



PREVISÃO DE GERAÇÃO DE POTÊNCIA EÓLICA UTILIZANDO REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso

Engenharia da Computação

Pedro Henrique Carvalho dos Santos
Orientador: Prof. Dr. Mêuser Jorge Silva Valença



UNIVERSIDADE
DE PERNAMBUCO

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

Pedro Henrique Carvalho dos Santos

**PREVISÃO DA GERAÇÃO DE
POTÊNCIA EÓLICA UTILIZANDO
REDES NEURAIS 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, junho de 2014.

MONOGRAFIA DE FINAL DE CURSO

Avaliação Final (para o presidente da banca)*

No dia 7 de 7 de 2014, às 9:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente PEDRO HENRIQUE CARVALHO DOS SANTOS, orientado pelo professor Mêuser Jorge Silva Valença, sob título Previsão de Geração de Potência Eólica Utilizando Redes Neurais Artificiais, a banca composta pelos professores:

Séregio 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: 9,5 (nove, cinco)

*(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.

Séregio Galdino

SÉREGIO GALDINO

Mêuser Jorge Silva Valença

MÊUSER JORGE SILVA VALENÇA

Dedico esse trabalho à minha família, em especial meu pai Paulo e minha mãe M^a Déia, à meus amigos e a todos que participaram dessa jornada que foi a graduação.

Agradecimentos

Agradeço em primeiro lugar à minha família, em especial aos meus pais, Paulo e Déia, que sempre me apoiaram e me deram todas as condições ao longo de toda minha vida. Às minhas irmãs, Paula, Marcela e Fernanda, cada qual com suas diferentes personalidades, mas apoio sempre presente.

Agradeço à companhia e apoio daqueles que percorreram esse trajeto ao meu lado e se tornaram amigos valiosos, Sergio, Anderson, Wendel, Lopes, Digo, Daniel, Santa Cruz, Mega, Morais, Fernando, Jamersson, Charamba e Marcelo. Obrigado a todos.

Agradeço aos amigos que foram tão importantes ao longo desses anos, em especial àqueles que vem desde antes da universidade: Ninja, Melo, Motta, Wagner, um agradecimento especial a todos vocês.

Agradeço aos professores, por transmitirem não apenas conhecimento, mas também suas experiências de vida, profissionais e pessoais. Um agradecimento especial ao meu orientador, Dr. Mêuser Jorge Silva Valença, por ter aceitado o desafio de me instruir nesses últimos passos da minha graduação.

Por fim, um agradecimento à Vinicius Montenegro, pela amizade de tantos anos e pela ajuda na revisão desse trabalho.

Resumo

A sempre crescente demanda por energia é um desafio enfrentado pela humanidade desde a época da revolução industrial e, embora a eficiência energética seja uma ciência em constante evolução, ainda é necessário aumentar constantemente as matrizes energéticas para atender a demanda. Atualmente, as fontes de energia mais utilizadas estão o carvão, gás natural e petróleo, fontes essas que são não apenas extremamente danosas para o meio ambiente, como também são fontes de origem não renovável. Visando combater os danos causados pela utilização dessas fontes, bem como evitar o esgotamento da produção de energia, governos ao redor do globo vêm cada vez mais estimulando o desenvolvimento de energias renováveis, que utilizam o poder de recursos naturais, como o sol, rios e ventos. A utilização do vento como fonte de energia, embora promissora, necessita de uma boa estratégia para previsão de resultados, visto que a variância do vento causa uma grande variação na potência elétrica produzida, sendo necessário prever resultados futuros para tornar a utilização desse meio de produção um componente estável da malha energética. Este trabalho tem como objetivo utilizar uma *Radial Basis Function Network* e uma *Multi-Layer Perceptron* para prever futuras potências geradas por um parque eólico, a partir de suas potências anteriores e comparar os resultados obtidos com o Modelo de Persistência e analisar qual das redes apresenta o melhor desempenho.

Palavras-Chave: Previsão da potência eólica, MLP, RBFN, Energia eólica

Abstract

The constantly growing power demand is a challenge faced by mankind since the industrial revolution and, despite energy efficiency is being in constant evolution, it is still necessary to constantly increase the power supplies to meet the demand. Currently, the main energy sources are coal, natural gas and oil, sources that are not only extremely dangerous to the environment, but also come from non-renewable sources. Aiming to combat the damages caused by the use of those power sources, as well avoiding a power outage, governments around the globe are increasingly promoting the development of renewable power sources, which harvest the power of natural resources, such as the sun, rivers and the wind. The use of wind as a power supply, although promising, depends on a good forecasting of the results, given the wind's variance can cause a huge difference in the amount of electricity produced, impelling the prediction of future results in order to assure this power generation as a stable component of the power grid. This paper aims to utilize a Radial Basis Function Network and a Multi-Layer Perceptron to predict future powers generation by a wind farm, using its previous power outcomes, and to compare the results with the Persistence Model, and to analyze which of the 2 networks has the best performance.

Keywords: Wind power forecasting, MLP, RBFN, Wind power

Sumário

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	3
Capítulo 2 Fundamentação Teórica	4
2.1 Energia Eólica	4
2.1.1 Vento	4
2.1.2 Turbina Eólica	6
2.1.3 Incentivo à Energia Eólica	9
2.1.4 Energia Eólica no Brasil	11
2.2 Redes Neurais	12
2.2.1 Introdução	12
2.2.2 Multi-Layer Perceptron	14
2.2.3 Radial Basis Function Network	15
2.2.4 Modelo de Persistência	18
2.2.5 Treinamento, testes e validação	18
Capítulo 3 Metodologia	20
3.1 Base de dados	20
3.2 Análise e Tratamento de dados	20
3.2.1 Formatação dos vetores de dados	20
3.2.2 Tratamento dos dados	21

3.3	Prevedo a Potência Gerada com MLP	22
3.4	Prevedo a Potência Gerada com RBFN	26
3.5	Testes e Comparativos	29
Capítulo 4 Resultados		31
Capítulo 5 Considerações Finais		33
5.1	Conclusões	33
5.2	Trabalhos Futuros	33
Bibliografia		35

Índice de Figuras

Figura 1.	Diferença de temperatura entre a costa e o mar ao longo do dia.....	5
Figura 2.	Turbina eólica de eixo vertical	8
Figura 3.	Turbina eólica de eixo vertical instalada além da costa	9
Figura 4.	Estrutura do neurônio biológico	13
Figura 5.	Modelo do TLU	14
Figura 6.	Representação de uma MLP com 3 neurônios na camada escondida	15
Figura 7.	Exemplo de função de base radial	16
Figura 8.	Superposição de funções de base radial	17
Figura 9.	Agrupamentos da MLP (esq.) e da RBFN.....	17
Figura 10.	EMQ Médio por número de neurônios na camada escondida para o Parque B	24
Figura 11.	EMQ Interno por número de neurônios na camada escondida, para o Parque B	24
Figura 12.	EMQ Médio por número de neurônios na camada escondida, para o Parque I	25
Figura 13.	EMQ Médio Interno por número de neurônios na camada escondida, para o Parque I.....	25
Figura 14.	Arquitetura da MLP gerada para o Parque B	26
Figura 15.	Arquitetura da MLP gerada para o Parque I.....	26

Índice de Tabelas

Tabela 1.	Vetor v defasado para utilização no treinamento da RNA	21
Tabela 2.	Spread x Neurônios para o Parque B.....	28
Tabela 3.	Spread x Neurônios para o Parque I.....	28
Tabela 4.	EMA dos resultados previstos	31
Tabela 5.	Resultados do teste de Wilcoxon para o Parque B	32
Tabela 6.	Resultados do teste de Wilcoxon para o Parque I	32

Tabela de Símbolos e Siglas

EMA – Erro Médio Absoluto

EMQ – Erro Médio Quadrático

MLP – Multi-layer Perceptron (Perceptron de Múltiplas Camadas)

RBFN – Radial Basis Function Network (Redes de Função Base Radial)

RNA – Rede Neural Artificial

Capítulo 1

Introdução

Este capítulo expõe a motivação para a realização desse trabalho. Após, serão definidos os objetivos para o trabalho. Por fim, uma explicação detalhada da estrutura dos conteúdos a serem abordados no restante da monografia.

1.1 Motivação

A sempre crescente demanda por energia é um desafio enfrentado pela humanidade desde a época da revolução industrial e, embora a eficiência energética esteja em constante evolução, ainda é necessário aumentar constantemente as matrizes energéticas para atender a demanda crescente, especialmente de países em desenvolvimento, fora da Organização Para a Cooperação e Desenvolvimento Economico (OECD, do inglês *Organisation for Economic Co-operation and Development*) [7]. Atualmente, entre as fontes de energia mais utilizadas estão o carvão, gás natural e petróleo, fontes essas que são não apenas extremamente danosas para o meio ambiente, como também são fontes ditas de origem não renovável, ou seja, são fontes cujo processo de regeneração é muito longo ou inexistente, tornando inviável a utilização sustentável daquele recurso.

Visando combater os danos causados pela utilização dessas fontes, bem como evitar o esgotamento da produção de energia, governos ao redor do globo vêm cada vez mais estimulando o desenvolvimento de energias renováveis, que utilizam o poder de recursos naturais, como o sol, rios e ventos. A utilização do vento como fonte de energia vem se mostrando promissora, crescendo de uma produção de 31,4 bilhões de kilowatthoras (kWh) em 2000 para 341,5 bilhões kWh em 2010, tornando a energia eólica a segunda maior contribuidora para o crescimento da utilização de energia renovável, atrás apenas da energia hidroelétrica [7].

Porém, a energia eólica é uma energia que está atrelada a incertezas, pois depende da direção e velocidade do vento, fatores que são afetados por diversas

variáveis, o que torna grande a variação do vento e afeta diretamente a quantidade de potência elétrica produzida. Esse problema invoca a necessidade de uma boa estratégia para previsão de resultados futuros, para tornar a utilização desse meio de produção um componente estável da malha energética. Existem diversos modelos para realizar tais previsões, inclusive modelos que utilizam técnicas de Redes Neurais Artificiais (RNA). Estes modelos porém, costumam trabalhar com dados relativos ao vento, como velocidade e direção, que podem não estar disponíveis ao produtor de energia.

Este trabalho tem como objetivo utilizar as redes *Radial Basis Function Network (RBFN)* e *Multi-Layer Perceptron (MLP)* para prever futuras potências geradas por um parque eólico, a partir de suas potências anteriores. A escolha da potência anterior é baseado na alta probabilidade de um produtor de energia eólica ter acesso à um medidor capaz de fornecer esses dados de maneira mais confiável que os sensores relativos ao vento. Ao fim, serão comparados os resultados obtidos pela *RBFN* e pela *MLP* com os obtidos pelo Modelo de Persistência para analisar qual das redes apresenta o melhor desempenho.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral desse trabalho é configurar RNAs de arquitetura *MLP* e *RBFN* para previsão de geração de potência elétrica a partir de valores anteriores de potência gerada e avaliar o desempenho dessas, através de uma comparação dos resultados de ambas entre si e com os resultados obtidos pelo Modelo de Persistência.

1.2.2 Objetivos específicos

1. Tratar os dados de entrada.
2. Testar combinações de parâmetros para as redes neurais *MLP* e *RBFN* visando melhorar o desempenho das mesmas.
3. Validar os resultados encontrados.

1.3 Estrutura da monografia

O capítulo 2 apresenta a fundamentação teórica necessária para entendimento do trabalho realizado: energia eólica e redes neurais artificiais, com destaque para as duas arquiteturas escolhidas para esse trabalho, a *MLP* e a *RBFN*. No capítulo 3 é descrita a metodologia definida com o objetivo de alcançar o objetivo geral do projeto, tais como o pré-processamento dos dados da base de dados, a configuração e uso das duas arquiteturas escolhidas. O capítulo 4 apresenta os resultados obtidos após as simulações, apresentando um comparativo entre as arquiteturas. Por fim, o capítulo 5 apresenta um resumo do trabalho final: Resultados encontrados, conclusões obtidas e propostas para trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Esse capítulo provê uma breve explicação do conteúdo base para execução do estudo. A seção 2.1 traz informações sobre a energia eólica, desde considerações sobre o vento, passando pelos equipamentos utilizados para geração de energia elétrica a partir do vento, incentivos à esse tipo de produção e panorama da energia eólica no Brasil. A seção 2.2 discorre sobre Redes Neurais Artificiais, com uma introdução ao tema, apresentações e informações sobre a *Multi-Layer Perceptron* e a *Radial Basis Function Network* e sobre as etapas de treinamento, validação e testes.

2.1 Energia Eólica

2.1.1 Vento

O vento é o responsável direto pela produção de energia eólica. É chamado de vento o deslocamento de massa de ar de uma região de maior pressão para uma região de menor pressão.

Um dos maiores contribuidores para a diferença de pressão entre áreas é a temperatura. Como a superfície da terra não é aquecida de forma regular, pois fatores como ângulo de incidência e composição da superfície (concreto, vegetação, água tem respostas diferentes à insolação) influenciam nas respostas térmicas das mesmas à quantidade de insolação, temos diferenças de temperaturas entre áreas. A medida que o ar sobre uma área esquenta mais que o de uma outra área próxima, ele começa a expandir e a subir, fazendo com que o ar mais frio da área próxima seja deslocado para ocupar o espaço deixado [15]. Esse princípio também é afetado pela topografia do lugar, sendo particularmente notável em regiões costeiras, dada a diferença como a terra e a água reagem à insolação, como observado na Figura 1 [15].

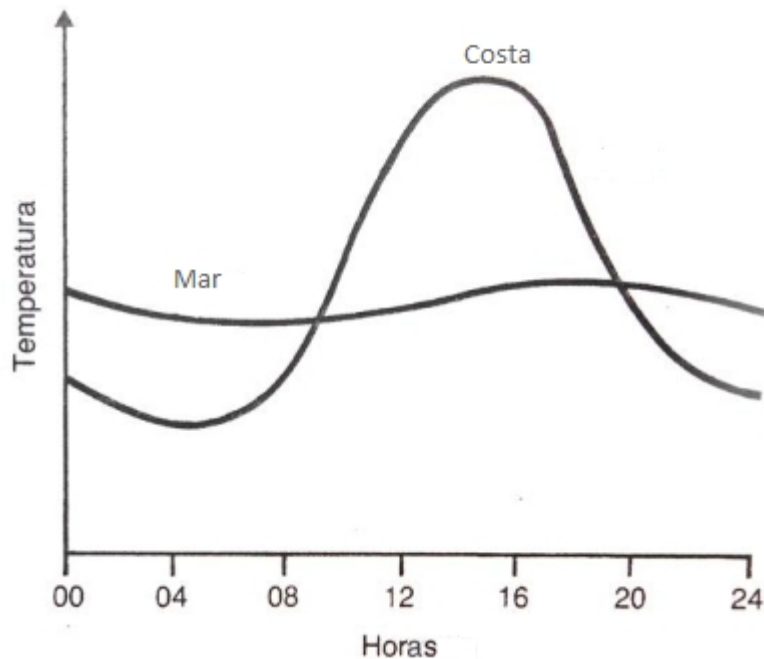


Figura 1. Diferença de temperatura entre a costa e o mar ao longo do dia.

Para a geração de energia eólica, a velocidade do vento é fundamental. A velocidade mínima de operação varia de acordo com um série de fatores, como: altura da turbina, densidade do ar, eficiência da turbina, entre outros. A energia potencial do vento é dada por uma relação cúbica, como visto na Equação 1 – ou seja, ao dobrar a velocidade do vento, teremos uma potência oito vezes maior [12].

$$W = \frac{1}{2} r A v^3$$

Equação 1. Potencial eólico medido numa área de ação

Onde:

- W = energia potencial do vento em *Watts*
- r = densidade do ar (varia de acordo com condições climáticas, como temperatura e umidade, além de diminuir com o aumento da altitude) em kg/m^3
- A = área atravessada pelo vento em m^2
- v = velocidade do vento em m/s

Além da velocidade, outro fator fundamental para a geração de energia a partir do vento é a direção do mesmo. A análise da direção do vento permite definir a

localização de turbinas eólicas num parque eólico a partir da direção predominante [19].

Os vários tipos de variação temporais da velocidade influenciam fortemente no aproveitamento da energia eólica, sendo importante conhecer e distinguir os mesmos [19].

- **Variações Anuais** - Para se obter um bom conhecimento do regime dos ventos não é suficiente basear-se na análise de dados de vento de apenas um ano; o ideal é dispor de dados referentes a vários anos.
- **Variações Sazonais** - O aquecimento não uniforme da superfície terrestre resulta em significativas variações no regime dos ventos, resultando na existência de diferentes estações do ano. Sendo assim, a utilização de médias anuais (ao invés de médias sazonais) pode levar a resultados que se afastam da realidade.
- **Variações Diárias** - Essas variações são importantes para definir o local mais adequado para a instalação do sistema eólico dentro de uma área que já foi escolhida para hospedar um parque eólico. Ao comparar a evolução da velocidade média ao longo do dia percebe-se que há uma significativa variação de um mês para os outros. Com esse tipo de informação pode-se projetar melhor o sistema eólico
- **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.

2.1.2 Turbina Eólica

O potencial do vento vem sendo explorado há muito pelo homem na forma de moinhos. Porém, em 1887, James Blyth construiu aquela que seria a precursora das turbinas eólicas: um moinho de vento, adaptado para gerar energia elétrica [16]. Nesse mesmo ano, o professor Charles F. Brush construiu uma turbina eólica capaz

de gerar 12kW, responsável por carregar 408 baterias presentes no sótão de sua mansão [16].

As turbinas eólicas são dispositivos que convertem a energia cinética do vento em energia elétrica, através de hélices, eixos e um gerador. São compostas por uma torre, hélices, rotores, gerador (converte as rotações dos rotores em energia elétrica) e sistemas de transmissão (a eletricidade deve ser enviada da turbina para uma subestação) [23]. A turbina funciona com a passagem do vento por suas hélices, o que faz com que as mesmas girem, causando o giro do eixo interno, que por sua vez gira outro eixo, conectado ao gerador. As rotações desse último eixo são as que de fato serão convertidas em eletricidade [23].

O precursor das turbinas eólicas modernas foi o cientista dinamarquês Poul la Cour. Motivado pelo desejo de levar energia elétrica às áreas rurais da Dinamarca, ele fundou, em 1903, uma sociedade para estudo do potencial elétrico da energia eólica e, em 1904, essa sociedade iniciou o primeiro curso sobre energia eólica. La Cour também foi o primeiro a descobrir que turbinas com menos pás e rotações maiores eram melhores na tarefa de converter energia do vento em eletricidade [16].

Na década de 20, surgiu uma nova variação da turbina eólica: a turbina de eixo vertical. Inventada pelo francês George Darrieus, essa turbina tem esse nome pois suas pás são conectadas na vertical, ao longo da turbina, como visto na Figura 2. Esse *design* apresenta como vantagens: a dispensa de estar direcionada ao vento (eliminando o uso de mecanismo de detecção da direção do vento e de reposicionamento da turbina), a posição dos componentes responsáveis pela geração de energia elétrica na base da turbina (facilitando a manutenção), a possibilidade de serem agrupadas mais próximas uma da outra, e a capacidade de gerar energia com menos vento (comparado com modelos de eixo horizontal) [4]. A principal desvantagem desses modelos de turbina é o desgaste sofrido a partir da ação do vento, dado o estresse aplicado sobre as pás causado pela grande variação das forças aplicadas sobre elas durante a rotação, o que as torna menos confiáveis que os modelos de eixo horizontal [4].



Figura 2. Turbina eólica de eixo vertical

Em 1931, na cidade de Ialta (localizada na península da Criméia), foi inaugurada a que viria a ser a precursora das turbinas eólicas de eixo horizontal modernas. A turbina, com 30 metros de altura e 3 pás, era capaz de gerar 100kW e de aproveitar efetivamente 32% do potencial eólico total. A evolução das turbinas de eixo horizontal teve no início em 1956, quando Johannes Juul projetou uma turbina de 3 pás capaz de gerar 200kW e dotada do primeiro sistema de freios, baseados em aerodinâmica, tão seguros e eficientes que são adotados em designs até hoje [16]. As turbinas atuais tem capacidade de geração na casa de *MegaWatts* (MW), com capacidade de alimentar milhares de domicílios europeus por ano [8], sendo a turbina com maior capacidade de geração capaz de produzir 10 MW [26].



Figura 3. Turbina eólica de eixo vertical instalada além da costa.

2.1.3 Incentivo à Energia Eólica

Visando incluir ou aumentar a participação de energias renováveis em sua malha energética, diversos países contam com medidas de incentivo, adotadas por seus governos. A busca por fontes de energias tem motivos variados, que vão da preocupação com o meio ambiente, à redução de gases responsáveis pelo efeito estufa à preocupação com futuros acidentes com instalações nucleares, como ocorrido em Fukushima, Japão, à busca por uma menor dependência de combustíveis não renováveis, como é o caso dos combustíveis fósseis e plutônio.

Ocupando o primeiro lugar mundial na geração de energia eólica em 2013 (GWEC, 2014), a China vem buscando diminuir sua dependência de combustíveis fósseis, investindo forte em energias renováveis, sendo a energia eólica um fator essencial nessa estratégia. Um dos primeiros incentivos à esse mercado foi a aprovação, em 2005, de uma lei que obriga as operadoras de energia elétrica a comprarem toda a energia elétrica produzida por fontes renováveis no país, além de promover diversos incentivos financeiros à fontes renováveis, como um fundo para apoiar o desenvolvimento de energia renovável, desconto em empréstimos e impostos para produtores desses modelos de energia [18]. Embora apresente dificuldades em cumprir exigências impostas por essa lei, a China vem se esforçando gradativamente em o fazer [13].

A segunda posição no ranking de produtores de energia eólica é ocupada pela Alemanha [11], país membro da União Europeia (UE), um bloco político-económico formado por 28 países localizados majoritariamente no continente europeu [22]. Os membros da UE se comprometeram à incluir fontes de energia renovável em sua malha energética, de modo que em 2020, 20% da energia consumida na UE seja produzida por essas fontes [2]. A Alemanha alcançou esse patamar em 2011, tendo 20% de sua energia provida por fontes renováveis [21]. No mesmo ano de 2011, o desastre na usina nuclear de Fukushima levou a Alemanha a debater o seu desligamento de energias nucleares e, conseqüentemente, o aumento de fontes renováveis em sua malha energética [21]. O modelo de incentivo adotado na Alemanha é chamado de *feed-in-tariff (FIT)*, onde contratos de longos prazos e acesso à malha energética são oferecidos aos produtores de energia renovável. O valor do kWh é definido normalmente pelo custo de implantação da tecnologia, acompanhado por uma taxa de regressão, onde o valor pago é reajustado para baixo a uma certa frequência, o que leva ao desenvolvimento e investimento em tecnologias mais eficientes, visando reduzir os custos necessários para obter a energia [5]. Recentes reduções nos valores pagos e o aumento da taxa de regressão à novos produtores de energia eólica mostram que a tecnologia já está bem estabelecida na Alemanha, tendo o governo alemão avaliado que seu custo de produção e riscos associados diminuíram consideravelmente nos últimos anos [21]. Esse tipo de incentivo é adotado ainda em diversos outros países.

Os Estados Unidos da América (EUA) utilizam diversos programas baseados em redução, ou até mesmo isenção, de impostos para incentivar a produção de energia eólica, sendo os principais o *Renewable Electricity Production Tax Credit (PTC)* e o *Business Energy Investment Tax Credit (ITC)*. O primeiro consiste num valor de 2.3 centavos de dólares (ajustados à inflação) a ser deduzido dos impostos do operador para cada kWh produzido, por um período de dez anos. O segundo é um incentivo fiscal dado ao operador que deseje instalar uma nova unidade de produção de energia eólica, de 30% do valor da unidade. Deve-se escolher no máximo um dos planos de incentivo para a instalação, não sendo possível acumular ambos [24]. Além desses incentivos, existem diversos outros, voltados para nichos, como o *Residential Renewable Energy Tax Credit*, destinado à usuários domésticos que queiram instalar pequenos sistemas eólicos em suas propriedades ou o

Qualified Energy Conservation Bonds, destinado à entidades isentas de impostos, que não se beneficiariam das deduções praticadas pelas outras formas de incentivo [24].

No Brasil, as medidas tomadas para desestatizar o setor elétrico na década de 90, que posteriormente criariam o mercado livre de energia, tiveram importantes efeitos para a produção da energia eólica. Em 1995, a lei nº 9074/95 permitiu que produtores independentes tivessem acesso à rede de distribuição de energia existente mediante o pagamento de encargos sobre o transporte, e em 1999 esses encargos foram reduzidos para produtores de energia de fontes renováveis. [10]. Porém, os incentivos mais incisivos viram na década de 2000, com o Programa Emergencial de Energia Eólica (PROEÓLICA) em 2001 e o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA) em 2002, ambos do tipo de FiT, como visto no modelo alemão. O PROEÓLICA visava implantar, até o fim de 2013, 1.500MW na malha energética brasileira, garantindo a compra da energia por um período de 15 anos [10]. O PROINFA se trata de um programa de incentivo à diversas fontes de energia renovável, de modo que essas energias seria compradas pela Eletrobrás através de um contrato de 20 anos, contados a partir do início da operação da planta produtora, e despachadas pela malha elétrica nacional, além de contar com a exigência de equipamentos produzidos no Brasil, estimulando a indústria local [10].

2.1.4 Energia Eólica no Brasil

O Brasil teve seus primeiros projetos de geração de energia eólica instalados durante a década de 90, sendo o primeiro instalado em Fernando de Noronha, em 1992, fruto de uma parceria entre a Companhia Energética de Pernambuco (CELPE), o Folkcenter (Dinamarca) e o Grupo de Energia Eólica da UFPE, uma turbina com capacidade de 75kW, que operou até 1995 e reduziu em 8% o consumo do óleo diesel utilizado para geração de energia elétrica na ilha [10].

Outro destaque no histórico da energia eólica brasileira são as implantações de parques eólicos no Ceará, estado que importava quase toda sua energia da Companhia Hidrelétrica do São Francisco (CHESF) e viu no potencial eólico uma saída para reduzir essa dependência. Em 1996, foi instalado o parque eólico do

Mucuripe, com o objetivo de mostrar a viabilidade técnica e econômica da produção eólica no estado. Em 1999, foram instalados dois parques eólicos sobre dunas de areia, a usina eólica de Prainha e a usina eólica da Praia da Taíba, um projeto pioneiro no mundo. Com 10MW instalados, a usina de Prainha era, à época, o maior parque eólico da América Latina. Esses investimentos não só mostravam a viabilidade do vento como fonte de energia, como também trouxeram investimentos importantíssimos, como a transferência de tecnologia de ponta da Enercon à custo zero, além do fornecimento de treinamento à técnicos brasileiros pela mesma [10].

A importância do Nordeste no setor eólico também é refletida pelos estudos realizados na região, que culminaram na publicação do Atlas Eólico da Região Nordeste, um atlas voltado à identificação dos ventos e potenciais eólicos das áreas nordestinas, em 1998. Esse projeto serviria de guia para projetos futuros, como o Atlas Eólico do Paraná, em 1999, até a elaboração do Panorama do Potencial Eólico no Brasil [1].

Embora o valor exato do potencial elétrico varie bastante entre estudos, dado as variações ou ausências de dados e diferentes metodologias aplicadas, o fator em comum entre eles é que o Nordeste tem o maior potencial, enquanto o Norte tem o menor. Segundo o Atlas do Potencial Eólico Brasileiro, o Brasil tem um potencial aproveitável de 143,5GW, sendo 75GW presentes na região Nordeste [6].

2.2 Redes Neurais

2.2.1 Introdução

Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência [3].

A estrutura neural é composta por neurônios, exibida na Figura 4, que são responsáveis por toda a comunicação do sistema nervoso, tendo um papel essencial no funcionamento do corpo, seu comportamento e raciocínio. Embora o cérebro de um mamífero possa ter muitos bilhões de neurônios, uma RNA grande não costuma ter mais do que centenas ou milhares de unidades de processamento.




Figura 4. Estrutura do neurônio biológico.

Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída. Eles se comunicam através de sinapses, uma região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio não são imediatamente retransmitidos, mas sim processados e, caso atinga um dado limiar de ação, o neurônio produz uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de um outro neurônio [3]. É importante conhecer que, caso o limiar excitatório (o limiar de ação utilizado para um neurônio decidir se produzirá uma saída) seja alcançado, o potencial de estimulação do neurônio não aumentará em caso de um estímulo mais intenso [25].

Em 1943, McCulloch e Pitts publicariam o primeiro modelo lógico inspirado no neurônio. Batizado de *Threshold Logic Unit* (TLU), o modelo constituía de uma função de soma das entradas, que são previamente ajustadas de acordo com pesos individuais à cada uma, e cujo resultado era utilizado como entrada numa função binária de ativação, como podemos ver na Figura 5.




Figura 5. Modelo do TLU.

Cada neurônio tem uma influência diferente na saída, devido ao seu peso único. Para que uma rede possa aprender com a experiência, os pesos devem ser reajustados para que a rede possa refletir corretamente quais entradas possuem maior influência na saída. Esse reajuste dos pesos é realizado por um algoritmo de aprendizado, existindo diversos algoritmos do tipo, com características distintas, tanto positivas, quanto negativas. Esse aprendizado pode ser supervisionado (quando a rede conhece a resposta do problema que ela está tentando resolver), não supervisionado (quando a rede não conhece a resposta do problema) e por reforço (quando um crítico externo avalia a resposta fornecida pela rede) e pode ser executado ao fim de cada iteração do treinamento da rede, ou em lote, ao fim do treinamento da rede [3].

O fim dos anos 50 e início dos anos 60 viram o surgimento de duas importantes redes neurais: a *Perceptron* em 1957 e a *Adaline* em 1960. A *Perceptron* foi uma das primeiras RNAs a utilizar uma regra de aprendizado para reajustar os pesos, enquanto a *Adaline* permitiu trabalhar com a saída da rede no espaço contínuo, oposto às saídas binárias ou discretas existentes, de acordo com a função de ativação escolhida. Essas redes foram fundamentais para o estudo das RNAs futuras, como a *Multi-Layer Perceptron* (MLP) e *Radial Basis Neural Network* (RBNN), que veremos em sequência.

2.2.2 Multi-Layer Perceptron

Uma das Redes Neurais Artificiais mais famosas, a *Multi-Layer Perceptron* é uma rede de propagação unidirecional que possui, além das camadas (conjunto de neurônios à executar no mesmo nível de hierarquia) de entrada e de saída, uma ou mais camadas intermediárias, também conhecidas como camadas escondidas.

Essas camadas escondidas fornece à MLP a capacidade resolver problemas não lineares, enquanto as redes *Perceptron* e *Adaline* não possuem esse poder de generalização. Essa diferença ocorre pois as camadas escondidas funcionam como extratoras de características, sendo seus pesos uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema, enquanto à camada de saída tem como objetivo construir o padrão de saída à partir dos resultados fornecidos pelas camadas intermediárias [3].




Figura 6. Representação de uma MLP com 3 neurônios na camada escondida

As redes com camadas escondidas apresentam uma dificuldade no treinamento, visto que o erro nessas camadas não é determinado. Em 1986, Rumelhart, Hinton e Williams desenvolveram um algoritmo de treinamento denominado *backpropagation*, um algoritmo de aprendizado supervisionado, que se provaria eficiente para treinar RNAs com camadas escondidas. Esse algoritmo funciona em dois passos: primeiro, as entradas são fornecidas à rede, que flui normalmente da entrada à saída, passando pelas camadas escondidas. Ao produzir a saída, o resultado é comparado com o resultado esperado, o erro é calculado, e os pesos são ajustados da camada de saída em direção à camada de entrada [3].

2.2.3 Radial Basis Function Network

As *Radial Basis Function Network*, ou Redes de Função de Base Radial (RBFN) são uma abordagem de redes neurais artificiais com origem na área de Análise Numérica com o propósito de aproximação de funções. Foram originalmente desenvolvidas para interpolação de dados em espaços multi dimensionais, e devido

ao seu sucesso neste tipo de operação, podem ser consideradas aproximadores universais de funções [20]. São unidirecionais e possuem uma única camada intermediária, o que as conferem capacidade de resolver problemas não linearmente solucionáveis.

Nas RBFN, a função de ativação dos neurônios da camada intermediária é uma função de base radial. Uma função de base radial é definida como aquela cujo o valor depende da distância da entrada ao centro da função, tendo seu máximo quando essa distância for zero. Normalmente é utilizada a distância euclidiana, definida na Equação 2. Esse função é representada por uma curva simétrica, como a da Figura 7, portanto a direção da distância não importa.

$$DE = \sqrt{\sum_{i=1}^k (X_i - T_i)^2}$$

Equação 2. Norma da distância euclidiana

Onde X_i e T_i são pontos.




Figura 7. Exemplo de função de base radial

Portanto a *RBFN* compõe sua camada intermediária de neurônios que representam funções de base radial com centros diferentes, sendo possível representar a mesma como uma superposição de funções de base radial, como na Figura 8. Para cada valor introduzido na rede, será calculado sua distância à cada neurônio da camada intermediária, sendo a camada de saída responsável por construir o padrão de saída da rede.




Figura 8. Superposição de funções de base radial

No caso de uma *RBFN* decrescente, quanto maior a distância entre a entrada e o centro, menor a ativação do neurônio. Nas redes *MLPs*, a ativação é dada pelo produto escalar entre o vetor de entradas e o vetor de pesos. Basicamente, a *MLP* tenta separar os valores através de hiperplanos, enquanto a *RBFN* utiliza hiper elipsoides (clusters) para separar os dados, como visto na Figura 9 [20].




Figura 9. Agrupamentos da *MLP* (esq.) e da *RBFN*

Ao final deste processo, um combinador linear na camada de saída atua para que as ativações das funções de base radial gerem uma saída linear, aos moldes dos dados de entrada. A generalização ocorre durante a interpolação de pontos não pertencentes ao conjunto de dados de treino, mas que estejam em sua vizinhança em uma superfície multi-dimensional. A saída obtida será então a soma das saídas de cada neurônio da camada escondida, ponderadas pelos seus respectivos pesos sinápticos.

A equação de saída da rede é definida pela Equação 3:

$$Y(n) = \sum_{k=0}^{k-1} w_k \varphi_k$$

Equação 3. Equação de saída da rede

Onde φ_k é o valor da saída do k-ésimo neurônio da camada escondida.

2.2.4 Modelo de Persistência

O Modelo de Persistência, ou Persistência é um modelo onde o valor a ser previsto é o resultado da observação imediatamente anterior, como dado pela equação 4:

$$Y(t) = Y(t - 1)$$

Equação 4. Modelo de Persistência

Esse modelo é utilizado como referência em previsões de curto prazo, onde não ocorrem grandes variações dos dados num curto espaço de tempo.

2.2.5 Treinamento, testes e validação

O treinamento de uma RNA consistem em apresentar diversos padrões repetidamente à rede, visando melhorar sua performance (reduzir a diferença entre o valor esperado e o valor obtido).

Existem diversos métodos de treinamento, cada qual indicado a uma arquitetura de rede ou a um cenário de treinamento. Neste trabalho, será utilizado um algoritmo de treinamento, chamado Algoritmo de Levenberg-Marquardt. Esse algoritmo foi introduzido para treinar redes unidirecionais, como a *MLP*, visando uma melhor taxa de convergência que o método clássico de backpropagation. É considerado um método mais rápido para treinamento que o backpropagation, também convergindo com menos iterações. Entretanto, ele requer mais cálculos por iteração, pois são calculadas as matrizes inversas, o que computacional tem um custo de processamento e memória superiores [14].

Cada método de treinamento tem suas particularidades e seus critérios, porém existem dois fatores que são comuns à eles: *overfitting* e treinamentos incompletos. *Overfitting* é o nome dado ao fenômeno que ocorre quando uma rede começa a

decorar padrões, ao invés de os generalizar. Isso ocorre quando o treinamento é mais logo do que o necessário, o que faz com que a rede comece a repetir os padrões existentes no conjunto de treinamento. Porém, ao ser apresentado um dado inédito à rede, ela não possui uma boa capacidade de generalização, pois sua performance está associada à memorização de padrões, e o resultado sai abaixo do esperado. Já o treinamento incompleto ocorre quando a rede encerra seu treinamento prematuramente, o que a impede de possuir um bom poder de generalização.

Uma solução adotada para resolver esses problemas é a utilização de validação cruzada. A validação cruzada é um critério de parada do treinamento onde os dados são divididos em 3 grupos: treinamento, validação e teste. Esses conjuntos não precisam ter o mesmo tamanho, sendo importante garantir que existam dados suficientes para todas as etapas do processo. Os dados de treinamento são utilizados para reajustes dos pesos normalmente, porém, a cada reajuste, são submetidos dados de validação à rede. Esses dados não reajustam os pesos e são utilizados para avaliar a capacidade de generalização da rede, pois ao não ajustar os pesos, não há chances da rede decorar os dados. Enquanto o valor do erro do conjunto de validação continuar diminuindo, a rede ainda tem capacidade de aprender. Porém, quando o valor do erro do conjunto de validação começa a aumentar, se observa o valor do erro do conjunto de testes. Se esse erro continuar a diminuir, significa que a rede está começando a decorar padrões e perdendo seu poder de generalização, devendo o treinamento ser interrompido. Por fim, o conjunto de testes é introduzido para calcular a performance da rede [9].

Capítulo 3

Metodologia

Neste capítulo serão apresentadas as etapas de desenvolvimento do estudo, seguidas da definição dos parâmetros dos modelos *RBFN* e *MLP* apoiadas na fundamentação teórica.

3.1 Base de dados

As bases de dados utilizada no projeto foram cedidas pelo Operador Nacional de Sistemas Elétricos (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 [17].

Visto que essas informações são estratégicas para os produtores, o nome dos parques eólicos será omitido dos dados, e um codinome será fornecido para o representar. O primeiro parque eólico será referenciado como *Parque B* e o segundo como *Parque I*. Os dados de média da potência elétrica gerada foram medidos a cada 30 minutos, num período que vai do dia 01 de abril de 2010 ao dia 31 de julho de 2012 para o Parque B e do dia 01 de dezembro de 2011 ao dia 31 de julho de 2012 para o Parque I.

O processo de medir e coletar as informações está sujeito à falhas, o que reflete na nossa base de dados. Medições incorretas precisam de tratamento para garantir que elas não prejudicarão o aprendizado de nossa rede.

3.2 Análise e Tratamento de dados

3.2.1 Formatação dos vetores de dados

O conjunto de dados a ser fornecido à uma rede neural deve ser bem formatado, para que o modelo possa corretamente ligar cada valor do vetor à um

neurônio da camada de entrada e, no caso de treinamentos supervisionados, realizar a mesma relação com os neurônios na camada de saída. E.g. uma rede neural com 3 neurônios na camada de entrada e um na camada de saída deve receber, a cada iteração, um conjunto com 3 entradas e uma saída.

Para trabalharmos com a previsão de valores de geração de energia a partir de valores gerados previamente, precisamos produzir uma defasagem nos dados, de modo que nosso conjunto possa posteriormente representar a entrada desejada pela rede. A defasagem constitui em tornar um dado medido num instante t e que ocupa a posição i do vetor de dados, presente no instante $t+1$ ocupando a posição $i+1$. A tabela 1 demonstra como se comporta um vetor unidimensional $v = \{1,2,3,4,5\}$ quando submetido à defasagem para uma rede de 3 neurônios na camada de entrada e 1 na camada de saída.

S	T-1	T-2	T-3
1			
2	1		
3	2	1	
4	3	2	1
5	4	3	2

Tabela 1. Vetor v defasado para utilização no treinamento da RNA.

3.2.2 Tratamento dos dados

Para treinar uma rede neural, é necessário que os dados estejam corretamente formatados, caso contrário a generalização será afetada, podendo levar a péssimas previsões. Primeiramente, é importante verificar se existem falhas nos dados e decidir como corrigir. Em nossas bases de dados, quando o valor de potência elétrica é desconhecido (falha na medição, no registro ou outros), ele é representado com o número -999, valor definido como padrão durante a construção das bases de dados dos Parques B e I. É fundamental garantir que nenhum conjunto de dados a ser introduzido em nossa rede possua esse valor. Para isso, após a defasagem, serão eliminados todos os conjuntos de dados que possuam um ou mais campos com o valor -999. Note que é possível eliminar os valores antes da defasagem, porém é necessário realizar ações complementares *durante* a defasagem, para garantir o alinhamento correto dos conjuntos gerados.

Em seguida, devemos normalizar os valores a serem fornecidos à nossa rede. Como as redes utilizam métricas de erro médio, a normalização evita que valores muito altos tenham maior impacto no aprendizado, relegando valores muito menores. Isso é possível pois a distribuição dos dados é reduzida. Também devemos atentar aos limites da função de ativação na camada de saída, gerando valores proporcionais aos limites dessa. A normalização é então realizada utilizando a Equação 5:

$$y = \frac{(l_{sup} - l_{inf})(x_i - x_{min})}{x_{max} - x_{min}} + l_{inf}$$

Equação 5. Equação para normalização dos dados

Onde:

- y = valor normalizado
- x_i = valor do elemento atual
- x_{min} = valor mínimo de x no conjunto
- x_{max} = valor máximo de x no conjunto
- l_{inf} = limite inferior escolhido arbitrariamente
- l_{sup} = limite superior escolhido arbitrariamente

Valores de limites muito próximos aos limites da função tendem a fazer com que a rede fique presa em mínimos locais, enquanto valores muito centrais tendem a gerar dados muito similares, impedindo a rede de extrair suas características [25]. Como os dados de potência gerada nunca assumem valores negativos, podemos estabelecer como limites inferiores e superiores os respectivos valores 0,10 e 0,90.

3.3 Prevendo a Potência Gerada com MLP

Para utilizar a *Multilayer Perceptron*, devemos ajustar os parâmetros da mesma. Entre os parâmetros configuráveis da MLP estão:

- Número de neurônios na camada de entrada
- Número de camadas escondidas e quantidade de neurônios em cada.
- Número de neurônios na camada de saída

- Função de ativação
- Critérios de parada

Além desses critérios, é importante definir a quantidade de dados dedicados ao treinamento, à validação e ao teste. Serão dedicados 50% dos dados para treinamento, 25% para validação e 25% para testes.

A função de ativação será a sigmoide logística, função que tem como intervalo $[0,1]$.

Como critério de parada, devemos definir o valor esperado a obter da performance da rede. Utilizaremos o Erro Médio Quadrático (EMQ) para medir a performance da rede, pois é exigência do algoritmo de treinamento Levenberg-Marquardt. O EMQ é definido na Equação 6. A meta definida para o EMQ foi 0, pois queremos identificar a precisão da RNA para o problema. Também foi definido como 6 o número de aumentos do EMQ da validação seguidos de diminuição do EMQ do treinamento para interromper o treinamento visando evitar *overfitting* da rede.

$$EQM = \frac{\sum_{i=1}^n (A_{ti} - A_{pi})^2}{n}$$

Equação 6. Erro Médio Quadrático

Onde:

- A_{ti} = valor medido para o instante i
- A_{pi} = valor previsto para o instante i

A escolha da quantidade de entradas foi baseada nos estudos realizados por Galle de Aguiar, medindo a correlação entre as variáveis da velocidade do vento. Como a velocidade do vento tem relação direta com a potência eólica, foi decidido utilizar 6 entradas para a rede [9].

Para a camada intermediária, foi decidido utilizar apenas uma camada escondida, e a quantidade de neurônios foi decidida após testes com variação na quantidade de neurônios na camada escondida, testados de 1 a 101 neurônios iterativamente, com passo de 5 neurônios adicionais. Primeiro, para o Parque B. A Figura 10 traz a média dos EMQ obtidos para a quantidade de neurônios na camada escondida, enquanto a Figura 11 traz a média interna, ou seja, excluindo o maior e

menor valor obtido. Dado que a configuração com 21 neurônios na camada escondida obteve o melhor desempenho em ambas as métricas, ela será a utilizada nas simulações desse parque.

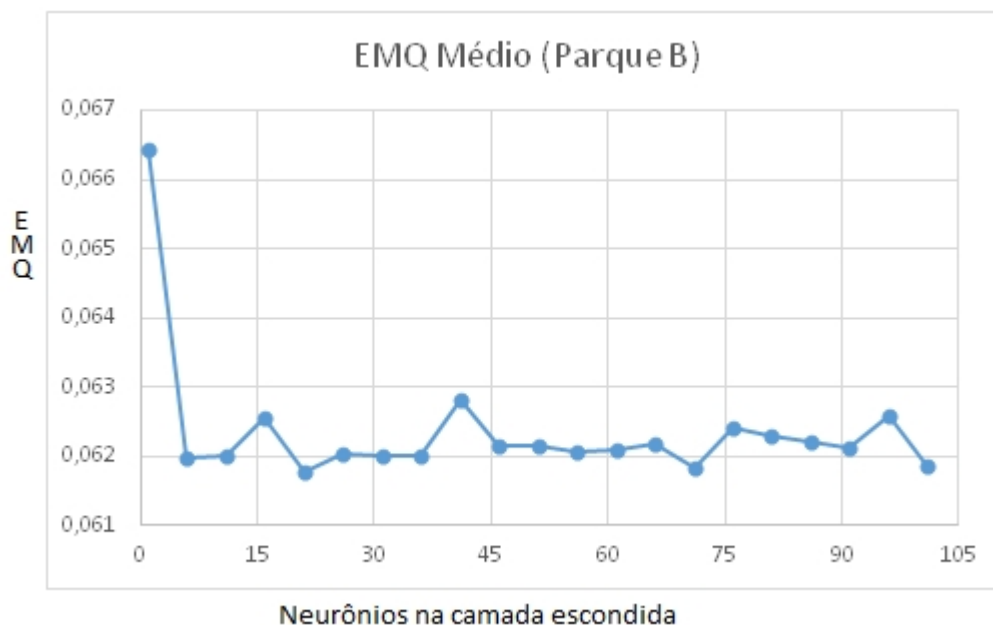


Figura 10. EMQ Médio por número de neurônios na camada escondida para o Parque B




Figura 11. EMQ Interno por número de neurônios na camada escondida, para o Parque B

Em seguida, realizaremos os mesmos testes para o Parque I. A Figura 12 traz a média dos EMQ obtidos para a quantidade de neurônios na camada escondida, enquanto a Figura 13 traz a média interna. Dado que a configuração com 31 neurônios na camada escondida obteve o melhor desempenho, ela será a utilizada nas simulações desse parque.




Figura 12. EMQ Médio por número de neurônios na camada escondida, para o Parque I




Figura 13. EMQ Médio Interno por número de neurônios na camada escondida, para o Parque I

Finalmente, a quantidade de neurônios na camada de saída é definida pela previsão que desejamos. Como desejamos prever 1h adiante, teremos dois neurônios na camada de saída, resultando numa rede 6-56-2, como ilustradas nas Figura 14 e Figura 15.




Figura 14. Arquitetura da *MLP* gerada para o Parque B




Figura 15. Arquitetura da *MLP* gerada para o Parque I

3.4 Prevendo a Potência Gerada com RBFN

Assim como na *MLP*, na Rede com Função Base Radial (*RBFN*) devemos configurar a rede visando obter o melhor desempenho. Dados os parâmetros:

- Número de neurônios na camada de entrada
- Número de neurônios na camada escondida.
- Número de neurônios na camada de saída
- Função de ativação
- Critérios de parada
- *Spread*

A quantidade de neurônios nas camadas de entrada e de saída deverá ser igual à quantidade das respectivas camadas na *MLP*, a fim de comparar as arquiteturas. Mais a frente, definiremos a quantidade de neurônios na camada escondida.

As RBFN utilizam funções gaussianas como função de ativação da camada escondida, e uma função linear na camada de saída. A função gaussiana é definida pela Equação 7:

$$f(\theta_{in}) = e^{-\theta_{in}^2}$$

Equação 7. Função Gaussiana

Onde θ_{in} é o valor de entrada do neurônio.

Essa função tem seu valor máximo no centro e diminui a medida que o valor se afasta do mesmo. É possível ajustar os resultados alterando o *spread* da função. Valores maiores para o *spread* fazem com que a aproximação da função seja mais suave. Um *spread* baixo fará com que menos neurônios sejam necessários para aproximar uma função que varie rapidamente, porém necessitará de mais neurônios para aproximar uma função de curva mais suave, causando problemas de generalização à rede.

A definição do valor do *spread* é por tentativa. Para testarmos iterativamente os *spreads*, utilizaremos o software MATLAB (MATrix LABoratory) que possui uma biblioteca voltada à redes neurais artificiais, que inclui uma função chamada *newrb*, que gera uma *RBFN* iterativamente, aumentando um neurônio a cada iteração, até que um critério de parada seja atendido. As etapas de cada iteração são descritas a seguir:

1. A rede é simulada
2. O conjunto de entrada com o maior erro é identificado
3. Um neurônio é criado e seu peso é dado pelo conjunto identificado no passo 2
4. Os neurônios da camada de saída são recalculados para minimizar o erro

Também serão testadas diferentes quantidades de neurônios na camada interna, a fim de identificar a combinação que provem o melhor resultado. Embora o EMQ da rede diminua com a adição de neurônios durante a elaboração da mesma, ao aplicarmos a rede à novos dados, o desempenho costuma sofrer um forte impacto, em especial para grandes quantidades de neurônios. É apresentado um resumo dos resultados para o Parque B na Tabela 2 e para o Parque I na Tabela 3. As análises dos dados levaram à escolha da configuração de 25 neurônios na camada escondida e *spread* de 0,7 para o Parque B e de 25 neurônios na camada escondida e *spread* de 0,6 para o Parque I. Também é importante notar que, como o vetor de dados possuía 1100 conjuntos, a utilização de valores próximos ao limite disponível (1000 neurônios) levou à um comportamento indesejável da rede.

Spread x Neurônios	10	25	50	100	200	500	1000
0,1	0,0209	0,0158	0,0141	0,01331	0,01479	0,0206	2,354
0,2	0,0111	0,009	0,0082	0,00816	0,00976	0,0421	1,3939
0,3	0,0089	0,0073	0,0072	0,00761	0,01158	0,1565	31,663
0,4	0,0079	0,0071	0,00707	0,0078	0,0156	0,4321	192,09
0,5	0,0071	0,0069	0,007	0,00848	0,01727	0,7901	2E+07
0,6	0,0073	0,0068	0,00717	0,00845	0,02053	1,4534	7578
0,7	0,0068	0,0066	0,00711	0,0083	0,01847	2,023	28642
0,8	0,0068	0,0069	0,00715	0,0087	0,02304	2,5329	34642
0,9	0,0067	0,0068	0,00711	0,0092	0,03069	4,3792	73197
1	0,0067	0,0069	0,00729	0,00977	0,03203	3,2313	1E+06

Tabela 2. Spread x Neurônios para o Parque B.

Spread x Neurônios	10	25	50	100	200	500	1000
0,1	0,0224	0,0173	0,01491	0,014477	0,016076	0,0203	0,1103
0,2	0,0116	0,0088	0,00854	0,008923	0,010473	0,0362	9E+06
0,3	0,0089	0,0077	0,00763	0,008747	0,012117	0,12	851,6
0,4	0,008	0,0073	0,00747	0,009012	0,014372	0,3272	75221
0,5	0,0078	0,0072	0,0077	0,008681	0,019973	0,88	575509
0,6	0,0075	0,0069	0,00792	0,009004	0,02245	1,8127	1E+08
0,7	0,0072	0,0071	0,00772	0,009201	0,031499	4,1629	8E+08
0,8	0,0071	0,0071	0,00767	0,009306	0,033204	3,3205	4E+06
0,9	0,0073	0,007	0,00824	0,009239	0,032615	4,9696	1E+06
1	0,0077	0,007	0,00835	0,009909	0,0457	7,0567	2E+06

Tabela 3. Spread x Neurônios para o Parque I

3.5 Testes e Comparativos

Após a definição de nossas redes, serão gerados os resultados, e partir dele devemos avaliar e comparar as redes. Primeiramente, os dados serão desnormalizados, para serem comparados com os valores originais. A equação para desnormalizar um dado é dada pela Equação 8:

$$y = \frac{(x_i - l_{inf})(x_{max} - x_{min})}{(x_{max} - x_{min})} + x_{min}$$

Equação 8. Equação para desnormalização dos dados

Onde:

- y = valor desnormalizado
- x_i = valor do elemento atual
- x_{min} = valor mínimo de x no conjunto original
- x_{max} = valor máximo de x no conjunto original
- l_{inf} = limite inferior escolhido arbitrariamente (0.1 para esse trabalho)
- l_{sup} = limite superior escolhido arbitrariamente (0.9 para esse trabalho)

Ao fim, será calculado o Erro Médio Absoluto (EMA), visando identificar a precisão da rede, bem como facilitar a comparação com outros modelos, inclusive aqueles a serem desenvolvidos posteriores à esse trabalho. A fórmula do EMA é descrita pela Equação 9:

$$EMA = \frac{\sum_{t=1}^n |A_{ti} - A_{pi}|}{n}$$

Equação 9. Erro Médio Absoluto

Onde:

- A_{ti} = valor medido para o instante i
- A_{pi} = valor previsto para o instante i

Também compararemos os resultados obtidos ao Modelo de Persistência, visando estabelecer uma métrica, nos valendo da referência do mesmo. Por fim, realizaremos testes estatísticos a fim de avaliar qual técnica possui o melhor desempenho na previsão da potência média gerada, aplicando o teste da soma dos pontos de Wilcoxon.

Capítulo 4

Resultados

Neste capítulo serão apresentados os resultados obtidos após a aplicação das etapas obtidas no capítulo 3.

Dado que os pesos dos neurônios da MLP são inicializados com valores aleatórios, precisamos que os resultados não sejam afetados por variação. Iremos gerar e treinar uma MLP e comparar o EMQ obtido com o valores de máximo e mínima utilizados para calcular o EMQ médio interno. Caso o valor obtido não esteja incluso nesse intervalo, iremos descartar essa rede, gerar uma nova (com novos pesos iniciais aleatórios) e a treinar, até obter uma configuração plausível.

Foram então gerados 30 conjuntos para cada arquitetura de rede, calculados os EMA de cada conjunto e produzida uma média, que pode ser visualizada na Tabela 4.

Modelo	EMA (Parque B)	EMA (Parque I)
<i>Persistência</i>	118.9513	17.2774
<i>MLP</i>	54.5074	14.8665
<i>RBFN</i>	13.8258	7.2595

Tabela 4. EMA dos resultados previstos

Em seguida, são executados os testes estatísticos para verificar a significância dos resultados. Executa-se o Teste da Soma dos Pontos de Wilcoxon para verificar se as amostras são estatisticamente distintas. Utilizando um nível de significância de 0.05, são realizadas os testes para as combinações de modelos (RBFN x MLP x Persistência) a fim de identificar a equivalência estatística entre eles, caso exista. Os resultados para o Parque B podem ser conferidos na Tabela 5 e na Tabela 6, para o Parque I.

	MLP	RBFN	Persistência
MLP	x	$2.2 * 10^{-22}$	$1.212 * 10^{-22}$
RBFN	x	X	$1.212 * 10^{-22}$
Persistência	x	x	x

Tabela 5. Resultados do teste de Wilcoxon para o Parque B (*p-value*)

	MLP	RBFN	Persistência
MLP	X	$2.2 * 10^{-22}$	$1.2 * 10^{-22}$
RBFN	X	X	$1.2 * 10^{-22}$
Persistência	X	X	X

Tabela 6. Resultados do teste de Wilcoxon para o Parque I (*p-value*)

Dado que os resultados obtidos pela aplicação do teste de Wilcoxon foram abaixo do nível de significância para todas as configurações, podemos concluir que os modelos são estatisticamente distintos. Pode-se então optar pelo modelo *RBFN* por ter obtido o menor EMA na previsão de geração de energia elétrica.

Capítulo 5

Considerações Finais

A energia eólica tem uma importante posição estratégica no futuro das energias renováveis, possuindo um bom potencial à explorar em diversos países do mundo, inclusive no Brasil. Porém ainda é um grande desafio tomar decisões estratégicas a cerca dessa fonte, pois o vento tem um certo caracter de incerteza.

Este trabalho teve por objetivo aplicar modelos de previsão, mais especificamente, redes neurais artificiais, para comparar as arquiteturas dessa e por fim, à escolha das redes, com o objetivo de prever a geração de potência elétrica a partir do vento.

Foi necessário a implementação de diferentes arquiteturas de redes neurais já conhecidas para utilizar com bases de dados reais, a fim de obter soluções ao problema. Essas redes foram testadas em diversas configurações diferentes, a fim de otimizar os resultados obtidos pela previsão de nossas redes neurais.

5.1 Conclusões

Após a validação por testes estatísticos, foi observado que as redes com função base radial obtiveram os melhores resultados, tanto para o Parque B, quanto para o I. Também podemos avaliar que, dado o alto valor para o EMA do Parque B para a aplicação de Persistência, é necessário um tratamento de dados mais refinados desse conjunto de dados, visto que a variação entre potência está muito acima do Parque I, que condiz mais com as expectativas, pois a velocidade do vento não varia muito num curto espaço de tempo.

5.2 Trabalhos Futuros

Propõe-se como trabalho futuros investigar outras arquiteturas de rede para resolver o problema, como redes especializadas em avaliação de series temporais. Obter base de dados de outros parques, para verificar a capacidade de reutilização

da metodologia aqui desenvolvida. Por fim, é preciso melhorar o desempenho da previsão para o Parque B, realizando uma avaliação e pré processamento dos dados mais avançados.

Bibliografia

- [1] ANEEL. **Atlas da Energia Eólica no Brasil**. Disponível em: <www.aneel.gov.br/aplicacoes/atlas/energia_eolica/6_3.htm> Acesso em: 4 de junho de 2014.
- [2] BROWN, Phillip. **European Union Wind and Solar Electricity Policies: Overview and Consideration**. 2013. Disponível em: <fas.org/sgp/crs/row/R43176.pdf> Acesso em: 04 junho de 2014.
- [3] CARVALHO, André Ponce de Leon F.. **Redes Neurais Artificiais**. Disponível em: <www.icmc.usp.br/pessoas/andre/research/neural> Acesso em: 05 de julho de 2014.
- [4] CHIRAS, D. **Wind Power Basics: A Green Energy Guide**. 2010. 1ed. New Society Publishers, 2010
- [5] COUTURE, Toby D.; KREYCIK, Karlynn C. Claire; WILLIAMS, Emily. **A Policymaker's Guide to Feed-in Tariff Policy Design**. 2010. Disponível em: <www.nrel.gov/docs/fy10osti/44849.pdf> Acesso em: 7 de junho de 2014.
- [6] CRESESB. **Atlas do Potencial Eólico Brasileiro**. Disponível em <www.cresesb.cepel.br/atlas_eolico> Acesso em: 8 de junho de 2014.
- [7] EIA. **International Energy Outlook 2013**. Disponível em: <www.eia.gov/forecasts/ieo/world.cfm> Acesso em: 03 de junho de 2014
- [8] EWEA. **Wind Energy FAQ**. Disponível em: <www.ewae.org/wind-energy-basics/faq> Acesso em: 09 de junho de 2014
- [9] AGUIAR, Bruna 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.
- [10] GAVINO, Natália Azevedo. **Energia Eólica: Uma Análise dos Incentivos à Produção (2002-2009)**. 2001. Monografia de Bacharelado (Bacharelado em

- Economia) – Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 2011.
- [11] GWEC. **Global Wind Statistics 2013**. 2014. Disponível em: <www.gwec.net> Acesso em: 05 de junho de 2014.
- [12] IOWA Energy Center. **Wind Speed and Power**. Disponível em: <www.iowaenergycenter.org/wind-energy-manual/wind-and-wind-power/wind-speed-and-power/> Acesso em: 06 de junho de 2014.
- [13] LUCKOCK, Tom. **Amendments to China's Renewable Energy Law**. 2010. Disponível em: <www.nortonrosefulbright.com/knowledge/publications/28854/amendments-to-chinas-renewable-energy-law> Acesso em: 10 de junho de 2014.
- [14] MORETTO. **Desconhecido**. Dissertação de Mestrado (Mestrado em Engenharia de Produção e Sistemas) – Pontifícia Universidade Católica do Paraná – PUCPR, Curitiba.
- [15] MUSK, Leslie F.. **Weather Systems**. 1988. 1ed. Cambridge University Press, 1988.
- [16] NIXON, Niki. **The History of Wind Power**. 2008. Disponível em: <www.theguardian.com/environment/2008/oct/17/wind-power-renewable-energy> Acesso em: 7 de junho de 2014
- [17] ONS. **Operador Nacional do Sistema Elétrico**. 2014. Disponível em: <www.ons.org.br>. Acessado em: 12 de junho de 2014.
- [18] REW. **China Passes Renewable Energy Law**. 2005. Disponível em: <www.renewableenergyworld.com/rea/news/article/2005/03/china-passes-renewable-energy-law-23531> Acessado em: 7 de junho de 2014
- [19] RODRIGUES, G. **Utilização de Redes Neurais para Previsão de Ventos no Horizonte de 24 Horas**. 2007. Dissertação de Mestrado – Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 2007
- [20] SOUZA, Rodrigo C. T. de. **Previsão de Séries Temporais Utilizando Rede Neural Treinada por Filtro de Kalman e Evolução Diferencial**. 2008.

- Dissertação de Mestrado (Mestrado em Engenharia de Produção e Sistemas)
– Pontifícia Universidade Católica do Paraná – PUCPR, Curitiba, 2008
- [21] SUHRBIER, Jens. **European Renewable Energy Incentive Guide – Germany**. 2013. Disponível em: <www.nortonfulbright.com/knowledge/publications/66180/european-renewable-energy-incentive-guide-germany> Acessado em: 10 de junho de 2014.
- [22] UE. **How the EU Works**. Disponível em: <europa.eu/about-eu/index_en.htm> Acessado em: 9 de junho de 2014.
- [23] US Department of Energy. **How do Wind Turbines Work**. Disponível em: <<http://energy.org/eere/wind/how-do-wind-turbines-work>> Acessado em: 05 de junho de 2014.
- [24] US Department of Energy. **Federal Incentives for Wind Power**. 2013. Disponível em: <www1.eere.energy.org/wind/pdfs/57933_eere_wwpp_federal_incentives.pdf> Acessado em: 05 de junho de 2014.
- [25] VALENÇA, Jorge Mêuser. **Fundamento das Redes Neurais**. Livro Rápido, 2011.
- [26] KABLE. **The World's 10 Biggest Wind turbines**. Disponível em: <www.power-technology.com/features/featurethe-worlds-biggest-wind-turbines-4154395> Acessado em 6 de julho de 2014.