE REDES NEURAIS NA
PREVISÃO DA VELOCIDADE DO
VENTO**

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

Recife, junho de 2014.

MONOGRAFIA DE FINAL DE CURSO

Avaliação Final (para o presidente da banca)*

No dia 7 de 7 de 2017, às 8:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente MARCELO LUIZ PEREIRA FREIRE, orientado pelo professor Mêuser Jorge Silva Valença, sob título Utilização de Redes Neurais na Previsão da Velocidade do Vento, a banca composta pelos professores:

Sérgio Galdino

Mêuser Jorge Silva Valença

Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada Aprovada com Restrições* Reprovada

e foi-lhe atribuída nota: 9,0 (note)

*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 07 dias para entrega da versão final da monografia a contar da data deste documento.

Sérgio Galdino

SÉRGIO GALDINO

Mêuser Jorge Silva Valença

MÊUSER JORGE SILVA VALENÇA

Dedico este trabalho a todos aqueles que me apoiaram durante toda minha caminhada.

Agradecimentos

Agradeço à minha mãe, Maria Emilia Pereira Freire, por seu apoio incondicional, carinho e educação.

Agradeço aos meus familiares e amigos pela participação em meu processo de graduação.

Finalmente, agradeço ao meu orientador, professor Mêuser Jorge Silva Valença, pelos ensinamentos, orientação e paciência.

Resumo

As energias renováveis estão se tornando cada vez mais essenciais por serem seguras, limpas, abundantes e não impactarem de forma negativa nas questões ambientais. Entre as diversas fontes disponíveis no mundo está o vento e sua escolha é uma das mais promissoras. Isso se explica devido a sua disponibilidade constante em qualquer lugar e por sua produção ser considerada de custo competitivo. Mesmo a energia eólica sendo uma das fontes de energia alternativa mais promissora, é difícil fazer previsões da velocidade do vento e, como consequência, da potência gerada devido às suas características complexas, como a alta variabilidade do vento, de sua direção, características topográficas e climáticas. Essa previsão é importante para determinar o potencial eólico futuro, otimizando o despacho da energia elétrica. Este trabalho tem como objetivo usar diferentes configurações de dois tipos de redes neurais, Multilayer Perceptron e Radial Basis Function Neural Network, para calcular a velocidade do vento. Além disso, realizar estudos comparativos dos resultados de cada uma das redes com modelos de referência, com o intuito de apontar possibilidade de melhorias e diminuição de erros de previsão.

Palavras-chave: Energia Eólica, Previsão da Velocidade do Vento, MLP, RBF.

Abstract

Renewable energies are becoming increasingly essential to be safe, clean, abundant and not impacting negatively on environmental issues. Among the various sources available in the world is the wind and its choice is one of the most promising. This is explained due to its competitive cost production and constant availability anywhere. Even wind power being one of the most promising sources of alternative energy, it is difficult to forecast wind speed and as a consequence, the power generated due to their complex characteristics, such as high variability of the wind, its direction, topographical and climate features. This prediction is important in determining the future wind potential, optimizing the dispatch of electricity. This paper proposes to use different configurations of two types of neural networks, Multilayer Perceptron and Radial Basis Function Neural Network to calculate the wind speed. Moreover, to compare the results of each network with reference models, in order to point out the possibility of improvement and reduction in forecast error.

Sumário

Capítulo 1 - Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.2.1 Objetivo Geral.....	2
1.2.2 Objetivos Específicos	2
1.3 Estrutura da Monografia	2
Capítulo 2 – Fundamentos Teóricos	3
2.1 Energia Eólica.....	3
2.1.1 Introdução.....	3
2.1.2 Recurso Eólico.....	4
2.1.3 Turbinas Eólicas	5
2.1.4 Potencial Eólico Brasileiro	11
2.1.5 Modelos de Previsão	11
2.2 Redes Neurais Artificiais.....	13
2.2.1 Neurônio Biológico.....	13
2.2.2 Neurônio Artificial.....	14
2.3 Multi-Layer Perceptron.....	16
2.3.1 Algoritmo <i>Backpropagation</i>	17
2.3.2 Critério de Parada.....	19
2.4 Radial Basis Function Networks	20
2.4.2 Treinamento da Rede RBF	21

Capítulo 3 - Metodologia	23
3.1 Base de Dados	23
3.2 Pré-processamento dos Dados	24
3.3 Determinação das Variáveis de Entrada.....	24
3.4 Arquiteturas de Rede Utilizadas – Predizendo a Velocidade do Vento .	27
3.5 Teste Estatístico	29
4. Resultados	30
4.1 Simulações e Comparações Estatísticas.....	31
5. Conclusão e Trabalhos Futuros	34
Bibliografia	35

Índice de Figuras

Figura 1.	Aerogeradores de Eixo Horizontal.....	6
Figura 2.	Aerogerador de Eixo Vertical.....	6
Figura 3.	Componentes de um aerogerador de eixo horizontal.....	8
Figura 4.	Neurônio Biológico.	13
Figura 5.	Modelo matemático de um neurônio biológico.	14
Figura 6.	Arquitetura MLP com quatro camadas.	16
Figura 7.	Melhor ponto de parada do treinamento.....	19
Figura 8.	Rede RBF.....	20
Figura 9.	Arquitetura da rede MLP.	30

Índice de Tabelas

Tabela 1. Amostra da base de dados utilizada.....	23
Tabela 2. Correlação linear entre a velocidade do vento e a mesma variável em tempos anteriores.....	26
Tabela 3. Neurônios na Camada Escondida x Erro Médio Quadrático	30
Tabela 4. Valores de Dispersão x Erro Médio Quadrático	31
Tabela 5. Erro Percentual Médio Absoluto das Redes.....	32
Tabela 6. Resultados do Teste de Wilcoxon.	33

Tabela de Símbolos e Siglas

ANEEL – Agência Nacional de Energia Elétrica

CBEE – Centro Brasileiro de Energia Eólica

EMQ – Erro Médio Quadrático

EPMA – Erro Percentual Médio Absoluto

MCT – Ministério de Ciência e Tecnologia

MLP – Multi-Layer Perceptron

ONS – Operador Nacional de Sistema Elétrico

PROINFA – Programa de Incentivo às Fontes Alternativas de Energia Elétrica

RBF – Radial Basis Function

RNA – Redes Neurais Artificiais

SIN – Sistema Interligado Nacional

Capítulo 1 - Introdução

1.1 Motivação

Um dos maiores desafios globais nos últimos anos tem sido o incentivo em tecnologias de geração de energias menos agressivas ao meio ambiente e, conseqüentemente, a redução das taxas de emissão de CO₂ ou outros gases do efeito estufa. Essa tentativa deve-se ao fato de que as energias mais utilizadas – petróleo, gás natural e carvão mineral – são extremamente poluentes e não renováveis.

As energias renováveis estão se tornando cada vez mais essenciais por serem seguras, limpas, abundantes e por causarem um menor impacto ambiental. Entre as diversas fontes disponíveis no mundo está o vento e sua escolha é uma das mais promissoras. Isso se explica devido a sua disponibilidade constante em qualquer lugar e por sua produção ser considerada de custo competitivo [1].

Assim, com a crescente preocupação em torno das questões ambientais, vários países têm investido na complementação de suas gerações energéticas. No Brasil, o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA), instituído pela Lei nº 10.438/2002, implantou, até 31 de dezembro de 2011, um total de 119 empreendimentos, constituído por 41 eólicas, 59 pequenas centrais hidrelétricas (PCHs) e 19 térmicas a biomassa. Principalmente na região Nordeste, a energia eólica vem recebendo maior atenção visto que há espaço para o aumento da geração de energia, já que a região ainda não atingiu seu potencial eólico, um dos maiores do país [3].

A geração de energia eólica é dada por meio de aerogeradores e a quantidade de energia transferida é função da densidade do ar, da área coberta pela rotação das pás (hélices) e da velocidade do vento [4]. Mesmo sendo uma das fontes de energia alternativa mais promissora, um dos seus principais problemas é a alta variabilidade, devido a características topográficas, climáticas, de altura e solo, o que dificulta a sua previsão.

A previsão da velocidade do vento é importante no planejamento e na melhor utilização dos recursos disponíveis, além de diminuir a incerteza e inconstância na geração da energia. Portanto, o maior desafio nessa previsão é encontrar um modelo que melhor consiga prever a velocidade de vento.

Essa previsão precisa é essencial para manter o sucesso que a energia eólica vem atingindo. Com uma diminuição cada vez maior no seu custo de instalação e operação, essa alternativa energética vem crescendo em desenvolvimento e demanda.

1.2 Objetivos

1.2.1 Objetivo Geral

De maneira geral, o objetivo do trabalho proposto é testar diferentes configurações com diferentes arquiteturas de Redes Neurais Artificiais (RNAs) com o intuito de prever a velocidade do vento.

1.2.2 Objetivos Específicos

Especificamente, o trabalho pretende definir quais variáveis exercem maior influência na previsão da velocidade do vento e realizar comparações entre os resultados obtidos.

1.3 Estrutura da Monografia

No capítulo 2 são apresentados os fundamentos teóricos essenciais para o entendimento do trabalho proposto, a saber: a energia eólica, a importância das técnicas de previsão na geração dessa forma de energia e as RNAs utilizadas no trabalho. O capítulo 3 demonstra como os experimentos serão conduzidos para atingir o objetivo geral do projeto, tais como a seleção de variáveis de entrada para a rede neural, o pré-processamento da base de dados, o tratamento das diferentes arquiteturas de Redes Neurais e as análises estatísticas utilizadas. Em seguida, no capítulo 4, todos os resultados obtidos são mostrados, assim como as comparações realizadas. Por fim, o capítulo 5 reúne as dificuldades encontradas, as discussões geradas, as conclusões obtidas e os trabalhos futuros.

Capítulo 2 – Fundamentos Teóricos

Este capítulo tem o objetivo de mostrar o conteúdo teórico utilizado como base no trabalho.

2.1 Energia Eólica

2.1.1 Introdução

Energia eólica é a conversão da energia cinética contida nos ventos, que são massas de ar em movimento, em energia mecânica. Seu aproveitamento ocorre por meio da conversão da energia cinética de translação em energia cinética de rotação, com o emprego de turbinas eólicas, também denominadas aerogeradores, para a geração de eletricidade [5].

A energia eólica é utilizada há milhares de anos com as mesmas finalidades: bombeamento de água, moagem de grãos e outras aplicações que envolvem energia mecânica. Para a geração de eletricidade, as primeiras tentativas surgiram no final do século XIX, mas somente um século depois, com a crise internacional do petróleo na década de 1970, é que houve interesse e investimentos suficientes para viabilizar o desenvolvimento e aplicação de equipamentos em escala comercial [5].

A primeira turbina eólica comercial ligada à rede elétrica pública foi instalada em 1976, na Dinamarca. Nos Estados Unidos, o potencial eólico instalado é da ordem de 4.600 MW e com um crescimento anual em torno de 10%. A previsão é que em 2020 o mundo terá 12% da energia gerada pelo vento, com uma capacidade instalada de mais de 1.200GW [3].

No Brasil, os primeiros estudos de viabilidade da energia eólica foram realizados no Ceará e em Fernando de Noronha (PE), no início dos anos 1990. Os resultados dessas medições possibilitaram a determinação do potencial eólico local e a instalação das primeiras turbinas eólicas do Brasil [5].

2.1.2 Recurso Eólico

A energia eólica pode ser considerada como uma das formas em que se manifesta a energia proveniente do Sol, isto porque os ventos são causados pelo aquecimento diferenciado da atmosfera. Essa não uniformidade no aquecimento da atmosfera deve ser creditada, entre outros fatores, à orientação dos raios solares e ao movimento da Terra.

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 [6].

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 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. Na prática, as aplicações levam em consideração apenas a velocidade média do vento.

A velocidade do vento decresce à medida que se aproxima da superfície da Terra devido à fricção entre o ar e o solo. Logo, quanto maior a aspereza do solo, maior o decréscimo da velocidade. Por isso, as medições em estações meteorológicas são tomadas em duas alturas padrão: 2 metros para propósitos agrícolas e 10 metros, o padrão internacional para medições meteorológicas. No Brasil, realizam-se também medições em alturas de 25 e 50 metros [7].

2.1.3 Turbinas Eólicas

As turbinas eólicas, também conhecidas como aerogeradores, são máquinas que conseguem transformar a energia cinética dos ventos em energia elétrica. Essa transformação ocorre quando o vento move-se entre as pás do aerogerador, transferindo parte de sua energia e rotacionando-as.

Essas turbinas podem ser classificadas de acordo com a posição do eixo do rotor:

- Rotores de Eixo Horizontal

São os mais comuns, e grande parte da experiência mundial está voltada para a sua utilização. As pás giram em um plano perpendicular à direção do vento. As principais vantagens no uso desse tipo de turbina são a eficiência e o acesso a maiores velocidades do vento, já que tais aerogeradores são instalados em ambientes altos. A principal desvantagem é a necessidade de um mecanismo que faça as turbinas girarem para se ajustar de acordo com a direção do vento.

- Rotores de Eixo Vertical

Nesse tipo de turbina as pás giram em um plano paralelo à direção do vento. As principais vantagens são o baixo custo de manutenção, já que, geralmente, essas turbinas são instaladas no solo, e a multidirecionalidade de suas pás, evitando que elas precisem ser posicionadas na direção do vento. A principal desvantagem encontra-se na eficiência. Por estarem instaladas no solo, essas turbinas não possuem acesso às altas velocidades do vento.

As Figuras 1 e 2 representam exemplos de aerogeradores de eixo horizontal e aerogeradores de eixo vertical, respectivamente.



Figura 1. Aerogeradores de Eixo Horizontal



Figura 2. Aerogerador de Eixo Vertical

Os aerogeradores de eixo horizontal, os mais utilizados e foco deste trabalho, são compostos das seguintes partes:

- Torre – Coluna que sustenta todos os componentes da turbina e posiciona o rotor a uma altura conveniente para o seu funcionamento.
- Rotor – É o componente que efetua a transformação da energia cinética dos ventos em energia mecânica de rotação. Todo o conjunto é conectado a um eixo que transmite a rotação das pás para o gerador.
- Pás – Dispositivos responsáveis pela interação com o vento, convertendo parte de sua energia cinética em trabalho mecânico.
- Nacele – Está ligada à torre e às pás do rotor. É o compartimento que abriga todo o mecanismo do gerador: multiplicador de velocidade, gerador, sistema de freio a disco, freios, embreagem, mancais, controle eletrônico, sistema hidráulico.
- Multiplicador de Velocidade – Transmite a energia mecânica do eixo do rotor ao eixo do gerador.
- Gerador Elétrico – Converte a energia mecânica do eixo em energia elétrica.
- Controle de Giro – Componentes que se ajustam à turbina de modo que ela fique perpendicular à direção do vento.
- Sistema de Freio a Disco – Controla a velocidade da hélice.
- Sensores de Vento – Calculam a velocidade e a direção do vento.
- Sistema de Controle – Monitora continuamente as condições do aerogerador.

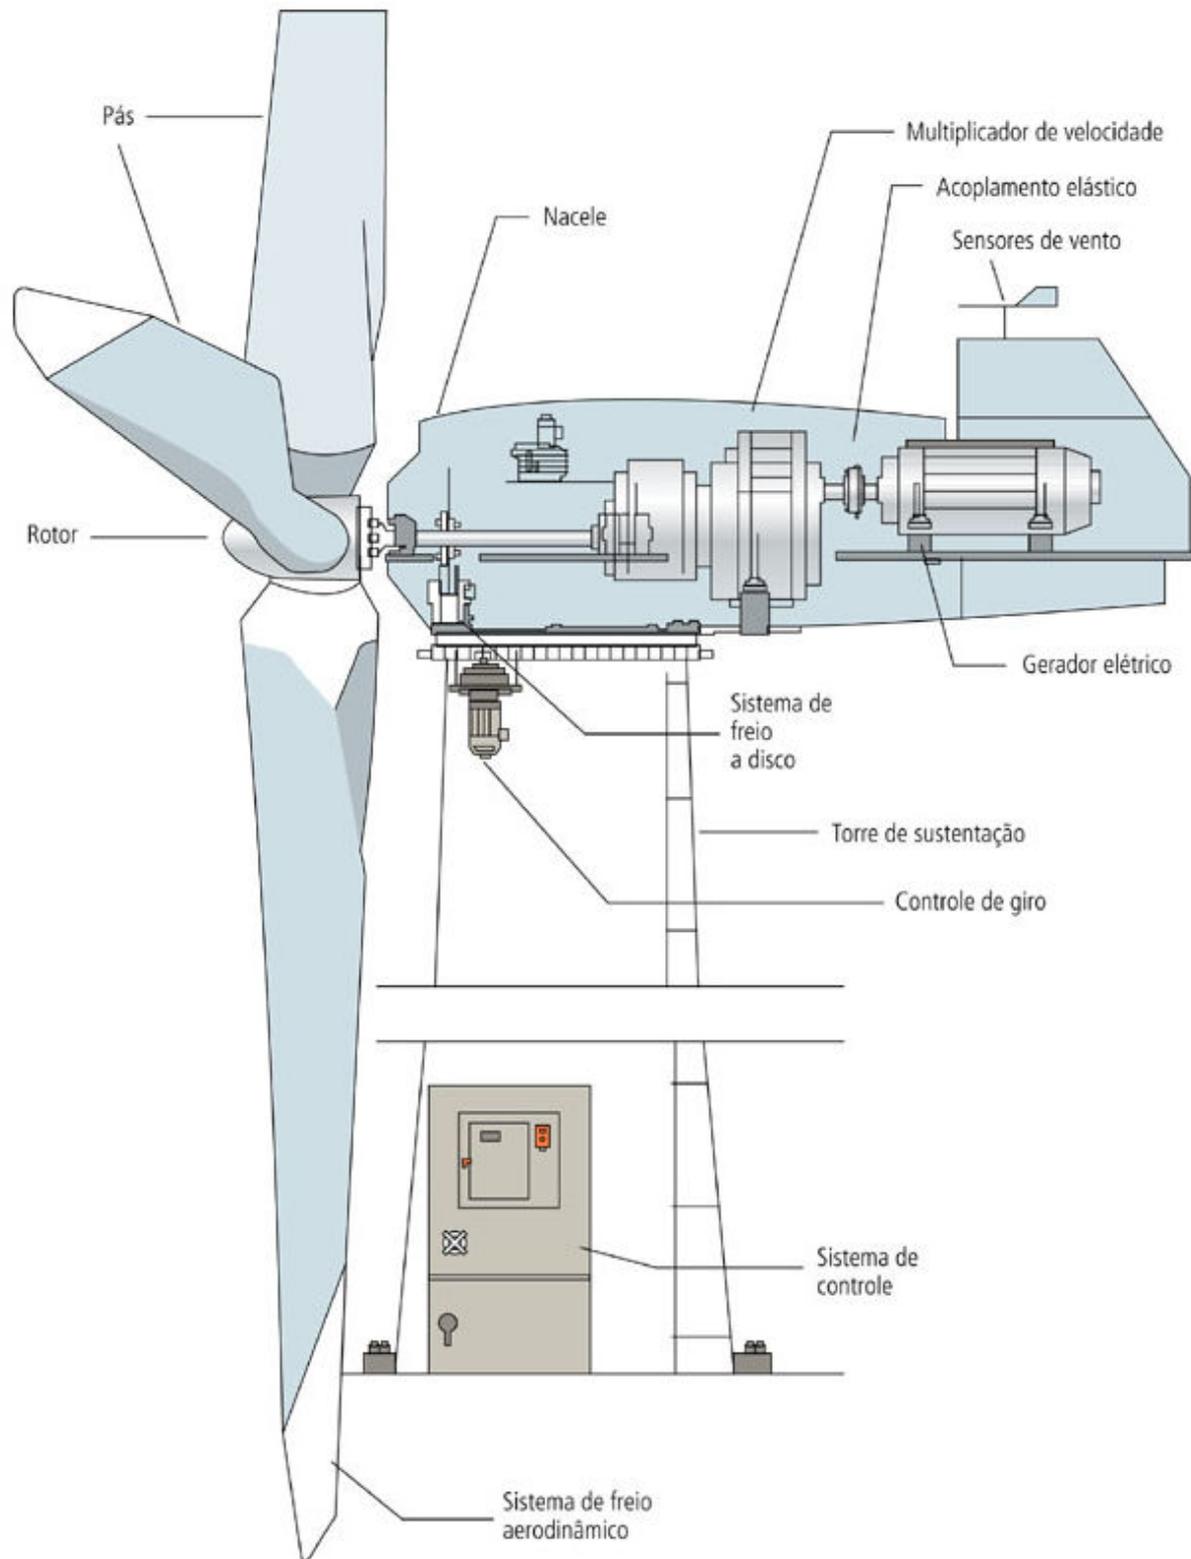


Figura 3. Componentes de um aerogerador de eixo horizontal.

A energia cinética do ar é extraída quando o ar 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:

C_p – é o coeficiente da potência. É a potência extraída pelo rotor dividida pela potência do vento;

ρ – densidade do ar em Kg/m^3 ;

A – área do rotor em m^2 ;

V – velocidade do vento em m/s .

Como pode ser observado na equação 2.2, a energia potencial da turbina eólica depende do cubo da velocidade do vento. Isso significa que se a velocidade do vento em um local dobrar, por exemplo, a energia potencial de saída de uma turbina eólica é multiplicada por 8. Isso mostra a importância da velocidade do vento para a estimativa da energia disponível.

Com relação ao aproveitamento da energia eólica é de fundamental importância diferenciar os tipos de variações temporais da velocidade dos ventos: variações anuais, sazonais, diárias e de curta duração [7].

- **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, 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) 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 uma significativa variação. 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.

2.1.4 Potencial Eólico Brasileiro

Embora haja divergências entre especialistas e instituições na estimativa do potencial eólico brasileiro, os diversos levantamentos e estudos realizados e em andamento têm dado suporte e motivado a exploração comercial da energia eólica no país.

Os primeiros estudos foram realizados na região Nordeste, principalmente no Ceará e em Pernambuco. Com o apoio da Agência Nacional de Energia Elétrica (ANEEL) e do Ministério de Ciência e Tecnologia (MCT), o Centro Brasileiro de Energia Eólica (CBEE) publicou em 1998 a primeira versão do Atlas Eólico da Região Nordeste, um importante passo no estudo da energia eólica no Brasil [5].

Atualmente, o potencial eólico do Brasil soma 300 GW e está concentrado principalmente no Nordeste e no Sul, com destaque para os estados da Bahia, do Rio Grande do Norte, Ceará e Rio Grande do Sul. Até o fim de 2016, a meta é inserir no sistema elétrico nacional 8,4 GW de potência eólica e isso significará 5,4% de participação na matriz energética brasileira contra os atuais 1,5%. E até 2020, estima-se um investimento de R\$40 bilhões no setor eólico brasileiro [5].

2.1.5 Modelos de Previsão

O aumento da participação da energia eólica na matriz energética mundial cria demandas para o planejamento, operação e mercado de energia. Por conta disso a previsão da geração da energia eólica precisa ser confiável e segura. Como a geração é inconstante é necessário realizar a previsão para garantir ao operador ferramentas para manter a capacidade de reserva na programação da distribuição de energia de forma a garantir o equilíbrio entre a carga e a geração da mesma, criando reserva de energia para compensar eventuais períodos de geração reduzida.

As previsões podem ser classificadas de acordo com a escala de tempo [7]:

- Curtíssimo prazo: São as previsões de poucos minutos à frente utilizadas principalmente para controlar a potência ativa do gerador.
- Curto prazo: De 1 a 72 horas. Utilizadas para planejar a operação e a distribuição da energia.
- Médio prazo: De 5 a 7 dias. Utilizadas na manutenção das plantas eólicas.
- Longo prazo: Acima de 7 dias. Utilizadas em planejamento de recursos energéticos e em leilões de energia.

Os modelos de previsão mais usados são os modelos físicos e os modelos estatísticos/inteligência artificial. Os modelos físicos realizam as previsões com base nos dados meteorológicos e utilizam métodos numéricos para previsão. Demandam grande esforço computacional e requerem um número elevado de dados, sendo recomendados para previsões de médio e longo prazo. Os modelos estatísticos e de inteligência artificial são mais simples e mais rápidos na realização das previsões, contudo possuem tendência à diminuição na precisão da previsão conforme o aumento da escala de tempo, por essa razão são mais recomendados para previsões de curtíssimo e curto prazo [1]. Uma das técnicas mais comumente usadas na construção dos modelos de inteligência artificial são as Redes Neurais Artificiais [8][9].

Outro modelo que apresenta bons resultados em previsões de velocidade do vento de curto prazo é o chamado modelo de persistência [10]. Esse modelo consiste em assumir que as condições que influenciam previsão não mudarão em um instante futuro t , fazendo com que a velocidade nesse instante t seja igual à velocidade atual. A razão pela qual o modelo de persistência apresenta bons resultados é que as condições climáticas geralmente não mudam abruptamente em poucas horas, fazendo com que esse modelo seja considerado de referência para previsões de curto prazo [11].

2.2 Redes Neurais Artificiais

Redes Neurais Artificiais é uma técnica de Computação Inteligente (CI) inspirada no funcionamento do cérebro humano e, como tal, é composta por unidades básicas de processamento (os neurônios artificiais) [12]. Uma RNA é um sistema adaptativo composto por unidades de processamento interconectadas, chamadas de neurônios, distribuídas em diferentes camadas trabalhando em união para a resolução de um problema.

2.2.1 Neurônio Biológico

O cérebro humano é composto por cerca de 10 bilhões de neurônios que se interconectam formando uma rede capaz de processar milhões de informações simultaneamente [13].

De forma simplificada, pode-se dizer que o neurônio biológico (Figura 4) é composto pelo corpo celular, de onde saem ramificações que são os dendritos. Desse corpo celular, sai um prolongamento chamado axônio. A passagem do impulso nervoso entre dois neurônios se dá na região de sinapse, formada pela união dos axônios de um neurônio e os dendritos do outro. Essa transmissão ocorre do axônio de um neurônio para os dendritos do neurônio seguinte, e não no sentido contrário [13].

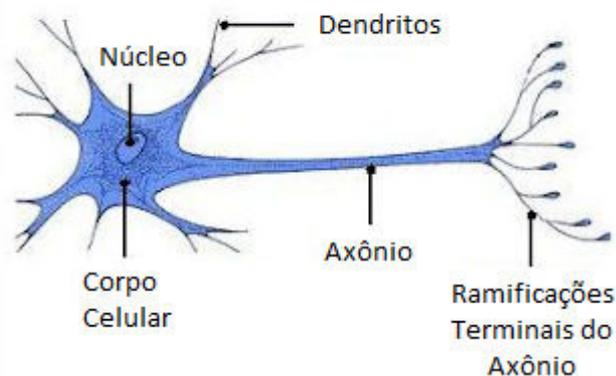


Figura 4. Neurônio Biológico.

Um aspecto importante para o entendimento do funcionamento do neurônio biológico é que a informação só é transmitida para outros neurônios se a intensidade do estímulo ultrapassar o limiar excitatório (Lei do Tudo ou Nada). Portanto, se o estímulo for muito pequeno, isto é, se sua intensidade for inferior ao limiar excitatório, não ocorrerá impulso nervoso. Caso passado esse limiar, o potencial de ação do neurônio continuará o mesmo, não importando a intensidade do estímulo.

2.2.2 Neurônio Artificial

A primeira proposta de modelo matemático do neurônio biológico foi feita por Mc-Culloch e Pitts em 1943 [14]. O modelo é bastante simples (Figura 5), 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 [12].

O modelo proposto representa o neurônio biológico utilizando uma regra de propagação e uma função de ativação $f(net)$. A emissão de sinal por esse neurônio está baseada em um limiar em analogia com a Lei do Tudo ou Nada [13].

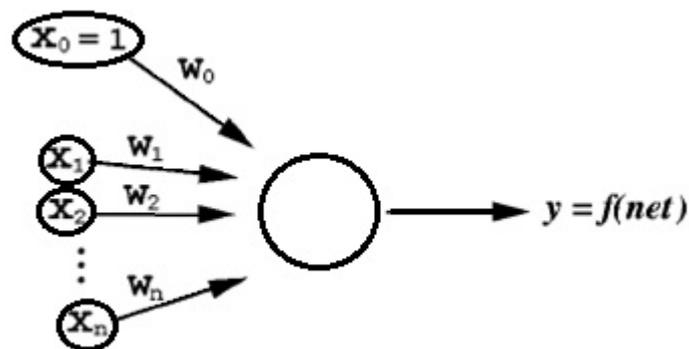


Figura 5. Modelo matemático de um neurônio biológico Mc-Culloch e Pitts.

Cada entrada (X_i) é multiplicada por um peso (W_i) que representa a relevância daquela entrada para o neurônio. Ou seja, quanto mais importante aquela

entrada, maior será seu peso. A soma do produto $X_i \cdot W_i$, dada pela equação 2.3, é usada como parâmetro para a função de ativação $f(net)$. Esta função, por sua vez, retorna o valor de saída do neurônio.

$$net_i = \sum_{i=0}^n X_i \cdot W_i \quad (2.3)$$

Os pesos do neurônio devem possuir valores que, ao multiplicá-los pela entrada, o valor de saída obtido se aproxime ao máximo da saída desejada. Logo, a inteligência do modelo de um neurônio artificial está nos pesos que o constitui [15].

A grande vantagem no uso de redes neurais artificiais para solução de problemas complexos provém, principalmente, de sua capacidade de aprendizagem através de exemplos e generalização da resposta adquirida durante o treinamento da rede. O treinamento, por sua vez, é um conjunto de regras adicionadas às RNAs de modo a aumentar a sua capacidade de generalização. Ao ajustar os pesos das conexões entre os neurônios é possível atingir a generalização.

Os primeiros modelos de RNAs propostos foram o Perceptron e o Adaline. O Perceptron lidava apenas com saídas discretas enquanto o Adaline permitia respostas no universo contínuo. Essa diferença ocorre na escolha das funções de ativação do neurônio.

Assim, a partir da união de neurônios artificiais, em uma ou mais camadas, é possível a construção das Redes Neurais Artificiais. Existem vários tipos de RNAs e uma das mais usadas é a Multi-Layer Perceptron.

2.3 Multi-Layer Perceptron

As redes *Multi-Layer Perceptron* (MLP) são uma generalização da rede Perceptron simples que apresentam, além das camadas de entrada e saída, a adição de pelo menos uma camada intermediária ou camada escondida.

A camada de entrada é formada por um conjunto de nós fontes onde cada neurônio representa uma variável considerada como entrada para o problema. A camada intermediária é responsável pela não linearidade da rede e permite que as redes MLP sejam capazes de resolver problemas considerados linearmente não separáveis. Os neurônios desta camada possuem geralmente uma função de ativação sigmoideal que pode ser a logística ou a tangente hiperbólica. Já a camada de saída é responsável pela resposta da rede e representa a variável desejada. Em geral, essa variável é aquela que se deseja prever ou classificar. Os neurônios desta camada, além da função de ativação sigmoideal, também podem apresentar uma função do tipo linear.

A figura 6 representa uma rede MLP com quatro camadas.

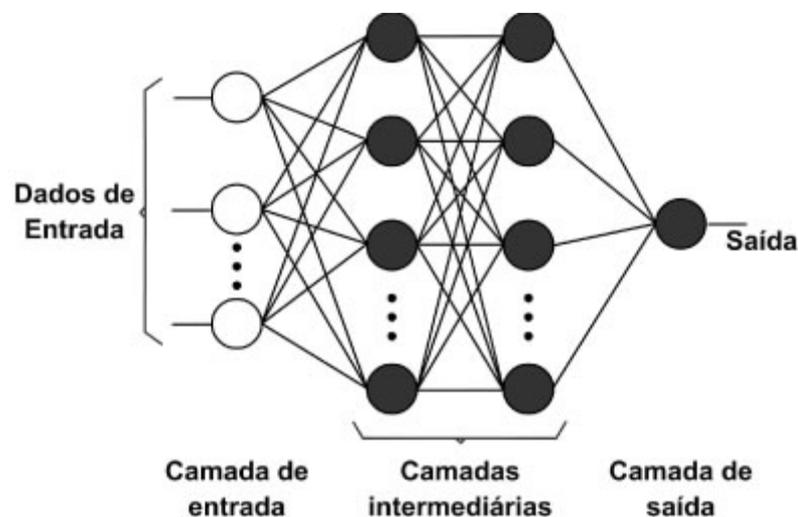


Figura 6. Arquitetura MLP com quatro camadas.

A rede MLP é do tipo *feedforward*, ou seja, a informação se propaga em uma única direção. Sempre da camada de entrada para a intermediária e, em seguida, para a camada de saída.

Assim como o Perceptron e Adaline, é necessário a utilização de um algoritmo que estabeleça o conjunto de pesos ótimos para a rede MLP. Esse processo é chamado de treinamento da rede. Nesse momento, os pesos que conectam os neurônios de uma camada com os neurônios da camada subsequente da rede são modificados para melhor se adequar ao problema. No entanto, a adição de uma ou mais camadas intermediárias torna o treinamento das redes MLP mais complexo.

Existem três tipos de aprendizado: supervisionado, não-supervisionado e por reforço [12]. As redes MLP aprendem de forma supervisionada.

No aprendizado supervisionado há o papel do “professor”, que conhece as respostas corretas para cada momento 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 adequa melhor ao problema. A dificuldade em redes de múltiplas camadas está em corrigir os pesos dos neurônios já que não se conhece o erro nas camadas intermediárias [12].

O algoritmo tradicionalmente utilizado para treinamento das redes MLP é conhecido como algoritmo *backpropagation* e resolve o problema da fase de treinamento citado anteriormente ao realizar uma propagação recursiva dos erros [13].

2.3.1 Algoritmo *Backpropagation*

O algoritmo *backpropagation* baseia-se no aprendizado por correção de erro (em que o erro é retro-propagado da camada de saída, passando pelas camadas intermediárias até a camada de entrada).

Basicamente, esse algoritmo consiste de dois passos: fase *forward*, que corresponde à propagação do sinal e a fase *backward*, que corresponde ao reajuste dos pesos. Há ainda dois importantes parâmetros nesse algoritmo: a taxa de aprendizado e o momento.

A taxa de aprendizado corresponde ao tamanho do passo em direção à correção do erro. Já o momento é utilizado para acelerar a convergência da rede e diminuir a incidência de mínimos locais [15].

O reajuste dos pesos é dado pela equação 2.4:

$$W_{i,j}^m(t+1) = W_{i,j}^m(t) + \alpha \delta_i^m f^{m-1}(net_j^{m-1}) + \beta \Delta W_{i,j}^m(t-1) \quad (2.4)$$

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 atual do i -ésimo peso do neurônio j no instante t , α é a taxa de aprendizagem, δ_i^m mede a sensibilidade do neurônio ao qual o peso em questão liga o neurônio j e β é o momento.

Caso o neurônio de índice j seja um da camada de saída, a sensibilidade é calculada de acordo com a seguinte equação:

$$\delta_i^m = (d_i - y_i) f'(net_i) \quad (2.5)$$

Onde d_i é a saída desejada, y_i é a saída encontrada após o treinamento da rede e $f'(net_i)$ é a derivada da função de ativação da camada de saída.

Caso contrário, δ_j é obtido através da seguinte equação:

$$\delta_j^{m-1} = f'^{m-1}(net_j^{m-1}) \sum_{i=1}^N w_{ij}^m \cdot \delta_i^m \quad (2.6)$$

Onde δ_i^m é a sensibilidade propagada pelo i -ésimo neurônio da camada imediatamente à frente, W_{ij}^m é o peso j do neurônio i e N é o número de neurônios na camada de saída.

2.3.2 Critério de Parada

No processo de aprendizagem supervisionada, o conjunto de padrões é mostrado à RNA várias vezes, determinando o número de épocas do treinamento. Os pesos podem ser modificados a cada amostra, ou a cada época e encontrar o momento de parada ideal não é uma tarefa tão simples, pois pode causar duas reacções indesejadas: se treinada demasiadamente, a RNA decora os padrões e perde sua capacidade de generalizar. Esse fenômeno recebe o nome de *overfitting*. Se treinada menos do que o necessário, a rede não aprende ou não generaliza o suficiente. Um dos critérios de parada mais utilizados é o da validação cruzada.

O critério de parada de validação cruzada divide o conjunto de dados em três partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para ajustar os 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 a rede. Por isso, enquanto o erro de validação cruzada estiver diminuindo, a rede continua generalizando.

A partir do momento em que o erro de validação começa a aumentar enquanto o de treinamento continua a diminuir, é sinal de que a rede pode estar decorando os padrões de treinamento. É nesse momento que o treinamento deve ser parado. Posteriormente, o conjunto de testes é introduzido na rede para avaliar o seu desempenho. A figura 7, a seguir, mostra o melhor ponto de parada.

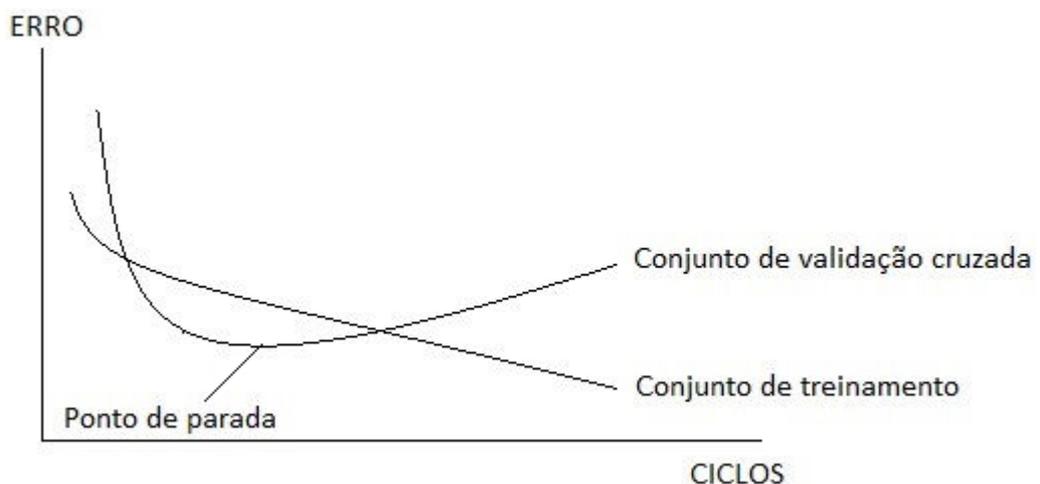


Figura 7. Melhor ponto de parada do treinamento.

2.4 Redes de Funções de Base Radial

Redes de Funções de Base Radial (redes RBF) são redes neurais artificiais que têm como funções de ativação as funções de base radial. Elas surgiram em 1988 e possuem similaridades com as redes MLP. A sua arquitetura consiste em uma camada de entrada, uma camada escondida e uma camada de saída. Um fator interessante a respeito da rede RBF é que, apesar de só possuir uma camada escondida, consegue resolver problemas não linearmente separáveis, pois as próprias funções de base radial não são lineares. Neste tipo de rede a transformação da camada de entrada para a camada oculta é não linear e da camada oculta para a camada de saída é linear. [13][15].

2.4.1 Estrutura da Rede RBF

A figura 8 representa a topologia da rede RBF. A camada de entrada realiza a interface entre o modelo e o meio. A segunda camada, ou camada escondida, realiza uma transformação não-linear do vetor de entrada. A camada de saída é composta por unidades de processamento lineares.

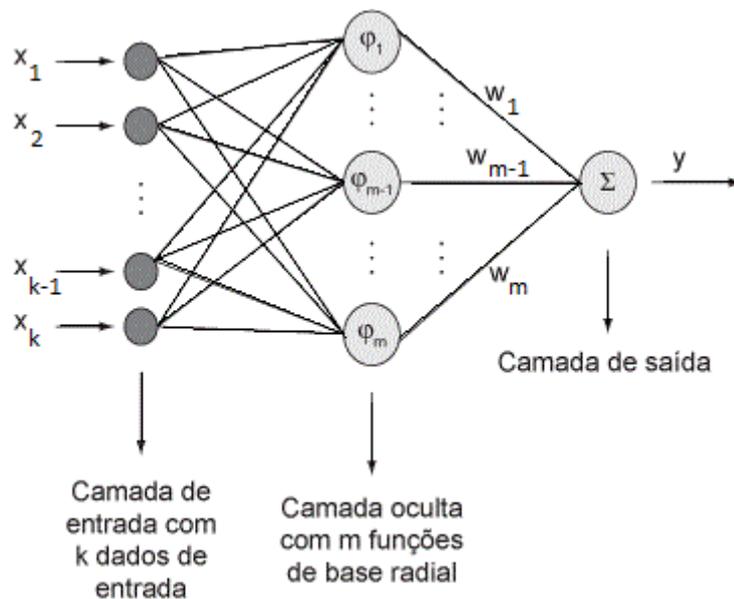


Figura 8. Rede RBF

A saída da rede y_k é uma combinação linear de funções de base radiais, dada pela equação (2.7)

$$y_k(x) = \sum_{j=0}^M w_{kj} \phi_j(x) \quad (2.7)$$

A função de ativação mais utilizada é a Gaussiana, descrita na equação 2.8. Essa função é executada na transformação da camada de entrada para a camada escondida.

$$\phi_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (2.8)$$

Onde os valores de x são as entradas da rede. μ_j e σ_j são o centro e a dispersão da i -ésima função de base radial.

2.4.2 Treinamento da Rede RBF

O treinamento mais utilizado é o do tipo híbrido, dividido em 2 fases: a primeira, não supervisionada é quando ocorre a definição dos parâmetros das funções de base radial da camada escondida, na segunda, supervisionada, são ajustados os pesos que ligam a camada escondida à camada de saída.

Na primeira fase é comum utilizar algoritmos de *clusterização* para achar os centros das funções radiais, como, por exemplo, o k -médias [13], esses algoritmos são usados para determinar um conjunto de centros que reflete, com precisão, a distribuição dos dados. Dado um conjunto de entradas x_j com $j = 1, 2, \dots, N$, o objetivo do algoritmo é encontrar um conjunto de K centros. O algoritmo, então, divide as entradas em subconjuntos S , com a intenção de minimizar a função F dada na equação (2.9). Essa minimização ocorre de acordo com a equação (2.10).

$$F = \sum_{i=1}^K \sum_{j \in S} \|x_j - \mu_i\|^2 \quad (2.9)$$

onde: μ_i é a média dos pontos pertencentes ao conjunto S calculada por

$$\mu_i = \frac{1}{N_i} \sum_{j \in S} x_j \quad (2.10)$$

No treinamento da RBF as entradas são dispostas aleatoriamente sobre cada conjunto. Então os dados são redistribuídos conforme mais próximo dos centros novos. Quando o cálculo do centro não apontar mais nenhuma mudança o algoritmo pára e o treinamento não supervisionado é finalizado [13][15].

O treinamento supervisionado é o simples ajuste dos pesos com a comparação da saída desejada com a função de erro escolhida. O número de neurônios na camada escondida pode ser definido por validação cruzada.

Capítulo 3 - Metodologia

Este capítulo mostra como as teorias apresentadas no capítulo 2 serão aplicadas para alcançar o objetivo do trabalho. Os algoritmos de redes neurais MLP e RBF que foram utilizados pertencem ao Neural Toolbox da IDE Matlab.

3.1 Base de Dados

A base de dados utilizada nos experimentos foi cedida pelo Operador Nacional de Sistema Elétrico (ONS). O ONS é o órgão responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), sob a fiscalização da ANEEL.

Os dados de velocidade média dos ventos são diários, foram observados de 30 em 30 minutos e o período em que foram medidos e coletados vai de 01 de dezembro de 2011 até 31 de julho de 2012.

A seguir, na tabela 1, uma amostra dos dados utilizados é apresentada.

Dia	Mês	Ano	Hora	Minuto	Segundo	Velocidade Média
1	12	2011	0	29	56	11,9
1	12	2011	0	59	56	12,1
1	12	2011	1	29	56	11,9
1	12	2011	1	59	56	11,8
1	12	2011	2	29	56	11,3
1	12	2011	2	59	56	11,1

Tabela 1. Amostra da base de dados utilizada

3.2 Pré-processamento dos Dados

A primeira etapa na fase de pré-processamento dos dados é a normalização dos dados. A normalização é importante para que as variáveis em intervalos diferentes recebam a mesma atenção durante o treinamento, ou seja, evita que valores altos influenciem demais os cálculos da RNA enquanto valores baixos passam despercebidos.

As variáveis têm que ser normalizadas de tal maneira que seus valores sejam proporcionais aos limites das funções de ativação utilizadas na camada de saída. O intervalo normalmente é dado entre 0 e 1, contudo o intervalo usado neste trabalho variou de 0,15 a 0,85, devido ao algoritmo *backpropagation* se tornar lento quando a derivada da função de ativação fica próxima de zero [13].

A normalização é dada por:

$$y = ((b - a)(x_i - x_{min}) / (x_{max} - x_{min})) + a \quad (3.1)$$

Onde y é o valor normalizado, b é o intervalo máximo da normalização (0.85), a é o intervalo mínimo da normalização (0.15), x_i é o valor da entrada, x_{min} é o valor mínimo das variáveis de entrada e x_{max} é o valor máximo das variáveis de entrada.

3.3 Determinação das Variáveis de Entrada

A quantidade de neurônios na camada de entrada e de saída é dada pelo problema a ser solucionado e depende do conhecimento do modelador com relação aos dados que está trabalhando [13].

Para que as RNAs possuam boa capacidade de aprendizado e generalização é necessário definir, além da quantidade de neurônios em cada camada, quais variáveis de entrada mais influenciam na saída da previsão. Neste trabalho, se utilizará apenas a própria velocidade do vento.

Uma grande quantidade de entradas aumenta o tamanho e a complexidade da rede, que retarda o treinamento e aumenta a quantidade de dados requeridos

para estimar os seus pesos. Além disso, a inclusão de entradas irrelevantes pode prejudicar o processo de treinamento [13].

É necessário verificar, ainda, o grau de dependência das variáveis. Para isso, faz-se uso de um método chamado correlação linear. O termo correlação significa a relação entre dois termos e é utilizado em estatística para indicar a força do relacionamento linear entre duas variáveis aleatórias.

A correlação entre duas variáveis pode ser medida de acordo com a equação 3.2:

$$C = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 - \sum (y - \bar{y})^2}} \quad (3.2)$$

onde C é a correlação, x e y são os valores das variáveis cuja correlação está sendo calculada, \bar{x} é o valor médio de x, \bar{y} é o valor médio de y.

A correlação linear tem seus valores sempre entre -1 e 1. Se o valor for próximo a zero, significa que as variáveis não estão relacionadas. O quadrado da correlação é conhecido como coeficiente de determinação e tem seu valor entre 0 e 1, sempre positivo.

A tabela 2, a seguir, mostra as correlações lineares entre a velocidade do vento no tempo t e a velocidade do vento nos tempos t – 30 minutos, t – 60 minutos, t – 90 minutos, t – 120 minutos, t – 150 minutos, t – 180 minutos e t – 210 minutos.

Correlação	Valor
t e (t – 30) minutos	0,964
t e (t – 60) minutos	0,852
t e (t – 90) minutos	0,833
t e (t – 120) minutos	0,789
t e (t – 150) minutos	0,737
t e (t – 180) minutos	0,695
t e (t – 210) minutos	0,655

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

Assim, as entradas a serem consideradas são:

- Velocidade do vento no tempo (t – 30) minutos.
- Velocidade do vento no tempo (t – 60) minutos.
- Velocidade do vento no tempo (t – 90) minutos.
- Velocidade do vento no tempo (t – 120) minutos.
- Velocidade do vento no tempo (t – 150) minutos.
- Velocidade do vento no tempo (t – 180) minutos.
- Velocidade do vento no tempo (t – 210) minutos.

As saídas da base serão 2 valores da velocidade do vento (t + 30) minutos e (t + 60 minutos), o que significa a previsão de 1 hora à frente.

3.4 Arquiteturas de Rede Utilizadas – Predizendo a Velocidade do Vento

A seguir são apresentados os parâmetros de configuração utilizados nas RNAs deste trabalho.

Rede MLP:

- Número de neurônios na camada de entrada: (7).
- Número de neurônios na camada escondida: {5, 10, 15, 20, 25}.
- Número de neurônios na camada de saída: (2).
- Função de ativação: (equação 3.3).
- Critério de parada: (validação cruzada).
- Taxa de aprendizado: (0,1).
- Momento: (0,3).

O algoritmo utilizado é o backpropagation e a função de ativação escolhida para os neurônios é a sigmóide logística, descrita na equação 3.3.

$$y = \frac{1}{1 + e^{-net_i}} \quad (3.3)$$

Onde y = valor de saída e net_i é a média ponderada dos pesos com as entradas do i -ésimo neurônio.

Essa função retorna valores pertencentes ao intervalo [0,1].

Rede RBF:

- Número de neurônios na camada de entrada.
- Número de neurônios na camada de saída.
- Função de ativação: Gaussiana.
- Treinamento híbrido.
- Vetores de centro da camada escondida: Definido pelo algoritmo k-medias.
- Pesos entre a camada escondida e a camada de saída: Definido pelo treinamento supervisionado.
- Dispersão das funções de base radial da camada escondida.

O número de entradas para ambas as redes foi definido de acordo com o método de correlação descrito na seção 3.3, ou seja, 7 valores passados de velocidade.

A saída são 2 valores de velocidade do vento, ou seja, previsão de 1 hora a frente.

Logo, os parâmetros restantes são o número de neurônios da camada escondida, para a rede MLP, e o valor da dispersão das funções de base, para a rede RBF.

Para definir tais parâmetros é necessário:

- Treinar as redes com diferentes números de dispersão e de neurônios na camada escondida para as redes RBF e MLP, respectivamente.
- Para cada valor, treinar a rede 30 vezes.
- Números de neurônios propostos: 5, 10, 15, 20, 25.
- Valores de dispersão propostos: 0.5, 0.8, 1, 2, 3 e 4.
- Para cada valor proposto, calcular a média do erro do treinamento.
- Configurar as redes com os valores com a menor média de erro.

A medida de erro adotada é o Erro Médio Quadrático (EMQ), mostrado na equação 3.4.

$$EMQ = \sqrt{\frac{\sum (d-y)^2}{N}} \quad (3.4)$$

onde d é a saída desejada, y é a saída fornecida pelo treinamento e N o número total de saídas do conjunto calculado.

3.5 Teste Estatístico

Após os 30 treinamentos [16] para cada tipo de rede neural, foi realizado teste estatístico para comparar o desempenho das arquiteturas de RNA na previsão da velocidade dos ventos.

O teste de Wilcoxon verifica a magnitude da diferença entre dois dados através da comparação das medianas das amostras. Esse teste assume que a distribuição das diferenças é simétrica. O primeiro passo da comparação foi verificar se as duas amostras comparadas são iguais ou diferentes. Para isso, foram elaboradas as seguintes 2 hipóteses para a representatividade da média dos erros. A hipótese nula (H_0) diz que as médias obtidas pelos erros das 2 redes não são significativamente diferentes. Já a hipótese alternativa (H_A) diz que as médias de erro obtidas são significativamente diferentes.

Após definir as hipóteses, foi fixado o valor do nível de significância 0,05, que determina a probabilidade de rejeitar acidentalmente uma hipótese nula verdadeira (falso positivo).

4. Resultados

Este capítulo apresenta os resultados obtidos através da metodologia descrita no capítulo 3.

As configurações de rede utilizadas são as definidas na seção 3.4.

Na rede MLP, a quantidade de neurônios da camada escondida foi definida realizando o treinamento da rede com o número de neurônios propostos na seção 3.4: 5, 10, 15, 20 e 25.

A tabela 3 mostra a quantidade de neurônios na camada escondida que apresentou o menor erro.

Neurônios na Camada Escondida	EMQ
5	0,017
10	0,014
15	0,013
20	0,016
25	0,015

Tabela 3. Neurônios na Camada Escondida x Erro Médio Quadrático

A figura a seguir mostra a arquitetura da rede MLP com os 7 neurônios na camada de entrada, 15 na escondida e 2 na camada de saída.

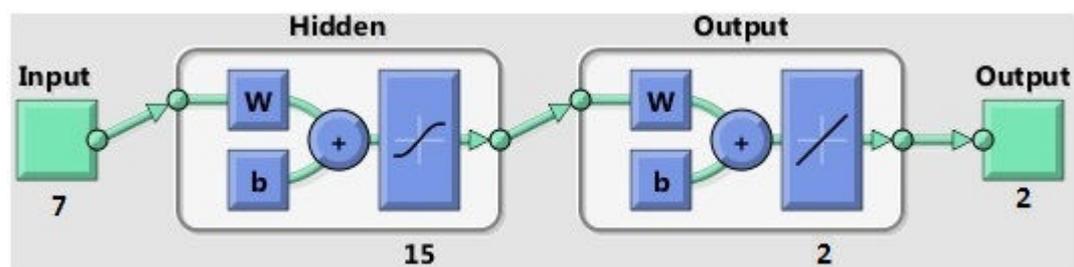


Figura 9. Arquitetura da rede MLP.

Ao utilizar a rede RBF com os mesmos 7 neurônios na camada de entrada, o melhor valor de dispersão encontrado entre os propostos na seção 3.4 foi 0,5, como mostra a tabela a seguir.

Valores de Dispersão	EMQ
0,5	0,023
0,8	0,028
1	0,031
2	0,034
3	0,035
4	0,036

Tabela 4. Valores de Dispersão x Erro Médio Quadrático

4.1 Simulações e Comparações Estatísticas

Uma vez treinadas com as melhores configurações obtidas nos testes, as redes estão prontas para o processo de simulação. As simulações têm como objetivo verificar qual das duas redes possui o menor erro na previsão da velocidade dos ventos. As duas redes utilizadas neste trabalho também são comparadas com o modelo de persistência no intervalo de previsão de uma hora à frente. O modelo de persistência em geral apresenta bons resultados, pois o tempo necessário para que mudanças atmosféricas ocorram é da ordem de várias horas.

Nesta etapa, separa-se uma amostra aleatória dos dados de entrada. Esse subconjunto é composto pelas entradas do conjunto de testes utilizadas na validação cruzada da rede MLP.

Os seguintes passos são utilizados para uma maior precisão nas comparações:

- Os dados de entrada separados são utilizados para encontrar as saídas simuladas pelas redes.
- Desnormalização da saída encontrada, revertendo o processo utilizado no pré-processamento descrito na seção 3.2.
- Calcula-se o erro com relação à saída desejada, também desnormalizada.
- Utiliza-se o modelo de persistência. Assumi-se que a velocidade do vento de uma hora à frente é igual à velocidade atual e calcula-se o erro.
- Comparação dos erros.

A medida de erro utilizada foi o Erro Percentual Médio Absoluto (EPMA), dado na equação 4.1.

$$EPMA = \frac{\sum_{i=1}^n \left| \frac{d_i - y_i}{d_i} \right| \cdot 100}{n} \% \quad (4.1)$$

onde n = número de previsões realizadas, d_i é a saída desejada para a i -ésima previsão e y_i é a saída obtida para a i -ésima previsão.

A tabela a seguir mostra o erro percentual médio absoluto das redes.

Método de Previsão	EPMA
MLP	14,82%
RBF	5,38%
Modelo de Persistência (1 hora à frente)	11,97%

Tabela 5. Erro Percentual Médio Absoluto das Redes.

Através dos erros percentuais médios apresentados na tabela 5 pode-se observar:

- A rede RBF apresentou maior capacidade de generalização do que a rede MLP. Com resultado melhor do que o modelo de persistência.
- A rede MLP apresentou uma pequena diferença com relação ao modelo de persistência, com *EPMA* ligeiramente maior.

Para finalizar, foi realizado o teste de Wilcoxon (seção 3.5) para determinar se existe diferença significativa entre as médias de erro obtidas pelas redes.

O teste foi conduzido com o auxílio do software R que utiliza como padrão um nível de significância de 0,05.

As amostras utilizadas foram os 30 erros obtidos de cada rede.

A tabela a seguir mostra o resultado dos testes.

Comparação	p-value
MLP x RBF	$2,2 \times 10^{-16}$
MLP x Modelo de Persistência	$2,2 \times 10^{-16}$
RBF x Modelo de Persistência	$2,2 \times 10^{-16}$

Tabela 6. Resultados do Teste de Wilcoxon.

Como o p-value é menor do que o nível de significância, a hipótese nula (seção 3.5) é rejeitada, ou seja, existe diferença significativa entre as médias obtidas. Demonstrando que os resultados obtidos com a rede RBF possuem melhor desempenho e são significativos e não são exclusividade das amostras utilizadas no teste.

5. Conclusão e Trabalhos Futuros

O principal objetivo deste trabalho foi aplicar técnicas de redes neurais artificiais para melhorar as estimativas de velocidade dos ventos utilizando-se de dados reais.

O melhor resultado obtido com este trabalho apresentou um erro de 5,38% em sua precisão na previsão da velocidade do vento, contra um erro de 11,97% do modelo de persistência.

Como trabalhos futuros, com a finalidade de diminuir os erros encontrados, tem-se:

- Testes com novas configurações de redes.
- Novas técnicas para seleção de outras variáveis de entrada, além da velocidade do vento.
- Utilização de outras funções de ativação.
- Utilização de outras bases de dados para realização de testes.
- Testar horizonte de previsão para 6 horas à frente.

Bibliografia

- [1] ALDABO, R. **Energia Eólica**. 1. ed. [S.l.]: ArtLiber, 2002. 156 p.
- [2] ELETROBRÁS. **Programas – PROINFA**. Acessado em 01 de setembro de 2013. Disponível em: <<http://www.eletronbras.com.br/elb/portal/data/Pages/LUMISABB61D26PTBRIE.htm>>.
- [3] DO AMARANTE O.A.C., BROWER M., ZACK J., LEITE DE SA A. “**Atlas do Potencial Eólico Brasileiro**”, Camargo-Schubert, TrueWind Solutions, CEPEL, 2001
- [4] Ministério do Meio Ambiente. **Energias Renováveis – Energia Eólica**. Acessado em 01 de setembro de 2013. Disponível em: <<http://www.mma.gov.br>>.
- [5] ANEEL – **Atlas de Energia Elétrica**. Disponível em: <<http://www.aneel.gov.br/aplicacoes/atlas>>
- [6] **Centro de Referência para Energia Solar e Eólica**. Disponível em: <<http://www.cresesb.cepel.br>>
- [7] RODRIGUES, Guilherme. **Utilização de Redes Neurais para Previsão de Ventos no Horizonte de 24 Horas**. Dissertação de Mestrado do Curso de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.
- [8] SARAIVA, Rodrigo. **Localização ótima dos conversores de um parque eólico para minimização de custos totais**. Dissertação de Mestrado do Curso de Engenharia Elétrica e de Computadores, Universidade Técnica de Lisboa, Lisboa, 2007.

- [9] MAKAROV, Y., HAWKINS, D., LEUZE, E. AND VIDOV, J. **California ISO Wind Generation Forecasting Service Design and Experience. Proceedings of American Wind Energy Association Conference**, Oregon, USA, 2003.
- [10] PIWKO, R., BAI, X., CLARK, K., JORDAN, G., MILLER, N. AND ZIMBERLIN, J. **The Effects of Integrating Wind Power on Transmission System Planning, Reliability, and Operations**. Report on Phase 2: System Performance Evaluation, Albany, New York, USA, 2005.
- [11] SIEBERT, N. **Development of Methods for Regional Wind Power Forecasting**. 2008.
- [12] BRAGA, A. de P.; CARVALHO, A. P. de Leon Filho de; LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.
- [13] VALENÇA SILVA, J. M. **Fundamentos das Redes Neurais**. Livro Rápido, 2011.
- [14] MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin os Mathematical Biophysics, 1943, p. 115-133.
- [15] HAYKIN, S. **Redes Neurais: Princípios e Práticas**. Bookman, 2007.
- [16] JURISTO, N.; MORENO, M. **Basics of Software Engineering Experimentation**. Kluwer Academic Publisher, 2001.