

# REDES NEURONAIS ARTIFICIAIS PARA PREVISÃO DA POTÊNCIA EÓLICA

J.P.S. Catalão, N.M.S. Martins  
*Universidade da Beira Interior (UBI),  
Departamento de Engenharia Electromecânica (DEM), Covilhã, Portugal,*  
[catalao@ubi.pt](mailto:catalao@ubi.pt)

V.M.F. Mendes  
*Instituto Superior de Engenharia de Lisboa (ISEL),  
Departamento de Engenharia Electrotécnica e Automação (DEEA), Lisboa, Portugal,*  
[vmendes@isel.pt](mailto:vmendes@isel.pt)

Palavras-chave: Inteligência artificial, redes neuronais, previsão da potência, energia eólica.

Resumo: A capacidade de gerir a integração de geração eólica na rede eléctrica depende essencialmente da previsão da potência eólica. Esta comunicação apresenta uma ferramenta computacional, baseada em redes neuronais artificiais, para a previsão da potência eólica. Apresentam-se os resultados numéricos obtidos para um caso de estudo, e conclui-se sobre o desempenho da ferramenta computacional proposta.

## 1 INTRODUÇÃO

O interesse pelas energias renováveis em geral, e pela energia eólica em particular, é motivado pela crescente preocupação ambiental a nível mundial, nomeadamente com as alterações climáticas resultantes da emissão de gases com efeito de estufa (GEE).

O aumento da temperatura da superfície terrestre tem sido associado ao aumento do efeito de estufa. Como consequência da actividade humana, a concentração de GEE tem vindo a aumentar acentuadamente desde o período pré-industrial (1750-1800). Nomeadamente, a concentração de dióxido de carbono (CO<sub>2</sub>), principal GEE, aumentou em cerca de 30% desde o período pré-industrial. Actualmente, o efeito combinado de todos os GEE corresponde a um aumento de mais de 50% do equivalente de CO<sub>2</sub> que existia nesse período.

Em 1997, o protocolo de Quioto fixou como objectivo a redução de 5.2% do nível mundial de emissões de GEE em 2010, quando comparados com os valores de 1990. Para que tal seja possível, várias medidas devem ser tomadas, nomeadamente ao nível do sector de energia, através da limitação das emissões de GEE e da promoção das fontes de energia renovável.

Em Portugal tem-se assistido nos últimos anos a um acentuado crescimento da produção eólica, motivado pela aprovação da Directiva da Renováveis. Nomeadamente, em 2005 verificou-se a maior taxa de crescimento europeia e a segunda maior em 2006.

O Governo Português havia imposto inicialmente o objectivo de alcançar, em 2010, 3750 MW de potência eólica instalada, mas, recentemente e com a previsão que Portugal atinja os objectivos delineados para 2010, antes da data prevista, o Governo decidiu impor novas metas, passando dos 3750MW para os 5100MW instalados em 2010, devido às taxas de crescimento que se têm vindo a registar [1].

Apesar do crescimento da produção eólica nacional, a possibilidade de armazenar e controlar este recurso é extremamente difícil dada a sua natureza intermitente e volátil.

A capacidade de gerir a integração de geração eólica na rede eléctrica depende essencialmente da previsão da potência eólica, sendo assim necessária a existência de ferramentas computacionais apropriadas.

A previsão da potência eólica poderá ter várias aplicações, nomeadamente [2]:

- na optimização da gestão da rede eléctrica, no que diz respeito ao despacho económico;

- no comércio da energia eólica no mercado de energia;
- no planeamento da manutenção dos parques eólicos e linhas de transporte.

A previsão da potência eólica é um problema complexo, devido ao comportamento aleatório do vento e às não linearidades introduzidas pela curva de potência dos aerogeradores. Assim, a investigação incide no estudo e desenvolvimento de ferramentas computacionais com o intuito de prever a potência eólica com precisão.

Qualquer método de previsão da potência eólica só poderá obter resultados satisfatórios se, à partida, obtiver melhores resultados, ou seja, menores erros na previsão, que os métodos considerados como sendo métodos de referência.

Os métodos considerados como métodos de referência são normalmente métodos mais simples, como o método da persistência, em que se considera que o valor previsto é igual ao apresentado no presente. Embora este método seja um método bastante simples, apenas se torna fiável para previsões em horizontes temporais a muito curto prazo.

De um modo geral, podem distinguir-se três métodos de previsão: métodos físicos, métodos estatísticos e métodos combinados [3]. Os métodos físicos tentam utilizar apenas considerações físicas para alcançar as melhores estimativas da velocidade do vento. Os métodos estatísticos procuram encontrar relações entre as variáveis explicativas e o valor da variável a prever, utilizando normalmente técnicas recursivas. Neste caso, é necessário determinar analiticamente uma expressão que traduza a relação entre os valores de entrada e saída. Contudo, métodos estatísticos mais sofisticados, como as redes neuronais artificiais, conseguem encontrar essa relação entre os valores de entrada e saída de modo a se gerarem melhores previsões que os métodos clássicos de regressão linear [4-5].

Esta comunicação apresenta uma ferramenta computacional, baseada em redes neuronais artificiais, para a previsão da potência eólica. Apresentam-se os resultados numéricos obtidos para um caso de estudo, e conclui-se sobre o desempenho da ferramenta computacional proposta.

## 2 REDES NEURONAIS

As redes neuronais artificiais, ou simplesmente redes neuronais, são uma aproximação das redes neuronais biológicas que resultam da interligação de unidades de processamento simples de forma a replicar o funcionamento do cérebro humano.

A Figura 1 apresenta a estrutura de cada unidade da rede neuronal.

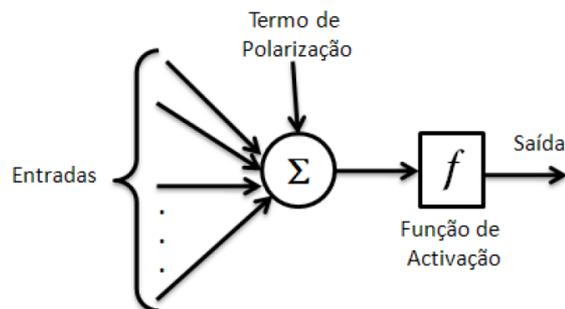


Figura 1: Estrutura de cada unidade de uma rede neuronal.

As unidades de processamento constituem os principais elementos de uma rede neuronal. A organização das unidades de processamento define a arquitectura ou topologia da rede neuronal.

Nas redes unidireccionais ou redes de alimentação directa, cujo grafo não apresenta realimentação, as unidades são frequentemente distribuídas em camadas – redes multicamada – uma camada de entrada, uma ou mais camadas intermédias, também denominadas por camadas escondidas, e uma camada de saída. As unidades em cada camada podem partilhar as mesmas entradas, mas não são conectadas umas às outras.

A Figura 2 apresenta uma rede neuronal com duas camadas intermédias, tendo a camada de saída apenas uma unidade.

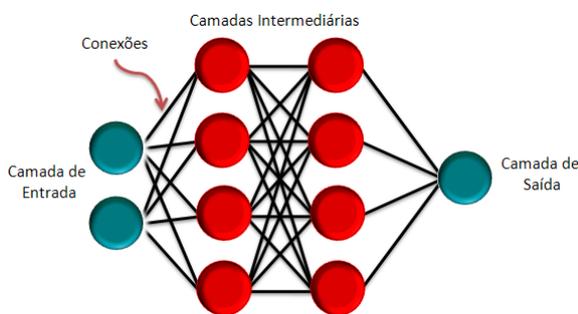


Figura 2: Rede neuronal com as unidades organizadas por camadas.

A selecção da topologia da rede neuronal é uma decisão muito importante e complexa. Por um lado, a escolha de uma topologia demasiado simples pode resultar na incapacidade de reproduzir correctamente os dados. Por outro lado, uma topologia demasiado flexível pode resultar numa má capacidade de generalização, em consequência da susceptibilidade de ajustamento ao ruído e a outras peculiaridades dos dados.

Assim, a selecção da topologia da rede deve ser norteada de acordo com um compromisso entre a simplicidade e a flexibilidade, visando a obtenção de redes com capacidade de generalização aceitável.

Tipicamente, a selecção da topologia da rede que permite obter melhores resultados para a previsão com redes neuronais obriga à avaliação de diversas combinações. Estas combinações incluem redes com diferentes números de camadas escondidas, diferentes números de unidades em cada camada, e diferentes tipos de funções de activação. A topologia da rede em que as funções de activação são contínuas e limitadas, e o número de unidades na camada escondida é suficiente, é considerada um aproximador universal.

A aprendizagem supervisionada é o método mais comum no treino de redes neuronais. Como o próprio nome indica, as entradas e saídas desejadas para a rede são fornecidas por um supervisor externo. O objectivo é ajustar os parâmetros da rede, de forma a minimizar o erro, que é função da diferença entre saída desejada e a saída fornecida pela rede. Esta minimização ocorre através do ajuste dos pesos da rede. Assim, ao contrário de um computador com arquitectura de Von Neumann que é programado, a rede neuronal é treinada através de exemplos. O algoritmo de aprendizagem generaliza esses exemplos e memoriza o conhecimento dentro dos pesos da rede.

Para além da importância da selecção adequada da topologia da rede neuronal, bem como os exemplos a recolher, é conveniente que o treino não seja demasiado prolongado, visto que, pode resultar na deterioração dos resultados da previsão. Tipicamente, à medida que se ajustam os pesos da rede o erro de treino diminui, acompanhado pela diminuição do erro de teste. Porém, um treino demasiado prolongado faz com que a rede memorize o conjunto de treino, pelo que o erro de treino continua a diminuir, deixando contudo a rede de possuir poder de generalização, pelo que o erro de teste começa a aumentar.

Nesta comunicação é utilizado o método de Levenberg-Marquardt para treinar a rede neuronal. Este método corresponde a uma variante do método de Newton, sendo cerca de 10 a 100 vezes mais rápido que o método do gradiente [6].

O método de Newton é um processo iterativo que visa a minimização de uma função  $\Omega$  através da seguinte equação de actualização:

$$\Delta \mathbf{y} = -[\nabla^2 \Omega(\mathbf{y})]^{-1} \nabla \Omega(\mathbf{y}) \quad (1)$$

em que  $\nabla^2 \Omega$  corresponde à matriz Hessiana  $\mathbf{H}$ , e  $\nabla \Omega$  corresponde ao vector do gradiente  $\mathbf{g}$ .

Assumindo que a função  $\Omega$  determina a soma do quadrado dos erros, sendo dada por:

$$\Omega(\mathbf{y}) = \sum_{k=1}^K e_k^2(\mathbf{y}) \quad (2)$$

e seja  $\mathbf{e}$  o vector dos erros, e  $\mathbf{J}$  a matriz Jacobiana dada por:

$$\mathbf{J}(\mathbf{y}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{y})}{\partial y_1} & \frac{\partial e_1(\mathbf{y})}{\partial y_2} & \dots & \frac{\partial e_1(\mathbf{y})}{\partial y_k} \\ \frac{\partial e_2(\mathbf{y})}{\partial y_1} & \frac{\partial e_2(\mathbf{y})}{\partial y_2} & \dots & \frac{\partial e_2(\mathbf{y})}{\partial y_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_K(\mathbf{y})}{\partial y_1} & \frac{\partial e_K(\mathbf{y})}{\partial y_2} & \dots & \frac{\partial e_K(\mathbf{y})}{\partial y_k} \end{bmatrix} \quad (3)$$

tem-se que:

$$\nabla \Omega(\mathbf{y}) = 2 \mathbf{J}^T(\mathbf{y}) \mathbf{e}(\mathbf{y}) \quad (4)$$

$$\nabla^2 \Omega(\mathbf{y}) = 2 \mathbf{J}^T(\mathbf{y}) \mathbf{J}(\mathbf{y}) + 2 \mathbf{S}(\mathbf{y}) \quad (5)$$

sendo a matriz  $\mathbf{S}$  dada por:

$$\mathbf{S}(\mathbf{y}) = \sum_{k=1}^K e_k(\mathbf{y}) \nabla^2 e_k(\mathbf{y}) \quad (6)$$

Desprezando as segundas derivadas do vector dos erros, a matriz Hessiana é dada por:

$$\nabla^2 \Omega(\mathbf{y}) = 2 \mathbf{J}^T(\mathbf{y}) \mathbf{J}(\mathbf{y}) \quad (7)$$

e substituindo (7) e (4) em (1) obtém-se a equação de actualização do método de Gauss-Newton, dada por:

$$\Delta \mathbf{y} = -[\mathbf{J}^T(\mathbf{y}) \mathbf{J}(\mathbf{y})]^{-1} \mathbf{J}^T(\mathbf{y}) \mathbf{e}(\mathbf{y}) \quad (8)$$

A vantagem do método de Gauss-Newton comparativamente ao método de Newton reside no facto de se evitar o cálculo das segundas derivadas do vector dos erros, que podem ser difíceis de obter. Contudo, uma desvantagem reside no facto da matriz  $\mathbf{J}^T \mathbf{J}$  poder não ser invertível. Esta desvantagem é ultrapassada pelo método de Levenberg-Marquardt, cuja equação de actualização é dada por:

$$\Delta \mathbf{y} = -[\mathbf{J}^T(\mathbf{y}) \mathbf{J}(\mathbf{y}) + \varsigma \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{y}) \mathbf{e}(\mathbf{y}) \quad (9)$$

em que  $\mathbf{I}$  é a matriz identidade, sendo o parâmetro  $\varsigma$  convenientemente modificado durante as iterações [7].

A ferramenta computacional desenvolvida para previsão da potência eólica é baseada em redes neuronais. A topologia da rede escolhida consiste em três camadas, sendo a camada escondida constituída por cinco unidades com função de activação do tipo tangente hiperbólica, e a camada de saída constituída apenas por uma unidade com função de activação do tipo linear. O treino da rede é efectuado pelo método de Levenberg-Marquardt.

### 3 ERRO DE PREVISÃO

O erro de previsão da potência eólica na hora  $k$  é dado por:

$$e_k = \hat{\lambda}_k - \lambda_k \quad (10)$$

em que  $\hat{\lambda}_k$  e  $\lambda_k$  são, respectivamente, a potência prevista e a potência verificada na hora  $k$ .

Para avaliar o desempenho da ferramenta computacional desenvolvida para a previsão da potência eólica são utilizados os seguintes critérios: MAPE, SSE, e SDE.

O critério MAPE corresponde ao erro médio absoluto em percentagem, sendo dado por:

$$\text{MAPE} = \frac{100}{K} \sum_{k=1}^K \frac{|\hat{\lambda}_k - \lambda_k|}{\bar{\lambda}} \quad (11)$$

em que  $\bar{\lambda}$  é a potência média durante o horizonte temporal considerado, sendo dada por:

$$\bar{\lambda} = \frac{1}{K} \sum_{k=1}^K \lambda_k \quad (12)$$

O critério SSE corresponde à soma do quadrado dos erros, sendo dado por:

$$\text{SSE} = \sum_{k=1}^K (\hat{\lambda}_k - \lambda_k)^2 \quad (13)$$

O critério SDE corresponde ao desvio padrão, sendo dado por:

$$\text{SDE} = \sqrt{\frac{1}{K} \sum_{k=1}^K (e_k - \bar{e})^2} \quad (14)$$

em que  $\bar{e}$  é o erro médio, durante o horizonte temporal considerado, sendo dado por:

$$\bar{e} = \frac{1}{K} \sum_{k=1}^K e_k \quad (15)$$

### 4 RESULTADOS NUMÉRICOS

A previsão da potência eólica é realizada para dois dias do ano, nos meses de Outubro de 2007 e Abril de 2008.

A potência prevista e a potência verificada com a ferramenta computacional para esses dias de Outono e Primavera são apresentados nas Figuras 3 a 4, respectivamente. A linha a traço interrompido e a linha a traço contínuo representam, respectivamente, a potência prevista e a potência verificada.

A ferramenta computacional desenvolvida foi implementada num computador com processador Pentium IV a 2.80 GHz e 512 MB de memória RAM, sendo a aplicação informática usada o MATLAB v.6.

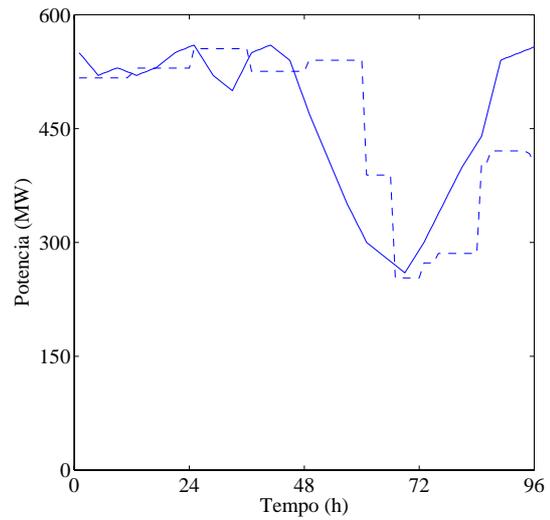


Figura 3: Potencia prevista e potencia verificada para 24 horas no mês de Outubro de 2007.

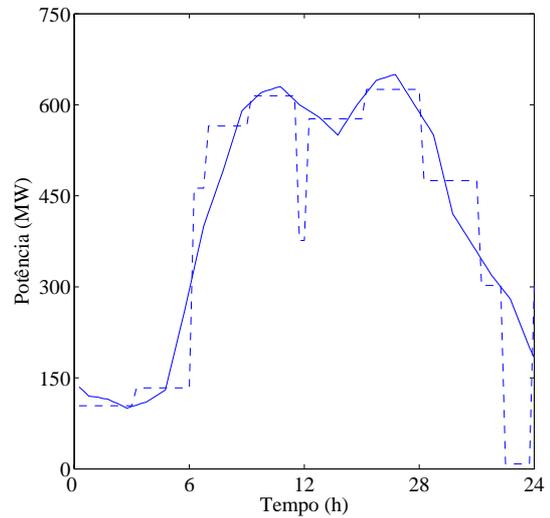


Figura 4: Potencia prevista e potencia verificada para 24 horas no mês de Abril de 2008.

A Tabela 1 apresenta a análise estatística do erro de previsão obtido com a ferramenta computacional. A primeira coluna indica a estação/mês considerados para a previsão, a segunda coluna indica o valor do MAPE, a terceira coluna indica a raiz quadrada do valor do SSE e a quarta coluna indica o valor do SDE.

Estação/Mês	MAPE	$\sqrt{\text{SSE}}$	SDE
Outono/Outubro 07	13.16%	811.82	56.29
Primavera/Abril 08	12.59%	833.83	67.33

Tabela 1: Análise estatística do erro de previsão.

A ferramenta computacional, baseada em redes neuronais artificiais, permite obter uma exactidão aceitável na previsão da potência eólica, com um valor médio de 12.9% para o MAPE. Ainda, o tempo de computação é de apenas 18 segundos.

## 5 CONCLUSÕES

Portugal é um país em grande expansão no que diz respeito ao desenvolvimento da energia eólica, pelo que terá de se munir com ferramentas computacionais apropriadas para a previsão da potência eólica, com o objectivo de solucionar as dificuldades ao nível da gestão do sistema electroprodutor.

A ferramenta computacional proposta nesta comunicação é baseada em redes neuronais artificiais. A escolha da arquitectura da rede recaiu numa arquitectura com cinco unidades na camada escondida e uma unidade na camada de saída. Verifica-se que, quanto menor for o intervalo de tempo entre amostras de valores, maior é a exactidão dos resultados, principalmente tendo em consideração grandezas de variação rápida e aleatória como acontece com a velocidade do vento.

A ferramenta computacional desenvolvida permite obter, não só, uma boa exactidão na previsão da potência eólica com um MAPE médio de 12.9%, mas também um tempo de computação aceitável de 18 segundos.

## REFERÊNCIAS

- [1] Estanqueiro, A., Castro, R., Flores, P., Ricardo, J., Pinto, M., Rodrigues, R., Lopes, J.P., 2008. How to prepare a power system for 15% wind energy penetration: the Portuguese case study, *Wind Energy*, Vol. 11, No. 1, p. 75-84.
- [2] Kariniotakis, G., Pinson, P., Siebert, N., Giebel, G., e Barthelmie, R., 2004. The state of the art in short-term prediction of wind power-from an offshore perspective, in *Proc. of 2004 SeaTech Week*, Brest, France.
- [3] Sideratos, G. e Hatziargyriou, N.D., 2007. An advanced statistical method for wind power forecasting, *IEEE Transactions on Power Systems*, Vol. 22, No. 1, p. 258-265.
- [4] Kariniotakis, G.N., Stavrakakis, G.S., e Nogaret, E.F., 1996. Wind power forecasting using advanced neural networks models, *IEEE Transactions on Energy Conversion*, Vol. 11, No. 4, p. 762-767.
- [5] Giebel, G., Landberg, L., Kariniotakis, G., e Brownsword R., 2003. State-of-the-art on methods and software for short-term prediction of wind energy production, in *Proc. of EWEC 2003*, Madrid, Spain.
- [6] Hagan, M.T., e Menhaj, M.B., 1994. Training feedforward networks with the Marquardt algorithm, *IEEE Transactions on Neural Networks*, Vol. 5, No. 6, p. 989-993.
- [7] Saini, L.M., e Soni, M.K., 2002. Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods, *IEE Proceedings-Generation Transmission and Distribution*, Vol. 149, No. 5, p. 578-584.