



**SNPTEE
SEMÍNÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

GPT 23
14 a 17 Outubro de 2007
Rio de Janeiro - RJ

**GRUPO II
GRUPO DE ESTUDO DE PRODUÇÃO TÉRMICA E FONTES NÃO CONVENCIONAIS**

**AVALIAÇÃO DE MÉTODOS CONVENCIONAIS E DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE
VENTOS E GERAÇÃO EÓLICA**

**Ronaldo Ribeiro Barbosa de Aquino * Josinaldo Bezerra de Oliveira Otoni Nóbrega Neto
Milde Maria da Silva Lira Aida Araújo Ferreira Pedro André Carvalho Rosas
Gabriela Seabra Melo e Santos**

DEPARTAMENTO DE ENGENHARIA ELÉTRICA E SISTEMAS DE POTÊNCIA – DEESP/UFPE

RESUMO

O aumento do potencial eólico brasileiro, para geração de energia elétrica, devido ao Programa de Incentivo de Fontes Alternativas de Energia Elétrica, PROINFA, tem motivado a necessidade de previsão da geração eólica. Necessidade esta, explicada pela característica de intermitência dos ventos, consequentemente incerteza na geração, dificultando assim, o planejamento da operação e o controle das Centrais Eólicas. Este trabalho apresenta ferramentas capazes de realizar previsão de geração eólica a partir de modelos estatísticos e de inteligência artificial. Permitindo desta forma, analisar qualitativamente e quantitativamente ambos os métodos, os quais são bastante utilizados para previsão em várias áreas.

PALAVRAS-CHAVE

Previsão de Ventos, Geração Eólica, Inteligência Artificial, Redes Neurais Artificiais, Transformadas Wavelets

1.0 - INTRODUÇÃO

No Brasil, após o racionamento de energia em 2001, deu-se início a diversos programas de incentivos e pesquisas no setor elétrico, a fim de evitar novo desabastecimento de energia como ocorrido anteriormente. Dentre estes programas destaca-se: o Programa de Incentivo de Fontes Alternativas de Energia Elétrica, PROINFA, que tem finalidade de diversificar a matriz energética brasileira e, consequentemente, diminuir o risco de déficit de energia.

Na fase inicial deste programa, está prevista a instalação de 3300 MW de fontes renováveis de energia, com destaque para a energia eólica, que segundo dados da Agência Nacional de Energia Elétrica, ANEEL, e do PROINFA contribuirá até 2008 com 1400 MW, instalados principalmente na região Nordeste.

Entretanto, o uso da energia cinética dos ventos para geração de energia elétrica produz alguns inconvenientes como, por exemplo, incertezas na geração ocasionando um custo adicional ao planejamento da operação do sistema, causando ainda dificuldades nos sistemas de controles das centrais eólicas. Tais inconvenientes, são provocados pela variabilidade das velocidades dos ventos. Desta forma, para uma adequada integração da fonte Eólica com sistema elétrico é imprescindível à aplicação de ferramentas ou de técnicas capazes de prever a energia a ser gerada por essas fontes.

Este trabalho propõe a aplicação de técnicas como: Modelos Estatísticos, Redes Neurais Artificiais, e Análise de multiresolução de dados, com a finalidade de produzir ferramentas capazes de realizar previsão de ventos e geração eólica com horizonte de 24 horas. As ferramentas desenvolvidas aqui auxiliam a subsidiar o planejamento do sistema híbrido de geração (hidráulico e eólico), mitigando os inconvenientes da geração eólica acima citados.

(*) Rua Acadêmico Hélio Ramos s/n, Cidade Universitária, Centro de Tecnologia, CEP 50.740-530 – Recife, PE – Brasil. Tel: (+55 81) 2126 8256 – Fax: (+55 81) 2126 8739 – Email: rrba@ufpe.br

Alguns dos trabalhos no âmbito de previsão de geração eólica incorporam além das séries de velocidades e potências geradas, as características de relevo, do terreno e informações climatológicas, que podem ser obtidas através de satélites, ver (1) e (2). Um outro modelo criado, além dessas informações usam dados de ventos de outros sítios eólicos a montante da localidade onde é realizada a previsão (4). Os modelos de previsão aqui avaliados são desenvolvidos unicamente a partir das séries temporais de velocidade de ventos, devido à insuficiência de dados, já que a geração eólica, no Brasil, só agora tem despertado maior interesse. Entretanto, os resultados encontrados são animadores, quando comparados com artigos pesquisados.

O desenvolvimento deste trabalho segue as seguintes etapas: 1. levantamento e análise da série de velocidades; 2. estudo e desenvolvimento do modelo estatístico de previsão; 3. estudo e desenvolvimento do modelo neural; 4. estudo e desenvolvimento do modelo neural através de uma análise de multiresolução de sinais usando transformada wavelet; 4. análise comparativa e conclusões entre os modelos criados.

O uso das técnicas aqui propostas deveu-se a aplicabilidade das mesmas em várias outras áreas de previsão, tais como: séries econômicas, mercado de energia (carga), dados meteorológicos, etc. Sendo assim, interessante verificar a aplicabilidade das mesmas para o caso específico de previsão de ventos e geração eólica.

2.0 - COMPOSIÇÃO E ANÁLISE DA SÉRIE TEMPORAL DA VELOCIDADE E GERAÇÃO EÓLICA

A série de velocidades utilizada no presente trabalho é constituída dos valores médios horários medidos na central eólica de Olinda-PE, entre Dezembro de 1996 a Julho de 1998. Entretanto, houve períodos em que o equipamento de medição de velocidade dos ventos (Anemômetro), instalado no local, foi desativado para manutenção. Desta forma, à composição da série temporal, alguns dados foram tomados a partir da média mensal do mês correspondente.

Os dados da série de velocidade dos ventos foram divididos em dois grandes conjuntos: O primeiro, utilizado para calcular os coeficientes de autocorrelação, no caso do modelo estatístico; já no caso dos modelos neurais, este conjunto é utilizado parte para treinamento e parte para validação do treinamento, conforme será discutido no item 4.0. O segundo conjunto é utilizado exclusivamente com o propósito de testar os modelos de previsão criados, isto é, estimar as suas performances quando em operação.

Na criação de modelos de previsão, é necessário analisar diversas variáveis que podem influenciar na grandeza a ser prevista, afim de determinar as principais variáveis que constituirão o modelo a ser criado, e ainda suas estruturas. Neste trabalho os modelos criados são univariados, ou seja, uma única variável no caso a velocidade dos ventos, é usada como variável explicativa das previsões.

Em modelos de previsão univariados a função de autocorrelação da série define sua aplicabilidade e desempenho, principalmente, nos modelos estatísticos. Através dela identifica-se a dependência entre os dados da série, o que facilita a análise dos dados. A Figura 1 apresenta a função de autocorrelação da série de velocidade de ventos.

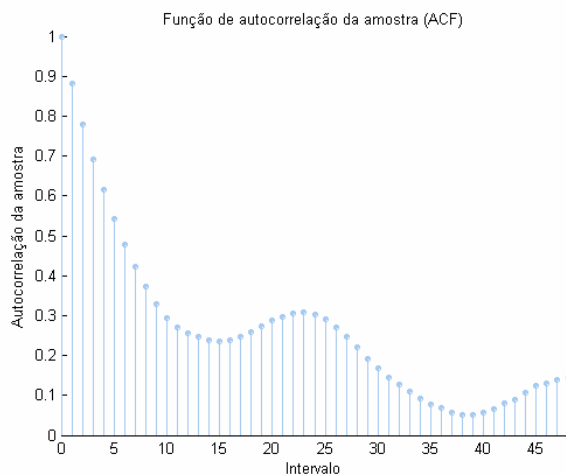


FIGURA 1 – Função de autocorrelação da amostra

Verifica-se facilmente, mediante uma análise qualitativa do gráfico da Figura 1, que os modelos de previsão com horizontes pequenos tendem a ter um desempenho superior aos de horizontes maiores. Além disso, observa-se que na proximidade de 24 horas a autocorrelação da série volta a aumentar. Este comportamento caracteriza a sazonalidade dos ventos entre os períodos do dia.

Para obtenção da previsão da geração eólica, a partir dos modelos de previsão de velocidade de vento é necessário conhecer a curva de potência da turbina. Esta curva relaciona as velocidades do vento com a respectiva energia gerada. A Figura 2 representa a curva de potência de uma turbina de 1000kW, usada neste trabalho.

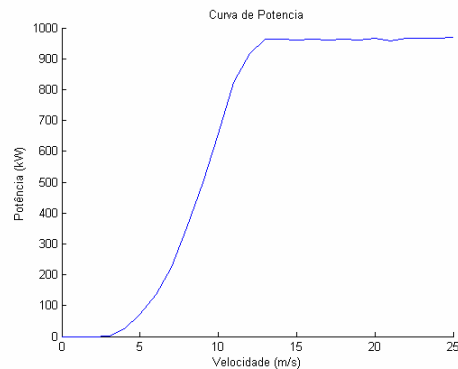


FIGURA 2 – Curva de potência

3.0 - MODELOS ESTATÍSTICOS

Atualmente, várias classes de modelos estatísticos tem sido objeto de estudo no desenvolvimento de ferramentas de previsão. Na previsão de geração eólica e de velocidade de ventos, destacam-se: O modelo de Persistência e o modelo Autoregressivo Media Móvel (ARMA), que faz parte de uma classe de modelos desenvolvidos por Box-Jenkins (10).

O modelo Persistência é bastante utilizado para previsão de curtíssimo prazo, com horizonte de até 2 horas. Os resultados obtidos com este modelo são praticamente imbatíveis para horizontes pequenos, conforme (2) e (3). Esta performance é devido a alta correlação entre os dados da série para janelas curtas como comprovado na Figura 1.

A previsão realizada por este modelo é considerada uma previsão simples ou ingênua em que o valor previsto, $X_{t+\Delta t}$, é calculado através do último valor corrente da série, X_t . Já para horizontes de previsão maiores, o modelo estatístico mais utilizado é o Autoregressivo Media Móvel – ARMA(p,q) representado pela Equação 1.

$$X_t = \sum_{j=1}^p a_j X_{t-j} + \sum_{k=0}^q b_k e_{t-k} \quad (1)$$

- X - Série de velocidades dos ventos;
- e - Série dos erros cometidos;
- a , b - são coeficientes de autocorrelação;
- p - ordem do modelo Auto-regressivo;
- q - ordem do modelo Média móvel.

Geralmente, a definição das ordens é feita de forma empírica. Neste trabalho p e q foram determinadas analisando a função de autocorrelação da série, o qual restringir o espaço de busca das ordens do modelo. Após estas análises e alguns testes o modelo implementado foi o ARMA(5,4).




FIGURA 3 - Previsão do Modelo ARMA (5, 4)




FIGURA 4 - Histograma do Modelo ARMA(5, 4)

As Figuras 3 e 4 mostram o desempenho do modelo ARMA(5,4) aplicado para previsão da geração eólica do conjunto de teste independente da série usada para os ajustes dos coeficientes, a e b, da Equação 1. O erro médio absoluto (MAE_{CAP} , Equação 2) da capacidade instalada, para o conjunto de teste foi 16,30%.

$$MAE_{CAP} = \frac{1}{N \cdot P \cdot CAP} \sum_{p=1}^P \sum_{i=1}^N |X_{pi} - T_{pi}| \times 100 \quad (2)$$

- N - Número de neurônios de saída da rede neural;
- P - Número de padrões;
- CAP - Capacidade instalada;
- X_{pi} - Saída processada pela RNA;
- T_{pi} - Saída desejada.

4.0 - REDES NEURAIS ARTIFICIAIS

As Redes neurais artificiais (RNA) são sistemas paralelos distribuídos compostos por unidade de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não lineares). Esta forma de computação não-algorítmica é caracterizada por sistema que relembram a estrutura do cérebro humano. O grande apelo destes modelos está em sua capacidade de “aprender”, “generalizar” ou “extrair regras” automaticamente durante seus treinamentos.

Atualmente vários problemas de engenharia são resolvidos com uso de técnicas de redes neurais artificiais, como, por exemplo, problemas de classificação, reconhecimento de padrões, otimização e, inclusive previsão. Na área de sistemas elétricos de potência, as RNA têm desempenhados boas performance em modelos de classificação e localização de faltas, previsão de carga, previsão de vazão, etc. Contudo, a aplicação de RNA para previsão de geração eólica ainda não se consolidou, e muitas vezes esta técnica é preterida pelos métodos estatísticos, numa abordagem mais tradicional.

Existem vários tipos de RNA, neste trabalho é utilizada a rede do tipo perceptrons de múltiplas camadas (MLP). Este tipo de rede é aplicada na maioria dos problemas resolvidos através de RNA. O processamento de informações pelas redes MLP são caracterizado por duas fases: A primeira, *forward*, na qual a informação é passada no sentido progressivo, camada por camada, até que a resposta seja produzida na camada de saída; a segunda fase, *backward*, existente apenas durante os treinamentos, e é responsável pela retropropagação do erro, camada por camada, para ajustar os pesos das redes com intuito de minimizar os erros do treinamento.

4.1 Desenvolvimentos dos modelos baseados em RNA

A formação dos modelos neurais MLP, de maneira geral, dividi-se em quatro etapas:

- Normalização dos dados;
- Treinamentos para seleção da arquitetura;
- Teste do modelo.

4.1.1 Normalização dos dados

Este processo é importante para assegurar que todas as variáveis usadas tenham igual atenção durante o treinamento. Além disso, os neurônios artificiais são compostos de funções de ativação limitadas em faixas. Por isso, a normalização dos dados deve limitar os valores nestas faixas. Neste projeto os dados foram normalizados de acordo com Equação 3.

$$X_{\text{Normalizado}} = \frac{X_{\text{Real}}}{1.1 \cdot X_{\text{Máx}}} \quad (3)$$

4.1.2 Treinamentos para seleção da arquitetura

As redes aqui utilizadas são de três camadas: entrada; oculta e saída, haja vista, a capacidade destas redes em resolver problemas não linearmente separáveis e, ainda de aproximar qualquer função não-linear. Devido ao comportamento da sazonalidade da série de velocidade dos ventos, verificado na Figura 1, as arquiteturas das redes neurais foram constituídas de 24 entradas, as quais correspondem as velocidades das 24 horas que antecedem a previsão; e 24 neurônios na camada de saída, representando a previsão da velocidade do vento das 24 horas do dia seguinte.

Quanto ao número de neurônios ocultos, este foi determinado a partir da criação e treinamentos de várias topologias de rede, com números de neurônios ocultos distintos. Cada topologia foi treinada dez vezes com inicializações de pesos diferentes, ver (8) e (9), utilizando o algoritmo de treinamento Rprop, *resilient back-propagation*, o qual é de adaptação global, conforme (6). Selecionando assim, a topologia que obteve a melhor performance, ou seja, menor erro médio quadrático (MSE), ver (8), sobre o conjunto de validação, o qual é um conjunto independente do conjunto de treinamento e é utilizado apenas para monitorar o treinamento da rede, que tem o propósito de garantir a capacidade de generalização das redes MLP.

A arquitetura que demonstrou melhor performance durante os treinamentos foi formada de 24 entradas, 20 neurônios na camada oculta e 24 neurônios na camada de saída, conforme a Figura 5.




FIGURA 5 – Arquitetura de RNA selecionada

Uma vez determinada a arquitetura do modelo neural de previsão, foi utilizado um processo de validação cruzada através do método k-fold sendo $k=10$, como na Tabela 1, para se obter uma distribuição, estatisticamente, melhor dos dados entre os conjuntos de treinamento, validação e teste, conforme apresentado em (8) e (9).

TABELA 1 – Experimentos criados a partir do método 10-fold

Exp.	Treinamento	Validação	Teste
1	5, 6, 7, 8, 9, 10	2, 3, 4	1
2	1, 6, 7, 8, 9, 10	3, 4, 5	2
3	1, 2, 7, 8, 9, 10	4, 5, 6	3
4	1, 2, 3, 8, 9, 10	5, 6, 7	4
5	1, 2, 3, 4, 9, 10	6, 7, 8	5
6	1, 2, 3, 4, 5, 10	7, 8, 9	6
7	1, 2, 3, 4, 5, 6	8, 9, 10	7
8	2, 3, 4, 5, 6, 7	9, 10, 1	8
9	3, 4, 5, 6, 7, 8	1, 2, 10	9
10	4, 5, 6, 7, 8, 9	1, 2, 3	10

4.1.3 Teste

O conjunto de dados utilizado nesta fase é independente do conjunto de treinamento, isto é, não é utilizado para ajustes dos pesos da rede neural. Ele só é apresentado à rede para estimar o desempenho das mesmas quando esta estiver em operação. Dentre os experimentos, criados pelo método k-fold, o experimento 7 apresentou a melhor performance, com MAE_{CAP} igual 5,60%, seu desempenho pode ser melhor analisado através dos gráficos da Figuras 6 e 7.




FIGURA 6 - Previsão do Modelo RNA 1

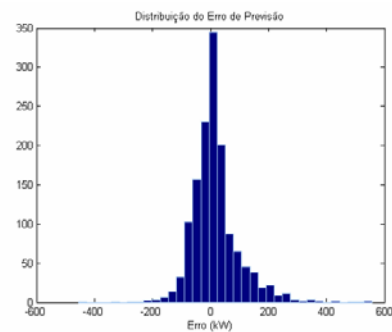


FIGURA 7 - Previsão do Modelo RNA 1

5.0 - MODELO NEURAL ATRAVÉS DA ANÁLISE DE MULTIRESOLUÇÃO DE SINAIS USANDO TRANSFORMADA WAVELETS.

5.1 Transformada Wavelet

As Transformadas Wavelets (TW) são funções matemáticas que separam dados em suas diferentes componentes de frequências, e extraem cada componente com uma resolução adequada à sua escala. A Transformada Wavelet surgiu como uma alternativa a Transformada de Fourier. Entretanto, as Wavelets apresentam um melhor desempenho para sinais não estacionários com mudanças bruscas e com descontinuidades, devido a suas resoluções variáveis no tempo e frequência.

Análise de multiresolução é uma técnica originada na área de processamento de sinais, que decompõe o sinal em escalas com diferentes resoluções em tempo e escala (7). Esta análise é realizada através do algoritmo piramidal, o qual torna o cálculo das TW eficientes. Este algoritmo possibilita obter “aproximações” e “detalhes” de um dado sinal de interesse. Uma aproximação é uma representação de baixa frequência do sinal, enquanto que um detalhe é a diferença entre duas representações sucessivas de baixa resolução (aproximação) do sinal original. Uma aproximação contém a tendência geral do sinal original, enquanto que um detalhe exibe os componentes de alta frequência deste sinal. (5) e (7).

5.2 Modelo Neural a partir de uma Análise de Multiresolução

Este modelo utiliza como variáveis de entrada a série de velocidade dos ventos, no entanto, esta é decomposta em vários sinais através TW da família *Daubechies*. O primeiro é um sinal de baixa frequência, também conhecido como sinal de aproximação, e os demais são sinais de alta frequência, conhecido como sinais de detalhes da série original. A saída da RNA neste modelo apresenta as velocidades de vento previstas para as 24 horas do dia seguinte. Para obtenção da geração prevista é utilizada a curva de potência. A Figura 8 representa este modelo. .

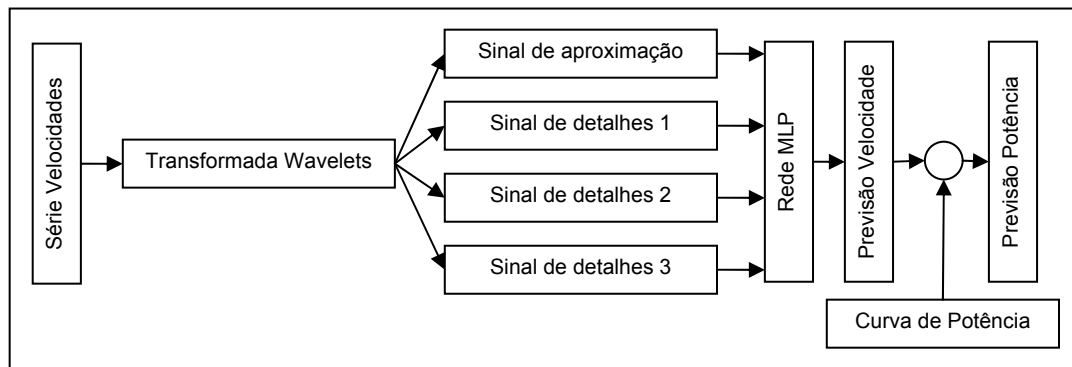


FIGURA 8 – Modelo RNA + TW

A arquitetura da RNA deste modelo foi determinada exatamente como a do modelo neural anterior e conforme (9) e (8). Ficando assim com 96 entradas, onde estas representam os coeficientes de aproximação e de detalhes 1, 2, e 3 das 24 horas que antecedem a previsão; 28 neurônios na camada oculta e 24 na camada de saída.

5.2.1 Resultados e Testes

Neste modelo, assim como modelo anterior, também foi utilizado o método de validação cruzada, k-fold, com objetivo de melhor distribuídos entre os conjuntos de treinamento, validação e teste. O resultado encontrado durante o teste pode ser verificado através das Figuras 9 e 10, quanto ao erro médio absoluto da capacidade instalada, MAE_{CAP} , encontrado durante o teste deste modelo foi 5,35%.

6.0 - ANÁLISES COMPARATIVAS

É observado com a ajuda dos histogramas dos erros de previsões dos modelos, nas Figuras 4, 7 e 10, que os modelos aqui avaliados são todos não tendenciosos. Entretanto, ficou evidenciado a diferença de performance entre os modelos durante os testes, principalmente, com relação ao modelo estatístico cujo MAE_{CAP} foi 16,30%.

A diferença de performance entre os modelos de previsões desenvolvidos neste trabalho pode ser explicado através de alguns fatores, são eles:

- Baixo valor dos coeficientes de autocorrelação da série de velocidades para previsão de 24h, no caso do modelo estatístico ARMA(5,4).
- Capacidade da RNA representar problemas não lineares contribuiu significativamente para a melhora das previsões, enquanto o modelo estatístico ARMA não tem a mesma característica, pois este é desenvolvido através de regressões lineares.




FIGURA 9 - Previsão do Modelo RNA + TW

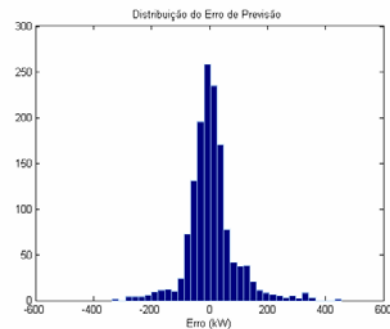


FIGURA 10 - Histograma do Modelo RNA + TW

- Dificuldade de parametrizar as ordens do modelo estatístico, ARMA, que obtivesse melhor desempenho, devido à complexidade do problema. Enquanto nos modelos neurais, o conhecimento do problema é passado através do mapeamento entrada-saída, durante o treinamento.
- Quanto à diferença de desempenho entre os modelos baseados em RNA, deveu-se a decomposição da série a partir da TW, reduzindo os ruídos da série original e enfatizando as partes mais representativas da mesma.

7.0 - CONCLUSÕES

Constatou-se neste trabalho a superioridade em desempenho dos modelo neurais, quando comparado ao modelo estatístico de previsão de geração eólica. Além disso, verifica-se que apesar da simplicidade dos modelos aqui propostos suas performances foram compatíveis com modelos mais complexos mostrados em (1) e (2).

A análise de multiresolução da série usando TW, que decompôs a série original de velocidade dos ventos em um sinal de aproximação e três sinais de detalhes, possibilitou uma melhora nos resultados encontrados. Para o modelo neural sem utilizar a TW, o erro MAE_{CAP} foi 5,60%, já no modelo que usou a TW o erro MAE_{CAP} foi 5,35%.

Contudo, a perspectiva de melhorar os resultados aqui apresentados é uma realidade, pois a série utilizada contém dados insuficientes para passar o conhecimento até rede neural do fenômeno em análise, haja vista, que os ventos podem ser influenciados por outras grandezas, tais como, temperatura, pressão e umidade conforme (1).

8.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) ERNST, B., ROHRIG, K.. Online-Monitoring and Prediction of Wind Power in German Transmission System Operation Center. World Wind Energy Conference, November 2003; http://www.iset.uni-kassel.de/abt/FB-I/publication/03-11-01_WWEC2003.pdf.
- (2) SIDERATOS, G., HATZIARGYRIOU, N.D., Application of Radial Basis Function Networks for Wind Power Forecasting . Lecture Notes in Computer Science, ICANN Greece set/ 2006, v. 4132, p. 726-735, 2006.
- (3) MILIGAN, M., SCHWARTZ, M., WAN, Y. Statistical Wind power forecasting Models: Results for U.S Wind Farms. National Renewable Energy Laboratory, 2003, CP 500-33956.
- (4) ALEXIADIS, M.C., DOKOPOULOS, P. S., SAHSAMANOGLU, H. S., Wind Speed and Power Forecasting based on Spatial Correlation Models. IEEE Transactions on Energy Conversion, Vol 14, No. 3, September 1999 pp 856-842.
- (5) REIS, A. J. R., SILVA, A., Previsor Neural de Carga Elétrica Baseado em Análise de Multiresolução Via Wavelets. VIII SEPOPE- Symposium of Specialists in Electric Operational and Expansion Planning. mai/2002, Cd Rom- IP-052, Brasília – DF- Brasil.
- (6) Riedmiller, M., Braun, H., A direct adaptive method for faster backpropagation learning: The RPROP algorithm, IEEE International Conference on Neural Networks, vol.1, 1993, pp.586-591..
- (7) LIRA, MILDE MARIA DA SILVA ; AQUINO, R. R. B. ; FERREIRA, AIDA ARAÚJO ; CARVALHO JR, M. A. ; LIRA, CARLOS ALBERTO BRAYNER . Improving Disturbance Classification by Combining Multiple Artificial Neural Networks. In: IEEE World Congress on Computational Intelligent / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 3436-3442.
- (8) AQUINO, R. R. B. ; FERREIRA, AIDA ARAÚJO ; LIRA, MILDE MARIA DA SILVA ; SILVA, GEANE BEZERRA DA ; NÓBREGA NETO, OTONI ; OLIVEIRA, JOSINALDO BEZERRA DE ; DINIZ, CARLOS FREDERICO DIAS ; FIDELIS, JUCLAR . A Hybrid Intelligent System for Short and Mid-term Forecasting for the CELPE

Distribution Utility. In: IEEE World Congress on Computational Intelligent / IJCNN 2006, 2006, Vancouver, BC, Canada. IEEE Xplore, 2006. p. 2556-2661.

- (9) FERREIRA, AIDA A. Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais. Dissertação de mestrado, UFPE, Recife-PE, 2004.
- (10) MONTGOMERY, DOUGLAS C., JOHNSON, LYNWOOD A., GARDINER, John S. Forecasting and Time Series Analysis. McGraw-Hill International Editions, 1990.

9.0 - DADOS BIOGRÁFICOS

Ronaldo Ribeiro Barbosa de Aquino

Nascido em Recife, PE em 06 de janeiro de 1962.

Doutorado (2001) em Engenharia Elétrica pela Universidade Federal de Campina Grande e Mestrado (1995) e Graduação (1983) em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Atualmente é Professor Adjunto II da Universidade Federal de Pernambuco.

Área de atuação: Sistemas Elétricos de Potência. Atuando principalmente nos seguintes temas: Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações em despacho hidrotérmico, previsão de carga elétrica e ventos, classificação de distúrbios, detecção falhas em isoladores e transformadores de potência.

Josinaldo Bezerra de Oliveira

Nascido em Goiana, PE em 06 de Junho de 1981

Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (2006).

Atualmente é mestrando em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Área de atuação: Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações em despacho hidrotérmico, previsão de carga elétrica e ventos, classificação de distúrbios, detecção falhas em isoladores.

Otoni Nóbrega Neto

Nascido em Recife, PE, em 14 de setembro de 1980.

Mestrado em Engenharia Elétrica pela Universidade Federal de Pernambuco (2006). Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (2004).

Atualmente é doutorando em Engenharia Elétrica pela Universidade Federal de Pernambuco. Tem experiência na área de Sistemas Elétricos de Potência. Atuando principalmente nos seguintes temas: Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações em despacho hidrotérmico, previsão de carga elétrica.

Milde Maria da Silva Lira

Nascida em Recife, PE em 20 de abril de 1961.

Doutorado (2004), Mestrado (1999) e Graduação (1989) em Engenharia Elétrica: UFPE.

Atualmente é professora da UFPE através da bolsa do PRODOC/ CAPES.

Áreas de Atuação: Sistemas Elétricos de Potência. Atuando principalmente em qualidade da energia elétrica, redes neurais artificiais, lógica fuzzy e transformadas wavelets.

Aida Araújo Ferreira,

Nascida em Recife, PE em 12 de fevereiro de 1967.

Mestrado (2004) em Ciência da Computação pela Universidade Federal de Pernambuco e Graduação (1989) em Ciência da Computação pela Universidade Católica de Pernambuco.

Atualmente é doutoranda em Ciência da Computação pela Universidade Federal de Pernambuco e professora do Centro Federal de Educação Tecnológica de Pernambuco.

Área de atuação: Ciência da Computação, com ênfase em Sistemas de Computação. Atuando principalmente nos seguintes temas: redes neurais artificiais, sistemas híbridos e sistemas de previsão.

Pedro André Carvalho Rosas

Nascido em em 10 de Fevereiro de 1974.

Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (1996) , mestrado em Engenharia Mecânica pela Universidade Federal de Pernambuco (1999) e doutorado em Electrical Power Engineering pela Technical University of Denmark (2003).

Atualmente é professor adjunto I da Universidade Federal de Pernambuco.

Áreas de atuação: Sistemas Elétricos de Potência. Atuando principalmente em Power Quality, Voltage Stability, Turbinas eólicas, Wind turbine, Wind modelling.

Gabriela Seabra Melo e Santos

Nascida em Recife, PE em 22 de Agosto de 1982

Graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (2006).

Atualmente é mestranda em Engenharia Elétrica pela Universidade Federal de Pernambuco.

Área de atuação: Sistemas Elétricos de Potência, Redes neurais artificiais e outras técnicas de inteligência artificial e suas aplicações detecção falhas em isoladores, previsão de carga elétrica e ventos, classificação de distúrbios.