



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
UNIDADE ACADÊMICA DE ENGENHARIA ELÉTRICA



FRANCISCO PAULO FERREIRA DE SOUSA

TRABALHO DE CONCLUSÃO DE CURSO

PREVISÃO DE GERAÇÃO DE UMA TURBINA ATRAVÉS DE UMA
REDE NEURAL ARTIFICIAL

Campina Grande
Novembro de 2012

FRANCISCO PAULO FERREIRA DE SOUSA

TRABALHO DE CONCLUSÃO DE CURSO

*Trabalho de Conclusão de Curso submetido à
Unidade Acadêmica de Engenharia Elétrica da
Universidade Federal de Campina Grande como parte
dos requisitos necessários para a obtenção do grau de
Bacharel em Engenharia Elétrica.*

Aprovado em 29 / 11 / 2012

Francisco Paulo Ferreira de Sousa
Aluno

Professor Avaliador
Universidade Federal de Campina Grande

Tarso Vilela Ferreira
Universidade Federal de Campina Grande

“Forecasting is very difficult, especially if it’s about the future...”

Niels Bohr

AGRADECIMENTOS

Este trabalho marca o final de uma etapa de minha vida cheia de conquistas e realizações. Chegar até aqui seria impossível sem o auxílio, companheirismo e dedicação de muitas pessoas, o que torna este trabalho uma realização de todos estes.

Sou grato ao Criador, fonte eterna de sabedoria e conhecimento porque dEle, por Ele e para Ele são todas as coisas.

Agradeço a meus pais Paulo Roberto Silva de Sousa e Adilene Ferreira de Sousa por terem ido muito além dos deveres paternos, incentivando, apoiando, corrigindo e vibrando com cada conquista.

Agradeço à minha noiva Fabíola Freire cujo amor, cuidado e dedicação foram e sempre serão fundamentais para a construção de minha vida. Obrigado pela paciência, encorajamento e apoio incondicionais.

Agradeço aos meus dois irmãos Renan e Syllas pela agradável convivência desde os tempos primeiros. Obrigado pela força e incentivo.

Agradeço aos meus inestimáveis colegas de graduação, especialmente a André Oliveira, Carlos Antônio, Edmílson Almeida, Eli Dias, Igor Torres, Luís Augusto Tiago Medeiros e Uian Sol. A caminha teria sido muito mais árdua sem a vossa companhia. Obrigado por terem compartilhado esta etapa da vida comigo.

Agradeço aos meus mestres Tarso Vilela, Edson Guedes e George Lira cujos conselhos foram de valiosa importância na minha vida acadêmica e pessoal.

Agradeço aos professores do Departamento de Engenharia Elétrica (DEE) da Universidade Federal de Campina Grande (UFCG) que contribuíram, sempre de forma prestativa, para a construção do conhecimento que hoje possuo.

Agradeço aos funcionários do DEE, especialmente os do LAT, que foram peças fundamentais para o sucesso da realização das atividades pertinentes ao trabalho e à minha graduação.

Resumo

Um dos grandes problemas enfrentados pela humanidade nos dias atuais é a crescente demanda por energia elétrica. O desafio energético mundial força uma maior eficiência dos sistemas elétricos e a procura por fontes de geração de energia que venham atender as necessidades da vida moderna e que diminuam os impactos ambientais, comuns nas formas tradicionais de geração. É neste cenário que as fazendas eólicas vêm se consolidando como uma alternativa viável. Entretanto, o gerenciamento de um parque eólico constitui-se uma tarefa com grandes dificuldades devido as complexas características do vento, como a alta variabilidade de sua velocidade e direção. Esse trabalho tem como objetivo desenvolver um sistema que utilize uma técnica de computação inteligente, conhecida como Rede Neural Artificial, para obter previsões de produção de energia e, assim, beneficiar o controle de despacho desta forma de geração, além de, fornecer uma ferramenta que auxilie no planejamento de manutenções.

Sumário

1. Introdução	7
2. Fundamentação Teórica	8
2.1 O recurso eólico	8
2.2 A sazonalidade do recurso	10
2.3 A transformação da energia	12
2.4 Redes Neurais artificiais	14
2.4.1 A unidade básica de processamento	15
2.4.2 Treinamento, Validação e Teste: As etapas de configuração de uma RNA	16
2.4.3 Aquisição de Parâmetros	17
3. Materiais	18
3.1 O aerogerador	18
3.2 Curva de Potência	20
3.3 Software	21
4. Métodos	22
4.1 Base de Dados	22
4.2 Configuração das Arquiteturas das RNAs utilizadas	23
4.2.1 Caso 1	24
4.2.2 Caso 2	24
4.2.3 Caso 3	25
5. Resultados	26
5.1 Caso 1	26
5.2 Caso 2	27
5.3 Caso 3	28
6. Conclusões	31
7. Referências Bibliográficas	32

1. Introdução

A energia é um bem essencial à vida moderna como a conhecemos, não apenas em seus artigos de luxo, mas na base de toda tecnologia que aumentou a qualidade de vida do homem está presente a energia em sua forma elétrica. No entanto, todo o processo desde a geração, passando pela transmissão, distribuição e utilização, tem repercussões ambientais. No novo paradigma da energia elétrica, o consumo desenfreado dá lugar a utilização eficiente e a geração a partir de fontes renováveis.

Algumas dessas fontes renováveis visam aproveitar sistemas naturais de movimento como o vento e as marés. Mas ao contrário de uma hidrelétrica onde se pode regular a vazão da represa ou de uma termoeletrica onde se pode controlar o estoque de carvão e gás, tais sistemas estão entregues à imponderabilidade. Dada a vulnerabilidade associada a estes novos recursos energéticos, é primordial a utilização de um conjunto vasto de tecnologias que permitam aumentar o fator de segurança do abastecimento. O recurso o eólico, está associado a um grau elevado de volatilidade e variabilidade que desde cedo se traduz em problemas de:

- Segurança de Abastecimento - Considerando a possibilidade de avarias das unidades produtoras, a variabilidade do recurso eólico e a necessidade de garantir a cobertura dos consumos por intermédio dos meios de produção disponíveis, há a necessidade de conhecer previamente uma estimativa acerca da produção eólica. De forma a identificar os volumes adequados de reservas operacionais que garantem os níveis de qualidade de serviço estipulados. Os sistemas de previsão permitem uma maior eficiência no processo de contratação de serviços de reserva reduzindo as incertezas associadas à produção esperada dos parques eólicos;
- Gestão dos Parques Eólicos - A gestão do parque eólico exige a definição de períodos de manutenção e poderá exigir o pré-despacho e o despacho dos aerogeradores com o objetivo de responder a solicitações do operador do sistema. Se o empreendedor possuir ferramentas que o informem acerca da produção prevista para um determinado período, poderá programar para os períodos com menor capacidade de produção do parque eólico as manutenções planejadas.

2. Fundamentação Teórica

2.1 O recurso eólico

O vento é o ar em movimento com uma determinada intensidade e direção e, resulta do deslocamento de massas de ar, provenientes do fenômeno das diferenças de pressão atmosférica entre duas regiões distintas. As diferenças de pressão estão associadas à radiação solar e a processos de aquecimento das massas de ar: nas altas pressões o ar desce e diverge dirigindo-se para as baixas onde converge e sobe. O aquecimento das superfícies terrestres e do mar é diferente dos polos para os trópicos, o que origina o deslocamento de fluxos de calor entre estas zonas, sendo o vento um dos transportadores deste calor. A figura seguinte ilustra os fluxos de vento.




Figura 1 – Fluxos de vento [1]

No seguimento dos fluxos do vento, existem também brisas, que representam um fluxo de vento localizado e de intensidade mais reduzida. As brisas têm origem térmica, por efeito de aquecimento ou arrefecimento desigual das superfícies terrestres, num determinado local. As brisas mais comuns são:

- Brisa Terrestre – Vento que sopra durante a noite da superfície terrestre para o mar. Durante a noite a superfície terrestre arrefece mais rapidamente do que a água do mar, dando origem a uma diferença de pressão: pressões altas na superfície terrestre e pressões baixas no mar;
- Brisa Marítima – Vento que sopra durante o dia do mar para a superfície terrestre. Durante o dia a superfície terrestre aquece mais rapidamente do que a água do mar, dando origem a uma diferença de pressão: pressões altas no mar e pressões baixas na superfície terrestre;

- Brisa de Montanha – Vento que sopra à noite dos picos das montanhas para os vales. À noite os picos das montanhas arrefecem mais rapidamente do que os vales, dando origem a uma diferença de pressão: pressões altas nos picos das montanhas e pressões baixas nos vales;
- Brisa do Vale - Vento que sopra de manhã do vale para os picos das montanhas. Os picos das montanhas aquecem primeiro do que os vales, dando origem a uma diferença de pressão, altas pressões nos vales e baixas pressões nos picos das montanhas.

As brisas são um comportamento diário do vento. Estes comportamentos explicam as propriedades de mudança de direção do vento e de sazonalidade associadas às séries temporais do recurso vento. O vento tem uma variabilidade sazonal, mensal, diária e até mesmo horária nos seus valores médios.

O vento pode ser representado no domínio das frequências Figura 2, segundo o estudo efetuado por [2]. Tal representação espectral é uma medida da energia cinética associada à componente horizontal da velocidade do vento. Embora o espectro só seja válido para caracterizar a zona onde se devem efetuar as medições, tem-se verificado que sua forma geral se mantém constante. A análise da Figura 2 revela a existência de dois picos de energia e um vale, formando três regiões distintas:

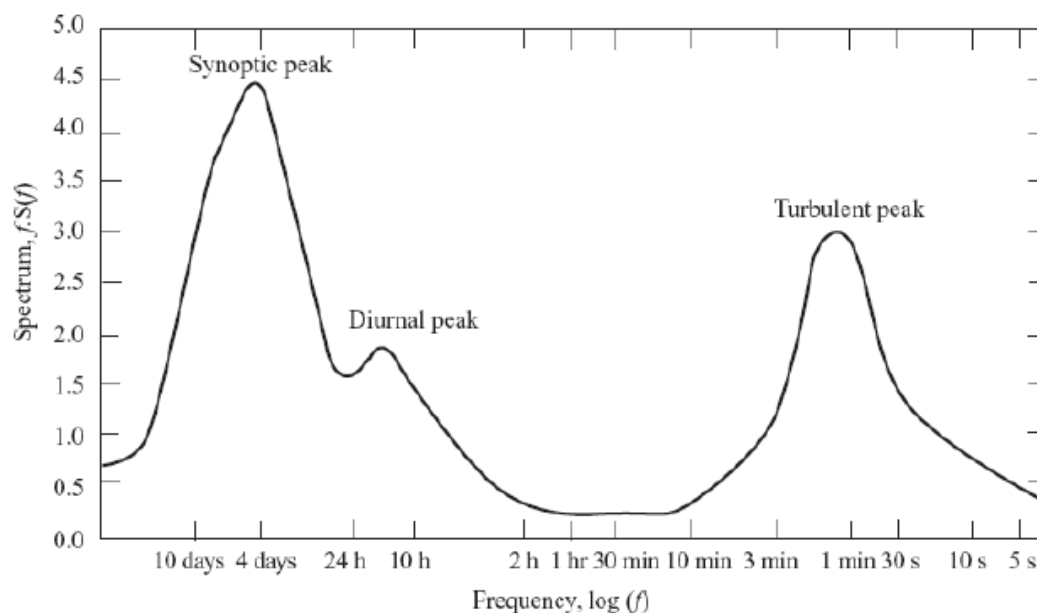


Figura 2 – Espectro de Van der Hoven [3]

- A zona macrometeorológica, associada a frequências baixas (correspondendo a períodos da ordem de alguns dias) e relacionada com movimento de grandes massas de ar, tipo depressões ou anti-ciclones.
- A zona micrometeorológica, associadas a frequências mais elevadas (correspondendo a períodos da ordem de poucos segundos) e relacionada com a turbulência atmosférica.
- A zona de vazio espectral, associada a períodos compreendidos aproximadamente entre 10 minutos e 2 horas, relacionada com zonas do espectro correspondentes a muito pouca energia.

A existência da zona de vazio espectral, contendo muito pouca energia associada, permite tratar separadamente as duas componentes características do vento, e encarar a turbulência como uma perturbação ao escoamento quase-estático caracterizado por uma velocidade média. Matematicamente, a função velocidade pode ser representada por:

$$u(t) = \bar{u} + u'(t). \quad (1)$$

A velocidade média é calculada com base num período que caia dentro do vazio espectral, tipicamente entre 10 minutos e 2 horas, e represente o regime quase-estático.

2.2 A Sazonalidade do Recurso

A velocidade do vento varia constantemente, de forma que, usualmente, recorre-se a ferramentas estatísticas para se descrevê-lo. Ao longo dos últimos anos tem sido sugeridas várias distribuições probabilísticas para descrever o regime de ventos, mas a distribuição de *Weibull* tem sido tradicionalmente considerada como a mais adequada.

A modelação da velocidade de vento recorrendo-se à distribuição de *Weibull* é feita pela estimação de dois parâmetros A e k, que permitem representar a variação média do vento. Estes dois parâmetros são designados por “fator de escala” e “fator de forma”. A Equação 2 descreve a fração de tempo em que a velocidade média do vento hora a hora excede a velocidade U, o parâmetro A corresponde ao fator de escala que está relacionado com a velocidade média anual e o parâmetro k ao fator de forma que descreve a variabilidade em torno da média.

$$f(\bar{u}) = \frac{k}{A} \left(\frac{\bar{u}}{A}\right)^{k-1} \exp\left\{-\left[\left(\frac{\bar{u}}{A}\right)^k\right]\right\}. \quad (2)$$

Os parâmetros A e k podem ser estimados recorrendo a medições da velocidade de vento durante longos períodos de tempo, sendo que as variações mais significativas ocorrem durante um ano. O impacto da variação destes parâmetros na distribuição de *Weibull* está

representado na Figura 3, onde se pode observar que a influência do parâmetro k se relaciona essencialmente com o desvio padrão, que pode ser entendido como a medida da dispersão da velocidade do vento no local. Fixando o parâmetro A e aumentando o parâmetro k , como são os casos de $A=8$ m/s, $k=1,5$ e $k=2,2$ (gráfico verde e laranja), verifica-se um aumento ligeiro da velocidade média anual e um decréscimo significativo do desvio padrão. Por outro lado, a variação do parâmetro A influencia a média anual estando relacionado com a disponibilidade do vento no local. Fixando o parâmetro k e aumentando o parâmetro A , como são o caso de $A=6$ m/s, $A=8$ m/s e $k=2$ (gráfico azul e ciano), verifica-se um aumento da banda de variação de velocidade e do desvio padrão, implicando um decréscimo de confiança.

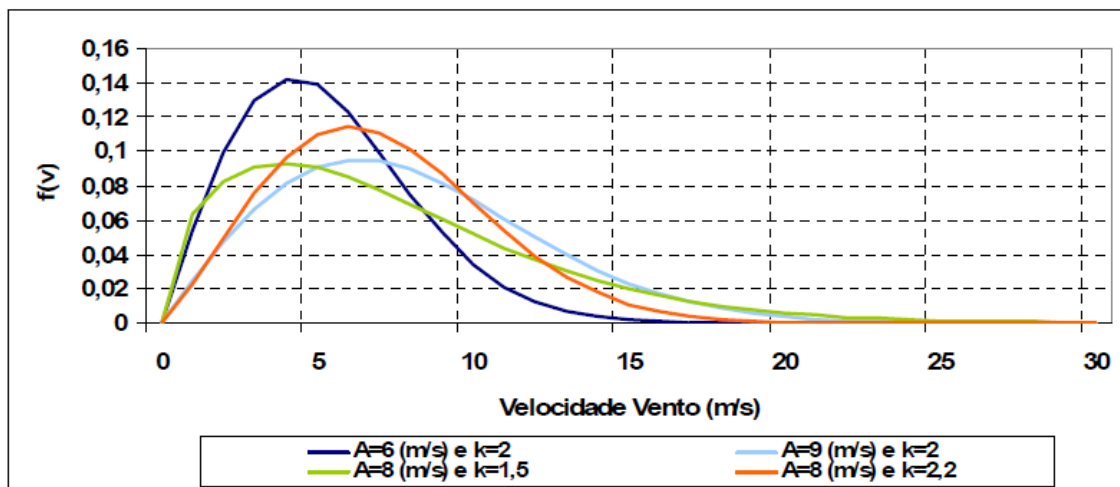


Figura 3 – Variação dos parâmetros de Weibull

A distribuição de Weibull das velocidades médias de vento hora a hora para um ano apresenta um grau considerável de variação aleatória. No entanto, existe uma componente forte de sazonalidade subjacente a estas variações, proveniente das mudanças de insolação durante o ano, em consequência da inclinação da linha de rotação da terra. Sendo assim, os meses de Inverno tendem a apresentar uma intensidade de vento maior do que os meses de Verão. Nos equinócios de Primavera e Outono existe maior probabilidade de ocorrerem ventos fortes e vendavais [4].

Na prática os dados são colhidos em intervalos regulares de alguns minutos até horas, constituindo-se um conjunto discreto de informações. Dessa forma, tem-se distribuições discretas da velocidade média do vento em classes de 1 m/s, pelo que a velocidade média anual se calcula, de forma aproximada por:

$$U_{ma} = \sum_{\bar{u}=0}^{\bar{u}_{m\acute{a}x}} \bar{u} f(\bar{u}). \quad (3)$$

E a distribuição de *Weibull* acaba por se apresentar como uma função contínua que se adequa à tendência da distribuição dos dados:

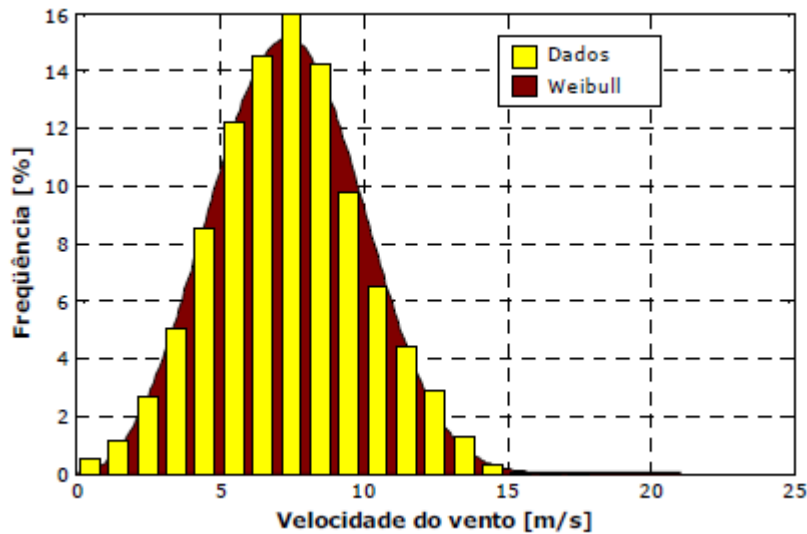


Figura 4 – Adequação da distribuição de *Weibull* aos dados medidos [5]

2.3 A Transformação de Energia

O movimento da massa de ar disponibiliza energia cinética que pode ser descrita por,

$$E = \frac{1}{2} \cdot \rho \cdot U^2. \quad (4)$$

Em que ρ corresponde à densidade volumétrica do ar e U à velocidade do vento não perturbada à altura do rotor da máquina. A potência pode ser obtida, multiplicando a energia pela área de passagem do ar e pela sua velocidade. Sendo assim a equação seguinte ilustra a expressão da potência mecânica:

$$P = \frac{1}{2} \cdot \rho \cdot A \cdot U^3 \quad (5)$$

Como se pode verificar pela Equação 5 a velocidade do vento é uma componente preponderante no valor da potência, dado que depende fortemente da velocidade, razão cúbica desta. Esta dependência acentua-se na zona não linear da curva, dado que uma pequena variação na velocidade de vento pode provocar uma grande variação na produção de um aerogerador e por consequência no parque eólico, pelo que é primordial na previsão da produção elétrica de parques eólicos a otimização dos parâmetros do modelo de previsão para esta zona da curva de potência.

A curva de potência representada na Figura 5, além de evidenciar a forte dependência da variação da potência face à variação da velocidade, também representa as zonas de *cut-in*, *cut-off* e *rated-speed*. Sendo a zona de *cut-in* definida pela zona compreendida entre 0 e 4 m/s que corresponde à zona de arranque do aerogerador. Na zona *cut-off*, o aerogerador, por questões de segurança relacionadas com os esforços mecânicos a que fica sujeito, é obrigado a parar por ação de tais esforços mecânicos ou procedem a um controle da velocidade de rotação. Este cenário ocorre para velocidades de vento superiores a 25 m/s. Denomina-se por *rated-speed* a velocidade de vento que permite obter uma potência próxima da nominal, normalmente 15 m/s.




Figura 5 – Curva de Potência da Turbina Impsa IV – 77 [6]

A potência elétrica, expressa na Equação 6 é obtida através da potência mecânica e do C_p , o coeficiente de *Betz*, que representa o limite de extração da energia do vento. As turbinas atingem normalmente valores máximos compreendidos entre 0,4 e 0,5, o que representa um rendimento na ordem dos 65% a 85%.

$$P_{el} = \frac{1}{2} \cdot C_p \cdot \rho \cdot A \cdot U^3 \quad (6)$$

A Figura 6 ilustra a curva do coeficiente C_p de um modelo de aerogeradores da Vestas, o V39. Este coeficiente depende do tipo de máquina e das condições de controle da mesma. Como se pode verificar para o modelo de aerogerador apresentado, as velocidades de vento que apresentam maior extração de energia estão compreendidas entre 6 e 12 m/s, para este modelo em particular. Os aerogeradores atuais têm um valor máximo para C_p de cerca de 45%.




Figura 6 – Curva Cp – Turbina Vestas V39 [7]

2.4 Redes Neurais Artificiais (RNAs)

As redes neurais artificiais (RNA) são modelos de processamento de informações inspirados na estrutura física natural do cérebro humano. Elas são conceitualmente sistemas paralelos, não lineares e distribuídos, compostos por unidades de processamento simples (neurônios). Essas unidades, por sua vez, estão dispostos em estruturas interligadas por um número de conexões (sinapses). Dentre as características inerentes às redes neurais, a principal é a capacidade de se adaptar a novas situações. Em diversas situações redes neurais são empregadas para classificar padrões. [9]

A pesquisa em RNAs começou na década de 1940 e se deu utilizando circuitos lógicos baseados em arquiteturas biológicas de neurônios de forma a realizarem trabalhos computacionais. Entretanto, após a publicação do livro Perceptrons em 1969 por Minsky e Papert, que mostravam as deficiências nos modelos e direcionamento das pesquisas até então, houve uma fuga de cientistas que trabalhavam na área.

O aumento de poder de processamento computacional e novas descobertas de alguns pesquisadores que se mantiveram na área reacendeu o interesse pelas RNAs no começo dos anos 80 e hoje em dia é objeto de interesse dos mais variados grupos de pesquisa em vários centros de estudo e pesquisa ao redor do mundo.

Redes Neurais Artificiais podem ser mais adequadamente caracterizadas como 'modelos computacionais' com propriedades particulares tais como a habilidade de adaptar-se e aprender, generalizar, agrupar ou organizar dados e na qual a operação é baseada em processamento paralelo. Entretanto, muitas das características mencionadas acima podem ser atribuídas a

modelos 'não-neurais' existentes; a questão mais intrigante é até que nível a abordagem neural apresenta-se mais adequada para certas aplicações do que os modelos existentes. Até hoje não existe uma resposta para essa pergunta [8].

2.4.1 A unidade básica de processamento

Corroborando a visão inicial de uma rede neural biológica, a unidade fundamental básica de uma RNA é o neurônio, cujo modelo é apresentado na figura abaixo.

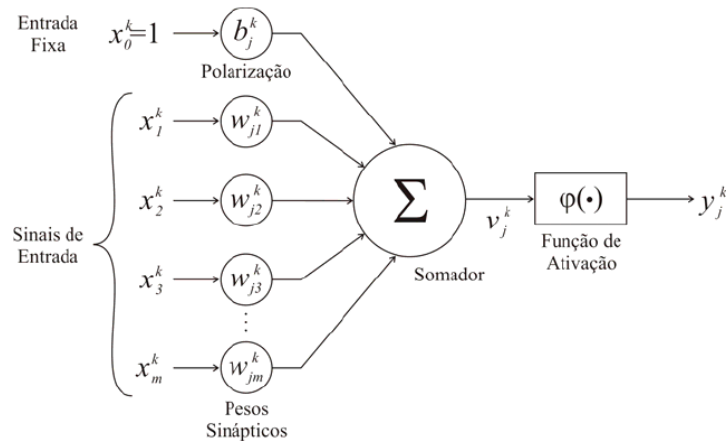


Figura 7 - Modelo de um neurônio numa RNA

Existem três elementos fundamentais na estrutura do neurônio [9]:

- Um conjunto de sinapses ou conexões, caracterizadas individualmente por um peso sináptico w_{ji}^k , que indica a importância do sinal de entrada i na determinação da saída do neurônio j da camada k .
- Um somador, que tem a função de realizar uma combinação linear dos sinais de entrada ponderada pelos respectivos pesos sinápticos de suas ligações.
- Uma função de ativação que adequa a amplitude da saída a um intervalo normalizado, geralmente $[0,1]$ ou $[-1,1]$.

O modelo do neurônio também inclui um termo denominado de polarização representado por b_{kj} , cujo efeito é modificar a entrada da função de ativação, através da aplicação de um sinal de entrada com valor fixo normalmente igual a $+1$. Dessa forma, o bias acaba tornando-se uma entrada adicional que possui um peso diferenciado, direcionando a saída para valores superiores ou inferiores aos que teriam sem sua presença.

Matematicamente, a saída do neurônio y_{kj} é representada pela seguinte equação:

$$y_j^k = F_j^k (b_j^k + \sum_{i=1}^{I_k} w_{ij}^k \cdot x_i^k) \quad (7)$$

onde I_k representa o número de entradas da camada. A função F é geralmente uma função sigmoideal, a exemplo da tangente hiperbólica.

Uma camada é formada por um conjunto de neurônios que formam o corpo da rede. Após passar por cada neurônio, as saídas destes tornam-se entradas para neurônios de uma camada subsequente e assim por diante até a saída final, que terá como resultado a codificação dos dados de entrada em classes definidas.

2.4.2 Treinamento, Validação e Teste: As etapas de configuração de uma RNA

Após uma rede neural ter sido criada, ela precisa ser configurada e então treinada. Configuração envolve manipulação da rede para que ela seja compatível com o problema que você deseja resolver, como é definido pelos dados das amostras. Depois de a rede ter sido configurada, o ajuste dos parâmetros da rede, chamados de pesos e biases, precisam ser ajustados, de forma que a performance da rede seja otimizada. Esse processo de ajuste é conhecido como o treinamento da rede.

Dessa forma, os procedimentos que fazem parte das etapas de configuração da RNA com aprendizado supervisionado são os seguintes:

- **Treinamento:** Nesse processo, os pesos das entradas das sinapses neurais são inicializados com valores aleatórios e a rede então interage. Sabendo-se o resultado esperado da base de dados de entrada, calcula-se então um erro que é realimentado na rede. Dependendo do processo de treinamento, sem retroalimentação (no qual os dados seguem um fluxo contínuo da entrada para saída) ou com retroalimentação (onde os dados seguem em direção a saída e retornam com o erro corrigindo a rede de trás para frente), a rede corrige-se a partir do cálculo de um erro que é alimentado nas sinapses na interação seguinte. Essas interações são chamadas de épocas. É no treinamento que ocorre a aprendizagem da rede neural.
- **Validação:** Nesta etapa a rede avalia o desempenho do processo de aprendizagem e generalização, para que seja certificado que ela está aprendendo a classificar as classes desejadas e não 'decorando' padrões, tornando-se ineficiente em classificar corretamente dados que sejam levemente diferentes da base de dados disponível, e assim, perdendo a capacidade de generalização.
- **Teste:** Nessa fase final, que só ocorre após o treinamento e a validação, a RNA está pronta para ser utilizada e são empregados dados de entrada previamente separados para certificar de que a rede possui uma boa taxa de acerto a partir de informações de parâmetros de entrada.

Ainda existem redes capazes de separar dados em classes sem um conjunto definido de entradas e saídas. São as redes não-supervisionadas. Elas agrupam conjuntos de dados em classes que possuem características semelhantes e não necessitam de um vetor de saída

indicando as saídas esperadas, a ser utilizado no processo de treinamento. Esse processo é conhecido por clusterização (do inglês cluster = aglomerar).

2.4.3 Aquisição de Parâmetros

Para resolver um determinado problema através de uma RNA, faz-se necessário que a mesma possua uma base de dados sólida e bem desenvolvida e que, principalmente, possua informações relevantes sob os aspectos únicos de cada classe a ser identificada pelo algoritmo.

Esse é um passo primordial e que deve ser realizado antes da configuração da RNA. Essa aquisição de parâmetros nada mais é que a extração de informações que servirão de entrada para cada neurônio e sua qualidade é determinante para o sucesso da rede.

3. Materiais

3.1 O aerogerador

O modelo de aerogerador especificado para o local do empreendimento foi o S88 2,1 MW da *Suzlon*. Tal máquina possui classe IEC II-A. É constituída de um rotor de três pás, com diâmetro de 95 m e eixo horizontal de concepção *upwind* (o rotor opera na frente da torre), fixado numa *nacelle* (cabine localizada no topo da torre e atrás das pás) que, além de suporta-lo, abriga o sistema de conversão de energia em si. Todo o conjunto está localizado em cima de uma torre de 90 m de altura fixada ao solo por meio de uma fundação de concreto armado. As principais dimensões do aerogerador são apresentadas na Figura 8.




Figura 8 – Principais dimensões do aerogerador S88 *Suzlon*

Todo o controle operacional da máquina, dos parâmetros elétricos da energia produzida e procedimentos de proteção são feitos automaticamente a partir de um sistema de controle computadorizado (inclui os sistemas de supervisão, proteção e controle – SCADA) abrigado na parte inferior e interna da torre metálica e que recebe informações dos diferentes sensores instalados em vários locais da máquina.

Os principais componentes formadores da turbina *Suzlon* S88-2,1MW são: a torre, a *nacelle* e o rotor. A torre abriga o sistema de cabeamento, controle e proteção da turbina, além propiciar a realização das inspeções e manutenções requeridas a operação da mesma. A Figura 9 esquematiza os principais equipamentos eletromecânicos abrigados na *nacelle* da turbina *Suzlon* S88-2,1MW:




Figura 9 – Componentes da nacelle – Turbina S88 Suzlon

.Acima da *nacelle* existem dispositivos de medição de velocidade e direção do vento que fornecem dados para o sistema que controla o ângulo de inclinação das pás (*pitch*) e o sistema *Yaw*, responsável por direcionar o plano do rotor a posição perpendicular a direção do vento. Foi desta medição que provieram os dados utilizados neste trabalho.

A velocidade de vento mínima para o início da geração é de 3,5 m/s e a máxima, de 25 m/s. O formato do rotor é otimizado para atingir a melhor condição aerodinâmica e de desempenho acústico, e o ângulo de ataque das mesmas pode ser ajustado através do sistema *pitch*, com a ajuda de motores elétricos, buscando as melhores condições de controle e segurança do sistema.

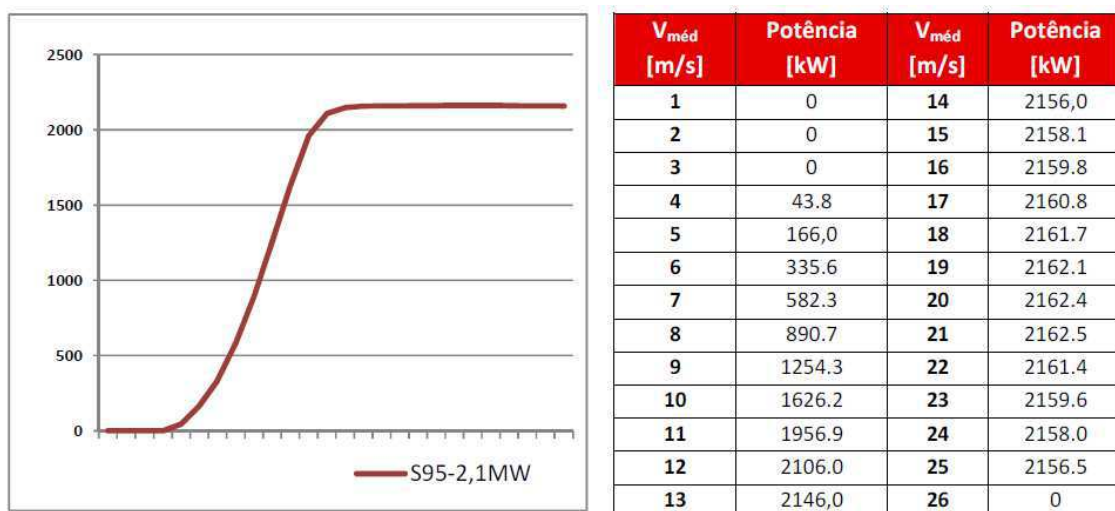
O gerador assíncrono tem como características nominais 2.100kW de potência, tensão de 600 V, 4 polos, 1800 rpm, escorregamento máximo de 20%. Cada aerogerador conta com um banco de capacitores chaveáveis (14 ao todo), permitindo que a máquina opere entre 0,94 (ind) < $\cos(\varphi)$ < 0,94 (cap). A máquina possui a tecnologia DFIG (*Doubly Fed Induction Generation*), ou Geração por Indução Duplamente Alimentada, o Sistema CONCYCLE de conversão de energia, da *Woodward*. Tal sistema possui, resfriamento a líquido e uma perda limitada pelo máximo de 18 kW.

3.2 Curva de Potência

A curva de potencia de uma turbina eólica é um gráfico que indica a potencia elétrica de saída para cada velocidade de vento diferente. Estas curvas são definidas a partir de medições em campo, por meio de um sistema anemométrico posicionado sobre a turbina eólica. Como há variações climáticas significativas entre os diferentes sítios, os fabricantes disponibilizam tabelas de curvas de potência para diversas massas específicas do ar.

Os dados da curva de potencia para a turbina *Suzlon S88-2,1MW*, para a massa específica do ar típica da área de implantação da usina, são apresentados na Tabela e Figura, a seguir:

Tabela 1 – Valores da Curva de Potência da Turbina S88 Suzlon



A curva de potência garantida pelo fabricante e utilizada em *softwares* específicos, como: *WAsP*, *WindPro* e *WindFarmer*, para efetuar cálculos e determinar a estimativa de geração anual de energia em GWh (através de *micrositing* – posicionamento das turbinas na área). Além desta curva, são utilizados os dados de ventos medidos no local, informações de rugosidade e topografia.

3.3 Software

Os dados foram obtidos através do sistema SCADA que gera um relatório contendo os seguintes dados:

- Velocidade média do vento nos últimos 10 minutos expressa em m/s.
- Posição da *nacelle* em graus orientados com o norte geográfico
- Potência ativa média gerada nos últimos 10 minutos expressa em MW.

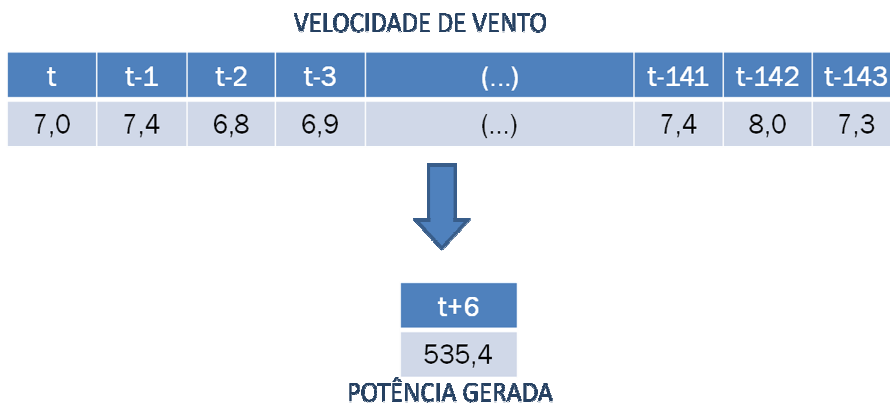
Para o tratamento desses dados foi utilizado MATLAB®. O software foi utilizado para adequar os dados à uma configuração numérica mais propícia ao trabalho com RNA bem como para a implementação propriamente dita da rede. Todos os códigos encontram-se na seção de Anexos deste trabalho.

4. Métodos

4.1 Base de dados

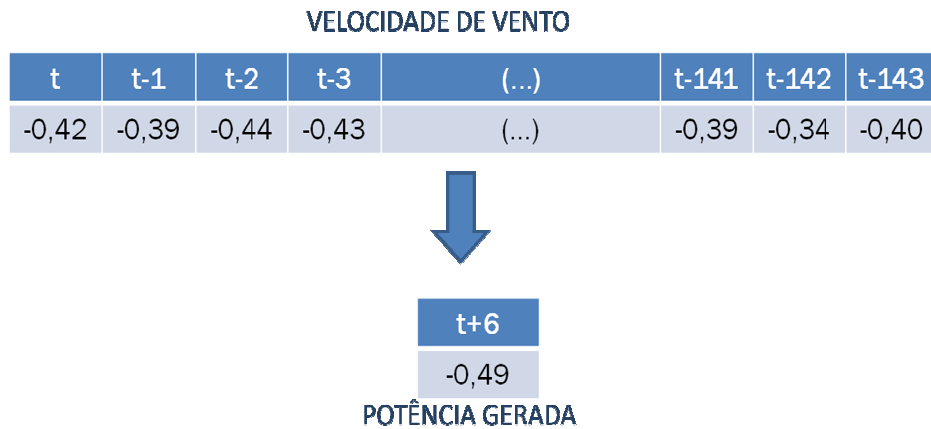
Do vento provém a força motriz para o acionamento da turbina. Dessa forma, tal variável é primordial como dado de entrada da rede. De acordo com [10] existe uma dependência estatística considerável do valor do vento atual com seus valores passados. Assim, definiu-se que a base de dados seria formada por padrões constituídos pelo valor do vento em um instante “t” e pelos valores passados referentes a um dia de medição, ou seja, os valores de t-1, t-2, t-3,...t-143.

Os valores de velocidade de vento seriam apresentados à rede visando uma previsão de potência *a posteriori* de uma hora antecedência. O formato dos dados de entrada é melhor elucidado pela Figura ???



Entretanto, inserir na rede valores de velocidade para que a mesma aponte para um valor de potência pode gerar inconsistências numéricas uma vez que as grandezas das variáveis de entrada e de saída são diferentes, enquanto as velocidades são dadas em poucas dezenas de m/s, a potência disponível é da ordem milhares de kilo-watts.

A fim de contornar esse problema recorreu-se a uma rotina implementada no MATLAB que redistribuía cada conjunto em um novo conjunto compreendido em um intervalo de -1 a 1 que possuía a média igual a zero e o desvio padrão 1. Assim, tanto velocidade de vento como potência gerada possuíam as mesmas características estatísticas.



4.2 Configurações das arquiteturas da RNAs utilizadas

Dentre as diversas arquiteturas de RNA, destacam-se como as mais difundidas as redes Perceptron de Múltiplas Camadas ou redes MLP, como são comumente conhecidas. Elas representam uma generalização do perceptron de camada única. [11]

Tipicamente uma rede MLP consiste de uma camada de entrada constituída de unidades sensoriais, uma ou mais camadas ocultas e uma camada de saída, todas conectadas, conforme mostrado na figura abaixo:




Figura 10 - Arquitetura de uma rede MLP [10]

A camada sensorial da rede foi elaborada com 144 entradas de forma a se adequar com os padrões de entrada. O número de neurônios da camada sensorial foi modificado diversas vezes de acordo com o progresso da elaboração da rede, visando o melhor desempenho possível. Para chegar à versão final a elaboração da rede passou por três configurações diferentes:

Caso 1

No Caso 1 pretendeu-se criar uma rede na qual fossem inseridos os padrões de vento conforme apresentado na seção anterior e que apresentassem na saída 21 neurônios que, combinados, representavam 21 níveis diferentes discretos de potência compreendidos de -1 a 1 em intervalos de 0,1. Para isso, a informação percorria uma camada oculta de 200 neurônios, seguindo a recomendação de [11] formular a camada escondida com algo entorno do dobro de neurônios da camada sensorial.

A camada de saída foi modificada de forma que ao neurônio com maior valor fosse atribuído o valor 1 e todos os outros zerados. O erro e, conseqüentemente, a realimentação foram calculados tendo em vista esta resposta. A tabela abaixo demonstra a relação entre a combinação dos neurônios sua saída e o nível de potência que os mesmos representam:

Tabela 2 – Representação dos níveis de potência encontrados nas 20 saídas.

Saída da RNA	Nível representado
00000000000000000001	-1
00000000000000000010	-0,9
00000000000000000100	-0,8
00000000000000001000	-0,7
00000000000000010000	-0,6
00000000000000100000	-0,5
00000000000001000000	-0,4
00000000000010000000	-0,3
00000000000100000000	-0,2
00000000001000000000	-0,1
00000000010000000000	0
00000000100000000000	0,1
00000001000000000000	0,2
00000010000000000000	0,3
00000100000000000000	0,4
00001000000000000000	0,5
00010000000000000000	0,6
00100000000000000000	0,7
01000000000000000000	0,8
10000000000000000000	0,9
10000000000000000000	1

Os resultados desta configuração podem ser encontrados na seção Resultados. No intuito de minimizar os problemas encontrados, foi proposta a configuração do Caso 2

Caso 2

A fim de minimizar os entraves descritos no Caso 1 foram tomadas três decisões:

- Diminuir a quantidade de neurônios na camada oculta.

- Discretizar a saída de forma a fornecer a mesma resposta dividida agora em 4 neurônios.
- Modificar os padrões de entrada para que também contivessem informações da potência gerada em instantes passados.

Assim foram testadas configurações com os neurônios na camada oculta variando entre 4 e 20 e as respostas esperadas foram arredondadas agora para se enquadrassem em 4 níveis diferentes da saída compreendidos entre -1 e 1 em intervalos de 0,1. A diminuição dos níveis de saída representa uma diminuição da precisão da previsão, um aspecto assumido por este trabalho.

Além da informação referente ao regime de vento também foi inserido na base de dados uma entrada contendo a média aritmética da potência gerada em t-144, t-288, t-432, t-576, ou seja, foi fornecida à rede a média da potência gerada em um dado momento do dia nos quatro últimos dias.

A tabela abaixo é um resumo desta representação:

Tabela 3 - Representação dos níveis de potência encontrados nas 4 saídas.

Saída da RNA	Nível representado
0001	-1 <= resposta < -0,5
0010	-0,5 <= resposta < 0
0100	0 <= resposta < 0,5
1000	0,5 <= resposta <= 1

Os resultados obtidos podem ser encontrados na seção seguinte.

Caso 3

No Caso 3 a discretização da saída em 4 níveis diferentes foi substituída por uma discretização em 2 níveis diferentes. Rearranjar 4 respostas em 2 ainda fornece uma solução razoável para a programação da manutenção nos parques eólicos pois afirma se na hora seguinte haverá uma produção considerável de energia que não poderia ser desperdiçada. Dessa forma, incorre-se em uma perda admissível de informação. A nova formatação da saída está resumida na tabela abaixo:

Tabela 3 - Representação dos níveis de potência encontrados nas 2 saídas.

Saída da RNA	Nível representado
0	-1 <= resposta < =0
1	0 < resposta < 1

Os resultados desta configuração estão dispostos na próxima seção.

5. Resultados

Caso 1

Para esta configuração a rede apresentou uma taxa de acertos em torno dos 50 % e evolução dos erros de treinamento e validação conforme apresentado nas figuras e tabela abaixo:




Figura 10 – Erros de Treinamento e Validação para o Caso 1 por número de iterações.




Figura 11 – Detalhe das curvas dos erros de Treinamento e Validação para o Caso 1 por número de iterações.

Tabela 4 – Acertos de previsão para o Caso 1

Execução	1	2	3	4	5	6	7	Média
Acertos	49,53%	50,21%	52,17%	47,87%	46,98%	47,76%	52,64%	49,59%

Os resultados podem ser explicados pela combinação de um volume intenso de informações condensado em uma saída de dimensão dez vezes inferior à da camada oculta. Tal gama de informações após passar por uma série de multiplicações e somas cria uma tendência da rede a apontar para os valores máximos e mínimos de saída configurando-se uma saturação. Este comportamento é tal que a retroalimentação foi incapaz de superar. O decaimento dos erros de treinamento e validação nas primeiras iterações e a manutenção destes valores pela maior parte das iterações seguintes sugerem que os resultados obtidos expressam as melhores previsões possíveis com a topologia em questão, de forma que não seria possível extrair melhor desempenho da configuração adotada. No intuito de minimizar tais problemas foi proposta a configuração do Caso 2

Caso 2

Os melhores resultados obtidos para a configuração do Caso 2 (4 neurônios na camada oculta e 4 na camada de saída) podem ser encontrados nas figuras e tabela a seguir:




Figura 12 – Erros de Treinamento e Validação para o Caso 2 por número de iterações.




Figura 13 – Detalhe das curvas dos erros de Treinamento e Validação para o Caso 2 por número de iterações.

Tabela 5 – Acertos de previsão para o Caso 2

Execução	1	2	3	4	5	6	7	Média
Acertos	59,49%	57,64%	57,24%	57,23%	57,85%	57,98%	56,78%	57,74%

Pode-se perceber um claro decaimento dos erros de treinamento e validação além de grande diminuição de saturação por parte da rede. Entretanto, o número de acertos ainda é baixo. Uma das principais razões reside no fato de os dados não terem sido coletados por um sistema que não visa a análise científica acurada, mas sim por um sistema cuja precisão é limite para a operação e manutenção do parque, e que apontamento, principalmente, eventos macros e isolados, diferentemente daqueles que são alvo deste estudo. Sendo assim, abriu-se mão da precisão mais apurada e foi sugerida a configuração do Caso 3.

Caso 3

Os resultados finais são resumidos pelas figuras e tabela a seguir:




Figura 14 – Erros de Treinamento e Validação para o Caso 3 por número de iterações.




Figura 15 – Detalhe das curvas dos erros de Treinamento e Validação para o Caso 3 por número de iterações.

Tabela 6 – Acertos de previsão para o Caso 3.

Execução	1	2	3	4	5	6	7	Média
Acertos	75,58%	75,46%	75,66%	75,69%	75,71%	75,45%	75,65%	75,60%

Diante da baixa qualidade dos dados utilizados e da pouca representatividade sazonal (2 anos) o algoritmo das RNAs demonstrou sua robustez ao gerar com razoável segurança (75,60%) a previsão de que a hora seguinte será de alta geração ou de baixa geração. Para a

programação de despacho de energia bem como para a programação de manutenções não é necessário o conhecimento exato da potência que será gerada. Em vez disso, uma indicação da tendência de geração já seria suficiente para a tomada de decisões.

6. Conclusões

A previsão de potência de parques eólicos tem se tornado de suma importância no cenário mundial pois permite maior controle do uso dos recursos de geração, em sua maioria, carvão, gás e combustível nuclear. No que diz respeito ao panorama nacional, a previsão para um curto espaço de tempo visa o auxílio no despacho de potência uma vez que o sistema interligado exige a coordenação da fonte principal (hidrelétrica) com as fontes secundárias (eólica, solar e térmica).

O alto grau de aleatoriedade do vento constitui-se uma barreira desafiadora à previsão e ao tratamento estatístico de forma que, assim como outras variáveis meteorológicas, uma previsão de com acerto de 70% já é tida como razoável.

No trabalho apresentado, o acerto das previsões rondou os 75% demonstrando consistência e robustez da utilização das RNAs. Entretanto, diferentemente da maioria dos casos cuja classificação é posta a cargo de uma Rede Neural, a captação de dados para a previsão de vento não é feita através de experimentos controlados pelo pesquisador mas sim provém de um sistema de monitoramento que armazena os parâmetros ao longo de anos. Assim a precariedade com que os dados são colhidos inserem erros e inconsistências que mascaram os atributos estatísticos que deveriam ser acentuados pela rede. Além do mais, a falta de dados que expressem a sazonalidade anual é um entrave para um maior percentual de acerto.

Uma possível melhora do desempenho da ferramenta aqui proposta seria o tratamento dos dados de vento e potência por filtros digitais que minimizassem os erros sistêmicos embutidos nas coletas, além de um intervalo de tempo maior para a coleta dos dados o que poderia inserir na rede mais informações referentes às mudanças anuais do regime de vento. Outra alteração possível seria a variação do número de camadas ocultas, dando assim meios para que a rede reagisse melhor à introdução de intenso volume de dados.

Considerando-se assim, o cenário no qual o trabalho foi desenvolvido pode-se atestar a utilização das RNAs como ferramenta eficiente na previsão de potência através dos dados de ventos passados.

7. Referências bibliográficas

- [1] Wenzel, G. M. – Wind Farm’s Desing – GL Garrad Hassan 2012
- [2] Van der Hoven, Isaac, 1957: POWER SPECTRUM OF HORIZONTAL WIND SPEED IN THE FREQUENCY RANGE FROM 0.0007 TO 900 CYCLES PER HOUR. J. Meteor., 14, 160–164.
- [3] Castro, R. M. – Introdução a energia Eólica, 1ª Ed., Lisboa: Universidade Técnica de Lisboa.
- [4] Sousa, J. N. M – “PREVISÃO DA PRODUÇÃO ELÉTRICA EM PARQUES EÓLICOS”, Dissertação de Mestrado, Porto, 2007.
- [5] Farias, C. S. – Relatório Técnico Interno Braselco.
- [6] Catálogo IMPSA – Turbina IV 77
- [7] Catálogo Vestas – Turbina V39
- [8] B. Krose e P. v. d. Smagt, An Introduction To Neural Networks, 8ª ed., Amsterdam: The University of Amsterdam, 1996.
- [9] T. V. Ferreira, “ESTIMAÇÃO INTELIGENTE DA POLUIÇÃO DE ISOLAMENTOS ELÉTRICOS BASEADA NOS VECSE DO RUÍDO ULTRASSÔNICO,” Tese de Doutorado, Campina Grande, 2011.
- [10] Rodrigues, G. C., “UTILIZAÇÃO DE REDES NEURAIIS PARA PREVISÃO DE VENTOS NO HORIZONTE DE 24 HORAS”, Dissertação de Mestrado, Rio de Janeiro, 2007
- [11] Haykin, S. “Redes neurais, princípios e prática”. 2ª. Ed. Porto Alegre: Bookman, 2001.