

UNIVERSIDADE FEDERAL DE PERNAMBUCO
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
CENTRO DE INFORMÁTICA

PEDRO HENRIQUE ROSENDO DINIZ

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
ESTIMATIVA DA VELOCIDADE DO VENTO E CERTIFICAÇÃO
DE CURVA DE POTÊNCIA EM TURBINAS EÓLICAS
TRABALHO DE GRADUAÇÃO**

RECIFE
2016

Pedro Henrique Rosendo Diniz

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
ESTIMATIVA DA VELOCIDADE DO VENTO E CERTIFICAÇÃO
DE CURVA DE POTÊNCIA EM TURBINAS EÓLICAS
TRABALHO DE GRADUAÇÃO**

Trabalho de Graduação apresentado à
graduação em Ciência da Computação do
Centro de Informática da Universidade
Federal de Pernambuco para obtenção do
grau de Bacharel em Ciência da Computação.

Orientador: Fernando da Fonseca de Souza
(dfd@cin.ufpe.br)

RECIFE
2016

Agradecimentos

Em primeiro lugar, agradeço à minha família pelo total apoio que dedicaram a mim durante toda minha vida acadêmica e pessoal. Sempre estiveram dispostos a me ajudar nos momentos que precisei e me davam forças em situações de dificuldade para continuar no meu objetivo.

Também gostaria de agradecer aos profissionais e amigos do estágio, que sempre estavam dispostos a tirar dúvidas e me ajudaram a construir este trabalho.

Agradeço também a minha namorada e amigos pessoais que sempre mantiveram-se pacientes e gentis. O apoio que recebi deles foi crucial e serei eternamente grato.

Por fim, porém não menos importante, gostaria de agradecer imensamente ao professor Dr. Fernando da Fonseca de Souza por acreditar no meu potencial desde a época do PET até esse momento de finalização da graduação. Levarei todos os seus ensinamentos e conselhos durante esses anos para o resto da minha vida.

Resumo

Nos últimos anos, a utilização de fontes de energia renováveis, em especial a eólica, vem crescendo e atraindo cada vez mais investimentos. Para atender metas climáticas globais de desenvolvimento sustentável, o investimento em energias renováveis deve duplicar até 2020 e mais do que triplicar até 2030, de acordo com novo relatório da Agência Internacional de Energias Renováveis (IRENA) [1]. A disponibilidade desse tipo de energia depende da velocidade do vento, que é bastante variável. A estimativa desta grandeza é um fator de grande relevância para operadores de usinas eólicas. Este trabalho propõe um método para o cálculo da estimativa da velocidade do vento, para uso na certificação de curva de potência de turbinas eólicas, utilizando redes neurais artificiais (ANN) em conjunto com software de simulação de fluidos baseado nos dados de torres de medições anemométricas do parque eólico e de produção de energia dos aerogeradores.

Palavras-chave: redes neurais, turbinas eólicas, curva de potência, estimativa da velocidade do vento

Abstract

In recent years, the use of renewable energy sources, especially wind power, has been growing and attracting more and more investment. In order to reach global climate targets for sustainable development, investment in renewable energy is expected to double by 2020 and more than triple by 2030, according to a new report from The International Renewable Energy Agency (IRENA) [1]. The availability of this type of energy depends on the wind speed, which is quite variable. The estimation of this element is a factor of great relevance for wind farm operators. This work proposes a method to estimate the wind speed, in order to use in power curve certification of wind turbines, using artificial neural networks (ANNs) in parallel with fluid simulation software based on anemometer towers' data and wind turbines' energy generation.

Keywords: neural networks, wind turbine, power curve, wind speed estimation

Lista de Figuras

Figura 1. Dispositivos e sensores de um aerogerador.....	12
Figura 2. Torre de medição anemométrica e seus sensores.....	13
Figura 3. Curva de potência medida comparada com a CP do fabricante.....	16
Figura 4. Exemplo de saída do WindSim para um Aerogerador.....	20
Figura 5. Procedimento 3-fold cross-validation.....	24
Figura 6. Nuvem de pontos da potência em função da velocidade de vento do WindSim.....	30
Figura 7. Nuvem de pontos da potência em função da velocidade de vento da rede neural.....	31

Lista de Tabelas

Tabela 1. Classe dos Aerogeradores.....	12
Tabela 2. Dados da curva de potência medida em formato de tabela.....	15
Tabela 3. Representação do conjunto de dados.....	22
Tabela 4. Valores do RMSE no 5-fold cross-validation do aerogerador 1.....	27
Tabela 5. Valores do MSE no 5-fold cross-validation do aerogerador 1.....	28
Tabela 6. Valores do MAE no 5-fold cross-validation do aerogerador 1.....	29

Sumário

1. Introdução.....	09
1.1 Contextualização e Motivação.....	09
1.2 Objetivos.....	10
1.3 Estrutura do Documento.....	10
2. Fundamentação Teórica.....	11
2.1 Estrutura de um Parque Eólico.....	11
2.2 Estimativa da Velocidade do Vento.....	13
2.3 Curva de Potência de um Aerogerador.....	14
3. Trabalhos Relacionados.....	17
3.1 Estimativa da Velocidade de Vento por meio de Redes Neurais.....	17
3.2 Análise do Desempenho Elétrico de um Aerogerador por meio do Anemômetro de Nacelle.....	18
4. Método proposto para estimativa da velocidade do vento.....	19
4.1 Utilização de Rede Neural Artificial.....	20
4.2 Definição dos parâmetros da Rede Neural.....	21
5. Experimentos e Análise de Resultados.....	26
5.1 Cenário de Simulação.....	26
5.2 Experimentos Realizados.....	26
5.3 Análise dos Resultados.....	31
6. Conclusão.....	33
6.1 Dificuldades Encontradas.....	33
6.2 Trabalhos Futuros.....	34
Referência Bibliográfica.....	35

1. Introdução

Este capítulo apresenta uma contextualização dos conceitos e termos abordados neste trabalho, assim como a motivação para o desenvolvimento do projeto. Após isso, os objetivos do trabalho são elencados. Por fim, a estrutura restante do documento é definida.

1.1 Contextualização e Motivação

Um parque eólico é constituído de vários aerogeradores dependendo da potência instalada. Torres anemométricas são instaladas no parque a fim de medir grandezas meteorológicas (temperatura, umidade, pressão, velocidade e direção do vento, entre outras) com o objetivo de facilitar o monitoramento das turbinas e do parque em si [1].

A curva de potência (CP) [2] de um aerogerador tem como finalidade indicar a potência gerada em função da velocidade do vento na altura do eixo do rotor da turbina. Para a estimativa de produção de energia, são consideradas turbinas com curva de potência certificada/medida conforme norma IEC 61400-12-1 (*Power performance measurements of electricity producing wind turbines*) [3] por meio de instituições credenciadas. Segundo a norma, para certificar um parque eólico por completo é necessário apenas certificar um único aerogerador. Em outras palavras, o desempenho do aerogerador testado é estendido para os outros aerogeradores do parque eólico. Outra forma atual de estimativa de produção de energia é utilizar a CP do fabricante do aerogerador garantida de forma contratual.

Contudo, o desempenho de um aerogerador pode ser afetado por vários motivos. Exemplos desses motivos incluem: falta de manutenção, erro na instalação, manutenção feita de forma errada, má fabricação, entre outros. Portanto, seria interessante ao produtor do parque ter a possibilidade de certificar de forma contínua e individual a curva de potência dos aerogeradores instalados a fim de otimizar a produção e gerenciar possíveis riscos.

1.2 Objetivos

O objetivo geral deste trabalho de graduação é propor um método para o cálculo da estimativa da velocidade do vento, para ser utilizado na certificação de curva de potência em turbinas eólicas, utilizando redes neurais artificiais [4] em conjunto com software de simulação de fluidos baseado nos dados de torres de medições anemométricas do parque eólico e de produção de energia individual oriundos dos sistemas de comunicação dos aerogeradores.

Este método será utilizado para monitoramento da CP de um aerogerador de forma contínua e individual com objetivo de melhorar a eficiência e eficácia da geração de energia por meio de fontes renováveis.

Também será feita uma análise da eficácia da rede neural utilizada, comparando determinadas métricas estatísticas com diferentes configurações da rede.

1.3 Estrutura do Documento

O restante deste trabalho está organizado da seguinte maneira:

- **Fundamentação teórica** - Neste capítulo serão abordados conceitos e termos técnicos da área de energia eólica, meteorologia e redes neurais que serão necessários para o entendimento do trabalho.
- **Trabalhos Relacionados** - Este capítulo abordará exemplos de trabalhos relacionados com certificação de curva de potência e estimativa de vento em parques eólicos utilizando redes neurais.
- **Método Proposto** - Neste capítulo será exposto o método proposto, no qual será descrita a estratégia utilizada.
- **Experimentos e Análise dos Resultados** - Neste capítulo serão descritos os detalhes (dados, ambiente, configuração, entre outros) dos experimentos realizados. Além disso, serão apresentados os resultados dos experimentos, bem como as estatísticas para análise de desempenho da rede neural utilizada.
- **Conclusão** - Por fim, serão mostradas as conclusões e trabalhos futuros.

2. Fundamentação Teórica

Esta seção visa elencar conceitos fundamentais para o entendimento do trabalho. Primeiramente é definida a estrutura básica de um parque eólico, explicando os seus principais elementos constituintes. Logo após, os principais métodos de estimativa de vento são comentados. Por final, o capítulo é encerrado com uma breve descrição do que é uma curva de potência de um aerogerador.

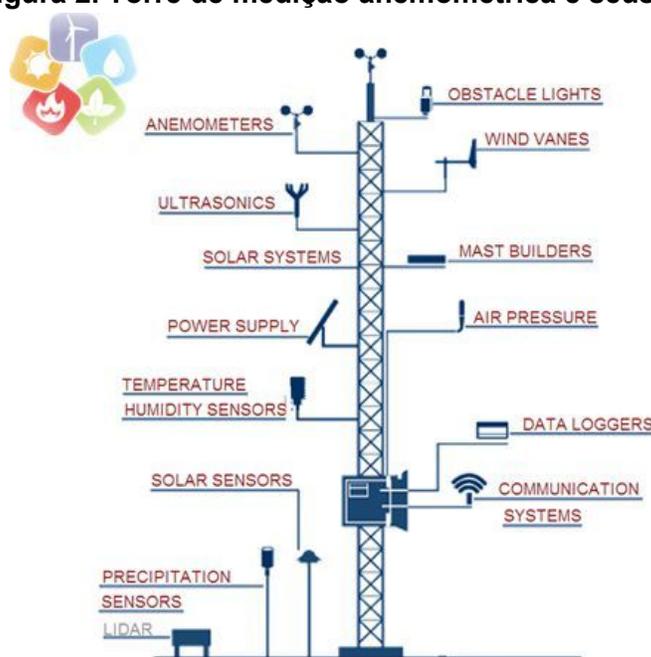
2.1 Estrutura de um Parque Eólico

Um parque eólico é um local no qual são instalados vários aerogeradores (geralmente de mesma potência) com o objetivo de produzir eletricidade. A Portaria MME nº 29/2011 define parque eólico como sendo:

conjunto de aerogeradores interligados eletricamente, situados nas áreas circulares com raio de até dez quilômetros em torno das torres de medição anemométrica, no caso de terrenos de superfície plana com rugosidade homogênea, e com raio de até seis quilômetros, no caso de terrenos complexos, identificados os aerogeradores e as torres de medição por suas coordenadas UTM (Universal Transversa de Mercator), sujeita à validação da EPE a definição do raio quanto à adequação com a topografia. [5]

Uma turbina eólica é uma máquina que converte a energia cinética do vento em energia elétrica e também é conhecida como aerogerador. Ela possui vários dispositivos e sensores como mostrado na Figura 1. Neste trabalho será dado enfoque aos sensores de nacelle e SCADA. O primeiro mede a velocidade do vento e o segundo mede a potência produzida. Os aerogeradores podem ser divididos em classes [6]. Essa classificação pode ser verificada na Tabela 1.

Figura 2. Torre de medição anemométrica e seus sensores



Fonte: Ammonit (2016)

2.2 Estimativa da Velocidade do Vento

O vento é o coração da geração eólica. Mesmo que pequena, cada mudança na velocidade do vento deverá ser levada em consideração em um parque eólico. Por exemplo, um aumento de 1% na velocidade do vento poderá representar um aumento de 2% na produção de energia [1]. Portanto, a estimativa dessa grandeza é de grande importância para os proprietários de parques eólicos.

Diversos fatores podem influenciar a velocidade do vento. As condições climáticas, as condições do terreno, a rotação da Terra, o gradiente de pressão, a direção do vento são alguns desses aspectos que ajudam a determinar essa grandeza.

Inúmeras técnicas podem ser aplicadas para estimar a velocidade do vento e consequentemente a produção de energia eólica. Esses métodos podem ser classificados em quatro abordagens: física, estatística convencional, correlação espacial e abordagem baseada em inteligência artificial [7]. A abordagem física é relacionada com as características meteorológicas do local de estudo e o método estatístico procura entender, por meio de modelos matemáticos, de que forma os

parâmetros que afetam o vento, como elevação, topografia e extensão do terreno podem ser levados em conta para uma estimativa eficaz.

O método mais preciso para medir a velocidade é colocar uma torre de medição anemométrica no lugar no qual é necessário saber essa informação. Porém, esta técnica custa caro por causa dos gastos com aquisição, instalação e manutenção de equipamentos. Este método é um exemplo de uma abordagem física.

A estimativa da velocidade do vento por meio de modelagem computacional feita por programas ou por meio de aprendizagem a partir de um conjunto de treinamento são exemplos de métodos que envolvem inteligência artificial. Por exemplo, o WindSim¹ é um software de modelagem de parques eólicos baseado em técnicas de dinâmica de fluidos computacional (CFD), que combina processamento numérico avançado com visualização 3D em uma interface simples para o usuário².

2.3 Curva de Potência de um Aerogerador

A norma IEC 61400 12-1 define em sua versão traduzida para português a curva de potência medida de um aerogerador como sendo: "tabela e gráfico que representam a potência líquida de um aerogerador medida, corrigida e normalizada em função da velocidade do vento, medida sob um procedimento de medição bem definido" [3].

Sendo assim, a curva de potência é uma forma de avaliar se o aerogerador está produzindo potência de acordo com o que ele foi projetado. Por meio da análise da CP é possível identificar prováveis anomalias no funcionamento da máquina e partir para um diagnóstico mais profundo. Portanto, a CP desempenha um papel importante no monitoramento do funcionamento de uma turbina eólica. A Figura 3 é um exemplo de comparação entre a curva de potência medida e a da projetada pelo fabricante. Já a Tabela 2 mostra os dados de uma CP em formato de tabela.

¹ <https://windsim.com/about.aspx>

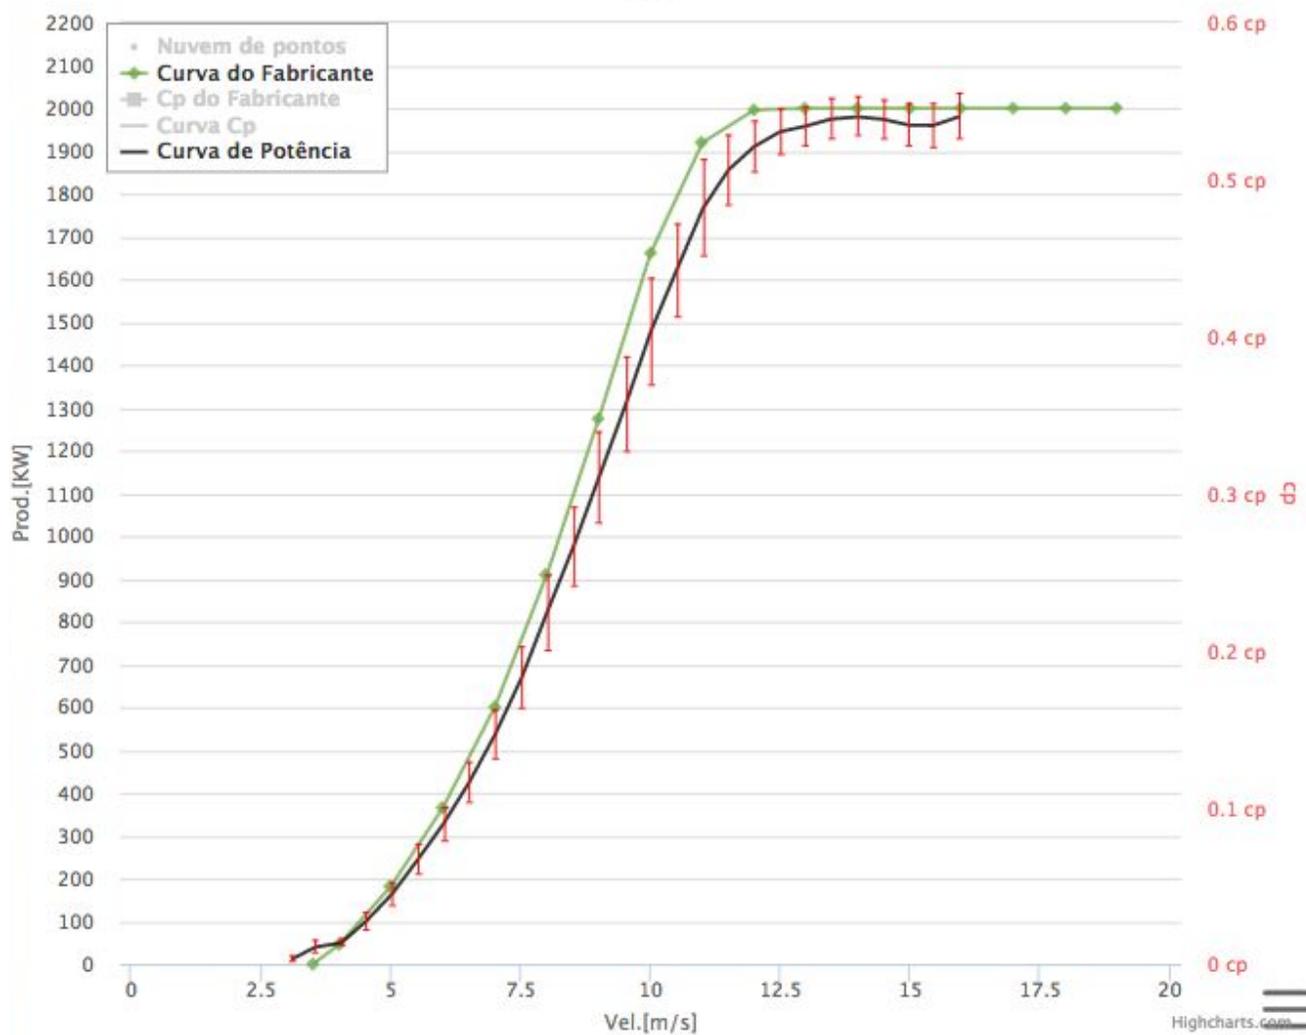
² <https://windsim.com/products.aspx>

Tabela 2. Dados da curva de potência medida em formato de tabela

Curva de potência medida (banco de dados A)							
Massa específica do ar de referência: 1,225 kg/m ³					Categoria A	Categoria B	Incerteza combinada
Nº interv.	Velocidade do vento na altura do cubo m/s	Potência de saída kW	C _p	Nº de conjuntos de dados (média 10 min.)	Incerteza-padrão <i>s_i</i> kW	Incerteza-padrão <i>u_i</i> kW	Incerteza-padrão <i>u_{ci}</i> kW
10	5,0	27,7	0,15	333	1,09	6,8	6,9
11	5,5	67,4	0,28	285	1,65	10,9	11,0
12	6,0	111,3	0,36	262	2,26	16,1	16,3
13	6,5	160,9	0,40	265	3,08	20,1	20,3
14	7,0	209,4	0,42	286	3,22	20,4	20,7
15	7,5	262,0	0,43	287	3,23	20,7	20,9
16	8,0	327,6	0,44	248	3,28	23,3	23,5
17	8,5	395,2	0,44	215	4,38	28,6	28,9
18	9,0	462,0	0,44	179	4,94	29,8	30,2
19	9,5	556,1	0,45	183	5,02	29,9	30,3
20	10,0	629,8	0,43	133	5,83	41,5	41,9
21	10,5	703,1	0,42	127	6,82	32,8	33,5
22	11,0	786,5	0,41	119	6,75	36,1	36,7
23	11,5	836,5	0,38	101	6,65	36,5	37,1
24	12,0	893,5	0,36	94	7,27	25,2	26,2
25	12,5	928,6	0,33	74	5,59	28,8	29,3
26	13,0	956,4	0,30	70	6,38	19,5	20,5

Fonte: IEC 61400-12-1 (2005)

Figura 3. Curva de potência medida comparada com a CP do fabricante



Fonte: Elaborada pelo autor (2016)

3. Trabalhos Relacionados

Neste capítulo serão apresentados métodos e técnicas relacionados com a proposta deste trabalho de graduação. Eles serão divididos em duas vertentes. A primeira busca elencar principais métodos de estimativa de vento utilizando redes neurais artificiais, porém não necessariamente voltados para certificação de curva de potência. Já a segunda vertente elenca um método para certificação de curva de potência utilizando valores reais medidos por meio de um sensor localizado no aerogerador.

3.1 Estimativa da Velocidade de Vento por meio de Redes Neurais

Na literatura existem vários trabalhos que relacionam o uso de redes neurais artificiais para estimativa da velocidade do vento. Alexiadis [8] utiliza *multilayer perceptron* para prever valores médios de velocidade nos próximos sessenta minutos seguintes. Bilgili e Sahin [9] utilizam ANN para prever essa grandeza utilizando variáveis meteorológicas mensais, como pressão, umidade e temperatura, estabelecendo um modelo entre essas variáveis. Já Velo et al. [7] apresenta um método para determinar a média anual da velocidade do vento em um terreno complexo usando redes neurais artificiais.

Esses exemplos de pesquisa tem como objetivo utilizar redes neurais para fazer uma estimativa futura da velocidade do vento no mesmo terreno. Ou seja, procuram responder a pergunta *"qual será a velocidade do vento daqui há uma hora nesse mesmo lugar?"*. Porém, neste trabalho é necessário descobrir ou estimar essa velocidade em outros lugares geográficos dentro do mesmo parque eólico, dado que foi feita uma medição em algum ponto (no caso, a medição da TMA). Ou seja, é necessário responder a perguntas parecidas com *"qual a velocidade do vento nesse mesmo intervalo de tempo no aerogerador mais longe da torre anemométrica, dado que nela foi medida uma velocidade de x m/s?"*.

Técnicas de simulação de fluidos são utilizadas para responder essa última pergunta. O WindSim é um programa amplamente utilizado no mercado de energia eólica e utiliza técnicas de dinâmica de fluidos computacional (CFD) para fazer seus cálculos. No capítulo 3 será apresentado um método que também visa responder essa pergunta de um modo mais prático e de forma contínua sem a necessidade de esperar longa configuração do ambiente que o parque eólico está localizado.

3.2 Análise do Desempenho Elétrico de um Aerogerador por meio do Anemômetro de Nacelle

A norma IEC 61400-12-2:2013 (*Power performance of electricity-producing wind turbines based on nacelle anemometry*) [10] especifica um procedimento para verificar as características de desempenho de potência de uma única turbina eólica.

Esta norma destina-se a ser utilizada quando as especificações operacionais ou contratuais específicas podem não estar em conformidade com os requisitos estabelecidos na IEC 61400-12-1:2005 [3]. O procedimento pode ser usado para a avaliação do desempenho energético de turbinas específicas em locais específicos, mas a metodologia também pode ser empregada para fazer comparações genéricas entre diferentes modelos de turbinas ou diferentes configurações de turbinas.

Estudos realizados investigam como é o desempenho de potência calculada pelo método da norma 61400-12-2 em diferentes condições climáticas e de terreno complexo [11], assim como analisam técnicas e limitações do uso de anemômetros nacelle e sensores SCADA [12] e comentam sobre desvios entre os dados de velocidade do vento medidos por meio dos anemômetros nacelle das turbinas eólicas e anemômetros instalados em torres de medição [13].

4. Método proposto para estimativa da velocidade do vento

O WindSim é um programa para auxiliar a projetar parques eólicos. No contexto do método proposto ele será utilizado para simular a condição de vento (a velocidade, especificamente) em cada aerogerador do parque eólico a ser analisado. Porém, como a execução do WindSim é de longa duração e não existiriam condições para analisar de forma contínua a velocidade dos ventos em cada aerogerador, foi sugerido o aprendizado do comportamento do WindSim por meio de uma rede neural artificial.

O WindSim leva em consideração certas informações como entrada da sua execução: informações topográficas, informações meteorológicas e dados dos sensores das torres de medição anemométrica do parque em questão.

Exemplos de dados providos pela TMA são os valores de sensores de pressão, temperatura, umidade, velocidade e direção do vento. Esses dados são coletados em diferentes alturas e com a regularidade de dez (10) em dez (10) minutos (na verdade é feita uma média de dez (10) em dez (10) minutos).

Após a execução do WindSim, serão encontrados os valores de velocidade de vento em cada aerogerador nos quais a rede neural artificial deverá aprender a reproduzir no futuro. Na Figura 4 encontra-se um exemplo de saída do WindSim. Esses dados são armazenados em um banco de dados relacional.

Figura 4. Exemplo de saída do WindSim para um Aerogerador

```

version           :, 491
site name         :, wecs_001
measurement period :, 15/08/2013 00:10 - 01/07/2015 00:10
site position     :,      375051.0      6416384.0
coordinate system :, 3
measurement height :,      90.00
air density       :,      1.20500
correction method :, pitch-regulated
interpolation     :, true
wake model        :, wake model 1
multiple wake model :, based on sum of squares

rec_nr:,   year:,   mon:,   date:,   hour:,   min:,   dir:,   speed:,   power:,
  1,   2013,   8,   15,   0,   10,   214.6,   3.36,   81.00
  2,   2013,   8,   15,   0,   20,   211.0,   3.02,   33.12
  3,   2013,   8,   15,   0,   30,   196.0,   2.57,   0.00
  4,   2013,   8,   15,   0,   40,   200.6,   3.02,   33.81
  5,   2013,   8,   15,   0,   50,   211.9,   3.06,   38.65
  6,   2013,   8,   15,   1,   0,   212.3,   3.69,   126.06
  7,   2013,   8,   15,   1,   10,   213.7,   3.06,   39.28
  8,   2013,   8,   15,   1,   20,   210.8,   3.37,   81.97
  9,   2013,   8,   15,   1,   30,   205.7,   3.53,   103.88
 10,   2013,   8,   15,   1,   40,   200.8,   3.19,   57.20

```

Fonte: Elaborada pelo autor (2016)

4.1 Utilização de Rede Neural Artificial

A rede neural artificial (ANN) escolhida é provida da *Fast Artificial Neural Network (FANN) Library*³. A FANN é uma biblioteca para implementação de ANN disponível em várias linguagens (C++⁴, *Python*⁵, entre outras). A linguagem de programação utilizada para implementação da ANN é *Python*. A FANN foi escolhida por ser uma biblioteca escrita em C++ (com *binding* para *Python*) e, conseqüentemente, ter mais velocidade que bibliotecas escritas originalmente em *Python*, por exemplo. Já *Python* foi escolhida como linguagem de programação pela possibilidade de utilização da mesma linguagem para a construção da rede e de um sistema *web* de visualização dos dados.

Uma rede neural artificial aplica o princípio de aproximação de função por exemplo, significando que ela aprende o comportamento da função alvo a partir de exemplos do comportamento da própria função [4]. Uma ANN pode aprender desde o

³ <http://leenissen.dk/fann/wp/>

⁴ <http://www.cplusplus.com/>

⁵ <https://www.python.org/>

padrão da função XOR até determinar se existe um tumor visível em uma imagem de raio-X ou prever mudanças no mercado financeiro. Dado que uma rede neural é capaz de resolver um problema por aprendizado supervisionado, deve ser definido um conjunto de treinamento com entradas e saídas conhecidas para que a ANN possa aprender o seu padrão de funcionamento. Foi utilizada uma rede neural *multilayer perceptron* (MLP) neste trabalho.

As redes MLP são formadas por uma camada de entrada, uma ou mais camadas intermediárias ou ocultas e uma camada de saída. Uma matriz de peso pode ser definida para cada uma dessas camadas. Esta topologia de ANN tem a aptidão de resolver problemas de classificação envolvendo padrões não-linearmente separáveis e pode ser usada como um aproximador universal de funções [14]. Portanto, a MLP foi escolhida como topologia de rede por causa do problema ter caráter supervisionado e também por causa da característica de aproximador universal de função desta topologia.

Os dados de velocidade obtidos por meio da saída do WindSim e das TMA são divididos em faixas de valores em uma escala entre 2,5-15 m/s variando a cada 0,5 m/s. Ou seja, são criadas 34 faixas de valores de velocidade. Para cada faixa de valor, será criada uma rede neural associada com o objetivo de aprender o comportamento do WindSim para cada aerogerador. Essa divisão foi feita porque os dados de velocidade do vento para construção da curva de potência da turbina devem ser divididos em faixas de velocidade com *step* de 0,5 m/s segundo a norma [3].

4.2 Definição dos parâmetros da Rede Neural

A camada de entrada da rede neural possui sete (7) nós (1 bias e 6 valores de entrada). Já a camada de saída possui dois (2) nós: um representando a velocidade e o outro a direção do vento. Os nós da camada de entrada são descritos abaixo:

- NÓ 1: Velocidade média do vento na altura do rotor do Aerogerador (altura média da TMA);

- NÓ 2: Direção média do vento no sensor de direção de maior altura da TMA;
- NÓ 3: Hora em que foi feita a medição na TMA;
- NÓ 4: Densidade calculada a partir das medições de temperatura, pressão e umidade pela TMA;
- NÓ 5: Desvio padrão da velocidade média do vento na altura do rotor do Aerogerador e
- NÓ 6: Mês em que foi feita a medição na TMA.

Antes desses valores descritos acima serem passados para a rede neural, eles serão normalizados entre valores de -1 a 1. A FANN aceita apenas valores normalizados nessa faixa de intervalo.

As etapas da pré-triagem dos dados até a fase de execução da rede neural podem ser definidas da seguinte maneira:

i. Pré-triagem e definição do conjunto de treinamento

O conjunto de dados pode ser representado da forma apresentada na Tabela 3:

Tabela 3. Representação do conjunto de dados

Camada de Entrada						Camada de Saída	
Nó 1	Nó 2	Nó 3	Nó 4	Nó 5	Nó 6	Velocidade WindSim	Direção WindSim

Fonte: Elaborada pelo autor (2016)

Esses dados passam por uma fase de pré-triagem, no qual são descartados valores inconsistentes. Exemplos de dados inconsistentes são valores zerados e negativos medidos pelos sensores da TMA. Após essa fase, será feito o treinamento e validação da rede neural artificial proposta.

ii. Fase de Treinamento e Validação

As configurações da rede neural para o treinamento são definidas a seguir:

- `connection_rate = 1;`

- `learning_rate = 0.7;`
- `num_input = 7;`
- `num_layers_hidden = 2;`
- `num_neur_layer_one = 89;`
- `num_neur_layer_two = 89;`
- `num_output = 2;`
- `desired_error = 0.000001;`
- `max_iterations = 3000;`
- `iterations_between_reports = 1000` e
- `activation_function_output = SIGMOID_SYMMETRIC_STEPWISE,`

onde:

connection_rate representa a taxa de conexão entre os nós das camadas;

learning_rate é a taxa de aprendizado da ANN;

num_input é a quantidade de nós na camada de entrada (um deles é um nó *bias*);

num_layers_hidden é a quantidade de camadas escondidas da rede;

num_neur_layer_one é a quantidade de nós na primeira camada escondida;

num_neur_layer_two é a quantidade de nós na segunda camada escondida;

num_output é a quantidade de nós na camada de saída;

desired_error é o máximo erro desejado durante o treinamento da rede;

max_iterations é a quantidade máxima de iterações durante o treinamento. Também é um critério de parada;

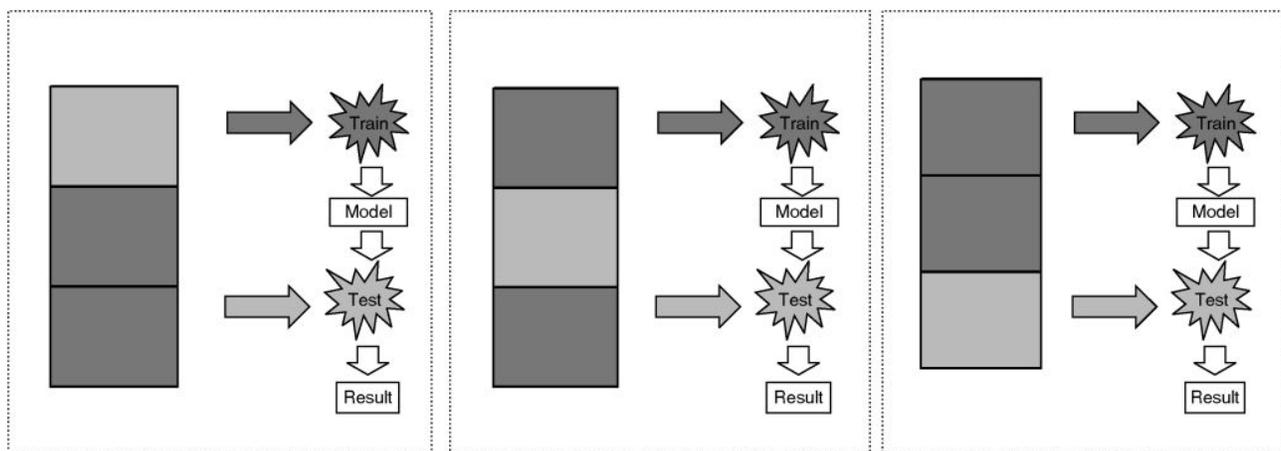
iterations_between_reports representa que a cada 1000 iterações durante o treinamento será mostrado no console o valor do erro associado e

activation_function_output representa o tipo de função que será calculada para ativação de um nó na camada de saída.

Foi proposta uma estratégia de *cross-validation 5-fold* para treinamento e validação dos dados. Cross-validation é um método estatístico de comparação e avaliação de algoritmos de aprendizagem no qual os dados são divididos em duas partes: uma para aprender ou treinar um modelo e a outra para validá-lo [15].

No *k-fold cross-validation*, os dados são randomizados e particionados em k segmentos iguais. Posteriormente, são feitas k iterações de treinamento-validação de forma que 1 segmento seja mantido para validação, enquanto as $k-1$ partes restantes sejam utilizadas para a aprendizagem [15]. A primeira ideia de *cross-validation* pode ser encontrada em [16]. Já um primeiro trabalho com uma descrição semelhante à versão atual do *k-fold cross-validation* pode ser visto em [17]. A Figura 5 ilustra o procedimento do *3-fold cross-validation*.

Figura 5. Procedimento 3-fold cross-validation [15]



Fonte: Refaeilzadeh et al. (2009)

Para definir qual a melhor interação com a configuração de rede neural a ser utilizada na fase de execução, as k iterações devem ser comparadas de acordo com alguma métrica de desempenho. Neste trabalho, serão utilizadas 3 métricas estatísticas: o erro absoluto médio (MAE), o erro quadrático médio (MSE) e a raiz do erro quadrático médio (RMSE). Abaixo encontram-se as formas de calcular essas métricas.

$$MAE = \frac{1}{n} \sum_1^n |x_t - x| \quad (1) \quad MSE = \frac{1}{n} \sum_1^n (x_t - x)^2 \quad (2)$$

$$RMSE = \sqrt{MSE} \quad (3)$$

onde,

x_t = valor alvo ou *target output*;

x = valor de entrada e

n = quantidade de tuplas entrada-valor alvo.

Após uma análise combinada dessas métricas, a melhor iteração é definida para cada faixa de valor de velocidade do vento do aerogerador.

iii. Fase de Execução

Durante a fase de execução, os dados originados nas TMA (após um processo de pré-triagem) são repassados como entrada para a melhor configuração de rede neural definida na fase de treinamento-validação para aquele determinado aerogerador e faixa de velocidade. A rede produzirá a saída correspondente de acordo com a generalização aprendida. Nesse momento já não há a presença do WindSim e os dados podem ser processados de maneira rápida e contínua.

5. Experimentos e Análise de Resultados

Este capítulo apresenta a descrição dos experimentos realizados, bem como a análise dos resultados obtidos.

5.1 Cenário de Simulação

Para esta simulação, foi utilizado um parque eólico com duas (2) torres de medição anemométricas e dezesseis (16) turbinas eólicas. Uma TMA é responsável pela medição de dados climáticos que serão levados em consideração para a velocidade do vento em sete (7) turbinas e a outra é responsável pelas nove turbinas restantes. Para efeito de diminuir a extensão do trabalho com várias tabelas de métricas calculadas, apenas o *cross-validation* de um aerogerador será mostrado. Porém, o mesmo processo foi executado para todas as turbinas do parque.

Foram coletados dados médios de dez (10) em dez (10) minutos dos sensores das TMA durante o período de um (1) ano. Compreendendo, assim, todas as estações do ano e fases de rotação da Terra.

Também foram fornecidos os dados de saída do WindSim para cada aerogerador após a simulação feita no mesmo período em que foram coletados os dados das TMA.

Os dados de velocidade do vento foram divididos em 34 faixas compreendidas entre 2.5-15 m/s, com variação de 0,5 m/s cada.

5.2 Experimentos Realizados

Para cada faixa de velocidade do vento de cada turbina é criada uma rede neural. Logo, foram criadas $34 \times 16 = 544$ ANN. Cada uma dessas redes passou pelo processo de *5-fold cross-validation* antes de ir para a fase de execução. Abaixo são mostradas as métricas calculadas para cada *fold* do aerogerador 1 em formato de tabelas.

Tabela 4. Valores da métrica RMSE do 5-fold cross-validation do aerogerador 1.

FAIXA BIN	FOLD 1	FOLD 2	FOLD 3	FOLD 4	FOLD 5
2.5	0.363	0.345	2.008	1.413	0.401
3	0.494	0.650	0.417	0.542	0.610
3.5	0.190	0.595	1.247	0.712	0.243
4	0.200	0.327	0.327	0.847	0.442
4.5	0.316	0.396	0.327	0.308	0.237
5	0.228	0.422	0.366	0.436	0.775
5.5	0.265	0.414	0.392	0.395	0.456
6	0.359	0.432	0.481	0.515	0.630
6.5	0.389	0.491	0.801	0.550	0.825
7	0.424	0.513	0.548	0.367	0.581
7.5	0.511	0.634	0.559	1.085	0.794
8	0.579	0.772	0.476	0.914	1.561
8.5	0.609	0.807	0.796	0.858	0.863
9	0.681	0.361	0.892	0.523	0.522
9.5	0.552	0.447	0.521	0.767	0.691
10	0.445	0.249	0.448	0.829	2.342
10.5	0.632	0.417	0.562	0.581	0.846
11	1.256	1.385	0.813	0.521	0.954
11.5	1.305	1.488	1.389	0.935	2.654
12	0.514	0.796	1.158	1.197	1.692
12.5	1.572	1.613	0.909	1.305	1.530
13	1.374	1.160	0.639	0.575	1.304
13.5	0.861	0.593	0.914	1.737	3.385
14	0.865	0.744	1.481	2.170	2.413
14.5	0.358	0.324	0.563	1.075	1.043
15	0.310	0.383	0.409	0.329	1.719

Fonte: Elaborada pelo Autor (2016)

Tabela 5. Valores da métrica MSE do 5-fold cross-validation do aerogerador 1.

FAIXA BIN	FOLD 1	FOLD 2	FOLD 3	FOLD 4	FOLD 5
2.5	0.132	0.119	4.033	1.996	0.161
3	0.244	0.423	0.174	0.294	0.372
3.5	0.036	0.354	1.554	0.507	0.059
4	0.04	0.107	0.107	0.717	0.195
4.5	0.1	0.157	0.107	0.095	0.056
5	0.052	0.178	0.134	0.19	0.601
5.5	0.07	0.171	0.154	0.156	0.208
6	0.129	0.187	0.231	0.265	0.397
6.5	0.151	0.241	0.641	0.302	0.68
7	0.18	0.263	0.3	0.135	0.338
7.5	0.261	0.402	0.312	1.178	0.63
8	0.335	0.596	0.227	0.835	2.436
8.5	0.371	0.651	0.634	0.737	0.744
9	0.464	0.13	0.796	0.274	0.273
9.5	0.305	0.2	0.271	0.588	0.477
10	0.198	0.062	0.201	0.687	5.487
10.5	0.399	0.174	0.316	0.337	0.716
11	1.577	1.919	0.661	0.271	0.911
11.5	1.703	2.215	1.929	0.875	7.044
12	0.264	0.633	1.341	1.433	2.862
12.5	2.472	2.601	0.826	1.702	2.342
13	1.889	1.345	0.408	0.331	1.7
13.5	0.741	0.352	0.836	3.018	11.457
14	0.748	0.554	2.194	4.707	5.824
14.5	0.128	0.105	0.317	1.156	1.088
15	0.096	0.147	0.167	0.108	2.956

Fonte: Elaborada pelo Autor (2016)

Tabela 6. Valores da métrica MAE do 5-fold cross-validation do aerogerador 1.

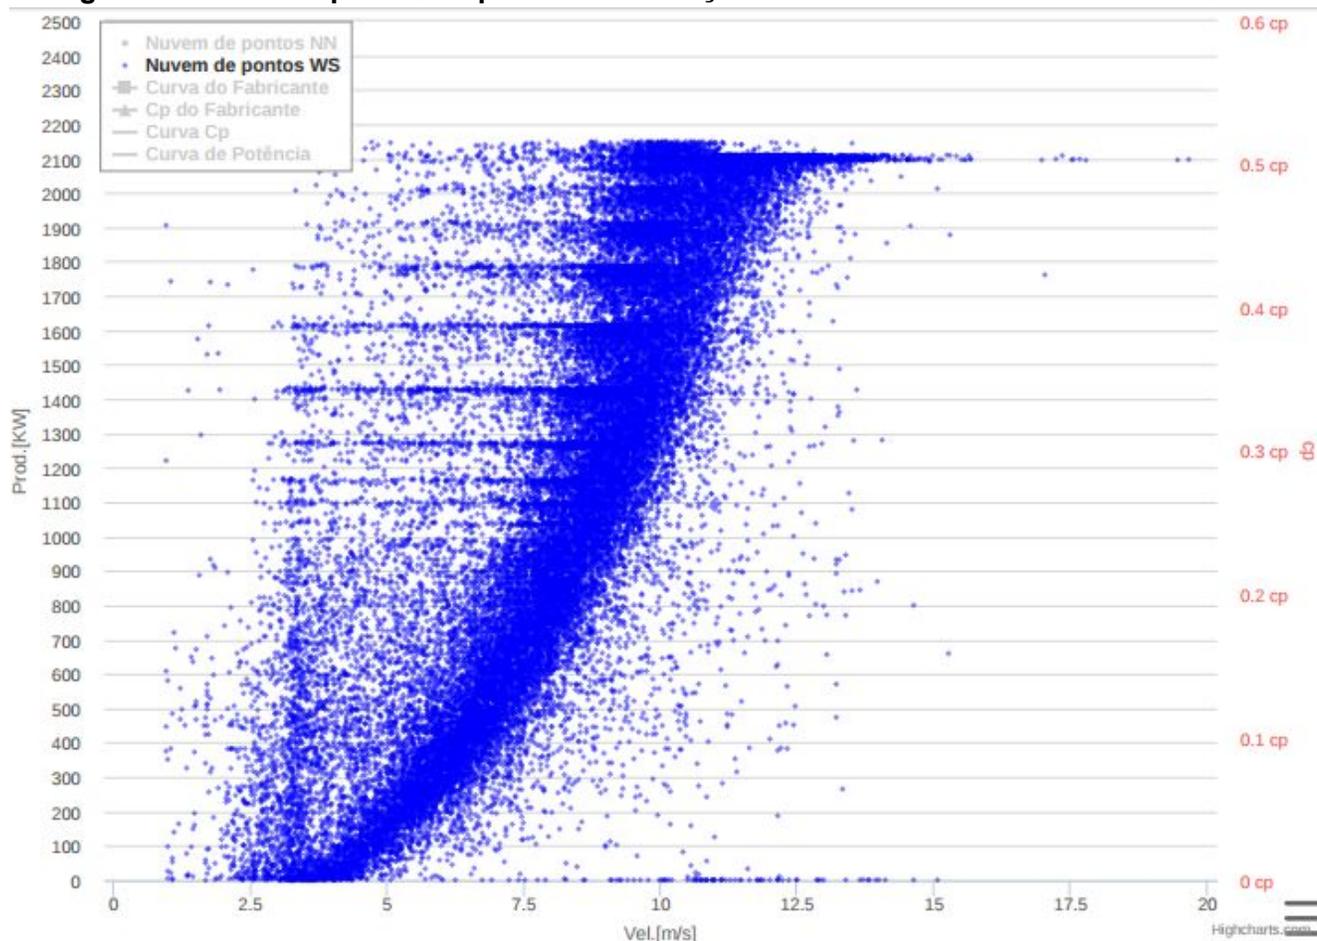
FAIXA BIN	FOLD 1	FOLD 2	FOLD 3	FOLD 4	FOLD 5
2.5	0.349	0.323	0.591	0.398	0.269
3	0.42	0.528	0.342	0.427	0.56
3.5	0.106	0.276	0.369	0.287	0.152
4	0.128	0.267	0.264	0.403	0.347
4.5	0.179	0.348	0.291	0.256	0.149
5	0.172	0.393	0.315	0.346	0.549
5.5	0.205	0.389	0.342	0.328	0.367
6	0.292	0.398	0.447	0.435	0.511
6.5	0.338	0.463	0.453	0.511	0.429
7	0.361	0.449	0.509	0.298	0.42
7.5	0.469	0.568	0.488	0.891	0.605
8	0.506	0.687	0.441	0.658	1.134
8.5	0.565	0.737	0.744	0.794	0.757
9	0.625	0.305	0.738	0.472	0.405
9.5	0.508	0.401	0.44	0.695	0.543
10	0.404	0.213	0.363	0.781	2.153
10.5	0.573	0.332	0.451	0.487	0.56
11	1.226	1.286	0.639	0.443	0.81
11.5	1.295	1.455	1.337	0.795	2.16
12	0.469	0.742	0.921	0.823	1.218
12.5	1.462	1.551	0.522	0.925	1.2
13	1.366	1.058	0.59	0.459	1.145
13.5	0.68	0.516	0.729	1.425	2.209
14	0.817	0.68	1.417	2.075	2.156
14.5	0.284	0.272	0.378	0.96	0.921
15	0.285	0.359	0.333	0.306	0.889

Fonte: Elaborada pelo autor (2016)

Nas Tabelas 4, 5 e 6, os segmentos com menores valores de RMSE, MSE e MAE foram destacados. Esses segmentos foram definidos como melhores e repassados para a fase de execução.

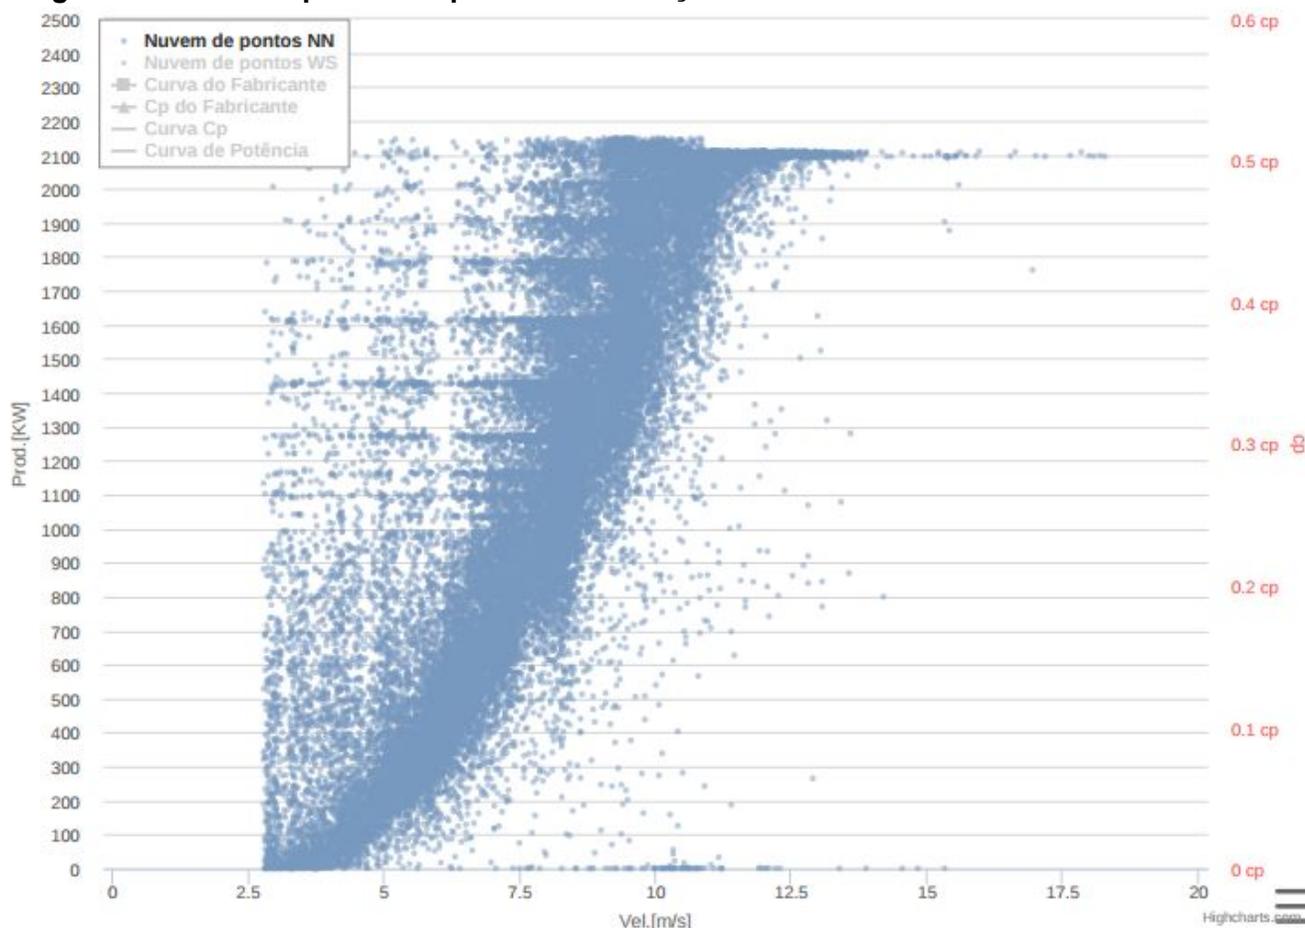
A seguir, são mostrados 2 gráficos nos quais são plotados os pontos de potência em função da velocidade do vento no aerogerador naquele instante de tempo. Os dados de potência são coletados por meio dos sensores SCADA das turbinas. No primeiro gráfico foram utilizados dados de velocidade calculados a partir do WindSim. Já no segundo gráfico, os dados foram estimados a partir da melhor rede neural para cada faixa de velocidade do aerogerador.

Figura 6. Nuvem de pontos da potência em função da velocidade de vento do WindSim.



Fonte: Elaborada pelo autor (2016)

Figura 7. Nuvem de pontos da potência em função da velocidade de vento da rede neural.



Fonte: Elaborada pelo autor (2016)

5.3 Análise dos Resultados

Analisando as tabelas com as métricas de desempenho, é possível perceber que os segmentos escolhidos por meio das métricas MSE e RMSE são iguais, como já era esperado. Porém, a métrica MAE também tornou-se bastante parecida com as outras duas na tomada de decisão dos melhores segmentos. Apenas em 1 faixa de velocidade a MAE foi diferente das demais. A partir dessa observação, é possível determinar que a utilização de qualquer uma das métricas individualmente como critério de escolha da rede neural a ser executada garantiria uma boa escolha.

Após uma análise minuciosa dos dados de erros absolutos entre a velocidade calculada pelo WindSim e da rede neural executada, foi possível perceber que cerca de

90% desses erros possui um valor de até 0,1. Já nos outros 10%, é verificável um valor alto de erro. Uma hipótese que explicaria isso indica que a velocidade no WindSim nesses casos é maior que 2 m/s do que a velocidade medida na TMA. Ou seja, a rede neural tem problemas em generalizar casos nos quais existe uma certa discrepância entre os dados medidos pela TMA e o calculado para o aerogerador a partir do WindSim. Esses casos aumentam à medida que os aerogeradores se afastam mais da TMA geograficamente.

Analisando os gráficos de velocidade x potência produzidos a partir dos dados do WindSim e da rede neural, é possível verificar uma boa semelhança entre eles com uma leve inclinação para direita nos pontos do segundo gráfico.

6. Conclusão

Este trabalho apresentou um método para o cálculo da estimativa da velocidade do vento, a ser utilizado na certificação de curva de potência em aerogeradores, utilizando redes neurais artificiais em paralelo com software de simulação de fluidos baseado nos dados de torres de medições anemométricas do parque eólico e de dados de potência das turbinas eólicas.

Inicialmente, foi discutida a motivação para este projeto, destacando a importância do monitoramento da curva de potência dos aerogeradores. Posteriormente, foram abordados conceitos e termos técnicos da área de energia eólica, meteorologia e redes neurais, tendo destaque as informações sobre trabalhos na literatura que utilizam redes neurais para estimativa de vento e suas principais diferenças para este projeto.

Logo após, foi apresentado o método proposto para este trabalho. A estrutura da rede neural foi definida e foi escolhido o método de *5-fold cross-validation* para treinamento e validação desta rede.

Finalmente, os experimentos realizados foram apresentados, com o objetivo de avaliar o método proposto por meio de métricas estatísticas. Além disso, também foi apresentada uma análise dos resultados obtidos a partir desses experimentos. É possível destacar dessa análise que as métricas MAE, MSE e RMSE são para decisão da melhor configuração de rede neural do método proposto neste trabalho, com uma pequena divergência em poucos casos. Também foi observado que a taxa de erro entre o WindSim e o método apresentado aumenta de acordo com a distância entre os aerogeradores e a torres de medição anemométrica.

6.1 Dificuldades Encontradas

As principais dificuldades giraram em torno da aquisição e filtragem dos dados obtidos das torres anemométricas e também do WindSim. Como este projeto tem um

caráter multidisciplinar foi necessário muita leitura e pesquisa sobre assuntos que não são originalmente de computação.

6.2 Trabalhos Futuros

Podem ser elencadas como possíveis contribuições futuras:

- Utilização de outro software ou modelo de estimativa de velocidade do vento para comparação com o WindSim;
- Análise mais detalhada e sistemática de certos parâmetros da rede neural, como taxa de aprendizado, quantidade máxima de iterações, quantidade de camadas escondidas e de seus respectivos nós;
- Filtragem de dados que apresentam certo grau de discrepância entre o valor medido pela TMA e o valor da rede neural. Foi verificado que diferenças de velocidades acima de 2 m/s diminuía o poder de generalização da rede. Porém, seria necessário um estudo mais cauteloso para definir este parâmetro;
- Utilização de outras métricas de desempenho para a abordagem utilizada na validação dos dados. Uma sugestão é utilizar a métrica R2;
- Verificar e implementar outras estratégias de validação de dados;
- Utilizar um período maior que 1 ano de dados para treinamento da rede neural e analisar essa contribuição a fim de melhorar o desempenho;
- Análise mais refinada dos parâmetros de entrada da rede neural. Identificar possíveis informações que podem ser repassadas como entrada da rede de modo a melhorar o desempenho e
- Utilização de outras topologias de redes neurais com o objetivo de compará-las com os resultados obtidos da MLP.

Referência Bibliográfica

- [1] European Wind Energy Association. **Wind Energy - The Facts: A guide to the technology, economics and future of wind power**. Londres, Reino Unido: Earthscan, 2009.
- [2] WAN, Y.; ELA, E.; ORWIG, K. **Development of an Equivalent Wind Plant Power-Curve**. Presented at WindPower 2010, Dallas, 2010, p. 4
- [3] IEC 61400-12-1. **Wind turbines Part 12-1: Power performance measurements of electricity producing wind turbines**. 1st ed., 2005.
- [4] MACKAY, D. J. C. **Information Theory, Inference, and Learning Algorithms**. Cambridge, Reino Unido: Cambridge Univ. Press, 2003, p. 468
- [5] BRASIL, Portaria n.º 29, de 28 de janeiro de 2011. Ministério de Minas e Energia, Artigo 6, Seção III, Inciso 1.
- [6] IEC 61400-1. **Wind turbines Part 1: Design requirements**. 3rd ed., 2005.
- [7] VELO, R.; LOPÉZ, P.; MASEDA, F. **Wind speed estimation using multilayer perceptron**. Energy Conversion and Management, 2014, v. 81, p. 1-9
- [8] ALEXIADIS, M. et al. **Short-term forecasting of wind speed and related electrical power**. Sol Energy, 1998, v. 63, p. 61-68.
- [9] BILGILI, M.; SAHIN, B. **Comparative analysis of regression and artificial neural network models for wind speed prediction**. Meteorol Atmos Phys, 2010, v. 109, p. 61-72.
- [10] IEC 61400-12-2. **Power performance of electricity-producing wind turbines based on nacelle anemometry**. 1st ed., 2013.
- [11] LIU, B. **Wind Turbine Power Performance Verification by Anemometer on the Nacelle**. Trondheim, Noruega, 2011.
- [12] ORMEL, F. **Advanced nacelle anemometry and SCADA-data, analysis techniques and limitations**. Presented at EWEA 2012, Lyon, 2012

- [13] ALLIK, A.; UIGA, J.; ANNUK, A. **Deviations between wind speed data measured with nacelle-mounted anemometers on small wind turbines and anemometers mounted on measuring masts.** Agronomy Research, 2014, v. 12, p. 433-444
- [14] HAYKIN, S. **Neural Networks and Learning Machines.** Hamilton, Canadá: Pearson Prentice Hall, 3rd ed., 2009, p. 797
- [15] REFAEILZADEH, P.; TANG, L.; LIU, H. **Cross-validation.** In: Encyclopedia of Database Systems. United States: Springer, 2009, p. 532-538.
- [16] LARSON, S. **The shrinkage of the coefficient of multiple correlation.** Journal of Educational Psychology, 1931, v. 22, p. 45-55
- [17] MOSTELLER, F.; TUERKEY, J.; **Data analysis, including statistics.** In: Handbook of Social Psychology. Reading: Addison-Wesley, 1968