

PREVISÃO DE CURTO PRAZO DA GERAÇÃO EÓLIO-ELÉTRICA PARA O NORDESTE BRASILEIRO POR REDES NEURAIS ARTIFICIAIS

André Rodrigues Gonçalves – andre.rodrigues@cptec.inpe.br

Enio Bueno Pereira – enio.pereira@cptec.inpe.br

Fernando Ramos Martins – fernando.martins@cptec.inpe.br

Instituto Nacional de Pesquisas Espaciais, Centro de Ciência do Sistema Terrestre

Resumo. A capacidade eólica instalada vem crescendo consistentemente em diversos países nos últimos anos. Por se tratar de uma forma de energia relativamente recente, seu desenvolvimento tecnológico ocorre paralelamente à expansão da indústria de geração eólica. Devido a seu caráter altamente variável no espaço e no tempo, um dos grandes desafios impostos por esta fonte consiste em prever a potência eólica disponível em um momento futuro, de modo a otimizar o despacho de energia pelo órgão gerenciador do sistema elétrico. Apesar dos inúmeros estudos efetuados no exterior, pouco se avançou nesta área no Brasil, onde a capacidade eólica instalada vem atingindo patamares significativos, predominantemente na região Nordeste. Este trabalho se propõe a desenvolver um modelo de previsão de potência disponível a curto-prazo para a região Nordeste utilizando a técnica de redes neurais artificiais alimentada por dados das saídas operacionais do modelo de previsão do tempo Eta20km do CPTEC/INPE. É apresentada uma discussão sobre a previsão de vento a curto-prazo e avaliado o impacto dos erros atuais na previsão da potência eólica disponível. Os resultados finais do trabalho devem corroborar a hipótese de que um ganho significativo nas previsões de vento pode ser alcançado a partir de um modelo de ajuste estatístico baseado em redes neurais artificiais.

Palavras-chave: Energia Eólica, Previsão de Vento, Refinamento Estatístico, Redes Neurais Artificiais

1. INTRODUÇÃO

Nas últimas décadas têm-se observado uma inserção crescente da geração eólio-elétrica na matriz energética mundial e a perspectiva é que esta seja ainda mais acentuada no futuro (WWEA, 2009). Este crescimento se justifica principalmente pelo estágio de maturidade tecnológica alcançado pela indústria eólica, que possibilitou à redução do custo da eletricidade produzida, aliado às metas mais ousadas de redução das emissões de CO₂ dada a pressão internacional para mitigar as possíveis causas do aquecimento global.

A energia eólica, assim como outras formas de energia dependentes da dinâmica de nossa ecosfera como a solar e das marés, apresenta grande variabilidade temporal, tornando necessário que se desenvolvam ferramentas de maior confiabilidade para a previsão de curto prazo da potência disponível. Estas ferramentas além de permitirem um melhor gerenciamento do sistema elétrico, auxiliam também na manutenção programada dos aerogeradores, reduzindo os riscos de danos por ventos extremos e tornando a energia eólica mais competitiva no mercado de eletricidade mundial.

Devido à incerteza associada à potência disponível, existe uma discussão na comunidade internacional sobre os limites seguros para a penetração da energia eólica na matriz energética de um país (Landberg *et al.* 2003), sendo que algumas economias já experimentam uma inserção próxima dos 20%, o que torna o aprimoramento das ferramentas de previsão um fator determinante para a segurança energética nacional.

As previsões de vento a curto prazo tem implicações também na capacidade de despacho de energia elétrica pelas linhas de transmissão e, portanto, no gerenciamento do sistema elétrico. O vento é um dos principais parâmetros meteorológicos que controlam a capacidade de dispersão do calor gerado devido ao aquecimento dessas linhas pelo Efeito Joule.

1.1. A energia eólica no Brasil

O Brasil possui um potencial eólico estimado de 143GW (Amarante *et al.* 2001), no entanto este valor pode ser ainda maior devido ao aumento das dimensões dos aerogeradores e à possibilidade de exploração do potencial *offshore*. Adicionalmente, projeções de cenários climáticos futuros indicam que este potencial tende a aumentar, (Pes, 2010) o que coloca o país em uma posição privilegiada no cenário mundial da energia eólica. Tal abundância se verifica principalmente nas regiões Nordeste, Sudeste e Sul, com predominância das regiões costeiras, o que se configura como uma vantagem para a transmissão elétrica dada a maior densidade de linhas de transmissão para a geração descentralizada com grandes centros urbanos, e da malha viária, o que repercute favoravelmente no custo dos projetos eólicos.

A região Nordeste brasileira possui ainda uma particularidade que é a complementaridade hidro-eólica, uma vez que as vazões dos rios e o regime de ventos possuem um ciclo sazonal alternado, que somado ao despacho

complementar das usinas termoelétricas permite o ajuste à demanda de eletricidade garantindo a segurança da geração elétrica na região. Este gerenciamento só é possível devido ao Sistema Interligado Nacional (SIN) que permite remanejamento das cargas pelo Operador Nacional do Sistema (ONS).

Embora com certa defasagem em relação à expansão mundial, nos últimos anos o país vem experimentando um forte crescimento no setor eólico, impulsionado principalmente pelo PROINFA (Dutra e Szklo, 2007), onde projeções futuras indicam que a penetração eólica brasileira superará 1% até 2012 segundo dados do Balanço Energético Nacional (BEN 2008). Neste contexto, se faz cada vez mais necessário o desenvolvimento de uma metodologia para a previsão de energia eólica de curto prazo adequada ao território brasileiro, que seja embasada nas previsões numéricas disponibilizadas operacionalmente no país e compatível com o clima tropical, permitindo assim que as usinas eólicas adquiram maior competitividade e que o sistema elétrico seja gerenciado de forma otimizada.

1.2. Previsão de geração a curto-prazo

A previsão de potência eólica disponível está intimamente relacionada à previsão do vento próximo à superfície, tratando-se, portanto de objeto de estudo das ciências atmosféricas. De maneira geral, se forem desprezadas perdas devido à instalação dos aerogeradores, que são características de cada parque, a potência disponível se torna uma função da velocidade do vento, conforme a curva de potência de um aerogerador de 2,1 MW disponível no mercado mostrada na figura (1).

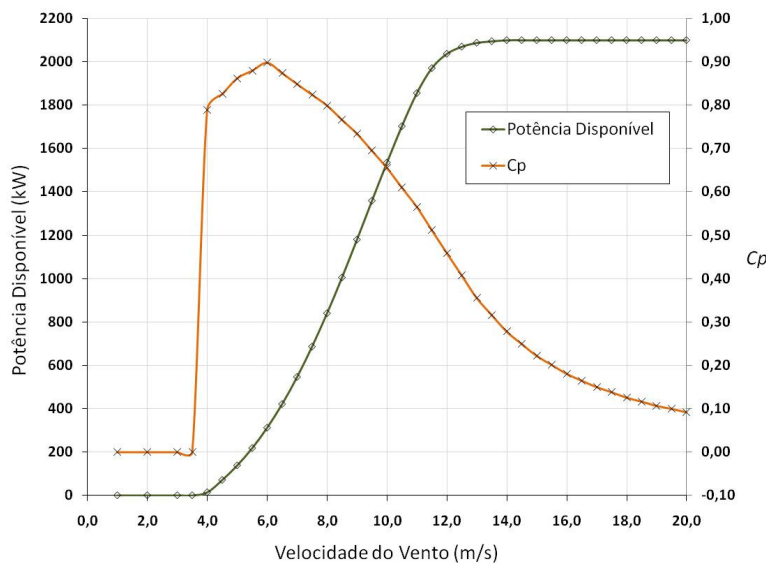


Figura 1. Curva de potência típica de um aerogerador de 2,1 MW.

É importante ressaltar que no intervalo operacional de ventos típico do aerogerador a potência disponível é função do cubo da velocidade do vento, de maneira que os erros na previsão de vento são amplificados quando convertidos em potência e justificando assim a necessidade de previsões de vento cada vez mais confiáveis. (Burton *et al.* 2001). Esta relação é representada pela equação (1), onde A é a área de giro da pá, ρ a densidade do ar, U o vento, e P a potência final disponível de um aerogerador. Conforme ilustrado o coeficiente de potência C_p varia significativamente e é também uma função da velocidade do vento.

$$P = C_p \cdot A \cdot \rho \cdot U^3 \quad (1)$$

No entanto os modelos de Previsão Numérica de Tempo (PNT), disponíveis operacionalmente foram desenvolvidos tendo como principal objetivo a previsão dos fenômenos físicos em escalas maiores, como o deslocamento de massas de ar e o avanço de frentes, e possuem uma resolução espacial da ordem de 10km, desprezando ou simplificando através de parametrizações alguns fenômenos micrometeorológicos o que resulta em uma performance degradada dentro da Camada Limite Atmosférica (CLA), onde estão os aerogeradores. Nesta camada da atmosfera as grandezas apresentam grande flutuação ao longo do tempo, devido à turbulência térmica e mecânica presente no escoamento, e como este ainda não é um processo físico completamente compreendido existe grande dificuldade em sua modelagem matemática (Stull, 1988). A aproximação para o perfil vertical comumente adotada na camada superficial corresponde a um perfil logarítmico, como descrito pela equação (2), onde U^* é a velocidade de fricção, Z_0 o comprimento de rugosidade, k a constante de Von Karman e Z a altura do solo. No entanto vale ressaltar que U^* varia significativamente em função da estabilidade atmosférica, o que exige o desenvolvimento de aproximações como a teoria da similaridade de Monin-Obukhov, desenvolvida a partir de 1954 e implementada em diversos modelos meteorológicos (Focken, 2006).

$$U = \frac{U^*}{k} \cdot \ln\left(\frac{Z}{Z_0}\right) \quad (2)$$

Nos últimos anos muitos estudos foram realizados utilizando técnicas diversas visando a otimização destas previsões de vento, desde modelagem física em microescala (Lange, 2006) até ferramentas estatísticas diversas (Fan *et al.*, 2009). Comumente opta-se por uma combinação entre estas técnicas para uma melhor performance das previsões (Costa *et al.*, 2006), (Ernst *et al.*, 2007).

No Brasil foram efetuados alguns estudos nesta área como, por exemplo a extrapolação de séries temporais de vento (Oliveira, 2008), a qual apresenta limitações para horizontes de previsão superior a 24 horas. Há exemplos também de trabalhos onde variáveis meteorológicas prognósticas como temperatura e pressão foram incluídas como preditores para um modelo estatístico (Dalmaz, 2007). Entretanto os resultados obtidos até o momento ainda são modestos quando comparados a modelos desenvolvidos em outros países (Guenard *et al.*, 2007), o que abre um leque de oportunidades e desafios para pesquisa nessa área.

Este trabalho apresenta uma metodologia que utiliza saídas operacionais do modelo ETA acoplado a um esquema de redes neurais artificiais com o fim de desenvolver um aplicativo de previsão de produção de energia eólica. A rede foi treinada para com base em dados anemométricos de torres localizadas em uma área-teste na região Nordeste do país.

1.3. Redes Neurais Artificiais

As redes neurais artificiais (RNA) surgiram como uma ferramenta para representar uma relação entre um conjunto de variáveis de entrada e saída, que é até então desconhecida, a partir de um conjunto de dados de treinamento. Se corretamente empregada possui a capacidade de representar fenômenos físicos complexos, e por isso ultimamente vêm sendo largamente empregada nas geociências propiciando grande avanço na modelagem (Mendes e Marengo, 2009). Sua principal vantagem em relação às regressões lineares múltiplas é justamente a capacidade de representar processos não-lineares. Neste estudo especificamente, devido ao caráter turbulento das variáveis meteorológicas no interior da CLA, as componentes não-lineares das equações de Navier-Stokes não podem ser desprezadas, justificando assim a melhor performance dos modelos de RNAs em relação à regressão linear múltipla para representação dos fenômenos micrometeorológicos. A principal vantagem das RNAs em relação à modelagem física é o custo computacional extremamente baixo. No entanto, a RNA apresenta desvantagens como a especificidade espacial, isto é, baixa capacidade de generalização, e a necessidade de uma base de dados observados suficientemente grande para representar as diferentes condições do processo físico a ser modelado.

Diversas são as possibilidades de estruturação de uma RNA, uma vez que é necessário selecionar o tipo de neurônio, o número de parâmetros de entrada, o número de camadas ocultas, o tipo de treinamento, sendo que testes com diferentes configurações são geralmente empregados para a definição de sua arquitetura (Haykin, 1997). Para se desenvolver um modelo de RNA é necessário que se tenha um conjunto de parâmetros de entrada, ou preditores, e um conjunto de saída, ou preditando. Esses conjuntos serão subdivididos para uso em duas etapas diferentes: treinamento da rede e validação das estimativas produzidas. A correta seleção dos preditores é fundamental para um bom desempenho do modelo (Mori e Umezawa, 2009).

2. DADOS

2.1. Dados de Campo

Os dados observacionais disponíveis para este trabalho são oriundos da rede SONDA, além de dados coletados no estado de Alagoas cedidos por colaboradores (Costa, 2009). Os dados foram coletados em torres anemométricas com diversos níveis de medição e constituídos por séries de intensidade e direção do vento conforme descrito na Tabela 1. A aquisição de dados possui resolução temporal de 10 minutos, mas a base de dados foi convertida para médias horárias devido à limitação na resolução dos preditores, originário dos modelos meteorológicos.

Adotou-se o Nordeste brasileiro como zona de treinamento, por se tratar da região de maior concentração de potencial eólico no Brasil. Foi observada a distribuição geográfica das torres para uma melhor representação do território, de modo que 3 torres se localizam no litoral e outras 4 torres no interior do continente como ilustra a Figura 2.

O período dos dados varia em função de cada torre, no entanto todas possuem pelo menos 12 meses completos e ininterruptos, possibilitando que o modelo desenvolvido identifique as variações sazonais do vento. Os dados que excedem este período podem ser usados para validação do modelo uma vez que lacunas nas séries não influenciam a habilidade de previsão da RNA depois de treinada. Cabe ressaltar que todos os dados estão compreendidos no intervalo de Agosto de 2006 a Abril de 2009 e foram qualificados de acordo com a metodologia de controle de qualidade desenvolvida para a rede SONDA e descrita em <http://sonda.cptec.inpe.br>.

Tabela 1. Características das torres anemométricas

ESTAÇÃO	SIGLA	ALTITUDE	ALTURA TORRE	NÍVEIS DE MEDIÇÃO
Água Branca - AL	AGB	718m	50m	30m/50m
Alcântara - MA	ALT	30m	70m	10m/28,5m/43m/70m
Girau do Ponciano - AL	GRP	410m	50m	30m/50m
Maragogi - AL	MRG	50m	50m	30m/50m
Petrolina - PE	PTR	387m	50m	10m/25m/50m
Roteiro - AL	RTR	60m	50m	30m/50m
São João do Cariri - PB	SJC	486m	50m	10m/25m/50m



Figura 2. Localização das torres

2.2. Dados provenientes do modelo Eta/CPTEC

O Eta é um modelo de mesoescala de previsão numérica de tempo que vêm sendo desenvolvido internacionalmente para fins operacionais e de pesquisa meteorológica há mais de 20 anos. Sua principal inovação em relação a outros modelos de mesoescala foi a introdução da coordenada vertical *eta* (η) em substituição à usual coordenada *sigma* (σ), pois enquanto esta acompanha o contorno do relevo a primeira discretiza o relevo em degraus, o que tem por objetivo reduzir erros no cálculo dos gradientes horizontais (Black, 1994) e (Chou, 1996).

No Brasil, o Eta roda operacionalmente desde 1996 pelo Centro de Previsão do Tempo e Estudos Climáticos (CPTEC/INPE) e vêm sendo constantemente aperfeiçoado e adaptado para uma melhor performance nas previsões de tempo sobre o continente Sul-americano, sendo denominado Eta/CPTEC. Apesar do avanço contínuo nos modelos meteorológicos estes ainda apresentam limitações em sua utilização para previsões próximas da superfície pois sua resolução horizontal é constituída de grades de algumas dezenas de quilômetros, não captando adequadamente aspectos micrometeorológicos de cada região. Além disso, muitas variáveis dentro da CLA não são parametrizadas dada a dificuldade de estimar seus valores em função da turbulência atmosférica, o que acarreta erros significativos para determinadas condições atmosféricas (Janjic, 1994).

Desde 2006 o modelo Eta está operacional na resolução espacial de 20x20 km onde são disponibilizadas saídas a cada 6 horas para um horizonte de previsão de 7 dias. Estas saídas constituem um total de 58 variáveis sendo 9 dispostas em 19 níveis de pressão, totalizando um grande volume de dados. Para alguns pontos de grade são gerados meteorogramas com resolução horária, permitindo assim a verificação detalhada do ciclo diário. Para este estudo foram selecionados e utilizados dados de saída do modelo Eta/CPTEC como preditores para a RNA fornecidos para o mesmo

período de disponibilidade dos dados de campo. Para os pontos com resolução temporal de 6 horas, os valores intermediários foram interpolados criteriosamente tendo como referência a grade mais próxima com resolução temporal horária. Cabe ainda ressaltar que as estimativas de vento do modelo Eta/CPTEC são disponibilizados para 10m de altura acima da superfície enquanto que as observações apresentam-se em diversos níveis.

3. METODOLOGIA

Primeiramente foram extraídos os dados do modelo Eta para os pontos de grade mais próximos de cada torre anemométrica através do software GrADS. Este procedimento gerou arquivos que armazenam apenas as variáveis potencialmente de interesse para a previsão de vento foram mantidas: 41 variáveis de superfície e 7 níveis de pressão.

A fim de se avaliar a habilidade do modelo Eta em prever o vento em superfície, foram feitas comparações entre o vento previsto e o observado para as diversas estações com horizonte de previsão de 24 horas. Os dados foram dispostos em forma de dispersão e foi calculado o coeficiente de correlação (R), o erro médio (ME) ou viés, e a raiz do erro médio quadrático (RMSE) todos para o nível de 10m. As equações (3), (4) e (5) descrevem o método de cálculo de cada um destes índices, onde P são dados previstos e O dados observados.

$$R = \frac{\sum_{i=1}^N (P_i - \bar{P})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^N (P_i - \bar{P})^2} \cdot \sqrt{\sum_{i=1}^N (O_i - \bar{O})^2}} \quad (3)$$

$$ME = \frac{1}{N} \sum_{i=1}^N (P_i - O_i) \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (5)$$

Nesta primeira análise optou-se por não fazer comparações em níveis mais elevados uma vez que a extrapolação vertical da saída do modelo poderia introduzir outros tipos de erro na análise. Posteriormente, procedeu-se a avaliação do modelo na previsão da potência eólica disponível ao longo do tempo, onde foi efetuada a conversão do vento observado em potência eólica observada a 50m empregando a Equação 1. Neste caso, o vento estimado pelo modelo Eta foi extrapolado através dos perfis verticais observados experimentalmente até a altura de 50m e também convertido em potência eólica disponível. A curva de potência utilizada para a conversão dos dados de vento foi a mesma ilustrada na Figura 1, que corresponde a de um gerador eólico típico com potência nominal de 1,5 MW. Os índices utilizados para a avaliação das previsões de potência foram os mesmos utilizadas nas previsões de vento e ambas análises foram efetuadas para dois períodos característicos, um mês seco e um mês chuvoso da região nordeste. Cabe ressaltar que alguns estudos discutem que os índices a serem minimizados variam em função do tipo de acordo de compra e venda de energia estabelecido entre o gerador e o comprador (Ravn, 2006), no entanto optou-se por manter os mesmos índices usados para avaliação do vento para permitir a avaliação do impacto deste sobre a energia produzida.

No desenvolvimento do modelo de previsão por RNA está sendo realizada inicialmente a seleção dos preditores, que a princípio pode ser qualquer conjunto das variáveis de interesse previamente selecionadas das saídas do modelo Eta/CPTEC. É interessante que se reduza ao máximo o número de preditores na RNA para evitar instabilidades devido ao número excessivo de pesos ajustáveis na rede e assegurar um bom processo de aprendizado mesmo para séries curtas. A primeira análise realizada é a separação por conjuntos utilizando a técnica de 'clustering' (Wilks, 2006), uma vez que alguns preditores podem apresentar uma forte correlação entre si, tornando desnecessária a inclusão de ambos. O próximo passo consiste no teste da correlação entre as séries de preditores (variáveis do modelo) e o preditando, que no caso é a intensidade do vento a 50m. Estes testes são executados para defasagens temporais distintas entre preditando e preditores para garantir a eliminação de qualquer atraso que possa existir entre observação e modelo. Cumprida esta etapa, as entradas da RNA estão definidas, no entanto foi preciso assegurar que a resolução temporal de todas as séries fosse a mesma, interpolando os valores para as variáveis com resolução temporal menor de forma a se obter dados horários.

O tipo de arquitetura inicialmente definida para a RNA é de Perceptrons de Múltiplas Camadas (*Multilayer Perceptron-MLP*), pois trata-se de uma RNA não-recorrente, com uma ou mais camadas ocultas capaz de implementar qualquer função contínua e por isso bastante usada em diversas áreas da ciência (Braga, 1996). O treinamento adotado é o algoritmo *Rprop* que parece levar a tempos menores de treinamento em relação ao algoritmo de *retropropagação* (Guarnieri, 2006). O número de camadas ocultas será definido em função dos resultados obtidos para cada configuração. A ferramenta computacional adotada para o desenvolvimento do modelo é o *Neural Network Toolbox* do MATLAB®. A rede está sendo treinada utilizando-se as previsões para t+24 horas do modelo Eta/CPTEC, onde t é o

tempo inicial, implicando portanto que previsões com maior antecedência sejam afetadas apenas pela degradação na acuracidade do próprio modelo Eta. As séries observacionais foram divididas em um parcela de treinamento e outra de validação para cada torre, sendo que em média 2/3 dos dados serão utilizados no treinamento da RNA.

A performance do modelo de previsão por RNAs será avaliada de forma similar ao modelo Eta, com a diferença que o modelo RNA gera as saídas de vento já a 50m do solo. Os mesmos índices serão utilizados na análise, porém será adicionado o cálculo do *Skill*, que é uma medida do ganho de um modelo em relação a outro para um determinado índice estatístico, conforme descrito na equação (6), onde no caso será avaliada a redução do RMSE do modelo RNA em relação ao Eta para as previsões de vento e potência disponível. Poderão ainda ser feitas avaliações dos modelos para cada estação do ano, ou a avaliação cruzada entre modelos de torres distintas, para se analisar capacidade de generalização obtida.

$$Skill(RMSE, Eta) = \frac{RMSE_{RNA} - RMSE_{Eta}}{RMSE_{Eta}} \quad (6)$$

4. DISCUSSÃO

Conforme discutido anteriormente, os modelos de PNT apresentam dificuldades na previsão de ventos próximo à superfície. Alguns estudos avaliaram o desempenho do modelo Eta tanto no Brasil como no exterior. Lazic *et al.* (2009) utilizando grades aninhadas de 3,5km para avaliação das previsões de vento, onde as comparações com dados observados levaram a ME de 0,48 m/s, RMSE de 1,38 m/s e coeficientes de correlação de 0,79 a 10m do solo. No Brasil foram realizados testes de sensibilidade no modelo Eta com intuito de se avaliar o ganho de acuracidade das previsões de vento (Lyra, 2008). Foi utilizada uma resolução espacial de 5 km, e os melhores resultados levaram a ME de -0,98 m/s, RMSE de 2,08 m/s e coeficientes de correlação de 0.79 a 10m do solo. Cabe ressaltar que neste trabalho também foram efetuadas comparações para a torre de Alcântara, usada neste experimento, onde os resultados mais próximos para o nível de 50m apresentaram desvios elevados e coeficientes de correlação baixos indicando que o modelo Eta não foi capaz de interpretar a dinâmica atmosférica local de maneira satisfatória.

A fim de verificar o comportamento do modelo Eta/CPTEC numa resolução espacial menor (20km) em função do uso das rodadas operacionais no CPTEC/INPE foi realizada a validação das estimativas com as observações obtidas na torre de Roteiro-Al para o mês de novembro de 2007. Esta torre possui uma vantagem na execução das comparações pois existem saídas do modelo Eta20km com resolução horária para pontos de grade próximos à torre. Para permitir a comparação ao mesmo nível do solo, as saídas do modelo, tipicamente a 10m, foram ajustadas para altura observada de 30m através de ajuste linear pela equação (2). Os resultados apresentaram ME de 2,59m/s, RMSE de 3,27 m/s e coeficientes de correlação inferiores a 0.16 para as previsões de vento. O gráfico comparativo e a dispersão para o vento estão ilustrados nas Figura 3 e 4, respectivamente. Esta análise preliminar sugere que o modelo Eta/CPTEC, utilizado operacionalmente para a previsão de tempo, tende a subestimar sistematicamente o valor de vento próximo a superfície, o que leva a subestimativas importantes na previsão de energia gerada ao final de um dia. Este resultado está em acordo com os obtidos pelos estudos anteriores. Esse procedimento de validação foi também realizado para as outras torres anemométricas listadas na Tabela 1, e apresentaram desvios incompatíveis com o objetivo de previsão de geração eólica através das saídas operacionais diretas do modelo. Isso justifica o emprego de técnicas de ajuste através de RNAs, treinadas para cada região de interesse, foco desse trabalho.

5. CONSIDERAÇÕES FINAIS

A previsão de potência eólica disponível já se mostrou essencial em países onde o a penetração desta forma de energia é significativa, estando relacionada à segurança, competitividade e eficiência do setor eólico-elétrico. No Brasil, entretanto, esta ainda é uma tecnologia incipiente com poucos estudos publicados. O principal objetivo do presente trabalho é a validação de uma metodologia passível de implementação operacional para parques eólicos no Nordeste brasileiro. Para isso mostrou-se necessário fazer um diagnóstico da capacidade atual de previsão de potência disponível, onde os resultados preliminares indicam que a performance do modelo numérico operacional Eta/CPTEC é bastante limitada, justificando o desenvolvimento de metodologia que produza estimativas de maior confiabilidade. Os resultados por vir devem corroborar a hipótese de que se pode obter ganhos significativos nas previsões através do acoplamento de modelos estatísticos baseados em RNAs às saídas operacionais, com resolução espacial de 20km, do modelo Eta/CPTEC.

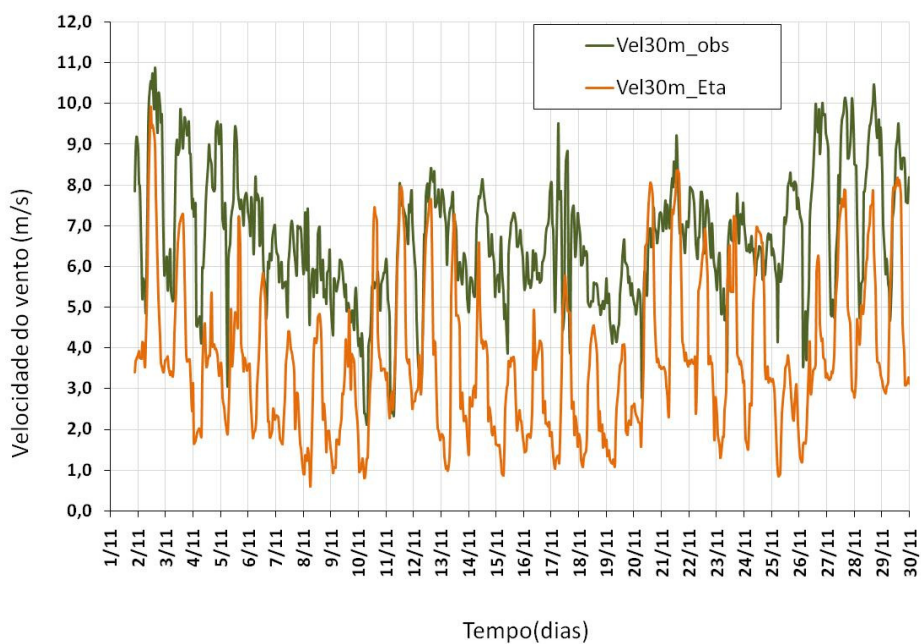


Figura 3. Comparação entre velocidade do vento modelada e observada para 30m do solo

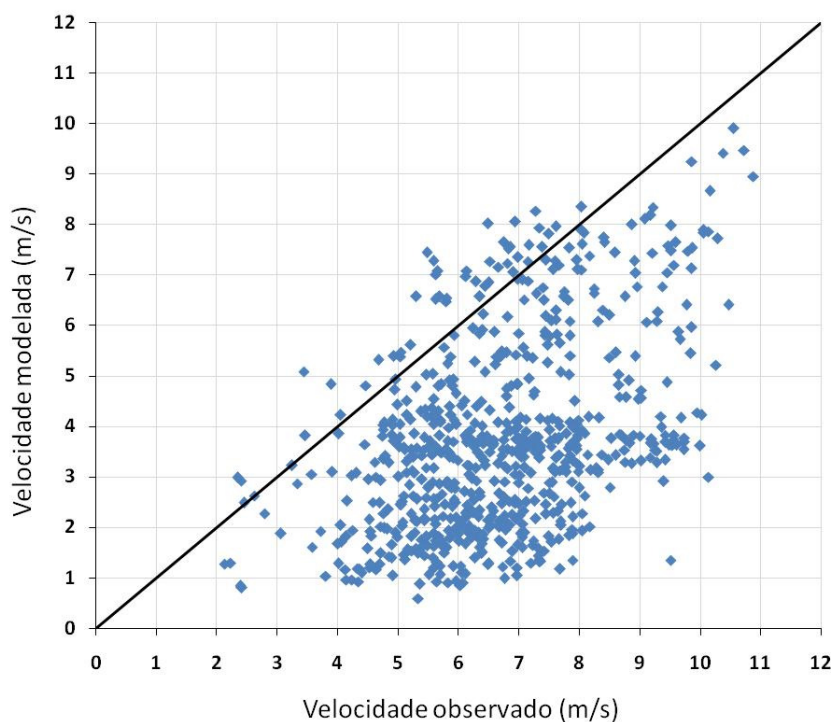


Figura 4. Dispersão entre velocidade do vento modelada e observada para 30m do solo

Agradecimentos

O autor agradece à CAPES por financiar este trabalho através da concessão da bolsa de mestrado, ao INPE por fornecer a estrutura necessária, ao Prof. Dr. Roberto Lyra da UFAL e ao Prof. Dr. Gilberto Fisch do IAE pela colaboração ao ceder os dados anemométricos, e aos membros do Grupo de Energias Renováveis do CCST-INPE pela ajuda cotidiana .

REFERÊNCIAS

- Black, T. L. 1994. The new NMC mesoscale ETA-model: description and forecast examples, *Weather Forecasting*, vol.9, n.2, pp. 265-278.
- Braga, A. P.; Carvalho A. C. P. F.; Ludermir, T. B., 1998. Fundamentos de redes neurais artificiais, 11a Escola de Computação/Universidade Federal do Rio de Janeiro.
- Burton, T., Sharpe, D., Jenkins, N., Bossanyi, E., 2001. *Wind Energy Handbook*, John Willey & Sons.
- Campbell, P.R.J., 2007. Short-Term Wind Energy Forecasting, *IEEE Canada Electrical Power Conference*, pp. 342-346
- Costa, G. B., 2009. Análise Numérica Espacial e Temporal do Vento no Estado de Alagoas, Dissertação de Mestrado, UFAL, Maceió.
- Costa, A., Crespo, A., Navarro, J., Palomares, A., Madsen, H., 2006. Modelling the Integration of Mathematical and Physical Models for Short-term Wind Power Forecasting, *European Wind Energy Conference - EWEC*, Athens, Greece.
- Chou, S. C., 1996. Modelo Regional Eta. Climanálise, Edição comemorativa de 10 anos,. Disponível em: <<http://www.cptec.inpe.br/products/climanalise/>>.
- Dalmaz, A., 2007. Estudo do potencial eólico e previsão de ventos para geração de eletricidade em Santa Catarina, Dissertação de Mestrado, UFSC, Florianópolis.
- Dutra, R. M. e Szklo, A. S., 2007. Incentive policies for promoting wind power production in Brazil: Scenarios for the Alternative Energy Sources Incentive Program (PROINFA) under the New Brazilian electric power sector regulation, *Renewable Energy*, vol. 33, pp. 65-76.
- Ernst, B., Oakleaf, B., Ahlstron, M. L., Lange, M., Moehrlen, C., Lange, B., Focken, U., Rohrig, K., 2007. Predicting the Wind, *IEEE Power & Energy magazine*, vol. 5, n. 6, pp. 78-89.
- Fan, S., Liao, J. R., Yokoyama, R., Chen, L., Lee, W.J., 2009. Forecasting the Wind Generation Using a Two-Stage Network Based on Meteorological Information, *IEEE Transactions on Energy Conversion*, vol. 24, n. 2.
- Foken, T., 2006. 50 years of the Monin-Obukhov similarity theory, *Boundary-Layer Meteorology*, vol.119, pp. 431-447.
- Guarnieri, R. A., 2008. Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA, Dissertação de Mestrado, PGMET, INPE, São José dos Campos.
- Haykin, S., 1994. *Neural networks: a comprehensive foundation*, Macmillan College Publishing Company.
- Landberg, L., Giebel, G., Nielsen, A., Nielsen, T., Madsen, H., 2003. Short-term Prediction - An Overview, *Wind Energy*, Vol.6, pp. 273-280
- Lange, M., Focken, U. 2006. *Physical Approach to Short-Term Wind Power Prediction*, Springer.
- Lazic, L., Pejanovic, Zivkovic, M. 2009. Wind forecasts for wind power generation using the Eta model, *Renewable Energy*, vol. 35, no.1 pp. 1236-1243.
- Lyra, A. A., 2009. Testes de sensibilidade e avaliação do modelo Eta para a região nordeste, Dissertação de Mestrado, PGMET, INPE, São José dos Campos.
- Janjić, Z. L. The step-mountain Eta coordinate model: further developments of the convection, viscous sublayer, and turbulence closure schemes, *Monthly Weather Review*, vol. 122, n.5, pp. 927-945.
- Guenard, V., Kariniotakis, G., Marti, I., 2007. ANEMOS Advanced Wind Power Forecasting. Operational Challenges and On-line Performance, *European Wind Energy Conference – EWEC*, Milan, Italy.
- Mendes, D., Marengo, J. A., 2009. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios, *Theoretical and Applied Climatology*, publicado on-line em ago/2009.
- Ministério de Minas e Energia (MME). Balanço energético nacional 2009 (BEN 2009). Disponível em: <<http://ben.epe.gov.br/>>
- Ministério de Minas e Energia (MME). PROINFA. Disponível em: <<http://www.mme.gov.br/programas/proinfa>>
- Mori, H. Umezawa, Y. 2009. Application of NBTree to Selection of Meteorological Variables in Wind Speed Prediction, *transmission & Distribution Conference & Exposition: Asia and Pacific*, Seoul, Korea.
- Oliveira, J. B., 2008. Sistemas inteligentes e wavelets para previsão de vento e geração eólica. Dissertação de Mestrado, UFPE, Recife.
- Pes, M. P., 2010. Dissertação de Mestrado, PGMET, INPE, São José dos Campos.
- Ravn, H. F., 2006. Short term wind power prognosis with different success criteria, *9th International Conference on Probabilistic Methods Applied to Power Systems*, Stockholm, Sweden.
- SONDA - Sistema de Organização Nacional de Dados Ambientais. Disponível em: <<http://sonda.cptec.inpe.br/>>
- Stull, R. B. 1988. *An introduction to boundary layer meteorology*. Dordrecht: Kluwer Academic Publishers.
- Wilks, D. S., 2006. *Statistical Methods in the Atmospheric Sciences*, Elsevier.
- World Wind Energy Association - WWEA, 2009. *World Wind Energy Report*. Disponível em: <<http://www.wwindea.org/>>

SHORT-TERM WIND POWER FORECAST USING ARTIFICIAL NEURAL NETWORKS FOR NORTHEAST BRAZIL

Abstract. *The installed wind energy capacity is increasing significantly in many countries worldwide. Since it is a relatively new energy source, its technology development occurs beside the wind industry expansion. Due to its highly variable characteristic in space and time, one of the main challenges is to forecast the available wind power in the future, in order to optimize the energy dispatch by electrical managing institutions. Despite all studies carried out abroad, there are few advances in this subject in Brazil, where the installed wind energy capacity is achieving relevant thresholds, predominantly in the northeast region. This study aims to develop a short-term wind power forecast model from the outputs of CPTEC/INPE Eta20km weather forecast model, using artificial neural networks techniques. It is presented a discussion over short-term wind forecast and the impact of current accuracy on the available wind power. The final results are expected to support the hypothesis that a significant gain in wind forecast performance can be achieved from a statistical adjustment model based on artificial neural networks.*

Key words: Wind Energy, Wind Forecast, Statistical Downscaling, Artificial Neural Networks