

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS COMO ESTRATÉGIA DE PREVISÃO DE PREÇOS NO CONTEXTO DE AGRONEGÓCIO

Luciano Ferreira

Doutor em Sistemas de Informação pela Universidade Federal do Rio Grande do Sul – UFRN
Professor da Universidade Federal do Rio Grande do Norte – UFRN
ferreira@ufrnet.br

Gilnei Luiz de Moura

Doutor em Administração pela Universidade de São Paulo – USP
Professor da Universidade Federal de Santa Maria – PPGA/CCSH/UFSM
gilneilm@usp.br

Denis Borenstein

Doutor em Pesquisa Operacional pela University of Strathclyde, Escócia
Professor da Universidade Federal do Rio Grande do Sul – UFRGS
denisb@ufrgs.br

Adalberto Américo Fischmann

Doutor em Administração pela Universidade de São Paulo – USP
Professor da Universidade de São Paulo – USP
aafischm@usp.br

RESUMO

Este artigo apresenta uma análise do uso de redes neurais artificiais como estratégia de previsão de preços no contexto do agronegócio. Para tanto, adotou-se como pano de fundo dados da Emater/RS (1992-2006) a respeito de quatro *commodities* específicas: soja, boi gordo, milho e trigo. A metodologia adotada durante a pesquisa seguiu os passos apresentados em Hair, Anderson, Tatham e Black (2005), utilizando-se o modelo de rede neural *perception*. Os dados trabalhados evidenciam a possibilidade do uso de redes neurais como uma estratégia de precificação dos preços de *commodities* agrícolas em mercados futuros. Embora deva-se ter atenção aos vieses cognitivos frequentes nos processos de tomada de decisão, acredita-se que há uma contribuição significativa à academia, bem como pode ser um ponto de partida para a melhoria nas decisões dos gestores rurais.

Palavras-chave: Agronegócio; Tomada de decisões; Redes neurais artificiais; Estratégia; Precificação.

1 INTRODUÇÃO

É consenso que qualquer sistema econômico deve conter os seguintes elementos fundamentais: Terra (RN); Mão de Obra (T); Capital (K); e Gestão do Empreendimento (M).

[...] nos últimos cem anos, várias tarefas na economia passaram a ser desempenhadas por organizações. Algumas dessas organizações são bastante grandes; poucos discordam que elas têm poder, o que quer dizer que são capazes de comandar os esforços de indivíduos e do Estado. Para a maioria das pessoas, isso é feito segundo os fins próprios dessas organizações, sendo esses os fins dos indivíduos que delas participam como empregados ou proprietários ... Encarando-se as coisas desse modo, a função do sistema econômico deixa de ser simples ... em parte, o sistema econômico atende aos interesses do indivíduo. Mas, em parte, como se reconhece agora, também atende os interesses de suas organizações (Galbraith, 1988, p. 3).

Byrns e Stone (1995, p. 6) consideram que a gestão do empreendimento “[...] fornece um tipo especial de recurso. Combina mão de obra, recursos naturais e capital para produção de bens e serviços enquanto assumem o risco pelos lucros”. Sob essa ótica, todas as unidades produtivas que compõem o sistema estão agrupadas em três grandes segmentos: setor primário – agricultura, pecuária, silvicultura, pesca; setor secundário – atividades industriais; e setor terciário – transportes, hotéis, bancos.

O agronegócio envolve esses três grandes segmentos, podendo ser entendido como toda relação comercial e industrial envolvendo a cadeia produtiva agrícola ou pecuária, ou seja, pode ser considerado como um sistema constituído de cadeias produtivas compostas por diferentes fornecedores de insumos e serviços, produção agropecuária, indústria de processamento e transformação, agentes de distribuição e comercialização, tendo como objetivo comum suprir o consumidor de produtos de origem agropecuária e florestal (Farina, 2000).

Segundo o Ministério do Desenvolvimento, Indústria e Comércio Exterior (2011) e dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2011), o segmento é responsável por cerca de 29% do Produto Interno Bruto (PIB) do Brasil, empregando aproximadamente 38% da mão de obra do país e sendo responsável por 42% das exportações brasileiras, além de ser superavitário sistematicamente.

Os negócios envolvendo as *commodities* agrícolas correspondem a uma significativa parcela desse valor, seu mercado é complexo e sua negociação pode ocorrer por meio dos mercados à vista, a termo ou de derivativos. O mercado de derivativos (também chamado de mercado de contratos futuros) caracteriza-se por ter um expressivo volume de negociações, normalmente significativamente superior ao mercado à vista. Essa situação ocorre pela presença de diferentes tipos de atores que atuam

no mercado futuro, além dos investidores tradicionais que muitas vezes não se interessam pelo bem físico, mas em realizar operações financeiras para obter ganho de capital (Corsini & Ribeiro, 2008).

As unidades que compõem as cadeias produtivas do setor primário (soja, trigo, milho, boi de corte) similarmente às empresas dos dois outros setores também buscam uma administração estratégica centrada na primazia da eficiência e eficácia. Contudo, as estratégias definidas em um processo de planejamento não garantem por si só o alcance e sucesso dos objetivos organizacionais, principalmente se for considerado que a probabilidade de haver certa *gap* entre a elaboração e a execução estratégicas é alta.

A decisão lógica sempre é considerada uma boa decisão, ou seja, aquela baseada em análise de incertezas, valores e preferências do tomador de decisão (Howard, 1989). Genericamente, toda decisão possui quatro pontos de dificuldade: (1) complexidade, (2) incerteza, (3) objetivos múltiplos que se inter-relacionam e (4) possibilidade de diferentes perspectivas levarem a diferentes conclusões de análise (Clemen & Reilly, 2001).

Simon propôs um modelo decisório que melhor se adapta a uma proposta racional de análise do processo decisório suportado por informações disponibilizadas por um sistema de informações. De forma simplificada, o modelo constitui-se basicamente de três fases em constante *feedback* entre si: Inteligência, ou coleta de informações; Concepção, ou estruturação; e Escolha (Simon, 1972).

Outra maneira de tratar o conceito de processo decisório é classificar os estudos em duas correntes: a descritiva e a normativa. Do ponto de vista descritivo, busca-se entender como as decisões são tomadas em um dado contexto, e como se comportam os tomadores de decisão diante de diferentes situações e sob diferentes perspectivas.

Do ponto de vista normativo, Clemen e Reilly (2001) reforçam que a boa decisão é resultado de um processo elaborado de forma racional, que pode ser repetido e trará os mesmos resultados de análise. Para tanto, é preciso que se crie uma estrutura de análise que proverá direção aos tomadores de decisão de qual o melhor caminho a seguir, com base em todas as influências e variáveis envolvidas.

Entretanto, como não é possível ao tomador de decisões o acesso a todas as possibilidades de ação, e medir todas as opções, seja pela impossibilidade física, seja pelo custo de um processo dessa natureza, torna-se situação comum optar por soluções satisfatórias e razoáveis, muitas vezes fixando critérios minimamente viáveis de performance (Lacombe & Heilborn, 2003).

Diante desses fatos, torna-se fundamental a pesquisa por novas metodologias que possam auxiliar no processo decisório do agronegócio, seja no planejamento de suas atividades, seja na tomada de decisões de seus gestores, seja na precificação de mercados futuros. Algumas iniciativas

relacionadas especificamente com esse setor já aparecem na literatura, principalmente em trabalhos nacionais. Os trabalhos internacionais são diversificados, porém confirmam a importância e oportunidade de utilização dos modelos de redes neurais, conforme apresentado no Quadro 1.

Autores	Método	Commodities ou segmento do estudo
Corsini e Ribeiro (2008)	Filtro de Kalman	Açúcar
Lima, Gois e Ulises (2007)	Arima	Açúcar, café, milho, soja, boi gordo
Yonenaga e Figueiredo (1999)	Redes neurais	Soja
Melo Milioni e Nascimento (2007)	Redes neurais	Açúcar
Sobreiro, Araujo, Mendonça e Nagano (2008)	Redes neurais	Açúcar
Sobreiro, Araujo e Nagano (2009)	Redes neurais	Etanol
Ribeiro, Sosnoski e Oliveira (2010)	Redes neurais, média móvel, suavização exponencial	Açúcar, etanol, café, soja
Ceretta, Righi e Schlender (2010)	Arima, redes neurais	Soja
Zou, Yang, Fu, Liu e Li (2010)	Redes neurais	Análise do solo
Kankal, Akpınar, Kömürçü e Özsahin (2011)	Redes neurais, modelos de regressão	Consumo de energia
Singhal e Swarup (2011)	Redes neurais	Preço de energia
Chen (2011), Gomes, Ludermir e Lima (2011), Khashei e Bijari (2011), Wong, Xia e Chu (2010)	Redes neurais	Séries financeiras
Eddy <i>et al.</i> (2008)	Redes neurais	Agricultura de precisão

Quadro 1 – Resumo dos trabalhos relacionados

Fonte: Elaborado pelos autores.

Portanto, considerando o contexto brasileiro e as especificidades do agronegócio, ainda há muito espaço para novos trabalhos, pois além de ser necessário explorar e discutir a aplicação de novas técnicas computacionais e/ou estatísticas, as conclusões obtidas a partir dos experimentos realizados devem ser pautadas em um maior rigor metodológico e com a análise do comportamento de diversas *commodities*, com amplitudes e médias variadas, condição indispensável para avaliar a generalidade dos modelos propostos. Analisando-se os trabalhos nacionais, principalmente, percebe-se carência na adoção de uma metodologia robusta para estruturação dos modelos utilizados na análise dos resultados.

As redes neurais artificiais, importante ramo da inteligência artificial, apresentam características muito relevantes para tarefas que envolvam previsão e classificação, tais como a capacidade de generalização, adaptação, correlação e aprendizado. A conjugação desses fatores facilita o tratamento de séries temporais, auxiliando na extração das características mais importantes de uma série, ou seja, sazonalidade e tendência (Fausett, 1994).

Portanto, este artigo apresenta a elaboração e a validação de um modelo baseado em redes neurais cujo objetivo é prever o comportamento de diferentes *commodities* agrícolas (soja, trigo, boi gordo e milho), oferecendo um método que possibilita traçar seu comportamento futuro, de forma a ser uma alternativa palpável aos gestores que, em diversas situações, precisam realizar negociações em mercados onde a incerteza está cada vez mais presente. Para tanto, utilizou-se dados coletados na base de dados da Emater-RS (1992-2006) e a metodologia proposta em Hair et al. (2005) para estruturação do modelo de redes neurais. O restante deste trabalho está organizado da seguinte maneira: a seção 2 apresenta conceitos relacionados à tomada de decisão; a seção 3 apresenta os principais conceitos relacionados a redes neurais; a seção 4 traz os passos metodológicos que foram seguidos para a construção do modelo; a seção 5 mostra os resultados obtidos com as simulações; e, por fim, a seção 6 está destinada a conclusão e trabalhos futuros.

2 TOMADA DE DECISÃO

A busca de vantagens competitivas que maximizem suas *core competences* é fator preponderante em boa parte das corporações mundiais de sucesso. Essa firme deliberação é, em parte, entendida ao se constatar que:

[...] as últimas décadas são marcadas por profundas mudanças de ordem econômica, política, social, cultural e tecnológica, com velocidades cada vez maiores. Essas mudanças têm gerado ambiente complexo que traz muitos desafios às organizações, uma vez que vislumbrar as oportunidades embutidas neste ambiente de riscos é um fator primordial para sua sobrevivência e importante fator de competitividade. Para enfrentar os desafios e conseguir enxergar as oportunidades oriundas desse ambiente de grandes mudanças e incertezas, os planejadores veem-se às voltas com o problema de prosperar o futuro e especular sobre as tendências do ambiente econômico, setorial e empresarial (Giovinazzo & Fischmann, 2001, citado em Costa & Almeida, 2002, p. 231).

Nesse contexto, Clemen e Reilly (2001) consideram que estudar técnicas de análise de decisão é fundamental para ser capaz de representar no mundo real problemas usando modelos que possam ser

analisados para ganhar perspicácia e entendimento, *i.e.*, similarmente à ideia de prospectar uma ação antes de executá-la.

Entretanto há o problema de como iniciar esse processo. Uma forma alternativa é identificar os elementos de uma situação analisada e classificá-los em quatro classes: (1) valores e objetivos; (2) decisões a serem tomadas; (3) eventos incertos – incertezas; e (4) consequências (Clemen & Reilly, 2001).

Eisenhardt e Zbaracki (1992) salientam que o modelo racional apresenta limites cognitivos. De modo análogo, March (1994) observa que, em processos racionais, a escolha depende de quais alternativas são consideradas, e estas podem envolver duas suposições sobre o futuro: a primeira suposição é sobre os estados futuros do objeto de decisão, há a condicional na escolha. A segunda suposição é de como o tomador de decisão se sentirá sobre aquele objeto de decisão quando ele tem experiência sobre o assunto em questão. É justamente nesse ponto que podem surgir os vieses de Bazerman (2004).

Langley, Mintzberg, Pitcher, Posada e Saint-Macary (1995) observam que a decisão possui algumas ambiguidades entre o se comprometer e o agir. O tomador de decisão dependendo de sua experiência pode sofrer influência e sua perspicácia pode ter papel preponderante em sua escolha, transcendendo a racionalidade necessária.

Similarmente, Papadakis, Lioukas e Chambers (1998) salientam que a tomada de decisão em uma organização pode seguir um comportamento padrão, *i.e.*, o próprio gestor pode acabar manipulando a informação que advém dos sistemas internos e/ou externos, mesmo com um *scanning* ambiental, *e.g.*, o que pode ser visto como ameaça por um ponto de vista, por outro poderia ser concebido como oportunidade. Considerando a provável existência de fatores como a comunicação lateral, a centralização e/ou descentralização hierárquica, e mesmo o ambiente político, há que se ter o cuidado com as decisões sobre a decisão, a **metadecisão** (Bernhardt, 2004).

Nesse sentido, Shimizu (2006, p. 17) corrobora as concepções supracitadas ao atentar que exceto os problemas de rotina, “[...] o processo de formular alternativas de decisão e escolher a melhor delas é quase sempre caótico e complexo”.

De modo geral, Shimizu (2006) classifica os problemas de decisão em quatro modelos (Figura 1): (1) modelo racional – decisão com certeza, decisão com otimização, decisão que usa heurísticas e meta-heurísticas, decisão na administração da produção, planejamento econômico que usa análise de entrada/saída de Leontief, decisão em planejamento de cadeia de suprimentos; (2) modelo processual – decisão em situação de incerteza ou risco, decisão que usa processos estocásticos; (3) modelo político

– decisão com incerteza, múltiplos objetivos e múltiplos cenários, decisão com competidor ou conflito, decisão em portfólio de ações, decisão em problemas de tecnologia da informação, decisão por grupos ou negociação; e (4) modelo ambíguo – modelo da lata de lixo, decisão pelo voto, decisão que usa sistemas especialistas difusos, decisão por negociação.

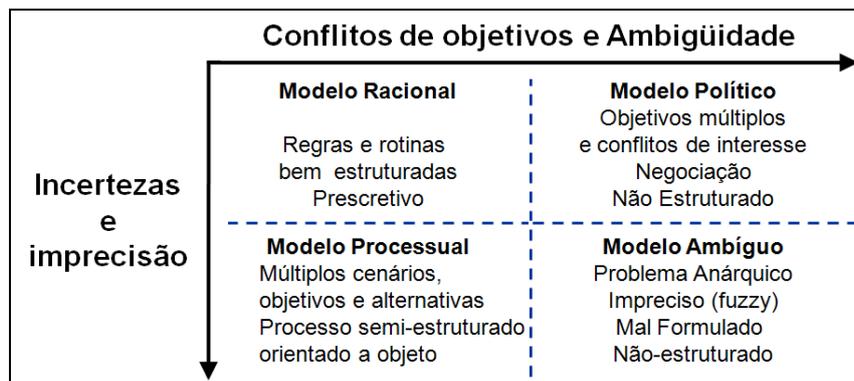


Figura 1 - Classificação dos problemas de decisão

Fonte: Adaptado de Chun (1998)

Com o advento e avanço da tecnologia da informação e dos sistemas inteligentes, uma ferramenta passou a ser típica para tomada de decisão: a ideia de se basear em banco de dados, coletados e indexados em uma série histórica. Os dados selecionados são tratados e comparados dentro de um modelo predeterminado, e o resultado relativo àquele modelo se torna uma predição. Esta predição pode ser incrementada ou descartada pelo tomador de decisões. É nesse amálgama que os estudos de redes neurais fluem como alternativas e/ou somatórios aos tomadores de decisão (Black, 2007).

3 REDES NEURAIAS ARTIFICIAIS

A construção de redes neurais artificiais tem inspiração nos neurônios biológicos e nos sistemas nervosos. Na verdade, as redes neurais artificiais são sistemas computacionais que imitam as habilidades do sistema nervoso biológico, usando um grande número de neurônios artificiais interconectados. Alguns desses neurônios recebem excitações do exterior e são chamados neurônios de entrada, correspondendo aos neurônios dos órgãos dos sentidos. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior, sendo chamados neurônios de saída e correspondem aos motoneurônios, ou seja, os neurônios biológicos que excitam os músculos. Há ainda os neurônios que

não são de entrada nem de saída e são conhecidos como neurônios internos. Os neurônios internos à rede têm grande importância, conhecidos na literatura como *hidden*, fazem com que alguns traduzam como **escondidos** (Barreto, 2002).

Portanto, o elemento mais básico de uma rede neural é um neurônio ou nó, uma unidade de processamento completa que atua em paralelo com outros neurônios na rede. Seus três elementos básicos são descritos a seguir, conforme apresentados na Figura 2:

- 1) Um conjunto de conexões de entrada, cada uma delas possuindo um peso associado; dessa forma, cada entrada x que está ligada a um dado neurônio deve ser multiplicada pelo seu respectivo peso w ;
- 2) Um somador, para realizar a soma da multiplicação dos sinais de entrada pelos seus respectivos pesos, considerando todas as conexões que chegam ao neurônio;
- 3) Uma função de ativação para gerar uma saída, a qual é enviada ao próximo nó do sistema. O objetivo da função de ativação é limitar a amplitude da saída do neurônio. Algumas funções de ativação mais utilizadas são as funções sigmoide, linear, passo e logística.

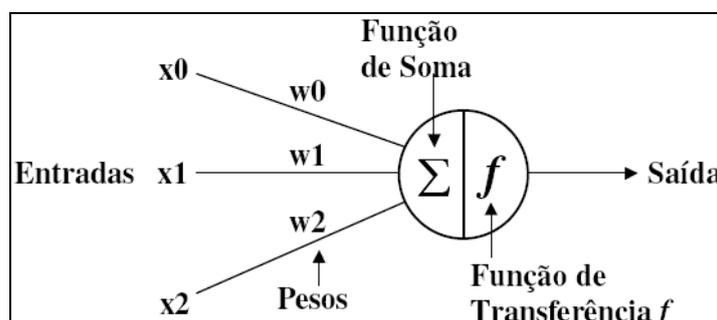


Figura 2 – Modelo de um neurônio

Fonte: Elaborado pelos autores.

Desse modo, uma rede neural passa a ser formada por um arranjo sequencial de três tipos básicos de neurônios: neurônios de entrada, neurônios intermediários e neurônios de saída, conforme demonstrado na Figura 3. Na camada de entrada são recebidos os valores iniciais de dados de cada caso, processados e transmitidos para as camadas intermediárias ou ocultas, que são um conjunto de nós utilizados pela rede neural para representar relações mais complexas do que apenas uma relação de um-a-um entre entrada e saída. São as camadas ocultas e a função de ativação que permitem a rede neural facilmente representar relações não lineares, as quais são muito problemáticas para técnicas multivariadas. Por fim, a camada de saída recebe os valores da camada intermediária, calcula o valor de saída, porém não envia a outra camada, pois esse representa o valor final. Ao se tratar de um

modelo preditivo, então esse é o valor de previsão, se está se tratando de um modelo de classificação, esse representa o valor de diferenciação e, assim, para as mais variadas aplicações.

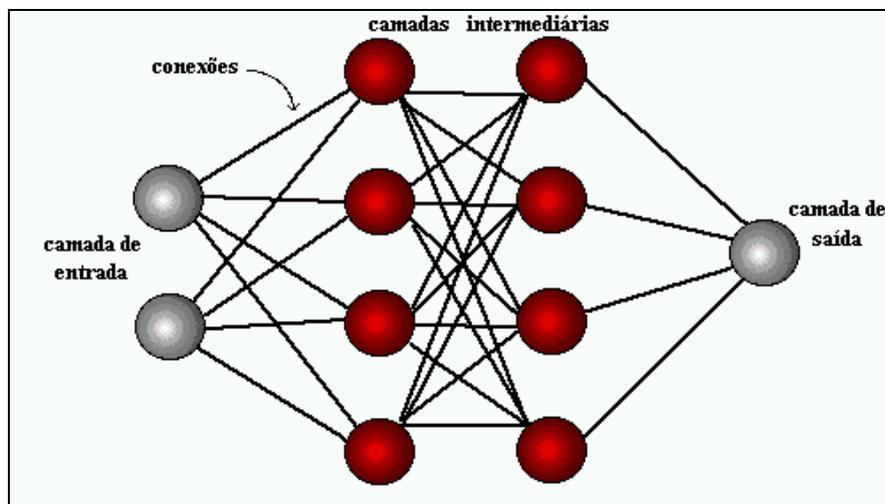


Figura 3 – Estrutura de uma rede neural

Fonte: Barreto (2002).

Outra característica de uma rede neural, tão importante quanto a capacidade de estabelecer relações não lineares, é sua capacidade de aprendizado. O aprendizado pode ser definido como a mudança no comportamento em procedimentos de treinamento, ou seja, é um processo de antes e depois, em que a performance é medida antes e depois do treinamento. A diferença indica o quanto se aprendeu (Loesch & Sari, 1996).

Em uma rede neural, logo que a entrada para um caso é processada pelo sistema, ela pode ser comparada com um real valor de saída que é desejado ou que se tem como objetivo a perseguir. Isso é chamado de treino do sistema em um modo de aprendizado supervisionado, em que os valores real e de saída são comparados. Se existe alguma diferença entre esses dois valores (semelhante a um valor residual), então um ajuste é feito no modelo na esperança de melhorá-lo. A forma mais comum de treino é a retropropagação. Nessa técnica, o erro no valor de saída é calculado e distribuído **para trás** ao longo do sistema, dessa forma, os pesos são modificados proporcionalmente, aumentando ou diminuindo, dependendo da direção do erro. Assim que todos os pesos tenham sido ajustados, a entrada para outro caso é feita na rede e o processo de retropropagação se repete. O objetivo passa a ser, então, processar um grande número de casos para minimizar a diferença existente entre o valor de saída, calculado pela rede, e o valor real, fornecido para treino.

Ainda cabe, para o contexto deste trabalho, uma última consideração sobre modelos de redes neurais. Segundo Hair et al. (2005), existem, basicamente, três tipos de modelos de redes neurais: (i) o

perception multicamadas; (ii) a função base radial e (iii) as redes Kohonen, O modelo *perception* multicamadas é o mais frequentemente utilizado e foi escolhido para ser utilizado na implementação deste trabalho. Uma descrição mais detalhada sobre cada um desses modelos, bem como suas aplicações típicas, podem ser encontradas, *e.g.*, em Barreto (2002), Fausett (1994), Hakykin (2002) e Schalkoff (1997).

4 MÉTODO DE PESQUISA

Nesta seção são descritos os procedimentos metodológicos utilizados para a construção do modelo de redes neurais para previsão de preços de produtos agrícolas. Os passos utilizados estão de acordo com as recomendações de Hair et al. (2005), em que são apresentados cinco aspectos fundamentais envolvidos na utilização de um modelo de redes neurais para previsão: (i) preparação dos dados, (ii) definição da estrutura do modelo, (iii) estimativa do modelo, (iv) avaliação dos resultados do modelo e (v) validação do modelo.

Na preparação dos dados o primeiro aspecto a ser considerado é o tamanho da amostra. Nessa etapa é necessário definir a amostra de treino, utilizada para estimar os pesos, e uma amostra separada de validação para independentemente avaliar a habilidade preditiva do modelo. A partição da amostra original é baseada primariamente no tamanho exigido para as amostras de calibração e validação. De acordo com Hair et al. (2005), uma boa prática para estimar o tamanho da amostra é utilizar de 10 a 30 casos no conjunto de dados para calibração para cada peso estimado. O autor explica que, quando o número de pesos se aproxima muito do tamanho da amostra, pode ocorrer o chamado superajuste, tornando o modelo muito específico à amostra. O número de pesos está relacionado com o número de neurônios da camada de entrada, da camada escondida e da camada de saída. Uma rede, como a utilizada neste trabalho, com dois neurônios na camada de entrada, cinco neurônios na camada escondida e um neurônio na camada de saída possui 15 pesos ($2 \times 5 + 5 \times 1$). Desse modo, estimou-se, para o contexto deste trabalho, um número mínimo de 150 valores para a amostra de calibragem, utilizando-se, portanto, os dados restantes para validação do modelo. Os dados utilizados foram coletados a partir de uma base de dados secundária proveniente da Emater-RS. Essa base corresponde ao preço médio mensal pago ao produtor no estado do Rio Grande do Sul de janeiro de 1992 até dezembro de 2006 (totalizando 168 meses) para os seguintes produtos: boi gordo, soja, milho e trigo. A última etapa de preparação dos dados consistiu de análise de assimetria, não normalidade,

observações atípicas (*outliers*) e normalização dos valores (todos os valores coletados foram normalizados para valores entre 0 e 1 para melhorar a velocidade e a precisão de treinamento).

A segunda etapa metodológica consistiu na definição da estrutura do modelo. Como o objetivo deste trabalho é realizar a previsão de preço sempre para o mês seguinte ($t+1$) a partir dos dois meses anteriores (t e $t-1$), a definição da estrutura do modelo ficou restrita a determinar o número de neurônios das camadas intermediárias, uma vez que fica estabelecido, a partir dos objetivos, que o número de neurônios da camada de entrada é dois e que o número de neurônios da camada de saída é um. Segundo Hair et al. (2005), apesar de haver a possibilidade de utilizar múltiplas camadas intermediárias, há consenso na utilização de apenas uma camada intermediária (ou escondida), uma vez que uma segunda camada pode acarretar, além de um superajuste dos dados, um aumento do tempo necessário para estimar os resultados. Portanto, nesta etapa de trabalho, o problema passou a ser estimar o melhor número de nós na camada oculta. Várias redes com diferentes quantidades de neurônios na camada oculta foram treinadas até que se encontrasse a melhor configuração. A seleção da melhor configuração foi feita com base no RMSE, conforme Tabela 1. Como pode ser observado, a configuração que apresentou o melhor RMSE médio durante os testes foi aquela com 5 nós na camada oculta, portanto, essa configuração passou a ser utilizada durante todos os experimentos realizados com o modelo desenvolvido.

Tabela 1 – RMSE para diferentes configurações de rede neural

Rede Produto	2-3-1	2-5-1	2-9-1	2-12-1
Soja	0,00359160	0,00360336	0,00346694	0,00355879
Boi gordo	0,00405874	0,00405874	0,00495829	0,00451003
Milho	0,00528765	0,00521627	0,00521928	0,00525511
Trigo	0,00237395	0,00229848	0,00230511	0,00232999
Média	0,00382799	0,00379421	0,00398741	0,00391348

Fonte: Elaborado pelos autores.

A terceira etapa metodológica corresponde à estimação do modelo, envolve buscar o melhor ajuste do modelo sem supertreinar a rede à amostra, ou seja, busca-se um modelo generalizável. Neste trabalho observaram-se duas importantes recomendações de Hair et al. (2005): (i) utilizar um limite mínimo de erro e parar de treinar a rede quando esse valor for atingido; conforme pode ser visualizado na Tabela 1, utilizou-se um limite de erro 0.025; (ii) monitorar a taxa de erro para as amostras de calibração e validação. Quando a rede começa a ser treinada, o ajuste melhora para ambas as amostras à medida que os pesos são calibrados. Em algum ponto, o erro da amostra de validação vai estabilizar e

talvez até começar a aumentar, divergindo da amostra de calibração. Nesse ponto, pode-se dizer que a amostra está supertreinada, fato, portanto, que deve ser evitado.

A avaliação dos resultados obtidos com a rede neural (quarta etapa da metodologia) consiste em determinar a precisão do nível de previsão obtido nas variáveis de saída. Neste trabalho, utilizou-se como medida de avaliação dos resultados a raiz do erro quadrado médio (RMSE), o coeficiente de desigualdade de Theil, o R^2 e o erro médio percentual absoluto (MAPE). Hair et al. (2005) sugerem que uma faixa de valores entre 0,05 e 0,08 para o RMSE é um intervalo aceitável, mas Schalkoff (1997) sugere que tanto para o RMSE como para o coeficiente de desigualdade de Theil e para o MAPE se procure alcançar os menores valores possíveis. Para o R^2 procura-se valores próximos de 1, os quais indicam que a rede apresenta elevada capacidade preditiva.

Por fim, a quinta etapa consistiu na validação do modelo, cujo objetivo é garantir que a solução encontrada é a melhor possível e que ela é tão generalizável quanto possível. Para garantir esses aspectos, utilizaram-se diferentes produtos agrícolas, com diferentes amplitudes de preço no que se refere aos preços mínimos e máximos.

5 APRESENTAÇÃO DOS RESULTADOS

Esta seção apresenta os resultados obtidos com o presente trabalho. O modelo foi implementado em linguagem Java, os dados de testes e validação são informados ao modelo em arquivo específico e as simulações executadas em um microcomputador com dois processadores Intel® T2300 de 1.6 Ghz e memória RAM de 2 Gb. Além da estrutura de redes neurais descrita na seção anterior (2-5-1), podem-se destacar os seguintes parâmetros do modelo: (1) critério de parada do algoritmo: 10.000 ciclos ou $MSE < 0.005$, o que ocorrer primeiro; (2) taxa de aprendizado = 0.8; (3) tamanho da amostra de treino: 140; (4) tamanho da amostra de validação: 20.

No decorrer desta seção apresentam-se inicialmente, para cada caso, as estatísticas utilizadas para a etapa de treinamento e, posteriormente, serão apresentados os resultados obtidos na etapa de validação do modelo desenvolvido. Nos gráficos apresentados, as ordenadas (eixo Y) representam a variação dos preços e as abscissas (eixo X) representam o número de amostras utilizadas.

A primeira *commoditie* avaliada foi a soja. Na amostra de treino, o menor valor do preço da saca de soja no período em análise foi de R\$ 7,50 e o maior valor foi R\$ 52,87. O RMSE para a amostra de treino foi de 0,0027573799. Após a etapa de treinamento, realizou-se a etapa de validação

da previsão gerada pelo modelo, conforme apresentado na Figura 4. Nessa etapa de validação conseguiu-se atingir uma diferença média de R\$ 1,190484 entre o preço real e o preço da soja estimado pelo modelo. O RMSE para a amostra de validação foi de 0,0049063267, o coeficiente de Theil foi de 0,0257179, o R^2 foi de 0,91097 e o MAPE foi 4,37%.

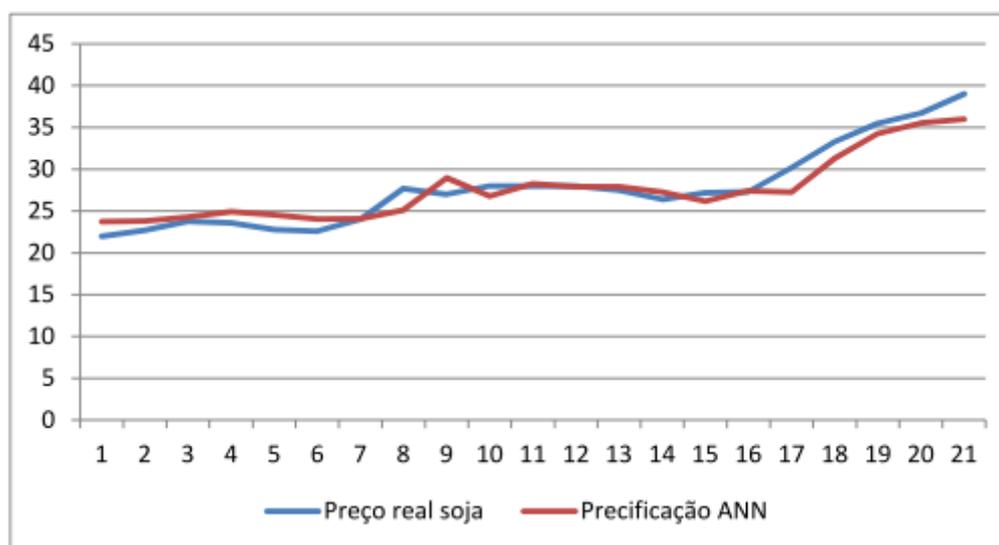


Figura 4 – Validação do modelo para previsão do preço da soja

Fonte: Elaborado pelos autores.

A segunda *commoditie* avaliada com o modelo foi o milho. Na fase de treinamento, o menor valor mínimo do preço do milho foi de R\$ 4,50 e o valor máximo foi R\$ 27,30. O RMSE para a amostra de treino foi de 0,0049247105. A etapa de validação da previsão do preço do milho gerada pelo modelo, conforme apresentado na Figura 5, gerou uma diferença média de R\$ 0,942674 entre o preço real e o preço estimado pelo modelo. O RMSE calculado para a amostra de validação foi de 0,007656769, o coeficiente de Theil obtido foi de 0,040514, o R^2 foi de 0,772965 e o MAPE foi de 6,29%.

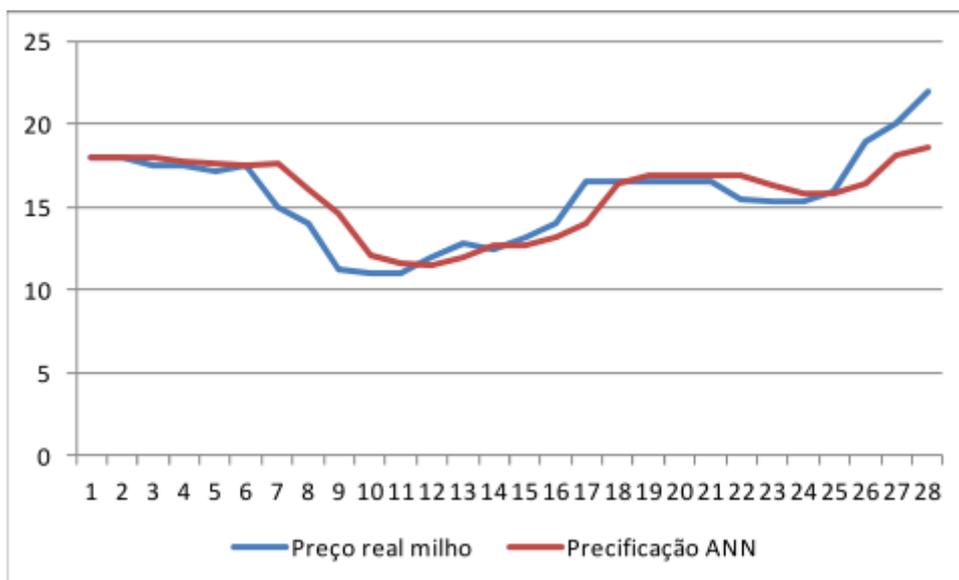


Figura 5 – Validação do modelo para previsão do preço do milho
 Fonte: Elaborado pelos autores.

A terceira *commoditie* avaliada com o modelo foi o boi gordo (preço dado em quilogramas). Nesse período, o menor valor foi R\$ 0,65 e o valor máximo foi R\$ 2,0. O RMSE para a amostra de treino foi de 0,00506369878. A Figura 6 apresenta os resultados obtidos na etapa de validação da previsão do preço do boi gordo gerado pelo modelo, houve uma diferença média de R\$ 0,0828892 entre o preço real e o preço estimado pelo modelo. O RMSE para a amostra de validação foi de 0,0073286638, o coeficiente de Theil foi de 0,033101, o R^2 foi de 0,6923 e o MAPE foi de 5,73%.

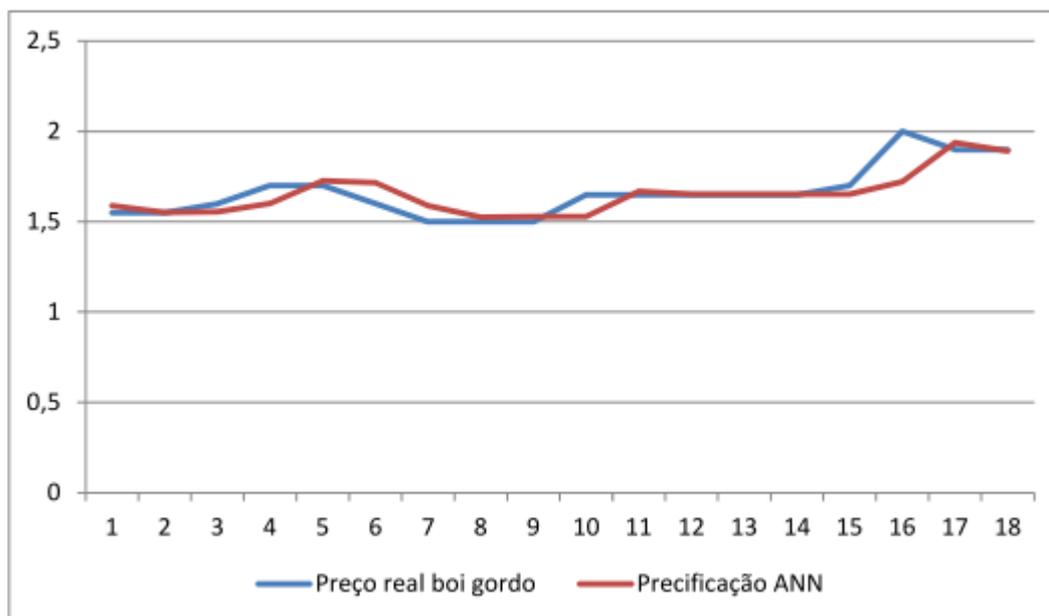


Figura 6 – Validação do modelo para previsão do preço do boi gordo
 Fonte: Elaborado pelos autores.

O último experimento realizado para demonstrar a aplicabilidade do modelo de redes neurais desenvolvido, bem como para demonstrar sua generalidade de aplicação a diferentes *commodities*, diz respeito ao preço do trigo. No período considerado, o valor da saca teve R\$ 6,50 como o menor valor e R\$ 38,50 como o maior valor pago ao produtor, em média. O RMSE para a amostra de treino foi de 0,0032161487 na etapa de treinamento da rede. A Figura 7 apresenta os resultados obtidos na etapa de validação da previsão do preço do trigo gerado pelo modelo, uma diferença média de R\$ 1,201756 entre o preço real e o preço estimado pelo modelo. O RMSE para a amostra de validação foi de 0,005625062485, o coeficiente de Theil foi de 0,040849, o R^2 foi de 0,870033 e o MAPE foi de 5,35%.

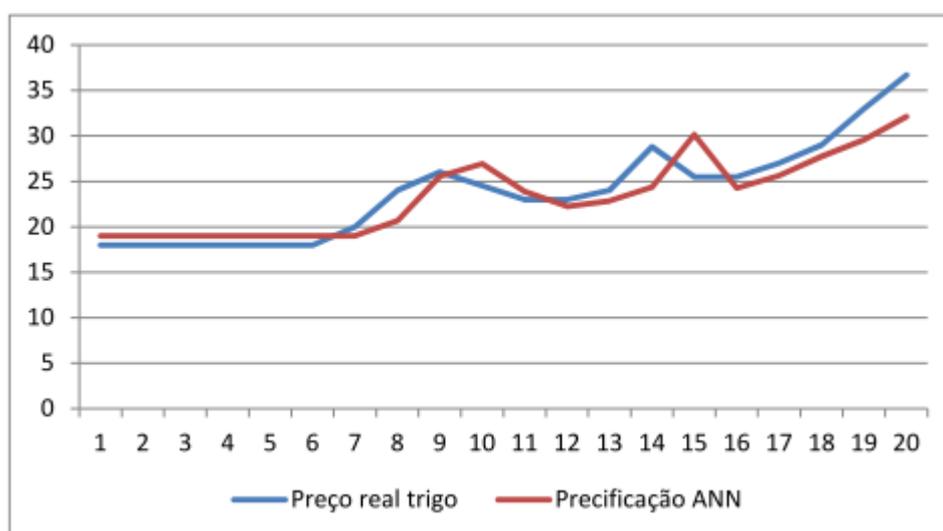


Figura 7 – Validação do modelo para previsão do preço trigo

Fonte: Elaborado pelos autores.

Por fim, apresenta-se, na Tabela 2, um resumo dos valores estatísticos obtidos ao longo dos experimentos realizados com o modelo. Os valores estatísticos encontrados ficaram dentro dos valores buscados no momento que se projetou a rede neural, pois Fausett (1994), um dos autores utilizados como referência ao longo deste trabalho, estabelece um nível de precisão dado pela seguinte equação: $e = 1 - W / P$, em que W é o número de pesos e P é o número de dados utilizados para treino. Portanto, como na rede neural utilizada neste trabalho tem-se que $W=15$ e $P=150$, chega-se a uma medida estimada para e de 0,9 ou 90%, ou seja, trabalha-se com uma margem de erro de 10% para o MAPE.

Tabela 2 – Resumo estatístico dos resultados

Estatística Produto	R²	MAPE	RMSE	Theil
Soja	0,910970	4,37 %	0,004906326	0,025717
Milho	0,772965	6,29 %	0,007656769	0,040514
Boi Gordo	0,692300	5,73 %	0,0073286638	0,033101
Trigo	0,870033	5,35 %	0,0056250624	0,040849
Média	0,811567	4,86 %	0,006379000	0,035045

Fonte: Elaborado pelos autores.

Portanto, considerando (1) que o PIB agropecuário brasileiro está crescendo continuamente na composição do PIB total do país; (2) que há a necessidade de se vislumbrar perspectivas futuras às cadeias produtivas que o compõe, bem como em melhorias na gestão do agronegócio nacional; (3) que as unidades que compõem as cadeias produtivas do setor primário similarmente às empresas dos outros setores também buscam sua eficiência e eficácia; e (4) que as decisões são sempre baseadas em informações, verifica-se, por meio dos resultados apresentados nesta seção, que o modelo proposto é uma boa alternativa para predição de preços futuros e para apoio da decisão no contexto do agronegócio brasileiro.

Em outras palavras, conforme supracitado, esses resultados fornecem indicativos de que o modelo estudado pode ser considerado como uma ferramenta alternativa ao cotidiano dos gestores do *agrobusiness*, uma vez que há uma revolução tecnológica e administrativa no campo, onde, muitas vezes, se vislumbra o mercado externo por se constatar vantagem competitiva no mercado nacional, e conseqüentemente impulsionar a busca por novas tecnologias e técnicas de gestão e decisão e com isso aumentar o potencial competitivo.

6 CONSIDERAÇÕES FINAIS

Este trabalho apresentou a definição e validação de um modelo de redes neurais para precificação de *commodities* agrícolas. A concepção do modelo passou pelas fases de preparação dos dados, definição da estrutura do modelo, estimativa do modelo, avaliação dos resultados do modelo e validação do modelo.

Os resultados obtidos podem ser considerados bastante relevantes, pois se demonstrou através das estatísticas R², coeficiente de Theil, RMSE e MAPE que o modelo apresenta uma alta capacidade preditiva, podendo, portanto, afirmar-se que a prática do uso de redes neurais artificiais pode ser

agregada ao processo decisório referente ao comportamento dos preços de *commodities* agrícolas e, conseqüentemente, a uma clarificação quantitativa a respeito dos riscos e incertezas que essa ação envolve. Além disso, pode-se verificar que a estratégia apresentada neste trabalho é uma boa alternativa aos métodos estatísticos tradicionais para previsão de séries temporais, tais como média móvel, suavização exponencial, filtragem adaptativa, ARIMA, entre outros.

Uma interessante alternativa, a ser explorada futuramente, para previsão de preços no contexto do agronegócio é o emprego de técnicas de elaboração de cenários com a utilização da internet. A técnica do *delphi* eletrônico pode ser utilizada para pesquisar tendências de preços futuros de *commodities*, especialmente quando se imaginam fortes possibilidades de ruptura das condições presentes. Os custos menores, tempo mais curto e maior abrangência envolvendo pontos de vista de diversos tipos de especialistas são grandes vantagens da utilização dessa outra abordagem (Giovinazzo & Fischmann, 2001).

Por fim, vale destacar ainda que em uma economia globalizada parece importante que as empresas brasileiras busquem entender o comportamento do mercado internacional de *commodities* agrícolas, principalmente com o objetivo de buscar maior competitividade. Logo, buscar estudos e pesquisas sobre esse fenômeno parece ser fonte enriquecedora para avaliação estratégica, de tomada de decisões, e, claro, da utilização de redes neurais artificiais para além da precificação.

Sob essa ótica, a observação do Ministro Ronaldo Mota Sardenberg de que “[...] os cenários não são predições sobre o que irá acontecer, mas descrições, com base em hipóteses plausíveis, do que poderá acontecer” (Marcial & Grumbach, 2002, p. 12) vale também para as constatações supracitadas, de que o futuro não pode ser predeterminado, mas deve ser prospectado.

REFERÊNCIAS

- Barreto, J. M. (2002). *Introdução às redes neurais artificiais*. Florianópolis: UFSC.
- Bazerman, M. H. (2004). *Processo decisório: para cursos de administração e economia*. Rio de Janeiro: Elsevier.
- Bernhardt, A. (2004). *O processo de tomada de decisão na percepção da coalizão dominante formal: um estudo de caso na Estobel*. Florianópolis: EPS/UFSC.

- Black, M. D. (2007). *Applying perceptrons to speculation in computer architecture*. Doctoral Dissertation, University of Maryland, College Park, Baltimore, USA.
- Byrns, R. T., & Stone, Jr., G. W. (1995). *Macroeconomia*. São Paulo: Makron Books.
- Ceretta, P. S., Righi, P. B., & Schlender, S. G. (2010). Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. *Informações Econômicas*, 40(9), 15-27.
- Chen, T. (2011). A hybrid fuzzy and neural approach for DRAM price forecasting. *Computers in Industry*, 62(2), 196–204.
- Chun, W. C. (1998). *The knowing organization: how organizations use information to construct meaning, create knowledge, and make decisions*. Oxford: Oxford University Press.
- Clemen, R. T., & Reilly, T. (2001). *Making hard decisions with decision tools*. Belmont: Duxbury.
- Corsine, F. P., & Ribeiro, C. O. (2008). Dinâmica e previsão de preços de commodities agrícolas com o filtro de Kalman. *Anais do Encontro Nacional de Engenharia de Produção*, Rio de Janeiro, RJ, Brasil, 28.
- Costa, B. K., & Almeida, M. I. R. (Coords.). (2002). *Estratégia: perspectivas e aplicações*. São Paulo: Atlas.
- Eddy, P. R., Smith, A. M., Hill, B. D., Peddle, D. R., Coburn, C. A., & Blackshaw, R. E. (2008). Hybrid segmentation: artificial neural network classification of high resolution hyperspectral imagery for site-specific herbicide management in agriculture. *Photogrammetric Engineering & Remote Sensing*, 74(10), 1249–1257.
- Eisenhardt, K. M., & Zbaracki, M. J. (1992). Strategic decision making. *Strategic Management Journal*, 13(S2), 17-37.
- Farina, E. M. M. Q. (2000). Organização industrial no agribusiness. In D. Zylbersztajn, & M. F. Neves (Orgs.), *Economia e gestão dos negócios agroalimentares* (pp. 39-60). São Paulo: Pioneira.
- Fausett, I. V. (1994). *Fundamentals of neural networks: architectures, algorithms and applications*. New Jersey: Prentice-Hall.
- Galbraith, J. K. (1988). *A economia e o interesse público*. São Paulo: Pioneira.
- Giovinazzo, R. A., & Fischmann, A. A. (2001). Delphi eletrônico – uma experiência de utilização da metodologia de pesquisa e seu potencial de abrangência regional. *Anais do Congresso Latino Americano de Estratégia*, 2001, Buenos Aires, Argentina, 14.
- Gomes, G. S. S., Ludermir, T. B., & Lima, L. M. M. R. (2011). Comparison of new activation functions in neural network for forecasting financial time series. *Neural Computing & Application*, 20(3), 417–439.

- Hair, J. F., Jr., Anderson, R. E., Tatham, R. L., & Black, W. C. (2005). *Análise multivariada de dados* (5a ed.). Porto Alegre: Bookman.
- Hakykin, S. (2002). *Redes neurais - princípios e prática* (2a ed.). Porto Alegre: Bookman.
- Howard, R. A. (1989). The evolution of decision analysis. In R. A. Howard, & J. E. Matheson (Eds.), *Readings on the principles and applications of decision analysis* (pp. 5-16). Menlo Park: Strategic Decision Group.
- Instituto Brasileiro de Geografia e Estatística. (2011). *Pesquisa geral no site*. Recuperado em 13 de dezembro, 2011, de <http://www.ibge.gov.br>.
- Kankal, M., Akpinar, A., Kömürçü, M. I., & Özsahin, T. S. (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927–1939.
- Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664–2675.
- Lacombe, F. J. M., & Heilborn, G. L. J. (2003). *Administração: princípios e tendências*. São Paulo: Saraiva.
- Langley, A., Mintzberg, H., Pitcher, P., Posada, E., & Saint-Macary, J. (1995). Opening up decision making: the view from the black stool. *Organization Science*, 6(3), 260-279.
- Lima, R. C., Gois, M. R., & Ulises, C. (2007). Previsão de preços futuros de commodities agrícolas com diferenciações inteira e fracionária, e erros heteroscedásticos. *Revista de Economia e Sociologia Rural*, 45(3), 621-644.
- Loesch, C., & Sari, S. T. (1996). *Redes neurais artificiais: fundamentos e modelos*. Blumenau: FURB.
- March, J. G. (1994). *A primer on decision making: how decisions happen*. New York: The Free Press.
- Marcial, E. C., & Grumbach, R. J. S. (2002). *Cenários prospectivos: como construir um futuro melhor*. Rio de Janeiro: FGV.
- Melo, B., Milioni, A. Z., & Nascimento, Jr., C. L. (2007). Daily and monthly sugar price forecasting using the mixture of local expert models. *Pesquisa Operacional*, 27(2), 235-246.
- Ministério do Desenvolvimento Indústria e Comércio Exterior. (2011). *Pesquisa geral no site*. Recuperado em 12 de dezembro, 2011, de <http://www.mdic.gov.br/sitio/>.
- Papadakis, V. M., Lioukas, S., & Chambers, D. (1998). Strategic decision-making processes: the role of management and context. *Strategic Management Journal*, 19(2), 115-147.

- Ribeiro, C. O., Sosnoski, A. A. K. B., & Oliveira, S. M. (2010). Um modelo hierárquico para previsão de preços de commodities agrícolas. *Revista Produção Online*, 10(4), 719-733.
- Schalkoff, R. J. (1997). *Artificial neural networks*. New York: McGraw-Hill.
- Shimizu, T. (2006). *Decisão nas organizações* (2a ed.). São Paulo: Atlas.
- Simon, H. A. (1972). *A capacidade de decisão e de liderança* (2a ed.). Rio de Janeiro: Cultura.
- Singhal, D., & Swarup, K. S. (2011). Electricity price forecasting using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, 33(3), 550–555.
- Sobreiro, V. A., Araujo, P. H. S. L., Mendonça, M. M., & Nagano, M. S. (2008). Uma estimação do valor da commodity de açúcar utilizando redes neurais artificiais. *Pesquisa & Desenvolvimento em Engenharia de Produção*, 7, 36-52.
- Sobreiro, V. A., Araujo, P. H. S. L., & Nagano, M. S. (2009). Precificação do etanol utilizando técnicas de redes neurais artificiais. *Revista de Administração*, 44(1), 46-58.
- Wong, W. K., Xia, M., & Chu, W. C. (2010). Adaptive neural network model for time-series forecasting. *European Journal of Operational Research*, 207(2), 807–816.
- Yonenaga, W. H., & Figueiredo, R. S. (1999). Previsão do preço da soja utilizando redes neurais. *Anais do Encontro Nacional de Engenharia de Produção*, Rio de Janeiro, RJ, Brasil, 19.
- Zou, P.; Yang, J., Fu, J., Liu, G., & Li, D. (2010). Artificial neural network and time series models for predicting soil salt and water content. *Agricultural Water Management*, 97(12), 2009–2019.

THE USE OF ARTIFICIAL NEURAL NETWORKS AS A STRATEGY FOR FORECASTING PRICES IN THE CONTEXT OF AGRIBUSINESS

ABSTRACT

This paper presents an analysis of the use of artificial neural networks as a strategy for forecasting prices in the context of agribusiness. For this purpose, data were adopted from EMATER/RS (1992-2006) on four specific commodities: soybean, live cattle, corn, and wheat. The methodology adopted during the research followed the steps shown in Hair et al. (2005), using neural network perception. The data discussed demonstrate the possibility of using neural networks as a strategy for predicting the price of agricultural commodities in future markets. However, one should pay attention to the common cognitive bias in the process of decision making, as it is believed that a significant contribution to academia lies there, as well as a starting point for improving management decisions in rural business.

Key-words: Agribusiness; Decision-making; Artificial neural networks; Strategy; Pricing.

Data do recebimento do artigo: 15/05/2011

Data do aceite de publicação: 22/08/2011