



**REDES NEURAS ARTIFICIAIS APLICADAS NA PREVISÃO DO PREÇO NO
MERCADO IBÉRICO DE ELETRICIDADE**

**ARTIFICIAL NEURAL NETWORKS APPLIED IN FORECASTING THE PRICE
IN THE IBERIAN ELECTRICITY MARKET**

Ronaldo Cordeiro Novaes¹

Leonardo Cesar de Morais²

Fernando Parra dos Anjos Lima³

Simone Silva Frutuoso Souza⁴

RESUMO: Este artigo propõe uma abordagem inteligente para previsão dos preços de energia elétrica no Mercado Ibérico de Eletricidade (MIBEL). No MIBEL, os preços da energia elétrica é fortemente depende de diversos fatores, nomeadamente, a carga, o mix de produção (energias renováveis e não-renováveis), a importação de energia e exportação entre Portugal e Espanha, as condições meteorológicas, entre outros fatores. A previsão de preços é uma tarefa bastante complexa e difícil de se realizar, dada a complexidade do mercado e também de sua dependência a vários fatores incontroláveis, que podem causar alterações repentinas nos preços. Neste sentido, técnicas de computação inteligente como as redes neurais artificiais, são alternativas eficientes para analisar este problema. Assim,

¹ Graduando em Engenharia Elétrica, UNITOLEDO, 2016.

² Graduando em Engenharia Elétrica, UNITOLEDO, 2016.

³ Doutor em Engenharia Elétrica, UNESP, 2016.

⁴ Mestre em Engenharia Elétrica, UNESP, 2013.

neste artigo propõe-se uma rede neural artificial multi-layer perceptron com backpropagation para resolver este problema. Para avaliar este sistema foram utilizados dados reais do mercado Ibérico. Os resultados demonstrar eficiência e robustez do método proposto.

Palavras-chave: Previsão de Preços; Mercado Ibérico de Eletricidade; Sistemas Inteligentes; Multi-Layer Perceptron; Backpropagation

ABSTRACT: This paper proposes an intelligent approach to forecast electricity prices in the Iberian Electricity Market (MIBEL). In MIBEL, electricity prices are strongly dependent on several factors, namely, the load, the production mix (renewable and non-renewable energy), energy import and export between Portugal and Spain, meteorological conditions, among others factors. Pricing is a very complex and difficult task, given the complexity of the market and its dependence on a number of uncontrollable factors that can cause sudden changes in prices. In this sense, intelligent computing techniques such as artificial neural networks are efficient alternatives to analyze this problem. Thus, in this paper we propose an artificial neural network multi-layer perceptron with backpropagation to solve this problem. To evaluate this system were used real data of the Iberian market. The results demonstrate efficiency and robustness of the proposed method.

Keywords: Prediction of Prices; Iberian Electricity Market; Intelligent Systems; Multi-Layer Perceptron; Backpropagation

1. Introdução

O mercado de energia elétrica mundial está em constante mudança, e passa por uma transformação através do conceito das redes elétricas inteligentes, ou conforme a denominação formal, “smart grids”. O conceito smart grid deve ser compreendido como uma nova abordagem de sistemas elétricos que se baseia na utilização intensiva de tecnologias de automação, computação e de telecomunicações para monitoramento e controle dos sistemas elétricos, permitindo a implantação de novas estratégias de controle, comunicação, proteção e otimização de forma que a eficiência dos sistemas atualmente em uso seja aumentada (DONGLI et al., 2011).

Revista Engenharia em Ação UniToledo, Araçatuba, SP, v. 01, n. 01, p. 153-168, out./dez. 2016.

A energia elétrica é essencial para as pessoas nos dias atuais, seja para produção de bens de consumo, como para o uso no cotidiano doméstico. Desta forma, nos últimos anos, a crescente integração de energia eólica, e outras fontes renováveis nos sistemas de energia elétrica, tem levantado diversas questões associadas à intermitência dessas fontes. Neste novo ambiente, a gestão adequada destas reservas torna-se ainda mais relevante, se comparada aos sistemas convencionais.

Dados estes fatos, as concessionárias de energia passaram a investir em suas instalações, de modo a automatizar e modernizar os processos de análise e operação do mercado, e, conseqüentemente, aumentar a lucratividade, visando transformar os sistemas atuais em redes elétricas smart grids (MCDONALD, 2003). Estas mudanças ocorrem devido a diversos fatores, como: novas tecnologias de geração, crescimento dos núcleos populacionais e industriais, condições climáticas e outros.

Um exemplo desta evolução ocorre com os governos de Portugal e Espanha que realizaram um acordo para criar o mercado ibérico de eletricidade (MIBEL), com o objetivo de liberalizar o setor da energia, aumentar a concorrência entre os agentes do mercado e, assim, incentivar o desenvolvimento tecnológico e de gestão econômica dos preços da energia. Outra meta prioritária foi o crescimento da geração de energia renovável e promover o intercâmbio de energia entre os dois países.

Com toda esta dinâmica, o mercado elétrico em geral sofre muita alteração, e os preços da eletricidade no MIBEL pode oscilar bastante, dependendo de uma série de variáveis, como a carga, o mix de produção (em especial, a produção das energias renováveis), importação e exportação de energia entre Portugal e Espanha, as condições meteorológicas, entre outros.

A previsão e interpretação dos padrões de preços são atribuições bastante importantes para os agentes de mercado. No entanto, como outros preços de mercado de ações, o comportamento dos preços de energia elétrica é bastante complexo e difícil de interpretar, dada a complexidade do mercado e sua dependência de vários fatores incontrolláveis, que causam alterações de preços anormais, como por exemplo, anormalidade no clima.

As técnicas de previsão são utilizadas para estimar, por exemplo, a evolução do consumo, de preços e da produção de energia (eólica, solar, CHP, mini-hídricas entre outras fontes), e detecção de mudanças significativas nas séries temporais, identificação dos períodos de reserva a subir ou descer, e o reconhecimento de alterações ou patamares de preços.

A previsão em sistemas elétricos de potência constitui-se numa atividade de grande relevância, tendo em vista que a maioria dos estudos realizados (fluxo de potência, despacho econômico, planejamento da expansão, análise de estabilidade, gestão de reservas, etc.), somente poderá ser realizada se houver a disponibilidade de uma estimativa (a mais precisa possível) da carga a ser atendida e do preço de mercado para o cenário atual do sistema elétrico. Esses estudos visam proporcionar, aos engenheiros e companhias do setor elétrico, um conjunto de informações vitais para que os sistemas elétricos possam ser planejados e operados de forma segura, confiável e econômica. A estimativa da carga, preços e produção de energia, seja de curto, médio ou de longo prazo, é determinada, via procedimentos previsores, a partir de dados históricos de consumo de energia, produção de energia, preços de energias e dados climáticos (CHAABENE, 2008), entre outros fatores importantes.

Neste contexto, na literatura, encontram-se diversas técnicas para realizar previsões, sendo as principais: regressão linear múltipla ou simples (O'DONOVAN, 1983), estimação de estado (GROSS; GALIANA, 1987), filtro de Kalman (O'DONOVAN, 1983), modelos ARIMA (*Auto Regressive Integrated Moving Average*), (BOX; JENKINS, 1976), redes neurais artificiais (CARPENTER et al., 1992; BOTTERUD et al., 2013; FIDALGO; LOPES, 2005), entre outras técnicas.

As técnicas utilizadas no problema de previsão de preços, são empregadas como ferramentas de suporte e tomadas de decisões vinculadas ao resultado da previsão. Neste contexto, tais ferramentas podem ser desenvolvidas utilizando-se técnicas de inteligência computacional, tais como: redes neurais artificiais, sistemas imunológicos artificiais, entre outras técnicas.

Com base na exposição supracitada, este artigo tem por objetivo apresentar um sistema inteligente para previsão do preço da energia elétrica a curto prazo no mercado

Ibérico (Portugal-Espanha) utilizando uma rede neural artificial multi-layer perceptron com backpropagation. Este sistema foi desenvolvido em Matlab® (MATLAB, 2011) e foi testado com dados reais do mercado Ibérico, cedidos pela companhia elétrica EDP (Energias de Portugal).

Os resultados foram analisados buscando comparações com resultados padrões adotados na literatura.

2. Mercado Ibérico de Eletricidade

O Mercado Ibérico de Eletricidade (MIBEL), foi o resultado de um acordo entre a República Portuguesa e o Reino de Espanha para a constituição de um mercado regional de eletricidade. Esta iniciativa encontra-se estrategicamente inserida no plano da Comissão Europeia visando a criação de um Mercado Europeu de Eletricidade.

O acordo foi assinado em 1 de outubro de 2004 e a sua posterior entrada em funcionamento em julho de 2007 tornou o MIBEL no segundo mercado regional a nível Europeu a ser constituído.

Como aspectos importantes do acordo estabelecido entre os dois países temos a caracterização do mercado e as alterações legislativas que foram necessárias produzir de modo a viabilizar a entrada em vigor do mercado (DOMÍNGUEZ; BERNAT, 2007).

O MIBEL contempla a liberdade e igualdade de acesso de todos os agentes a todas as plataformas de negociação, promovendo assim um regime de livre concorrência. Outros aspectos importantes são a transparência, liquidez e estabilidade do próprio mercado, bem como a preocupação com a qualidade de serviço e com a garantia de abastecimento de energia elétrica.

O MIBEL é um mercado contínuo, assim como a necessidade de energia elétrica por parte dos consumidores. Assim, o mercado encontra-se em funcionamento todo o ano, a toda a hora.

Este mercado adoptou várias características do modelo anteriormente em operação na Espanha. O modelo de funcionamento do mercado é misto (Pool e Contratos Bilaterais) e existem duas zonas geográficas distintas de operação do sistema, Portugal e Espanha.

Para a entrada em funcionamento do MIBEL foram criadas duas entidades responsáveis pela gestão do mercado ibérico de energia: o Operador del Mercado Ibérico de Energia (OMIE), polo Espanhol, e o Operador do Mercado Ibérico de Energia, polo Português (OMIP). O OMIE é responsável pela gestão dos mercados diário e intra-diário, enquanto o OMIP é responsável pela gestão dos mercados de derivados.

As entidades concessionárias das redes de transporte, em Portugal e na Espanha, permaneceram como os operadores de sistema. Estes operadores têm como função a validação dos resultados obtidos no mercado, gerem a contratação dos serviços de sistema e os desvios dos programas contratados e operam o sistema em tempo real.

A ERSE (Entidade Reguladora do Sistema Elétrico), entidade reguladora em Portugal, dispõe de competências alargadas no que diz respeito à fixação das tarifas, assim como um conjunto de regras reguladoras de todo o setor elétrico Nacional. Nesse sentido a ERSE regula as seguintes atividades:

- Aquisição de energia elétrica, gestão global do sistema e o transporte de energia elétrica.
- Distribuição de energia elétrica, comercialização de redes, comercialização regulada e compra e venda de energia elétrica.

Na Espanha, a ERSE tem funções menos abrangentes, sendo consultada aquando da fixação das tarifas.

Caso o mercado tivesse um desempenho mais positivo e sólido, não deveriam ser reguladas algumas tarifas, como o caso da tarifa de venda a clientes finais. Porém o mercado ainda se encontra longe de um funcionamento que permita a existência de confiança governamental suficiente de modo a aplicar essas medidas.

2.1 Preço de Mercado

O conceito geral de preço de mercado, é o valor pelo qual um bem ou serviço é oferecido no mercado, sendo assim importante caracterizar o mercado em que determinado bem ou serviço está inserido, de modo a entender a volatilidade que lhe pode estar associada.

Os mercados podem assumir diferentes tipos de classificação (VENTOSA, 2005):

- Concorrência Perfeita – mercado onde existem muitos compradores e muitos vendedores e onde nenhum agente consegue influenciar o preço das mercadorias;
- Concorrência Imperfeita – mercado onde existe muitos compradores e muitos vendedores, porém existe diferenciação dos produtos;
- Oligopólio – mercado onde poucas empresas controlam a oferta, por conseguinte, o mercado. Isto acontece devido ao número de vendedores ser reduzido, quando comparado com o número de compradores;
- Monopólio - mercado onde apenas um agente define o seu preço e a sua quantidade negociada.

Tais tipos de mercado, influenciam drasticamente a forma de operar e comercializar a energia, bem como o seu preço.

3. Rede Neural Artificial Multi-layer Perceptron com Backpropagation

A rede neural artificial Multi-Layer Perceptron (MLP) corresponde a um processador paralelo, constituído de neurônios (unidades de processamento). Os neurônios são dispostos em uma ou mais camadas interligadas por um grande número de conexões. As conexões estão associadas a pesos que representam o conhecimento. O aprendizado da rede MLP é denominado de treinamento e ocorre através do ajuste dos pesos. O aprendizado comumente é realizado utilizando algum algoritmo de treinamento. Neste trabalho adotou-se o algoritmo de backpropagation, que é o algoritmo mais conhecido para treinamento de redes MLP. O algoritmo backpropagation é uma técnica de aprendizado supervisionado que utiliza pares (entrada e saída desejada) para através do cálculo do erro, ajustar os pesos da rede e adquirir conhecimento (HAYKIN, 1994).

De forma mais detalhada, o processo de aprendizagem da rede MLP utilizando o backpropagation é executado através dos passos a seguir (WERBOS, 1974):

1. Iniciar os pesos com valores aleatórios e não nulos;
2. Apresentar um padrão de entrada e propagá-lo até a saída da rede;

3. Calcular os erros instantâneos na saída da rede (E), em que (1) representa o cálculo do erro de cada neurônio da rede no instante n , e (2) representa o cálculo do erro total no instante n ;

$$e_j(n) = d_j(n) - y_j(n) \quad (1)$$

$$E(n) = \frac{1}{2} \sum_{j=1}^m e_j^2(n) \quad (2)$$

4. Calcular os gradientes locais (δ) dos neurônios da camada de saída, dado pela equação (4). O gradiente do neurônio j é resultante do produto entre o erro desse neurônio (e_j) com a derivada da função de ativação (Q') aplicada ao campo local induzido v_j calculado em (3), onde w_{ij} representa o peso de entrada associado a cada neurônio j ;

$$v_j(n) = \sum_{i=0}^m w_{ij}(n) - y_i(n) \quad (3)$$

$$\delta_j(n) = e_j(n)Q'(v_j(n)) \quad (4)$$

5. Ajustar os pesos da camada de saída utilizando as expressões em (5):

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (5)$$

$$w_{ji}(n+1) = w_{ji} + \Delta w_{ji}(n)$$

6. Calcular os gradientes locais dos neurônios da camada oculta utilizando (6), em que p refere-se à quantidade de neurônios à direita conectados a j :

$$\delta_j(n) = Q'(v_j(n)) \sum_{k=1}^p \delta_k(n) w_{kj}(n) \quad (6)$$

7. Ajustar os pesos da camada oculta utilizando as expressões em (7);

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (7)$$

$$w_{ji}(n+1) = w_{ji} + \Delta w_{ji}(n)$$

8. Repetir os passos de 2 a 7 para todos os padrões de treinamento (1 época);

9. Calcular a cada época o erro médio quadrado (EMQ) para o treinamento utilizando a expressão (8), onde N representa o número de padrões utilizados no treinamento;

$$EMQ = \frac{1}{N} \sum_{j=1}^N E(j) \quad (8)$$

10. Se o EMQ for maior que o valor desejado (VD) ou se o contador de épocas for menor que o número máximo de épocas ($NMEp$), repetir o passo 8. Em caso contrário pare;

4. Previsão de Preços no Mercado Ibérico

Nesta seção apresenta-se a descrição da metodologia de previsão de preços do MIBEL utilizando uma rede neural artificial MLP com backpropagation.

4.1 Dados do Conjunto de Treino e Testes

O horizonte temporal em análise neste estudo foi de 24 horas, tendo a escolha das variáveis sido feita em conformidade com esse fato. Os dados contemplam todo o ano de 2013, assim como os quatro primeiros meses de 2014.

O período entre 1 de janeiro de 2013 e 28 de fevereiro de 2014 foi considerado como conjunto de treino, enquanto os meses de março e abril de 2014 representam o conjunto de teste. O período de treino tem um total de 425 dias, e corresponde a 10200 Alvos (saídas) diferentes. O conjunto de teste é posterior ao conjunto de treino de forma a simular o que acontece na realidade. O período correspondente ao conjunto de Testes representa um total de 61 dias, e corresponde a 1464 saídas.

Os conjuntos de Treino e Testes foi compostos por 11 variáveis, sendo: Ano; Mês; Dia_Semana; Hora; Preço_Dia-1; Preço_Dia-7; Preço_Dia-14, Consumo_Dia-1, Consumo_Dia-7, Mix_Produções_Dia-1 e Mix_Produções_Dia-7.

4.2 Normalização dos Dados

É necessário que se realize a normalização dos dados para tornar o processo de aprendizagem da rede MLP mais rápido e mais eficiente. Se os seus dados estiverem normalizados os seus valores encontram-se na mesma ordem de grandeza, reduzindo-se os efeitos de escala e de polarização.

A normalização consiste na transformação de valores que se encontram nas suas escalas reais, para uma escala a definir, de modo a promover a sua equalização.

Foi utilizado o método Min-Max para normalizar os dados (SARAIVA et al., 2002). Este método foi configurado para converter todos os valores na gama de intervalo [-1; 1] e a conversão é realizada conforme a equação (9).

$$v' = \frac{v - \min_a}{\max_a - \min_a} (\max_A - \min_A) + \min_A \quad (9)$$

em que: v' é o valor normalizado, v é o valor a ser normalizado, \min_a e \max_a são o valor mínimo e máximo da grandeza desnormalizada, e \min_A e \max_A são o valor mínimo e máximo do intervalo ao qual a grandeza deve ser normalizada.

4.3 Metodologia de Previsão

Na sequência apresenta-se a arquitetura e a forma de análise de eficiência do sistema de previsão baseado na rede neural MLP.

4.3.1 Arquitetura do Sistema de Previsão

A arquitetura da rede neural MLP utilizada possui, 11 neurónios na camada de entrada, 15 neurónios na camada escondida e 1 neurónio na camada de saída. Assim, foram utilizadas 264 entradas para se obter a previsão para as 24 horas de um dia, como é o objetivo deste trabalho. Na Figura 1 está ilustrada a da arquitetura simplificada da rede neural MLP utilizada, de modo a obter-se uma saída.

Os parâmetros utilizados pela RNA Multi-Layer Perceptron foram: $NMEp=10^4$ e $VD=10^{-6}$. Vale ressaltar, que foram testadas diversas configurações para a arquitetura da rede neural MLP, e a arquitetura adotada foi a que apresentou melhores resultados.

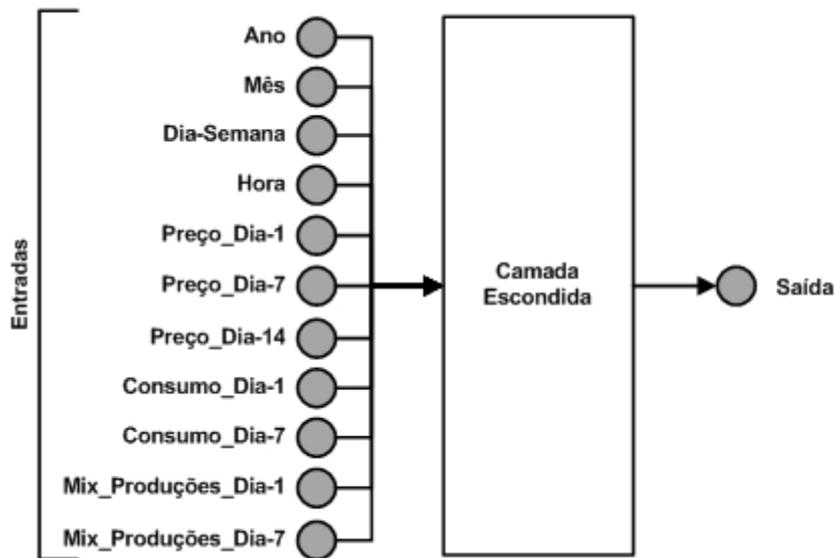


Figura 1. Arquitetura da rede MLP utilizada para previsão.

4.3.2 Análise da Performance do Sistema de Previsão

De modo a analisar a performance da rede neural MLP proposta, foi utilizado o MAPE (*Mean Absolute Percentage Error*), apresentado na equação (10), que representa o erro absoluto percentual médio. Este indicador compara o resultado obtido pela previsão com o resultado real do mercado (PINO, 2008).

$$MAPE = \frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{\left(\frac{a_k + y_k}{2} \right)} \right|}{N} * 100\% \quad (10)$$

em que: a_k é a o preço real, e y_k é a previsão obtida pela rede MLP.

5. Aplicações e Resultados

Nesta seção apresentam-se os resultados obtidos com a rede MLP para previsão de preços do MIBEL.

O conjunto de teste, ao qual são atribuídos estes resultados são referentes ao período compreendido entre o dia 1 de março de 2014 e o dia 30 de abril de 2014. Neste

período vale destacar a existência de três feriados: 18 e 20 de abril (Páscoa) e 25 de abril (Dia da Liberdade em Portugal), sendo uma 6ª feira, domingo e 6ª feira, respectivamente.

5.1 Resultados Obtidos para Dias Úteis e Final de Semana

Na sequência são apresentados os resultados da previsão da rede MLP para os dias úteis e finais de semana. De forma ilustrativa, foram escolhidos alguns dos melhores resultados para serem apresentados e os resultados globais serão apresentados nos tópicos a seguir. Os dias escolhidos foram: Domingo, 16 de março de 2014; 2ª Feira, 21 de abril de 2014; 3ª Feira, 18 de março de 2014.

As Figuras 2, 3 e 4 ilustram a curva de previsão em relação ao valor real do preço da energia ao longo das 24 horas do referido dia. O valor do MAPE para os dias apresentados foi de 4,27%, 3,81% e 3,47%, respectivamente.

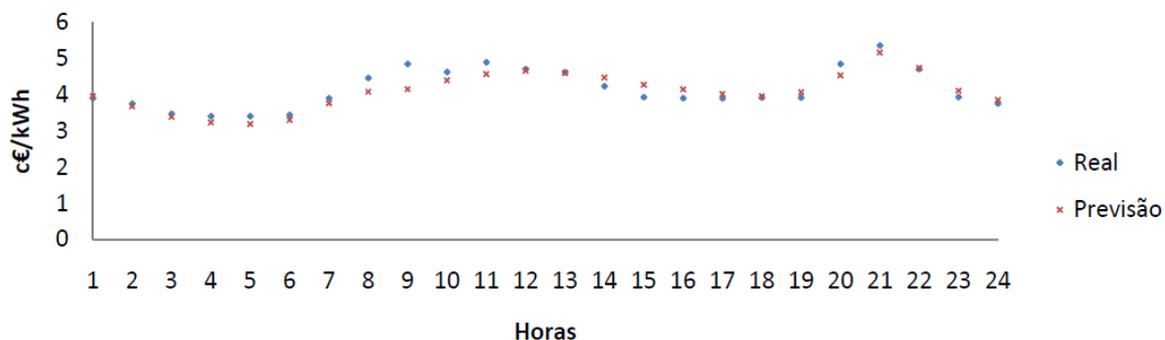


Figura 2. Curva de Previsão para as 24 horas do dia 16 de março de 2014.

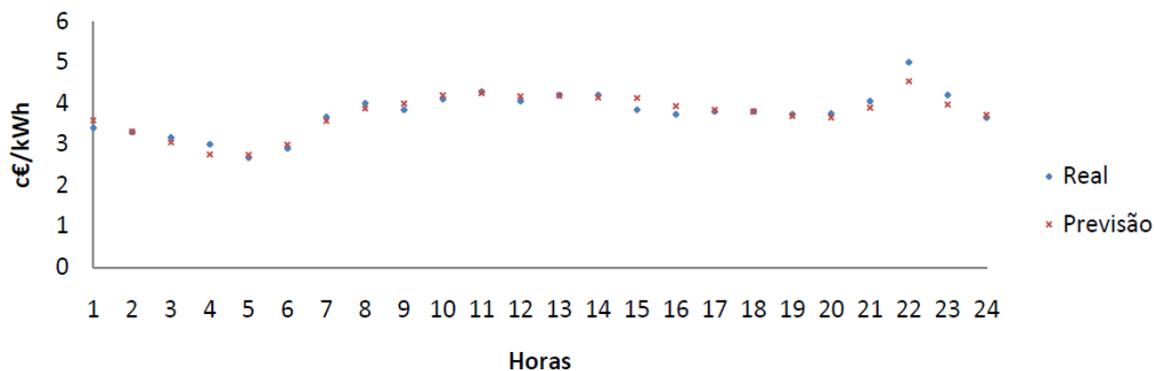


Figura 3. Curva de Previsão para as 24 horas do dia 21 de abril de 2014.

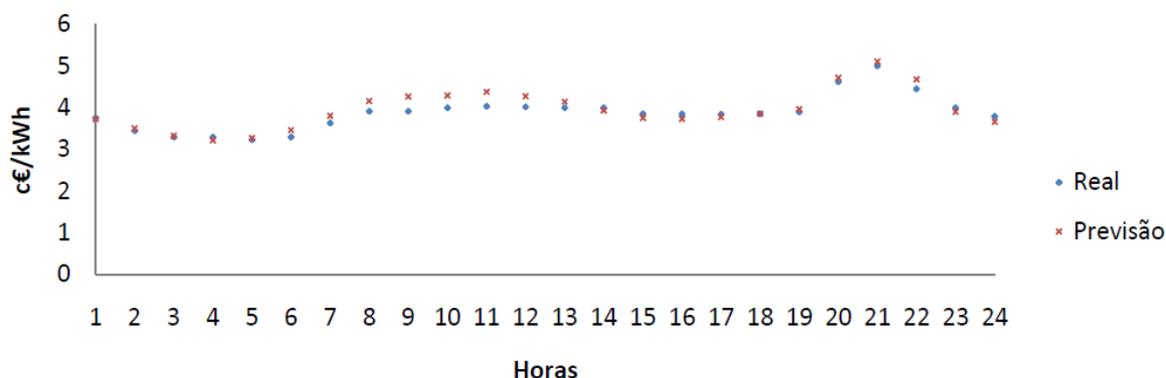


Figura 4. Curva de Previsão para as 24 horas do dia 18 de março de 2014.

5.2 Resultados Obtidos para Feriados

Na sequência apresenta-se de forma ilustrativa o resultado de uma previsão para um feriado. O dia escolhido foi: 6º Feira, 25 de abril de 2014. A Figura 5 ilustra a curva de previsão em relação ao valor real do preço da energia ao longo das 24 horas do referido dia. O valor do MAPE para o dia foi de 5,23%.

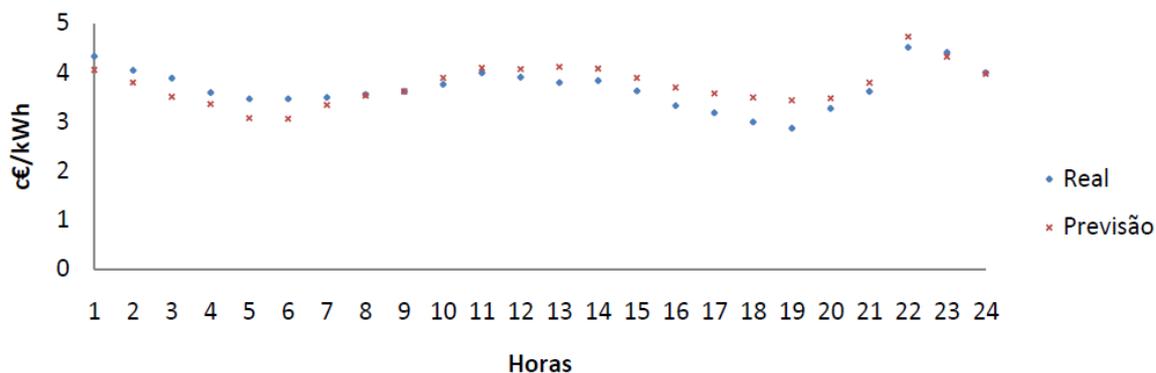


Figura 5. Curva de Previsão para as 24 horas do dia 25 de abril de 2014.

5.3 Resultados Globais

Em termos globais, o valor médio do MAPE para a rede MLP obtido, foi de 8,40%.

Este estudo analisa num período de dados com um contexto económico mundial conturbado, que originou uma elevada diminuição do preço de energia eléctrica. Esta diminuição originou consequentemente uma alteração no diagrama de cargas habitual. Estes acontecimentos influenciam a previsão da rede MLP, no entanto, os resultados são considerados satisfatórios para um sistema de previsão com tamanha complexidade.

Na Tabela 1 a seguir, apresentam-se os valores médios de MAPE para cada dia previsto.

Tabela 1. Valores médios do MAPE por dia.

Dia	Março		Abril	
	1	Sab	5,94%	Ter
2	Dom	8,48%	Qua	6,92%
3	Seg	5,16%	Qui	8,30%
4	Ter	13,08%	Sex	6,27%
5	Qua	32,20%	Sab	4,55%
6	Qui	7,16%	Dom	5,59%
7	Sex	11,44%	Seg	8,88%
8	Sab	8,14%	Ter	12,23%
9	Dom	7,19%	Qua	11,53%
10	Seg	8,44%	Qui	11,89%
11	Ter	7,75%	Sex	12,86%
12	Qua	3,94%	Sab	13,96%
13	Qui	6,24%	Dom	4,66%
14	Sex	12,00%	Seg	10,45%
15	Sab	4,32%	Ter	8,74%
16	Dom	4,27%	Qua	8,18%
17	Seg	3,97%	Qui	5,42%
18	Ter	3,47%	Sex	14,55%
19	Qua	5,32%	Sab	9,07%
20	Qui	5,84%	Dom	7,96%
21	Sex	8,42%	Seg	3,82%
22	Sab	16,50%	Ter	7,23%
23	Dom	6,63%	Qua	9,04%
24	Seg	9,07%	Qui	11,57%
25	Ter	4,88%	Sex	5,24%
26	Qua	9,53%	Sab	7,71%
27	Qui	7,44%	Dom	8,46%
28	Sex	7,03%	Seg	9,29%
29	Sab	13,74%	Ter	8,85%
30	Dom	6,78%	Qua	4,47%
31	Seg	6,21%		

A Tabela 2 ilustra os valores médios do MAPE por hora durante os meses de março e abril.

Foi analisado o MAPE médio por hora, de forma a verificar se a rede MLP prevê corretamente o preço de energia elétrica, ou se mostrou dificuldades em algum período horário. Conforme observa-se na Tabela 2 pode-se afirmar a capacidade que a rede MPL tem para se adaptar a diferentes períodos, destacando-se o período da noite.

Tabela 2. Valores médios do MAPE por hora.

Hora	1h	2h	3h	4h	5h	6h	7h	8h
MAPE	7,46%	7,86%	8,61%	12,79%	13,14%	11,09%	7,05%	8,94%
Hora	9h	10h	11h	12h	13h	14h	15h	16h
MAPE	10,20%	8,76%	8,79%	8,12%	7,39%	7,16%	6,93%	7,12%
Hora	17h	18h	19h	20h	21h	22h	23h	24h
MAPE	7,82%	8,62%	6,79%	6,87%	8,56%	8,22%	6,65%	6,50%

6. Conclusões

Neste artigo foi apresentada uma abordagem inteligente para previsão dos preços de energia elétrica no MIBEL, baseada na rede neural MLP com backpropagation. Neste contexto o sistema de previsão proposto apresentou resultados satisfatórios, obtendo um índice MAPE global de 8,40% para o período de dias previsto. Vale destacar, que no MIBEL, o preço da energia elétrica é fortemente depende de diversos fatores, como a carga, o mix de produção (energias renováveis e não-renováveis), a importação de energia e exportação entre Portugal e Espanha, as condições meteorológicas, entre outros fatores, o que torna o processo de previsão bastante complexo. Assim, através da aplicação da rede neural MLP, pode-se concluir que um sistema inteligente é capaz de se adaptar a diversas situações, apreender e estar apto a realizar uma boa previsão de preços para este mercado de energia tão complexo. Por fim, conclui-se que a metodologia proposta é bastante eficiente e robusta, apresentando diversas vantagens, em relação a outros métodos de previsão.

Referências Bibliográficas

- BOTTERUD, A.; ZHOU, Z.; WANG, J.; SUMAILI, J.; KEKO, H.; MENDES, J.; BESSA, R.J.; MIRANDA, V. Demand response and probabilistic wind power forecasting in electricity markets: a case study of Illinois, **IEEE Transactions on Sustainable Energy**, v. 4, n. 1, p. 250-261, 2013.
- BOX, G. E.; JENKINS, G. M. **Time series analysis: Forecasting and control**. Holden-Day, San Francisco, 1976.
- CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLD, J. H.; ROSEN, D. B. Fuzzy ARTMAP: A neural network for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Network**, v. 3, n. 5, p. 689-713, 1992.

- CHAABENE, M. Measurements Based Dynamic Climate Observer, **Solar Energy**, v. 82, n. 9, p. 763-771, 2008.
- DOMÍNGUEZ, E. F.; BERNAT, J. X. Restructuring and generation of electrical energy in the Iberian Peninsula. **Energy Policy**, v. 35, n. 10, p. 5117-5129, 2007.
- DONGLI, J.; MENG, X.; SONG, X. Study on technology system of self-healing control in smart distribution grid. In: International Conference on Advanced Power System Automation and Protection, 2011, Beijing. Proceedings... Beijing: IEEE, 2011. p. 26-30. 1-5.
- FIDALGO, J. N.; LOPES, J. A. P. Load Forecasting Performance Enhancement When Facing Anomalous Events, **IEEE Transactions on Power Systems**, v. 20, n. 1, p. 408-415, 2005.
- GROSS, G.; GALIANA, F. D. Short-Term load forecasting, **IEEE Transactions on Power Systems**, v. 75, n. 12, p. 1558-1573, 1987.
- HAYKIN, S. H. **Neural Networks: A comprehensive foundation**, MacMillan College Publishing, New York, 1994.
- MATLAB 7.8 version. Math Works Company, 2011.
- MCDONALD, J. D. **Electric Power Substations Engineering**, New York: CRC Press, 2003.
- O'DONOVAN, T. M. **Short Term Forecasting: An Introduction to the Box-Jenkins Approach**, John Wiley & Sons, New York, 1983.
- PINO, R. Forecasting next-day price of electricity in the Spanish energy market using artificial neural networks. **Engineering Applications of Artificial Intelligence**, v. 21, n. 1, p. 53-62, 2008.
- SARAIVA, J. P. T.; SILVA, J. L. P. P.; LEÃO, M. T. P. **Mercados de electricidade regulação e tarifação de uso das redes**. Coleção Manuais 6. 2002, Porto: FEUP Edições. 293.
- VENTOSA, M. Electricity market modeling trends. **Energy Policy**, v. 33, n. 7, p. 897-913, 2005.
- WERBOS, P. J. **Beyond regression: New tools for prediction and analysis in the behavioral sciences**, PhD. Thesis, Harvard University, 1974.