



**XXIII SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

FI/GPT/10
18 a 21 de Outubro de 2015
Foz do Iguaçu - PR

GRUPO – II

GRUPO DE ESTUDO DE PRODUÇÃO TÉRMICA E FONTES NÃO CONVENCIONAIS - GPT

PREVISÃO DE SÉRIES DE VELOCIDADE DO VENTO UTILIZANDO ANÁLISE ESPECTRAL SINGULAR E REDES NEURAIS ARTIFICIAIS

Valk L. O. Castellani(*)
CEPEL

Cabral Lima
UFRJ

José F.M. Pessanha
CEPEL

RESUMO

A perspectiva de uma maior participação da energia eólica na matriz energética brasileira indica a necessidade do desenvolvimento de sistemas para previsão da geração eólica em horizontes de curto, médio e longo prazo com a finalidade de apoiar a integração segura e econômica dos aproveitamentos eólicos na operação do sistema elétrico. Este trabalho tem por objetivo apresentar resultados obtidos com o modelo proposto desenvolvido utilizando a decomposição da série temporal utilizando a análise espectral singular e a previsão através das redes neurais artificiais para previsão de curto prazo da velocidade do vento.

PALAVRAS-CHAVE

Energia Eólica, Análise Espectral Singular, Redes Neurais Artificiais, Previsão, Velocidade do Vento

1.0 - INTRODUÇÃO

A necessidade de promover o crescimento econômico sustentável tem contribuído para o desenvolvimento das fontes alternativas e/ou renováveis para geração de energia elétrica. Entre as opções disponíveis a energia eólica, por ser um recurso limpo e abundante, surge como uma das mais promissoras. Principalmente, levando em consideração que o “Atlas do potencial eólico brasileiro” do ano de 2001, estima que o Brasil tem um potencial eólico de aproximadamente 143 GW a 50 metros de altura (1), e por isso, esta é uma das fontes alternativas e/ou renováveis mais promissoras.

Contudo o vento é um recurso não controlável e tem um comportamento estocástico. Por esta razão, a previsão de séries de velocidade de vento se torna um importante objeto de estudos, e para isso podem ser utilizadas uma grande diversidade de técnicas, métodos e modelos. O uso destas previsões estão diretamente ligadas a segurança do suprimento de energia, tais como: (i) a utilização de previsões semanais para elaboração de cronogramas de manutenções do parque eólico; (ii) a utilização de previsões diárias (de hora em hora), auxiliando a tomada de decisões estratégicas; (iii) a utilização de previsões horárias para tomada de decisões de despacho de unidades geradoras.

Sendo assim, as ferramentas para a previsão da velocidade do vento e da produção de energia nos parques eólicos são fundamentais nas decisões relacionadas com os despachos das usinas geradoras, principalmente em sistemas predominantemente hidráulicos, como é o caso do sistema elétrico brasileiro.

Neste trabalho propõe-se um modelo para previsão da velocidade do vento. No modelo proposto são utilizadas duas abordagens: (i) a Análise Espectral Singular (Singular Spectrum Analysis - SSA) (2,3,4), que incorpora

(*) Avenida Horácio Macedo, n° 354 – sala 227 – CEP 21.941-911 Rio de Janeiro, RJ – Brasil
Tel: (+55 21) 2598-6452 – Fax: (+55 21) 2598-6482 – Email: vcastell@cepel.br

elementos da análise clássica de séries temporais, estatística multivariada, geometria multivariada, sistemas dinâmicos e processamento de sinais na análise de séries temporais; (ii) a Rede Neural Artificial (RNA) (5), que são sistemas paralelos distribuídos, compostos por unidades de processamentos simples, denominadas neurônios.

O modelo proposto realiza previsão de curto prazo para velocidade do vento e, é baseado na decomposição da série histórica de velocidade do vento através da SSA, de forma a produzir um conjunto de k séries distintas. Cada uma destas k séries se referenciam a um dos k componentes que representam a série histórica, e para cada um destes componentes são construídos previsores baseados em RNA destinadas à realizar a previsão dos valores seguintes destes componentes. As previsões realizadas para estes k componentes são somadas, e com isso é obtida a velocidade do vento prevista para um horizonte de previsão até 24 horas à frente.

O artigo está organizado em seis seções. A seguir, na seção 2 tem-se uma breve apresentação da SSA e na seção 3 uma descrição resumida das RNA. O modelo proposto é apresentado na seção 4 e os resultados obtidos na seção 5. Por fim, na seção 6 são apresentadas as principais conclusões do trabalho.

2.0 - ANÁLISE ESPECTRAL SINGULAR (SSA)

A SSA é um método não paramétrico empregado na análise e previsão de séries temporais, particularmente na suavização, na filtragem e na extração de periodicidades. A SSA, em sua versão básica, consiste em duas etapas, decomposição e reconstrução, cada uma com dois passos a serem seguidos (2, 3, 4).

2.1 Decomposição

A etapa de decomposição da série temporal via SSA está subdividida em dois passos, incorporação e decomposição em valores singulares (Singular Value Decomposition - SVD). O passo de incorporação consiste em realizar o mapeamento que transfere um vetor unidimensional com os dados da série temporal, por exemplo, $Y=(y_1, y_2, y_3, y_4, y_5, y_6, \dots, y_n)$ em uma sequência de vetores multidimensionais defasados, de acordo com o tamanho da janela L , pré-determinado. Esse parâmetro L deve ser um valor inteiro tal que $2 \leq L \leq N$, onde N é o número de observações da série temporal. Nesse passo, então, é criada a matriz de trajetória X , conforme mostrada abaixo:

$$X = \begin{bmatrix} y_1 & y_2 & y_3 & y_4 & \cdots & y_{N-L+1} \\ y_2 & y_3 & y_4 & y_5 & \cdots & y_{N-L+2} \\ y_3 & y_4 & y_5 & y_6 & \cdots & y_{N-L+3} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & y_{L+2} & y_{L+3} & \cdots & y_N \end{bmatrix} \quad (1)$$

A matriz de trajetória é uma matriz de Hankel cujos elementos x_{ij} são idênticos ao longo de todas as posições da matriz X , onde $i+j$ permanece constante (6).

No segundo passo da decomposição, a SVD (7) é aplicada à matriz X que passa a ser expressa como uma soma de matrizes elementares, ou seja, $X=X_1+X_2+\dots+X_L$. As matrizes elementares de X são obtidas por $X_i = \sqrt{\lambda_i} U_i V_i^T$, onde λ_i é o i -ésimo valor singular de X (os valores singulares são tomados em ordem decrescente de magnitude $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$), U_i é o i -ésimo vetor singular esquerdo de X e V_i é o i -ésimo vetor singular direito de X . Seja $d=\max(i \mid \lambda_i > 0)$, o número de valores singulares diferentes de zero. Assim, a matriz X pode ser expressa pela seguinte equação:

$$X = \sum_{i=1}^d X_i = \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T \quad (2)$$

As matrizes $X_i \forall i=1, d$ têm posto 1 e a coleção (λ_i, U_i, V_i) é chamada de autotripla SVD da matriz X (2).

2.2 Reconstrução

A etapa de *reconstrução* é composta de dois passos, *agrupamento* e *média diagonal*. O passo de *agrupamento* corresponde à classificação das matrizes X_i em grupos e soma destas matrizes elementares dentro de cada grupo. Particionando o conjunto de índices $J=1, \dots, d$ em subconjuntos disjuntos I_1, \dots, I_m , em que cada $I=\{i_1, \dots, i_p\}$ é um grupo

de índices. Portanto, a matriz X_I correspondente ao grupo I é definida como $X_I = X_{i_1} + \dots + X_{i_p}$. Logo a matriz X pode ser escrita da seguinte maneira:

$$\tilde{X} = \sum_{l=1}^m X_{I_l} \quad (3)$$

O processo de escolher os conjuntos I_1, \dots, I_m é chamado o agrupamento de autotriplas. Portanto, a contribuição da componente X_I na expansão em (3) é medido pela razão dos autovalores correspondentes:

$$\sum_{i \in I} \lambda_i / \sum_{i=1}^d \lambda_i \quad (4)$$

O segundo passo da *reconstrução* e último passo da SSA é a *média diagonal* e que consiste em transformar a matriz de trajetória em uma série temporal. Sejam y_{ij} os elementos da matriz \tilde{X} de dimensão $L \times K$ onde $1 \leq i \leq L$ e $1 \leq j \leq K$ (2, 3, 5). Considere $L^* = \min(L, K)$, $K^* = \max(L, K)$ e $N = L + K - 1$.

$$g_k = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} (y_m^*, k-m+2) & , 0 \leq k \leq L^* - 1 \\ \frac{1}{L^*} \sum_{m=1}^{L^*} (y_m^*, k-m+2) & , L^* - 1 \leq k \leq K^* \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-k+1} (y_m^*, k-m+2) & , K^* \leq k \leq N \end{cases} \quad (5)$$

O passo de *média diagonal* transfere a matriz \tilde{X} para uma série $g_0, g_1, \dots, g_k, \dots, g_{N-1}$ através da equação (5), que corresponde à média de elementos ao longo das diagonais cujos índices das linhas (i) e colunas (j) satisfazem a igualdade $i+j=k+2$.

3.0 - REDES NEURAIIS ARTIFICIAIS (RNA)

As RNA são sistemas compostos por unidades de processamento denominados neurônios e dispostas em uma ou mais camadas interligadas por um grande número de conexões (*sinápses*) geralmente unidirecionais e com pesos para ponderar as entradas recebidas por cada neurônio. Cada neurônio realiza a soma ponderada dos sinais de entrada ($\sum w \cdot x$) e aplica uma função de ativação ao resultado obtido (*net*) e obtém um sinal de saída, conforme ilustrado pelo modelo matemático do neurônio na Figura 1. Assim, cada neurônio faz o mapeamento dos sinais de entrada em um único sinal de saída que é propagado para os neurônios da camada seguinte.

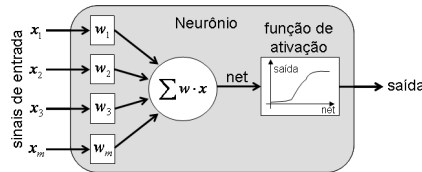
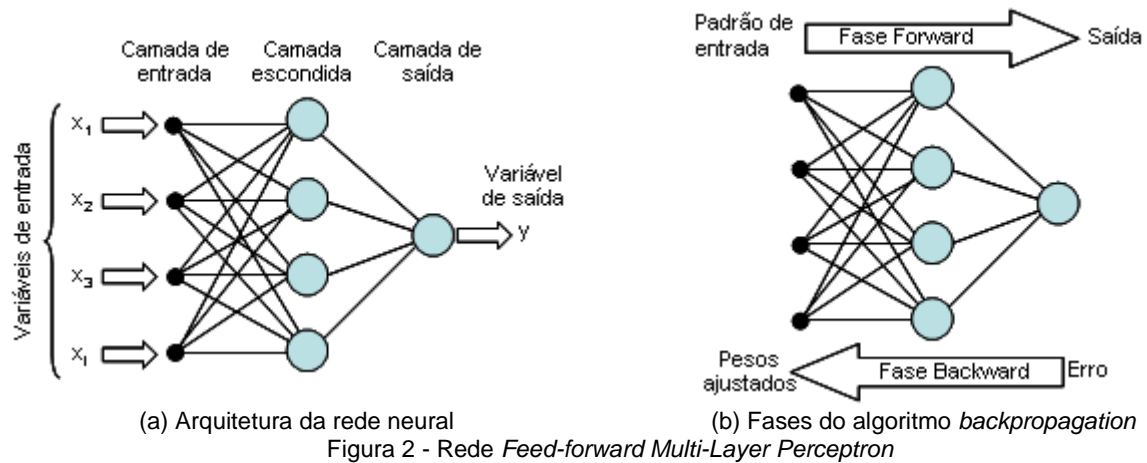


Figura 1 - Modelo do neurônio artificial

A arquitetura mais usual é a *feed-forward MLP (Multi-Layer Perceptron)* com três camadas, conforme ilustrado na Figura 2a. Os pesos w nas conexões entre as camadas são ajustáveis de forma análoga ao que acontece no cérebro humano, onde as sinápses são reforçadas ou enfraquecidas.

A primeira camada recebe os sinais de entrada e as transmite para os neurônios da camada escondida para que estes extraíam as características relevantes e passem os resultados para a camada de saída da rede. A especificação do número de camadas escondidas e do número de neurônios em cada camada é realizada de forma empírica. As RNAs com apenas uma camada escondida são capazes de aproximar qualquer função contínua não linear. Assim, é razoável considerar apenas uma camada escondida, sendo que o número de neurônios nesta camada é determinado empiricamente por meio da avaliação do erro de previsão alcançado em cada configuração avaliada.



O ajuste dos pesos das sinapses entre os neurônios é realizado por meio de um processo iterativo denominado treinamento. O principal algoritmo de treinamento é o *backpropagation* (5), no qual o ajuste dos pesos se dá pela execução de um processo de otimização realizado em duas fases: *forward* e *backward*, conforme ilustrado na Figura 2b. Na fase *forward* é calculada a resposta fornecida pela rede para um dado padrão de entrada, enquanto na fase *backward*, o erro, ou seja, o desvio entre a resposta desejada e a resposta encontrada pela rede, é utilizado para ajustar os pesos das conexões entre os neurônios da rede.

Ao longo do treinamento os vários padrões de entrada e as respectivas saídas desejadas são apresentados à RNA de forma a realizar um aprendizado supervisionado, onde os pesos das sinapses são corrigidos iterativamente pelo algoritmo do gradiente descendente (8) com o objetivo de minimizar a soma dos quadrados dos desvios (erros) entre a saída desejada e a saída da rede neural.

$$E = \frac{1}{2} \sum_{p=1}^{padrões} (d_p - y_p)^2 \quad (1)$$

onde p é o número de padrões de treinamento, d_p é a saída desejada no p -ésimo padrão de treinamento e y_p é a saída gerada pela rede quando alimentada com o p -ésimo padrão de treinamento.

4.0 - MODELO PROPOSTO

O modelo proposto para a previsão de velocidade do vento é baseado na decomposição da série filtrada de velocidade do vento, através da SSA, de forma a produzir um conjunto de séries para cada um dos componentes.

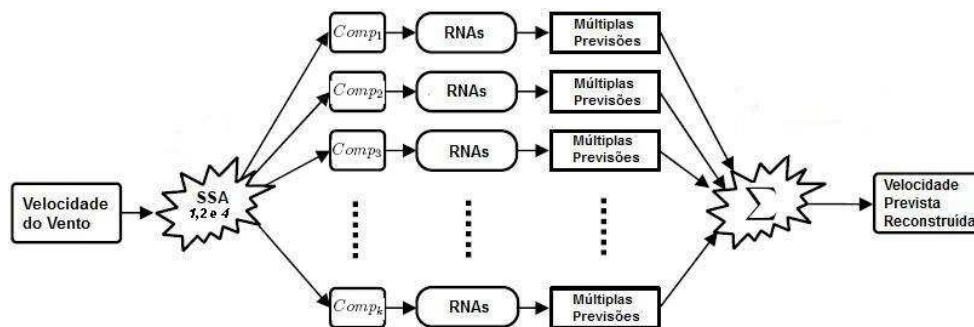


Figura 3 - Funcionamento do modelo proposto para previsão de velocidade do vento. Adaptado de (9).

De acordo com a Figura 3, o predictor de velocidade do vento funciona da seguinte forma:

- A série de velocidade do vento passa por três passos da SSA (*incorporação, decomposição em valores singulares e média diagonal*), gerando assim k séries distintas;
- São treinadas 24 redes neurais artificiais, uma RNA para cada hora do dia e para cada uma das k séries;
- Por meio das RNA são realizadas múltiplas previsões, uma para cada componente.
- É realizada a reconstrução da série de velocidade do vento prevista. Nesse caso, o resultado das previsões das k componentes são somadas em relação a hora, de forma a gerar a série de velocidade prevista.

Tabela 1 - Percentual explicado por componente

Número de Componentes	Percentual Explicado	Percentual Acumulado
1	49,41%	49,41%
2	11,57%	60,98%
3	8,90%	69,88%
4	5,08%	74,96%
5	3,69%	78,65%
6	2,88%	81,53%
7	2,35%	83,88%
8	2,14%	86,02%
9	1,90%	87,92%
10	1,45%	89,37%
11	1,10%	90,47%
12	1,03%	91,50%
13	1,03%	92,53%
14	0,96%	93,49%
15	0,95%	94,44%
16	0,84%	95,28%
17	0,78%	96,06%
18	0,76%	96,82%
19	0,65%	97,47%
20	0,59%	98,06%
21	0,54%	98,60%
22	0,51%	99,11%
23	0,45%	99,56%
24	0,44%	100,00%

O tamanho da janela L definido para a SSA foi de 24 horas. Após alguns experimentos foi possível observar que, para série de velocidade de vento, as 7 primeiras componentes explicam 83,88% da série original, de acordo com a Tabela 1. Foram executados diversos casos de testes com diferentes números de entradas para as RNA e com diferentes números de componentes, e a consideração de sete componentes se mostrou satisfatória quanto a precisão das previsões para o estudo realizado neste trabalho. A Figura 4 ilustra as curvas de cada uma das sete componentes extraídas da velocidade do vento.

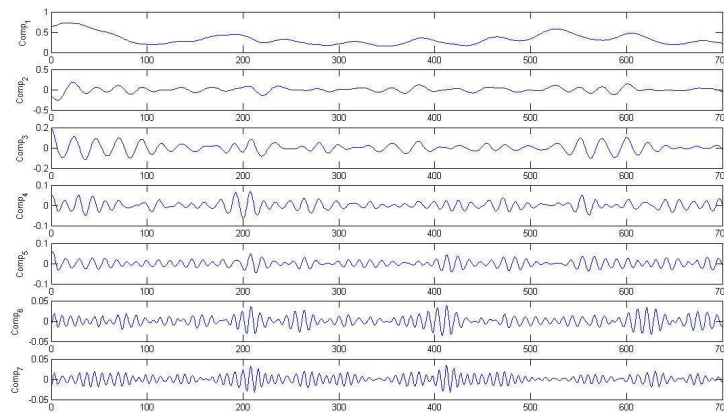


Figura 4 – Componentes selecionadas

Na sequência foram avaliadas 12 configurações para as arquiteturas das RNA responsáveis pelas previsões das componentes SSA. Estes experimentos mostraram que a melhor configuração para as RNA é composta por 9 neurônios na camada de entrada com função de propagação *tansig*, 11 neurônios na camada intermediária com função de propagação *tansig*, e 1 neurônio na camada de saída com função de propagação *purelin*, e o treinamento foi realizado com o algoritmo *trainrp*.

5.0 - EXPERIMENTOS E RESULTADOS

Para validar o modelo proposto foram executados quatro casos de testes, para isso foram escolhidos aleatoriamente quatro períodos distintos, descritos na Tabela 2.

Tabela 2 – Períodos dos experimentos

Caso	Início do Treinamento	Fim do Treinamento	Início do Teste	Fim do Teste
Caso 1	03/03/2007	03/04/2007	04/04/2007	05/04/2007
Caso 2	19/07/2008	19/08/2008	20/08/2008	21/08/2008
Caso 3	25/01/2009	25/02/2009	26/02/2009	27/02/2009
Caso 4	10/03/2010	10/04/2010	11/04/2010	12/04/2010

Para cada um dos casos estudados foram realizadas 24 previsões para um horizonte de 24 horas à frente. Portanto, a primeira previsão inicia-se na 1ª hora do primeiro dia de testes e termina na 24ª hora deste mesmo dia, a segunda previsão inicia na 2ª hora do primeiro dia e termina na 1ª hora do segundo dia, e assim sucessivamente. Por fim, a 24ª previsão inicia na 24ª do primeiro dia e termina na 23ª hora do segundo dia.

Para esse experimento os quatro casos passaram pelo processo de treinamento da RNA e foram executados obtendo os resultados em relação a métrica MAPE¹, apresentada na Tabela 3, e em relação a métrica MAE², apresentada na Tabela 4. Os valores apresentados nestas tabelas referem-se as médias das métricas obtidas para as 24 previsões realizadas para cada caso e para cada horizonte apresentado.

Tabela 3 – MAPE – Conjunto de teste

Caso/Horizonte	1	6	12	18	24
Caso 1	13,64%	23,26%	25,02%	25,90%	25,83%
Caso 2	6,82%	7,22%	7,88%	8,86%	11,85%
Caso 3	5,84%	8,47%	10,41%	11,21%	12,09%
Caso 4	9,26%	13,60%	20,07%	21,10%	24,91%
Média	8,89%	13,14%	15,84%	16,77%	18,67%

Foi observado que o caso 1, apesar de apresentar o pior resultado na Tabela 3 (MAPE) com 25,83%, apresenta o melhor resultado em relação à métrica MAE (Tabela 4) com 0,811 m/s. Isso ocorre, principalmente, por causa do nível de velocidade em que o vento se encontra, por exemplo, a velocidade mínima encontrada no conjunto de dados é de 0,0718 m/s e a velocidade máxima é de 24,2153 m/s. Assim sendo, se a velocidade é muito baixa, existe uma tendência aos erros serem maiores, principalmente, em relação à métrica MAPE. Por exemplo, se a velocidade real fosse 1 m/s e, levando em consideração que para 24 previsões o MAE (para o caso 1) é de 0,811 m/s, a velocidade prevista seria 1,811 m/s, isto iria gerar um MAPE de 81,1%. Em contrapartida, se a velocidade real fosse 24 m/s e a velocidade prevista 24,811 m/s, essa previsão iria gerar um erro de apenas 3,38% em relação a métrica MAPE.

Tabela 4 – MAE – Conjunto de teste

Caso/Horizonte	1	6	12	18	24
Caso 1	0,418	0,733	0,783	0,804	0,811
Caso 2	0,431	0,517	0,628	0,744	0,911
Caso 3	0,430	0,662	0,835	0,924	0,949
Caso 4	0,348	0,518	0,735	0,826	0,957
Média	0,407	0,607	0,745	0,825	0,907

Observa-se que as métricas são relevantes, no entanto a avaliação de um especialista para determinar quando o modelo deve ser re-treinado também é muito importante. E isso deve ser feito, principalmente, com base na análise das curvas das velocidades observadas e previstas, conforme apresentado na Figura 5.

Para fins de análise, nota-se uma melhora significativa em relação à métrica MAPE comparada aos resultados obtidos para o horizonte de uma hora a frente do trabalho (10) que foi de 17,96%, no entanto, cabe ressaltar que os trabalhos foram realizados com séries de dados diferentes. Outro ponto, agora em relação ao trabalho (11), é que este apresenta valores menores que os apresentados nesta pesquisa em relação à métrica MAPE (3,16% para o horizonte de três horas, 4,44% para cinco horas e 6,80% para dez horas), no entanto, em relação à métrica MAE (0,5848 m/s para o horizonte de três horas, 0,6601 m/s para cinco horas e 1,1005 m/s para dez horas), os resultados obtidos nesta pesquisa são menores. Em comparação a uma pesquisa nacional, vale notar que os valores obtidos, para métrica MAPE, nesta pesquisa, são melhores que os obtidos nos trabalhos (12) e (13) para o horizonte de 24 horas que no melhor caso apresentou 27,568%, e no trabalho (14) que apresentou 16,16%, 39,37%, 45,45% e 46,98% para métrica MAPE nos horizontes de 1, 6, 12 e 24 horas.

Contudo é importante destacar que essa comparação deve ser vista com ressalvas, pois a série considerada neste trabalho é diferente das séries consideradas pelos autores dos trabalhos referenciados.

¹ MAPE, Mean Absolute Percentual Error

² MAE, Mean Absolute Error

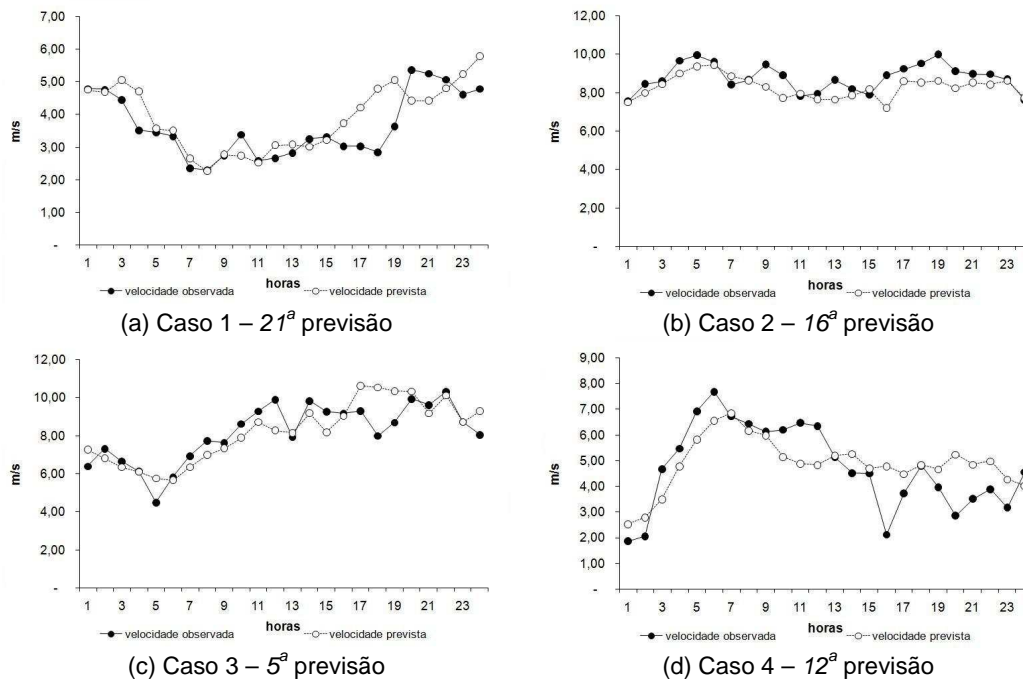


Figura 5 – Perfis observados e previstos

6.0 - CONCLUSÃO

O modelo proposto para previsão de séries de velocidade do vento é um modelo híbrido baseado na decomposição da série de velocidade de vento via SSA e na previsão por RNA. O modelo proposto foi avaliado em um experimento computacional e os resultados alcançados são satisfatórios se comparados com os resultados da literatura. Embora não se possa comparar diretamente os resultados devido ao fato dos trabalhos da literatura terem sido realizados com diferentes séries históricas de vento, o predictor proposto apresentou resultados compatíveis com pesquisas nacionais e internacionais para os diversos horizontes apresentados neste trabalho.

A aplicação da SSA na decomposição da série se mostrou bastante útil na remoção de ruídos frequentemente encontrados nos registros de velocidade de vento. A remoção de ruídos contribuiu para a melhoria da qualidade dos padrões entrada/saída considerados nos treinamentos das redes neurais artificiais e assim foi possível alcançar previsões mais precisas. Destaca-se que esta mesma estratégia pode ser empregada em outras séries de interesse da operação do sistema elétrico, por exemplo, a série de carga.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) AMARANTE, O. C. et al. Atlas do potencial eólico brasileiro. Brasília: Centro de Pesquisas de Energia Elétrica, 2001.
- (2) GOLYANDINA, N. ; NEKRUTKIN, V. ; ZHIGLJAVSKY, A. Analysis of time series structure: ssa and related techniques. 1.ed. Boca Raton: Chapman and Hall/CRC, 2001.
- (3) HASSANI, H. Singular spectrum analysis: methodology and comparison. Journal of Data Science, New York, v. 5, n. 4991, p. .239-257, 2007.
- (4) HASSANI, H. Singular spectrum analysis: a relatively new and powerful technique for time series analysis and forecasting. ANNUAL INTERNATIONAL SYMPOSIUM ON FORECASRING, 31., 2011. Prague. Proceedings ... Prague: IIF, 2011.
- (5) Haykin, S. Redes Neurais – Princípios e Prática, 2a edição. Editora Bookman, 2001.
- (6) MARQUES, C. et al. Singular spectrum analysis and forecasting of hydrological time series. Physics and Chemistry of the Earth Parts ABC, Oxford, Eng.: v. 31, n. 18, p. 1172-1179, 2006.
- (7) JOHNSON, R. A. ; WICHERN, D. W. Applied multivariate statistical analysis. 4. ed. Upper Saddle River: Prentice-Hall, 1998.

- (8) JANG, J. S. R. ; SUN, C. T. ; MIZUTANI, E. Neuro-fuzzy and soft computing – a computational approach to learning and machine intelligence. 1. ed. Upper Saddle River: Prentice-Hall, 1997.
- (9) VAHABIE, A. H. et al. Combination of singular spectrum analysis and autoregressive model for short term load forecasting. In: 2007 IEEE LAUSANNE POWER TECH, 2007, Lausanne. Proceedings ... Lausanne: IEEE, 2007. p. 1090–1093.
- (10) CASTELLANI, V. L. O. ; PESSANHA, J. F. M. ; LIMA, C. Técnicas de inteligência computacional na previsão de séries de velocidade do vento: uma comparação da lógica nebulosa com redes neurais artificiais. In: XXI SNPTÉE - SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA, 2011, Florianópolis. Anais... Florianópolis: CIGRÉ-Brasil, 2011.
- (11) LIU, H. et al. A hybrid statistical method to predict wind speed and wind power. Renewable Energy, Oxford, Eng., v. 35, n. 8, p. 1857-1861, Aug. 2010.
- (12) AQUINO, R. et al. Application of wavelet and neural network models for wind speed and power generation forecasting in a brazilian experimental wind park. In: IJCNN 2009. INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2009, Atlanta. Proceedings ... Georgia: INSS /IEEE, 2009. p. 172-178.
- (13) AQUINO, R. et al. Previsão de ventos e geração eólica: buscando a melhor modelagem através de inteligência artificial. In: SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA, 11., 2009, Belém. Anais... CIGRÉ-Brasil, 2009.
- (14) BEZERRA, E. C. et al. Utilização do método de otimização por nuvem de partículas (PSO) na escolha da topologia de redes neurais artificiais empregadas na estimação da velocidade do vento. In: CBIC 2011. CONGRESSO BRAZILEIRO DE INTELIGÊNCIA COMPUTACIONAL, 10., 2011, Fortaleza. Anais ... Fortaleza: INNS, 2011.

8.0 - DADOS BIOGRÁFICOS



Valk Luiz de Oliveira Castellani: Nascido em Volta Redonda – RJ, Brasil, em 1975. Graduado em Tecnologia em Processamento de Dados pela Fundação Dom André Arcoverde em 1998. Pós-Graduado em Tecnologia de Banco de Dados em 2001 e Engenharia de Sistemas de Computação em 2002 pela Universidade Estácio de Sá. Mestre em Informática pela Universidade Federal do Rio de Janeiro em 2012. Trabalha no Centro de Pesquisas de Energia Elétrica – CEPEL desde 2006 com o desenvolvimento de interfaces gráficas para o sistema de encadeamento de modelos energéticos.