
Precificação do etanol utilizando técnicas de redes neurais artificiais

Vinicius Amorim Sobreiro
Pedro Henrique de Sousa Leão Araújo
Marcelo Seido Nagano

RESUMO

O interesse por previsão de valores conduziu a realização de várias pesquisas, na área financeira e de negócios, nos últimos anos, mas poucas foram feitas com o propósito de estimar os valores dos combustíveis. Essa lacuna se torna mais notável quando se observa o Etanol Combustível no Brasil. Nesse sentido, o objetivo neste artigo é comparar o desempenho das redes neurais artificiais (RNAs), usando a arquitetura Perceptron multicamadas, com o do método ARIMA para previsão do preço do Etanol Combustível. Tal possibilidade permite fazer previsões dos preços futuros desse produto que é comercializado e consumido no mundo inteiro. O método adotado para realizar tal comparação foi o das medidas de erro agregado em previsões. Como resultado, observou-se que a aplicação das RNAs obteve uma aproximação mais satisfatória quando comparada à aplicação do método ARIMA quanto aos dados reais, o que em conclusão evidencia a importância das RNAs na previsão dos preços do Etanol Combustível.

Palavras-chave: previsão, etanol, redes neurais artificiais, ARIMA, Brasil.

1. INTRODUÇÃO

Os agrocombustíveis e o aquecimento global vêm ocupando um lugar de relevância na mídia, na política e nas mais diversas áreas de pesquisa no Brasil. De certo modo, a necessidade de reduzir as emissões dos gases de efeito estufa, como o dióxido de carbono (CO₂), responsáveis pelo aquecimento global não é um problema novo. Contudo, essa questão torna-se mais intensa não apenas por seus prováveis impactos sobre o meio ambiente, mas também pela possibilidade de esgotamento das reservas mundiais de petróleo.

Em geral, a referência mais frequente acerca da emissão de gases de efeito estufa é a queima de combustíveis fósseis, cujo maior responsável é o setor de transporte ou, mais precisamente, o transporte privado individual. Esse fato resulta dos 800 milhões de automóveis existentes no mundo, que consomem mais de 50% das fontes de energia produzidas no mundo inteiro. Para alguns

Recebido em 15/janeiro/2008
Aprovado em 05/dezembro/2008

Sistema de Avaliação: *Double Blind Review*
Editor Científico: Nicolau Reinhard

Vinicius Amorim Sobreiro, Graduado em Economia, Especialização em Engenharia de Produção com ênfase em Pesquisa Operacional pela Universidade Estadual de Londrina, Mestre em Engenharia de Produção Mecânica pela Escola de Engenharia de São Carlos da Universidade de São Paulo, é Doutorando em Engenharia de Produção na Escola de Engenharia de São Carlos da Universidade de São Paulo (CEP 13566-590 — São Carlos/SP, Brasil). E-mail: sobreirovinicius@gmail.com
Endereço:
Universidade de São Paulo
Escola de Engenharia de São Carlos
Departamento de Engenharia de Produção Mecânica
Avenida Trabalhador São-carlense, 400
13566-590 — São Carlos — SP

Pedro Henrique de Sousa Leão Araújo, Graduado em Engenharia de Produção e Mestre em Engenharia de Produção pela Escola de Engenharia de São Carlos da Universidade de São Paulo (CEP 13566-590 — São Carlos/SP, Brasil), é Consultor da Ernst & Young.
E-mail: pedrocaadr@hotmail.com

Marcelo Seido Nagano, Doutor na área de Pesquisa Operacional, Pós-Doutor em Matemática Aplicada e Computacional pelo Instituto Nacional de Pesquisas Espaciais, é Professor do Departamento de Engenharia de Produção e do Programa de Pós-Graduação em Engenharia de Produção da Escola de Engenharia de São Carlos da Universidade de São Paulo (CEP 13566-590 — São Carlos/SP, Brasil).
E-mail: drnagano@usp.br

pesquisadores, como Bravo (2007), já se começa a identificar como consenso a idéia do pico do petróleo de Hubbert, isto é, por volta de 2005 a 2025 vai se gastar mais energia para extrair um barril de petróleo do que a energia líquida e transportável que ele disponibiliza. Ampliando essa questão, do ponto de vista energético surge a necessidade de uma alternativa ao petróleo, que forneça insumo aos diversos setores da economia.

A partir dessas constatações, desponta uma nova frente do agronegócio, ou seja, surge entre os agrocombustíveis o etanol como o ator principal desse drama energético. No Brasil, o etanol é um agrocombustível derivado da cana-de-açúcar que apresenta a maior representatividade quando observados o seu volume de produção e a coordenação de sua cadeia produtiva.

Os dados sobre o mercado do etanol, especialmente sobre o preço, são vitais para o desenvolvimento de projetos na área da agricultura, principalmente para a produção da cana-de-açúcar, pois podem influenciar a oferta e a demanda nos canais de distribuição e os aspectos econômicos da agricultura brasileira. Consequentemente, as previsões dos preços podem fornecer uma redução das incertezas dentro do mercado de etanol, auxiliar na determinação da quantidade a ser produzida e no estabelecimento de políticas governamentais apropriadas e sustentáveis.

A previsão de séries temporais, como o preço de uma *commodity*, é parte importante dentro da área de previsão. Tal importância está assentada na capacidade de estimar, mediante dados de algumas variáveis, como por exemplo o preço do período anterior e o erro aleatório, um modelo que explique o comportamento desse conjunto de observações. Atualmente, o método mais utilizado e conhecido é o Autorregressivo Integrado de Médias Móveis (ARIMA), de Box e Jenkins.

Não obstante, as Redes Neurais Artificiais (RNAs) também são motivo de muito interesse nas atividades de pesquisa nas últimas décadas visto seu desempenho sobre a capacidade de previsão. A principal vantagem das RNAs consiste em sua utilização em dados ou observações que necessitem da aquisição de conhecimento nelas contido, visando à compreensão do fenômeno observado. Porém, segundo Zhang, Patuwo e Hu (1998), alguns pesquisadores depararam-se com muitas promessas e incertezas, pois muitos não compreendem os fatores-chave do desempenho das RNAs. Ainda dentro desse enfoque, o algoritmo de aprendizagem mais utilizado para realizar previsões é o *backpropagation*. Em termos amplos, ele pode ser compreendido como um algoritmo que, por meio dos dados de entrada, pondera todos os pesos das RNAs a fim de apresentar os melhores dados de saídas.

Nesse sentido, quando se observa a literatura a respeito de previsão de séries temporais, é possível notar vários estudos que comparam RNAs e métodos estatísticos como o ARIMA, como os de Church e Curram (1996), Kohzadi *et al.* (1996), Cao, Leggio e Schniederjans (2005), Kumar (2005), Co e Boosarawongse (2007), Wang e Elhag (2007), Pino *et al.*

(2008), que indicam como resultado vantagens do primeiro sobre o segundo método. Contudo, segundo Zou *et al.* (2007), essas qualidades ou vantagens dependem do objeto de observação e seus dados, pois, para Luxhoj, Riis e Stensballe (1996) e Zhang (2003), o melhor modelo resultaria da combinação de RNAs e ARIMA. No escopo das RNAs, vários pesquisadores têm proposto a combinação com outros métodos. Tsaih, Hsu e Lai (1998) e Pai e Lin (2005) propõem, mediante a combinação de RNAs com técnicas baseadas em regras de sistemas, a previsão dos índices futuros da S&P 500.

Dentro desse contexto, o principal objetivo neste artigo é comparar a previsão do preço do Etanol mediante RNAs e o método ARIMA. Assim, a precisão alcançada pelos modelos será a mais importante medida de desempenho. Os métodos quantitativos mais utilizados para a realização dessa avaliação, conforme Zhang, Patuwo e Hu (1998), são a Soma Quadrada dos Erros (SSE), a Média das Diferenças Absoluta (MAD), o Erro Quadrático Médio (MSE), o Percentual de Erro Absoluto Médio (MAPE) e a Raiz do Erro Quadrático Médio (RMSE).

A precificação do etanol utilizando técnicas de RNAs é um tema ainda pouco debatido empírica e teoricamente. Consequentemente, esse fato ressalta a importância deste trabalho, pois ele acrescenta evidências nas utilizações das RNAs e do ARIMA mediante uma aplicação detalhada e bem-sucedida de previsão de preços de *commodities*.

Este artigo está estruturado como segue: na segunda seção apresentam-se os principais conceitos sobre o etanol, ARIMA e RNAs por meio de uma revisão de literatura; na terceira, apresentam-se os dados e demonstram-se os critérios utilizados na avaliação da previsão; na quarta são expostos os procedimentos para a seleção dos modelos; na quinta são demonstrados os resultados obtidos; e, finalmente, na sexta seção, apresentam-se as discussões e conclusões.

2. REVISÃO DA LITERATURA

2.1. O uso do etanol no Brasil

De maneira geral, a utilização do etanol como aditivo à gasolina remonta à década de 1920. Produzido a partir da cana-de-açúcar a partir de 1931 ele passou a ser oficialmente adicionado à gasolina, que era importada. No entanto, apenas em 1975 o governo brasileiro fomentou as condições, por meio do Programa Nacional do Álcool (Proálcool), para o setor sucroalcooleiro brasileiro tornar-se, três décadas mais tarde, um dos mais modernos do mundo. Nesse contexto, a utilização do etanol ou do álcool etílico hidratado combustível, em substituição à gasolina, resultou em uma economia de aproximadamente um bilhão de barris de petróleo no Brasil nos últimos 30 anos. Esse montante corresponde a 22 meses da produção atual de petróleo do Brasil ou, em valores monetários, por exemplo, a economia realizada nos últimos oito anos resultou em US\$ 61 bilhões.

Em termos amplos, o Proálcool tinha como objetivos principais a introdução no mercado da mistura gasolina-álcool etílico anidro combustível e, em especial, o incentivo ao desenvolvimento de veículos movidos a etanol. Abordando esse projeto em termos cronológicos, é possível separá-lo, resumidamente, em quatro fases distintas quanto à produção e à utilização em larga escala do etanol no Brasil.

- **Primeira fase (1975 a 1979)** — o governo brasileiro sofreu com a primeira crise do petróleo, ocorrida em 1973, e, além disso, houve a queda do preço do açúcar no mercado internacional. Conseqüentemente, decidiu aumentar os incentivos para a produção de etanol, evitando a ociosidade do parque industrial sucroalcooleiro e a dependência nacional dos combustíveis fósseis.
- **Segunda fase (1979 a 1989)** — iniciada devido à segunda crise do petróleo, em 1979. A principal característica desse período foi o estabelecimento de uma série de incentivos públicos fiscais e financeiros que envolveram desde os produtores do etanol até os consumidores finais.
- **Terceira fase (1989 a 2000)** — essa fase foi marcada pela desistência do governo em auxiliar o Programa por meio de incentivos públicos fiscais e financeiros. O governo brasileiro, diante da redução dos preços do petróleo no mercado internacional, de certa forma transferiu para a iniciativa privada as decisões quanto ao planejamento e à execução das atividades de produção.
- **Quarta fase (2000 até os dias atuais)** — fase em que ocorreu a revitalização do etanol por causa da liberação dos preços em nível setorial e da introdução dos veículos *flex-fuel*, em 2003, que utilizam qualquer mistura de etanol com gasolina. Além disso, vem ocorrendo elevação nas exportações devido ao aumento do preço do petróleo no mercado mundial, o que força o setor sucroalcooleiro a depender do mercado externo.

Cabe ressaltar que os impactos do etanol combustível ultrapassam os aspectos econômicos ou geográficos e atingem os sociais, pois a área cultivada com cana-de-açúcar ocupa 0,60% do território brasileiro e necessita de um milhão de

pessoas como mão-de-obra em empregos diretos e de seis milhões para suprir os empregos indiretos. Além disso, quanto aos aspectos ambientais, os ganhos com a utilização do etanol resultam em redução da emissão de gases de efeito estufa, principalmente do gás carbônico (CO₂), e na realização dos compromissos assumidos mediante o Protocolo de Quioto sobre os problemas climáticos. No período de 1970 a 2005, a utilização do etanol combustível no Brasil evitou a emissão de 644 milhões de toneladas de CO₂ na atmosfera.

2.2. Método ARIMA

Como bem salientam Ediger e Akar (2007), o modelo ARIMA é resultante dos modelos autorregressivos (AR) e médias móveis (MA), que surgiram na literatura em, respectivamente, 1926 e 1937. Em 1970, Box e Jenkins apresentaram o método ARIMA, para a análise de séries temporais, no livro *Time Series Analysis, Forecasting and Control*. No modelo ARIMA são identificados os processos subjacentes que mostram o mecanismo do processo gerador visando sempre à precisão quanto aos dados (BOX e JENKINS, 1994).

A partir de sua publicação, o método tornou-se uma das abordagens mais populares para a previsão de valor e continua sendo utilizado atualmente para tal. Em termos amplos, esse método supõe que os valores futuros de uma variável possam ser combinações lineares de seus valores e erros passados (ZOU *et al.*, 2007), contrariando os modelos de regressão em que uma variável é explicada a partir de seus regressores. Além disso, como destaca Junttila (2001), o grande mérito do ARIMA foi reunir as técnicas existentes até então na literatura para construir modelos que descrevessem com precisão e de forma parcimoniosa o processo gerador da série temporal, proporcionando dessa forma previsões acuradas quanto aos valores futuros.

Esse modelo é eficientemente utilizado para previsão de variáveis econômicas, mercadológicas e sociais. Entretanto, sua utilização fica restrita à quantidade de dados, ou seja, ele requer no mínimo 50 e preferencialmente 100 ou mais observações (TSENG e TZENG, 2002). No quadro 1 são apresentadas algumas pesquisas que utilizaram o modelo ARIMA com o propósito de realizar previsão.

Quadro 1

Exemplos de Pesquisas que Utilizaram o ARIMA

| Ano | Pesquisadores | Objeto de Estudo |
|------|-----------------------|---|
| 1998 | Ho e Xie | Previsão de falhas em sistemas mecânicos. |
| 2001 | Junttila | Previsão da taxa de inflação futura na Finlândia. |
| 2001 | Tseng <i>et al.</i> | Previsão da taxa de câmbio entre a moeda norte-americana e a de Taiwan. |
| 2002 | Tseng e Tzeng | Previsão da produção de máquinas e bebidas fortes em Taiwan. |
| 2007 | Ediger, Akar e Urgulu | Previsão das quantidades produzidas de combustível fóssil. |
| 2007 | Erdogdu | Previsão da demanda de eletricidade na Turquia. |
| 2007 | Zou <i>et al.</i> | Previsão do preço do trigo na China. |

Segundo Zou *et al.* (2007), geralmente as séries temporais, ou seja, conjunto de observações dos valores que uma variável assume em diferentes momentos do tempo, podem ser expressas mediante o ARIMA utilizando a equação [1]:

$$X_t = \theta_0 + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad [1]$$

em que:

X_t é o valor atual no instante t ;

e_t é o erro aleatório no instante t ;

ϕ_i ($i = 1, 2, \dots, p$) e θ_i ($i = 1, 2, \dots, q$) são os parâmetros do modelo.

Ademais, p denota o número de termos autorregressivos e q representa o número de termos de média móvel.

Esse modelo é autorregressivo porque permite estimar a série temporal a partir de seus valores passados. Para a utilização do método ARIMA, há a necessidade de a série temporal apresentar a condição de estacionariedade, ou seja, os dados da série temporal precisam apresentar as seguintes características: média constante e variância constante. Contudo, nem sempre a série temporal é estacionária, existindo, portanto, a necessidade de realização de um processo de diferenciação a fim de obter-se uma série estacionária. Em geral, esse processo de diferenciação é representado pela variável d , e assim a representação do método ARIMA pode ser (p, d, q) .

É válido destacar que o ARIMA é um dos modelos da metodologia Box e Jenkins; existem também outros modelos, como o autorregressivo (AR), o de média móvel (MA) e o autorregressivo de médias móveis (ARMA). A identificação do modelo mais apropriado à série temporal é realizada por meio de funções de autocorrelação (FAC) e correlação parcial (FACP). Conseqüentemente, de maneira genérica, o modelo ARIMA pode ser aplicado em três fases: identificação do modelo, ou seja, verificação da aplicação do modelo; estimação dos parâmetros da equação [1]; e verificação de seu desempenho por meio das medidas de erro agregado.

O principal problema do modelo ARIMA é sua caracterização como um modelo matemático teoricamente sofisticado, que requer profundo conhecimento de amplas técnicas para sua utilização. Dessa forma, a aplicação do modelo ARIMA oferece alguma dificuldade aos usuários, visto que requer treinamento em análise estatística e um *software* específico (MÉLARD e PASTEELS, 2000).

2.3. Redes Neurais Artificiais — RNAs

A partir da década de 1990, a utilização de RNAs vem ganhando muita notoriedade por não requerer pré-especificações ou estabelecimento de hipóteses e suposições sobre a distribuição estatística ou propriedades dos dados e por apresentar a capacidade de aprendizado sobre o relacionamento das variáveis (STEINER e WITTKEMPER, 1996; DECO,

NEUNEIER e SCHÜRMAN, 1997; ORMONEIT, 1999; THAWORNWOG e ENKE, 2004; TERÄSVIRTA, DIJK e MEDEIROS, 2005; HUANG e YU, 2006; MALIK e NASEREDDIN, 2006; HASSAN, NATH e KIRLEY, 2007).

As RNAs consistem numa área de pesquisa relativamente recente, mas de importância crescente no grupo do conhecimento que envolve o campo da inteligência artificial. Para Zhang, Patuwo e Hu (1998), a aplicação de RNAs para previsão ocorreu em 1968 com o trabalho de Hu, que fazia previsões sobre o clima. Apenas por volta de 1990 é que começam a surgir as primeiras aplicações de RNAs no ambiente financeiro nos Estados Unidos. Atualmente, no Brasil, são poucas as pesquisas que contemplam RNAs para estimação de preços e, dentre elas, destaca-se a utilização das RNAs para previsão de séries temporais (DINIZ *et al.*, 1998) e para previsão do valor das *commodities* no agronegócio (FREIMAN e PAMPLONA, 2005).

As RNAs consistem numa área de pesquisa relativamente recente, mas de importância crescente no grupo do conhecimento que envolve o campo da inteligência artificial.

Ademais, as RNAs são compreendidas como métodos que aprendem com um exemplo por meio de funções de aproximação universal (HORNIK, STINCHCOMBRE e WHITE, 1989), ou seja, uma classe de modelos não lineares que permite identificar padrões em dados (PAO, 2007). Ainda nessa linha, as RNAs buscam imitar um sistema biológico como o cérebro humano, visto que ambos compreendem grande número de interconexões das unidades de processamentos não lineares chamadas de neurônios, que apresentam como principal função o armazenamento e a disponibilidade de informação (SCHÖNEBURG, 1990; WIDROW, RUMELHART e LEHR, 1994; FREIMAN e PAMPLONA, 2005; RAZI e ATHAPPILLY, 2005; BIALOSKORSKI NETO, NAGANO e MORAES, 2006).

Nessa perspectiva, as RNAs demonstram características semelhantes às do comportamento humano, como: aprender por experiência (RED'KO, MOSALOV e PROKHOROV, 2005); associar diferentes padrões (ZHANG, PATUWO e HU, 1998); realizar generalizações a novas entradas ou *inputs* com bases em padrões anteriores (CHAKRABORTY *et al.*, 1992).

A sistematização das RNAs é realizada conforme o padrão de conexão entre várias camadas das redes, os números de neurônios em cada camada, a capacidade da aprendizagem e as funções de ativação, ou seja, uma rede neural é um conjunto de entrelaçamentos, no qual cada conexão apresenta um peso associado a fim de ajustar os *inputs* de entradas aos *outputs* referentes à saída. Adicionalmente, é válido salientar que a camada localizada entre a camada de entrada e a de saída recebe a denominação de camada escondida, conforme demonstrado na figura 1.

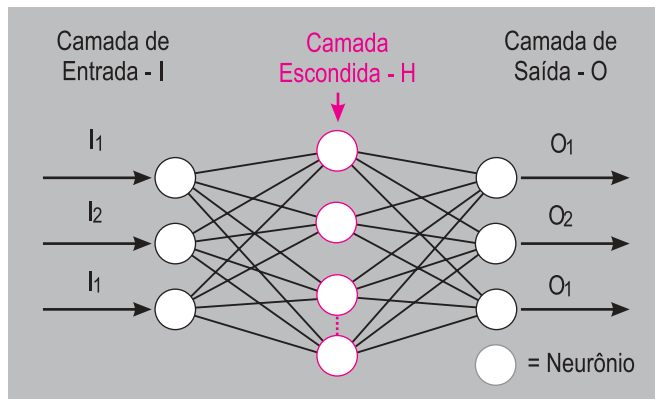


Figura 1: As Três Camadas de Uma RNA

Fonte: Adaptada de Wang e Elhag (2007).

Segundo Tsang *et al.* (2007) e Wang e Elhag (2007), geralmente as arquiteturas de RNAs apresentam de uma a duas camadas escondidas para solucionar a maioria dos problemas. O número de neurônios das camadas escondidas é obtido pela equação [2].

$$K = \frac{P}{5 \times (N + M)} \quad [2]$$

em que:

K é o número de neurônios nas camadas escondidas;

P é a quantidade de dados para treinamento;

N é a quantidade de entrada;

M é a quantidade de saída.

Para o funcionamento das RNAs, cada neurônio da camada escondida deve receber um sinal de ativação que corresponde à soma ponderada dos dados da camada de entrada ou de outra camada, e processar pela função de ativação, fornecendo à próxima camada um novo sinal de ativação. A ponderação dos sinais de ativação pode ser realizada por meio da equação [3].

$$X_j = \sum_i I_i W_{ij} \quad [3]$$

em que:

X_j é o valor do neurônio j da camada escondida ou de entrada;

I_i é a informação resultante do neurônio da camada de entrada ou escondida i ;

W_{ij} é o peso entre a camada de entrada ou escondida i e o neurônio j .

Entre as várias funções de ativação existentes, a mais utilizada é a função sigmoide, cuja forma generalizada é apresentada pela equação [4].

$$f(X_j) = \frac{1}{1 + e^{-x_j}} \quad [4]$$

em que:

$f(X_j)$ é a função de ativação;

e é o número neperiano;

x_j é o valor do neurônio j na camada escondida ou de entrada.

A função de ativação sigmoide representada na equação [4] deve respeitar a seguinte propriedade:

$$\frac{df}{dX_j} = f(X_j)[1 - f(X_j)],$$

ou seja, seus resultados devem estar dentro do intervalo de zero e um. O neurônio da camada de saída recebe o sinal, demonstrado na equação [5], da camada escondida.

$$Y_k = \sum_i h_j W_{jk} \quad [5]$$

em que:

Y_k é o valor do neurônio k da camada de saída;

h_j é a informação resultante do neurônio da camada escondida j ;

W_{jk} representa o peso entre a camada escondida e a camada de saída.

Todos esses sinais representados por meio da equação [5] são convertidos pela função de ativação, ou seja,

$$f(Y_k) = \frac{1}{1 + e^{-Y_k}},$$

visando à obtenção dos valores de saída. A função de erro para os neurônios de saída é definida conforme apresentada na equação [6].

$$E(W) = \frac{1}{2} \sum_k (d_k - o_k)^2 \quad [6]$$

em que:

$E(W)$ representa a função de erro;

d_k é o valor desejado para a camada de saída k ;

o_k representa o valor obtido na camada de saída k .

A função de erro deverá ser minimizada para que as RNAs obtenham o melhor desempenho possível. Nesse sentido, faz-se necessário destacar que existem três tipos de aprendizagem em RNAs:

- **supervisionada** — na qual é apresentado o conjunto de dados de entrada e saída para que as RNAs façam os ajustes necessários nos pesos a fim de que se obtenha o menor erro possível;
- **não supervisionada** — nesse tipo, a rede recebe os dados a fim de estabelecer o reconhecimento de padrões ou classes;
- **híbrida** — classificação que resulta da mistura dos tipos supervisionada e não supervisionada, ou seja, existem camadas distintas trabalhando com tipos de aprendizagem diferentes.

Consequentemente, vários algoritmos têm sido desenvolvidos para minimizar o valor obtido pela função de erro. Con-

forme constatado na literatura especializada, o algoritmo *back-propagation*, pertencente à classe de técnicas de aprendizagem supervisionada, é o mais utilizado nas aplicações de previsão. Esse algoritmo é compreendido como a realização de dois procedimentos:

- *forward* — as RNAs são apresentadas aos dados de entradas, que se propagam camada por camada, mas nenhum peso das RNAs é alterado;
- *backward* — no qual os pesos são ajustados conforme a função de erro, ou seja, os resultados obtidos são subtraídos dos desejados, visando produzir os erros; assim, os pesos das RNAs são atualizados para que a resposta obtida se aproxime o máximo possível da desejada. Esse processo é repetido várias vezes com o propósito de alcançar-se o menor erro possível.

Zhang, Patuwo e Hu (1998) e Pao (2007) salientam que entre as arquiteturas mais utilizadas destacam-se a de regressão, a probabilística e a *perceptron* multicamadas. Assim, na figura 2 são apresentadas as representações generalizadas dessas três tipologias.

...entre as arquiteturas mais utilizadas destacam-se a de regressão, a probabilística e a perceptron multicamadas.

A arquitetura caracterizada como regressão é, normalmente, utilizada para estimar valores para variáveis como posições futuras, valores futuros e interpolação multivariada. A arquitetura probabilística é utilizada para auxiliar na estimação de limites entre categorias ou padrão de dados; por essa razão, é usada na classificação de problemas. Por outro lado, destaca-se na literatura a arquitetura denominada *Perceptron* Multicamada, por ser simples e, conseqüentemente, a mais utilizada (KUCUK, 2006).

Considerando essas arquiteturas, vários trabalhos, como o de Hassan, Nath e Kirley (2007), propõem a utilização de modelos híbridos, ou seja, a combinação das RNAs com outros modelos, como Hidden Markov, ou com algoritmos genéticos (SMITH e GUPTA, 2000; HASSAN e NATH, 2005; XUEFENG *et al.*, 2006; HASSAN, NATH e KIRLEY, 2007), a fim de obter melhores resultados. Para Tsaih, Hsu e Lai (1998), as RNAs apresentam os melhores resultados quando são treinadas com vários conjuntos de dados sobre a mesma observação, em vez de serem treinadas apenas com uma base de dados das observações.

A utilização de RNAs no ambiente financeiro para previsão de preços de produtos nos últimos anos vem aumentando (WONG e MONACO, 1995; WONG, BODNOVICH e SELVI, 1997; WONG e SELVI, 1998; WONG, LAI e LAM, 2000). No quadro 2 apresentam-se algumas pesquisas feitas nessa área, a partir de 1990, com o propósito de realizar previsão de preços de mercadorias.

Na próxima seção, apresentam-se as fontes dos dados, as condições e os critérios utilizados para comparar o desempenho entre o modelo ARIMA e as RNAs na previsão dos preços do etanol combustível.

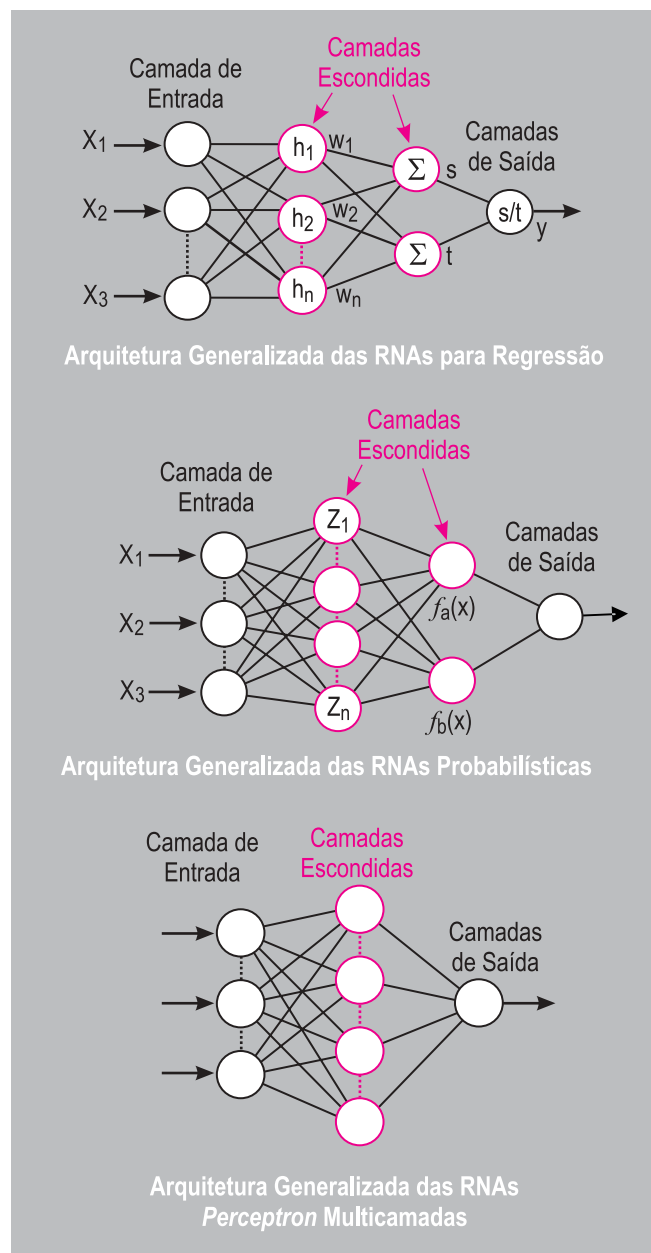


Figura 2: Arquiteturas Generalizadas das RNAs
 Fonte: Adaptada de Thawornwog e Enke (2005).

Quadro 2

Exemplos de Pesquisas Voltadas para a Previsão

| Ano | Pesquisadores | Objeto de Estudo |
|------|------------------------------------|--|
| 1992 | Chakraborty <i>et al.</i> | Estimação do preço da farinha de trigo nas cidades de Buffalo, Minneapolis e Kansas. |
| 1999 | Ornoneit | Cotação dos derivativos no mercado alemão. |
| 2005 | Thawornwog e Enke | Índice S&P 500. |
| 2005 | Teräsvirtaa, Dijk e Medeiros | Índices de preço ao consumidor para países do G7. |
| 2006 | Bodyanskiy e Popov | Volatilidade do índice Dow Jones para o retorno industrial médio. |
| 2006 | Huang e Yu | Cotações no mercado de ações para Taiwan de 1991 a 2003. |
| 2006 | Malik e Nasereddin | Preço da cotação do barril de petróleo. |
| 2007 | Haofei <i>et al.</i> | Estimação dos preços dos produtos alimentícios na China. |
| 2008 | Andreou, Charalombous e Martzoukos | Índice S&P 500. |

3. MÉTODOS — DESCRIÇÃO DOS DADOS E CRITÉRIOS DE AVALIAÇÃO DA PREVISÃO

No tocante à modelagem dos dados, considerando o método Box-Jenkins e observando as principais etapas sugeridas por Gujarati (2006) para sua aplicação, os procedimentos utilizados neste trabalho para identificação do melhor modelo foram: verificação da estacionariedade na série temporal; identificação do modelo, ou seja, a escolha de (p, d, q) ; estimação dos parâmetros do modelo escolhido; verificação da aderência do modelo aos dados considerando os seus resíduos; e previsão dos valores futuros. Assim, convém ressaltar as principais características quanto ao conjunto de dados e aos critérios de avaliação da previsão.

3.1. Conjunto de dados

Os dados dos preços referentes ao litro do etanol combustível utilizados neste artigo são semanais, do período de julho de 2000 até setembro de 2007, isto é, um total de $n = 375$ observações, como ilustrado na gráfico 1.

Os valores foram obtidos no Centro de Estudos Avançados em Economia Aplicada (Cepea), que é parte integrante do Departamento de Economia, Administração e Sociologia da Escola Superior de Agricultura Luiz de Queiroz, unidade da Universidade de São Paulo. O etanol combustível segue os padrões da Agência Nacional de Petróleo. Nesse sentido, a previsão fornecerá os preços futuros do etanol, pois os dados referentes à amostra são os preços semanais desse produto, considerando os períodos anteriores.

3.1.1. Caracterização da série temporal

Com o objetivo de verificar a estacionariedade da série temporal, foi utilizado o teste de raiz unitário, com auxílio da estatística Tau (τ) e dos valores críticos de Dickey-Fuller para os dados de preço do etanol. Como resultado, identificou-se que a série temporal original não era estacionária, ou seja, não

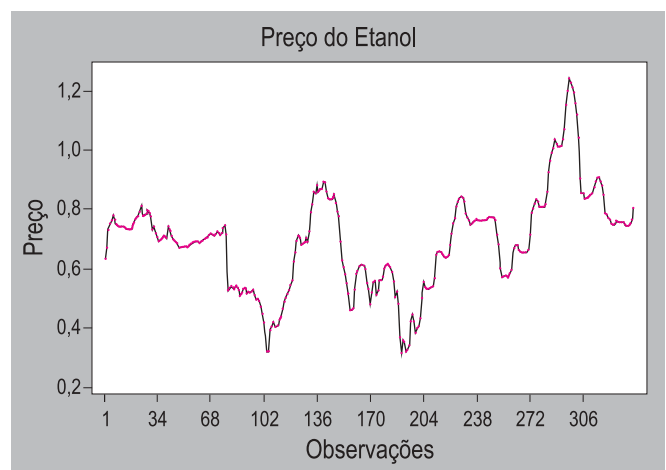


Gráfico 1: Dados de Série Temporal do Etanol Combustível

Fonte: Centro de Estudos Avançados em Economia Aplicada (Cepea).

apresentava média e variância constantes. Assim, conforme indicado por Gujarati (2006), foi empregado o processo de diferenciação a fim de obter-se uma série estacionária. Nesse sentido, conforme demonstrado no gráfico 2, a primeira diferença obtida apresentou-se estacionária visto que o valor obtido para τ foi de 9,65, enquanto, considerando Dickey-Fuller, o valor crítico a 5% de significância é de 2,87 para até 500 observações.

Além disso, visando também à identificação da série estacionária, foi elaborado, conforme apresentado no gráfico 3, o correlograma com o gráfico de autocorrelação para a primeira diferença.

O correlograma com o gráfico de correlação parcial também foi elaborado para a primeira diferença, como consta no gráfico 4.

Nesse contexto, foram utilizados os dados da primeira diferença para modelar os valores referentes ao preço do etanol, ou seja, para estimar o modelo ARIMA que melhor represente tais dados.




Gráfico 2: Primeira Diferença dos Preços do Etanol

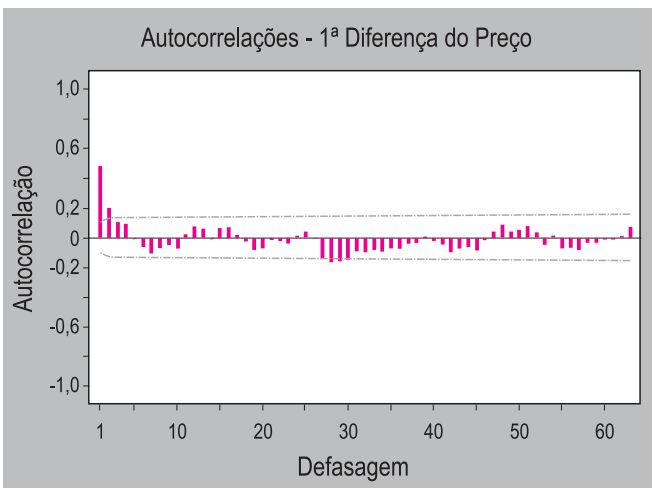


Gráfico 3: Autocorrelação da Primeira Diferença

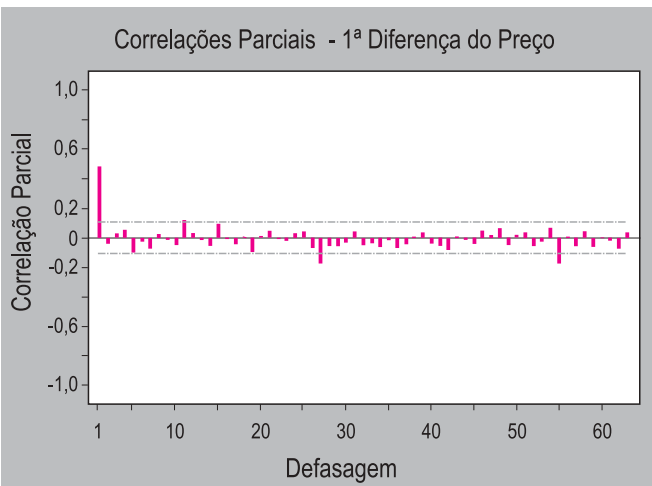


Gráfico 4: Correlação Parcial para a Primeira Diferença

3.1.2. Tamanho do conjunto de dados

Embora na exista, segundo Zou *et al.* (2007), um consenso na literatura sobre como dividir a quantidade de dados entre o treinamento e o teste das RNAs, há conformidade em utilizar o maior número de observações no treinamento. Muitos trabalhos utilizam as seguintes proporções para treinamento e teste: 70:30%, 80:20% ou 90:10%. Neste estudo foi utilizada a proporção de 90:10%, ou seja, 338 foram utilizadas para o treinamento e 37 observações foram utilizadas no teste. Por razões de espaço, os dados originais não estão listados neste artigo, porém podem ser obtidos no *website* <www.cepea.esalq.usp.br>.

3.2. Critérios de avaliação da previsão

Para avaliar e comparar o desempenho da previsão, é necessário apresentar os critérios de avaliação. Neste estudo, a Soma

Quadrada dos Erros, $SSE = \sum (e_t)^2$, a Média das Diferen-

ças Absolutas, $MAD = \frac{\sum |e_t|}{N}$, o Erro Quadrático Médio,

$MSE = \frac{\sum (e_t)^2}{N}$, o Percentual de Erro Absoluto Médio,

$MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| \times 100$, e a Raiz do Erro Quadrático Médio,

$RMSE = \sqrt{\frac{\sum (e_t)^2}{N}}$, são utilizados visando à identificação dos

erros de predição no modelo ARIMA e nas RNAs. Tais medidas procuram identificar a diferença entre os valores reais e os estimados. Para as cinco medidas de desempenho, o t representa o número da observação, o N é número total de observações, o y_t é o valor observado, ou atual, e o e_t é o erro ou a diferença entre o valor obtido e o valor observado (ZHANG, PATUWO e HU, 1998). O modelo com os menores valores para SSE, MSE, MAD, MAPE e RMSE é considerado o melhor quando comparado ao outro.

Além disso, de acordo com Sartoris (2003), visando testar a aderência do modelo ARIMA aos dados, serão aplicados aos resíduos do modelo a função de autocorrelação e o teste de Ljung e Box comparado com a distribuição qui-quadrada.

4. PROCEDIMENTOS DE PREVISÃO

4.1. A seleção do modelo ARIMA

Considerando que a primeira diferença da série temporal é estacionária e utilizando o *software* Minitab 14 da *Statistical Software*, foi possível identificar, mediante o correlograma e os padrões teóricos das funções de autocorrelação e correlação parcial, conforme indica Gujarati (2006), o tipo de modelo

adequado para os dados. Dessa maneira, o modelo mais ajustado aos dados foi o ARIMA (4,1,0), ou seja, a função apresenta quatro termos autorregressivos, foi diferenciada uma única vez e não apresenta médias móveis.

Cumpramos enfatizar que o ARIMA (4,1,0) resultou na equação

$$P^* = 0,00038 + ,497P_{t-1}^* + 0671P_{t-11}^* - 0,153P_{t-27}^* - 0,116P_{t-55}^* \quad [7]$$

em que P^* representa a primeira diferença da série temporal, isto é, $P^* = \Delta P = (P_t - P_{t-1})$. Nesse sentido, conforme apresentado na tabela 1, após a identificação do modelo foram aplicados a função de autocorrelação e o teste de Ljung e Box nos resíduos com o objetivo de verificar a aderência do modelo aos dados (SARTORIS, 2003).

Tabela 1

Autocorrelação e Teste Ljung-Box nos Resíduos

| Defasagem (K) | Autocorrelação (AC) | Ljung-Box | Qui-Quadrado (K,90%) |
|---------------|---------------------|-----------|----------------------|
| 1 | 0,010559 | 0,0318 | 2,71 |
| 2 | -0,072240 | 1,5245 | 4,61 |
| 3 | -0,019878 | 1,6379 | 6,25 |
| 4 | 0,088611 | 3,8999 | 7,78 |
| 5 | -0,041775 | 4,4045 | 9,24 |
| 6 | -0,030515 | 4,6746 | 10,64 |
| 7 | -0,093137 | 7,2009 | 12,02 |
| 8 | -0,012180 | 7,2443 | 13,36 |
| 9 | 0,001552 | 7,2450 | 14,68 |
| 10 | -0,105698 | 10,5345 | 15,99 |

Os limites para a função de autocorrelação, considerando os resíduos, são fornecidos por $\pm \frac{2}{\sqrt{n}}$, em que n representa a quantidade de elementos da amostra. Nesse sentido, considerando a tabela 1, os valores de AC estão no intervalo de 0,1342 a -0,1342 e os valores do teste Ljung-Box são inferiores aos limites da distribuição qui-quadrado, o que indica, por sua vez, que os resíduos se comportam como um ruído branco e que o modelo estimado foi adequado aos dados.

4.2. Ajustando o modelo de RNAs aos dados

Para realizar a previsão do preço do etanol combustível foram criados 36 modelos ou possíveis situações das mais prováveis combinações para a arquitetura das RNAs. Contudo, eles são limitados às seguintes características: apresentam, no máximo, cinco entradas — N e apenas uma saída — M; apresentam, no máximo, duas camadas escondidas e, na segunda camada escondida, o número de neurônios será seis.

Além disso, é válido ressaltar que o número de neurônios das camadas escondidas também pode ser obtido por meio da equação [2]. Assim, o número inicial de neurônios para os 36 modelos foi de 13 neurônios.

Antes de iniciar o processo de treinamento, foi realizada a normalização dos dados com objetivo de aumentar o desempenho das RNAs. Neste artigo, a equação [8] foi utilizada para realizar a padronização dos dados dentro do intervalo de 0 a 1.

$$x_t^* = \frac{(x_t - x_{\min})}{x_{\max}} \quad [8]$$

em que:

- x_t^* é o valor normalizado no intervalo de 0 a 1;
- x_t é o valor real ou observado;
- x_{\min} é o valor mínimo entre o conjunto de observações;
- x_{\max} é o valor máximo entre o conjunto de observações.

Para realizar a previsão do preço do etanol combustível foram criados 36 modelos ou possíveis situações das mais prováveis combinações para a arquitetura das RNAs.

O modelo de RNAs foi construído com o auxílio do software MatLab 6.5 da Mathworks. Nele, todos os 36 modelos de RNAs foram treinados e testados com o algoritmo *back-propagation*. O critério de convergência utilizado no MatLab para a aplicação das RNAs foi o MSE menor ou igual a 0,001 ou um número máximo de 3.000 interações. Ademais, todos os experimentos foram repetidos dez vezes e, posteriormente, as médias de SSE, MSE, MAD, MAPE e RMSE foram computadas. Na tabela 2 são apresentados os resultados da previsão fora da amostra das variações de número de entradas, camadas escondidas e neurônios quanto ao desempenho das RNAs, e, por conseguinte, são listados todos os critérios de avaliação das RNAs apontados na seção 3.2.

Com base na tabela 2, o melhor modelo é o (5 x 2 x 1), isto é, cinco entradas, duas camadas escondidas e uma saída, para realizar a previsão do preço do etanol combustível.

5. RESULTADOS OBTIDOS

Os desempenhos correspondentes à previsão e à avaliação comparativa dos resultados são resumidamente apresentados no gráfico 5, considerando os dados originais da série temporal das RNAs (5 x 2 x 1) e do ARIMA (4,1,0).

Com base no gráfico 5, o desempenho das RNAs (5 x 2 x 1) é melhor para a previsão do preço do etanol combustível quando comparado com os resultados obtidos pelo modelo ARIMA (4, 1, 0). A comparação do desempenho dos dois modelos consta na tabela 3.

Tabela 2

Comparação de Vários Modelos RNAs Considerando a Previsão Fora da Amostra

| Número de Entradas (N) | Número de Camadas Escondidas | Número de Neurônios das Camadas Escondidas | | Número de Saída | SSE | MSE | MAD | MAPE | RMSE |
|------------------------|------------------------------|--|----------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | | Primeira | Segunda | | | | | | |
| 1 | 1 | 13 | — | 1 | 0,373414 | 0,010092 | 0,072975 | 18,638055 | 0,100460 |
| 1 | 1 | 14 | — | 1 | 0,364809 | 0,009860 | 0,066804 | 16,425923 | 0,099296 |
| 1 | 1 | 15 | — | 1 | 0,365564 | 0,009880 | 0,068927 | 16,907485 | 0,099399 |
| 1 | 2 | 13 | 6 | 1 | 0,372736 | 0,010074 | 0,069942 | 17,141550 | 0,100369 |
| 1 | 2 | 14 | 6 | 1 | 0,391625 | 0,010584 | 0,078507 | 21,404213 | 0,102881 |
| 1 | 2 | 15 | 6 | 1 | 0,435414 | 0,011768 | 0,082913 | 22,099946 | 0,108480 |
| 2 | 1 | 13 | — | 1 | 0,213770 | 0,005778 | 0,052056 | 13,023170 | 0,076010 |
| 2 | 1 | 14 | — | 1 | 0,243631 | 0,006585 | 0,053720 | 13,357072 | 0,081146 |
| 2 | 1 | 15 | — | 1 | 0,205675 | 0,005559 | 0,048570 | 12,269909 | 0,074557 |
| 2 | 2 | 13 | 6 | 1 | 0,226690 | 0,006127 | 0,055243 | 15,153714 | 0,078274 |
| 2 | 2 | 14 | 6 | 1 | 0,214779 | 0,005805 | 0,047775 | 12,031313 | 0,076189 |
| 2 | 2 | 15 | 6 | 1 | 0,238552 | 0,006447 | 0,055678 | 13,912608 | 0,080295 |
| 3 | 1 | 13 | — | 1 | 0,145816 | 0,003941 | 0,041555 | 10,616246 | 0,062777 |
| 3 | 1 | 14 | — | 1 | 0,148615 | 0,004017 | 0,040598 | 10,289747 | 0,063377 |
| 3 | 1 | 15 | — | 1 | 0,139536 | 0,003771 | 0,041374 | 10,502746 | 0,061410 |
| 3 | 2 | 13 | 6 | 1 | 0,174104 | 0,004706 | 0,047407 | 12,123483 | 0,068597 |
| 3 | 2 | 14 | 6 | 1 | 0,148833 | 0,004023 | 0,042783 | 10,825973 | 0,063423 |
| 3 | 2 | 15 | 6 | 1 | 0,136803 | 0,003697 | 0,046758 | 13,291046 | 0,060806 |
| 4 | 1 | 13 | — | 1 | 0,136803 | 0,003697 | 0,046758 | 13,291046 | 0,060806 |
| 4 | 1 | 14 | — | 1 | 0,074107 | 0,002003 | 0,029904 | 7,760402 | 0,044754 |
| 4 | 1 | 15 | — | 1 | 0,065326 | 0,001766 | 0,028472 | 7,374301 | 0,042019 |
| 4 | 2 | 13 | 6 | 1 | 0,083141 | 0,002247 | 0,032204 | 8,386609 | 0,047403 |
| 4 | 2 | 14 | 6 | 1 | 0,070347 | 0,001901 | 0,030015 | 7,847759 | 0,043604 |
| 4 | 2 | 15 | 6 | 1 | 0,078514 | 0,002122 | 0,031039 | 7,938005 | 0,046065 |
| 5 | 1 | 13 | — | 1 | 0,135259 | 0,003656 | 0,038716 | 9,756476 | 0,060462 |
| 5 | 1 | 14 | — | 1 | 0,137701 | 0,003722 | 0,038926 | 9,313773 | 0,061005 |
| 5 | 1 | 15 | — | 1 | 0,064215 | 0,001736 | 0,026566 | 6,681433 | 0,041660 |
| 5 | 2 | 13 | 6 | 1 | 0,045644 | 0,001234 | 0,024103 | 6,103474 | 0,035123 |
| 5 | 2 | 14 | 6 | 1 | 0,045644 | 0,001234 | 0,024103 | 6,103474 | 0,035123 |
| 5 | 2 | 15 | 6 | 1 | 0,031519 | 0,000852 | 0,020714 | 5,663618 | 0,029187 |
| 6 | 1 | 13 | — | 1 | 0,068831 | 0,001912 | 0,030865 | 8,055955 | 0,043726 |
| 6 | 1 | 14 | — | 1 | 0,152418 | 0,004234 | 0,043745 | 10,564503 | 0,065068 |
| 6 | 1 | 15 | — | 1 | 0,062862 | 0,001746 | 0,027626 | 6,990934 | 0,041787 |
| 6 | 2 | 13 | 6 | 1 | 0,067382 | 0,001872 | 0,031888 | 8,607109 | 0,043263 |
| 6 | 2 | 14 | 6 | 1 | 0,068867 | 0,001913 | 0,035754 | 10,527065 | 0,043738 |
| 6 | 2 | 15 | 6 | 1 | 0,065186 | 0,001811 | 0,030946 | 7,735284 | 0,042552 |

Nota: A linha em destaque representa o melhor modelo em comparação com os demais.

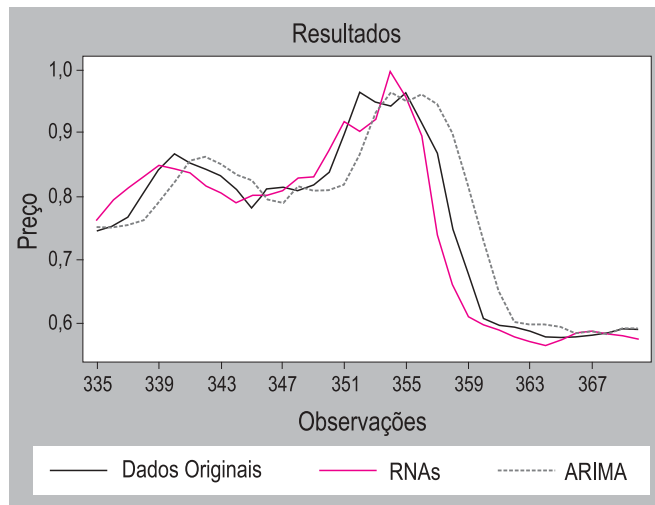


Gráfico 5: Desempenho de Previsão do Preço do Etanol Combustível Fora da Amostra

Os dados constantes na tabela 3 demonstram que o modelo RNAs apresentou o melhor desempenho fora da amostra, considerando que os valores obtidos para SSE, MSE e RMSE são menores em comparação com os do ARIMA.

5. DISCUSSÕES E CONCLUSÕES

Neste artigo, examinou-se o desempenho do modelo RNAs comparado com o modelo estatístico ARIMA para a previsão do preço do etanol combustível no mercado do Brasil. Para realização dessa comparação foram utilizados como critérios de comparação a Soma Quadrada dos Erros (SSE), a Média das Diferenças Absoluta (MAD), o Erro Quadrático Médio (MSE), o Percentual de Erro Absoluto Médio (MAPE), e a

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDREOU, Panayiotis C.; CHARALAMBOUS, Chris; MARTZOUKOS, Spiros H. Pricing and trading European options by combining artificial neural networks and parametric models with implied parameters. *European Journal of Operational Research*, [S.l.], v.185, Issue 3, p.1415-1433, Mar. 2008.
- BIALOSKORSKI NETO, Segismundo; NAGANO, Marcelo Seido; MORAES, Marcelo Botelho da Costa. Utilização de redes neurais artificiais para avaliação socioeconômica: uma aplicação em cooperativas. *Revista de Administração da Universidade de São Paulo (RAUSP)*, São Paulo, v.41, n.1, p.59-68, jan./mar. 2006.
- BODYANSKIY, Yevgeniy; POPOV, Sergiy. Neural network approach to forecasting of quasiperiodic financial time series. *European Journal of Operational Research*, [S.l.], v.175, Issue 3, p.1357-1366, Dec. 2006.
- BOX, George P.; JENKINS, Gwilm M. *Time series analysis: forecasting and control*. 3rd ed. New Jersey: Prentice Hall, 1994. 598p.
- BRAVO, E. *Agrocombustíveis, cultivos energéticos e soberania alimentar na América Latina*: aquecendo o debate sobre

Tabela 3
Comparação dos Melhores Resultados dos Dois Modelos

| Modelo | Fora da Amostra | | | | |
|--------|-----------------|----------|----------|----------|----------|
| | SSE | MSE | MAD | MAPE | RMSE |
| ARIMA | 0,561773 | 0,001789 | 0,028465 | 4,509443 | 0,042298 |
| RNAs | 0,522286 | 0,001663 | 0,028589 | 4,551423 | 0,040784 |

Nota: Fora da amostra — 24 de novembro de 2006 a 03 de agosto de 2007.

Raiz do Erro Quadrático Médio (RMSE). A análise indicou que as RNAs com duas camadas escondidas podem, precisa e satisfatoriamente, apresentar uma função que pode ser utilizada como um método alternativo para a previsão do preço do etanol combustível por gerentes financeiros e empresários. Em consequência, os resultados obtidos demonstraram que o modelo RNAs é consideravelmente mais acurado do que o modelo ARIMA, tradicionalmente utilizado como ponto de referência.

Do ponto de vista da aplicação prática, esse resultado pode ser utilizado para auxiliar os comerciantes a restringirem seus riscos com relação às oscilações do preço do etanol combustível, além de facilitar o processo de tomada de decisão. Além disso, este trabalho pode ajudar no estabelecimento de políticas governamentais apropriadas e sustentáveis, pois o etanol combustível, resultante da produção da cana-de-açúcar, tem grande importância no desenvolvimento econômico do País. Por fim, vale registrar que se pretende, em estudos futuros, analisar e comparar o desempenho das RNAs com o modelo de Autorregressão Vetorial (VAR) para previsão do preço do etanol. ♦

agrocombustíveis. São Paulo: Expressão Popular, 2007. 112p.

CAO, Qing; LEGGIO, Karyl B.; SCHNIEDERJANS, Marc J. A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. *Computers & Operations Research*, [S.l.], v.32, Issue 10, p.2499-2512, Oct. 2005.

CHAKRABORTY, Kanad; MEHROTRA, Kishan; MOHAN, Chilukuri K.; RANKA, Sanjay. Forecasting the behavior of multivariate time series using neural networks. *Neural Networks*, [S.l.], v.5, Issue 6, p.961-970, Nov./Dec. 1992.

CHURCH, Keith B.; CURRAM, Stephen P. Forecasting consumers expenditure: a comparison between econometric and neural network models. *International Journal of Forecasting*, [S.l.], v.12, Issue 2, p.255-267, June 1996.

CO, Henry C.; BOOSARAWONGSE, Rujirek. Forecasting Thailand's rice export: statistical techniques vs. artificial neural networks. *Computers & Industrial Engineering*, [S.l.], v.53, Issue 4, p.610-627, Nov. 2007.

- DECO, Gustavo; NEUNEIER, Ralph; SCHÜRMANN, Bernd. Non-parametric data selection for neural learning in non-stationary time series. *Neural Networks*, [S.l.], v.10, Issue 3, p.401-407, Apr. 1997.
- DINIZ, H.; ANDRADE, L.C.M.; CARVALHO, A.C.P.L.F.; ANDRADE, M.G. Previsão de séries temporais utilizando redes neurais artificiais e modelos de Box & Jenkins. In: SIMPÓSIO BRASILEIRO DE REDES NEURASIS, 5., 1998, Belo Horizonte. *Anais...* Belo Horizonte, Minas Gerais: UFMG, 1998.
- EDIGER, Volkan S.; AKAR, Sertac. ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, [S.l.], v.35, Issue 3, p.1701-1708, Mar. 2007.
- EDIGER, Volkan S.; AKAR, Sertac; URGULU, Berkin. Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model. *Energy Policy*, [S.l.], v.34, Issue 18, p.3836-3846, Dec. 2007.
- ERDOĞDU, Erkan. Electricity demand analysis using cointegration and ARIMA modelling: a case study of Turkey. *Energy Policy*, [S.l.], v.35, Issue 2, p.1129-1146, Feb. 2007.
- FREIMAN, José Paulo; PAMPLONA, E.O. Redes neurais artificiais na previsão do valor de commodity do agronegócio. In: ENCUESTRO INTERNACIONAL DE FINANZAS, 5., 2005, Santiago. *Anais...* Chile: Universidade Lusíada do Porto, 2005.
- GUJARATI, Damodar. *Econometria básica*. 4.ed. Rio de Janeiro: Campus, 2006. 812p.
- HAOFEI, Zou; GUOPING, Xia; FANGTING, Yang; HAN, Yang. A neural network model based on the multi-stage optimization approach for short-term food price forecasting in China. *Expert Systems with Applications*, [S.l.], v.33, Issue 2, p.347-356, Aug. 2007.
- HASSAN, M.R.; NATH, B. Stock market forecasting using hidden markov model: a new approach. In: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM DESIGN AND APPLICATION, 5., 2005, Poland. *Proceedings...* Poland: Wrocław University of Technology, 2005. p.192-196.
- HASSAN, Md. Rafiul; NATH, Baikunth; KIRLEY, Michael. A fusion model of HMM, ANN and GA for stock market forecasting. *Expert Systems with Applications*, [S.l.], v.33, Issue 1, p.171-180, July 2007.
- HO, S.L.; XIE, M. The use of ARIMA models for reliability forecasting and analysis. *Computer Ind. Engineering*, [S.l.], v.35, n.1-2, p.213-216, Oct. 1998.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multi-layered feedforward networks are universal approximates. *Neural Networks*, [S.l.], v.2, Issue 5, p.359-366, Nov. 1989.
- HUARNG, Kunhuang; YU, Tiffany Hui-Kuang. The application of neural networks to forecast fuzzy time series. *Physica A: Statistical Mechanics and its Applications*, [S.l.], v.363, Issue 2, p.481-491, May 2006.
- JUNTILA, Juha. Structural breaks, ARIMA model and Finnish inflation forecasts. *International Journal of Forecasting*, [S.l.], v.17, Issue 2, p.203-230, April/June 2001.
- KOHZADI, Nowrouz *et al.* A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing*, [S.l.], v.10, Issue 2, p.169-181, Mar. 1996.
- KUCUK, Ilker. Multilayered perceptron neural networks to compute energy losses in magnetic cores. *Journal of Magnetism And Magnetic Materials*, [S.l.], v.307, Issue 1, p.53-61, Dec. 2006.
- KUMAR, Usha A. Comparison of neural networks and regression analysis: a new insight. *Expert Systems With Applications*, [S.l.], v.29, Issue 2, p.424-430, Aug. 2005.
- LUXHOJ, James T.; RIIS, Jens O.; STENSALLE, Brian. A hybrid econometric-neural network modeling approach for sales forecasting. *Int. J. Production Economics*, [S.l.], v.43, Issue 2-3, p.175-192, June 1996.
- MALIK, Farooq; NASEREDDIN, Mahdi. Forecasting output using oil prices: a cascaded artificial neural network approach. *Journal of Economics and Business*, [S.l.], v.58, Issue 2, p.168-180, Mar./Apr. 2006.
- MÉLARD, G.; PASTEELS, J.-M. Automatic ARIMA modeling including interventions, using time series expert software. *International Journal of Forecasting*, [S.l.], v.16, Issue 4, p.497-508, Oct./Dec. 2000.
- ORMONEIT, D. A regularization approach to continuous learning with an application to financial derivatives pricing. *Neural Networks*, [S.l.], v.12, Issue 10, p.1405-1412, Dec. 1999.
- PAI, Ping-Feng; LIN, Chih-Sheng. A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega*, [S.l.], v.33, Issue 6, p.497-505, Dec. 2005.
- PAO, Hsiao-Tien. Forecasting electricity market pricing using artificial neural networks. *Energy Conversion and Management*, [S.l.], v.48, Issue 3, p.907-912, Mar. 2007.
- PINO, Raúl *et al.* Forecasting next-day price of electricity in the Spanish energy market using artificial neural networks. *Engineering Applications of Artificial Intelligence*, [S.l.], v.21, Issue 1, p.53-62, Feb. 2008.
- RAZI, Muhammad A.; ATHAPPILLY, Kuriakose. A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Systems with Applications*, [S.l.], v.29, Issue 1, p.65-74, July 2005.
- RED'KO, Vladimir G.; MOSALOV, Oleg P.; PROKHOROV, Danil V. A model of evolution and learning. *Neural Networks*, [S.l.], v.18, Issues 5-6, p.738-745, July/Aug. 2005.
- SARTORIS, Alexandre. *Estatística e introdução à econometria*. São Paulo: Saraiva, 2003. 426p.
- SCHÖNEBURG, E. Stock price prediction using neural networks: a project report. *Neurocomputing*, [S.l.], v.2, Issue 1, p.17-27, June 1990.
- SMITH, Kate A.; GUPTA, Jatinder N.D. Neural networks in business: techniques and applications for the operations researcher. *Computers & Operations Research*, [S.l.], v.27, Issues 11-12, p.1023-1044, Sept. 2000.
- STEINER, M.; WITTKEMPER, H.G. Using neural networks to forecast the systematic risk of stocks. *European Journal of Operational Research*, [S.l.], v.90, Issue 3, p.577-588, May 1996.
- TERÄSVIRTAA, Timo; DIJK, Dick van; MEDEIROS, Marcelo C. Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series: a re-examination. *International Journal of Forecasting*, [S.l.], v.21, Issue 4, p.755-774, Oct./Dec. 2005.
- THAWORNWONG, Suraphan; ENKE, David. The adaptive selection of financial and economic variables for use with artificial neural networks. *Neurocomputing*, [S.l.], v.56, Issue 1, p.205-232, Jan. 2004.

- THAWORNWONG, Suraphan; ENKE, David. The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Applications*, [S.l.], v.29, Issue 4, p.927-940, Nov. 2005.
- TSAIH, Ray; HSU, Yenshan; LAI, Charles C. Forecasting S&P 500 stock index futures with a hybrid AI system. *Decision Support Systems*, [S.l.], v.23, Issue 2, p.161-174, June 1998.
- TSANG, Philip M. *et al.* Design and implementation of NN5 for Hong Kong stock price forecasting. *Engineering Applications of Artificial Intelligence*, [S.l.], v.20, Issue 4, p.453-461, June 2007.
- TSENG, Fang-Mei *et al.* Fuzzy ARIMA model for forecasting the foreign exchange market. *Fuzzy Sets and Systems*, [S.l.], v.118, Issue 1, p.9-19, Feb. 2001.
- TSENG, Fang-Mei; TZENG, Gwo-Hsiung Tzeng. A fuzzy seasonal ARIMA model for forecasting. *Fuzzy Sets and Systems*, [S.l.], v.126, Issue 3, p.367-376, Mar. 2002.
- WANG, Ying-ming; ELHAG, Taha M.S. A comparison of neural network, evidential reasoning and multiple regression analysis in modelling bridge risks. *Expert Systems With Applications*, [S.l.], v.32, Issue 2, p.336-348, Feb. 2007.
- WIDROW, B.; RUMELHART, D.E.; LEHR, M.A. Neural networks: applications in industry, business and science. *Communications of the ACM*, [S.l.], v.37, Issue 3, p.93-105, Mar. 1994.
- WONG, Bo K.; BODNOVICH, Thomas A.; SELVI, Yakup. Neural network applications in business: a review and analysis of the literature (1988-1995). *Decision Support Systems*, [S.l.], v.19, Issue 4, p.301-320, Apr. 1997.
- WONG, Bo K.; LAI, Vincent S.; LAM, Jolie. A bibliography of neural network business applications research: 1994-1998. *Computers & Operations Research*, [S.l.], v.27, Issues 11-12, p.1045-1076, Sept. 2000.
- WONG, Bo K.; MONACO, John A. Expert system applications in business: a review and analysis of the literature (1977-1993). *Information & Management*, [S.l.], v.29, Issue 3, p.141-152, Sept. 1995.
- WONG, Bo K.; SELVI, Yakup. Neural network applications in finance: a review and analysis of literature (1990-1996). *Information & Management*, [S.l.], v.34, Issue 3, p.129-139, Oct. 1998.
- XUEFENG, Li; LU, Liu; LIHUA, Wu; ZHAO, Zhang. Predicting the final prices of online auction items. *Expert Systems with Applications*, [S.l.], v.31, Issue 3, p.542-550, Oct. 2006.
- ZHANG, G. Peter. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, [S.l.], v.50, Issue 1, p.159-175, Jan. 2003.
- ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, [S.l.], v.14, Issue 1, p.35-62, Mar. 1998.
- ZOU, H. F. *et al.* An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting. *Neurocomputing*, [S.l.], v.70, Issue 16-18, p.2913-2923, Oct. 2007.

Forecasting ethanol price using artificial neural networks techniques

The interest for forecast of values led the accomplishment of several researches, in the financial area and of businesses, in the last years; however, little was accomplished with the purpose of esteeming the values of the fuels. That gap becomes more notable when Ethanol fuel is observed in Brazil. In that sense, the objective of this article is to compare the acting of the ANNS, using the architecture Multilayer Perceptron, with the method ARIMA for forecast of Ethanol Fuel's price. Such possibility allows doing forecasts of the future prices of that product that it is marketed and consumed in the whole world. The method adopted to accomplish such comparison it went to the mistake measures joined in forecasts. As result was observed that the application of ANNs obtained a more satisfactory approach compared to the method ARIMA with relationship to the real data, which in conclusion evidence the importance of ANNs in the forecast of Ethanol Fuel's prices.

Keywords: forecast, ethanol, artificial neural network, ARIMA, Brazil.

Determinación del precio del etanol por medio de técnicas de redes neuronales artificiales

El interés por la previsión de valores condujo a la realización de varias investigaciones en el área financiera y de negocios en los últimos años, sin embargo, pocas se realizaron con el propósito de estimar los valores de los combustibles. Esa laguna se hace más evidente cuando se observa el etanol combustible en Brasil. En ese sentido, el objetivo de este artículo es comparar el desempeño de las redes neuronales artificiales (RNAs), usando la arquitectura perceptron multicapa, con el método ARIMA para previsión del precio del etanol combustible. Dicha posibilidad permite hacer previsiones de los precios futuros de ese producto que se comercializa y consume en todo el mundo. El método adoptado para realizar la comparación fue el de las medidas de error agregado en previsiones. Como resultado, se observó que la aplicación de las RNAs obtuvo una aproximación más satisfactoria comparada con el método ARIMA en cuanto a los datos reales, lo que en conclusión evidencia la importancia de las RNAs en la previsión de los precios del etanol combustible.

Palabras clave: previsión, etanol, redes neuronales artificiales, ARIMA, Brasil.