



ISSN 2175-6295 Rio de Janeiro- Brasil, 12 e 13 de agosto de 2010

PREVISÃO DA VELOCIDADE DO VENTO COM SISTEMA DE INFERÊNCIA NEURO-FUZZY ADAPTATIVO

José Francisco Moreira Pessanha

UERJ – Universidade do Estado do Rio de Janeiro
Departamento de Estatística – Instituto de Matemática e Estatística Sala 6028-B
Rua São Francisco Xavier, 524 – Maracanã 20550-900, Rio de Janeiro – RJ
professorjfm@hotmai.com

Ilitch Vitali Gomes da Silva

PUC-RJ – Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Elétrica
Rua Marquês de São Vicente 225, Gávea 22451-041, Rio de Janeiro - RJ
ilitchsilva@yahoo.com.br

Reinaldo Castro Souza

PUC-RJ – Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Elétrica
Rua Marquês de São Vicente 225, Gávea 22451-041, Rio de Janeiro - RJ
reinaldo@ele.puc-rio.br

Resumo

Com o advento da energia eólica, a operação de sistemas elétricos deverá dispor de modelos que forneçam previsões do montante de energia elétrica gerada nas fontes eólicas com a finalidade de proporcionar uma integração segura e econômica dos parques eólicos na programação do despacho da geração. Neste trabalho é descrita a aplicação de um sistema de inferência neuro-fuzzy adaptativo (ANFIS) na previsão de curto-prazo da velocidade do vento, o dado de entrada para a previsão da potência eólica gerada. Para ilustrar a aplicação da metodologia foram consideradas as medições anemométricas realizadas em São João do Cariri, um município situado na região central do Estado da Paraíba, onde se localiza uma das estações anemométricas do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais).

Palavras-chave: energia eólica, velocidade do vento, previsão, sistemas neuro-fuzzy

Abstract

With the advent of wind power, the operation of the electrical systems should have forecasting models of the amount of electricity generated by the wind sources in order to provide a safe and economical integration of wind farms in the generation scheduling. This work describes an application of the *adaptive neuro-fuzzy inference system* (ANFIS) in the short-term forecasting of wind speed, the input data for prediction of the wind power generated. In order to illustrate the application of the methodology were considered the wind speed measurements performed by an anemometric station of the SONDA project (National

Organization System of Environment Data) at São João do Cariri, a municipality located in the central region of the state of Paraíba.

Key-words: Wind energy, Wind speed, forecasting, neuro-fuzzy

1. INTRODUÇÃO

A energia cinética do vento ou energia eólica é um recurso natural limpo, abundante e inesgotável e o seu aproveitamento para produção de energia elétrica é uma das alternativas mais promissoras para reduzir as emissões dos gases do efeito estufa e mitigar os efeitos de crises no mercado de combustíveis fósseis. No entanto, a geração eólica é intermitente e à medida que a energia eólica ganha participação na matriz energética é fundamental que a operação do sistema elétrico disponha de modelos que forneçam previsões do montante de energia elétrica gerada nas fontes eólicas com a finalidade de proporcionar uma integração segura e econômica dos parques eólicos na programação do despacho da geração.

Para ilustrar a relevância do tema destaca-se o projeto ANEMOS (Kariniotakis et al, 2004), que reúne 22 organizações de 7 países europeus com o objetivo de desenvolver modelos apropriados para a previsão de curto-prazo (até 48 horas à frente) da geração eólica *onshore* e *offshore*.

A relação entre a potência gerada P e a velocidade do vento v é graficamente representada na curva de potência ilustrada na Figura 1.

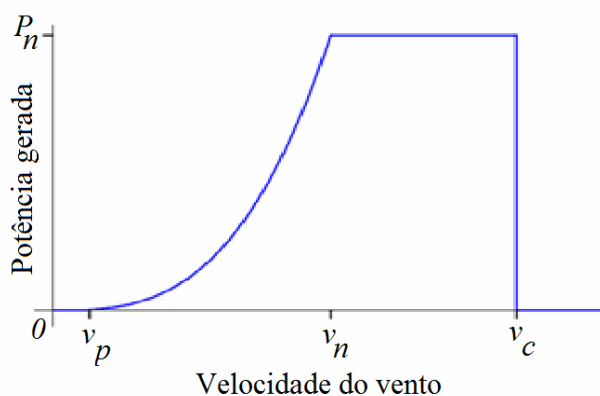


Figura 1 – Curva de potência típica de uma turbina eólica

Conforme indicado pela curva de potência na Figura 1, a conversão de energia eólica em energia elétrica se dá a partir de uma velocidade mínima denominada velocidade de partida v_p (*cut-in wind speed*). A potência da turbina é limitada ao valor nominal P_n , à velocidade nominal v_n (*rated wind speed*). Para velocidades entre v_p e v_n a potência elétrica P gerada pela turbina eólica cresce com o cubo da velocidade do vento v transversal à área A varrida pelo seu rotor (Custódio, 2009):

$$P = 0,5 \cdot C_p \cdot \eta_m \cdot \eta_g \cdot \rho \cdot A \cdot v^3 \quad (1)$$

onde η_m é o rendimento mecânico da caixa de transmissão, η_g é o rendimento do gerador, ρ é a densidade do ar e C_p é o coeficiente de potência da turbina, que expressa a parcela (%) da potência disponível no vento que é extraída pela turbina.

A partir da velocidade nominal o controle de velocidade da turbina mantém a potência gerada constante até que para velocidades superiores à velocidade de corte v_c (*cut-out wind speed*) a turbina é retirada de operação para preservá-la de esforços mecânicos excessivos (Custódio, 2009).

A equação (1) indica que para prever a potência eólica gerada pode-se começar pela previsão da velocidade do vento. O modelo de persistência é o método mais simples para prever a

velocidade do vento e consiste em estimar a velocidade no instante $t+x$ como sendo a mesma do instante t . Naturalmente, a acurácia deste modelo decresce rapidamente à medida que o horizonte de previsão é aumentado. Em virtude da deficiência do modelo de persistência várias modelos para previsão de curto prazo da velocidade do vento têm sido desenvolvidos. Usualmente estes modelos são classificados em duas categorias: modelos físicos e modelos de séries temporais (Giebel et al, 2003, Wu & Hong, 2007).

Os modelos físicos são baseados em uma descrição detalhada do terreno onde está instalado o parque eólico (por exemplo, a orografia e a rugosidade do solo), das turbinas eólicas (altura do cubo da turbina) e do *layout* do parque com a localização das turbinas. Esta categoria de modelos abrange métodos numéricos para previsão climática (*numeric weather prediction - NWP*). Tais modelos fornecem previsões da velocidade do vento para os pontos de uma malha ao redor das turbinas e por meio de interpolações podem ser obtidas previsões da velocidade do vento na altura do cubo da turbina eólica. Embora sejam mais precisos, estes modelos ainda demandam grande esforço computacional e por este motivo a sua utilização na previsão de curto prazo é bastante limitada, pois não permitem atualizar as previsões no tempo requerido pelos operadores de sistemas elétricos.

A segunda família de modelos inclui a modelagem de séries temporais, uma abordagem que na situação mais simples envolve a análise dos valores passados da própria variável que se pretende prever. A análise de séries temporais conta com uma ampla variedade de métodos estatísticos (ARIMA, análise harmônica, wavelets, etc.) e métodos de inteligência computacional (redes neurais artificiais, lógica fuzzy e sistemas neuro-fuzzy). Esta abordagem tem a vantagem de fornecer e atualizar as previsões na escala de tempo em que são tomadas as decisões operativas do sistema elétrico. No entanto, esta abordagem deve ser utilizada somente para previsão de curto prazo, pois a precisão das previsões obtidas diminui com a expansão do horizonte de projeção.

Kariniotakis et al. (1996) e Sfetsos (2000) avaliaram a capacidade preditiva de diferentes modelos de series temporais na previsão de curto prazo da geração eólica e da velocidade do vento respectivamente. Os autores compararam modelos lineares autoregressivos, wavelets, redes neurais *feed-forward*, redes neurais recorrentes, redes com função de base radial e redes neuro-fuzzy adaptativas (*adaptative neuro-fuzzy inference system - ANFIS*), sendo que esta última abordagem apresentou bons resultados na previsão da velocidade do vento (Sfetsos, 2000) e alcançou o melhor desempenho na previsão da geração eólica até 10 horas à frente e em horizontes de 24 a 48 horas à frente (Pinson & Kariniotakis, 2003). Alguns exemplos da aplicação do modelo ANFIS na previsão de geração eólica podem ser encontrados em Pinson e Kariniotakis (2003), Potter et al. (2004) e Pousinho et al (2010).

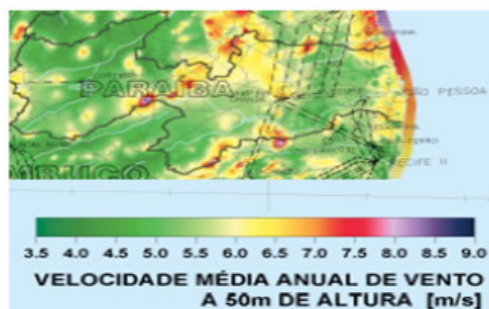
Este trabalho tem como objetivo apresentar a aplicação da modelagem ANFIS (Jang et al, 1997) na previsão da velocidade do vento.

Para ilustrar a aplicação da metodologia considerou-se o município de São João do Cariri, situado na região central do Estado da Paraíba (Figura 2a), onde está localizada uma das estações anemométricas do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais), um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) coordenado pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC).

A estação de São João do Cariri encontra-se a 486 metros de altitude a $7^{\circ}22'54''$ de latitude sul e $36^{\circ}31'38''$ de longitude oeste (Chou et al, 2006). Embora São João do Cariri não tenha um grande potencial eólico (Figura 2b), a sua escolha neste trabalho foi motivada pelo fato desta localidade dispor de uma série histórica de registros anemométricos com resolução temporal de 10 minutos e sem lacunas nas observações durante um período superior a um ano. A série analisada refere-se ao ano de 2006 e pode ser obtida na página do projeto SONDA (<http://sonda.cptec.inpe.br>).



(a) Município de São João do Cariri
Fonte: Wikipedia



(b) Velocidade média anual a 50 m de altura
Fonte: Atlas do potencial eólico brasileiro
<http://www.cresesb.cepel.br>

Figura 2 – Divisão administrativa e atlas do potencial eólico do Estado da Paraíba


O artigo está organizado em cinco seções. A seguir, na seção 2 é apresentada uma breve descrição da rede ANFIS. Em seguida, na seção 3 são apresentados alguns resultados da análise estatística da série de velocidade de vento a 50 m de altura considerada neste trabalho. A modelagem da rede ANFIS, as previsões obtidas e a discussão dos resultados são apresentadas na seção 4. Por fim, na seção 5 são resumidas as principais conclusões do trabalho.

2. SISTEMAS NEURO-FUZZY

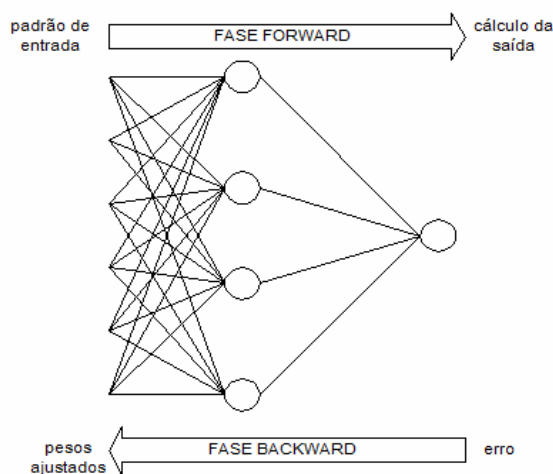
Os sistemas neuro-fuzzy combinam a capacidade de aprendizado das redes neurais artificiais com o poder de interpretação lingüística da lógica fuzzy (Jang et al, 1997, Pacheco & Vellasco, 2007). Por esta razão é importante descrever de forma breve alguns conceitos básicos sobre redes neurais artificiais e lógica fuzzy antes de apresentar a rede ANFIS.

2.1 Redes neurais artificiais

As redes neurais artificiais são sistemas paralelos distribuídos, compostos por unidades de processamento simples denominados neurônios e dispostas em uma ou mais camadas interligadas por um grande número de conexões (sinapses) geralmente unidirecionais e com pesos para ponderar as entradas recebidas por cada neurônio. A arquitetura mais usual é a rede neural *Multi Layer Perceptron* (MLP) com três camadas, conforme ilustrado na Figura 3a. De forma análoga ao que acontece no cérebro humano, onde as sinapses são reforçadas ou enfraquecidas, os pesos nas conexões entre as camadas são ajustados durante o processo de aprendizagem da rede neural.



(a) Arquitetura da rede neural



(b) Fases do algoritmo *backpropagation*

Figura 3 – Rede *Multi Layer Perceptron*

A primeira camada da rede é a camada de entrada, sendo a única camada exposta às variáveis de entrada. Esta camada transmite os sinais de entrada para os neurônios da camada escondida para que estes extraiam as características relevantes ou padrões dos sinais de entrada e transmitam os resultados para a camada de saída, a última camada da rede. A definição do número de camadas escondidas e do número de neurônios em cada camada é feita de forma empírica e depende da distribuição dos padrões de entrada, da quantidade de ruído presente nos exemplos de treinamento e da complexidade da função a ser aprendida. O treinamento de uma rede neural consiste em um processo iterativo de ajuste dos pesos das conexões entre as unidades de processamento. O principal algoritmo de treinamento é o *backpropagation*, onde o ajuste dos pesos se dá pela execução de um processo de otimização realizado em duas fases: *forward* e *backward*, conforme mostra a Figura 3b.

Na fase *forward* é calculada a resposta fornecida pela rede para um dado padrão de entrada. Já na fase *backward* o desvio (erro) entre a resposta desejada (alvo) e a resposta efetivamente fornecida pela rede é utilizado para ajustar os pesos das conexões da rede. Enfim, ao longo do treinamento da rede neural os vários padrões de entrada e as respectivas saídas desejadas são apresentados à rede neural, de tal forma que os pesos das sinapses sejam corrigidos iterativamente pelo algoritmo do gradiente descendente com o objetivo de minimizar a soma dos quadrados dos erros:

$$E = \frac{1}{2} \sum_{p=1}^{\text{padrões}} \sum_{j=1}^n (d_j^p - y_j^p)^2 \quad (2)$$

onde p é o número de padrões de treinamento (padrões de entrada e saída), n é o número de neurônios da camada de saída, d_j^p é a saída desejada para o j -ésimo neurônio da camada de saída no p -ésimo padrão de treinamento e y_j^p é a saída gerada pelo j -ésimo neurônio da camada de saída quando a rede é alimentada com o p -ésimo padrão de entrada.

2.2 Sistema de inferência fuzzy

Na lógica fuzzy o grau de verdade de uma declaração é representado por um número no intervalo $[0,1]$, ao contrário do que ocorre na lógica clássica em que o grau de verdade assume apenas dois valores: 0 (declaração falsa) e 1 (declaração verdadeira). Esta característica da lógica fuzzy é útil em muitas situações práticas onde a intensidade de um fenômeno é descrita de maneira imprecisa por meio de variáveis lingüísticas: baixo, moderado baixo, médio, moderado alto ou alto. A teoria dos conjuntos fuzzy e os conceitos de lógica fuzzy podem ser utilizados para traduzir em termos matemáticos a informação imprecisa expressa por um conjunto de regras lingüísticas, sentenças fornecidas por um especialista e expressas através de implicações lógicas da forma *SE antecedente ENTÃO conseqüente* (Pacheco & Vellasco, 2007).

O processo de inferência fuzzy avalia os níveis de compatibilidade das variáveis de entradas com os antecedentes das várias regras, ativando os conseqüentes com intensidades proporcionais aos mesmos. O resultado desta operação é um conjunto fuzzy que é convertido em um número real, a resposta do sistema de inferência fuzzy (Pacheco & Vellasco, 2007). A Figura 4 ilustra o princípio de raciocínio em um sistema de inferência fuzzy com duas regras, cujos antecedentes são definidos pela composição de dois conjuntos fuzzy A e B que representam o comportamento das variáveis de entrada x e y respectivamente. Cada regra oferece como resposta uma combinação linear das variáveis de entrada, sendo que a saída do sistema de inferência fuzzy é a média ponderada destas respostas parciais, onde os pesos são os graus de ativação das regras (w_1 e w_2) que expressam a compatibilidade das variáveis de entrada x e y com os antecedentes das regras (Pacheco & Vellasco, 2007).




Figura 4 – Sistema de inferência fuzzy (Fonte: Jang et al, 1997)

2.3 Adaptive Neuro-Fuzzy Inference System (ANFIS)

O modelo ANFIS (Jang et al, 1997) é treinado como uma rede neural, mas uma vez treinado opera exatamente como um sistema de inferência fuzzy. A arquitetura da ANFIS é composta por cinco camadas, conforme ilustrado na Figura 5. A título de ilustração considere duas entradas x e y e uma saída z . No contexto da previsão de séries temporais, as variáveis x e y correspondem aos valores passados da velocidade do vento: $z(t), z(t-1), \dots$ ou valores passados de variáveis explicativas ou previsões meteorológicas, por exemplo, valores passados e futuros da temperatura. Suponha que a base de regras contenha duas regras fuzzy “se-então”:

Regra 1: Se x é A_1 e y é B_1 então $f_1 = p_1x + q_1y + r_1$

Regra 2: Se x é A_2 e y é B_2 então $f_2 = p_2x + q_2y + r_2$

onde A_1 e A_2 são os conjuntos fuzzy da variável x e B_1 e B_2 os conjuntos fuzzy da variável y . Destaca-se que o conseqüente de cada regra é uma combinação linear das variáveis de entrada (x e y) e corresponde a uma previsão para o valor da variável de saída z . Se x e y são os valores passados da própria variável de saída, os conseqüentes das regras são modelos lineares autoregressivos, portanto, cada regra fornece uma previsão para a variável de saída.

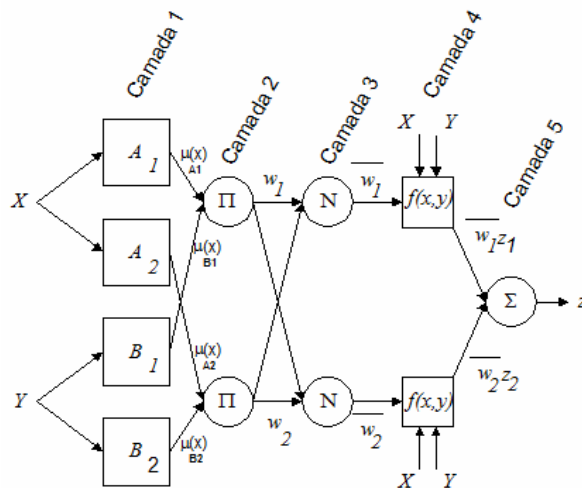


Figura 5 - Arquitetura ANFIS

Na camada 1, cada nó representa um conjunto fuzzy de uma variável de entrada (x ou y) e como resultado fornece o grau de pertinência μ do valor de entrada no conjunto fuzzy:

$$Saída_i^1 = \mu_{A_i}(x), \text{ grau de pertinência do valor da variável } x \text{ no conjunto fuzzy } A_i, i=1,2$$

$$Saída_i^1 = \mu_{B_i}(y), \text{ grau de pertinência do valor da variável } y \text{ no conjunto fuzzy } B_i, i=1,2$$

O grau de pertinência μ da entrada nos conjuntos fuzzy A ou B pode ser definido por funções triangulares ou gaussianas, mas usualmente é descrito pela função sino generalizada:

$$\mu A_i(x) = \left(1 + \left| \frac{x - b_i}{a_i} \right|^{2c_i} \right)^{-1}, i = 1, 2 \quad \mu B_i(x) = \left(1 + \left| \frac{x - e_i}{d_i} \right|^{2f_i} \right)^{-1}, i = 1, 2 \quad (3)$$

Onde (a_i, b_i, c_i) e (d_i, e_i, f_i) são conjuntos de parâmetros (*premise parameters*) ajustados durante o treinamento da rede. Na camada 2, cada nó Π calcula o grau de ativação de uma regra fuzzy, definido pelo produto entre os graus de pertinência das variáveis de entrada nos conjuntos fuzzy que formam os antecedentes das regras:

$$Saída_i^2 = w_i = \mu A_i(x) \cdot \mu B_i(y), \text{ grau de ativação da } i\text{-ésima regra fuzzy } i=1,2 \quad (4)$$

Na camada 3, cada nó N normaliza o grau de ativação de uma regra fuzzy dividindo o grau de ativação da i -ésima regra pela soma dos graus de ativação de todas as regras:

$$Saída_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (5)$$

O valor normalizado do grau de ativação fornece uma medida da importância de cada regra fuzzy, quanto maior o valor normalizado, maior a importância da respectiva regra.

Na camada 4, cada nó calcula a resposta de uma regra fuzzy, ou seja, uma previsão para o valor da variável z , definida por uma combinação linear das variáveis de entrada:

$$Saída_i^4 = \bar{w}_i (p_i x + q_i y + r_i), \quad i=1,2 \quad (6)$$

onde (p_i, q_i, r_i) são parâmetros (*consequent parameters*) a serem ajustados durante o treinamento.

Por fim, na camada 5 o nó Σ faz a média ponderada das previsões parciais para a variável de saída, onde cada previsão parcial é ponderada pelo grau de ativação da respectiva regra fuzzy:

$$Saída_i^5 = \sum_j \bar{w}_j (p_j x + q_j y + r_j) = \sum_j w_j (p_j x + q_j y + r_j) / \sum_j w_j \quad (7)$$

No ajuste dos *premise* e *consequent parameters* a ANFIS usa o método dos mínimos quadrados para determinar os *consequent parameters* e a retropropagação do erro (método do gradiente descendente) para aprender os *premise parameters* (Jang et al, 1997).


3. ANÁLISE ESTATÍSTICA DAS MEDIÇÕES DE VELOCIDADE DO VENTO

A base de dados anemométricos analisada encontra-se disponibilizada na página do projeto SONDA. Esta base contém registros da velocidade e da direção do vento tomados a cada 10 minutos na altura de 50 metros. Os dados referem-se ao ano de 2006. A seguir, na Tabela 1 são apresentadas algumas estatísticas descritivas da velocidade média horária do vento a 50 metros de altura.

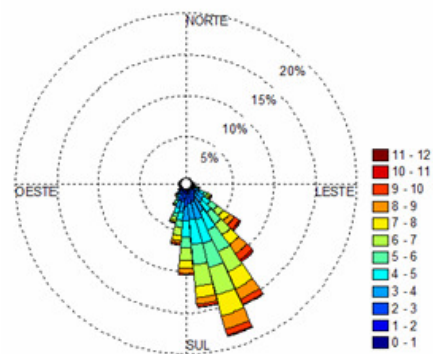
Tabela 1 – Estatísticas da velocidade média horária do vento em São João do Cariri – PB

Número de observações	8760
Média m/s	5,3101
Mediana m/s	5,2367
Desvio-padrão m/s	2,1475
Mínima m/s	0,3283
Máxima m/s	11,1950
1º quartil m/s	3,6483
3º quartil m/s	6,8425

Na Figura 6a são apresentadas as distribuições de freqüência da velocidade horária do vento a 50 metros de altura. As distribuições de freqüência revelam que na maior parte do tempo a velocidade do vento a 50 m não ultrapassa 10 m/s. O histograma também indica que a velocidade do vento não segue uma distribuição Normal (estatística qui-quadrado = 360,22 com 30 graus de liberdade). Em geral, a distribuição de probabilidade que melhor se ajusta aos registros da velocidade do vento é a distribuição de Weibull (Custódio, 2009) (estatística qui-quadrado = 149,68 com 30 graus de liberdade). A rosa dos ventos na Figura 6b indica que os ventos em São João do Cariri são predominantemente de sul (Chou et al, 2006). Na seqüência, na Figura 7 são apresentadas as médias mensais e horárias da velocidade de vento a 50 metros de altura. A Figura 7a revela que a disponibilidade do potencial eólica não é uniforme ao longo do dia, mas concentra-se no período da noite, enquanto a Figura 7b mostra que a velocidade média do vento ao longo do ano não é constante.




(a) Freqüência relativa




(b) Freqüência relativa acumulada

Figura 6 – Distribuições de freqüência da velocidade horária do vento a 50 m de altura



(a) Médias horárias





(b) Médias mensais

Figura 7 - Médias horárias e mensais da velocidade do vento (m/s) a 50 m de altura

4. MODELAGEM ANFIS E PREVISÕES

A modelagem da rede ANFIS foi realizada por meio da rotina *anfisedit*, uma *toolbox* do Matlab (Jang et al, 1997). A modelagem da rede ANFIS se inicia com a análise das autocorrelações entre os registros horários da velocidade de vento (Figura 8b) com a finalidade de identificar as variáveis de entrada da rede ANFIS, ou seja, a janela de valores passados que fornece a melhor previsão da velocidade de vento. Na Figura 8b o perfil da função de autocorrelação (Souza & Camargo, 1996) exibe picos localizados em intervalos de 24 horas que decaem lentamente o que indica a existência de uma componente sazonal na série. Por esta razão foram tomadas as primeiras diferenças da série da velocidade do vento, ou seja, $\Delta v = v(t) - v(t-1)$ e, em seguida, tomadas as diferenças sazonais horárias da série diferenciada, $y(t) = \Delta^{24} \Delta v = \Delta v(t) - \Delta v(t-24)$, onde $v(t)$ é a velocidade do vento no instante t . A finalidade desta transformação consiste em remover a componente sazonal da série. A série transformada e a respectiva função de autocorrelação são ilustradas na Figura 9. A função de autocorrelação (FAC) da série transformada $y(t)$ apresenta um valor significativo no lag 24,



indicando que $y(t-24)$ deve ser uma das variáveis de entrada da rede ANFIS. As demais variáveis de entrada da ANFIS também são valores defasados da série transformada, identificados com o auxílio da FAC ilustrada na Figura 9b: $y(t-1)$, $y(t-2)$ e $y(t-3)$.



(a) Série horária da velocidade do vento

(b) Função de autocorrelação (FAC)

Figura 8 - Série horária da velocidade do vento em São João do Cariri no ano de 2006



(a) Série transformada

(b) Função de autocorrelação (FAC)

Figura 9 - Série transformada da velocidade do vento $\Delta^{24}\Delta X$

Resumindo, a rede ANFIS identificada tem uma saída $y(t)$ e quatro entradas $y(t-1)$, $y(t-2)$, $y(t-3)$ e $y(t-24)$, portanto a rede é desenhada para fornecer previsões da série transformada $y(t) = \Delta^{24}\Delta v = \Delta v(t) - \Delta v(t-24)$ até 1 hora à frente. No modelo proposto cada variável de entrada foi representada por dois conjuntos fuzzy gaussianos, portanto, o sistema fuzzy especificado tem 16 regras fuzzy (2^4), cada uma com quatro antecedentes e um conseqüente. A arquitetura da rede ANFIS é apresentada na Figura 10.

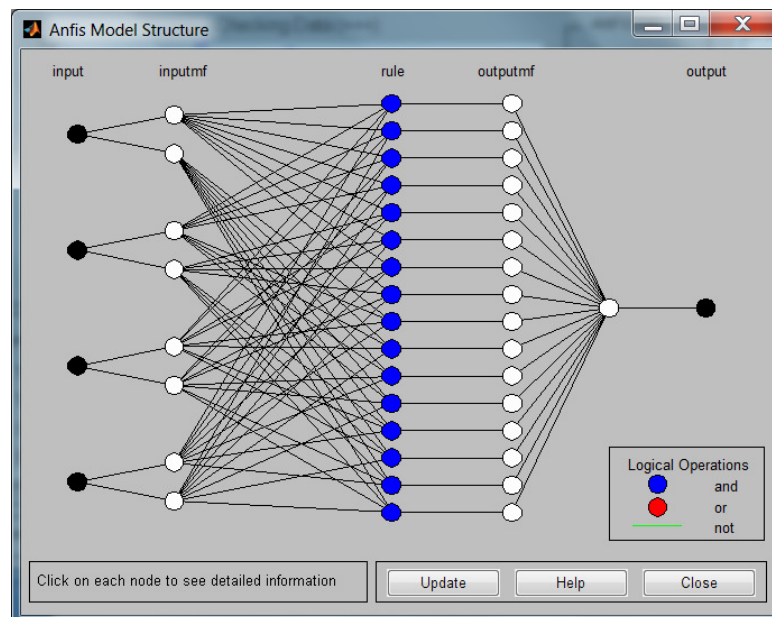


Figura 10 – Rede ANFIS gerada pelo Matlab

O conjunto de pares entrada-saída utilizados no treinamento da rede ANFIS foi gerado a partir da série transformada com observações referentes ao ano de 2006. A partir das 8760 observações horárias da série de velocidade do vento foram gerados 8711 pares entrada-saída, sendo que 7404 foram utilizados no treinamento, 871 foram usados na fase de teste e 436 na validação. Seguindo um procedimento comum nas aplicações da rede ANFIS, os valores dos conjuntos de treinamento, teste e validação ainda foram normalizados antes do início do processo de treinamento da rede:

$$q(t) = [y(t) - \text{mínimo}(y(t))] / [\text{máximo}(y(t)) - \text{mínimo}(y(t))] \quad (8)$$

A seguir, o diagrama de dispersão na Figura 11 ilustra a forte correlação entre os valores observados e os estimados pela rede ANFIS para a velocidade do vento (m/s). A distribuição de frequência dos desvios dos valores estimados em relação aos valores observados é apresentada na Figura 12, ao lado dos índices da qualidade do ajuste *in sample*.





Figura 11 - Valores observados e estimados



Índices de qualidade do ajuste (*in sample*)

MAD = 0,8074 m/s

MAPE = 19,20%

RMSE = 1,0656 m/s

Índices de qualidade do ajuste (*out sample*)

MAD = 0,8288 m/s

MAPE = 16,63 %

RMSE = 1,1449 m/s

Mean Absolute Deviation (MAD), Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE)

Figura 12 – Desvios entre os valores estimados e os valores observados

A boa capacidade preditiva da rede ANFIS pode ser verificada no período *out sample* que abrange a primeira semana de janeiro de 2007, conforme ilustrado a seguir na Figura 13. Os valores do MAD, MAPE e RMSE na Figura 12 expressam uma qualidade razoável do ajuste no período *out sample*.




Figura 13 - Valores previstos e observados na primeira semana de 2007 (período *out sample*)

Os resultados apresentados acima se referem a projeções de até 1 hora à frente. Mas é possível realimentar a rede ANFIS com suas próprias previsões de até 1 hora à frente para gerar, por exemplo, previsões de até 24 ou 48 horas à frente. Naturalmente a qualidade das previsões se reduz à medida que o horizonte de previsão é expandido. Na Figura 14 são apresentadas as previsões de até 1 hora à frente e até 48 horas à frente nos primeiros dois dias de janeiro de 2007 (período *out sample*). Os resultados mostram que a realimentação da rede com suas próprias previsões produz resultados razoáveis até 24 horas à frente.

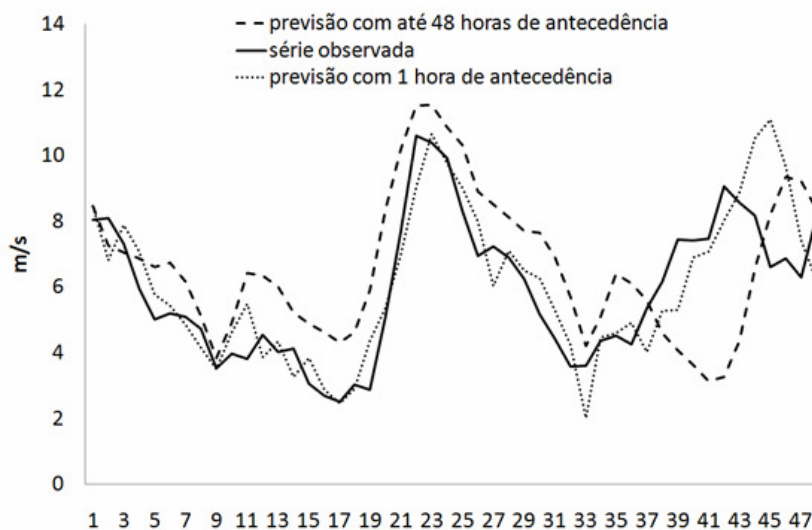


Figura 14 – Previsões com horizontes até 48 horas à frente com realimentação da rede ANFIS

5. CONCLUSÕES

A rede ANFIS é uma das abordagens mais promissoras para a previsão de curto prazo da velocidade do vento e da geração de energia eólica. Neste trabalho foi apresentado um processo para identificação da arquitetura de redes ANFIS para a previsão da velocidade do vento baseada nos valores passados da própria série. Os resultados do estudo para a localidade de São João do Cariri – PB foram apresentados e embora sejam animadores, mais investigações devem ser realizadas para aprimorar a modelagem da rede ANFIS com a finalidade de reduzir o nível de erro. Uma das direções das investigações futuras é a introdução de outras variáveis de entrada para além dos valores passados da própria série de velocidade de vento, por exemplo, a temperatura.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Chou, S.C., Chagas, D.J., Paiva Neto, A.C., Ventura, G.M., Lyra, A., Pereira, E.B. Regime eólico de quatro estações no Nordeste, XIV Congresso Brasileiro de Meteorologia, Florianópolis, 2006.
- [2] Custódio, R.S. Energia eólica para produção de energia elétrica, Eletrobrás, Rio de Janeiro, 2009.
- [3] Jang, J.S.R., Sun, C.T. Mizutani, E. Neuro-Fuzzy and soft computing: a computational approach to learning and machine intelligence, Prentice Hall, 1997.
- [4] Kariniotakis G., G.S. Stavrakakis, E.F. Nogaret Wind power forecasting using advanced neural network models. IEEE Transactions on Energy Conversion, Vol. 11, No. 4, December 1996, pp. 762-767.
- [5] Kariniotakis, G., Ranchin, T., Moussafir, J., Buty, D., Usaola, J., Sanchez, I., Marti, I., Madsen, H., Nielsen, T.S., Lac, C., Frayssinet, P., Waldl, H.P., Dierich, F., Halliday, J., Bownsword, R., Giebel, G., Landberg, L., Kallos, G., Louka, P., Ottavi, J., Focken, U., Lange, M., Ancín, J.K., Toefling, J., McCoy, D., Fagan, E., Collmann, M., Thalassinakis, E., Gigandidou, A., Morales, G.G., Barquero, C., Arriba, P., Cruz, I., Hatziaergyion, N., Sideratos, G. Towards next generation short-term forecasting of wind power – The ANEMOS Project, Global Windpower 2004 Conference & Exhibition, Chicago, 28-31, March, 2004.
- [6] Giebel, G., Landberg, L., Karionatakis, G., Brownsword, R. State-of-the-art on methods and software tools for short-term prediction of wind energy production, European Wind Energy Conference & Exhibition, Madrid, 2003.
- [7] Pacheco, M.A.C., Vellasco, M.M.B.R. Sistemas inteligentes de apoio à decisão: análise econômica de projetos de desenvolvimento de campos de petróleo sob incertezas, Rio de Janeiro, Ed. PUC-Rio, Ed. Interciência, 2007.
- [8] Pousinho, H.M.I., Mendes, V.M.F., Catalão, J.P.S. Neuro-Fuzzy Approach to Forecast Wind Power in Portugal, International Conference on Renewable Energies and Power Quality (ICREPQ'10), Granada, Spain, 23th to 25th March, 2010.
- [9] Pinson, P., Kariniotakis, G.N. Wind Power Forecasting using Fuzzy Neural Networks Enhanced with On-line Prediction Risk Assessment, IEEE Bologna PowerTech Conference, June 23-26, Bologna, Italy, 2003.
- [10] Potter, C., Ringrose, M., Negnevitsky, M. Short-term wind forecasting techniques for power generation, Australasian Universities Power Engineering Conference (AUPEC 2004), 26-29 September, Brisbane, Australia, 2004.
- [11] Sfetsos, A. A comparison of various forecasting techniques applied to mean hourly wind speed time series, Renewable Energy, 21, pp. 23-35, 2000.
- [12] Souza, R.C., Camargo, M.E. Análise e previsão de séries temporais: os modelos ARIMA, Ijuí, SEDIGRAF, 1996.
- [13] Wu, Y.K., Hong, J.S. A literature review of wind forecasting technology in the world, PowerTech, 2007.