

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

Luciano Ferreira<sup>1,3</sup>

Gilnei Luiz de Moura<sup>2,3</sup>

Denis Borenstein<sup>1</sup>

Adalberto A. Fischmann<sup>2</sup>

Fabio Dal-Soto<sup>3</sup>

[lferreira@unicruz.edu.br](mailto:lferreira@unicruz.edu.br)

[gilneilm@usp.br](mailto:gilneilm@usp.br)

[denisb@ufrgs.br](mailto:denisb@ufrgs.br)

[aafischm@usp.br](mailto:aafischm@usp.br)

[fsoto@unicruz.edu.br](mailto:fsoto@unicruz.edu.br)

1 UFRGS, Escola de Administração/PPGA – Porto Alegre, RS, Brasil

2 USP, Faculdade de Economia, Administração e Contabilidade/PPGA - São Paulo, SP, Brasil

3 Universidade de Cruz Alta (UNICRUZ) - Cruz Alta, RS, Brasil

## 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 et al. (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, tenha-se que 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: Agribusiness. Tomada de Decisões. Redes Neurais Artificiais. Estratégia.

## 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). Galbraith (1988, p.3) aponta que,

“[...] 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.”

Byrns e Stone Jr. (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”. Nesta 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 (HOLANDA, 1987).

Em se tratando especificamente do Setor Primário, Rossi e Neves (2004) apontam que o Brasil detém quase 20% da área agricultável do mundo e utiliza apenas 10% a 20% de seu potencial. Para Ministro da Agricultura do Brasil, Roberto Rodrigues, “o agronegócio é, sem sombra de dúvida, o mais importante setor de toda a economia nacional: vale 29% do PIB, gera 37% de todos os empregos no país e responde por 42% das exportações totais, sendo superavitário sistematicamente” (Rodrigues *in* ROSSI; NEVES, 2004, p. 21).

De acordo com dados do IBGE a comparação do PIB total e do PIB Agropecuário em valores correntes apresenta um crescimento considerável. A Tabela 1 apresenta esta comparação no período de 1991 a 2004.

Tabela 1. Brasil: PIB e PIB Agropecuário – Valores correntes (Milhões de UMC<sup>1</sup>)

Ano/Trimestre	PIB total	PIB Agropecuário
1991	165.786	11.342
1992	1.762.637	119.967
1993	38.767	2.628
1994	349.205	30.458
1995	646.192	51.493
1996	778.887	58.811
1997	870.743	62.109
1998	914.188	67.550
1999	973.846	71.856
2000	1.101.255	78.258
2001	1.198.736	89.287
2002	1.346.028	104.908
2003	1.556.182	138.191
2004	1.766.621	159.643

Fonte: IBGE – Sistema de Contas Nacionais Trimestrais ([www.ibge.gov.br](http://www.ibge.gov.br)), 2005.

Notas: <sup>1</sup> Unidade monetária corrente - Do 1º/1991 ao 4º/1992, 1991 e 1992: milhões de Cruzeiros.

Do 1º/1993 ao 4º/1993 e 1993: milhões de Cruzeiros Reais.

Do 1º/1994 (1994) em diante: milhões de Reais.

Note-se que tanto na afirmação do Ministro como nos dados do IBGE há certa conformidade em relação à importância desse setor econômico para a economia brasileira, apesar dos dados do IBGE serem menos generosos que a percepção do Ministro.

Os dados da Tabela 1 consideram diferentes unidades financeiras correntes, portanto para melhor constatar o crescimento real da relação do PIB agropecuário com o PIB Total esboça-se o Gráfico 1.




Gráfico 1. Variação PIB Agropecuário em relação ao PIB Total

Fonte: Dados adaptados do IBGE, 2005.

Pautando-se na concepção de que o PIB agropecuário brasileiro está num crescente contínuo na composição do PIB Total do país, e que há a necessidade de se vislumbrar perspectivas futuras às cadeias produtivas que o compõe, bem como de melhorias à gestão do *agribusiness* nacional, tem-se que o termo cadeia produtiva refere-se a um “conjunto de agentes econômicos que possuem parte relevante dos seus negócios na produção de determinado produto ou serviço” (Garcia *apud* NEVES & ROSSI, 2004, p.3).

Por sua vez, as unidades que compõe as cadeias produtivas do setor primário (Ex. 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 poder haver certo *gap* entre a elaboração e a execução estratégicas é alta.

Frisa-se que é premissa básica que o ser humano tem vários desejos e necessidades, e, portanto, está constantemente no dilema de optar, consciente ou inconscientemente, por atitudes, ações e caminhos que os minimize e/ou os satisfaça. Ao partir-se dessa concepção, faz-se necessário ter-se claro que as decisões são sempre baseadas em informações, e que na sociedade atual a informação é abundante, *i.e.*, exige a necessidade de o pensamento crítico se tornar ainda mais relevante, e que se alie a busca do conhecimento à busca de resultados (TERRA, 2001).

É considerada uma boa decisão a decisão lógica, com base em 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; FREITAS *et al.*, 1997).

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 frente a diferentes situações e sob diferentes perspectivas.

Do ponto de vista normativo, Clemen e Reilly (2001) reforçam que a boa decisão é resultado de todo 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 o 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 e HEILBORN, 2003).

Diante deste contexto, verifica-se a necessidade premente de ferramentas que auxiliem a gestão do *agribusiness*, seja no planejamento de suas atividades, seja na tomada de decisões de seus gestores (BRESSAN, 2004). Neste sentido, esse artigo almeja levantar uma proposta que explique o comportamento dos preços de produtos agrícolas e possibilite traçar o comportamento futuro desses produtos, de forma a ser uma alternativa palpável aos gestores que necessitam na maioria das vezes tratar de negociações em mercados futuros.

O objetivo específico do presente trabalho consiste em apresentar uma metodologia de previsão de preço de algumas *commodities* agrícolas, mais especificamente de quatro produtos: o boi gordo, a soja, o milho e o trigo. Para tanto, a partir de dados coletados junto à base da Emater-RS (1992-2006), e pautando-se na metodologia de Hair *et al.* (2005), escolheu-se o modelo de rede neural *perception* multicamadas para implementação desse objetivo. Desta forma, buscou-se a configuração que apresentasse o melhor RMSE (raiz do erro quadrado médio) médio durante os testes.

## 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 velocidade 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 vêm-se às voltas com o problema de prosperar o futuro e especular sobre as tendências do ambiente econômico, setorial e empresarial”. (Giovinazzo e Fischmann *in* COSTA; ALMEIDA, 2002, p. 231)

Neste 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 a idéia 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) conseqüências (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 neste ponto que podem surgir os vieses de Bazerman (2004).

Langley *et al.* (1995) observam que a decisão possui algumas ambigüidades 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 *et al.* (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 advêm 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).

Neste 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.

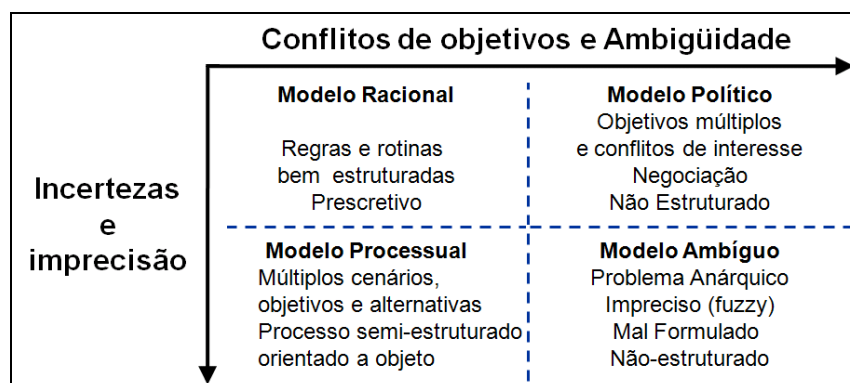


Figura 1. Classificação dos problemas de decisão

Fonte: Adaptado de CHOO, G. W. The knowing organization.

Oxford: Oxford University Press, 1998. In: Shimizu, 2006, p. 34.

Com o advento e avanço da tecnologia da informação e dos sistemas inteligentes, uma ferramenta passou a ser típica para tomada de decisão: a idéia 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 pré-determinado, e o resultado relativo àquele modelo se torna uma predição. Esta predição pode ser incrementada ou descartada pelo tomador de decisões. É neste amálgama que os estudos de redes neurais fluem como alternativas e/ou somatórias aos tomadores de decisão (BLACK, 2007).

As redes neurais, enquanto ramo da inteligência artificial, já têm apresentado resultados expressivos “em tarefas que envolvam previsão e classificação”, uma vez que, “[...] possuem a capacidade de generalização, adaptação, correlação e aprendizado, o que facilita o tratamento com séries temporais [...] podem extrair as características mais importantes da série, como sazonalidade, tendência, etc.” (YONENAGA; FIGUEIREDO, 1999, p. 1).

### 3. REDES NEURAIS 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 nem entrada nem de saída, os quais são conhecidos como neurônios internos. Estes neurônios internos à rede têm grande importância, conhecidos na literatura como “*hidden*”, fazendo 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 estão as funções sigmóide, linear, passo e a logística.




Figura 2. Modelo de um neurônio  
Fonte: Dos autores, 2008

Desse modo, uma rede neural passa a ser formada por um arranjo seqüencial 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, onde a performance é medida antes e depois do treinamento. A diferença indica o quanto se aprendeu (LOESCH e 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 se chama de treino do sistema em um modo de aprendizado supervisionado, onde 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 desse 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 desse trabalho. Uma descrição mais detalhada sobre cada um desses modelos, bem como suas aplicações típicas, podem ser encontradas, *e.g.*, em Fausett (1994), Schalkoff (1997), Hakykin (2002), Barreto (2002).

#### 4. METODOLOGIA

Nessa 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), onde 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 super ajuste, 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 nesse trabalho, com dois neurônios na camada de entrada, cinco neurônios na cada escondida e um neurônio na camada de saída possui 15 pesos ( $2 \times 5 + 5 \times 1$ ). Desse modo, estimou-se, para o contexto desse 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 a partir 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 precisão de treinamento).



A segunda etapa metodológica consistiu na definição da estrutura do modelo. Como o objetivo desse 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 super ajuste dos dados, um aumento do tempo necessário para estimar os resultados. Portanto, nessa 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 2. 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 2. RMSE para diferentes configurações de rede neural

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

Fonte: Dos Autores, 2008.

A terceira etapa metodológica corresponde à estimação do modelo, envolve buscar o melhor ajuste do modelo sem super treinar a rede à amostra, ou seja, busca-se um modelo generalizável. Nesse 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 2, utilizou 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 irá melhorar para ambas as amostras e 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 super treinada, fato, portanto, que deve ser evitado.

A avaliação dos resultados obtidos com a rede neural (quarta etapa da metodológica) consiste em determinar a precisão do nível de previsão obtido nas variáveis de saída. Nesse 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

Essa seção apresenta os resultados obtidos com o presente trabalho. Inicialmente serão apresentados os resultados obtidos na fase de treinamento e posteriormente serão apresentados os resultados obtidos na etapa de validação do modelo desenvolvido. Note-se que nos gráficos apresentados nas Figuras 4 a 11 as ordenadas (eixo Y) representam a variação dos preços e as abscissas (eixo X) representam o número de amostras utilizadas para treino e para validação.

A Figura 4 apresenta o resultado do treinamento da rede neural para previsão do preço da soja, vale destacar que 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.

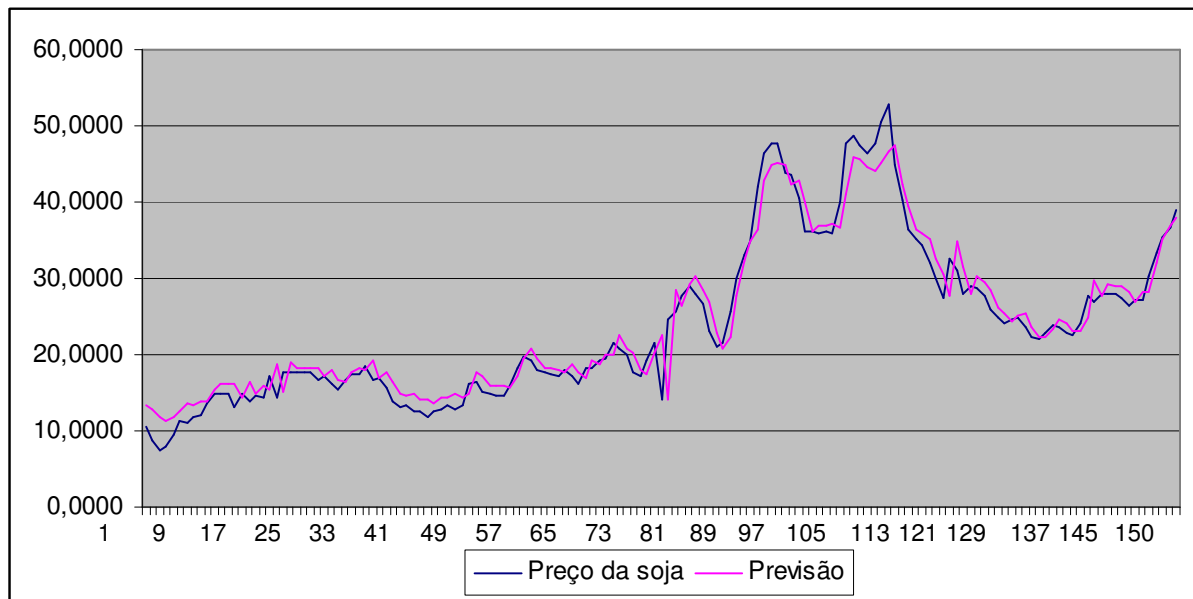


Figura 4. Resultado do treinamento da rede para preço da soja

Fonte: Dos autores, 2008.

Após a etapa de treinamento, realizou-se a etapa de validação da previsão gerada pelo modelo, conforme apresentado na Figura 5. 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%.

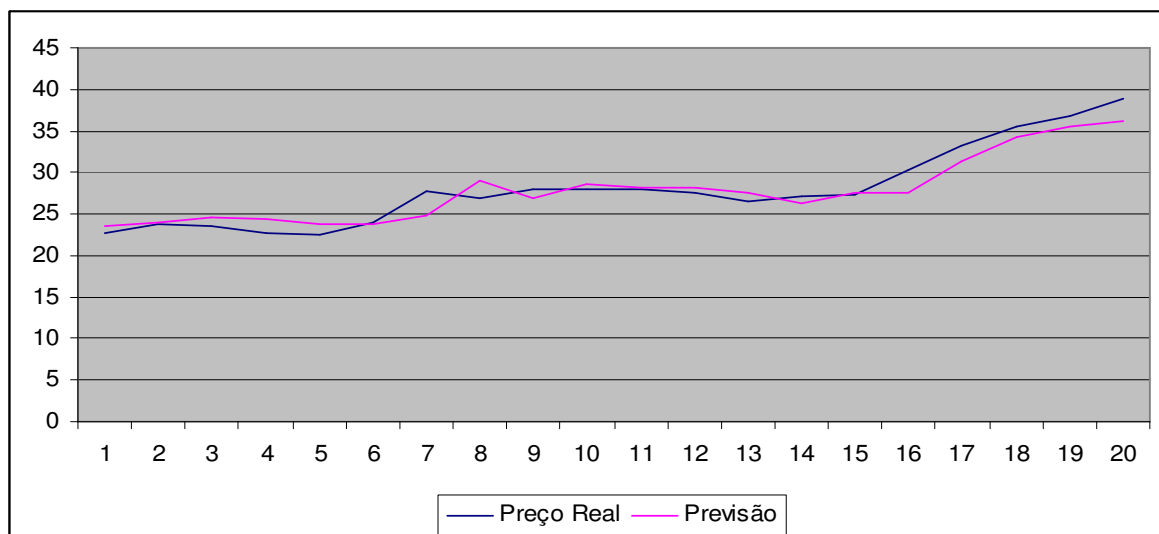


Figura 5. Validação do modelo para previsão do preço da soja  
Fonte: Dos Autores, 2008.

A Figura 6 apresenta o resultado do treinamento da rede neural para previsão do preço do milho. Nesse período, 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.




Figura 6. Resultado do treinamento da rede para preço do milho  
Fonte: Dos autores, 2008.

A etapa de validação da previsão do preço do milho gerada pelo modelo, conforme apresentado na Figura 7 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%.

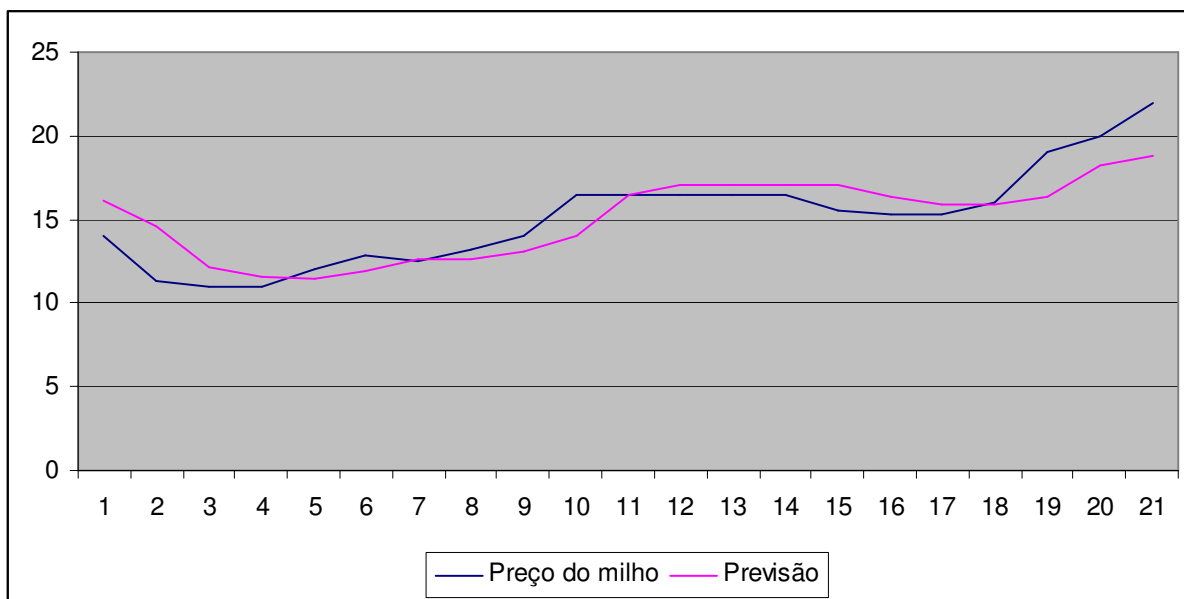


Figura 7. Validação do modelo para previsão do preço do milho  
Fonte: Dos autores, 2008.

A Figura 8 apresenta o resultado do treinamento da rede neural para previsão do preço do boi gordo (preço dado em quilogramas). Nesse período, o menor valor mínimo do preço do milho foi de R\$ 0,65 e o valor máximo foi R\$ 2,0. O RMSE para a amostra de treino foi de 0,00506369878.




Figura 8. Resultado do treinamento da rede para preço do boi gordo  
Fonte: Dos autores, 2008

A Figura 9 apresenta os resultados obtidos na etapa de validação da previsão do preço do boi gordo gerado pelo modelo, 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%.

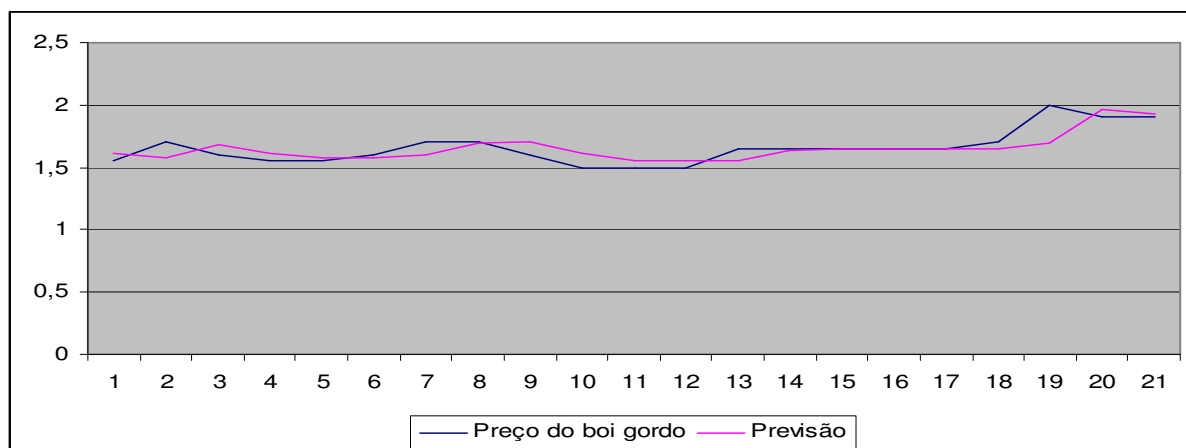


Figura 9. Validação do modelo para previsão do preço do boi gordo  
Fonte: Dos autores, 2008.

Por fim, o último experimento realizado para demonstrar a aplicabilidade do modelo de redes neurais desenvolvido para o contexto do agronegócio, bem como, para demonstrar sua generalidade de aplicação, 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. A Figura 10 apresenta os resultados da etapa de treinamento da rede. O RMSE para a amostra de treino foi de 0,0032161487.




Figura 10. Resultado do treinamento da rede para preço do trigo  
Fonte: Dos autores, 2008.

A Figura 11 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 11. Validação do modelo para previsão do preço do trigo  
Fonte: Dos autores, 2008.

Por fim, apresenta-se na Tabela 3, 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 referencia ao longo desse trabalho, estabelece um nível de precisão dado pela seguinte equação:  $e = 1 - W / P$ , onde  $W$  é o número de pesos e  $P$  é o número de dados utilizados para treino. Portanto, como na rede neural utilizada nesse 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 3. Resumo estatístico dos resultados

Produto \ Estatística	$R^2$	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: Dos autores, 2008.

## 6. CONSIDERAÇÕES FINAIS

A forma em que os dados foram apresentados leva a uma conclusão simples, porém relevante: a prática do uso de redes neurais artificiais pode ser agregada satisfatoriamente ao

processo decisório referente ao comportamento dos preços de algumas *commodities* agrícolas, e conseqüentemente, uma clarificação quantitativa a respeito dos riscos que essa ação envolve. Salienta-se que vieses cognitivos também podem se fazer presentes nos processos de tomadas de decisão nos ambientes das empresas rurais.

Contudo esse parecer é muito mais complexo do que parece, a boa decisão - minimização do risco - depende de vários outros fatores além do comportamento de uma série temporal de dados, como é o caso dessas *commodities*. Justamente, questões como as de precificação em mercados futuros certamente se farão presentes em futuras pautas de reunião de gestores rurais, talvez advindas de seus próprios *feelings*, ou talvez pela ação da globalização e concorrentes que passem a ofertar novas soluções para novos problemas a um mercado cada vez mais exigente.

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 desta outra abordagem (GIOVINAZZO e FISCHMANN, 2002) .

Nesta 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.” (Ministro Ronaldo Mota Sardenberg in MARCIAL & GRUMBACH, 2002: 12) vale também para as constatações supracitadas, de que o futuro não pode ser predeterminado, mas deve ser prospectado.

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.

## 7. REFERÊNCIAS

BARRETO, J. M. Introdução às redes neurais artificiais. Florianópolis: UFSC, 2002.

BAZERMAN, M. H. Processo decisório: para cursos de administração e economia. Rio de Janeiro: Elsevier, 2004.

BERNHARDT, A. O processo de tomada de decisão na percepção da coalizão dominante formal: um estudo de caso na Estobel. Florianópolis: EPS/UFSC, 2004.

BLACK, M. D. Applying perceptrons to speculation in computer architecture. University of Maryland, College Park, United States – Baltimore, 2007. Dissertation – University of Maryland.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. RAE-Eletrônica, v. 3, n. 1, Art. 9, 2004.

BYRNS, R. T.; STONE JR., G. W. Macroeconomia. São Paulo: MAKRON Books, 1995.

- CLEMEN, R. T.; REILLY, T. Making hard decisions with decision tools. Belmont, Duxbury, 2001.
- EISENHARDT, K. M.; ZBARACKI, M. J. Strategic decision making. *Strategic Management Journal*, Vol. 13, Winter, 1992, pp. 17-37.
- FAUSETT, I. V. Fundamentals of neural networks: architectures, algorithms and applications. New Jersey: Prentice-Hall, 1994.
- FREITAS, H. M. R.; BECKER, J. L.; KLADIS, C. M.; HOPPEN, N. Informação e decisão: sistemas de apoio e seu impacto. Porto Alegre: Ortiz, 1997.
- GALBRAITH, J. K. A economia e o interesse público. São Paulo: Pioneira, 1988.
- GIOVINAZZO, R. A.; FISCHMANN, A. A. Delphi eletrônico – uma experiência de utilização da metodologia de pesquisa e seu potencial de abrangência regional. In: COSTA, B. K.; ALMEIDA, M. I. R. (coordenadores). Estratégia: perspectivas e aplicações. São Paulo: Atlas, 2002.
- HAIR, Jr., J. F.; ANDERSON, R. E.; TATHAM, R. L. BLACK, W. C. Análise multivariada de dados. 5ª ed. Porto Alegre: Bookman, 2005.
- HAKYKIN, S. Redes neurais - princípios e prática. 2ª Ed. Porto Alegre: Bookman, 2002.
- HOLANDA, N. Planejamento e projetos: uma introdução às técnicas de planejamento e de elaboração de projetos. Fortaleza: Estrela, 1987.
- HOWARD, R. A. The evolution of decision analysis. In: Howard, R. A. et al. Readings on the principles and applications of decision analysis - Vol. I. California: Strategic Decision Group, p. 5-16, 1989.
- IBGE. Disponível em: <<http://www.ibge.gov.br>>.
- KUPLER, D. Competitividade da indústria brasileira: visão de conjunto e tendências de alguns setores. Baseado no relatório Síntese da Industriado Estudo da Competitividade da Indústria Brasileira (ECIB) – Consórcio liderado pelo Instituto de Economia Industrial da Universidade Federal do Rio de Janeiro (IEI/UFRJ), Instituto de Economia da Universidade de Campinas (IE/UNICAMP), Fundação Centro de Estudos de Comércio Exterior e Fundação Dom Cabral. Contrato entre o Ministério de Ciências e Tecnologia, a Financiadora de Estudos e Projetos (FINEP) e a Fundação de Economia de Campinas (FECAMP), no âmbito do Programa de Apoio ao Desenvolvimento Científico e Tecnológico (PADCT), 1993. Disponível em: <<http://www.ecoagencia.com.br>> Acesso 07 de nov. 2005.
- LACOMBE, F. J. M.; HEILBORN, G. L. J. Administração: princípios e tendências. São Paulo: Saraiva, 2003.
- LANGLEY, A.; MINTZBERG, H.; PITCHER, P.; POSADA, E.; SAINT-MACARY, J. Opening up decision making: the view from the black stool. *Organization Science*, Vol. 6, No. 3, May - Jun., 1995, pp. 260-279.
- LOESCH, C.; SARI, S. T. Redes neurais artificiais: fundamentos e modelos. Blumenau: FURB, 1996.

MARCH, J. G. A primer on decision making: how decisions happen. New York: The Free Press, 1994.

MARCIAL, E. C.; GRUMBACH, R. J. S. Cenários prospectivos: como construir um futuro melhor. Rio de Janeiro: Editora FGV, 2002.

PAPADAKIS, V. M.; LIOUKAS, Spyros; CHAMBERS, D. Strategic decision-making processes: the role of management and context. *Strategic Management Journal*, Vol. 19, No. 2, Feb., 1998, pp. 115-147.

ROSSI, R. M.; NEVES, M. F. (coordenadores). Estratégias para o trigo no Brasil. São Paulo: Atlas, 2004.

SCHALKOFF, R. J. Artificial neural networks. New York: McGraw-Hill, 1997.

SIMON, H. A. A capacidade de decisão e de liderança. 2. ed. Rio de Janeiro: Cultura, 1972.

SHIMIZU, T. Decisão nas organizações. 2. ed. São Paulo: Atlas, 2006.

TERRA, J. C. C. Gestão do conhecimento: o grande desafio empresarial: uma abordagem baseada no aprendizado e na criatividade. São Paulo: Negócio, 2001.

YONENAGA, W. H.; FIGUEIREDO, R. S. Previsão do preço da soja utilizando redes neurais. In: XIX ENEGEP - Encontro Nacional de Engenharia de Produção, Rio de Janeiro, 1999.