

Previsão dos Preços da Energia Eléctrica através de Redes Neurais Artificiais

João Catalão †
Silvio Mariano †
Victor Mendes ‡
Luís Ferreira §

† Departamento de Engenharia Electromecânica
UBI – Universidade da Beira Interior
Catalao@ubi.pt
sm@ubi.pt

‡ Departamento de Engenharia Electrotécnica e Automação
ISEL – Instituto Superior de Engenharia de Lisboa
vfmendes@isel.pt

§ Departamento de Engenharia Electrotécnica e de Computadores
IST – Instituto Superior Técnico
lmf@ist.utl.pt

Abstract

In this paper, a computational tool based on artificial neural networks is presented for electricity prices forecasting to support decision making in a competitive environment. The numerical results obtained for a case study illustrate the behaviour of the computational tool proposed comparatively to a time-series approach.

Resumo

Neste artigo é apresentada uma ferramenta computacional, baseada em redes neuronais artificiais, para a previsão dos preços da energia eléctrica no apoio à decisão em ambiente competitivo. Apresentam-se os resultados numéricos obtidos para um caso de estudo, e conclui-se sobre o desempenho da ferramenta computacional proposta comparativamente a uma abordagem baseada em séries temporais.

Keywords: Price forecasting, Neural network, Levenberg-Marquardt algorithm

Title: Electricity prices forecasting through artificial neural networks.

1 Introdução

A energia eléctrica está no cerne da sociedade moderna, sendo uma componente essencial do nosso estilo de vida e um factor determinante na competitividade da economia. O contexto actual de reestruturação do sector eléctrico, promovendo a conversão de um monopólio natural num mercado concorrencial e possibilitando a liberdade de escolha do fornecedor de energia eléctrica por parte dos consumidores, introduz a exigência de competitividade nas empresas produtoras (Catalão, 2006).

A liberalização do sector eléctrico torna os preços da energia eléctrica voláteis e incertos. Os preços em mercados eléctricos competitivos reagem rapidamente às variações na oferta e na procura, assumindo uma influência significativa na optimização da exploração de recursos energéticos. Para se poder lidar com a incerteza tem de se recorrer à previsão. Esta incerteza introduz um risco suplementar que deve ser gerido da melhor forma pelas empresas produtoras. Uma ferramenta computacional que forneça uma previsão fiável dos preços da energia eléctrica representa uma vantagem competitiva para as empresas produtoras.

Em ambiente centralizado, os preços da energia eléctrica tendem a reflectir as políticas socio-económicas vigentes, estando relacionados com os custos operacionais. Assim, a previsão dos preços é realizada tipicamente apenas a longo prazo, considerando a evolução dos custos dos combustíveis e a inovação tecnológica das centrais (Angelus, 2001). As estratégias a desenvolver para o planeamento em ambiente centralizado assentam fundamentalmente na previsão da procura de energia eléctrica, existindo escassa necessidade para o desenvolvimento de uma ferramenta que assegure cobertura de risco do preço, dada a sua natureza determinística.

A reestruturação do sector eléctrico pretende incentivar a competição entre empresas produtoras a fim de diminuir o preço da energia eléctrica para os consumidores. A exactidão na previsão dos preços da energia eléctrica é vital em ambiente competitivo, permitindo reduzir o risco de subestimar ou sobrestimar o lucro potencialmente obtido (Bastian et al., 1999). Os erros de previsão têm implicações significativas para as empresas produtoras ao nível dos lucros, quotas de mercado, e, em última instância, na valorização bolsista (Bunn, 2000).

O perfil dos preços da energia eléctrica exhibe maior complexidade que o perfil da procura de energia eléctrica, dadas as particularidades associadas ao perfil dos preços.

Na maioria dos mercados eléctricos competitivos o perfil dos preços apresenta as seguintes particularidades (Nogales et al., 2002):

- Não estacionaridade, i.e., média e variância não constantes;
- Sazonalidade diária e semanal;
- Efeito de calendário, i.e., fins-de-semana e feriados públicos;
- Aleatoriedade e volatilidade.

A previsão dos preços da energia eléctrica assumiu importância relevante no final da década de noventa, tendo sido propostas diversas abordagens para essa previsão. Em geral, dois tipos de abordagens podem ser utilizados para a previsão dos preços da energia eléctrica: (1) séries temporais; (2) inteligência artificial.

As abordagens baseadas em séries temporais (Nogales et al., 2002), em particular a abordagem AR — Auto Regressive (Fosso et al., 1999) e a abordagem ARIMA — Auto Regressive Integrated Moving Average (Contreras et al., 2003; Zhou, 2006), podem ser muito exactas, mas requerem vasta informação e o tempo de computação é geralmente elevado (Rodríguez and Anders, 2004). Ainda, a abordagem GARCH — Generalized

Autoregressive Conditional Heteroskedastic (Garcia et al., 2005) e a abordagem Wavelet-ARIMA (Conejo et al., 2005) foram propostas com o intuito de melhorar o desempenho das abordagens anteriores.

As abordagens baseadas em inteligência artificial, nomeadamente redes neuronais artificiais e lógica difusa, são comparativamente às anteriores menos exigentes no que respeita ao tempo de computação. Em particular, as redes neuronais artificiais, utilizadas com sucesso para a previsão da procura de energia eléctrica (Hippert et al., 2001; Saini and Soni, 2002), são também utilizadas para a previsão dos preços da energia eléctrica (Szkuta et al., 1999; Wang and Ramsay, 1998; Yamin et al., 2004, Catalão et al., 2006).

Neste artigo é apresentada uma ferramenta computacional, baseada em redes neuronais artificiais, para a previsão dos preços da energia eléctrica no apoio à decisão em ambiente competitivo. Apresentam-se os resultados numéricos obtidos para um caso de estudo, e conclui-se sobre o desempenho da ferramenta computacional proposta comparativamente a uma abordagem baseada em séries temporais.

2 Redes Neuronais Artificiais

O cérebro humano é constituído por cerca de 10^{11} células nervosas ou neurónios. Cada neurónio, por sua vez, é constituído por: dendrites, corpo central, axónio e sinapses. O neurónio recebe estímulos de entrada por intermédio das dendrites, sinais que são posteriormente adicionados pelo corpo central e difundidos pelo axónio para as sinapses.

As redes neuronais artificiais, ou, simplesmente, redes neuronais, resultam da interligação massiva de unidades de processamento simples, projectadas de forma a replicar o funcionamento do cérebro humano (Haykin, 1999).

A estrutura de cada unidade de uma rede neuronal é apresentada na figura 1.

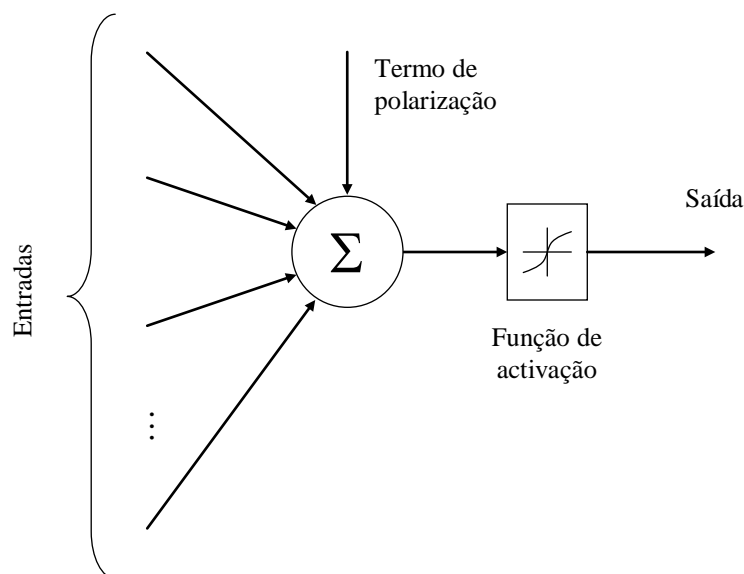


Figura 1: Estrutura de cada unidade de uma rede neuronal: entradas, termo de polarização, função de activação e saída

Cada unidade de uma rede neuronal realiza a soma ponderada das suas entradas, às quais é adicionado um termo constante denominado de termo de polarização. A saída depende de uma função de activação ou de transferência, sendo do tipo: linear, sigmóide ou tangente hiperbólica.

A organização das unidades 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 camadas escondidas, e uma camada de saída. As unidades em cada camada podem compartilhar as mesmas entradas, mas não são conectadas umas às outras. A camada de entrada tem por objectivo adquirir os dados, sendo os dados propagados à camada seguinte sem qualquer processamento. Assim, os dados são processados apenas pelas unidades nas camadas escondidas e na camada de saída.

A topologia de uma rede neuronal unidireccional genérica com três camadas é apresentada na figura 2. A rede neuronal considerada é dita completamente interligada, visto que, toda a unidade pertencente a uma determinada camada está ligada a toda a unidade pertencente à camada adjacente.




Figura 2: Rede neuronal unidireccional com três camadas e uma unidade na camada de saída

A selecção da topologia da rede neuronal é uma decisão importante e complexa. Por um lado, a escolha de uma topologia demasiado simples pode resultar na incapacidade de reproduzir correctamente os dados — sub-ajustamento dos 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 — sobre-ajustamento 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 os 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 (Principe et al., 2000). Neste artigo, a rede neuronal usada consiste em: uma camada escondida com função de activação do tipo tangente hiperbólica; uma camada de saída com apenas uma unidade e função de activação do tipo linear. O número de unidades na camada escondida é tipicamente determinado por um processo de tentativa-e-erro, tendo-se convergido para cinco unidades na camada escondida.

O conhecimento necessário para a previsão com redes neuronais envolve dois processos: o treino e a aprendizagem.

O processo de treino é tipicamente realizado de forma supervisionada, sendo assumido que um conjunto de treino representativo está disponível, obtido através dos dados históricos, contendo as entradas e as correspondentes saídas desejadas. A recolha adequada dos dados para o treino da rede neuronal assume uma influência significativa no sucesso do treino.

O processo de aprendizagem é um processo de optimização. No processo de aprendizagem supervisionada a rede neuronal aprende a partir do conjunto de treino constituído por pares entrada-saída, ajustando os pesos e as polarizações em cada iteração de forma a minimizar uma determinada medida de erro entre a saída produzida e a saída desejada. Este processo é repetido até que um critério de paragem seja alcançado. O conhecimento adquirido pela rede neuronal através do processo de aprendizagem é testado com um conjunto de teste diferente do conjunto de treino. A rede deve ser capaz de generalizar e reproduzir, com exactidão aceitável, dados nunca antes apresentados.

Para além da importância da selecção adequada da topologia da rede neuronal, bem como dos dados a recolher, é conveniente que o treino não seja demasiadamente prolongado — sobre-treino da rede — visto que, pode resultar na deterioração dos resultados da previsão. Tipicamente, à medida que se ajustam os pesos e as polarizações 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.

O sobre-treino é geralmente evitado estabelecendo um critério de paragem antecipada do treino da rede por: perda de generalização; quebra no progresso do treino; atingir um número máximo de iterações. Na paragem antecipada os dados recolhidos são divididos em conjunto de treino e conjunto de validação. O conjunto de validação é usado para um pseudo-teste, durante o treino da rede. Assim, em cada iteração a rede é treinada apenas com o conjunto de treino, sendo avaliado o erro com o conjunto de validação. O conjunto de validação não deve ser demasiado pequeno comparativamente ao conjunto de treino, visto que, o treino poderá parar numa altura indesejada, não sendo a rede convenientemente testada. O conjunto de teste é novamente utilizado para medir o desempenho da rede após o treino.

O algoritmo de aprendizagem supervisionada mais popular é o algoritmo de retropropagação do erro (Szkuta et al., 1999; Wang and Ramsay, 1998). Os dados recolhidos pela camada de entrada são propagados até à camada de saída. A saída produzida é comparada com a saída desejada para avaliar o erro, que é retropropagado ao longo das várias camadas. Cada unidade na camada escondida recebe apenas uma porção do erro, proporcional à contribuição relativa dessa unidade na elaboração da

saída. Os pesos e polarizações são actualizados progressivamente visando a minimização da função que determina a soma do quadrado dos erros, podendo ser usado o método do gradiente nessa minimização. Contudo, apesar da sua simplicidade o método do gradiente apresenta uma velocidade de aprendizagem reduzida, exigindo um tempo de computação significativo e não garantindo sempre a convergência para o mínimo global.

O processo de aprendizagem depende da taxa de aprendizagem e do termo de momento, que podem ser ajustados. A taxa de aprendizagem é a proporção do erro determinado pelo gradiente segundo a qual os pesos devem ser actualizados. O termo de momento representa a fracção dos pesos anteriores que deve ser incluída no cálculo dos novos pesos. Por um lado, uma taxa de aprendizagem reduzida tem a vantagem de permitir alterar de forma suave os pesos em cada iteração, mas conduz a uma velocidade de aprendizagem reduzida que se manifesta sob a forma de tempos de treino elevados. Por outro lado, uma taxa de aprendizagem elevada pode fornecer uma convergência mais rápida, mas pode também ocasionar instabilidade. Assim, a taxa de aprendizagem deve ser aumentada progressivamente, evitando a instabilidade pelo ajuste do termo de momento (Almeida, 1997).

Neste artigo é utilizado o método de Levenberg-Marquardt para treinar uma rede neuronal unidireccional com três camadas e uma unidade na camada de saída. O método de Levenberg-Marquardt, que corresponde a uma variante do método de Newton, é cerca de 10 a 100 vezes mais rápido que o método do gradiente (Hagan and Menhaj, 1994).

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

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

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 Ω determina a soma do quadrado dos erros, sendo dada por:

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

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

$$\mathbf{J}(\mathbf{x}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{x})}{\partial x_1} & \frac{\partial e_1(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial e_1(\mathbf{x})}{\partial x_k} \\ \frac{\partial e_2(\mathbf{x})}{\partial x_1} & \frac{\partial e_2(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial e_2(\mathbf{x})}{\partial x_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_K(\mathbf{x})}{\partial x_1} & \frac{\partial e_K(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial e_K(\mathbf{x})}{\partial x_k} \end{bmatrix} \quad (3)$$

tem-se que:

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

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

sendo a matriz S dada por:

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

Desprezando as segundas derivadas do vector dos erros, i.e., assumindo que $S \approx 0$, a matriz Hessiana é dada por:

$$\nabla^2 \Omega(\mathbf{x}) = 2 \mathbf{J}^T(\mathbf{x}) \mathbf{J}(\mathbf{x}) \tag{7}$$

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

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

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:

$$\Delta \mathbf{x} = -[\mathbf{J}^T(\mathbf{x}) \mathbf{J}(\mathbf{x}) + \zeta \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}) \mathbf{e}(\mathbf{x}) \tag{9}$$

em que \mathbf{I} é a matriz identidade, sendo o parâmetro ζ convenientemente modificado durante as iterações.

Quando o segundo termo entre parênteses rectos em (9) pode ser desprezado comparativamente ao primeiro, i.e., quando o parâmetro ζ é suficientemente pequeno, o método de Levenberg-Marquardt tem um desempenho idêntico ao do método de Gauss-Newton, apresentando em consequência uma convergência rápida. Quando o primeiro termo entre parênteses rectos em (9) pode ser desprezado comparativamente ao segundo, i.e., quando o parâmetro ζ é suficientemente grande, o método de Levenberg-Marquardt tem um desempenho idêntico ao do método do gradiente, apresentando em consequência uma convergência lenta (Saini and Soni, 2002).

3 Medida do Erro de Previsão

O erro de previsão do preço da energia eléctrica na hora k é dado por:

$$e_k = \hat{\lambda}_k - \lambda_k \quad k \in K \tag{10}$$

em que $\hat{\lambda}_k$ e λ_k são, respectivamente, o preço previsto e o preço verificado na hora k .

Para avaliar o desempenho da ferramenta computacional proposta para a previsão dos preços da energia eléctrica são utilizados os seguintes critérios: MAPE — *Mean Absolute Percentage Error*; SSE — *Sum Squared Error*; SDE — *Standard Deviation of Error*.

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

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

em que $\bar{\lambda}$ é o preço médio da energia eléctrica, durante o horizonte temporal considerado, sendo dado por:

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

Os preços da energia eléctrica podem atingir valores muito acima do normal em alguns intervalos de tempo, denominados de picos de preço, mas podem também atingir valores nulos em outros intervalos de tempo. Assim, em (11) é utilizado o preço médio da energia eléctrica durante o horizonte temporal, visando evitar a dificuldade motivada por preços próximos de zero (Shahidehpour et al., 2002).

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

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

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

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

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

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

4 Caso de Estudo

O caso de estudo é constituído pelos dados históricos dos preços do Mercado Eléctrico Espanhol em 2002, sendo o horizonte temporal de 168 horas. As abordagens propostas para a previsão dos preços do Mercado Eléctrico Espanhol têm sido baseadas apenas em séries temporais, em particular na abordagem ARIMA. Assim, a ferramenta computacional proposta neste artigo, baseada em redes neuronais artificiais, é estudada comparativamente à abordagem ARIMA.

A ferramenta computacional proposta foi implementada num computador com processador a 1.6-GHz e 512 MB de RAM, usando a aplicação informática MATLAB.

A previsão dos preços da energia eléctrica é realizada para quatro semanas do ano, nos meses de Fevereiro, Maio, Agosto e Novembro. Os preços previstos e os preços verificados com a ferramenta computacional para as semanas de Inverno, Primavera, Verão e Outono são apresentados, respectivamente, nas figuras 4 a 7. Assim, os quatro perfis dos preços da energia eléctrica apresentados, um para cada estação do ano, permitem ilustrar resultados indicativos para o ano inteiro.




Figura 4: Preços previstos e preços verificados para a semana de Inverno. As linhas a traço interrompido e as linhas a traço contínuo representam, respectivamente, os preços previstos e os preços verificados




Figura 5: Preços previstos e preços verificados para a semana de Primavera. As linhas a traço interrompido e as linhas a traço contínuo representam, respectivamente, os preços previstos e os preços verificados




Figura 6: Preços previstos e preços verificados para a semana de Verão. As linhas a traço interrompido e as linhas a traço contínuo representam, respectivamente, os preços previstos e os preços verificados




Figura 7: Preços previstos e preços verificados para a semana de Outono. As linhas a traço interrompido e as linhas a traço contínuo representam, respectivamente, os preços previstos e os preços verificados

Os dados usados na previsão dos preços da energia eléctrica correspondem aos dados históricos dos preços verificados nas sete semanas precedentes à semana considerada. Assim, os dados usados na previsão dos preços para a semana de: Inverno, 18-24 de Fevereiro de 2002, correspondem aos preços horários de 7 de Janeiro a 17 de Fevereiro de 2002; Primavera, 20-26 de Maio de 2002, correspondem aos preços horários de 8 de Abril a 19 de Maio de 2002; Verão, 19-25 de Agosto de 2002, correspondem aos preços horários de 8 de Julho a 18 de Agosto de 2002; Outono, 18-24 de Novembro de 2002, correspondem aos preços horários de 7 de Outubro a 17 de Novembro de 2002.

Na tabela 1 é apresentada a análise estatística do erro de previsão obtido com a ferramenta computacional. A primeira coluna indica a semana considerada, 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.

Tabela 1: Análise estatística do erro de previsão

Semana	MAPE	$\sqrt{\text{SSE}}$	SDE
Inverno	5.23%	37.92	1.82
Primavera	5.36%	39.63	1.91
Verão	11.40%	81.14	4.23
Outono	13.65%	76.92	3.86

A ferramenta computacional, baseada em redes neuronais artificiais, permite obter uma exactidão aceitável na previsão dos preços da energia eléctrica, com um valor médio de 8.91% para o MAPE.

Na tabela 2 é apresentado o valor do MAPE para a ferramenta computacional, baseada em redes neuronais artificiais, e para a abordagem ARIMA.

Tabela 2: Valor do MAPE para a ferramenta computacional, baseada em redes neuronais artificiais, e para a abordagem ARIMA

Semana	Redes neuronais	ARIMA
Inverno	5.23%	6.32%
Primavera	5.36%	6.36%
Verão	11.40%	13.39%
Outono	13.65%	13.78%

A exactidão na previsão dos preços da energia eléctrica é superior à obtida com abordagem ARIMA, visto que, o valor do MAPE para a ferramenta computacional é inferior. Ainda, o tempo de computação requerido pela ferramenta computacional é de 20 segundos, enquanto que a abordagem ARIMA requer cerca de 5 minutos, para cada semana considerada.

5 Conclusões

A previsão fiável dos preços da energia eléctrica representa uma vantagem competitiva para as empresas produtoras. Esta previsão tem uma influência decisiva na optimização da exploração de recursos energéticos.

Uma ferramenta computacional, baseada em redes neuronais artificiais, foi proposta para a previsão dos preços a curto prazo do Mercado Eléctrico Espanhol. A topologia da rede neuronal consiste em três camadas, tendo a camada escondida cinco unidades com função de activação do tipo tangente hiperbólica, e a camada de saída apenas uma unidade com função de activação do tipo linear. O treino da rede foi efectuado pelo método de Levenberg-Marquardt.

Os resultados numéricos confirmam o bom desempenho da ferramenta computacional proposta, visto que, obtém uma maior exactidão na previsão dos preços da energia eléctrica comparativamente à abordagem ARIMA, com um tempo de computação inferior.

6 Referências

- Almeida, L. B. (1997) *Multilayer Perceptrons*, Handbook of Neural Computation, Oxford University Press, UK.
- Angelus, A. (2001) Electricity Price Forecasting in Deregulated Markets, *Electricity Journal*, Vol. 14, No. 3, pp. 32-41.
- Bastian, J., Zhu, J., Banunaryanan, V., and Mukerji, R. (1999) Forecasting Energy Prices in a Competitive Market, *IEEE Computer Applications Power*, Vol. 12, No. 3, pp. 40-45.
- Bunn, D. W. (2000) Forecasting Loads and Prices in Competitive Power Markets, *Proceedings of the IEEE*, Vol. 88, No. 2, pp. 163-169.
- Catalão, J. P. S. (2006) *Novas Metodologias de Optimização em Sistemas de Energia Hidrotérmicos*, Dissertação de Doutoramento, Universidade da Beira Interior, Covilhã.
- Catalão, J. P. S., Mariano, S. J. P. S., Mendes, V. M. F., and Ferreira, L. A. F. M. (2006) Application of Neural Networks on Next-Day Electricity Prices Forecasting, *Proceedings of the 41st International Universities Power Engineering Conference*, Newcastle upon Tyne, UK.
- Conejo, A. J., Plazas, M. A., Espínola, R., and Molina, A. B. (2005) Day-Ahead Electricity Price Forecasting using the Wavelet Transform and ARIMA Models, *IEEE Transactions on Power Systems*, Vol. 20, No. 2, pp. 1035-1042.
- Contreras, J., Espínola, R., Nogales, F. J., and Conejo, A. J. (2003) ARIMA Models to Predict Next-Day Electricity Prices, *IEEE Transactions on Power Systems*, Vol. 18, No. 3, pp. 1014-1020.
- Fosso, O. B., Gjelsvik, A., Haugstad, A., Mo, B., and Wangensteen, I. (1999) Generation Scheduling in a Deregulated System. The Norwegian Case, *IEEE Transactions on Power Systems*, Vol. 14, No. 1, pp. 75-80.
- Garcia, R. C., Contreras, J., van Akkeren, M., and Garcia, J. B. C. (2005) A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices, *IEEE Transactions on Power Systems*, Vol. 20, No. 2, pp. 867-874.
- Hagan, M. T. and Menhaj, M. B. (1994) Training Feedforward Networks with the Marquardt Algorithm, *IEEE Transactions on Neural Networks*, Vol. 5, No. 6, pp. 989-993.
- Haykin, S. (1999) *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, New Jersey, USA.

- Hippert, H. S., Pedreira, C. E., and Souza, R. C. (2001) Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, *IEEE Transactions on Power Systems*, Vol. 16, No. 1, pp. 44-55.
- Nogales, F. J., Contreras, J., Conejo, A. J., and Espinola, R. (2002) Forecasting Next-Day Electricity Prices by Time Series Models, *IEEE Transactions on Power Systems*, Vol. 17, No. 2, pp. 342-348.
- Principe, J. C., Euliano, N. R., and Lefebvre, W. C. (2000) *Neural and Adaptive Systems: Fundamentals Through Simulations*, Wiley, New York, USA.
- Rodriguez, C. P. and Anders, G. J. (2004) Energy Price Forecasting in the Ontario Competitive Power System Market, *IEEE Transactions on Power Systems*, Vol. 19, No. 1, pp. 366-374.
- Saini, L. M. and 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, pp. 578-584.
- Shahidehpour, M., Yamin, H., and Li, Z. (2002) *Market Operations in Electric Power Systems: Forecasting, Scheduling and Risk Management*, Wiley, New York, USA.
- Szkuta, B. R., Sanabria, L. A., and Dillon, T. S. (1999) Electricity Price Short-Term Forecasting using Artificial Neural Networks, *IEEE Transactions on Power Systems*, Vol. 14, No. 3, pp. 851-857.
- Wang, A. J. and Ramsay, B. (1998) A Neural Network Based Estimator for Electricity Spot-Pricing with Particular Reference to Weekend and Public Holidays, *Neurocomputing*, Vol. 23, No. 1, pp. 47-57.
- Yamin, H. Y., Shahidehpour, S. M., and Li, Z. (2004) Adaptive Short-Term Electricity Price Forecasting using Artificial Neural Networks in the Restructured Power Markets, *International Journal of Electrical Power & Energy Systems*, Vol. 26, No. 8, pp. 571-581.
- Zhou, M., Yan, Z., Ni, Y. X., Li, G., and Nie, Y. (2006) Electricity Price Forecasting with Confidence-Interval Estimation through an Extended ARIMA Approach, *IEE Proceedings-Generation Transmission and Distribution*, Vol. 153, No. 2, pp. 187-195.