

FERRAMENTA COMPUTACIONAL BASEADA EM REDES NEURONAIS PARA PREVISÃO DOS PREÇOS DA ENERGIA ELÉCTRICA NUM MERCADO COMPETITIVO

João Catalão^{1*}, Sílvio Mariano¹, Victor Mendes² e Luís Ferreira³

1: Departamento de Engenharia Electromecânica
Universidade da Beira Interior
R. Fonte do Lameiro, 6201-001 Covilhã, Portugal
e-mail: {catalao,sm}@ubi.pt

2: Departamento de Engenharia Electrotécnica e Automação
Instituto Superior de Engenharia de Lisboa
R. Conselheiro Emídio Navarro, 1950-062 Lisboa, Portugal
e-mail: vfmendes@isel.pt

3: Departamento de Engenharia Electrotécnica e de Computadores
Instituto Superior Técnico
Av. Rovisco Pais, 1049-001 Lisboa, Portugal
e-mail: lmf@ist.utl.pt

Palavras-chave: Ferramenta Computacional, Redes Neurais, Previsão dos Preços, Energia Eléctrica, Mercado Competitivo

Resumo. *Esta comunicação trata o problema da previsão dos preços da energia eléctrica. A previsão fiável dos preços da energia eléctrica é de crucial importância para as empresas produtoras num mercado competitivo. As abordagens propostas para a previsão dos preços da energia eléctrica têm sido baseadas em séries temporais e em redes neuronais. Para o Mercado Eléctrico Espanhol as abordagens propostas têm sido apenas baseadas em séries temporais, em particular na abordagem ARIMA. Assim, surge a motivação para a aplicação de redes neuronais na previsão dos preços do Mercado Eléctrico Espanhol, sendo avaliada a exactidão na previsão comparativamente à abordagem ARIMA.*

1. INTRODUÇÃO

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. Pelo que, uma ferramenta computacional que forneça uma previsão fiável dos preços da energia eléctrica representa uma vantagem competitiva para as empresas produtoras face à concorrência.

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, tendo em conta a evolução dos custos dos combustíveis e a inovação tecnológica das centrais [1]. 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 [2]. 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 [3].

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: 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.

Nesta comunicação é desenvolvida uma ferramenta computacional, baseada em redes neuronais, para a previsão dos preços a curto prazo do Mercado Eléctrico Espanhol. O interesse pelo sector eléctrico em Espanha surge pelo facto de este país ser o único com o qual Portugal tem interligações, as quais influenciam o sector eléctrico em Portugal. Ainda, a existência de rios comuns, como por exemplo, o rio Douro, condiciona a exploração dos recursos hídricos em Portugal.

As abordagens propostas para a previsão dos preços do Mercado Eléctrico Espanhol têm sido baseadas apenas em séries temporais [4], em particular na abordagem ARIMA — Auto Regressive Integrated Moving Average [5]. A abordagem ARIMA exige a construção de um modelo matemático a partir dos dados históricos recolhidos, a estimação dos parâmetros associados ao modelo e sua posterior validação. Tem como principal vantagem o facto de poder ser bastante exacta em previsões sobre um amplo leque de séries temporais.

Contudo, na abordagem ARIMA é difícil conciliar os parâmetros com o modelo inicialmente construído à medida que novos dados surgem, sendo necessário rever o modelo, ou então, construir um novo modelo. Ainda, a construção de um modelo matemático para sistemas complexos e não lineares é de difícil elaboração, sendo a abordagem ARIMA computacionalmente exigente.

As abordagens baseadas em redes neuronais [6,7] apresentam características que não se encontram nas abordagens convencionais de previsão baseadas em séries temporais, nomeadamente: aprendizagem e generalização; processamento maciçamente paralelo; não linearidade; adaptabilidade; robustez e degradação suave.

Estas características são a principal razão pela qual nesta comunicação se optou pelas redes neuronais, visto que, se pretendeu implementar um meio de previsão dos preços da energia eléctrica que assegurasse simultaneamente uma fiabilidade aceitável e tempos de computação reduzidos.

2. REDES NEURONAIS

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 resultam da interligação massiva de unidades de processamento simples, projectadas de forma a replicar o funcionamento do cérebro humano [8].

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

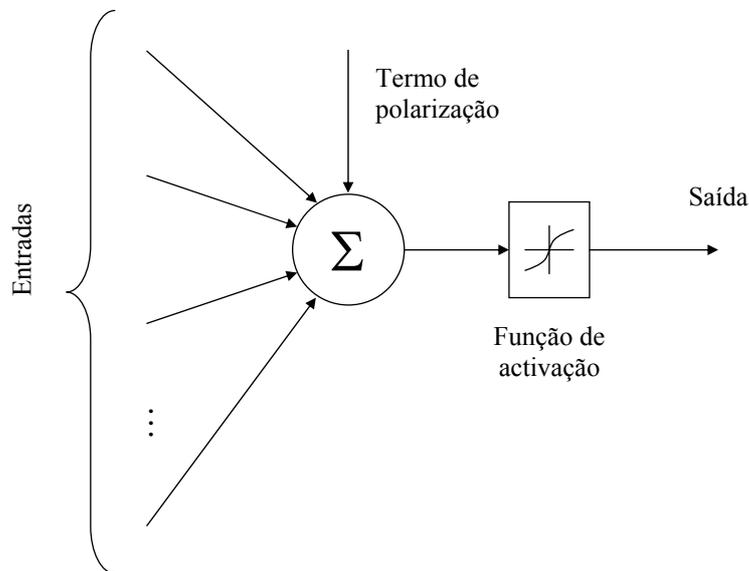


Figura 1. Estrutura de cada unidade de uma rede neuronal: entradas, termo de polarização, função de activação e saída.

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.

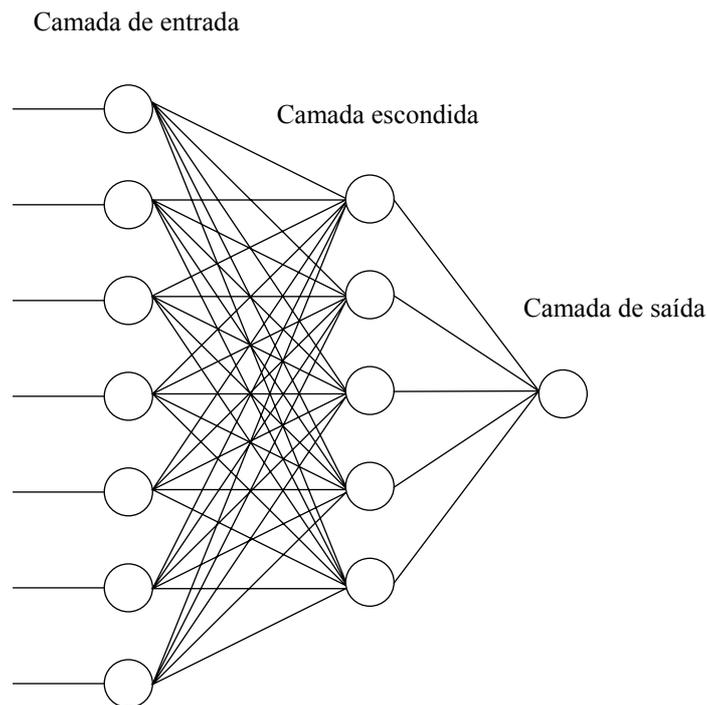


Figura 2. Rede neuronal unidireccional com três camadas e uma unidade na camada de saída.

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 [9].

Nesta comunicação, 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. 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 o 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.

Nesta comunicação é utilizado o método de Levenberg-Marquardt [10] 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.

3. FERRAMENTA COMPUTACIONAL

Uma ferramenta computacional, baseada em redes neuronais, é desenvolvida 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 é efectuado pelo método de Levenberg-Marquardt.

Em geral, o preço da energia eléctrica é influenciado pelos seguintes factores: dados históricos dos preços e da procura de energia eléctrica; reserva e importação de energia eléctrica; interrupções no fornecimento de energia eléctrica devido a falhas; estratégias de ofertas em bolsa de energia eléctrica; manutenção das unidades de produção; temperatura atmosférica e estado do tempo.

Os preços médios diários do Mercado Eléctrico Espanhol em 2002 são apresentados na Figura 3.

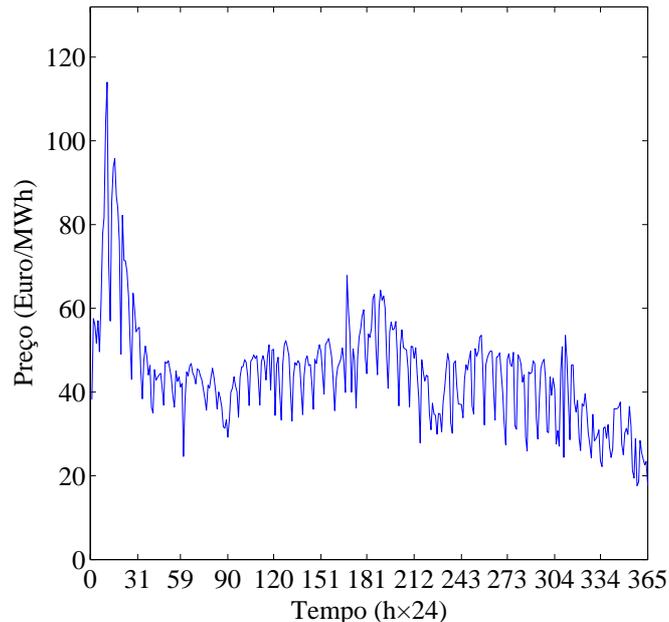


Figura 3. Preços médios diários do Mercado Eléctrico Espanhol em 2002.

Não sendo possível considerar todos os factores apresentados anteriormente é necessário escolher aqueles que, podendo ser conhecidos, são mais importantes para a previsão dos preços da energia eléctrica. Por exemplo: segundo a referência [11] a consideração da reserva e importação de energia eléctrica, e das interrupções no fornecimento de energia eléctrica devido a falhas, não melhoram a previsão. A informação referente às estratégias de ofertas em bolsa de energia eléctrica e à manutenção das unidades de produção é geralmente confidencial [11]. Ainda, segundo a referência [12] o efeito da temperatura atmosférica e do estado do tempo pode ser incorporado na procura de energia eléctrica. Contudo, no caso da abordagem ARIMA e das redes neuronais, os dados históricos da procura de energia eléctrica não melhoram significativamente a previsão [12].

Na ferramenta computacional são utilizados somente os dados históricos dos preços do Mercado Eléctrico Espanhol. Assim, a influência dos dados históricos dos preços, resultante das características de sazonalidade diária e semanal do perfil dos preços, é considerada a mais importante para a previsão dos preços da energia eléctrica.

4. MEDIDA DO ERRO DE PREVISÃO

O erro de previsão dos preços da energia eléctrica na hora k é dado por:

$$e_k = \hat{\lambda}_k - \lambda_k \quad (1)$$

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 desenvolvida 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:

$$\text{MAPE} = \frac{100}{K} \sum_{k=1}^K \frac{|\hat{\lambda}_k - \lambda_k|}{\bar{\lambda}} \quad (2)$$

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

$$\bar{\lambda} = \frac{1}{K} \sum_{k=1}^K \lambda_k \quad (3)$$

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 (2) é utilizado o preço médio da energia eléctrica durante o horizonte temporal, visando evitar a dificuldade motivada por preços próximos de zero [13].

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

$$\text{SSE} = \sum_{k=1}^K (\hat{\lambda}_k - \lambda_k)^2 \quad (4)$$

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

$$\text{SDE} = \sqrt{\frac{1}{K} \sum_{k=1}^K (e_k - \bar{e})^2} \quad (5)$$

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

$$\bar{e} = \frac{1}{K} \sum_{k=1}^K e_k \quad (6)$$

5. RESULTADOS NUMÉRICOS

Nesta secção são apresentados os resultados numéricos obtidos, ilustrando o desempenho da ferramenta computacional desenvolvida para a previsão dos preços da energia eléctrica. O caso de estudo é constituído pelos dados históricos dos preços do Mercado Eléctrico Espanhol em 2002, sendo o horizonte temporal de 168 horas.

A previsão dos preços da energia eléctrica é realizada para quatro semanas representativas das quatro estações do ano, nos meses de Fevereiro, Maio, Agosto e Novembro. A ferramenta computacional, baseada em redes neuronais, é posteriormente comparada à abordagem ARIMA em termos de exactidão na previsão e tempo de computação.

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.

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

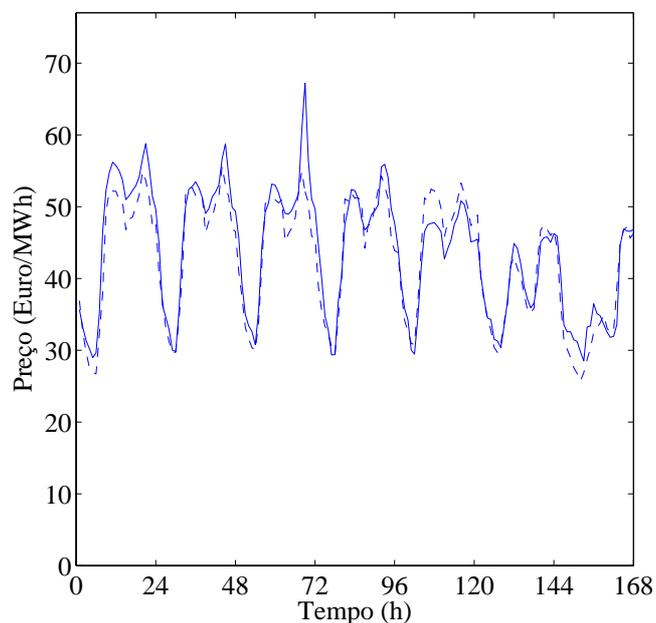


Figura 4. Preços previstos e preços verificados para a semana de Inverno. As linhas a traço interrompido e as linhas a traço contínuo representam respectivamente os preços previstos e os preços verificados.

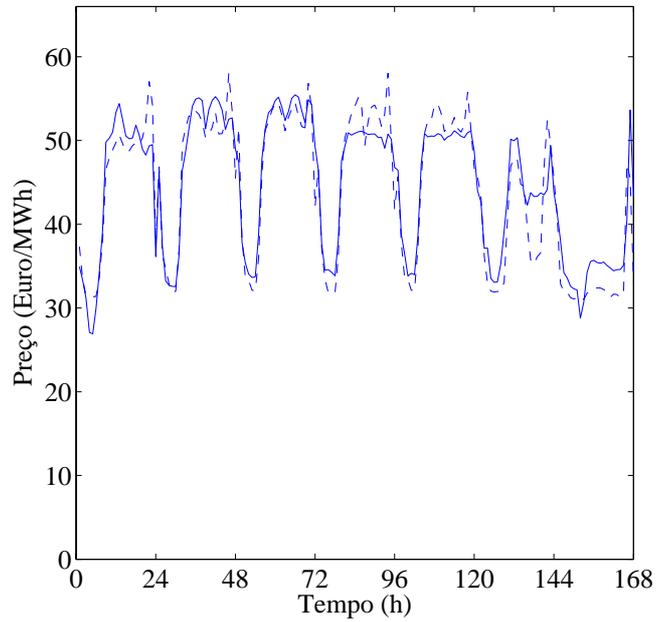


Figura 5. Preços previstos e preços verificados para a semana de Primavera. As linhas a traço interrompido e as linhas a traço contínuo representam respectivamente os preços previstos e os preços verificados.

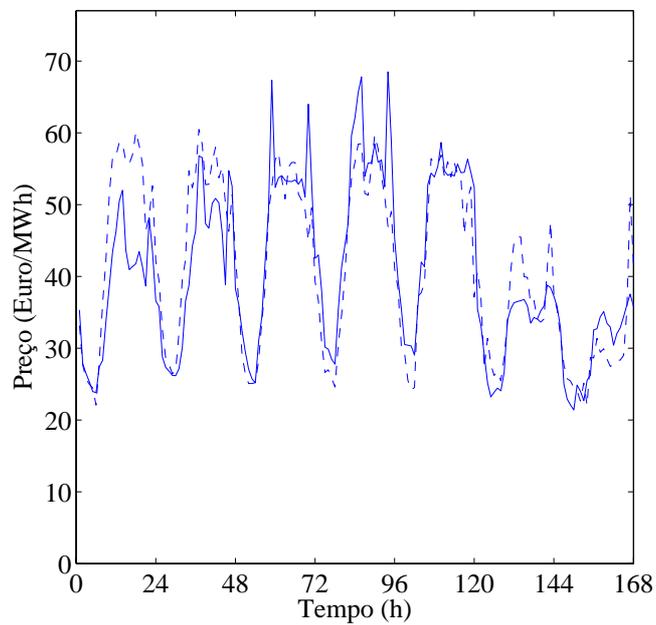


Figura 6. Preços previstos e preços verificados para a semana de Verão. As linhas a traço interrompido e as linhas a traço contínuo representam respectivamente os preços previstos e os preços verificados.

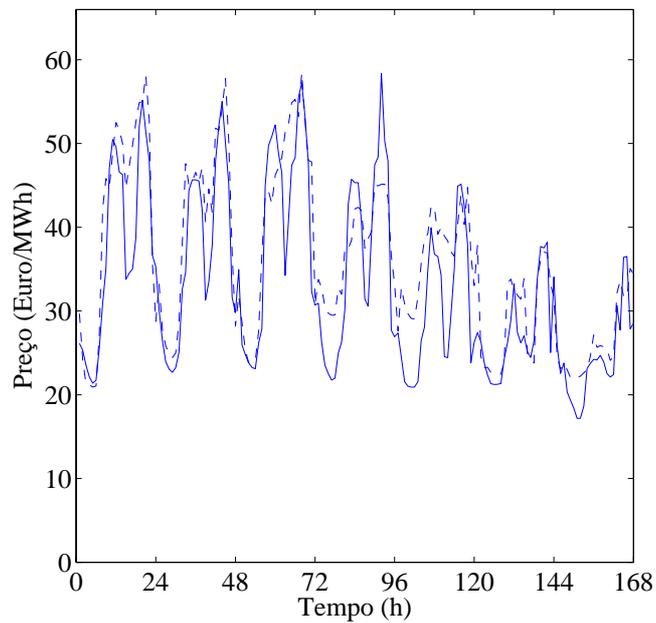


Figura 7. Preços previstos e preços verificados para a semana de Outono. As linhas a traço interrompido e as linhas a traço contínuo representam respectivamente os preços previstos e os preços verificados.

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.

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

Tabela 1. Análise estatística do erro de previsão.

A ferramenta computacional, baseada em redes neuronais, 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, 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%

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

A ferramenta computacional apresenta uma melhor adequação comparativamente à abordagem ARIMA para a previsão dos preços da energia eléctrica. Ainda, o tempo de computação requerido pela ferramenta computacional desenvolvida é de 20 segundos, enquanto que a abordagem ARIMA requer cerca de 5 minutos, para cada semana considerada.

6. CONCLUSÕES

A previsão fiável dos preços da energia eléctrica representa uma vantagem competitiva para as empresas produtoras face à concorrência. Uma ferramenta computacional, baseada em redes neuronais, é desenvolvida 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 é efectuado pelo método de Levenberg-Marquardt. A ferramenta computacional permite obter não só uma exactidão aceitável na previsão dos preços da energia eléctrica, mas também um tempo de computação inferior comparativamente à abordagem ARIMA.

REFERÊNCIAS

- [1] A. Angelus, “Electricity price forecasting in deregulated markets”, *Electricity J.* Vol. **14**, pp. 32-41, (2001).
- [2] J. Bastian, J. Zhu, V. Banunarayanan e R. Mukerji, “Forecasting energy prices in a competitive market”, *IEEE Comput. Appl. Power* Vol. **12**, pp. 40-45, (1999).
- [3] D.W. Bunn, “Forecasting loads and prices in competitive power markets”, *Proc. IEEE* Vol. **88**, pp. 163-169 (2000).
- [4] F.J. Nogales, J. Contreras, A.J. Conejo e R. Espínola, “Forecasting next-day electricity prices by time series models”, *IEEE Trans. Power Syst.* Vol. **17**, pp. 342-348, (2002).
- [5] J. Contreras, R. Espínola, F.J. Nogales e A.J. Conejo, “ARIMA models to predict next-day electricity prices”, *IEEE Trans. Power Syst.* Vol. **18**, pp. 1014-1020, (2003).
- [6] B.R. Szkuta, L.A. Sanabria e T.S. Dillon, “Electricity price short-term forecasting using artificial neural networks”, *IEEE Trans. Power Syst.* Vol. **14**, pp. 851-857, (1999).

- [7] H.Y. Yamin, S.M. Shahidehpour e Z. Li, “Adaptative short-term electricity price forecasting using artificial neural networks in the restructured power markets”, *Electr. Power Energy Syst.* Vol. **26**, pp. 571-581, (2004).
- [8] S. Haykin, *Neural networks: a comprehensive foundation*, Prentice-Hall, New Jersey (1999).
- [9] J.C. Principe, N.R. Euliano e W.C. Lefebvre, *Neural and adaptive systems: fundamentals through simulations*, Wiley, New York (2000).
- [10] M.T. Hagan e M.B. Mehraj, “Training feed forward networks with Marquardt algorithms”, *IEEE Trans. Neural Netw.* Vol. **5**, pp. 989-993, (1994).
- [11] C.P. Rodriguez e G.J. Anders, “Energy price forecasting in the Ontario competitive power system market”, *IEEE Trans. Power Syst.* Vol. **19**, pp. 366-374, (2004).
- [12] A.J. Conejo, J. Contreras, R. Espínola e M.A. Plazas, “Forecasting electricity prices for a day-ahead pool-based electric energy market”, *Int. J. Forecast.* Vol. **21**, pp. 435-462, (2005).
- [13] M. Shahidehpour, H. Yamin e Z. Li, *Market operations in electric power systems: forecasting, scheduling and risk management*, Wiley, New York (2002).