



PREVISÃO DE GERAÇÃO DE ENERGIA EÓLICA UTILIZANDO REDES NEURAIAS ARTIFICIAIS

Trabalho de Conclusão de Curso

Engenharia da Computação

Wendel Vanderley da Paz
Orientador: Mêuser Jorge Silva Valença



**UNIVERSIDADE
DE PERNAMBUCO**

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

WENDEL VANDERLEY DA PAZ

**PREVISÃO DE GERAÇÃO DE ENERGIA
EÓLICA UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

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

Recife, dezembro de 2014.

De acordo

Recife

____/____/____

Orientador da Monografia

*Dedico este trabalho a todos aqueles que, de alguma forma, contribuíram para
minha formação.*

Agradecimentos

Agradeço,

A Deus por ter me reservado um lugar na família maravilhosa que eu tenho, pelos amigos que colocou em minha vida e pelas conquistas ao longo dessa jornada.

Aos meus pais, Ana Paula Vanderley da Paz e Nelson José da Paz Filho, que nunca mediram esforços para me proporcionar a melhor educação e os melhores ensinamentos. Se não fosse o empenho de vocês talvez eu não tivesse alcançado tudo que conquistei até hoje. A minha irmã, Gyslainne Vanderley, pelo convívio por todos esses anos. 'Essa conquista, assim como todas as outras foram, também é de vocês'.

Aos meus tios, tias, avôs e avós, por terem desempenhado um papel complementar na minha educação e formação como cidadão. Cada um de vocês é responsável por uma parte disso tudo. Aos meus primos e primas por terem proporcionado os melhores momentos da minha infância.

A minha namorada, Bianca Alves, e sua família, que me acompanham desde o início da minha graduação. Companheira em todos os momentos, inclusive quando ficamos 1 ano separados por um oceano durante meu intercâmbio acadêmico. Obrigado pelo seu apoio, pela amizade de todas as horas, seu amor e sua paciência. 'Esta conquista também é sua, amor'.

Aos amigos do "Padasto", que me acompanham desde a época do colégio me proporcionando momentos sensacionais. Aos amigos de turma (2008.2), por todas as horas de estudos e momentos divertidos durante esses anos. Um agradecimento especial a Rafael Lopes, Sergio Ribeiro, Pedro Henrique e Tarcísio Mendes pelo apoio dado quando estivemos em solo francês, durante nosso intercâmbio acadêmico.

A todos os meus professores, por compartilhar comigo o conhecimento necessário para minha formação. Agradeço, também, ao meu orientador Mêuser Jorge Silva Valença e suas orientandas Bruna Galle e Lara Dantas, pela ajuda no desenvolvimento deste trabalho.

Resumo

A energia elétrica é um recurso indispensável para manter o funcionamento e o desenvolvimento da sociedade moderna. Esta demanda por energia é suprida, em sua grande parte, por fontes de energias não renováveis – petróleo, gás natural e carvão mineral – que além de extremamente nocivas ao meio ambiente podem ter suas reservas esgotadas em alguns anos. Diante deste quadro, faz-se necessário a busca por fontes energéticas limpas e renováveis, dentre elas a energia eólica, objeto de estudo deste trabalho. Mesmo sendo considerada uma das fontes de geração de energia mais promissoras, a energia advinda do vento apresenta alguns pontos que merecem um estudo mais aprofundado visto que se faz necessário um bom aproveitamento deste recurso para uma geração mais eficiente de energia. Para isso, faz-se necessário um estudo do potencial eólico do local que abrigará o parque eólico para extração da energia dos ventos levando-se em consideração variáveis como o relevo da região, velocidade e direção do vento, por exemplo. Este trabalho fará uso das redes neurais artificiais para prever a geração de energia pelo parque eólico, mediante influência do vento, baseando-se em um histórico da velocidade do vento na região, onde, realizar-se-á a seleção da melhor arquitetura entre as redes neurais MLP (*Multi-Layer Perceptron*) e a RBFN (*Radial Basis Function Network*), utilizando-se diferentes configurações em cada uma.

Palavras-chave: Energia eólica, vento, previsão da velocidade do vento, velocidade, MLP, RBFN.

Abstract

Electricity is an indispensable resource to maintain the functioning and the development of modern society. The most part of this growing demand for energy is supplied by non-renewable energy – oil sources, natural gas and mineral coal – which, besides extremely harmful to the environment, may have their reserves emptied in a few years. From this situation, it is necessary search others clean and renewable energy sources, and the wind is one of them. Despite being considered one of the most promising sources of electricity generation, the energy originated by wind presents some points that deserves a detailed study about the use of this resource, for a better use of energy generation. For this, the study of the relief of the region, wind speed and direction of the wind, for example, is necessary before to installation to the wind farm for the extraction of wind energy. The goal of this paper is to select the best artificial neural networks for predicting the average wind speed, between two architectures: Multi-layer Perceptron (MLP) and Radial Basis Function (RBF).

Key-words: wind energy, wind, predicting the average wind speed, speed, MLP, RBFN.

Sumário

Capítulo 1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.2.1 Objetivo Geral	2
1.2.2 Objetivos Específicos	3
1.3 Estrutura da Monografia	3
Capítulo 2 Fundamentação Teórica	4
2.1 Energia Eólica	4
2.1.1 Introdução	4
2.1.2 O Vento	6
2.1.3 Fatores que influenciam o regime dos ventos	6
2.1.4 Turbina eólica	8
2.1.5 Potencial Eólico Brasileiro	11
2.2 Redes Neurais	12
2.2.1 Introdução	12
2.2.2 Neurônio Biológico	12
2.2.3 Neurônio Artificial	13
2.3 <i>Multi-layer Perceptron</i>	15
2.3.1 Algoritmo <i>Backpropagation</i>	17
2.3.2 Critério de Parada	19
2.4 <i>Radial Basis Function Network</i>	20
2.4.1 Estrutura da Rede RBF	20
2.4.2 Treinamento da Rede RBF	22
Capítulo 3 Metodologia	24

3.1	Base de Dados	24
3.2	Pré-processamento dos Dados	25
3.2.1	Normalização dos Dados	25
3.2.2	Defasagem dos Dados	26
3.3	Definição das Variáveis de Entrada da Rede	27
3.4	Arquiteturas de Redes Neurais Utilizadas Na Predição da Velocidade Média do Vento	29
3.4.1	Rede <i>Multilayer Perceptron</i>	29
3.4.2	Rede <i>Radial Basis Function</i>	32
3.4.3	Modelo de Persistência	34
3.5	Comparativo e Teste Estatístico	35
3.5.1	Comparação dos Resultados das Arquiteturas MLP e RBF	35
3.5.2	Teste Estatístico	35
	Capítulo 4 Resultados	36
	Capítulo 5 Conclusão e Trabalhos Futuros	38
5.1	Conclusão	38
5.2	Trabalhos Futuros	38
	Bibliografia	39

Índice de Figuras

Figura 1.	Moinho de vento comum nos campos holandeses	5
Figura 2.	Turbina eólica de eixo vertical	10
Figura 3.	Turbina eólica de eixo horizontal	11
Figura 4.	Neurônio Biológico	13
Figura 5.	Modelo matemático do neurônio proposto por McCulloch e Pitts	14
Figura 6.	<i>Multi-layer Perceptron</i> de três camadas	16
Figura 7.	Ponto de parada do treinamento utilizando a validação cruzada	20
Figura 8.	Estrutura da Rede RBF	21
Figura 9.	EMQ Médio por número de neurônios na camada escondida para o parque I	31
Figura 10.	EMQ Médio por número de neurônios na camada escondida para o parque B	31

Índice de Tabelas

Tabela 1. Distribuição da área de cada continente segundo a velocidade do vento....	7
Tabela 2. Amostra de dados relativos ao Parque I	25
Tabela 3. Exemplo de defasagem de dados.....	26
Tabela 4. Correlação linear entre a velocidade do vento e a mesma variável em tempos anteriores.....	28
Tabela 5. EMQ de acordo com a relação <i>Spread</i> x Neurônios na Camada Escondida para o parque I.....	33
Tabela 6. EMQ de acordo com a relação <i>Spread</i> x Neurônios na Camada Escondida para o parque B.....	34
Tabela 7. Média do Erro Médio Quadrático dos resultados das 30 simulações.....	36
Tabela 8. Resultado do teste estatístico da Soma dos Postos de Wilcoxon.....	37

Tabela de Símbolos e Siglas

RNA	Rede Neural Artificial
MLP	<i>Multilayer Perceptron</i>
RBFN	<i>Radial Basis Function Network</i>
RBF	<i>Radial Basis Function</i>
EMQ	Erro Médio Quadrático
VAWT	<i>Vertical Axis Wind Turbine</i>
HAWT	<i>Horizontal Axix Wind Turbine</i>
ONS	Operador Nacional do Sistema Elétrico
Abeeólica	Associação Brasileira de Energia Eólica
ANEEL	Agência Nacional de Energia Elétrica
MCT	Ministério da Ciência e Tecnologia
CBEE	Centro Brasileiro de Energia Eólica
UFPE	Universidade Federal de Pernambuco

Capítulo 1

Introdução

Este Capítulo apresenta os motivos da realização deste trabalho. Em seguida serão traçados os objetivos a serem seguidos ao longo da monografia e por fim será mostrada a estrutura do conteúdo exposto neste trabalho.

1.1 Motivação

A energia é um ingrediente essencial para o desenvolvimento e bom funcionamento da sociedade. Segundo estudos realizados no ano 2000, a demanda por este recurso, no mundo, cresce cerca de 2% ao ano e poderá atingir o dobro do consumo nos 30 anos seguintes [11].

Mundialmente, a demanda atual por recursos energéticos é suprida, em sua grande parte, por fontes de energias não renováveis – petróleo, gás natural e carvão mineral – e extremamente poluentes. Assim, faz-se necessário a busca por novas tecnologias para a geração de energia, de forma que as necessidades energéticas sejam providas de maneira limpa e renovável, diminuindo, assim, a degradação do meio ambiente.

No Brasil, a maior parte da energia elétrica consumida é proveniente das usinas hidrelétricas, que chegam a produzir cerca de 123,1 mil megawatts (MW). Esse valor somado aos quase 8,1 mil MW advindos de países vizinhos, deixam a disposição da população cerca de 131,2 mil MW de potência [20]. Porém, por se tratar de um sistema dependente de recursos hídricos, fenômenos naturais como períodos prolongados de estiagem, seca, em algumas regiões do país, podem comprometer a produção energética. Sendo assim, cresce o interesse por incentivos à busca de fontes energéticas complementares para que esse déficit de produção seja corrigido e a energia eólica surge como uma ótima opção.

Segundo boletim divulgado, em fevereiro de 2014, pela Associação Brasileira de Energia Eólica (Abeeólica), em seis anos, a capacidade instalada da energia eólica no Brasil vai aumentar quase 300%. Ao levar em conta os parques eólicos em

construção e a energia já contratada, o país sairá dos atuais 3.445,3 megawatts para 13.478,3 MW de potência, energia suficiente para abastecer cerca de 20 milhões de casas no país [9].

Por se tratar de uma fonte alternativa de energia, renovável e limpa, faz-se necessário planejar e otimizar a utilização deste recurso para que se possa extrair o máximo do potencial eólico sem degradar o meio ambiente. Para isso, realizam-se estudos com as variáveis que afetam diretamente a produção de energia elétrica proveniente do vento – topografia da região, velocidade e direção do vento, etc – a fim de prever a capacidade eólica de uma determinada região antes de ser implantado um parque gerador de energia eólica, diminuindo a incerteza e, conseqüentemente, os custos na instalação e operação dos parques.

Então, pode-se observar que um trabalho preciso a cerca da previsão do potencial eólico é fundamental para se obter sucesso na exploração deste recurso, mantendo essa alternativa energética sempre crescente em desenvolvimento tendo em vista o grande potencial que o Brasil dispõe devido as suas características demográficas.

1.2 Objetivos

1.2.1 Objetivo Geral

Como um todo, o objetivo deste trabalho é utilizar diferentes arquiteturas de Redes Neurais Artificiais (RNAs) a fim de indicar a que retorna o melhor resultado para previsão de geração eólica, quando submetidas aos dados de velocidade média do vento presentes nas bases de dados cedidas pelo Operador Nacional do Sistema Elétrico (ONS).

Então, após realização dos testes com as arquiteturas neurais MLP e RBFN para previsão da geração eólica, serão realizadas comparações entre os resultados obtidos por ambas com o intuito de avaliar a arquitetura que obteve melhor desempenho.

1.2.2 Objetivos Específicos

1. Realizar a defasagem e tratamento dos dados para obtenção de informações válidas que servirão de entradas para as redes neurais;
2. Testar várias combinações de parâmetros para as redes neurais MLP e RBFN com entradas definidas pelo estudo da correlação linear e 2 saídas da rede;
3. Validar os resultados obtidos nos experimentos através de testes estatísticos.

1.3 Estrutura da Monografia

No Capítulo 2, serão apresentados os fundamentos teóricos necessários para o entendimento do conteúdo proposto no trabalho, a saber: energia eólica e redes neurais artificiais, com destaque para as redes MLP e RBFN, escolhidas para serem aplicadas neste trabalho. O Capítulo 3 traz a forma de condução dos experimentos para alcançar o objetivo do trabalho, tais como tratamento e processamento dos dados de velocidade do vento e as configurações e utilização das arquiteturas neurais usadas em simulação. No Capítulo 4 serão expostos os resultados obtidos das simulações, bem como o estudo comparativo das arquiteturas diante dos resultados obtidos. Por fim, o Capítulo 5 apresenta um resumo do que fora abordado neste projeto envolvendo os resultados obtidos, conclusão, propostas para trabalhos futuros e dificuldades encontradas ao longo do desenvolvimento.

Capítulo 2

Fundamentação Teórica

Este Capítulo tem objetivo de fazer uma abordagem a cerca do conteúdo básico necessário para a realização do estudo. A Seção 2.1 provê informações sobre a energia eólica e os fatores que influenciam diretamente a sua geração, equipamentos utilizados na geração de eletricidade a partir dos ventos. Traz, também, um panorama da situação eólica no Brasil. A Seção 2.2 faz uma introdução às bases teóricas das Redes Neurais Artificiais dando ênfase as estruturas que serão utilizadas nos estudo apresentado neste material: *Multi-layer Perceptron* e a *Radio Basis Function Network*. Também, nesta Seção, serão abordadas as etapas de treinamento das redes, validação dos resultados e testes.

2.1 Energia Eólica

A energia eólica é produzida, atualmente, por meio de aerogeradores, onde a energia cinética contida nos ventos é captada através das hélices acopladas à turbina que, ao acionar o gerador elétrico, converte esta energia em energia cinética de rotação. É uma fonte abundante, renovável, limpa e disponível em várias regiões do planeta [16].

2.1.1 Introdução

Acredita-se que a utilização dos ventos como energia tenha origem no Egito, por volta do ano 2800 AC, quando os egípcios utilizavam velas em barcos para auxiliar a força dos remos dos escravos. Posteriormente, os persas, por volta do ano 700 DC, construíram os primeiros moinhos de vento verticais para atuarem como força nas nós, na moagem de grãos [8].

Outras civilizações do oriente médio, mais notadamente os muçulmanos, continuaram com as idéias persas e construíram seus próprios moinhos de vento. Com o retorno das cruzadas, acreditou-se que os muçulmanos tinham levado as idéias sobre o moinho de vento para a Europa, mas provavelmente foram os

holandeses que desenvolveram o tradicional moinho de vento horizontal com hélices, comuns nos campos dos holandeses e ingleses como ilustra a **Figura 1**.



Figura 1. Moinho de vento comum nos campos holandeses
[Fonte: retirada do site: <http://finestraperileuropa.blogspot.com.br/>]

A geração de energia elétrica por meio da força dos ventos teve início no século XX, com alguns dos primeiros desenvolvimentos creditados aos dinamarqueses. Nos anos 90, especificamente em 1930, muitas empresas americanas produziram geradores eólicos para serem vendidos à fazendeiros. Basicamente, essas máquinas poderiam produzir até 1000 watts de potência.

Ainda nos anos 90, alguns países europeus construíram enormes geradores de energia eólica, tais como: França, com máquinas avançadas que geravam entre 100 *kilowatts* (kW) e 300 kW, e Alemanha. Porém, devido a forte concorrência dos fluidos fósseis para geração de energia, essas máquinas eólicas foram deixadas de lado [8].

Atualmente, os aerogeradores tem despertado grande interesse por causa das práticas ambientais de sustentabilidade e, também, devido aos outros meios de geração de energia terem suas fontes limitadas e não renováveis, ao contrário do vento, que se configura como uma fonte limpa e renovável.

2.1.2 O Vento

Responsável direto na geração da energia eólica, o vento é resultado do deslocamento de massas de ar que se movem de áreas com maior pressão atmosférica para áreas onde a pressão é mais baixa, sendo a altitude e a temperatura os principais responsáveis por gerar esta diferença de pressão que a atmosfera exerce sobre a Terra.

Quanto a altitude, quanto maior, menor é a pressão atmosférica e quanto menor, maior é a pressão. No que se refere a temperatura, devido a distribuição desigual de incidências dos raios solares sobre a superfície terrestre, algumas áreas são mais quentes que outras, fazendo com que, nas áreas mais quentes, o ar sofra uma maior expansão, deixando-o em constante ascensão e tornando a pressão atmosférica mais baixa. Por outro lado, nas zonas térmicas mais frias, a pressão que o ar exerce sobre a Terra é maior, fazendo com que essa massa de ar ocupe o espaço deixado pelo ar que ascendeu na região mais quente. Assim, através deste deslocamento das massas de ar, forma-se a matéria prima essencial para a produção de energia eólica: o vento.

2.1.3 Fatores que influenciam o regime dos ventos

A avaliação do potencial eólico de uma região requer um estudo sistemático sobre os fatores que influenciam diretamente o regime dos ventos, entre os principais fatores destacam-se:

- A variação da velocidade de acordo com a altura;
- A rugosidade do terreno, caracterizada pela vegetação, utilização da terra e construções;
- Presença de obstáculos nas redondezas;
- O relevo, que pode causar efeitos de aceleração e desaceleração no escoamento do ar.

Em um primeiro momento, as estimativas do potencial bruto ou teórico do aproveitamento da energia eólica em determinada região, podem ser feitas realizando-se uma coleta de dados em aeroportos, estações meteorológicas e através de observações de mapas topográficos, por exemplo, para fins de uma

avaliação inicial da possibilidade de instalação de um parque eólico na região em estudo [7][2].

Para que a energia eólica seja tecnicamente aproveitável, faz-se necessário que, a uma altura de 50 metros (m), por exemplo, tenha-se uma velocidade mínima do vento de 7 a 8 metros por segundo (m/s) [12]. Segundo a Organização Mundial de Meteorologia, apenas 13% da superfície da terra possui ventos soprando a uma velocidade média igual ou superior a 7 m/s, a uma altura de 50 m como indica a **Tabela 1** [2].

Tabela 1. Distribuição da área de cada continente segundo a velocidade do vento

Fonte: [12]

Região/Continente	Velocidade do Vento (m/s) a 50 metros de Altura					
	6,4 a 7,0		7,0 a 7,5		7,5 a 11,9	
	(10 ³ km ³)	(%)	(10 ³ km ³)	(%)	(10 ³ km ³)	(%)
África	3.750	12	3.350	11	200	1
Austrália	850	8	400	4	550	5
América do Norte	2.550	12	1.750	8	3.350	15
América Latina	1.400	8	850	5	950	5
Europa Ocidental	345	8,6	416	10	371	22
Europa Ocidental & ex-URSS	3.377	15	2.260	10	1.146	5
Ásia (excluindo ex-URSS)	1.550	6	450	2	200	5
Mundo	13.650	10	9.550	7	8.350	6

Como descrito nos objetivos deste trabalho, o foco deste estudo é utilizar a variável velocidade do vento para prever o potencial eólico de determinada região para geração de energia e, como já fora visto, a velocidade do vento é fator fundamental neste processo.

A velocidade mínima do vento, necessária para um bom aproveitamento eólico varia de acordo com diversos fatores como: altura, eficiência da turbina, densidade do ar, entre outros. A energia potencial que pode ser extraída do vento, através das turbinas eólicas, é dada pela equação:

$$W = C_p \frac{1}{2} \rho A v^3 \quad (2.1)$$

onde:

- W é a energia potencial do vento em *Watts*;
- C_p é o coeficiente de performance relacionado a energia cinética de saída, depende do modelo da turbina, e a relação entre a velocidade do rotor e a velocidade do vento;
- ρ é a densidade do ar em kg/m^3 ;
- A é a área atravessada pelo vento em m^2 ;
- v é a velocidade do vento em m/s .

A partir da equação 2.1, pode-se concluir que a potência gerada possui uma relação cúbica com a velocidade do vento, ou seja, se a velocidade do vento dobrar, a potência gerada pelo vento nestas condições ficaria oito vezes maior [5].

2.1.4 Turbina eólica

A turbina eólica, também conhecida como aerogerador, é a principal tecnologia utilizada atualmente para extração da energia cinética do vento para transformação em energia elétrica. Este processo ocorre, inicialmente, com a incidência dos ventos sobre as pás giratórias da turbina, convertendo essa energia cinética em energia mecânica de eixo (torque x rotação), a qual é convertida em energia elétrica (tensão x corrente) através de um gerador elétrico [21].

O aerogerador é formado basicamente por três peças fundamentais [15]:

- **pás do rotor:** são basicamente as velas do sistema. Atuam como barreiras para o vento que, ao serem forçadas pelo mesmo, movem-se transferindo parte da energia cinética dos ventos para o rotor;
- **rotor:** eixo da turbina eólica conectado ao cubo do rotor. Quando forçado a girar, faz com que o eixo também gire transferindo a energia mecânica rotacional do rotor para o eixo, que está conectado a um gerador elétrico;

- **gerador:** trata-se de um dispositivo que utiliza a indução eletromagnética para produzir tensão elétrica. Quando o rotor gira o eixo, este gira um conjunto de ímãs que, por sua vez, gera tensão na bobina existente no gerador. Essa tensão induz a circulação de corrente elétrica através das linhas de transmissão para distribuição de energia elétrica.

Essencialmente, existem dois tipos de turbinas eólicas: turbinas de eixo vertical e turbinas de eixo horizontal.

As turbinas eólicas de eixo vertical (VAWT - *Vertical Axis Wind Turbines*) são raras e a única em produção comercial atualmente é a turbina do francês Darrieus.

Montada na posição vertical, perpendicular ao solo, uma VAWT está permanentemente alinhada com o vento, assim, nenhum ajuste se faz necessário quando a direção do vento mudar. Entretanto, ao colidir com a força do vento, as pás não se movem por si só, faz-se necessário um impulso elétrico para dar partida [15].

A turbina eólica de eixo vertical é sustentada por meio de cabos de amarração, dispensando o uso de torres. Com isso o rotor fica em uma elevação menor que as turbinas de eixo horizontal, fazendo com que capte o vento em velocidades mais baixas devido a interferências do solo, como mostra a **Figura 2**. Assim, as VAWTs são consideradas menos eficientes que as turbinas eólicas de eixo horizontal.




Figura 2. Turbina eólica de eixo vertical

Fonte: [15]

As turbinas eólicas de eixo horizontal (HAWT - *Horizontal Axix Wind Turbine*) são montadas horizontalmente, paralelas ao solo. Diferente das VAWTs, as HAWTs precisam se alinhar constantemente com a direção do vento utilizando mecanismos de ajuste. O sistema de ajuste consiste de motores elétricos e caixas de engrenagens que movem o rotor para direita ou para esquerda.

As turbinas são fixadas longe do solo, no topo de torres, cuja elevação permite um melhor aproveitamento da velocidade do vento devido a menor interferência do solo. A **Figura 3** mostra em detalhes uma turbina eólica de eixo horizontal [15].




Figura 3. Turbina eólica de eixo horizontal

Fonte: [15]

2.1.5 Potencial Eólico Brasileiro

No Brasil, estudos apontam um grande potencial eólico indicado por valores extremamente consideráveis, embora, atualmente, ainda haja divergências entre especialistas e instituições no levantamento de dados entimados a cerca deste potencial [10]. Dados de janeiro de 2014 indicam que a capacidade instalada dos parques eólicos em operação no Brasil é de 2.211 megawatts (MW), correspondendo a uma potência 20% maior que àquela indicada no mesmo período em 2013, de 1.841 MW. Já a geração total média dessas usinas saltou de 612 MW em janeiro de 2013 para 763 MW no mesmo período em 2014, significando um aumento de 25% [6]. Os primeiros estudos do potencial eólico brasileiro foram realizados na região nordeste do país, principalmente nos estados de Pernambuco e do Ceará que, com o apoio da ANEEL (Agência Nacional de Energia Elétrica) e do

Ministério da Ciência e Tecnologia (MCT), resultou na publicação em 1988 da primeira versão do Atlas Eólico da Região Nordeste, pelo Centro Brasileiro de Energia Eólica – CBEE, da Universidade Federal de Pernambuco – UFPE [10].

Estima-se que, para 2015, com uma expansão de energia eólica prevista de 6 gigawatts (GW) da capacidade eólica instalada, o Brasil ultrapasse a Alemanha e ocupe a posição de número dois no *ranking* mundial, atrás apenas da China [18].

2.2 Redes Neurais

2.2.1 Introdução

A Rede Neural Artificial (RNA) é um paradigma de processamento de informações, da área de inteligência computacional, inspirado no funcionamento do sistema de processamento de informações biológico, tal como o cérebro humano [22].

O cérebro humano é composto por uma rede de neurônios interligados formando um sistema capaz de processar milhões de informações em paralelo. Mesmo constituído por neurônios individualmente lentos, o cérebro é capaz de processar informações mais rapidamente que o mais rápido computador existente atualmente devido a sua capacidade de processar trilhões de operações simultaneamente [23].

Assim, pode-se definir uma RNA como sendo um sistema adaptativo constituído de unidades de processamento interconectadas, chamadas de neurônios, os quais estão organizados em: camada de entrada e outra de saída, podendo haver ou não uma ou mais camadas intermediárias entre elas, também conhecidas como camada escondida [23].

2.2.2 Neurônio Biológico

Acredita-se que o cérebro humano é composto por cerca de 10 bilhões de neurônios interconectados, capazes de processar milhões de informações simultaneamente [23].

Unidade funcional do sistema nervoso, o neurônio, ilustrado na **Figura 4**, é uma célula excitável responsável por transmitir informações pelo corpo humano,

mesmo a um metro de distância, através de pequenos impulsos elétricos. Essa comunicação é direcional, ou seja, possui um sentido de entrada e saída em cada neurônio [17]. Assim, cada unidade funcional recebe os sinais através dos dendritos – ramificações do corpo celular, ou soma – e transmitem o impulso elétrico por um prolongamento chamado axônio.




Figura 4. Neurônio Biológico

Fonte: [17]

A transmissão da informação entre dois neurônios ocorre através das ligações sinápticas, entre as terminações nervosas do axônio de um neurônio e os dendritos do neurônio seguinte, sempre nesse sentido.

Um detalhe importante do funcionamento desta unidade de processamento do sistema nervoso humano é que a informação só é passada de um neurônio para outro caso o impulso nervoso ultrapasse o limiar excitatório do neurônio que recebe o sinal (Lei do Tudo ou Nada). Logo, se a intensidade do estímulo for pequeno demais a ponto de não ultrapassar o limiar de excitação do neurônio, nada ocorrerá, porém, caso esse limiar seja ultrapassado, o neurônio responderá a este impulso de maneira que o potencial de ação deste neurônio independe da intensidade deste impulso.

2.2.3 Neurônio Artificial

Um neurônio artificial é uma representação matemática concebida como um modelo de neurônio biológico.

A primeira proposta de um modelo matemático para representação de um neurônio biológico foi feita por McCulloch e Pitts em 1943 [23]. O modelo proposto é bastante simples e procura representar a estrutura e funcionalidades de um neurônio biológico através de um conjunto de entradas, uma regra de propagação e uma ou mais saídas, que correspondem, respectivamente, aos dendritos, soma, ou corpo celular, e as ramificações das extremidades do axônio. A emissão de sinal através desta representação de neurônio está baseada em um limiar, obedecendo a Lei do Tudo ou Nada do neurônio biológico [23]. Na **Figura 5**, pode-se observar a representação neural proposta por McCulloch e Pitts.

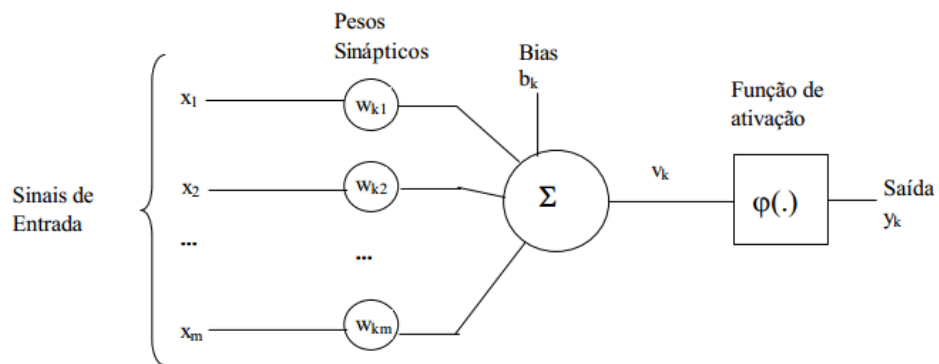


Figura 5. Modelo matemático do neurônio proposto por McCulloch e Pitts

[Fonte: retirada do site: <http://www.scielo.br/img/revistas/ca/v21n4/a03fig17.gif>]

Cada entrada, representada por x_i , é multiplicada pelo seu respectivo peso sináptico w_{ki} , que representa o grau de importância da entrada para o neurônio. Em outras palavras, quanto maior o peso, mais relevante é a entrada para o neurônio. O somatório de todos produtos entrada x peso ($x_i \cdot w_{ki}$), dado pela equação 2.2, gera um resultado v_k que será o parâmetro da função de ativação $\varphi(\cdot)$. Esta função retorna o valor de saída do neurônio.

$$v_k = \sum_{i=0}^m x_i \cdot w_{ki} \quad (2.2)$$

Desta forma, os valores dos pesos atribuídos às entradas do neurônio devem estar configurados de forma que o(s) resultado(s) obtido(s) na(s) saída(s) do neurônio se aproximem ao máximo do resultado desejado [13].

As redes neurais artificiais podem ser utilizadas para solucionar problemas complexos devido, principalmente, a sua grande capacidade de aprendizagem, adquirida com o treinamento da rede, e a obtenção de generalizações, que permitem que uma determinada rede seja capaz de resolver qualquer problema a partir de um determinado momento do treinamento. O treinamento, por sua vez, trata-se de um conjunto de regras aplicadas às RNAs a fim de atingir um aumento na sua capacidade de generalização. Esta generalização é atingida ao realizar-se os ajustes necessários dos pesos das entradas da rede durante o treinamento.

Os primeiros modelos de RNAs propostos foram o Perceptron, apresentado por Frank Rosenblatt em 1957, e o Adaline, apresentado por Widrow e Hoff em 1960 [23]. O Perceptron trabalhava com saídas discretas, solucionando problemas linearmente separáveis enquanto o Adaline trabalhava com saídas no espaço contínuo.

Assim, outras arquiteturas de RNAs foram sendo propostas dentre elas as que são objetos de estudo neste trabalho: *Multi-Layer Perceptron* (MLP) e a *Radial Basis Function Network* (RBFN).

2.3 Multi-layer Perceptron

As redes *Multi-layer Perceptron* (MLP) podem ser consideradas generalizações do *Perceptron*, pois possuem uma arquitetura semelhante, formada por camadas de entrada e saída. A diferença entre essas duas arquiteturas está na existência de pelo menos uma camada intermediária – camada escondida – entre as camadas de entrada e saída na rede MLP.

A camada de entrada desta rede é composta pelos neurônios que representam as variáveis de entrada da estrutura, consideradas entrada do problema. A camada escondida, ou camadas escondidas, pois pode haver mais de uma, é a parte da arquitetura responsável pela não linearidade da rede, tornando-as capazes de resolver problemas reais. Diferentemente das redes Perceptron e

Adaline, cuja principal atuação é na resolução de problemas linearmente separáveis, as redes MLP atuam em problemas não lineares e isso se deve inserção da camada intermediária nesta estrutura composta por neurônios cujas funções de ativação são, em geral, sigmoidal: logística ou a tangente hiperbólica. Assim, problemas do mundo real, considerados problemas linearmente não separáveis, podem ser solucionados pelas redes Perceptron de múltiplas camadas.

A camada de saída da MLP é contituída dos neurônios que representam a resposta da rede em face do problema apresentado. Em geral, essa variável é a que se deseja prever. Nesta camada, os neurônios podem apresentar uma função de ativação linear, além da sigmoidal.

Na **Figura 6**, pode-se observar uma rede MLP de três camadas.




Figura 6. Multi-layer Perceptron de três camadas

[Fonte: Retirada do site: <http://www.mdpi.com/>]

A rede MLP é do tipo *feedforward*, ou seja, o fluxo de operação da rede ocorre em uma única direção, sempre no sentido da camada de entrada para a camada de saída.

Assim como nas estruturas Perceptron e Adaline, a rede MLP passa por uma fase de treinamento, onde, a fim de obter uma configuração de pesos ótimos, a rede deve ajustar seus pesos de forma que se obtenha o melhor resultado nos neurônios

da camada de saída. É nesta etapa que ocorre o processo de aprendizagem, a fase que se busca uma generalização da rede.

Existem três tipos de aprendizado: supervisionado, não supervisionado e por reforço. As arquiteturas MLP utilizam a forma de aprendizado supervisionado, aquela que onde há o papel do “professor”, que já conhece previamente os resultados esperados em cada momento do treinamento da rede. Assim, é possível calcular o erro na saída da rede e corrigir os pesos de forma que essa nova configuração tente retornar valores mais próximos do esperado. Nas redes de múltiplas camadas, pelo fato de possuir uma ou mais camadas intermediárias, este processo torna-se mais complexo já que não se conhece o erro nas camadas escondidas [4].

Para o ajuste dos pesos durante a fase de aprendizagem, utiliza-se algoritmos de otimização, sendo o algoritmo *Backpropagation* o mais tradicionalmente utilizado.

2.3.1 Algoritmo *Backpropagation*

Com origem nos trabalhos de Paul Werbos, em 1974, o *Backpropagation* ganhou popularidade apenas nos anos 80 com os trabalhos de Geoffrey Hinton, David Rumelhart e Ronald Willams [23].

Como característica principal, o algoritmo realiza o ajuste dos pesos na rede Perceptron de múltiplas camadas de maneira recursiva, visto que em uma MLP não se conhece o erro – diferença entre o resultado desejado e o quadrado do resultado obtido na saída do neurônio – dos neurônios das camadas escondidas.

A aprendizagem da rede com o uso do *Backpropagation* ocorre em duas fases: fase *forward* e a fase *backward*, onde ocorre a retropropagação do erro para ajuste dos pesos da rede. Durante a primeira fase, os sinais são propagados no sentido progressivo, ou seja, da camada de entrada da rede para a camada de saída. Ao fim desta etapa, o erro é calculado e os pesos permanecem fixos. Na segunda fase, os sinais se propagam no sentido inverso e os pesos são ajustados pela regra delta generalizada, como mostra a equação:

$$W_{i,j}^m(t+1) = W_{i,j}^m(t) + \alpha \delta_i^m f^{m-1}(\text{net}_j^{m-1}) + \beta \Delta W_{i,j}^m(t-1) \quad (2.3)$$

onde:

- $W_{i,j}^m(t + 1)$ é o novo valor atribuído ao i-ésimo peso do neurônio j;
- $W_{i,j}^m(t)$ é o valor do i-ésimo peso do neurônio j no instante t;
- α é a taxa de aprendizagem;
- δ_i^m refere-se a sensibilidade do neurônio j ao qual está atribuído o peso em questão ;
- β é o momento.

Para o cálculo da sensibilidade têm-se duas situações: quando o neurônio de índice j está na camada de saída, equação 2.4, e quando o neurônio não está presente na camada de saída, equação 2.5.

$$\delta_i^m = (d_i - y_i)f'(net_i) \quad (2.4)$$

Sendo d_i e y_i o valor de saída desejado e o valor de saída encontrado, respectivamente, e $f'(net_i)$ é a derivada da função de ativação da camada de saída [1].

$$\delta_j^{m-1} = f'^{m-1}(net_j^{m-1}) \sum_{i=l}^N w_{i,j}^m \delta_i^m \quad (2.5)$$

onde δ_i^m refere-se a sensibilidade propagada pelo i-ésimo neurônio cuja camada está imediatamente a frente, $w_{i,j}^m$ é o peso j do neurônio i e N é o número de neurônios na camada [1].

2.3.2 Critério de Parada

No processo de treinamento da rede MLP, um conjunto de padrões é exibido à RNA por um determinado número de ciclos ou épocas do treinamento. A cada ciclo, os pesos da rede podem ser modificados a fim de encontrar o resultado ótimo, a generalização da rede. Atingir a generalização da rede é uma tarefa relativamente difícil, pois a definição do momento ideal de parada não é simples. Uma escolha inadequada para a parada do treinamento pode gerar dois problemas: *overfitting*, quando a rede é treinada em demasia, fazendo com que ela decore os padrões, e conseqüentemente, perca sua capacidade de generalização, e quando a rede é treinada menos que o necessário, fazendo com que a RNA não seja capaz de aprender, ou generalizar, o suficiente.

Assim, um dos critérios utilizados nos treinamentos das redes neurais artificiais para determinar o momento de encerrar o aprendizado é usando a técnica da validação cruzada. Para isso, divide-se o conjunto de padrões em três partes: treinamento, validação e testes.

Depois de cada ciclo, a rede treinada é testada utilizando para isso o conjunto de validação cruzada, aplicando-se um conjunto de padrões nunca vistos pela rede até o momento a fim de verificar a diferença entre a saída calculada e a saída desejada. Como o conjunto de validações cruzadas nunca terá seus pesos ajustados, os mesmos sempre se mostrarão como novidades para a rede. Dessa forma, enquanto o erro da validação cruzada continuar a diminuir, a rede continua generalizando.

A partir do momento que o erro de validação cruzada começar a aumentar ao passo que o erro do treinamento continua a diminuir, a rede pode estar decorando os padrões e é hora de encerrar o treinamento. Após o encerramento do aprendizado da rede, submete-se a RNA a um conjunto de testes para avaliação de seu desempenho.

A **Figura 7** mostra o momento de parada do treinamento da rede.




Figura 7. Ponto de parada do treinamento utilizando a validação cruzada

Fonte: [19]

2.4 Radial Basis Function Network

As redes *Radial Basis Function* (RBF) surgiram em 1988 como uma alternativa às redes perceptron de múltiplas camadas [23]. A sua organização estrutural é semelhante à MLP, composta por: uma camada de entrada, com neurônios que representam as variáveis de entrada do sistema, uma camada escondida e uma camada de saída. A diferença entre estas arquiteturas está no fato de a RBF possuir apenas uma camada intermediária (camada escondida), enquanto a MLP pode possuir uma ou mais.

Nas RBFs, os neurônios da camada escondida possuem apenas funções de base radial (funções não lineares) como funções de ativação, permitindo a resolução de problemas linearmente não separáveis, assim como as redes *perceptron* de múltiplas camadas.

Neste tipo de rede observa-se que a transformação da camada de entrada para a camada intermediária ocorre de forma não linear, já a transformação da camada oculta para a camada de saída é um processo linear [23][12].

2.4.1 Estrutura da Rede RBF

A **Figura 8** ilustra uma rede RBF com entradas de X_1, \dots, X_n e uma saída \hat{y} . Como já fora dito, a função de ativação dos neurônios da camada intermediária são funções de base radial. Uma função de base radial é aquela cujo valor depende da distância entre a entrada e o centro da função, sendo este valor máximo quando a

distância for zero. Portanto, na entrada de cada neurônio, a distância entre o centro do neurônio e o vetor de entradas é calculada [24].




Figura 8. Estrutura da Rede RBF

[Fonte: Retirada do site: <http://reference.wolfram.com/>]

A saída da rede \hat{y} é uma combinação linear de funções de base radial, dada pela equação a seguir:

$$\hat{y}(X) = \sum_{j=1}^n w_{nj} \phi_j(X) \quad (2.6)$$

onde $\hat{y}(X)$ é a saída da rede, w_{nj} é o peso n do j -ésimo neurônio da camada escondida e $\phi_j(X)$ é a função de ativação gaussiana do j -ésimo neurônio da camada escondida.

A função de ativação dos neurônios de saída mais utilizada é a Gaussiana [19], descrita na equação 2.7.

$$\phi_j(X) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (2.7)$$

onde:

- X são os valores de entrada da rede;
- $x - \mu_j$ são o centro e a dispersão da i -ésima função de base radial.

Esta função apresenta seu valor máximo no centro e a medida que se afasta dele, tem seu valor diminuído. O ajuste dos resultados obtidos da função pode ser realizado modificando-se o seu *spread* (dispersão). Um *spread* com valores altos faz com que a aproximação da função seja mais suave, já um *spread* com valores mais baixos faz com que a rede necessite de menos neurônios para aproximar uma função que varia seus resultados rapidamente, porém necessita de mais neurônios para aproximar uma função de curva mais suave, causando uma possível perda de generalização da rede.

2.4.2 Treinamento da Rede RBF

Nas redes RBF, dentre todas as abordagens de treinamento existentes, a forma de treinamento mais utilizada é o chamado treinamento híbrido, por utilizar tanto a forma de aprendizagem não supervisionada quanto a forma supervisionada [23].

O treinamento desta rede se resume na determinação dos parâmetros das funções de base radial (aprendizagem não supervisionada com utilização de funções não lineares) e, uma vez que estes parâmetros são considerados fixos, o treinamento da rede passa para a etapa de ajustes de pesos que ligam a camada oculta à camada de saída da rede (aprendizagem supervisionada com utilização de funções lineares). Desta forma, assim que os parâmetros das funções de bases radiais estejam definidos, o ajuste dos pesos funciona de maneira semelhante à rede ADALINE.

Na fase de aprendizagem não supervisionada do treinamento, os centros das funções de base radial podem ser definidos por algoritmos de *clusterização*, como o algoritmo *k*-médias, cujo objetivo é encontrar um conjunto de K centros μ_i ($i = 1, 2, \dots, K$) das funções de base radial em função do conjunto de exemplo de entrada x_j , sendo $j = 1, 2, \dots, N$ [23].

O algoritmo divide o conjunto de exemplos de entrada em K subconjuntos S_i contendo, cada um deles, N_i exemplos com o objetivo de minimizar a função:

$$F = \sum_{i=1}^K \sum_{j \in S_i} \|x_j - \mu_i\|^2 \quad (2.8)$$

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

$$\mu_i = \frac{1}{N_i} \sum_{j \in S_i} x_j \quad (2.9)$$

Assim, inicialmente, os exemplos de entrada são distribuídos aleatoriamente nos subconjuntos de K e então seus respectivos centros são calculados. Posteriormente, esses exemplos são redistribuídos de acordo com sua maior proximidade com centros anteriormente calculados [23]. Este processo é repetido até que não ocorram mais mudanças de exemplos entre os subconjuntos de K.

A fase de aprendizagem supervisionada do treinamento ocorre logo após a definição dos parâmetros das funções de base radial, ocorrida na fase não supervisionada. Nesta segunda etapa do treinamento, os pesos que ligam a camada escondida à camada de saída da rede são ajustados através de um combinador linear que atua na camada de saída para que as ativações das funções de base radial gerem uma saída linear, aos moldes dos dados de entrada.

A saída obtida será verificada de maneira semelhante à uma rede tradicional, com a utilização de uma função objetivo como, por exemplo, o erro médio quadrático (EQM) e utilizando, como critério de parada, a validação cruzada.

Capítulo 3

Metodologia

Este Capítulo apresenta como serão aplicadas as teorias apresentadas no Capítulo anterior para a realização do estudo proposto neste trabalho.

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 fiscalização da ANEEL [1][5][19].

Por se tratar de informações estratégicas para os responsáveis pela produção dos dados, os nomes oficiais dos parques eólicos serão omitidos e um codinome será utilizado para representar cada um dos parques: *Parque I* e *Parque B*. Os dados da velocidade média coletadas, variável usada para estudo neste trabalho, são diários e foram medidas a cada 30 minutos, no período que vai de 01 de Dezembro de 2011 ao dia 18 de Julho de 2012 para o Parque I e no período que vai de 01 de Abril de 2010 ao dia 01 de Abril de 2011 para o Parque B.

Esta base apresenta alguns valores com falhas, representados por -999, em alguns períodos do dia. A fim de evitar uma perda na linearidade dos dados, esses valores que representam falhas foram substituídos pela média entre os dois valores, válidos, anteriores e os dois valores, válidos, posteriores, para um mesmo período que o do dado falho.

A seguir pode-se observar uma amostra desses dados.

Tabela 2. Amostra de dados relativos ao Parque I

Dia	Mês	Ano	Hora	Minuto	Segundo	Velocidade Média
7	12	2011	14	29	56	14,22027
7	12	2011	14	59	56	15,01151
7	12	2011	15	29	56	-999
7	12	2011	15	59	56	13,69891

3.2 Pré-processamento dos Dados

3.2.1 Normalização dos Dados

Após substituição de todos os valores da base de dados que representaram falhas durante o processo de coleta das informações, os dados que compreendem o período relativo a este estudo, informado na Seção 3.1, são submetidos, em um primeiro momento, à normalização.

A normalização dos dados é aplicada para melhorar a distribuição dos dados durante o treinamento da rede neural, fazendo com que a RNA trate os dados com a mesma ênfase, ou seja, evita que os valores altos influenciem em demasia as operações da rede e que os valores mais baixos passem despercebidos.

O processo de normalização faz com que os dados respeitem os limites das funções de ativação empregadas na camada de saída, cujo intervalo, normalmente, varia entre 0 e 1. No entanto o intervalo usado neste trabalho foi de 0.15 a 0.85, devido a baixa performance do algoritmo *backpropagation* quando os valores se aproximam muito de zero [23].

A normalização é dada por:

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

onde:

- y é o valor normalizado;
- a e b são os valores mínimo e máximo do intervalo de normalização, que correspondem a 0.15 e 0.85 respectivamente;
- x_{min} e x_{max} são, respectivamente, o valor mínimo e o valor máximo das variáveis de entrada.

3.2.2 Defasagem dos Dados

O modelo de previsão trabalha prevendo valores baseado em observações de dados anteriores. Assim, realizar-se-á uma defasagem nos dados de velocidade média, variável de estudo neste trabalho, a fim de ter como entradas da rede os dados em um instante de tempo anterior ao dado atual, para previsão deste dado em um instante futuro.

A defasagem constitui um processo que torna um dado medido em uma época t , ocupando uma posição i do vetor de dados, presente na época $t - 1$, ocupando a posição $i + 1$ do vetor. A **Tabela 3** mostra o posicionamento dos dados mediante defasagem de um vetor $d = \{0, 1, 2, 3, 4, 5\}$.

Tabela 3. Exemplo de defasagem de dados
[Fonte: Elaboração Própria]

$t - 3$	$t - 2$	$t - 1$	t
			0
		0	1
	0	1	2
0	1	2	3
1	2	3	4
2	3	4	5

Após realizado o processo, os dados estão normalizados e defasados e o próximo passo será a definição das variáveis de entrada da rede.

3.3 Definição das Variáveis de Entrada da Rede

A quantidade de neurônios na camada de entrada e de saída é definida de acordo com o problema a ser solucionado e isso depende do conhecimento do modelador da rede a cerca dos dados que estão sendo trabalhados.

Em uma rede neural, deve-se ter o cuidado ao definir a quantidade de neurônios na camada de entrada, pois uma rede com um número grande de neurônios aumenta a sua complexidade e retarda o processo de treinamento [23].

Neste trabalho, será utilizado apenas a variável velocidade média do vento e a quantidade de neurônios na camada de entrada da rede será definida através da técnica de correlação linear. O termo correlação significa a relação entre dois valores e em estatística é utilizado para verificar o grau de influência que um valor exerce sobre o outro.

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

$$C = \frac{\sum \frac{(x - \bar{x})(y - \bar{y})}{SxSy}}{n - 1} \quad (3.2)$$

onde:

- C é a correlação linear;
- x é o valor da variável x ;
- y é o valor da variável y ;
- \bar{x} é o valor médio de x ;
- \bar{y} é o valor médio de y ;
- Sx representa a soma dos valores de x ($Sx = \sum x$);
- Sy representa a soma dos valores de y ($Sy = \sum y$);
- n é o tamanho da amostra de dados.

A correlação linear tem seus valores compreendidos no intervalo de -1 a 1. Se os valores forem muito próximos de zero, significa que as variáveis não estão

relacionadas, caso a correlação seja positiva, significa que as variáveis movem-se juntas e a correlação fica mais intensa quando se aproxima de 1. Caso a correlação seja negativa, indica que as variáveis seguem em direções opostas e a ligação fica mais forte quando se aproxima de -1 [1].

O quadrado da correlação é conhecido como coeficiente de determinação e tem seu valor sempre positivo, variando entre 0 (zero) e 1.

A **Tabela 4** mostra as correlações lineares, para os dados do Parque I, 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, $t - 210$ minutos, $t - 240$ minutos, $t - 270$ minutos, $t - 300$ minutos e $t - 330$ minutos.

Tabela 4. Correlação linear entre a velocidade do vento e a mesma variável em tempos anteriores

[Fonte: Elaboração Própria]

Correlação	Valor
t e $t - 30$ minutos	0,948987
t e $t - 60$ minutos	0,889826
t e $t - 90$ minutos	0,833855
t e $t - 120$ minutos	0,779624
t e $t - 150$ minutos	0,725648
t e $t - 180$ minutos	0,673844
t e $t - 210$ minutos	0,625785
t e $t - 240$ minutos	0,580462
t e $t - 270$ minutos	0,539612
t e $t - 300$ minutos	0,501562
t e $t - 330$ minutos	0,469878

Assim, as as variáveis de entrada selecionadas para serem submetidas aos experimentos deste trabalharam foram:

- Velocidade média do vento no tempo $t - 30$ minutos;
- Velocidade média do vento no tempo $t - 60$ minutos;
- Velocidade média do vento no tempo $t - 90$ minutos;
- Velocidade média do vento no tempo $t - 120$ minutos;

- Velocidade média do vento no tempo $t - 150$ minutos;
- Velocidade média do vento no tempo $t - 210$ minutos;
- Velocidade média do vento no tempo $t - 240$ minutos;
- Velocidade média do vento no tempo $t - 270$ minutos;
- Velocidade média do vento no tempo $t - 300$ minutos.

Neste trabalho, serão realizadas previsões de 1h à frente, ou seja, a camada de saída das redes será representada por dois neurônios, ou seja, dois valores para a velocidade média do vento em $t + 30$ minutos e $t + 60$ minutos.

3.4 Arquiteturas de Redes Neurais Utilizadas Na Predição da Velocidade Média do Vento

Nesta Seção, serão mostradas as configurações das redes arquiteturas utilizadas para realização dos experimentos. Todas as simulações com as redes neurais, MLP e RBF, foram realizadas no ambiente do MATLAB R2011a.

3.4.1 Rede *Multilayer Perceptron*

Para utilização da MLP, deve-se fazer o ajustes dos seus parâmetros. A seguir, segue a lista de parâmetros que foram configurados para realização dos experimentos neste trabalho:

- Quantidade de neurônios na camada de entrada;
- Quantidade de neurônios na camada de saída;
- Função de cálculo do erro;
- Número de camadas intermediárias e a quantidade de neurônios em cada uma delas;
- Função de ativação;
- Critério de parada;
- Taxa de aprendizado;
- Momento.

A quantidade de neurônios na camada de entrada foi definida pelo estudo da correlação linear descrito na Seção 3.3, ou seja, 9 neurônios na camada de entrada da rede que representam a variável velocidade média do vento em tempos anteriores a t .

Para a camada de saída, foi estabelecida a quantidade de 2 neurônios, ou seja, previsão de 1 hora a frente (instantes $t + 30 \text{ minutos}$ e $t + 60 \text{ minutos}$).

A função de cálculo de erro utilizada nas simulações foi o Erro Médio Quadrático (EMQ). Por definição, o erro médio quadrático é a soma dos quadrados da diferença entre o valor desejado e o valor obtido, de cada saída da rede, como mostra a equação a seguir:

$$EMQ = \frac{\sum (d - y)^2}{N} \quad (3.3)$$

onde d e y são, respectivamente, o valor desejado e o valor obtido de rede e N é a quantidade de neurônios na camada de saída.

Para os experimentos realizados neste trabalho, foi utilizada apenas uma camada escondida e a quantidade de neurônios foi definida empiricamente. A MLP foi submetida a 100 treinamentos com quantidades diferentes de neurônios em cada uma delas, sendo esta quantidade incrementada em um neurônio nos treinamentos de 1 a 30 e em cinco neurônios nos treinamentos de 30 a 100. Assim, aquele que apresentou o melhor desempenho, ou seja, menor erro médio quadrático, definiu a quantidade de neurônios na camada escondida.

Para o Parque I, a melhor performance obtida ($EMQ = 0,00267941$) é a da rede que apresentou 9 neurônios na camada escondida, como mostra o gráfico de desempenho por número de neurônios na camada escondida na **Figura 9**.

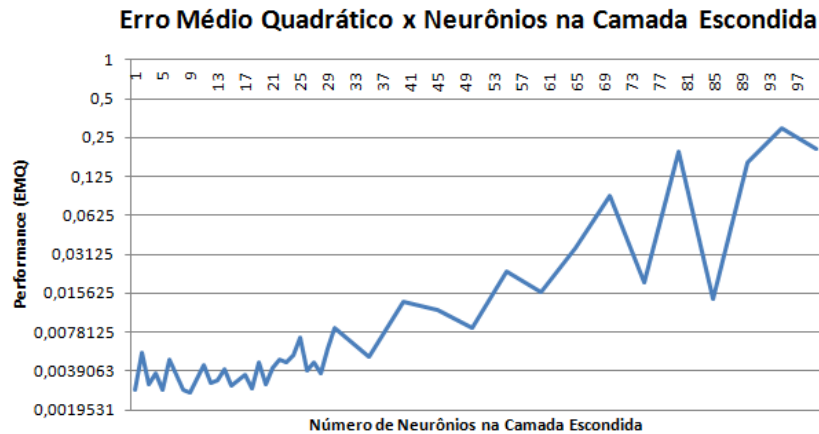


Figura 9. EMQ Médio por número de neurônios na camada escondida para o parque I
[Fonte: Elaboração Própria]

Para o Parque B, a rede de melhor desempenho (EMQ = 0,00276928) possui em sua camada intermediária, também, 9 neurônios, como mostra a **Figura 10.**




Figura 10. EMQ Médio por número de neurônios na camada escondida para o parque B
[Fonte: Elaboração Própria]

Para a MLP, o algoritmo utilizado é o *backpropagation* e a função de ativação escolhida para os neurônios da camada escondida foi a sigmoide logística, definida por:

$$y = \frac{1}{1 + e^{-net_i}} \quad (3.4)$$

onde:

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

Para a camada de saída será utilizada a função linear.

O critério de parada utilizado é o de validação cruzada, descrita na Seção 2.3.2 deste documento. Para isso, o conjunto de dados a serem utilizados no treinamento foi dividido em 50% para treinamento, 25% para validação e 25% para os testes.

Vários testes foram realizados para a definição da taxa de aprendizado e do momento. O teste que apresentou o melhor resultado apresentava em sua rede um valor de taxa de aprendizado de 0,4 e um valor de momento de 0,6.

3.4.2 Rede *Radial Basis Function*

Assim como a MLP, a rede RBF também necessita de alguns ajustes de parâmetros para sua utilização. A seguir, pode-se observar a lista desses parâmetros:

- Número de neurônios na camada de entrada;
- Número de neurônios na camada de saída;
- Número de neurônios na camada escondida;
- Função de ativação;
- Critérios de parada;

- *Spread*.

A fim de fazer uma comparação entre as arquiteturas da rede MLP e RBF, a quantidade de neurônios na camada de entrada e de saída é igual a quantidade apresentada para a rede MLP, isto é, 9 neurônios para a camada de entrada e 2 neurônios para a camada de saída. Logo, a RBFN também trabalha com previsão da velocidade média do vento 1h a frente.

As RBFNs utilizam funções gaussianas como função de ativação para os neurônios da camada escondida e funções lineares para os neurônios da camada de saída. Na Seção 2.4.1, equação 2.7, pode-se encontrar a definição desta função.

O *spread* é definido empiricamente através da execução da RBFN em um *loop* de 10 iterações tendo seu *spread* variando de 0.1 a 1 e, para cada *spread*, testada uma rede RBF com 10, 25, 50, 100, 200 e 500 neurônios. As *Tabelas 5 e 6* mostram o *spread* e as quantidades de neurônios na camada escondida, utilizados nas simulações dos Parques I e B.

Tabela 5. EMQ de acordo com a relação *Spread* x Neurônios na Camada Escondida para o parque I

<i>spread</i> x Neurônios	10	25	50	100	200	500
0,1	0,006838994	0,004149537	0,003535798	0,002989539	0,002777402	0,002621747
0,2	0,003222622	0,002497988	0,002294675	0,002135376	0,002004828	0,002138061
0,3	0,002484239	0,002100735	0,001992172	0,001965757	0,001955466	0,002226909
0,4	0,00221383	0,00201968	0,0020167	0,001989466	0,002043903	0,002335176
0,5	0,002209638	0,001962459	0,001972071	0,002014029	0,002078655	0,002356246
0,6	0,002079805	0,001968609	0,00196804	0,001987357	0,002067814	0,002496102
0,7	0,002006737	0,001953941	0,001961591	0,002011519	0,002069763	0,002545346
0,8	0,002015229	0,001966829	0,001982316	0,002009029	0,002077874	0,002630642
0,9	0,002010069	0,001972119	0,001998972	0,002035682	0,002089584	0,002418965
1	0,001999273	0,001973385	0,001966502	0,002015576	0,00211835	0,002446676

Tabela 6. EMQ de acordo com a relação *Spread* x Neurônios na Camada Escondida para o parque B

<i>spread</i> x Neurônios	10	25	50	100	200	500
0,1	0,007906962	0,004960281	0,004065379	0,003777774	0,004409618	0,007209836
0,2	0,003341473	0,00271833	0,002443009	0,002400144	0,003023916	0,007138092
0,3	0,002651752	0,002111208	0,002111385	0,002313876	0,003472065	0,014352147
0,4	0,002170679	0,002073302	0,00209505	0,002395023	0,003731764	0,024285464
0,5	0,002168974	0,002006493	0,002062012	0,00244326	0,003649254	0,030317743
0,6	0,002160367	0,002016099	0,002097761	0,002520973	0,004008547	0,044385067
0,7	0,002018217	0,002006512	0,002085096	0,002509446	0,004070019	0,057485493
0,8	0,002049232	0,002028018	0,002098018	0,002489479	0,004203743	0,06079174
0,9	0,002024274	0,002038958	0,002095838	0,002630151	0,004646325	0,058938433
1	0,002018663	0,002030978	0,002083574	0,002429544	0,004518558	0,067287213

Como pode-se observar, para o Parque I, o treinamento da RBF que apresentou o melhor EMQ foi o que utilizou 25 neurônios na camada escondida e o *spread* com o valor 0,7. Para o Parque B, o melhor desempenho da rede ocorreu, também, com 25 neurônios na camada escondida e o *spread* com valor 0,5.

3.4.3 Modelo de Persistência

O modelo de persistência é definido pela equação:

$$y(t) = y(t - i) \tag{3.5}$$

onde $y(t)$ é o valor previsto da velocidade do vento no instante t e $y(t - i)$ é o valor da velocidade do vento em um instante imediatamente anterior.

O modelo de persistência é considerado bastante eficaz para previsões de curta duração e é usado como uma referência a ser batida em estudos de predição de dados de até 6h à frente [3].

3.5 Comparativo e Teste Estatístico

Ao término das simulações, a fim de indicar a melhor arquitetura na previsão de velocidade média do vento para geração de energia eólica, serão aplicados o teste estatístico da Soma dos Postos de Wilcoxon, além de estudos comparativos entre as arquiteturas MLP, RBF e o modelo de Persistência.

3.5.1 Comparação dos Resultados das Arquiteturas MLP e RBF

Após definição das configurações das estruturas das RNAs, as redes foram submetidas a 30 treinamentos [19] cada uma. Os 30 resultados obtidos, de cada rede, tiveram seus EMQs médios calculados e comparados entre si e com o modelo persistência. O objetivo das comparações é verificar qual das arquiteturas obteve o melhor resultado, que é o objetivo central deste trabalho.

3.5.2 Teste Estatístico

Em seguida, será aplicado o teste estatístico da Soma de Postos de Wilcoxon, com o propósito de verificar se as amostras obtidas das redes neurais são estatisticamente distintas e avaliar qual técnica detém o melhor desempenho na previsão da velocidade média do vento.

Esse teste apresenta um conjunto de hipóteses nula e alternativa definido para caracterizar o *p-value* obtido na aplicação desse teste. A hipótese nula diz que o conjunto de dados das topologias comparadas possuem desempenhos estatisticamente iguais. A hipótese alternativa aponta que existe diferença significativa entre as amostras, ou seja, existe diferença de desempenho entre as amostras comparadas.

Capítulo 4

Resultados

Este Capítulo apresenta os resultados obtidos após aplicação das etapas dos métodos descritas no Capítulo anterior.

Os parâmetros das redes MLP e RBF, utilizados nas simulações, foram configurados como descritos nas seções 3.4.1 e 3.4.2, respectivamente.

As configurações iniciais dos pesos das redes neurais utilizadas, foram atribuídas aleatoriamente pelas funções *feedforwardnet*, para a MLP, e *newrb*, para a RBF, durante a fase de treinamento. Ambas fazem parte da biblioteca de redes neurais da ferramenta MATLAB R2001a.

Foram realizadas 30 simulações com cada uma das arquiteturas para previsões 1h à frente, aplicando-se os dados dos Parques I e B. As médias dos EMQs, resultante das saídas das redes, podem ser observadas e comparadas na **Tabela 7**.

Tabela 7. Média do Erro Médio Quadrático dos resultados das 30 simulações
[Fonte: Elaboração Própria]

Modelo	Média das EMQs (30 simulações)	
	Parque I	Parque B
Persistência	1,4367266515	1,4859577067
MLP	3,0568629190	3,1962912150
RBF	2,2750536730	2,4383802300

A partir desses resultados, foi aplicado o teste estatístico da Soma dos Postos de Wilcoxon. Para cada conjunto de EMQs, resultante das saídas das 30 simulações das topologias RBF e MLP, foi realizado o teste não-paramétrico da Soma dos Postos de Wilcoxon a fim de verificar se as amostras são estatisticamente distintas.

O teste estatístico da Soma dos Postos de Wilcoxon foi realizado usando o *software* R, cujo nível de significância é estabelecido com o valor de 0.05. Na **Tabelas 8**, tem-se os resultados obtidos desse teste.

Tabela 8. Resultado do teste estatístico da Soma dos Postos de Wilcoxon

MLP x RBF	
Base de Dados	<i>p-value</i>
Parque I	< 2.2e-16
Parque B	< 2.2e-16

Os resultados do teste para os Parques I e B, indicam que o *p-value* é muito menor que o nível de significância, descartando a hipótese nula do teste da Soma dos Postos de Wilcoxon (Seção 3.5.2), ou seja, as amostras comparadas são estatisticamente distintas. Dessa forma, com apoio dos dados apresentados na **Tabela 7**, pode-se concluir que a rede RBF apresenta um melhor desempenho que a MLP, tanto para o Parque I quanto para o Parque B.

Os resultados das simulações da **Tabela 7** demonstram, também, que o desempenho dos modelos de arquitetura MLP e RBF são inferiores aos apresentados pelo modelo de persistência.

Capítulo 5

Conclusão e Trabalhos Futuros

5.1 Conclusão

Este trabalho teve como objetivo principal realizar a seleção da arquitetura neural, entre duas das várias redes existentes, que obteve o melhor desempenho na predição da velocidade média do vento para 1h à frente. As topologias utilizadas foram a MLP e a RBF. Como o modelo de persistência é considerada referência nas previsões de curta duração, os resultados obtidos foram comparados a ele a fim de verificar a coerência nos resultados obtidos.

A fim de atingir esse objetivo, foram utilizadas funções de redes neurais, para MLP e RBF, existentes na biblioteca do MATLAB R2011a. As bases de dados aplicadas, foram as do Parque I e Parque B cedidas pelo Operador Nacional do Sistema Elétrico. Diante das ferramentas e dos dados, foram feitas diversas simulações para configuração das redes e seus treinamentos.

O teste estatístico aplicado, permitiu a realização da análise de desempenho das topologias utilizadas. Assim, foi possível verificar, através dos resultados obtidos neste estudo de caso, que a rede de base de função radial obteve (RBF) melhor desempenho para a previsão de séries temporais em relação a MLP.

5.2 Trabalhos Futuros

Para trabalhos futuros, propõe-se buscar novas arquiteturas de rede que permitam a resolução de problemas, como os que envolvem séries temporais, ou ainda investigar novas configurações para as redes existentes a fim de alcançar desempenhos melhores que os atingidos atualmente.

Bibliografia

- [1] AGUIAR, B. C. G. de. **Utilizando Reservoir Computing para a Previsão da Velocidade do Vento**, 2012. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Universidade de Pernambuco – UPE, Recife, 2012.
- [2] ANEEL. **Atlas de Energia Elétrica**. Acessado em 21 de setembro de 2014. Disponível em: <<http://www.aneel.gov.br/aplicacoes/atlas>>.
- [3] BEZERRA, Erick C.; DO REGO, Marcos C.O.; BRAGA, ARTHUR P. de S.; LEÃO, S. P. R. **Comparação Entre Modelos Estatísticos e Redes Neurais Usando Persistência como Referência para a Previsão da Velocidade do Vento**. Departamento de Engenharia Elétrica, Universidade Federal do Ceará – UFCE. Disponível em: <<http://www.sba.org.br/rsv/SBAI/SBAI2011/85906.pdf>>.
- [4] BRAGA, A. de P.; PONCE DE LEON, F. d. C. A.; BERNARDA LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.
- [5] CARVALHO DOS SANTOS, H. P. **Previsão da Geração de Potência Eólica Utilizando Redes Neurais Artificiais**, 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Universidade de Pernambuco – UPE, Recife, 2014.
- [6] CCEE. Câmara de Comercialização de Energia Elétrica. **Capacidade instalada para energia eólica cresce 20% no Brasil**. Acessado em 10 de novembro de 2014. Disponível em: <<http://www.ccee.org.br/>>.
- [7] CRESESB. **Atlas do Potencial Eólico Brasileiro**. Acessado em 23 de setembro de 2014. Disponível em: <http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/Atlas%20do%20Potencial%20Eolico%20Brasileiro.pdf>.
- [8] Energia Eólica. **Histórico da energia dos ventos**. Acessado em 14 de outubro de 2014. Disponível em:

- <<https://evolucaoenergiaeolica.wordpress.com/historico-da-energia-dos-ventos>>.
- [9] EXAME. **Energia eólica sopra forte no Brasil; veja estados campeões**. Acessado em 11 de setembro de 2014. Disponível em:
<<http://exame.abril.com.br/economia/noticias/energia-eolica-sopra-com-impeto-no-brasil-veja-quem-lidera>>.
- [10] FELIPE, D. B. L.; LOBATO, E. de M.; QUINTAN, V. C. **Energia eólica: análise sobre o potencial eólico brasileiro**. Acessado em 10 de outubro de 2014. Disponível em:
<<http://www.essentiaeditora.iff.edu.br/index.php/BolsistaDeValor/article/view/1830/1008>>.
- [11] GOLDEMBERG, J. – **Pesquisa e Desenvolvimento na Área de Energia**. Acessado em 15 de Março de 2014. Disponível em: <<http://www.scielo.br>>.
- [12] GRUBB, M. J; MEYER, N. I. **Wind energy: resources, systems and regional strategies**. In: JO-HANSSON, T. B. et. al. Renewable energy: sources for fuels and electricity. Washington, D.C.: Island Press, 1993. p.
- [13] HAYKIN, S. **Redes Neurais: Princípios e Práticas**. Bookman, 2007.
- [14] JURISTO, N.; MORENO, M. **Basics of Software Engineering Experimentation**. Kluwer Academic Publisher, 2001.
- [15] LAYTON, J. **Como funciona a energia eólica**. Acessado em 17 de outubro de 2014. Disponível em:
<http://www.fiec.org.br/artigos/energia/energia_eolica.htm>.
- [16] Ministério do Meio Ambiente. **Energia Eólica**. Acessado em 15 de outubro de 2014. Disponível em:
<<http://www.mma.gov.br/clima/energia/energias-renovaveis/energia-eolica>>.
- [17] O CÉREBRO NOSO DE CADA DIA. **Neurônios**. Acessado em 19 de setembro de 2014. Disponível em:<<http://www.cerebronosso.bio.br/neurnios>>.

- [18] PAC2. Ministério do Planejamento. **Brasil ultrapassa Alemanha em expansão de energia eólica em 2015**. Acessado em 8 de outubro de 2014. Disponível em: <<http://www.pac.gov.br/noticia/22d0c0bd>>.
- [19] PEREIRA FREIRE, L. M. **Utilização de Redes Neurais na Previsão da Velocidade do Vento**, 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Universidade de Pernambuco – UPE, Recife, 2014.
- [20] Portal Brasil. **Fontes hidráulicas geram a maior parte da energia elétrica**. Acessado em 13 de setembro de 2014. Disponível em: <<http://www.brasil.gov.br/infraestrutura/2011/12/fontes-hidraulicas-geram-a-maior-parte-da-energia-eletrica>>.
- [21] SOLAR. **Fontes de Energia Renováveis, Geração Eólica**. Acessado em 17 de outubro de 2014. Departamento de Eletrotécnica - Universidade Federal do Rio de Janeiro. Disponível em: <http://www.solar.coppe.ufrj.br/eolica/eol_txt.htm>.
- [22] STERGIOU, C.; SIGANOS, D. **Neural Networks**. Acessado em 19 de setembro de 2014. Disponível em: <http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html>.
- [23] VALENÇA SILVA, J. M. **Fundamentos das Redes Neurais**. [S.l.]: Livro Rápido, 2011.
- [24] Wolfram Mathematica. **Neural Networks Documentation, Radial Basis Function Networks**. Acessado em 29 de outubro de 2014. Disponível em: <<http://www.cresesb.cepel.br>>.