

A FEA e a USP respeitam os direitos autorais deste trabalho. Nós acreditamos que a melhor proteção contra o uso ilegítimo deste texto é a publicação online. Além de preservar o conteúdo motiva-nos oferecer à sociedade o conhecimento produzido no âmbito da universidade pública e dar publicidade ao esforço do pesquisador. Entretanto, caso não seja do interesse do autor manter o documento online, pedimos compreensão em relação à iniciativa e o contato pelo e-mail bibfea@usp.br para que possamos tomar as providências cabíveis (remoção da tese ou dissertação da BDTD).

**UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE
DEPARTAMENTO DE ADMINISTRAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO**

**REDES NEURAIS ARTIFICIAIS: UMA CONTRIBUIÇÃO NO PROCESSO DE
PREVISÃO DE PREÇOS DO AÇÚCAR E ÁLCOOL DO ESTADO DE SÃO PAULO**

Antonio Sérgio Torres Penedo

Orientador: Prof. Dr. Marcio Mattos Borges de Oliveira

SÃO PAULO

2005

Prof. Dr. Adolpho José Melfi
Reitor da Universidade de São Paulo

Profa. Dra. Maria Tereza Leme Fleury
Diretora da Faculdade de Economia, Administração e Contabilidade

Prof. Dr. Eduardo Pinheiro Gondim de Vasconcellos
Chefe do Departamento de Administração

Prof. Dr. Isak Kruglianskas
Coordenador do Programa de Pós-Graduação em Administração

T338.52
P398r
e.2

ANTONIO SÉRGIO TORRES PENEDO

DEDALUS - Acervo - FEA



20600028092

T338.52 P398r e.2
187694
20600028092



Powered by MidProStar - www.logprocess.com.br

**REDES NEURAIS ARTIFICIAIS: UMA CONTRIBUIÇÃO NO PROCESSO DE
PREVISÃO DE PREÇOS DO AÇÚCAR E ÁLCOOL DO ESTADO DE SÃO PAULO**

Dissertação apresentada ao Departamento de
Administração da Faculdade de Economia,
Administração e Contabilidade da
Universidade de São Paulo como requisito
para a obtenção do título de Mestre em
Administração.

Orientador: Prof. Dr. Marcio Mattos Borges de Oliveira

SÃO PAULO

2005

87694

87694

Dissertação defendida e aprovada, em 29.08.2005, no Programa de Pós-Graduação em Administração, pela seguinte comissão julgadora:

Prof. Dr. Marcio Mattos Borges de Oliveira

Prof. Dr. André Lucirton Costa

Prof. Dr. José Dutra de Oliveira Neto

FICHA CATALOGRÁFICA

Elaborada pela Seção de Publicações e Divulgação do SBD/FEA/USP

Penedo, Antonio Sérgio Torres

Redes neurais artificiais: uma contribuição no processo de previsão de preços do açúcar e álcool do estado de São Paulo / Antonio Sérgio Torres Penedo. -- São Paulo, 2005.

78 p.

Dissertação (Mestrado) – Universidade de São Paulo, 2005

Bibliografia.

1. Preço - Previsão 2. Redes neurais 3. Açúcar 4. Álcool I. Universidade de São Paulo. Faculdade de Economia, Administração e Contabilidade II. Título.

CDD – 338.52

Dedico este trabalho a minha mãe Irene Aparecida Barboza Torres Penedo, que com carinho e amor, sempre mostrou-me como enfrentar com coragem e paciência, quaisquer adversidades que se oponha à nossas vidas. Pelos conselhos a mim direcionados e por ser a minha principal fonte de incentivo.

AGRADECIMENTOS

Agradeço a Deus por atribuir minhas tarefas e permitir que eu as cumprisse.

Aos meus pais, Antonio Torres Penedo Netto e Irene Aparecida Barboza Torres Penedo, que nunca pouparam esforços para garantirem-me a possibilidade de seguir adiante em todas as etapas de minha vida.

As minhas irmãs, Renata Barbosa Torres Penedo e Raquel Barbosa Torres Penedo, que compreenderam os momentos de ausência e souberam contribuir com a serenidade, amor e carinho que sempre precisei.

Ao Prof. Dr. Marcio Mattos Borges de Oliveira, que me orientou com muita seriedade mantendo o bom humor e dedicação, muitíssimo obrigado. Em especial, agradeço a confiança que me foi concedida no início do trabalho, quando nem nos conhecíamos. Valeu, muito obrigado.

Um obrigado especial ao Prof. Dr. José Dutra de Oliveira Neto, que acompanhou grande parte desta dissertação, não poupando esforços para que o resultado final fosse o melhor possível.

À Sônia Borges de Oliveira que muito me ajudou durante o Mestrado, muito obrigado. Agradeço à Érika, Rita e ao Eduardo secretários de pós-graduação, pelo carinho e atenção.

Sou muito grato ao amigo Pedro Marcos Roma de Castro, que me acompanhou durante todo o Mestrado, sendo co-autor de diversos trabalhos publicados.

À CAPES pelo apoio financeiro fornecido durante parte do desenvolvimento deste trabalho.

E a todos que de alguma forma contribuíram com a realização deste trabalho.

RESUMO

Redes neurais artificiais (RNA) têm sido utilizadas numa grande variedade de tarefas, inclusive propondo soluções interessantes a problemas de várias áreas de administração, como finanças, marketing, vendas ou compras e até mesmo em recursos humanos. Neste trabalho propõe-se a concepção e execução de um plano experimental para explorar a influência dos parâmetros: número de camadas e número de neurônios intermediários, sobre o desempenho das RNA's. A rede neural artificial irá analisar o impacto dos preços do barril de petróleo *WTI Spot* (mercado norte-americano) e *Europe Brent Spot* (mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) e da taxa de câmbio comercial nos preços do açúcar cristal e do álcool anidro combustível prevendo os valores de comercialização destes produtos. Os experimentos deste estudo serão realizados com base em dados históricos de preços dos produtos da indústria canvieira (açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do álcool anidro combustível no Estado de São Paulo seguindo as especificações da Agência Nacional de Petróleo – ANP), visto que na região encontra-se um grande número de indústrias deste segmento, sendo desta maneira de grande importância regional.

ABSTRACT

Artificial neural networks (RNA) they have been used in a great variety of tasks, besides proposing interesting solutions to problems of several administration areas, as finances, marketing, sales or purchases and even human resources. In this work intends the conception and execution of an experimental plan to explore the influence of the parameters: number of layers and numbers of intermediate neurons, on the acting of RNA. The artificial neural network will analyze the impact of the prices of the barrel of petroleum WTI Spot (North American market) and Europe Brent Spot (European market), contract future of sugar rude nº11 of the New York, a Coffe, Sugar & Cocoa Exchange Inc. (Csce), New York Board of Trade (NYBOT) and of the commercial exchange rate in the prices of the granulated sugar and of the alcohol combustibile anidro forecasting the values of commercialization of these products. The experiments of this study will be accomplished with base in historical data of prices of the products of the sugar cane industry (granulated sugar conditioned in bags of 50 kg negotiated in the cash market of the State of São Paulo destined to the domestic market and of the alcohol combustibile anidro in the State of São Paulo following the specifications of the National Agency of Petroleum-ANP), because in the area is a great number of you elaborate of this segment, being this way of great regional importance.

SUMÁRIO

LISTA DE FIGURAS.....	3
LISTA DE TABELAS.....	4
I – INTRODUÇÃO.....	5
1.1. Problema de Investigação.....	8
1.2. Objetivos.....	9
1.3. Organização da Dissertação.....	9
II – REFERENCIAL TEÓRICO.....	11
2.1. Mercado Sucroalcooleiro.....	11
2.1.1. O Setor Sucroalcooleiro no Brasil.....	11
2.1.2. O Desenvolvimento do Complexo Canavieiro Brasileiro.....	13
2.1.3. Setor Açucareiro Nacional e Mundial.....	15
2.2. Redes Neurais Artificiais.....	18
2.2.1. Fundamentos das Redes Neurais Artificiais.....	18
2.2.2. Histórico das Redes Neurais Artificiais.....	20
2.2.3. Neurônio Biológico.....	22
2.2.4. Neurônio Artificial.....	23
2.2.4.1. Sinapses dos Neurônios Artificiais.....	24
2.2.4.2. Função de Ativação.....	25
2.2.4.2.1. Função Linear.....	25
2.2.4.2.2. Função Degrau ou Heaviside.....	26
2.2.4.2.3. Função Logística ou Sigmoidal e Função Tangente Hiperbólica.....	27
2.2.5. Topologia das Redes Neurais Artificiais.....	27
2.2.6. Paradigmas de Aprendizagem.....	29
2.2.6.1. Aprendizado com um Professor ou Aprendizado Supervisionado.....	29
2.2.6.2. Aprendizado sem um Professor.....	30
2.2.6.2.1. Aprendizado Não Supervisionado.....	30
2.2.6.2.2. Aprendizado por Reforço.....	30
2.2.7. Aprendizado em Redes Neurais Artificiais.....	31
2.2.7.1. Aprendizado por Correção de Erro.....	31
2.2.7.2. Aprendizado Hebbiano.....	33
2.2.7.3. Aprendizado Competitivo.....	34
2.2.8. Principais Modelos de Redes Neurais Artificiais.....	35

2.2.8.1. Perceptron.....	35
2.2.8.1.1. Algoritmo da Rede Perceptron.....	36
2.2.8.2. Redes de Múltiplas Camadas (MLP).....	36
2.2.8.2.1. Algoritmo de MLP.....	39
2.2.8.3. Rede de Kohonen.....	40
2.2.8.3.1. Algoritmo de aprendizado da rede Kohonen.....	41
2.2.8.3.2. Algoritmo LVQ.....	42
2.2.8.4. Rede Hopfield.....	42
2.2.8.4.1. Algoritmo de aprendizado da rede de Hopfield.....	44
2.2.9. Tarefas de Aprendizado.....	44
2.2.9.1. Associação.....	44
2.2.9.2. Reconhecimento de Padrões.....	45
2.2.9.3. Aproximação.....	45
2.2.9.4. Controle.....	45
2.2.9.5. Filtragem.....	46
2.2.9.6. Formação de Feixe.....	46
III – PROCEDIMENTOS METODOLÓGICOS.....	47
3.1. Tipo de Pesquisa.....	47
3.2. Definição das Variáveis.....	48
3.3. Etapas da Execução da Pesquisa.....	49
3.4. Instrumentos para a Execução do Projeto de Pesquisa.....	49
3.5. Definição de um Plano Experimental.....	50
IV – APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS.....	52
V – CONCLUSÕES E RECOMENDAÇÕES.....	59
5.1. Conclusões.....	59
5.2. Trabalhos Futuros.....	61
REFERÊNCIAS.....	62
ANEXO A - AÇÚCAR CRISTAL NO ESTADO DE SÃO PAULO.....	68
ANEXO B - ÁLCOOL ANIDRO COMBUSTÍVEL NO ESTADO DE SÃO PAULO.....	70
ANEXO C - TAXA DE CÂMBIO COMERCIAL.....	72
ANEXO D – BARRIL DE PETRÓLEO <i>WTI SPOT E EUROPE BRENT SPOT</i>	74
ANEXO E - CONTRATO FUTURO DE AÇÚCAR BRUTO N°11 DA CSCE/NYBOT.....	77

LISTA DE FIGURAS

Figura 01 - Estrutura de uma rede neural.....	19
Figura 02 - Estágios de uma RNA	20
Figura 03 - Representação de um Neurônio Biológico.....	23
Figura 04 - Modelo não linear de um neurônio.....	24
Figura 05 - Gráfico de uma função de ativação Linear.....	26
Figura 06 - Gráfico e Equação de uma função de ativação Degrau ou Heaviside.....	26
Figura 07 - Gráfico e Equação de uma função de ativação Sigmoidal e Tangente Hiperbólica.....	27
Figura 08 - RNA Não-Recorrente ou Feedforward com uma e duas camadas.....	28
Figura 09 - RNA Recorrente.....	28
Figura 10 - Rede Neural de múltiplas camadas.....	37
Figura 11 - Ilustração das direções de dois fluxos de sinal: propagação do sinal funcional e retropropagação do erro.....	38
Figura 12 - Gráfico do erro percentual na previsão dos preços do açúcar.....	55
Figura 13 - Gráfico do erro percentual na previsão dos preços do álcool.....	57

LISTA DE TABELAS

Tabela 01 - Volume de cana-de-açúcar, álcool e açúcar produzido pelo país.....	11
Tabela 02 - Produção regional de cana-de-açúcar, açúcar e álcool.....	13
Tabela 03 - Produção, exportação mundial e nacional de açúcar.....	15
Tabela 04 - Erro percentual para previsão do açúcar e do álcool.....	51
Tabela 05 - Erro percentual para previsão do açúcar.....	54
Tabela 06 - Erro percentual para previsão do álcool.....	56

I – INTRODUÇÃO

O desejo e a necessidade de controlar algumas incertezas são temas centrais das relações do homem com a natureza e seus futuros eventos. Frequentemente, é necessário tomar decisões sob um ambiente de incertezas, nas quais têm pouco ou nenhum conhecimento, sendo muito interessante a análise dos possíveis efeitos das decisões a serem tomadas. Para lidar com problemas dessa ordem, é necessário identificar potenciais de sucesso e fracasso ao longo do tempo.

Assim, as exigências de maior capacidade de trabalho e a crescente competição nos diferentes setores da economia nacional demandam um grande profissionalismo. A busca por uma posição no mercado competitivo do mundo atual envolve mudanças nas cadeias produtivas do *agribusiness* mundial, assim como no segmento de agronegócios.

O desenvolvimento de projetos de comercialização desses produtos demanda conhecimentos precisos das suas principais características, especialmente, do seu comportamento comercial mundial visando resultados mais realistas capazes de uma avaliação mais segura do seu funcionamento. Vários trabalhos sobre redes neurais artificiais (RNA) têm sido publicados e inúmeras aplicações têm sido discutidas nas soluções de uma grande variedade de tarefas. De acordo com Almeida (1995), redes neurais podem ser utilizadas em diversas áreas de administração, como finanças, marketing, vendas ou compras e até mesmo em recursos humanos. Na área financeira, pode-se utilizar para avaliações de crédito, de riscos de inadimplência de empresas, de riscos de seguros, riscos de hipotecas, ou mesmo avaliação de riscos de papéis financeiros. Na área de marketing, utiliza-se para simular o comportamento do consumidor face a novos produtos, simular as vendas para um próximo período em função do resultado obtido em período anterior ou ainda sugerir produtos mais adaptados ao perfil de cada cliente. Na área de recursos humanos, pode-se utilizar RNA para verificar se o perfil de um candidato é condizente com determinada vaga de emprego.

A escolha de RNA como técnica nesse estudo, decorreu ao fato de sua aplicação nas mais diversas áreas da administração incluindo trabalhos de previsão e análise. Abelém (1994) modela RNAs para fazer previsões da série do preço do ouro no mercado internacional utilizando os mecanismos de escolha da função de ativação dos neurônios, função erro, parâmetros de controle do gradiente descendente e do tempo de treinamento. Trabalhos mais

recentes como o de Coelho e Canciglieri Junior (2000), Curry (2003), Zhang (2003), Hamid e Iqbal (2004), Ghiassi, Saidane e Zimbra (2005), também utilizam RNAs para análise de séries temporais. Através da cooperação de RNA e técnicas de decomposição de séries temporais Calôba, Calôba e Saliby (2002) obtêm uma previsão de vendas de cerveja na Austrália; Chen e Leung (2004) utilizam RNA para a previsão de taxas de câmbio; Cho (2003) utiliza RNA para fazer a previsão de demanda de viagem de diferentes países para Hong Kong. Previsão da inflação (NAKAMURA, 2005), análise de crédito (OLIVEIRA NETO; TROMPIERE; KITAMURA, 2003; KUMAR; HAYNES, 2003) e análise de mercado financeiro (YAO; LI; TAN, 2000; FADLALLA; LIN, 2001; KANAS; YANNOPOULOS, 2001; JAGRIC, 2003) são outras aplicações de RNA na área de finanças.

Orlandi (1997) utiliza uma rede neural *feedforward* (FRNs), para aprender a classificar as situações das organizações empresariais em solventes, insolventes e pré-insolventes a fim de, posteriormente, classificar novas organizações que não participaram do processo de treinamento. O método consiste em analisar as empresas através de cinco índices (Rentabilidade do Patrimônio, Liquidez Geral, Liquidez Seca, Liquidez Corrente, Endividamento Geral) considerados de extrema importância na verificação da situação de uma organização.

Mendes Filho, Carvalho e Matias (1996) analisam o desempenho obtido por uma RNA “*Multi Layer Perceptron*” treinadas com o algoritmo “*backpropagation*” na aplicação de avaliação de risco de inadimplência no crédito financeiro. Benite (2003) utiliza topologias auto-organizadas na classificação e exploração de dados macroeconômicos para a elaboração e análise de cenários.

De acordo com Lucifredi e Hou (1994), as RNAs são compostas por uma camada de entrada, camadas intermediárias (uma ou mais) e uma camada de saída. O número de entrada e saída são fixados em função dos dados de treinamento, e entradas adicionais podem ser geradas com o uso de linhas defasadas. O número de camadas intermediárias e neurônios nestas camadas não possui um limite teórico. Vários trabalhos têm tratado da escolha da configuração da rede neural, mas para a determinação do tamanho da rede ainda persiste o conceito de tentativas e erros (SHARPE; CHOW, 1994).

O projeto da rede neural precisa levar em consideração vários fatores para obter um desempenho em um nível aceitável, onde cada projetista de rede tem suas próprias idéias e quais são aceitáveis em cada caso. Porém as arquiteturas desejadas são as que têm pequeno erro, um pequeno tempo de treinamento, uma pequena sensibilidade e um pequeno número de neurônios. Se a rede tiver sido bem treinada ela será capaz de reconhecer condições intermediárias entre as treinadas, isto é, a rede terá capacidade de generalização. Assim, o presente trabalho parte de um plano experimental, baseado no trabalho de Almeida e Dumontier (1996), para a escolha da configuração da rede.

Uma das etapas mais importantes para a aplicação e capacidade de generalização de rede neural (RN) é a escolha do padrão de entradas para o treinamento de uma RN, ou seja, durante a execução do treinamento são necessários dados que representem o modelo em questão.

Como a participação do Brasil no mercado internacional de açúcar é elevada, aproximadamente 40% das exportações mundiais são nacionais, Silveira (2004) analisou alguns aspectos da relação do mercado doméstico brasileiro desta *commodity* com os preços internacionais. Neste trabalho, foi analisado o impacto da produção brasileira de açúcar (potencial de exportação dessa *commodity*) sobre a formação do preço no mercado internacional. O autor utilizou as cotações da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) na análise da influência da produção brasileira sobre os preços internacionais, considerando-se que esta bolsa é a maior referência para o mercado de açúcar e a que tem maior liquidez.

Como o álcool anidro e a gasolina são utilizados em nosso país como combustível e sendo uma parcela de álcool adicionada à gasolina, é esperado que os seus valores sejam relacionados entre si. Assim, como o álcool é obtido através da cana-de-açúcar e a gasolina do petróleo, este trabalho utilizou-se das variáveis preço do barril de petróleo *WTI Spot* (mercado norte-americano) e *Europe Brent Spot* (mercado europeu) na previsão dos preços do açúcar e álcool advindos no Brasil, em sua maior parte, da mesma matéria-prima: a cana-de-açúcar.

Desta maneira, baseado no trabalho de Silveira (2004), devido ao fato do Brasil ser responsável por cerca de 40% das exportações mundiais de açúcar e o álcool anidro e a gasolina serem utilizados em nosso país como combustível, foram escolhidas as variáveis: preço do barril de petróleo *WTI Spot* (mercado norte-americano) e *Europe Brent Spot*

(mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) e a taxa de câmbio comercial para análise de impacto nos preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do álcool anidro combustível no Estado de São Paulo seguindo as especificações da Agência Nacional de Petróleo – ANP.

As séries de preços do Açúcar Cristal e do Álcool Anidro Combustível utilizadas no estudo são aferida pelo CEPEA – Centro de Estudos Avançados em Economia Aplicada da Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo. Justifica-se a utilização desses dados para o mercado doméstico pelo fato do Estado de São Paulo ser o responsável por aproximadamente 60% da produção de açúcar e álcool nacional.

Dessa maneira, o presente trabalho visa contribuir, utilizando redes neurais artificiais, na análise dos impactos dos preços do barril de petróleo *WTI Spot* (mercado norte-americano) e *Europe Brent Spot* (mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) e a taxa de câmbio comercial prevendo os preços do açúcar e álcool no estado de São Paulo.

1.1. PROBLEMA DE INVESTIGAÇÃO

Como os preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do Álcool Anidro Combustível no Estado de São Paulo se comporta frente ao preço do barril de petróleo *WTI Spot* (mercado norte-americano) e *Europe Brent Spot* (mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) e a taxa de câmbio comercial e como é feita a previsão desses produtos por meio de redes neurais artificiais?

1.2. OBJETIVOS

Objetivo Geral:

Construir e executar um plano experimental para explorar a influência do tamanho da rede (número de neurônios e camadas intermediárias) sobre o desempenho das RNA no caso específico deste estudo e analisar o impacto de algumas variáveis externas (preço do barril de petróleo *WTI Spot* e *Europe Brent Spot*, contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc. (CSCE)*, pertencente à *New York Board of Trade (NYBOT)* e a taxa de câmbio comercial) nos preços do açúcar cristal e do álcool anidro combustível.

Objetivos Específicos:

- Avaliar a influência das variáveis preço do barril de petróleo *WTI Spot* e *Europe Brent Spot*, contrato futuro de açúcar bruto nº11 da Csce/Nybot e a taxa de câmbio comercial prevendo os preços do açúcar cristal e do álcool anidro combustível;
- estudar os fundamentos e funcionamento dos algoritmos de uma rede neural artificial;
- avaliar como se obtém resultados de previsão utilizando redes neurais artificiais;
- gerar conhecimento para o grupo de pesquisa na utilização de redes neurais artificiais em previsões.

1.3. ORGANIZAÇÃO DA DISSERTAÇÃO

O presente trabalho de dissertação está dividido em 5 capítulos que cobrem: a justificativa da realização deste estudo, o setor alcooleiro nacional e mundial, redes neurais artificiais, estudo de aplicações de *RNA* na previsão de séries, modelagem de *RNA*, avaliação dos resultados e conclusão.

O capítulo 1 inicia-se com a apresentação de algumas publicações sobre a utilização das *RNA* e sua importância em previsões de séries. Em seguida mostra o problema de investigação, os objetivos e por fim a organização desse trabalho.

O capítulo 2 é iniciado pela descrição do setor sucroalcooleiro no Brasil, dividido por duas grandes regiões produtoras: Norte-Nordeste e Centro-Sul. Apresenta a importância do segmento canavieiro no Brasil e no mundo, sendo o Estado de São Paulo o principal responsável pela produção e exportação nacional. Em seguida, o capítulo faz um levantamento dos principais conceitos na área de redes neurais artificiais, apresentando um breve histórico de alguns acontecimentos marcantes na evolução das *RNA*, descreve o funcionamento de um neurônio artificial, das funções de ativação, das topologias e dos principais tipos de treinamento. Conclui-se o capítulo com uma descrição dos principais modelos de *RNA*, com ênfase para o algoritmo de treinamento utilizado: o retropropagação do erro e com as tarefas que podem ser realizadas pela *RNA*.

O capítulo 3 aborda os procedimentos metodológicos utilizados no estudo. Inicia-se apresentando o tipo de pesquisa realizado e sua importância. Em seguida, faz um levantamento das variáveis com a descrição dos instrumentos utilizados para a execução do trabalho juntamente com um plano experimental para explorar alguns parâmetros no desempenho na *RNA*.

O capítulo 4 avalia os resultados obtidos e os procedimentos utilizados.

O capítulo 5 apresenta as conclusões e considerações sugerindo possíveis trabalhos futuros.

II – REFERENCIAL TEÓRICO

2.1. MERCADO SUCROALCOOLEIRO

2.1.1. O SETOR SUCROALCOOLEIRO NO BRASIL

A cana-de-açúcar, matéria-prima básica para a produção do açúcar e álcool, tem ocupado importante posição na agricultura brasileira ao longo das duas últimas décadas. Essa posição é expressa, de acordo com a UNICA – União da Agroindústria Canavieira de São Paulo, pelo volume de 359,3 milhões de toneladas de cana, 14,8 milhões de metros cúbicos de álcool e 24,9 milhões de toneladas de açúcar. O volume de cana-de-açúcar, álcool e açúcar produzido pelo país, pode ser visto na tabela 01.

Tabela 01 - Volume de cana-de-açúcar, álcool e açúcar produzido pelo país

Safra	Cana-de-açúcar (toneladas)	Álcool (metros cúbicos)	Açúcar (toneladas)
1990/1991	222.429.160	11.515.151	7.365.344
1991/1992	229.222.243	12.716.180	8.604.321
1992/1993	223.382.793	11.694.758	9.318.490
1993/1994	218.336.005	11.284.726	9.332.896
1994/1995	240.712.907	12.685.111	11.703.315
1995/1996	251.827.212	12.589.765	12.653.029
1996/1997	287.809.852	14.372.351	13.659.380
1997/1998	303.057.415	15.399.449	14.880.691
1998/1999	314.922.522	13.868.578	17.942.109
1999/2000	306.965.623	13.021.804	19.387.515
2000/2001	257.622.017	10.593.035	16.248.705
2001/2002	293.050.543	11.536.034	19.218.011
2002/2003	320.650.076	12.623.225	22.567.260
2003/2004	359.315.559	14.808.705	24.925.793

Fonte: UNICA – União da Agroindústria Canavieira de São Paulo (2005)

Nota-se que de 1990 à 2003, a produção de cana-de-açúcar passou de 222,4 milhões de toneladas na safra 1990/1991 para 359,3 milhões de toneladas na safra 2003/2004. No que se refere à produção de álcool, o Brasil passou de 11,5 milhões de metros cúbicos na safra 1990/1991 à 14,8 milhões de metros cúbicos na safra 2003/2004. A produção de açúcar passou de 7,3 milhões de toneladas na safra 1990/1991 para 24,9 milhões de toneladas na safra 2003/2004.

As principais regiões produtoras de açúcar e álcool do país são a região Centro-Sul com safra de maio à dezembro e a região Norte-Nordeste com safra de setembro à março. A região Centro-Sul é composta pelos estados: Espírito Santo, Goiás, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Rio de Janeiro, Rio Grande do Sul, Santa Catarina e São Paulo. A região Norte-Nordeste é composta pelos estados: Alagoas, Bahia, Ceará, Maranhão, Pará, Paraíba, Pernambuco, Piauí, Rio Grande do Norte, Sergipe e Tocantins.

A existência de duas regiões produtoras de cana-de-açúcar, álcool e açúcar, permite que no Brasil o abastecimento de açúcar e álcool ocorra durante o ano todo, já que os períodos de safra entre as regiões são diferentes.

A competição entre a atividade sucroalcooleira das regiões Norte-Nordeste e Centro-Sul, as diferenças entre as estruturas de produção, na gestão empresarial e as condições do clima e do solo são destacadas por Lima e Silva (1995) no trabalho intitulado "*A economia canavieira de Pernambuco e a reestruturação necessária*". De acordo com os autores, a forte presença do Estado garantiu a manutenção da agroindústria canavieira mas agiu como uma barreira aos estímulos de crescimento perante o mercado.

A produção regional de cana-de-açúcar, açúcar e álcool pode ser vista na tabela 02. Observa-se que na safra 2003/2004, a produção de cana-de-açúcar da região Centro-Sul representou cerca de 83% do total produzido no País, sendo o estado de São Paulo o responsável por 57% da produção nacional. Esse estado é também o principal responsável pelas produções de açúcar e álcool com 60% e 59%, respectivamente, da produção nacional.

Tabela 02 - Produção regional de cana-de-açúcar, açúcar e álcool

Safr	Norte-Nordeste			Centro-Sul		
	Cana-de-açúcar (toneladas)	Açúcar (toneladas)	Álcool (m ³)	Cana-de-açúcar (toneladas)	Açúcar (toneladas)	Álcool (m ³)
1990/1991	52.234.501	2.856.517	1.807.301	170.194.659	4.508.828	9.707.850
1991/1992	50.191.326	2.769.632	1.748.879	179.030.917	5.834.689	10.967.301
1992/1993	47.164.430	3.130.068	1.630.565	176.218.363	6.188.421	10.064.193
1993/1994	34.421.824	2.265.206	912.914	183.914.181	7.067.690	10.371.812
1994/1995	44.629.258	3.211.477	1.549.613	196.083.649	8.491.838	11.135.498
1995/1996	47.413.177	3.337.574	1.734.219	204.414.035	9.315.455	10.855.546
1996/1997	56.205.772	3.184.842	2.266.093	231.604.080	10.474.538	12.106.258
1997/1998	54.281.977	3.526.216	2.144.936	248.775.438	11.354.475	13.254.513
1998/1999	45.141.192	2.781.830	1.631.216	269.781.330	15.160.279	12.237.362
1999/2000	43.016.724	2.487.333	1.368.092	263.948.899	16.900.182	11.653.712
2000/2001	50.522.960	3.612.764	1.528.671	207.099.057	12.635.941	9.064.364
2001/2002	48.832.459	3.245.849	1.359.744	244.218.084	15.972.162	10.176.290
2002/2003	50.243.383	3.789.205	1.471.141	270.406.693	18.778.055	11.152.084
2003/2004	60.194.968	4.505.316	1.740.068	299.120.591	20.420.477	13.068.637

Fonte: UNICA – União da Agroindústria Canavieira de São Paulo (2005)

Nota-se que existe uma tendência de concentração da produção canavieira na região Centro-Sul. A região, na safra 1990/1991, foi responsável por 76% da cana-de-açúcar, 61% do açúcar e 84% do álcool produzidos no Brasil. Na safra 2003/2004, passou a ser responsável por 83% da cana-de-açúcar, 81% do açúcar e 88% do álcool produzidos no Brasil.

Devido a importância da região Centro-Sul, mais especificamente o Estado de São Paulo, em termos de participação na produção total do setor sucroalcooleiro, esta é a região considerada a área de estudo dessa pesquisa.

2.1.2. O DESENVOLVIMENTO DO COMPLEXO CANAVIEIRO BRASILEIRO

O complexo agroindustrial canavieiro, constitui uma das mais antigas atividades econômicas no Brasil. De acordo com Ramos e Belik (1989), a cana-de-açúcar foi introduzida no nordeste brasileiro e foi destaque na produção brasileira durante quatro séculos devido sua proximidade ao mercado europeu e suas condições climáticas. A partir de meado do século XVIII e início do século XIX, teve início a produção de açúcar e aguardente na região Centro-

Sul do país, mais especificamente nos estados de São Paulo, Minas Gerais e Rio de Janeiro. Mas a produção na região Centro-Sul começou a ter destaque a partir de 1930, devido a uma redução da demanda externa e a crise mundial de 1929. Nesse cenário, foi iniciado em 1933 a intervenção estatal no setor com a criação do Instituto de Açúcar e Alcool (IAA) com o intuito de promover o planejamento e controle da produção adequando à demanda externa e interna (BELIK et al., 1998).

No decorrer da II Guerra Mundial, o transporte marítimo do açúcar nordestino para região Centro-Sul, passou a sofrer empecilhos que promoveram a transferência do eixo de produção canavieiro e açucareiro. Essa mudança intensificou-se principalmente no sudeste onde concentrava-se o maior mercado interno consumidor do país. A interferência estatal continuou sendo uma característica do setor com mecanismos de controle de preços, garantia de mercado, controle de entrada de novas unidades produtoras, controle da exportação e restrições ao capital estrangeiro. Visando o controle de mercado, a concentração e o desenvolvimento do complexo agroindustrial, foi criado em 1941 o Estatuto da Lavoura Canavieira, em 1966 o Programa Nacional de Melhoramento da Cana-de-Açúcar, em 1971 o Programa de Racionalização da Agroindústria Açucareira e em 1975 o Programa Nacional do Alcool – Proálcool (PINAZZA e ALEMANDRO, 2000).

Com a criação do Proálcool, ocorreu um fortalecimento das regiões e estados com tradição nesse segmento com uma posterior distribuição em estados com razoável infra-estrutura mas sem tradição alcooleira. Em 1990 é extinto o Instituto de Açúcar e Alcool e no início desta década o preço do açúcar deixa de ser tabelado. A partir de 1994 as exportações do açúcar são liberadas, em 1997 o álcool anidro deixa de ser tabelado; em 1998 libera o preço da cana-de-açúcar e em 1999 o preço do álcool hidratado.

Diante desses fatores, ocorre uma mudança no controle na produção e comercialização dos produtos oriundos da agroindústria canavieira. Estas deixam de ser orientadas pelo governo e a passam a fazerem parte da administração privada. Assim, as empresas deixam de serem dependentes do Estado e se tornam responsável à distribuição, controle e colocação de seus produtos canavieiros (açúcar e álcool) no mercado. Diante disso, os produtores passam a conduzir suas ações de acordo com os sinais emitidos por preços administrados em mercados livres e competitivos (ALVES, 2002).

2.1.3. SETOR AÇUCAREIRO NACIONAL E MUNDIAL

O açúcar produzido mundialmente pode ser oriundo da cana-de-açúcar, beterraba ou milho diferenciando apenas no processo de produção. No Brasil, o setor sucroalcooleiro tem grande destaque pelo fato de ser o maior produtor e exportador mundial. No período de 1999 à 2005, ocorreu um crescimento de 0,8% a.a. na produção de açúcar. No mesmo período, as exportações mundiais cresceram à uma taxa de 2% a.a., enquanto que as exportações brasileira cresceu num ritmo de 9,9% a.a. Dessa maneira, a participação do Brasil nas exportações de açúcar cresceu de 27,23% para 39,58% na safra de 1999 à 2005, conforme observa-se na tabela 03.

Tabela 03 - Produção, exportação mundial e nacional de açúcar

Safra	Produção Mundial (Toneladas)	Exportação Mundial (Toneladas)	Exportação Brasileira (Toneladas)	Porcentual Exportado pelo Brasil
1999/2000	136.435.000	41.503.000	11.300.000	27,23
2000/2001	130.662.000	37.699.000	7.700.000	20,42
2001/2002	134.386.000	41.179.000	11.600.000	28,17
2002/2003	148.874.000	45.828.000	14.000.000	30,55
2003/2004	141.732.000	45.595.000	15.240.000	33,42
2004/2005	141.687.000	45.727.000	18.100.000	39,58
Taxa Cresc. a.a.	0,8%	2,0%	9,9%	-

Fonte: USDA – United States Department of Agriculture (2005)

O desempenho do setor sucroalcooleiro em relação aos outros países deve-se a vários fatores dentre eles: o elevado teor de fibra, que lhe confere independência em relação à energia externa; a cana-de-açúcar apresentar, em termos energéticos, claras vantagens competitivas na comparação com outras culturas. Especificamente na região Centro-Sul, a produção teve nos últimos anos significativa evolução. Com o desenvolvimento de novas variedades, cada vez mais adaptadas ao clima, tipo de solo e mais resistentes a pragas; uso de insumos modernos; melhoria do sistema de transporte e mecanização da lavoura; melhores processos de planejamento e controle; melhoria na extração do caldo e diminuição de perdas no processo; menor uso de produtos químicos no processo industrial de fabricação de açúcar e álcool; inovações no processo de produção de açúcar e álcool; gerenciamento da produção e co-geração de energia elétrica, a produtividade agroindustrial sucroalcooleira se destacou perante

os outros países. Em São Paulo, responsável por cerca de 57% da produção nacional, a produtividade média de produção de cana-de-açúcar está ao redor de 80 a 85 toneladas por hectare. A qualidade da matéria-prima, medida pela sacarose contida na planta, está entre 14 e 15,5%, o que equivale ao rendimento médio de 140 a 145 kg de açúcares totais por tonelada de cana. Para o álcool, isso significa rendimento entre 80 e 85 litros por tonelada (CARVALHO, 2000).

Outra grande importância da agroindústria canavieira, pode ser notada no contingente de pessoas que empregam, mais de 1 milhão de brasileiros. No país cerca de 80% da cana colhida é cortada à mão precedido da queima da palha da planta, o que torna o trabalho mais seguro e rentável para o trabalhador. No Estado de São Paulo, onde 25% da área plantada é colhida por máquinas, a legislação estipula prazos para que o fogo deixe de ser usado no manejo da cana. Assim, a evolução tecnológica é, portanto, gradativa, exigindo o desenvolvimento de políticas realistas de reciclagem e reaproveitamento de mão-de-obra e o monitoramento de impactos ambientais.

No Brasil, de acordo com Carvalho (2000), o álcool hidratado é o combustível de cerca de 3 milhões de veículos; já o álcool anidro misturado na gasolina é o combustível de cerca de 17 milhões de veículos. O álcool é utilizado de forma intensiva na indústria de bebidas, nos setores químico, farmacêutico e de limpeza.

O mercado interno brasileiro pode ser dividido em doméstico e industrial. No primeiro prevalecem os açúcares cristal e refinado; no industrial, os açúcares demerara e líquido. O consumo brasileiro é de 52 kg per capita, e a média mundial está em torno de 22 kg per capita (MARJOTTA-MAISTRO; BURNQUIST, 1998).

Os subprodutos da cana-de-açúcar (bagaço, méis, torta e resíduos de colheita) são todos reaproveitados. Com 3 kg de açúcar e 17,1 kg de bagaço pode-se obter, por exemplo, 1 kg de plástico biodegradável derivado da cana, utilizando-se como solventes outros subprodutos da usina. Do bagaço da cana-de-açúcar, pode-se obter o bagaço hidrolisado para alimentação animal além de diversos tipos de papéis, fármacos e produtos com grande número de aplicações na indústria química e farmacêutica. Do melaço da cana-de-açúcar, além do álcool utilizado como combustível, bebida, e na indústria química, farmacêutica e de cosméticos, extraem-se levedura, mel, ácidos. Do álcool etílico podem ser fabricados polietileno, estireno,

cetona, acetaldeído, poliestireno, ácido acético, éter, acetona e toda a gama de produtos que se extraem do petróleo. Seu variado uso inclui a fabricação de fibras sintéticas, pinturas, vernizes, vasilhames, tubos, solventes, plastificantes, etc. Dos resíduos da cana-de-açúcar, utilizam-se a vinhaça e o vinhoto como fertilizantes. Dessa maneira, a cana-de-açúcar gera, assim como o petróleo, uma gama considerável de produtos, de fermento a herbicidas e inseticidas, com importante diferencial mas com as vantagens de serem biodegradáveis e não ofensivos ao meio ambiente (PINAZZA, 2000, CARVALHO, 2002, PINAZZA; ALIMANDRO, 2003).

2.2. REDES NEURAIIS ARTIFICIAIS

2.2.1. FUNDAMENTOS DAS REDES NEURAIIS ARTIFICIAIS

O surgimento das redes neurais artificiais, não provocou interesse inicial nas pessoas. Essas não acreditavam no seu potencial de utilização, não sendo difundida e ficando meio esquecida no passado. No entanto, o ressurgimento do interesse em redes neurais ocorreu repentinamente, tanto na teoria quanto na prática, com o aparecimento de aplicação computacional com um domínio prévio e restrito da inteligência humana. Tem sido aplicado na fabricação de máquinas onde o aprendizado tem atingido uma semelhança com o processo mental humano e, também, a fim de dar um novo e significativo interesse para o termo inteligência artificial.

A organização e o processamento de informações no cérebro é um processo que se dá em diferentes níveis. O processamento da informação visual é um dos processos mais complexos do cérebro e, portanto, a organização do caminho ótico tem influenciado os modelos da cadeia neural. A obtenção de uma rede neural artificial demanda o desenvolvimento de um modelo matemático que descreva adequadamente o funcionamento do sistema biológico.

Um computador pode então simular o modelo rapidamente e algum grau de segurança pode ser ganho com respeito à sua operação e funcionamento. Mudanças podem, serem feitas para o modelo realçar sua realização ou para simplificá-la. Para criar um modelo que simule um sistema biológico, de qualquer modo, deve-se primeiro estudar e entender este sistema.

As redes neurais artificiais são inspiradas biologicamente, isto é, elas são compostas de elementos que realizam, de maneira análoga, a maior parte das funções elementares do neurônio biológico (WASSERMAN, 1989). As RNA's usualmente são compostas por uma camada de entrada, camadas intermediárias (uma ou mais) e uma camada de saída (LUCIFREDI; HOU, 1994). Em cada camada existem elementos, chamados neurônios que se comunicam entre si através de ligações. Essas ligações são ponderadas e os valores passam de um neurônio para o próximo.

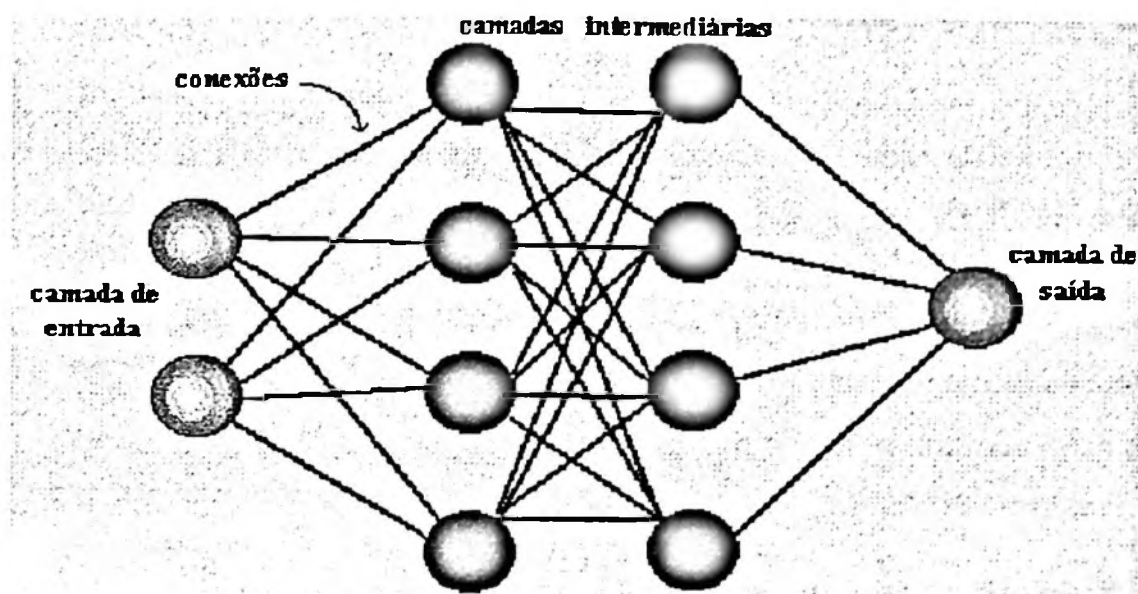


Figura 01- Estrutura de uma rede neural (ABELEM, 1994).

Estes elementos são organizados de modo que o seu funcionamento possa ser associado com o funcionamento do cérebro. Nesse caso, a rede neural artificial exibe um número surpreendente de características próximas as características cerebrais. Por exemplo, o aprendizado a partir de experiências generaliza prévios conhecimentos para reconhecer uma nova e abstrata característica a partir de entradas com dados até então desconhecidos.

Em função dessa semelhança funcional alguns otimistas defendem que as redes neurais artificiais logo duplicarão as funções do cérebro humano. No entanto a atual inteligência exibida pela mais sofisticada rede neural artificial é bastante limitada e o entusiasmo deve ser ajustado a realidade. Contudo, não é correto ignorar a surpreendente performance de certas redes neurais artificiais. As habilidades apresentadas pelas redes, hoje ainda limitadas, sugerem que um entendimento profundo da inteligência humana pode ser útil e, com isso, avançar rumo a aplicações revolucionárias.

Uma das características das redes neurais artificiais é que elas podem adaptar seus procedimentos em resposta ao seu meio. Esse fato, mais que muitos outros, é responsável pelo ressurgimento do interesse no desenvolvimento e utilização das redes neurais. Apresentando um grupo de entradas (que por ventura contenham as saídas desejadas), elas se auto-ajustam para produzirem respostas consistentes. Uma enorme variedade de algoritmos de treinamento tem sido desenvolvido, cada um com suas vantagens e desvantagens principalmente, em relação aos diferentes tipos de aplicação das redes neurais.

O primeiro estágio de uma rede neural, é o “treinamento” ou “aprendizado”. O treinamento faz o ajuste dos pesos de ponderação, em função das entradas, definidas para cada saída desejada. A rede aprende por meio de ajuste dos pesos de interconexão entre as camadas. As saídas que a rede está produzindo são repetidamente comparadas com as saídas desejadas e a cada iteração os pesos de conexão são ajustados na direção das saídas desejadas. O aprendizado (validação) ocorre quando a rede neural atinge uma solução generalizada para um dado problema. De acordo com Oliveira Neto, Trompiere e Kitamura (2003), os estágios de uma rede neural pode ser observada na figura 02.

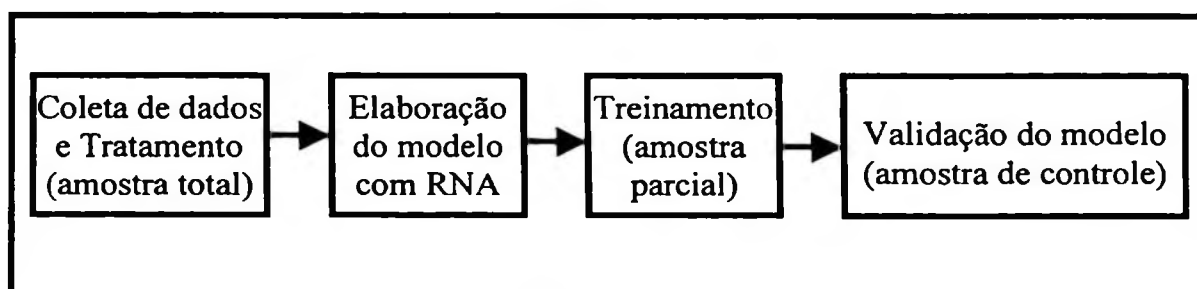


Figura 02 - Estágios de uma RNA (OLIVEIRA NETO; TROMPIERE e KITAMURA 2003)

Diferentes arquiteturas e diferentes parâmetros de treinamento podem ser utilizados. Rede neural é uma ferramenta com grande capacidade de generalização, desde que treinada corretamente para isto.

Embora vários trabalhos tenham tratado da determinação do tamanho da rede, a escolha da configuração da rede neural ainda persiste o conceito de tentativas e erros (SHARPE; CHOW, 1994).

2.2.2. HISTÓRICO DAS REDES NEURAIIS ARTIFICIAIS

Os primeiros modelos simplificados de neurônios biológicos foram propostos por Warren McCulloch (psiquiatra e neurocientista) e Walter Pitts (matemático) em 1943 no trabalho intitulado “*A logical calculus of the ideas immanent in nervous activity*” em *Bulletin of Mathematical Biophysics* (MINSK; PAPERT, 1988). O trabalho de McCulloch e Pitts (1943) descreve um modelo de neurônio artificial com suas capacidades computacionais baseando-se em cinco hipóteses:

- A atividade de um neurônio artificial é binária, ou seja, a cada instante o neurônio, ou dispara (atividade 1), ou não dispara (atividade 0);
- a rede neural artificial é constituída por linhas direcionada inspiradas nas sinapses dos neurônios biológicos, sem pesos, podendo ser excitatórias ou inibitórias;
- cada neurônio da rede neural tem um limiar fixo θ , e apenas dispara se a entrada total, num dado instante, for maior ou igual a θ ;
- independentemente do número de sinapses excitatórias que estejam chegando, se chegar conjuntamente uma única sinapse inibitória o neurônio não dispara. Se num dado instante o neurônio receber um sinal inibitório, este não dispara, caso contrário calcula-se o somatório dos sinais excitatórios e compara com o limiar θ . Sendo maior que θ dispara, caso contrário, ele não dispara.
- sinal inibitório ou excitatório leva uma unidade de tempo para passar de um neurônio da rede para outro reproduzindo um atraso sináptico.

McCulloch e Pitts (1947) através do livro "*How we know universals*" tentam combinar conceitos da biologia, psicologia, matemática e engenharia que seria novamente discutido pelo psicólogo Hebb (1949) através de seu livro "*The Organization of Behavior*".

Rosenblatt (1962) com o seu livro "*Principles of Neurodynamics*", demonstrou, através de modelos de neurônios baseados nos conceitos de McCulloch e Pitts (1943), que o seu modelo de rede neural chamado de *Perceptron* poderia ser treinada para reconhecimento de certos tipos de padrões. De acordo com Haykin (1999), a tarefa de reconhecimento de padrões pode ser definido como o processo pelo qual um padrão ou sinal recebido por um sistema é atribuído a uma única classe de um conjunto de classes pré-definidas.

Assim, o *perceptron* simples desenvolvido por Rosenblatt (1962) possui três camadas. A primeira camada de unidades sensoriais denominadas retina recebe as entradas do exterior possuindo conexões fixas. A segunda camada de unidades, chamada de associativas, recebe impulsos da primeira camada através de conexões cuja eficiência da transmissão (peso) é ajustável e as envia para a terceira camada de saída formada por unidades de resposta. Num primeiro momento a saída da rede é aleatória, mas, com o ajuste gradual dos pesos, treina-se o *perceptron* para fornecer saídas de acordo com os dados do conjunto de treinamento. Este tipo

de *perceptron* comporta-se como um reconhecedor de padrões, que divide o espaço de entrada em diferentes regiões para cada uma das classes existentes.

Após uma onda de entusiasmo com a capacidade das redes neurais em reconhecer padrões através do *Perceptron*, Minsky e Papert (1969) provaram com o livro chamado "*Perceptrons*" que as redes neurais de Rosenblatt (1962) era limitado a solucionar problemas de associação de padrões apenas quando os conjuntos eram linearmente separáveis, mudando a euforia inicial para uma desilusão. Os resultados observados pelos autores foram devastadores, e a utilização de Redes Neurais Artificiais para a solução de problemas práticos foi relegada a um plano secundário durante parte de 1970 ao início de 1980.

A utilização das redes de *perceptron* na solução de problemas de reconhecimento de padrões para conjuntos não linearmente separáveis foi eliminada por Rumelhart, Hinton e Williams (1986) através do algoritmo de Correção de Erros de Retropropagação ou Regra Delta Generalizada ou ainda mais conhecido por "*Backpropagation*" para redes de *Perceptron* de várias camadas de neurônios, com entradas e saídas analógicas. Após a descoberta do "*Backpropagation*", recuperou-se o interesse pela área, sendo utilizado em aplicações de diversas áreas de conhecimento de diagnósticos médicos (ROCHA, 1992), passando por detecção de falhas em estruturas (DEMARCHI, 2001) até finanças (ALMEIDA, 1995).

2.2.3. NEURÔNIO BIOLÓGICO

Conforme descreve Haykin (1999), o cérebro humano é uma estrutura de processamento altamente complexa, não linear e paralela. Possui uma enorme quantidade de processadores conhecidos como neurônios que, entre outras coisas, transmite os impulsos nervosos à outros neurônios e células musculares. São constituídos basicamente por dendritos, corpo celular (soma) e axônio. Vários são os tipos de neurônios, mas pode classifica-los em três tipos:

- Neurônios sensoriais: tipicamente, têm dendritos longos e um axônio curto. Carregam mensagens dos receptores sensoriais para o sistema nervoso central;
- neurônios motores: têm um axônio comprido e dendritos curtos. Transmitem mensagens do sistema nervoso central para os músculos (ou glândulas);
- interneurônios: ocorrem apenas no sistema nervoso central e conectam os neurônios entre si.

Os dentritos são as portas de entrada de impulsos químicos para o neurônio. O corpo celular recebe as entradas que advém dos dentritos, somando estas entradas através de um modelo e gera um sinal de ativação ou não para o axônio. O axônio é o canal que transmite o impulso elétrico de saída produzido pelo neurônio. A representação de um neurônio biológico é ilustrado na figura 03.

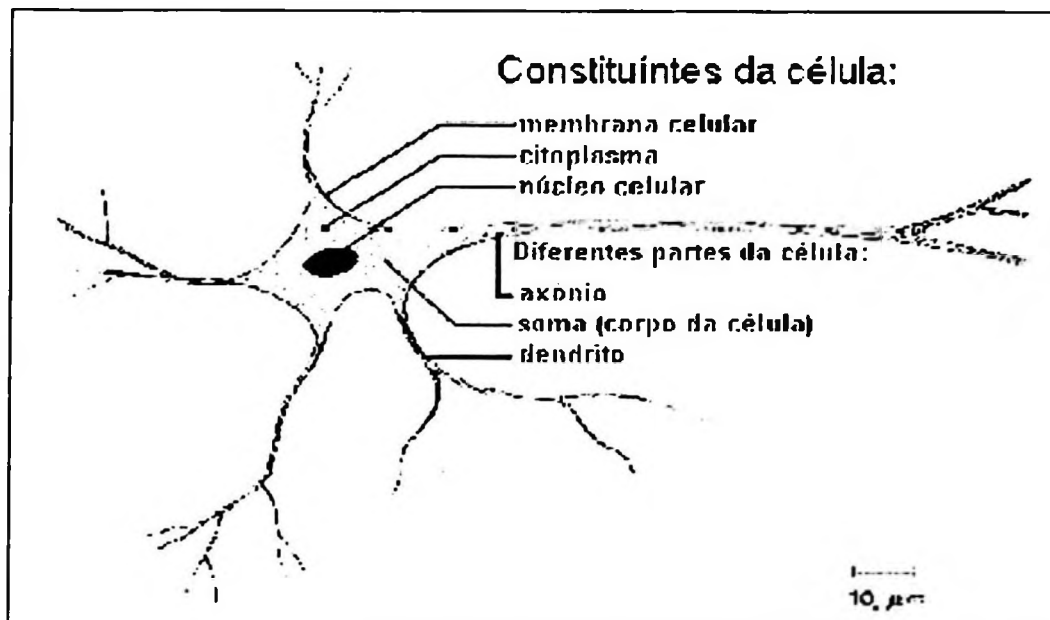


Figura 03 - Representação de um Neurônio Biológico (HERTZ; KROGH; PALMER, 1991)

As regiões onde os neurônios se conectam são conhecidas por sinapses, podendo ser inibitória ou excitatória possuindo diferentes intensidade influenciando no comportamento de outros neurônios. Uma sinapse excitatória influencia positivamente a ativação de um neurônio, enquanto que uma sinapse inibitória influencia a desativação de um neurônio (Haykin, 1999).

2.2.4. NEURÔNIO ARTIFICIAL

O modelo de neurônio artificial é a unidade de processamento de uma rede neural artificial e está baseado na concepção do neurônio biológico. Um conjunto de entradas (x_1, x_2, \dots, x_n) são aplicadas ao neurônio artificial, e cada entrada é multiplicada por um peso correspondente ($w_{k1}, w_{k2}, \dots, w_{kn}$), gerando entradas ponderadas, de maneira análoga à força das sinapses dos neurônios biológicos. Em seguida estas entradas ponderadas são somadas e obtém-se um valor u_k que será comparado com o valor limite para ativação do neurônio. Se alcançar o valor limite de ativação do neurônio, ele se ativará, caso contrário o neurônio ficará inativo. O esquema de um neurônio artificial pode ser visto na figura 04.




Figura 04 - Modelo não linear de um neurônio; adaptado de Haykin (1994)

De acordo com Bocanegra (2002), pode-se distinguir alguns elementos considerados importantes na estrutura de um neurônio:

- Sinapses ou elos de conexão caracterizada pelo peso ($w_{k1}, w_{k2}, \dots, w_{kn}$). O peso w_{kn} é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
- somatório que irá somar as entradas multiplicadas pelo respectivo peso, ou seja,

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (01)$$

- função de ativação ou função de restrição que irá limitar o intervalo da amplitude do sinal de saída.

A seguir são apresentados algumas descrições das sinapses nos neurônios artificiais e alguns tipos de função de ativação.

2.2.4.1. SINAPSES DOS NEURÔNIOS ARTIFICIAIS

A simulação das conexões sinápticas nos neurônios artificiais é feita através do uso da variável chamada peso. Assim, os pesos são valores que representam o grau de importância que determinada entrada possui em relação àquele determinado neurônio. Conforme Orlandi (1997), essas conexões simuladas mudam em função da intensidade do sinal de entrada, assim o peso muda o seu valor representativo para a rede. Sendo a entrada muito estimulada, o peso

correspondente à sua conexão será estimulado que por sua vez, irá influenciar mais no resultado do sinal de saída.

Os pesos quando analisados de maneira matemática são vistos como uma matriz de valores onde cada vetor dessa matriz corresponde a um neurônio. As entradas (x_1, x_2, \dots, x_n) apresentadas para um neurônio multiplicadas pelos pesos ($w_{k1}, w_{k2}, \dots, w_{kn}$) somadas com o viés b_k multiplicada por uma constante $x_0 = 1$, é o sinal de excitação no neurônio. Estas entradas ponderadas (u_k) podem ser representadas pela seguinte expressão:

$$u_k = w_{k1}x_1 + \dots + w_{kn}x_n + b_kx_0 = \sum_{j=0}^n w_{kj}x_j \quad (02)$$

2.2.4.2. FUNÇÃO DE ATIVAÇÃO

De acordo com Haykin (1999), a função de ativação representada por $\varphi(\cdot)$ define a saída de um neurônio conforme o nível de atividade da sua entrada. O comportamento da base de dados utilizada ou o tipo de problema a ser aprendido pela rede neural irá influenciar na seleção da função de ativação. Assim, sua escolha dependerá da experiência prática do operador em manipular os diversos modelos de redes neurais existentes, assim como o seu conhecimento das aplicações bem sucedidas de cada arquitetura. Conforme Fausett (1994) as funções de ativação mais utilizadas em redes neurais artificiais são: Função Linear, Função Degrau ou *Heaviside*, Função Logística ou Sigmoidal e Função Tangente Hiperbólica.

2.2.4.2.1. FUNÇÃO LINEAR

Redes de camadas simples que apresentam apenas uma camada de entrada e uma de saída são os modelos que utilizam este tipo de função. A saída da função de ativação linear é representada por uma equação linear apresentando uma série de limitações quanto à sua capacidade de representação. Pode ser representada pelo gráfico figura 05.




Figura 05 - Gráfico de uma função de ativação Linear (BOCANEGRA, 2002)

2.2.4.2.2. FUNÇÃO DEGRAU OU *HEAVISIDE*

Algumas limitações do modelo linear pode ser superada pela adição de não linearidades. Um modelo parcialmente linear muito utilizado é a função do Degrau ou *Heaviside*. Seu uso assume o comportamento de um neurônio com apenas dois estados de disparos possíveis: a ausência de disparos (-1 ou 0), ou disparando com a frequência máxima (1). A Função Degrau ou *Heaviside* de ativação pode ser representada pelos gráficos e equações na figura 06.




Figura 06 - Gráfico e equação de uma função de ativação Degrau ou *Heaviside* (BOCANEGRA, 2002)

2.2.4.2.3. FUNÇÃO LOGÍSTICA OU SIGMOIDAL E FUNÇÃO TANGENTE HIPERBÓLICA

Utilizada em redes que são submetidas a processos de aprendizado que utilizam derivada. É definida como uma função de caráter estritamente crescente com derivada simples e fácil de calcular. A Função Logística ou Sigmoidal possui resposta apenas no intervalo entre 0 e 1, mas se caso os neurônios apresentarem ativação no intervalo entre -1 e 1 , utiliza-se a função tangente hiperbólica de ativação com comportamento semelhante a função Sigmoidal. As gráficas da Função Sigmoidal e Função Hiperbólica podem ser representadas pela figura 07.




Figura 07 - Gráfico e Equação de uma função de ativação Sigmoidal e Tangente Hiperbólica

(BOCANEGRA, 2002)

2.2.5. TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS

A maneira como os neurônios de uma rede neural artificial conectam-se é conhecida como topologia. Dentre as várias topologias existentes, pode dividi-las basicamente em duas classes: Não-Recorrentes ou *Feedforward* e Recorrentes.

Uma RNA Não-Recorrente ou *Feedforward* é aquela que não possui realimentação (loops) de suas saídas para suas entradas e por isso são ditas “sem memória”. Sua estrutura em camadas pode ser formada por apenas uma (RNA de camada única) ou mais camadas (RNA multi-camadas). Redes Neurais multi-camadas possui um conjunto de neurônios de entrada, uma

camada de saída e uma ou mais camadas escondidas. De acordo com Wasserman (1989), a camada de entrada não é considerada uma camada da rede pois apenas distribui os padrões. A camada de saída é a camada de neurônios que fornece a saída da rede. As camadas escondidas não possuem ligações diretas nem com a entrada nem com a saída. A figura 08 representa uma RNA Não-Recorrente ou *Feedforward* com uma e duas camadas.




Figura 08 - RNA Não-Recorrente ou Feedforward com uma e duas camadas (HAYKIN, 1994)

Uma RNA Recorrente é aquela que possui realimentação das saídas para as entradas, sendo suas saídas determinadas pelas entradas atuais e pelas saídas anteriores. Suas estruturas não são necessariamente organizadas em camadas. Quando são, os neurônios de uma camada podem possuir interligações com camadas não consecutivas, gerando interconexões mais complexas que as RNAs Não-Recorrentes. Uma representação de uma RNA Recorrente pode ser vista na figura 09.




Figura 09 - RNA Recorrente (HAYKIN, 1994)

2.2.6. PARADIGMAS DE APRENDIZAGEM

Assim como uma criança aprende a andar, falar associar objetos e nomes, as RNAs aprendem por experiência através de exemplos, ou tentativa e erro. Na computação os dados são manipulados através de regras apropriadas sendo que em uma rede neural treina-se os dados para a solução do problema desejado. Após escolher um conjunto de dados que representam o problema, aplica-se um conjunto de entradas a fim de produzir um conjunto de saídas desejados ou no mínimo consistentes. Esta tarefa é conhecida por treinamento, que consiste em aplicar seqüencialmente vetores de entrada (um conjunto de entrada ou saída é conhecido por vetor) a fim de ajustar os pesos da rede de acordo com um procedimento de treinamento pré-determinado. Durante esta fase os pesos da rede iram convergir gradualmente para certos valores, tal que a aplicação de vetores de entrada produza as saídas necessárias. A maneira como a rede neural artificial se relaciona com o seu ambiente, ou seja, como ela ajusta o conjunto de pesos de modo que a rede consiga executar uma tarefa específica é conhecido por paradigmas de aprendizado. Eles são classificados de duas formas distintas: Aprendizado com um Professor (Aprendizado Supervisionado) e Aprendizado sem um Professor (HAYKIN, 1999).

2.2.6.1. APRENDIZADO COM UM PROFESSOR OU APRENDIZADO SUPERVISIONADO

Neste tipo de treinamento são necessários conjuntos de dados de entradas e saídas da rede neural. O procedimento consiste em aplicar um vetor de entrada e calcular e comparar a saída obtida com a desejada. O erro entre os sinais obtido e o alvo desejado é utilizado para atualizar os pesos da rede de acordo com um algoritmo determinado a fim de minimizar o erro. Este procedimento de treinamento irá se repetir até que o erro ou diferença entre os sinais obtidos e o alvo desejado seja aceitável. Este tipo de aprendizado, no qual compara-se a resposta da rede com a resposta correta previamente é conhecida por aprendizado com um professor.

De acordo com Haykin (1994), os modos de aprendizado supervisionado podem ser classificados em:

- Estático: o aprendizado é executado até que o desempenho desejado seja obtido pela rede, e uma vez conseguido isso os pesos são fixados e a rede não é mais submetida ao aprendizado.
- dinâmico: o aprendizado ocorre em tempo real, tendo dessa maneira um processo contínuo de aprendizado.

2.2.6.2. APRENDIZADO SEM UM PROFESSOR

Este paradigma de aprendizado não requer um vetor alvo para as saídas, sendo assim, não faz comparações para determinar a resposta ideal. Assim, não há um professor supervisionando o processo, ou seja, não tem exemplos rotulados da função que será aprendida pela rede. De acordo com Haykin (1994), os modos de aprendizado sem um professor podem ser classificados em Aprendizado Não Supervisionado e Aprendizado por Reforço.

2.2.6.2.1. APRENDIZADO NÃO SUPERVISIONADO

Este paradigma de aprendizado utiliza os neurônios como classificadores, e os dados de entrada como os elementos para a classificação, sendo a rede neural e o seu algoritmo de aprendizado responsável pelo processo de classificação. De acordo com Hertz *et al.* (1991), o aprendizado não supervisionado é utilizado quando a meta de treinamento não está totalmente definida na forma de exemplos específicos, sendo a correlação dos dados ou sinais de entrada a única informação disponível. Dessa maneira a rede deve ser projetada para criar categorias ou classes para essas correlações a fim de produzir os sinais de resposta correspondentes às categorias de entrada. Essa auto-organização envolve um processo de competição e cooperação entre os neurônios, sendo muito utilizado por pesquisadores como detector de características devido a capacidade de discriminar estímulos.

2.2.6.2.2. APRENDIZADO POR REFORÇO

Este tipo de paradigma é uma combinação do aprendizado supervisionado e o não supervisionado. Aplica-se uma entrada à rede e esta obtém um sinal de reforço (sim/não) avaliativo, não instrutivo como no aprendizado supervisionado. Este sinal é bastante limitado

pois este sinal é apenas uma declaração sobre a resposta associada com um padrão particular a respeito de ser boa ou ruim.

Comparando o aprendizado por reforço e o aprendizado supervisionado, observa-se algumas características específicas. O aprendizado por reforço necessita de um crítico sendo um sistema estimativo não estabelecendo o que fazer a priori. O aprendizado ocorre por tentativa e erro no qual a rede é recompensada em caso de sucesso e punida em caso de fracasso. O aprendizado supervisionado requer um professor sendo um sistema instrutivo.

2.2.7. APRENDIZADO EM REDES NEURAIS ARTIFICIAIS

O aprendizado em uma RNA ocorre através de um processo iterativo de ajustes aplicados aos pesos sinápticos e *thresholds*. Esse ajuste é realizado através de um algoritmo seguindo algum paradigma de aprendizado. O Algoritmo de aprendizado consiste de um conjunto de regras bem definidas para resolver um problema de aprendizagem. Existe uma grande variedade de algoritmos de aprendizagem que diferem entre si pela forma de ajuste dos pesos, podendo ser divididos em três classes principais: Aprendizado por Correção de Erro, Aprendizado Hebbiano e Aprendizado Competitivo.

2.2.7.1. APRENDIZADO POR CORREÇÃO DE ERRO

Neste tipo de algoritmo, tem-se uma saída desejada (d_k) e uma saída real obtida (y_k) para um neurônio (k) num determinado instante (n). Normalmente $y_k(n)$ apresenta uma diferença ($e_k(n)$) em relação à $d_k(n)$ conforme a equação abaixo:

$$e_k(n) = d_k(n) - y_k(n) \quad (03)$$

O objetivo deste algoritmo é minimizar uma função de erro quadrático ($\xi(n)$) baseada no $e_k(n)$, tal que a saída obtida de cada neurônio de saída se aproxime da saída desejada para aquele neurônio. A função de erro quadrático ($\xi(n)$) é definida como:

$$\xi(n) = \frac{1}{2} e_k^2(n) \quad (04)$$

A minimização da função ($\xi(n)$) em relação aos pesos sinápticos através do método do gradiente descendente é conhecida por regra delta e foi proposta por Widrow e Hoff (1960). $w_{kj}(n)$ é o valor do peso sináptico w_{kj} do neurônio k excitado por um elemento $x_j(n)$ do vetor de sinal $x(n)$ no instante de tempo n . A regra delta determina que o ajuste $\Delta w_{kj}(n)$ aplicado ao peso sináptico no instante n seja o seguinte:

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (05)$$

Assim, o valor atualizado do peso sináptico w_{kj} é determinado pela equação a seguir:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (06)$$

O parâmetro η é conhecido como parâmetro de taxa de aprendizado, e provoca um grande impacto na precisão do aprendizado por correção de erro. Se η for grande, a razão de aprendizado é acelerada, mas ocorre o perigo do processo de aprendizado divergir e o sistema tornar-se instável. Se η for pequena, a razão de aprendizado é suave, mas ocorre o perigo de levar um longo tempo para o sistema convergir para uma solução estável.

Pode-se caracterizar uma rede neural construindo um gráfico ($\xi(n)$) versus $w_{kj}(n)$. A superfície multidimensional construída é conhecida como superfície de erro. Dependendo do tipo de unidades de processamento usado para construir a rede neural, pode-se identificar duas situações:

- A rede neural possuir unidades de processamento lineares e a superfície de erro possuir um único ponto de mínimo;
- a rede neural possuir unidades de processamento não lineares e a superfície de erro possuir um ponto de mínimo global e vários pontos de mínimo local.

Nas duas situações, o objetivo do algoritmo de correção de erro é partir de um ponto qualquer sobre a superfície de erro (determinada pelos valores iniciais w_{kj}) para a direção de um mínimo global. Na primeira situação, o objetivo é alcançado, já na segunda situação o objetivo nem sempre é alcançado.

De acordo com Prosdocimo (1996), o problema do mínimo local é descrito como a possibilidade de o processo de aprendizado encontrar um mínimo local. O problema ocorre quando o erro encontrado é maior que o erro admissível e a rede neural artificial não consegue encontrar um ponto com um erro menor. Assim, a única solução é a reinicialização do aprendizado alterando alguns parâmetros livres da rede ou reiniciar a rede alterando os pesos.

2.2.7.2. APRENDIZADO HEBBIANO

Hebb (1949) através do livro "*The Organization of Behavior*" propôs o postulado de que, se um neurônio A é repetidamente estimulado por um outro neurônio B, ao mesmo tempo em que ele está ativo, ficará mais sensível aos estímulos de B, e a conexão sináptica de B para A será mais eficiente.

De acordo com Stent (apud HAYKIN, 1994), se dois neurônios forem ativados sincronamente (simultâneo), a força da sinapse será aumentada; e se forem assincronamente a força da sinapse será enfraquecida ou eliminada. Esta sinapse, chamada de sinapse Hebbiana, é definida como uma sinapse que usa um mecanismo dependente do tempo, altamente local e muito interativo para aumentar a eficiência sináptica como uma função da correlação entre as atividades pré-sinápticas e pós-sinápticas. Além disso, reconhece que uma atividade correlacionada positivamente produz um fortalecimento sináptico, e que uma atividade correlacionada negativamente ou sem correlação produz um enfraquecimento sináptico.

Brown *et al.* (1990) caracterizou a sinapse Hebbiana de acordo com os seguintes mecanismos:

- Mecanismo dependente do tempo: As modificações em uma sinapse Hebbiana dependem do tempo exato de ocorrência dos sinais pré-sinápticos e pós-sinápticos;
- mecanismo local: Uma sinapse é um local de transmissão de sinais onde os sinais que transportam a informação estão próximos sendo esta informação usada pela sinapse Hebbiana para produzir uma modificação sináptica local;
- mecanismo interativo: Uma mudança na sinapse Hebbiana depende da interação exata entre as atividades pré-sinápticas e pós-sinápticas;
- mecanismo conjuncional ou correlacional: A condição para uma mudança na eficiência sináptica é a conjunção das atividades pré-sinápticas e pós-sinápticas e também a correlação sobre o tempo entre essas atividades.

De acordo com o postulado de Hebb (1949), o ajuste do peso sináptico (Δw_{kj}) no tempo n pode ser representado pela seguinte equação:

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (07)$$

Na equação anterior, $F(,)$ é uma função de ambas as atividades pré-sinápticas e pós-sinápticas. Um caso simples da aprendizagem Hebbiana pode ser representada pela seguinte equação:

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (08)$$

onde η é uma constante positiva que determina a taxa de aprendizagem

A repetição do sinal de entrada (atividade pré-sináptica) x_j provoca um aumento de y_k levando a um crescimento exponencial que conduzirá o peso sináptico (w_{kj}) para uma saturação. Para evitar esta situação, Kohonen (1998), propôs a introdução de um fator não linear impondo um limite ao crescimento do peso sináptico (w_{kj}).

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) - a y_k(n) w_{kj}(n) \quad (09)$$

onde: a é uma constante positiva

2.2.7.3. APRENDIZADO COMPETITIVO

Neste tipo de aprendizado os neurônios competem entre si para serem ativados, pois o neurônio que fornece a resposta mais significativa para uma determinada entrada pode se modificar tornando mais equivalente a entrada. Conforme o sinal de entrada, um neurônio de saída melhor responderá por ela e será o vencedor, assim, sempre que esta entrada for apresentada, este neurônio será disparado. Assim, os neurônios individuais iram se especializar em conjuntos de padrões semelhantes.

O neurônio vencedor j terá a saída (y_j) igual a um, e os sinais de saída dos neurônios que perdem a competição são iguais a zero. Para cada neurônio distribui-se uma quantia fixa de pesos sinápticos nos seus nós de entrada representada pela expressão a seguir:

$$\sum_j w_{kj} = 1 \quad (10)$$

Se um neurônio ganha a competição, então cada nó de entrada daquele neurônio “abandona” uma proporção de seus pesos sinápticos que serão distribuídos entre os nós de entrada ativos. Se um neurônio não responder a um padrão de entrada, então nenhum aprendizado ocorre nele. Assim, o neurônio irá aprender transferindo os pesos sinápticos de seus nós de entrada inativos para os nós ativos.

Kohonen (1989) propôs o seguinte ajuste do peso sináptico:

$$\begin{aligned} \Delta w_{kj}(n) &= \eta(x_j(n) - w_{kj}(n)) && \text{se o neurônio } k \text{ vencer a competição} \\ \Delta w_{kj}(n) &= 0 && \text{se o neurônio } k \text{ perder a competição} \end{aligned} \quad (11)$$

Este tipo de aprendizado é muito utilizado para o descobrimento de características estatísticas semelhantes para a classificação de padrões de entrada. Para realizar a tarefa de agrupar os padrões de entrada (*clustering*), de maneira estável, estes devem se localizar em agrupamentos distintos, pois, caso contrário, a rede poderá não responder mais a um determinado padrão de entrada com o mesmo neurônio de saída.

2.2.8. PRINCIPAIS MODELOS DE REDES NEURAIS ARTIFICIAIS

2.2.8.1. PERCEPTRON

Esse modelo de rede, proposto por Rosenblatt (1962), possui neurônios básicos conectados em uma maneira simples. Sua função de ativação é a função do tipo Degrau ou *Heaviside* e seu aprendizado é supervisionado e baseado na sinapse Hebbiana. O fracasso da utilização deste tipo de rede foi provado por Minsky e Papert (1969). Eles demonstraram que redes

neurais de uma única camada, do tipo *Perceptron*, eram capazes de resolver apenas problemas linearmente separáveis. O algoritmo de aprendizado da rede *Perceptron*, de acordo com Orlandi (1997), pode ser visto a seguir:

2.2.8.1.1. ALGORITMO DA REDE PERCEPTRON

Inicializar os pesos e os *Thresholds* aleatoriamente

Repete enquanto houver padrões de entrada

Passo 1: Apresentar um padrão de entrada e a saída desejada

Passo 2: Calcular as Saídas

$$y_k(t) = f_a \left[\sum_{j=0}^p w_{kj}(t)x_j(t) \right]$$

Ative o passo ajuste de pesos

Passo 3: Ajuste de Pesos

Se $y_k(t)$ estiver correta :

$$w_{kj}(t+1) = w_{kj}(t)$$

Se $y_k(t) = 0$, mas deveria ser 1 :

$$w_{kj}(t+1) = w_{kj}(t) + x_j(t)$$

Se $y_k(t) = 1$, mas deveria ser 0 :

$$w_{kj}(t+1) = w_{kj}(t) - x_j(t)$$

Passo 4: Se o erro for aceitável,

Fim,

Se não for,

Volte ao passo 1.

2.2.8.2. REDES DE MÚLTIPLAS CAMADAS (MLP)

As arquiteturas de redes de múltiplas camadas ou *MultiLayer Perceptron* (MLP) são os modelos de redes neurais artificiais mais conhecidos e utilizados com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. A arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas

intermediárias(ou escondidas) de unidades computacionais e uma camada de saída. Os sinais se propagam camada a camada pela rede, ou seja, da camada de entrada para a camada de saída em uma direção positiva. Seu treinamento é do tipo supervisionado e utiliza o algoritmo chamado de retropropagação do erro (backpropagation) baseado na regra de aprendizado que corrige o erro durante o treinamento.

Uma rede neural de múltiplas camadas pode ser representada pela figura 10. Nesta rede todos os neurônios de uma camada estão conectados com os neurônios da próxima camada, ou seja, possui todas as conexões.




Figura 10 - Rede Neural de múltiplas camadas (HAYKIN, 1999)

A camada de entrada é composta por neurônios sensoriais que não modificam os sinais externos, ou seja, não processa nenhuma informação apenas distribui para a próxima camada. As unidades de saída constituem a camada de saída da rede e as demais unidades constituem as camadas intermediária. Essas camadas intermediárias ou de saída são responsáveis por duas tarefas:

- Calcular o sinal de saída da unidade, que normalmente é expresso como uma função não linear do sinal de entrada e pesos sinápticos associados;
- Calcular uma estimativa instantânea do vetor gradiente, que é necessário para a retropropagação do erro através do erro.

O processo de retropropagação do erro é constituído de duas fases: propagação do sinal funcional (“*feedforward*”) e uma de retropropagação do erro (“*backpropagation*”). Na fase positiva, os vetores de dados são aplicados às unidades de entrada, e seu efeito se propaga pela rede, camada a camada, produzindo um conjunto de saídas como respostas da rede. Durante esta fase os pesos das conexões são mantidos fixos. Na retropropagação do erro, os pesos são ajustados através da regra de correção de erro, ou seja, a resposta da rede num instante de tempo é subtraída da saída desejada produzindo um sinal de erro. Este sinal de erro é propagado da saída para a entrada, camada a camada, dando origem ao nome “retropropagação do erro”. Assim, os pesos são ajustados para reduzir a diferença da resposta da rede e a resposta desejada. Na figura 11 pode-se observar os dois tipos de sinais.

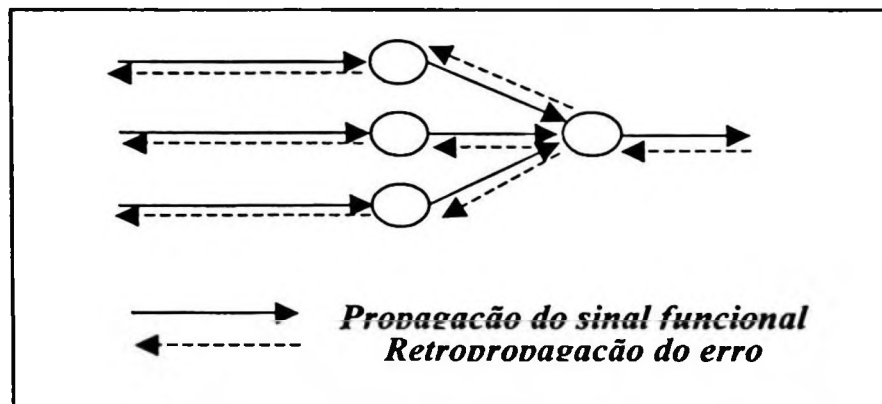


Figura 11: Ilustração das direções de dois fluxos de sinal: propagação do sinal funcional e retropropagação do erro (HAYKIN, 1999)

- sinal funcional: um sinal funcional é um sinal de entrada (estímulo) que chega na entrada e é propagado positivamente (neurônio a neurônio) através da rede, e aparece na saída como um sinal de saída.
- sinal de erro: os sinais de erro se originam nas saídas e são retropropagados (neurônio a neurônio) através da rede.

2.2.8.2.1. ALGORITMO DE MLP

De acordo com Orlandi (1997), o algoritmo de redes de múltiplas camadas pode ser visto a seguir.

Passo 1: Apresentar um padrão de entrada e a saída desejada

Coloque os padrões de entrada na camada de entrada e saída desejada nas respectivas camadas, através de uma estratégia de apresentação, então ative o passo calcule saída.

Passo 2: Calcular as Saídas

A partir da primeira camada, permita que cada camada produza os valores de saída até atingir a camada de saída, e então ative o passo ajuste pesos da camada de saída.

Passo 3: Ajuste de Pesos

Para cada neurônio j da camada de saída, atualize todos os pesos w_{ij} de acordo com a equação a seguir, em seguida ative o passo ajuste de pesos das camadas escondidas.

$$\Delta w_{ij} = \eta \delta_j o_i$$

onde:

η : taxa de aprendizado

o_i : saída do neurônio

δ_j : diferença (erro) entre a saída obtida e a saída desejada do neurônio j , calculada pela seguinte equação:

$$\delta_j = o_j (d_j - o_j) (1 - o_j)$$

onde: d_j é a saída desejada de n_j

Passo 4: Ajuste de pesos das camadas escondidas

Para ajustar os pesos de todas as camadas escondidas, deve-se atualizar o peso w_{ki} de um neurônio n_i de uma camada escondida que está ligado a outro neurônio n_k na camada anterior conforme a seguinte equação:

$$\Delta w_{ki} = \eta \delta_i o_k$$

onde:

η : taxa de aprendizado

δ_i : erro relativo do neurônio n_i , de acordo com a seguinte equação:

$$\delta_i = o_i (1 - o_i) \sum w_{ij} \delta_j$$

o_k : saída de n_k , que estimula n_i via w_{ki}

Após todas as conexões terem sido ajustadas ative o passo cheque magnitude do erro.

Passo 5: Cheque Magnitude do Erro

Para cada padrão é calculada a função de erro quadrático (ξ)

$$\xi = \frac{1}{2} \sum_{j=1}^p (d_j - o_j)^2$$

O erro médio quadrático (ξ_{av}) é calculado da seguinte forma:

$$\xi = \frac{1}{N} \sum_{N=1}^N \xi$$

Se o erro médio quadrático for aceitável,

Fim

Se não for,

Volte ao passo 1.

2.2.8.3. REDE DE KOHONEN

Este tipo de rede possui os neurônios amplamente conectados com as entradas, simulando as funções de aprendizado de certas áreas do cérebro (córtex). A definição de vizinho é fundamental para a compreensão da rede, assim, um neurônio i possui vizinhos como $i+1$ e $i-1$ formando a vizinhança um conjunto de vizinhos que inicia extenso e é diminuído com o tempo.

O vetor de pesos do neurônio que gerar a menor distância euclidiana (d_e) com o vetor de entrada será o vencedor. Neste modelo não supervisionado e competitivo, os pesos do neurônio vencedor e seus vizinhos são ajustados dentro de um certo raio. Após o treinamento, a rede está apta a fazer agrupamentos, sendo os grupos rotulados para indicar as classes que representam. A equação da distância euclidiana (d_e) pode ser vista a seguir:

$$d_e = \sum (x_i - w_{ji})^2 \quad (12)$$

Para aumentar a eficiência da rede neural no reconhecimento de padrões, a rede Kohonen, após o treinamento, pode passar por um ajuste na camada de neurônios. Dentro os diversos ajustes possíveis, o vetor de quantização de aprendizado (LVQ) é o mais utilizado. Os algoritmos da rede Kohonen e do algoritmo LVQ, de acordo com Orlandi (1997), podem ser vistos a seguir.

2.2.8.3.1. ALGORITMO DE APRENDIZADO DA REDE KOHONEN

Inicializar os pesos dos neurônios com valores aleatórios baixos (baixos em relação aos valores de entrada)

Definir o raio de vizinhança de cada neurônio e a taxa de aprendizado inicial

Repita enquanto houver padrões de entrada

Passo 1: Apresentar uma entrada à rede

Passo 2: Calcular a distância euclidiana entre a entrada e os pesos para cada neurônio de saída

$$d_e = \sum_{j=1}^p (x_i(t) - w_{ji}(t))^2$$

Passo 3: Selecionar o neurônio vencedor, ou seja, o neurônio que apresentar a menor distância euclidiana

Passo 4: Os pesos do neurônio selecionado são atualizados juntamente com todos os neurônios que estão dentro da vizinhança

$$w_{ji}(t+1) = w_{ji}(t) + \eta(t)(x_i(t) - w_{ji}(t))$$

Passo 5: Reduzir a taxa de aprendizado

Passo 6: Reduzir o raio

Até raio < raio mínimo

2.2.8.3.2. ALGORITMO LVQ

Passo 1: Selecionar os vetores de treinamento com classificação conhecida

Passo 2: Definir o raio e a taxa de aprendizado iniciais

Repita enquanto houver padrões de entrada

Passo 3: Para cada padrão de treinamento com classificação conhecida

Para cada neurônio

Calcular a distância euclidiana

Selecionar o neurônio com menor distância

Passo 4: Atualizar os pesos do neurônio vencedor e de seus vizinhos

$$w_{ji}(t+1) = w_{ji}(t) + \eta(t)(x_i(t) - w_{ji}(t)) \quad (\text{correta})$$

$$w_{ji}(t+1) = w_{ji}(t) - \eta(t)(x_i(t) - w_{ji}(t)) \quad (\text{incorreta})$$

Reduzir a taxa de aprendizado

Se o erro for aceitável,

Fim

Se não for,

Volte ao passo 3

2.2.8.4. REDE HOPFIELD

A rede de Hopfield, utiliza o neurônio básico de McCulloch e Pitts (1943) como unidade de processamento, onde cada neurônio calcula a sua entrada ponderada menos o threshold e através da função de ativação degrau ou Heaviside para a determinação do seu estado de saída (-1,+1). Aplica-se em todos os nós simultaneamente as entradas da rede, continuando o ciclo através de uma sucessão de estados até a convergência para uma solução estável. A ocorrência desta solução é a não alteração dos valores dos nós. A diferença de operação entre o perceptron e a rede Hopfield está na obtenção solução. No perceptron as entradas aplicadas são ponderadas e a rede produz uma saída que representa a solução. Na rede Hopfield, a primeira saída é levada como uma nova entrada, produzindo uma nova saída, que irá ser

novamente uma entrada. Este processo de obtenção irá ocorrer até quando não houver mais modificação de ciclo para ciclo, ou seja, quando a saída alcançar uma estabilidade.

De acordo com Haykin (1994) a rede Hopfield possui duas fases: Fase de Armazenagem e Fase de Recuperação.

- Fase de Armazenagem: Suponha uma solução de vetores N-dimensionais denotados por $\{Z_{\mu} / \mu = 1, 2, \dots, p\}$. Estes vetores são chamados de memórias fundamentais e representam os padrões a serem memorizados pela rede. O elemento $Z_{\mu, i}$ é um elemento de memória fundamental e de acordo com a generalização do aprendizado de Hebb, é o peso sináptico de um neurônio i para o neurônio j definido por:

$$w_{ji} = \sum_{\mu=1}^p Z_{\mu, j} Z_{\mu, i} \quad (13)$$

- Fase de Recuperação: Durante esta fase, deve-se apresentar um Vetor V que representa uma versão incompleta ou com ruído de uma memória fundamental da rede. A recuperação da informação ocorre seguindo a regra dinâmica na qual calcula-se para cada neurônio a entrada ponderada, comparada com o threshold para a obtenção dos estados de saída (-1 ou +1). Este processo irá continuar até não ocorrer mais mudanças de estados.

A rede Hopfield é uma recorrente, completamente conectada e com pesos sinápticos simétricos. O treinamento é não supervisionado e é baseado na sinapse Hebbiana. Pode ser utilizada como memória associativa ou memória endereçável por conteúdo. Sua função principal é recuperar um padrão armazenado na memória em resposta à apresentação de uma versão incompleta ou com ruídos. O algoritmo da rede Hopfield, de acordo com Orlandi (1997), pode ser visto a seguir.

2.2.8.4.1. ALGORITMO DE APRENDIZADO DA REDE DE HOPFIELD

Passo 1: Designar os pesos da conexão

$$w_{ji} = \sum_{\mu=1}^p Z_{\mu i} Z_{\mu j} \quad i \neq j$$

$$w_{ji} = 0 \quad i = j$$

Passo 2: Inicializar com um padrão desconhecido

$$s_j(0) = v_j, \quad j = 1, \dots, N$$

Passo 3: Iterar até a convergência

$$s_j(t+1) = f_a \left[\sum_{i=0}^N w_{ji} s_i(t) \right]$$

Repete a iteração até as saídas dos nós continuarem inalteradas

2.2.9. TAREFAS DE APRENDIZADO

A tarefa que uma rede neural executa irá influenciar na escolha do algoritmo de aprendizado. Assim, conforme Haykin (1999) as principais tarefas de aprendizado são:

2.2.9.1. ASSOCIAÇÃO

A associação pode ser classificada em heteroassociação ou auto-associação. Na heteroassociação um conjunto arbitrário de padrões de entrada é associado a um outro conjunto arbitrário de padrões de saída. Na auto-associação, uma rede neural armazena um conjunto de padrões repetidamente apresentados. Depois, é apresentada à rede uma descrição alterada do padrão original armazenado e a tarefa é recordar o padrão original. A diferença entre as duas formas de associação é devido ao fato de a heteroassociação mapear um conjunto de pares de entrada e saída conhecidos, ou seja, através de um aprendizado supervisionado, enquanto a auto-associação envolve um aprendizado não supervisionado.

2.2.9.2. RECONHECIMENTO DE PADRÕES

Esta tarefa de aprendizado tem a tarefa de classificar padrões de entrada em categorias ou classes. Inicialmente, através de uma seção de treinamento, as redes neurais recebem um conjunto de padrões repetidas vezes com a categoria que cada padrão pertence. Em seguida, novos padrões de entrada ainda desconhecidos mas pertencentes à mesma população de padrões utilizada para treinar a rede, são apresentados à rede, que tem a tarefa de classificar esses novos padrões corretamente. Os reconhecimentos de padrões são representados por regiões, cada uma das quais associadas a uma classe. Este tipo de classificação pode ser realizado por um aprendizado supervisionado. Pode-se utilizar um aprendizado não supervisionado para fazer a classificação de padrões que a priori não possui categorias previamente estabelecidas. A função de classificar padrões por redes neurais tem a vantagem desta construir fronteiras de decisões, definidas pelo processo de treinamentos, não lineares entre as diferentes classes e ainda oferece um método prático para resolver problemas altamente complexos de classificação.

2.2.9.3. APROXIMAÇÃO

Considere uma função definida por $y = f(x)$, onde o vetor x é a entrada, y é a saída e $f(\)$ uma função desconhecida. Pode-se utilizar uma rede neural para aproximar uma função não linear ($f(\)$), através dos pares de vetores de entrada e saída $\{ (x_1, y_1), (x_2, y_2), (x_3, y_3), (x_4, y_4), \dots, (x_N, y_N) \}$. Um problema de aproximação com estas características, pode ser solucionado através de um aprendizado supervisionado onde x_i desempenha o vetor de entrada e y_i desempenha a saída desejada.

2.2.9.4. CONTROLE

O controlar significa manter em condição controlada um processo ou uma parte de um sistema. Esta é uma tarefa de aprendizado que uma rede neural pode exercer da seguinte maneira: suponha um sistema dinâmico desconhecido não linear definido por $\{x(t), y(t)\}$, onde $x(t)$ é a entrada do controle e $y(t)$ é a saída. Escolhe-se um modelo de referência onde o objetivo é determinar um limite da entrada do controle, para que ocorra a trajetória desejada determinada pelo modelo. Neste tipo de tarefa o aprendizado por reforço é o mais comumente utilizado.

2.2.9.5. FILTRAGEM

Tarefa de aprendizado utilizado para extração de informações sobre uma determinada grandeza de interesse partindo de um conjunto de dados ruidosos, podendo esses ruídos surgir de diversas fontes. Com a utilização de um filtro pode-se realizar uma previsão do processamento de informação, sendo a previsão um dos seus principais objetivos. Um conjunto de valores passados $\{x(t-1), x(t-2), \dots, x(t-M)\}$ é utilizado para prever um exemplo do presente $\{x(t)\}$. Este tipo de previsão pode ser resolvido utilizando um aprendizado por correção de erro de uma maneira não supervisionada, sendo os exemplos de treinamento retirados do próprio processo. Suponha-se que $x(t)$ seja a resposta desejada, $\hat{x}(t)$ a previsão produzida pela rede neural. A diferença entre $x(t)$ e $\hat{x}(t)$ será o sinal de erro $\{e(t)\}$ utilizado para ajustar os parâmetros livres da rede neural.

2.2.9.6. FORMAÇÃO DE FEIXE

Esta tarefa de aprendizado é geralmente utilizada para localizar um alvo, como em sistemas de radar e sonar. Seu objetivo é detectar um alvo de interesse sofrendo um sinal interferência e de um ruído do receptor. Neste caso, a rede neural pode ter seus parâmetros livres ajustados através de um algoritmo de aprendizagem por correção de erro.

III – PROCEDIMENTOS METODOLÓGICOS

3.1. TIPO DE PESQUISA

O presente trabalho visa analisar como os preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do Álcool Anidro Combustível no Estado de São Paulo se comporta frente ao preço do barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent Spot (mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc.* (CSCE), pertencente à *New York Board of Trade* (NYBOT) e a taxa de câmbio comercial e como é feita a previsão desses produtos por meio de redes neurais artificiais.

A escolha de RNA como técnica nesse estudo, decorreu ao fato de sua aplicação nas mais diversas áreas da administração incluindo trabalhos de previsão e análise. Uma abordagem estruturada de concepção de redes neurais mostra-se necessária devido aos parâmetros que podem ser alterados na configuração de uma rede neural (número de camadas e números de neurônios intermediários) e também ao tempo necessário para explorar a influência desses parâmetros.

Este trabalho propõe a concepção e execução de um plano experimental, baseado no trabalho de Almeida e Dumontier (1996), para explorar a influência dos parâmetros: número de camadas e número de neurônios intermediários. A avaliação do plano é feita através da análise do erro percentual médio obtido pela rede na fase de validação do modelo, e posteriormente, através de uma análise gráfica. Um grupo (portfólio) de redes é elaborado, a partir do plano experimental, que reúne um determinado número de redes ótimas incorporando conhecimentos sobre a previsão de preços da indústria canavieira. Ele pode servir como uma base de conhecimento a ser introduzido em um sistema de apoio à decisão, atenuando o erro produzido pelo uso de apenas uma rede.

3.2. DEFINIÇÃO DAS VARIÁVEIS

A participação do Brasil no mercado internacional de açúcar é elevada, aproximadamente 40% das exportações mundiais são nacionais. Silveira (2004) analisou alguns aspectos da relação do mercado doméstico brasileiro desta commodity com os preços internacionais. Nesse trabalho, foi analisado o impacto da produção brasileira de açúcar (potencial de exportação dessa commodity) sobre a formação do preço no mercado internacional. O mesmo utilizou as cotações do contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc. (CSCE)*, pertencente à *New York Board of Trade (NYBOT)* na análise da influência da produção brasileira sobre os preços internacionais, considerando-se que esta bolsa é a maior referência para o mercado de açúcar e a que tem maior liquidez.

Desta maneira, baseado no trabalho de Silveira (2004) e devido ao fato do Brasil ser responsável por cerca de 40% das exportações mundiais de açúcar, foram escolhidas as variáveis: preço do barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent Spot (mercado europeu), contrato futuro de açúcar bruto nº11 da bolsa de Nova Iorque, a *Coffe, Sugar & Cocoa Exchange Inc. (CSCE)*, pertencente à *New York Board of Trade (NYBOT)* e a taxa de câmbio comercial para análise de impacto nos preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do álcool anidro combustível no Estado de São Paulo seguindo as especificações da Agência Nacional de Petróleo – ANP.

As séries de preços do açúcar cristal, representada por SSP, e do Álcool Anidro Combustível, representada por ASP, utilizadas no estudo é a aferida pelo Centro de Estudos Avançados em Economia Aplicada (CEPEA) da Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo. Justifica-se a utilização desses dados para o mercado doméstico pelo fato do Estado de São Paulo ser o responsável por aproximadamente 60% da produção de açúcar e álcool nacional.

As séries de preços da bolsa de futuro *New York Board of Trade (Nybot)*, representada por SNY, foi utilizada como referência sobre os preços internacionais. A série da taxa de câmbio comercial, representada por TCC, foi obtida junto ao Instituto de Pesquisa Econômica Aplicada (IPEA). As séries do barril de petróleo WTI Spot, representada por PNA, e Europe

Brent Spot, representada por PEB, foram obtidas junto ao United States Department of Agriculture (USDA).

A periodicidade escolhida para o estudo da identificação dos fatores de impacto nos preços do açúcar e álcool no Estado de São Paulo, foi a semanal. A utilização de dados semanais justifica-se por permitir a rápida transmissão entre os valores envolvidos no trabalho, o que poderia não ocorrer se os valores fossem mensais. Os dados do presente trabalho correspondem ao período entre 04/07/2000 e 30/12/2004 e totalizam 235 semanas.

3.3. ETAPAS DA EXECUÇÃO DA PESQUISA

A abordagem proposta, para a execução desta pesquisa segue os seguintes passos:

- i. definição de um plano experimental;
- ii. levantamento das variáveis de estudo;
- iii. construção das redes neurais a partir do plano experimental;
- iv. análise gráfica dos resultados.

3.4. INSTRUMENTOS PARA A EXECUÇÃO DO PROJETO DE PESQUISA

De acordo com Shih (1994), o aplicativo computacional utilizado como emulador de Redes Neurais foi o Neuralyst®. Para o desenvolvimento do trabalho o aluno teve disponíveis os recursos do Núcleo de Apoio Computacional (NAC) do Departamento de Administração da FEA/USP Ribeirão Preto. O NAC conta com um número suficiente de microcomputadores do tipo Pentium e estações de trabalho IBM, necessários para o desenvolvimento do trabalho. Parte do material bibliográfico necessário para a pesquisa se encontra disponível na biblioteca central do Câmpus da Universidade de São Paulo – Ribeirão Preto. O complemento do material foi feito com artigos recentes, os quais foram obtidos por meio dos programas de Comutação Bibliográfica da USP (programa COMUT), via Internet e bibliotecas co-irmãs.

3.5. DEFINIÇÃO DE UM PLANO EXPERIMENTAL

Os seguintes elementos serão explorados através do plano experimental:

- i. número de camadas intermediárias: os números de camadas intermediárias foram explorados utilizando-se uma, duas, três e quatro camadas intermediárias;
- ii. número de neurônios intermediários: em cada camada o número de neurônios foi limitado à: 10, 20 e 30 neurônios.

O plano experimental para o erro médio percentual para previsão do açúcar e do álcool pode ser visto na tabela 04.

Tabela 04 - Erro médio percentual para previsão do açúcar e do álcool

Número camadas intermed.	Nº de neurônios nas camadas intermed.	SNY/TCC	PNA/SNY/TCC	PEB/SNY/TCC	PEB/PNA/SNY/TCC
Uma Camada	10				
	20				
	30				
Duas Camadas	10 10				
	20 20				
	30 30				
Três Camadas	10 10 10				
	20 20 20				
	30 30 30				
Quatro Camadas	10 10 10 10				
	20 20 20 20				
	30 30 30 30				

IV – APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Visando analisar como os preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do Álcool Anidro Combustível no Estado de São Paulo se comportam frente ao preço do barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent Spot (mercado europeu), contrato futuro de açúcar bruto nº11 da Csce/Nybot e a taxa de câmbio comercial foi utilizado o aplicativo computacional Neuralyst®, de acordo com Shih (1994), como emulador de Redes Neurais.

Inicialmente foram coletados os dados para a pesquisa via internet com periodicidade semanal. A utilização de dados semanais justifica-se por permitir a rápida transmissão entre os valores envolvidos no trabalho, o que poderia não ocorrer se os valores fossem mensais. Os dados do presente trabalho correspondem ao período entre 04/07/2000 e 30/12/2004, totalizam 235 semanas e podem ser vistos em anexo deste trabalho. As fontes de coleta de dados juntamente com a sigla utilizada neste trabalho pode ser vista na tabela 06.

Quadro 01 - Fonte da coleta de dados

Variável	Sigla	Tipo	Fonte de coleta
Açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno	SSP	Dependente	www.cepea.esalq.usp.br
Álcool Anidro Combustível no Estado de São Paulo	ASP	Dependente	www.cepea.esalq.usp.br
Barril de petróleo <i>WTI Spot</i> (mercado norte-americano)	PNA	Independente	www.usda.gov
Barril de petróleo <i>Europe Brent Spot</i> (mercado europeu)	PEB	Independente	www.usda.gov
Contrato futuro de açúcar bruto nº11 da Csce/Nybot	SNY	Independente	www.nybot.com
Taxa de câmbio comercial	TCC	Independente	www.ipeadata.gov.br

Os dados obtidos foram divididos em subconjuntos distintos: subconjunto de treinamento (90% dos dados) e subconjunto de validação (10% dos dados). Os dados foram divididos aleatoriamente entre os conjuntos através do software Neuralyst®. Foi utilizada uma rede de múltiplas camadas (MLP), feedforward, algoritmo back-propagation, com função de ativação sigmoidal e supervisionada.

Os parâmetros de aprendizado utilizados foram: taxa de aprendizado = 1 e momentum = 0,9. O fator limitante de parada na fase de treinamento foi o número de épocas de treinamento, fixado em 1000 épocas de treinamento.

Inicialmente na previsão dos preços do açúcar e álcool, foram utilizadas as variáveis contrato futuro de açúcar bruto nº11 da Csce/Nybot (SNY) e a taxa de câmbio comercial (TCC) que, de acordo com Silveira (2004), têm influência nos preços dos mercados domésticos do Brasil pelo fato do país ser responsável por cerca de 40% das exportações mundiais de açúcar. Em seguida, foram acrescentados os dados dos preços do barril de petróleo WTI Spot (PNA) e Europe Brent Spot (PEB) com o objetivo de analisar se estas entradas influenciam os preços do açúcar e álcool no mercado interno, devido ao fato do álcool anidro e a gasolina serem utilizados em nosso país como combustível e sendo uma parcela de álcool adicionada à gasolina.

As tabelas e gráficos com os erros percentuais na previsão do açúcar e do álcool podem ser vistos a seguir:

Tabela 05 - Erro médio percentual para previsão do açúcar

Número camadas intermed.	Nº de neurônios nas camadas intermed.	SNY/TCC	PNA/SNY/TCC	PEB/SNY/TCC	PEB/PNA/SNY/TCC
Uma Camada	10	9,93	9,92	8,5	7,61
	20	9,18	10,59	8,45	8,06
	30	9,53	9,83	8,68	7,6
Duas Camadas	10 10	9,68	8,62	7,38	8,18
	20 20	9,78	9,12	7,59	7,51
	30 30	8,82	9,02	7,54	6,93
Três Camadas	10 10 10	10,23	9,56	11,3	10,57
	20 20 20	9,5	8,99	5,8	7,31
	30 30 30	8,66	8,09	6,92	6,84
Quatro Camadas	10 10 10 10	15,26	14,77	16,74	14,59
	20 20 20 20	14,34	16,36	16,87	12,32
	30 30 30 30	16,85	16,86	17,09	15,18
	Média do Erro Percentual	10,98	10,98	10,24	9,39

De posse dos valores da tabela 05, obteve-se o gráfico da figura 12.

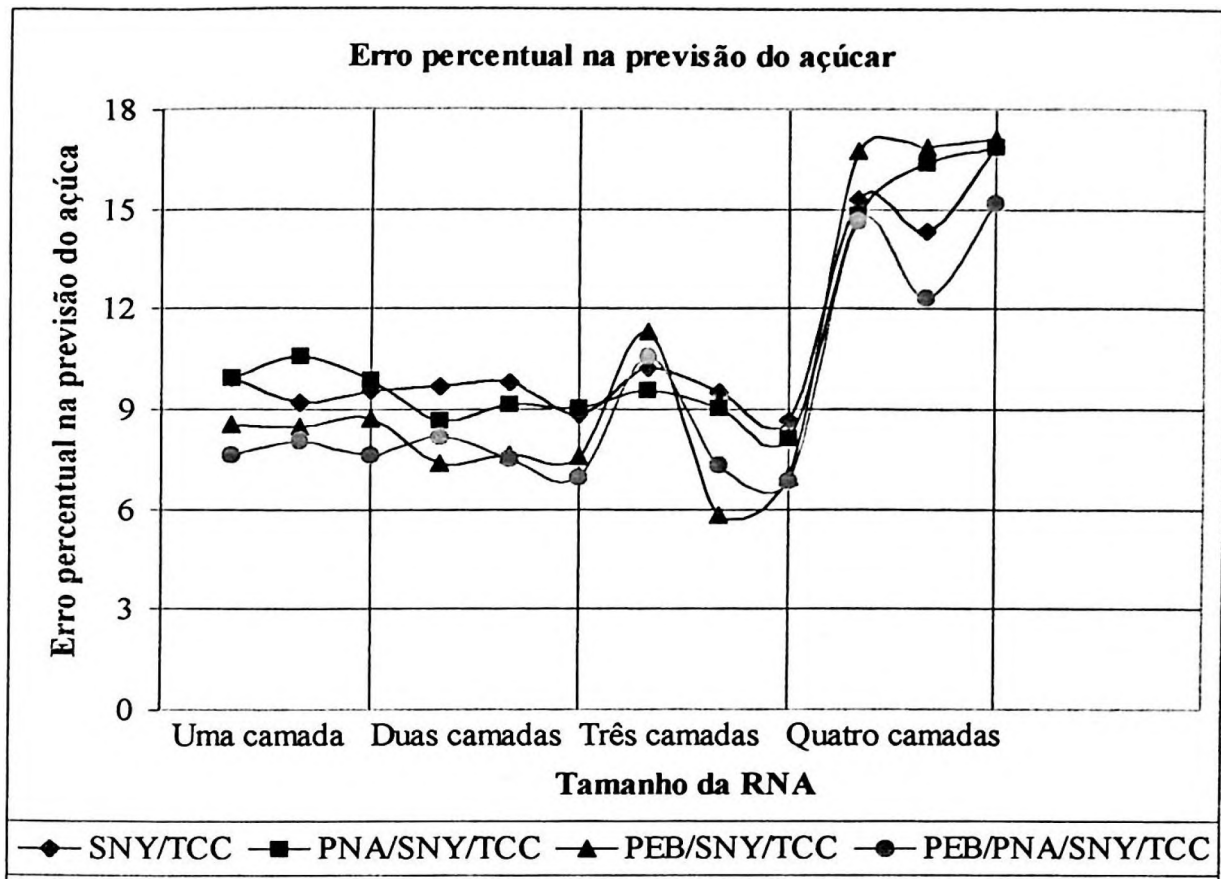


Figura 12 - Gráfico do erro médio percentual na previsão dos preços do açúcar

Na análise das previsões obtida, observa-se que a média do erro percentual declina de 10,98% para 9,39% com o acréscimo de variáveis independentes. Nota-se que o acréscimo da variável petróleo negociado na Europa (PEB) causou um erro percentual (10,24%) menor que o erro percentual (10,98%) com acréscimo isolado da variável petróleo negociado no mercado norte americano (PNA).

Deve-se notar que o acréscimo de camadas intermediárias continuamente não irá provocar uma diminuição contínua do erro percentual. O erro percentual médio obtido para a configuração de rede de quatro camadas intermediárias provocou uma ascensão no erro conforme se observa na figura 12.

Tabela 06 - Erro médio percentual para previsão do álcool

Número camadas intermed.	Nº de neurônios nas camadas intermed.	SNY/TCC	PNA/SNY/TCC	PEB/SNY/TCC	PEB/PNA/SNY/TCC
Uma Camada	10	13,29	11,46	14,55	13,53
	20	12,19	11,49	13,19	16,05
	30	13,84	11,97	14,13	14,08
Duas Camadas	10 10	12,61	10,36	12,49	7,95
	20 20	12,56	15,71	9,28	9,50
	30 30	12,72	10,70	9,46	9,68
Três Camadas	10 10 10	14,50	12,27	9,97	10,06
	20 20 20	13,99	10,47	9,29	10,32
	30 30 30	14,96	10,89	8,94	8,06
Quatro Camadas	10 10 10 10	20,85	19,67	20,83	18,31
	20 20 20 20	18,31	20,84	19,37	17,82
	30 30 30 30	21,27	20,13	18,02	19,23
	Média do Erro Percentual	15,09	13,78	13,29	12,88

De posse dos valores da tabela 08, obteve-se o gráfico da figura 13




Figura 13: Gráfico do erro médio percentual na previsão dos preços do álcool

Na análise das previsões obtida, observa-se que a média do erro percentual declina de 15,09% para 12,88% com o acréscimo de variáveis independentes. Nota-se que o acréscimo da variável petróleo negociado na Europa (PEB) causou um erro percentual (13,29%) menor que o erro percentual (13,78%) com acréscimo isolado da variável petróleo negociado no mercado norte americano (PNA).

Deve-se notar que o acréscimo de camadas intermediárias continuamente não irá provocar uma diminuição contínua do erro percentual. O erro percentual médio obtido para a configuração de rede de quatro camadas intermediárias provocou uma ascensão no erro conforme se observa na figura 13.

Um dos problemas enfrentados no treinamento de rede *multi layer perceptron* (MLP) diz respeito à definição de seus parâmetros. A seleção dos parâmetros (número de camadas e número de neurônios) de treinamento do algoritmo back-propagation é um processo pouco conhecido, onde pequenas diferenças, nestes parâmetros, podem levar a grandes divergências. No caso específico, pode causar grandes alterações nos erros percentuais.

O critério de parada de treinamento da rede pode ser um fator que influencie a capacidade de generalização da RNA. O critério utilizado foi encerrar o treinamento após 1000 épocas de treinamento, mas poderiam ser utilizados outros critérios, ou combinação de métodos, como:

- encerrar o treinamento após o erro quadrático médio ficar abaixo de uma constante c ;
- encerrar o treinamento quando a percentagem de classificações corretas estiverem acima de uma constante c .

Outro aspecto que precisa ser observado é a frequência das atualizações dos pesos. A frequência de ajustes dos pesos influencia o desempenho obtido durante o treinamento. Duas abordagens diferentes têm sido utilizadas quanto à frequência (periodicidade) para o ajuste de pesos pelo algoritmo back-propagation:

- por padrão (on-line);
- por ciclo (batch).

Em cada abordagem há vantagens e desvantagens. Na abordagem por padrão, os pesos são atualizados após a apresentação de cada padrão de treinamento. Esta abordagem é estável se a taxa de aprendizado for pequena (é aconselhável reduzir progressivamente esta taxa). Ao utilizar taxas elevadas, a rede torna-se instável. A abordagem por padrão é mais rápida, principalmente, se o conjunto de treinamento for grande e redundante. Outra vantagem desta técnica é que ela requer menos memória.

Na abordagem por ciclo, os pesos são atualizados após todos os padrões terem sido apresentados. Esta técnica é mais estável, mas ela pode ser lenta, se o conjunto de treinamento for grande e redundante. No presente trabalho, foi utilizado o critério de parada após n ciclos (1000 ciclos de treinamento) com a frequência de ajustes dos pesos por padrão.

V – CONCLUSÕES E RECOMENDAÇÕES

5.1. CONCLUSÕES

No presente estudo foram analisadas a influência das variáveis preços do barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent Spot (mercado europeu), contrato futuro de açúcar bruto nº11 da Csce/Nybot e a taxa de câmbio comercial na previsão dos preços do açúcar cristal acondicionado em sacas de 50 kg negociado no mercado à vista do Estado de São Paulo destinado ao mercado interno e do álcool anidro combustível no Estado de São Paulo seguindo as especificações da Agência Nacional de Petróleo – ANP, utilizando redes neurais artificiais.

Na caracterização do setor agro-industrial açucareiro, realizada no início dessa dissertação e de acordo Silveira (2004), o Brasil apresenta uma participação elevada no mercado internacional de açúcar, aproximadamente 40% das exportações mundiais são nacionais, o que justifica a realização de estudos dessa natureza. A escolha das variáveis preço do barril de petróleo WTI Spot (mercado norte-americano) e Europe Brent Spot (mercado europeu), deve-se ao fato do álcool anidro e a gasolina serem utilizados em nosso país como combustível e sendo uma parcela de álcool adicionada à gasolina. Assim, espera-se que os seus valores sejam relacionados entre si.

Como o álcool e o açúcar são obtidos no Brasil da mesma matéria-prima, a cana-de-açúcar, utilizou-se as mesmas variáveis na previsão dos preços do açúcar e álcool, e posteriormente, no cálculo do erro médio percentual.

A escolha de RNA como técnica nesse estudo, decorreu ao fato de sua aplicação nas mais diversas áreas da administração incluindo trabalhos de previsão e análise. A rede neural pode ser entendida como um instrumento da tecnologia da informática, que permite o auxílio à organizações na tomada de decisões, transformando dados em informações úteis.

A aplicação de redes neurais contempla diversas áreas de conhecimento, de diagnósticos médicos até em detecção de falhas em estruturas. Na administração, pode ser utilizada em finanças, marketing, vendas ou compras e até mesmo em recursos humanos. Na área de recursos humanos, pode-se utilizar RNA para verificar se o perfil de um candidato é

condizente com determinada vaga de emprego. Na área de marketing, utiliza-se para simular o comportamento do consumidor face a novos produtos, simular as vendas para um próximo período em função do resultado obtido em período anterior ou ainda sugerir produtos mais adaptados ao perfil de cada cliente. Na área financeira, pode-se utilizar para avaliações de crédito, de riscos de inadimplência de empresas, de riscos de seguros, riscos de hipotecas, ou mesmo avaliação de riscos de papéis financeiros.

Dentre as características das redes neurais artificiais, a capacidade de aprendizado, ou seja, a possibilidade de estabelecer relações entre diversas variáveis, é uma de grande destaque. Essa abordagem contrasta com a computação programada que requer algoritmos detalhados.

Outra característica interessante das redes neurais artificiais é que, uma vez construídas, elas não dependem mais da base de dados de origem, ou seja, o conhecimento adquirido está nas conexões (pesos) entre os neurônios.

Uma crítica que pode ser feita aos sistemas neuronais, mais precisamente no treinamento de rede MLP, diz respeito à definição de seus parâmetros. A seleção dos parâmetros de treinamento do algoritmo back-propagation é um processo pouco conhecido, muitas vezes chamado de “caixa preta”. Pequenas diferenças nestes parâmetros podem levar a grandes divergências tanto no tempo de treinamento como na generalização obtida.

Através dos resultados obtidos, conclui-se que a rede utilizada para resolver o problema de previsão de preços do açúcar e álcool é uma ferramenta útil para uma tomada de decisão.

5.2. TRABALHOS FUTUROS

Em termos de trabalhos futuros, há alguns projetos e adaptações que podem estender o trabalho desenvolvido:

- realizar um estudo mais rigoroso da série a ser prevista, com um pré-tratamento minucioso da série, buscando eliminar possíveis informações não significativas, juntamente com uma ampliação da periodicidade com um maior número de observações;
- avaliar e comparar com RNA's outros algoritmos de treinamento, se possível, com os que não apresentam problemas intrínsecos do método do gradiente descendente, ou seja, a respeito do tempo de treinamento e de mínimos locais;
- utilizar juntamente com RNA's outros métodos estatísticos de previsão, para possíveis comparações. Empregar na configuração de RNA's, técnicas computacionais que procuram otimizar as arquiteturas da rede;
- analisar outras possíveis variáveis independentes que possam influenciar os preços do açúcar cristal e do álcool anidro negociados no Estado de São Paulo.

REFERÊNCIAS

- ABELÉM, A. J. G. **Redes neurais artificiais na previsão de séries temporais**. 1994. 100f. Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 1994.
- ALMEIDA, F. C. Desvendando o uso de redes neurais em problemas de administração de empresas. **Revista de Administração de Empresas RAE**, São Paulo, v. 35, n. 1, p. 46-55, 1995.
- _____; DUMONTIER, P. O uso de redes neurais em avaliação de riscos de inadimplência. **Revista de Administração RAUSP**, São Paulo, v. 31, n. 1, p. 52-63, jan-mar, 1996.
- ALVES, L. R. A. **Transmissão de preços entre produtos do setor sucroalcooleiro do Estado de São Paulo**. 2002. 122f. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2002.
- BELIK, W.; RAMOS, P.; VIAN, C. E. F. Mudanças institucionais e seus impactos nas estratégias dos capitais do complexo agroindustrial canavieiro no Centro-Sul do Brasil. In: Congresso Brasileiro de Economia e Sociologia Rural, **Anais...**, Brasília, 1998.
- BENITE, M. **Aplicação de modelos de redes neurais na elaboração e análise de cenários macroeconômicos**. 2003. 142f. Dissertação (Mestrado em Engenharia de Produção) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2003.
- BOCANEGRA, C. W. R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 108f. Dissertação (Mestrado em Engenharia Civil) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002.
- BROWN, T. H.; KAIRISS, E. W.; KEENAN, C. L. Hebbian synapses: biophysical mechanism and algorithms. **Annual Review of neuroscience**, Palo Alto- EUA, v. 13, p. 478-480, 1990.
- CALÔBA, G. M.; CALÔBA, L. P.; SALIBY, E. Cooperação entre redes neurais artificiais e técnicas “clássicas” para previsão de demanda de um série de vendas de cerveja na austrália. **Pesquisa Operacional**, São Paulo, v. 22, n. 3, p. 345-358, 2002.
- CARVALHO, E. P. Aposta na versatilidade. **Agroanalysis**, v. 22, n. 10, p. 23-25, outubro, 2002.
- CARVALHO, L. C. C. Pesos diferentes. **Agroanalysis**, v. 20, n. 3, p. 41-45, março, 2000.

CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA (CEPEA/USP). **Indicador dos preços de açúcar e álcool**. Disponível em: <<http://www.cepea.esalq.usp.br>>. Acesso em: 10 jan. 2005.

CHEN, A.S.; LEUNG, M. T. Regression neural network for error correction in foreign exchange forecasting and trading. **Computers & Operations Research**, v. 31, n. 7, p. 1049-1068, jun, 2004.

CHO, V. A comparison of three different approaches to tourist arrival forecasting. **Tourism Management**, v.24, n.3, p. 323-330, jun, 2003.

COELHO, L. S., CANGIOLIERI JÚNIOR, O. Rede neural de base radial aplicada em previsão de séries temporais: algoritmo e aplicação. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 20., **Anais...**, São Paulo, 2000.

CURRY, B. "Simple" neural networks for forecasting. **The International Journal of Management Science**, v.32, n.2, p. 97-100, abr, 2004.

DEMARCHI, D. **Técnicas não Destrutivas de Monitoramento e Detecção de Falhas Estruturais Utilizando Redes Neurais**. 2001. 107f. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista "Júlio de Mesquita Filho", Ilha Solteira, 2001.

FADLALLA, A.; LIN, C. An analysis of the applications of neural networks in finance. **Interfaces**, vol. 31, n. 4, p. 112 – 122, july-august, 2001.

FAUSETT, L. **Fundamentals of neural networks – architectures, algorithms, and applications**. Englewood Cliffs, Prentice-Hall, 1994.

GHIASSI, M.; SAIDANE, H.; ZIMBRA, D. K. A dynamic artificial neural network model for forecasting time series events. **International Journal of Forecasting**, vol. 21, n. 2, p. 341-362, april-june, 2005.

HAMID, S. A., IQBAL, Z. Using neural networks for forecasting volatility of S&P 500 Index futures prices. **Journal of Business Research**, vol. 57, n. 10, p. 1116-1125, October, 2004.

HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. New York, Macmillan College Publishing Company, 1994.

_____. **Neural Networks – A Comprehensive Foundation**. Upper Saddle River, Prentice-Hall, Second edition, 1999.

HEBB, D. O. **The Organization of Behavior**. New York, Wiley, 1949.

HERTZ, J.; KROGH, A.; PALMER, R. G. **Introduction to the theory of neural computation**. Redwood city, Addison-Wesley, 1991.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA). **Taxa de câmbio comercial**. Disponível em: <<http://www.ipeadata.gov.br>>. Acesso em: 17 fev. 2005.

JAGRIC, T. Forecasting with leading economic indicators: a neural network approach. **Business Economics**, vol. 38, n. 4, p. 42 – 55, october, 2003.

KANAS, A.; YANNOPOULOS, A. Comparing linear and nonlinear forecasts for stock returns. **International Review of Economics & Finance**, vol. 10, n. 4, p. 383-398, december, 2001.

KOHONEN, T. **Self-organizing maps**. Berlin, Springer-Verlag, 1995.

KUMAR, K.; HAYNES, J. Forecasting credit ratings using RNA and statistical techniques. **International Journal of Business Studies**, vol.11, n. 1, p. 91 – 109, june, 2003.

LIMA, J.P.R.; SILVA, G. V. A economia canavieira de Pernambuco e a reestruturação necessária. **Revista de Economia do Nordeste**, v. 26, n.2, p. 181-203, abril-junho, 1995.

LUCIFREDI, A.; HOU, Z. The Construction of Neural Networks for Bilinear Systems Identification a Possible use to Crack Detection. In: INTERNATIONAL CONFERENCE ON NOISE & VIBRATION ENGINEERING, 19, **Anais...**, Leuven, 1994.

MARJOTTA-MAISTRO, M. C.; BURNQUIST, H. L. Características do consumo industrial de açúcar. **Preços Agrícolas**, v. 12, n. 141, p. 19-21, julho, 1998.

McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MENDES FILHO, E. F., CARVALHO, A. C. P. L. F., MATIAS, A. B. Utilização de redes neurais artificiais na análise de crédito a pessoas físicas In: SIMPÓSIO BRASILEIRO DE REDES NEURAIAS, 5., **Anais...**, Recife, 1996.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry**. Massachusetts, MIT Press, 1988.

_____; _____. **Perceptrons**. Cambridge, MIT Press, 1969.

NAKAMURA, E. Inflation forecasting using a neural network. **Economics Letters**, vol. 86, n. 3, p. 373-378, march, 2005.

NEW YORK BOARD OF TRADE (NYBOT). **Indicador de preços do açúcar no mercado internacional**. Disponível em: <<http://www.nybot.com>>. Acesso em: 15 fev. 2005.

OLIVEIRA NETO, J.D.; TROMPIERE G.; KITAMURA, L. M. Neural network application in credit evaluation. In: *The Business Association of Latin American Studies - BALAS, 2003, Anais...*, São Paulo, 2003.

ORLANDI, V. de F. **Redes neurais artificiais: uma contribuição no processo de decisões financeiras e uma aplicação na previsão de insolvência das organizações**. 1997. 119f. Dissertação (Mestrado em Engenharia de Produção) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1997.

PINAZZA, L.A.; ALIMANDRO, R. Cana-de-açúcar: Alimento bom e doce. *Agroanalysis*, v. 23, n. 4, p. 10-32, abril, 2003.

PINAZZA, L.A.; ALIMANDRO, R. Via Crucis. *Agroanalysis*, v. 20, n. 3, p. 14-20, março, 2000.

PINAZZA, L.A.; Pesos diferentes. *Agroanalysis*, v. 20, n. 3, p. 41-45, março, 2000.

PITTS, W.; McCULLOCH, W. S. How we Know Universals. *Bulletin of Mathematical Biophysics*, v.9, p. 127-147, 1947.

PROSDOCIMO, M. Z. **Sistema para transformar texto em voz utilizando redes neurais para a língua portuguesa**. 1996. 102f. Dissertação (Mestrado em Ciência da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas de São Carlos, Universidade de São Paulo, São Carlos, 1996.

RAMOS, P.; BELIK, W. Intervenção estatal e agroindústria canavieira do Brasil. *Revista de Economia e sociologia Rural*, v. 27, n. 2, p. 197-214, abril-junho, 1989.

ROCHA, A. F.; GUILHERME, I. R.; THEOTO, M.; MIYADAHIRA, A. M. K.; KOIZUMI, M. S. A neural net for extracting knowledge from natural language data bases. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 819-828, set, 1992.

ROSENBLATT, F. **Principles of Neurodynamics**. New York, Spartan, 1962.

RUMELHART, D. E., HINTON, G. E.; WILLIAMS, R. J. Learning representation by back-propagation error. *Nature*, n.323, p. 533-536, 1986.

SHARPE, R. P.; CHOW, M. A. Methodology using Fuzzy Logic to Optimize Feedforward Artificial Neural Network Configurations. *IEEE Transactions on Systems Man and Cybernetics*, v.24, n.3, p.760-768, 1994.

SHIH, Y. **Neuralyst user's guide**, Shal, Faeley Editor, 1994.

SILVEIRA, A. M. **A relação entre os preços de açúcar nos mercados doméstico e internacional**. 2004. 89f. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2004.

UNIÃO DA AGROINDÚSTRIA CANAVIEIRA DE SÃO PAULO (UNICA). **Produção nacional de cana-de-açúcar, álcool e açúcar**. Disponível em: <<http://www.única.com.br>>. Acesso em: 10 abril 2005.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). **Cotações do barril de petróleo**. Disponível em: <<http://www.usda.gov>>. Acesso em: 23 março 2005.

WASSERMAN, P. D. **Neural Computing; Theory and Practice**. New York, Van-Nostrand Reinhold, 1989.

YAO, J.; LI, Y.; TAN, C. L. Option price forecasting using neural networks. **Omega**, vol. 28, n. 4, p. 455-466, august, 2000.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v.50, n.1, p. 159-175, janeiro de 2003.

ANEXOS

ANEXO A - AÇÚCAR CRISTAL NO ESTADO DE SÃO PAULO

ANEXO B - ÁLCOOL ANIDRO COMBUSTÍVEL NO ESTADO DE SÃO PAULO

ANEXO C - TAXA DE CÂMBIO COMERCIAL

ANEXO D - BARRIL DE PETRÓLEO *WTI SPOT E EUROPE BRENT SPOT*

ANEXO E - CONTRATO FUTURO DE AÇÚCAR BRUTO Nº11 DA CSCE/NYBOT

ANEXO A - AÇÚCAR CRISTAL NO ESTADO DE SÃO PAULO

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
07-jul-00	21,12317
14-jul-00	20,66471
21-jul-00	21,60855
28-jul-00	22,90034
04-ago-00	24,91580
11-ago-00	25,94836
18-ago-00	25,79554
25-ago-00	25,36963
01-set-00	25,01292
08-set-00	24,43531
15-set-00	23,63710
22-set-00	23,00956
29-set-00	22,14980
06-out-00	22,43936
13-out-00	23,67607
20-out-00	25,42828
27-out-00	25,76972
03-nov-00	25,26762
10-nov-00	24,85105
17-nov-00	24,20063
24-nov-00	24,37330
01-dez-00	24,20767
08-dez-00	23,74487
15-dez-00	23,11604
22-dez-00	24,02492
28-dez-00	24,71147
05-jan-01	25,35511
12-jan-01	25,34372
19-jan-01	24,97850
26-jan-01	24,44399
02-fev-01	23,92150
09-fev-01	23,54745
16-fev-01	23,01273
23-fev-01	22,50659
02-mar-01	22,44221
09-mar-01	22,60573
16-mar-01	23,22519
23-mar-01	24,12129
30-mar-01	24,77978
06-abr-01	24,84728
12-abr-01	25,01936
20-abr-01	24,86549
27-abr-01	24,53651
04-mai-01	24,14625

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
11-mai-01	24,03849
18-mai-01	24,06708
25-mai-01	24,04629
01-jun-01	23,75139
08-jun-01	23,49032
15-jun-01	23,14333
22-jun-01	23,44796
29-jun-01	23,71923
06-jul-01	23,87774
13-jul-01	23,75597
20-jul-01	23,49647
27-jul-01	23,45174
03-ago-01	23,19456
10-ago-01	22,84882
17-ago-01	22,64839
24-ago-01	22,49418
31-ago-01	23,03061
06-set-01	23,42253
14-set-01	23,53179
21-set-01	23,65490
28-set-01	23,79714
05-out-01	24,00416
11-out-01	23,94082
19-out-01	23,87885
26-out-01	23,86151
01-nov-01	23,90005
09-nov-01	23,82188
16-nov-01	23,75493
23-nov-01	23,60806
30-nov-01	23,81338
07-dez-01	23,88168
14-dez-01	24,27932
21-dez-01	24,98517
28-dez-01	25,60914
04-jan-02	26,07754
11-jan-02	26,11369
18-jan-02	25,89429
25-jan-02	25,19840
01-fev-02	23,90713
08-fev-02	23,51070
15-fev-02	23,14478
22-fev-02	22,13087
01-mar-02	21,54452
08-mar-02	21,10031

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
15-mar-02	21,18883
22-mar-02	21,49133
28-mar-02	21,42310
05-abr-02	21,20100
12-abr-02	20,70977
19-abr-02	20,56242
26-abr-02	20,38541
03-mai-02	20,34928
10-mai-02	20,91748
17-mai-02	20,73607
24-mai-02	20,68862
31-mai-02	20,64984
07-jun-02	20,15184
14-jun-02	18,93174
21-jun-02	17,60928
28-jun-02	16,85391
05-jul-02	16,87312
12-jul-02	17,80602
19-jul-02	20,11523
26-jul-02	21,89133
02-ago-02	22,72006
09-ago-02	23,08671
16-ago-02	23,32772
23-ago-02	22,81250
30-ago-02	22,45950
06-set-02	22,18378
13-set-02	23,74387
20-set-02	25,05000
27-set-02	27,93804
04-out-02	29,85206
11-out-02	31,62553
18-out-02	36,11443
25-out-02	39,07047
01-nov-02	40,44800
08-nov-02	40,38740
14-nov-02	39,87759
22-nov-02	39,92931
29-nov-02	39,95681
06-dez-02	39,55702
13-dez-02	39,69262
20-dez-02	39,98412
27-dez-02	40,22817
03-jan-03	40,67793
10-jan-03	41,32894

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
17-jan-03	41,86184
24-jan-03	42,45691
31-jan-03	43,68422
07-fev-03	44,91001
14-fev-03	45,40706
21-fev-03	45,50109
28-fev-03	45,31692
07-mar-03	45,25750
14-mar-03	44,84738
21-mar-03	44,31965
28-mar-03	40,56924
04-abr-03	39,41326
11-abr-03	39,85685
17-abr-03	40,07679
25-abr-03	38,23426
02-mai-03	36,17351
09-mai-03	33,86747
16-mai-03	30,09492
23-mai-03	28,18597
30-mai-03	27,00146
06-jun-03	26,42643
13-jun-03	25,63738
20-jun-03	24,07602
27-jun-03	23,31407
04-jul-03	23,05462
11-jul-03	23,09441
18-jul-03	23,37885
25-jul-03	24,86161
01-ago-03	27,82843
08-ago-03	30,18868
15-ago-03	29,93051
22-ago-03	29,77558
29-ago-03	27,64339
05-set-03	25,89161
12-set-03	24,50243
19-set-03	23,12406
26-set-03	21,78012
03-out-03	21,50189
10-out-03	21,82427
17-out-03	21,33662
24-out-03	20,46573
31-out-03	19,73688
07-nov-03	20,14039
14-nov-03	20,28424

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
21-nov-03	20,65920
28-nov-03	21,01043
05-dez-03	21,34066
12-dez-03	21,50723
19-dez-03	21,39134
26-dez-03	21,27074
02-jan-04	20,94569
09-jan-04	20,93559
16-jan-04	19,74966
23-jan-04	18,57315
30-jan-04	17,79956
06-fev-04	18,24868
13-fev-04	18,20453
20-fev-04	17,85608
27-fev-04	18,18805
05-mar-04	18,65903
12-mar-04	20,12458
19-mar-04	22,04045
26-mar-04	25,67504
02-abr-04	28,29119
08-abr-04	28,99014
16-abr-04	28,69184
23-abr-04	27,86433
30-abr-04	24,31191
07-mai-04	22,95206
14-mai-04	21,89116
21-mai-04	21,43068
28-mai-04	22,96636
04-jun-04	25,47453
11-jun-04	26,99269
18-jun-04	27,25613
25-jun-04	27,00953
02-jul-04	26,45680
08-jul-04	27,00916
16-jul-04	27,81820
23-jul-04	28,62580
30-jul-04	29,37120
06-ago-04	30,00623
13-ago-04	30,30209
20-ago-04	30,21894
27-ago-04	29,75013
03-set-04	29,76237
10-set-04	29,52922
17-set-04	28,58767

Açúcar Cristal SP - SSP	
Data	Valor (R\$)
24-set-04	27,93907
01-out-04	27,27806
08-out-04	27,27808
15-out-04	27,51207
22-out-04	27,77111
29-out-04	28,38581
05-nov-04	28,48765
12-nov-04	29,53064
19-nov-04	30,36593
26-nov-04	31,57424
03-dez-04	32,11132
10-dez-04	32,14963
17-dez-04	31,28157
23-dez-04	30,48756
30-dez-04	29,89658

ANEXO B - ÁLCOOL ANIDRO COMBUSTÍVEL NO ESTADO DE SÃO PAULO

Álcool Anidro SP - ASP	
Data	Valor (R\$)
07-jul-00	0,58163
14-jul-00	0,59382
21-jul-00	0,64931
28-jul-00	0,68418
04-ago-00	0,69130
11-ago-00	0,69276
18-ago-00	0,68138
25-ago-00	0,66698
01-set-00	0,66003
08-set-00	0,65882
15-set-00	0,65667
22-set-00	0,65792
29-set-00	0,64958
06-out-00	0,64950
13-out-00	0,64928
20-out-00	0,65105
27-out-00	0,65848
03-nov-00	0,66182
10-nov-00	0,67426
17-nov-00	0,68785
24-nov-00	0,69604
01-dez-00	0,69961
08-dez-00	0,70564
15-dez-00	0,71069
22-dez-00	0,70898
28-dez-00	0,70806
05-jan-01	0,71039
12-jan-01	0,71087
19-jan-01	0,70640
26-jan-01	0,70614
02-fev-01	0,69560
09-fev-01	0,69370
16-fev-01	0,67640
23-fev-01	0,66771
02-mar-01	0,65708
09-mar-01	0,64672
16-mar-01	0,64547
23-mar-01	0,63730
30-mar-01	0,61283
06-abr-01	0,60613
12-abr-01	0,61319
20-abr-01	0,61119
27-abr-01	0,60106
04-mai-01	0,58997

Álcool Anidro SP - ASP	
Data	Valor (R\$)
11-mai-01	0,57888
18-mai-01	0,56453
25-mai-01	0,56994
01-jun-01	0,56529
08-jun-01	0,57078
15-jun-01	0,57226
22-jun-01	0,57072
29-jun-01	0,57580
06-jul-01	0,58164
13-jul-01	0,59018
20-jul-01	0,60053
27-jul-01	0,61018
03-ago-01	0,61803
10-ago-01	0,62964
17-ago-01	0,62648
24-ago-01	0,62404
31-ago-01	0,62282
06-set-01	0,62600
14-set-01	0,62536
21-set-01	0,62474
28-set-01	0,62686
05-out-01	0,62952
11-out-01	0,63934
19-out-01	0,63972
26-out-01	0,63535
01-nov-01	0,63051
09-nov-01	0,63104
16-nov-01	0,63178
23-nov-01	0,62869
30-nov-01	0,62655
07-dez-01	0,62883
14-dez-01	0,62949
21-dez-01	0,62977
28-dez-01	0,61963
04-jan-02	0,62631
11-jan-02	0,62200
18-jan-02	0,62173
25-jan-02	0,62113
01-fev-02	0,61751
08-fev-02	0,61700
15-fev-02	0,61661
22-fev-02	0,61346
01-mar-02	0,60280
08-mar-02	0,61015

Álcool Anidro SP - ASP	
Data	Valor (R\$)
15-mar-02	0,61033
22-mar-02	0,61279
28-mar-02	0,60872
05-abr-02	0,61087
12-abr-02	0,61122
19-abr-02	0,61358
26-abr-02	0,60469
03-mai-02	0,59713
10-mai-02	0,57811
17-mai-02	0,57831
24-mai-02	0,56504
31-mai-02	0,54945
07-jun-02	0,52153
14-jun-02	0,49210
21-jun-02	0,45711
28-jun-02	0,42088
05-jul-02	0,42281
12-jul-02	0,46360
19-jul-02	0,47882
26-jul-02	0,48545
02-ago-02	0,48368
09-ago-02	0,48383
16-ago-02	0,48490
23-ago-02	0,49255
30-ago-02	0,52417
06-set-02	0,55492
13-set-02	0,57841
20-set-02	0,58552
27-set-02	0,60190
04-out-02	0,61074
11-out-02	0,62648
18-out-02	0,65778
25-out-02	0,70682
01-nov-02	0,75066
08-nov-02	0,76280
14-nov-02	0,76837
22-nov-02	0,76808
29-nov-02	0,76636
06-dez-02	0,77016
13-dez-02	0,77764
20-dez-02	0,79097
27-dez-02	0,79539
03-jan-03	0,84500
10-jan-03	0,88724

Álcool Anidro SP - ASP	
Data	Valor (R\$)
17-jan-03	0,94691
24-jan-03	0,97074
31-jan-03	1,00881
07-fev-03	1,10779
14-fev-03	1,00651
21-fev-03	1,00657
28-fev-03	1,00362
07-mar-03	1,00818
14-mar-03	1,00845
21-mar-03	1,01048
28-mar-03	1,00057
04-abr-03	0,99880
11-abr-03	1,00027
17-abr-03	0,99968
25-abr-03	0,99115
02-mai-03	0,98285
09-mai-03	0,96653
16-mai-03	0,91902
23-mai-03	0,81807
30-mai-03	0,70101
06-jun-03	0,67504
13-jun-03	0,65199
20-jun-03	0,62500
27-jun-03	0,60328
04-jul-03	0,55960
11-jul-03	0,54846
18-jul-03	0,56490
25-jul-03	0,61656
01-ago-03	0,68112
08-ago-03	0,70363
15-ago-03	0,71694
22-ago-03	0,72458
29-ago-03	0,72502
05-set-03	0,71706
12-set-03	0,67877
19-set-03	0,64299
26-set-03	0,60805
03-out-03	0,56331
10-out-03	0,59378
17-out-03	0,61545
24-out-03	0,62777
31-out-03	0,62244
07-nov-03	0,63421
14-nov-03	0,65394

Álcool Anidro SP - ASP	
Data	Valor (R\$)
21-nov-03	0,66780
28-nov-03	0,67191
05-dez-03	0,71013
12-dez-03	0,71759
19-dez-03	0,72108
26-dez-03	0,70764
02-jan-04	0,71286
09-jan-04	0,68019
16-jan-04	0,62115
23-jan-04	0,59125
30-jan-04	0,60634
06-fev-04	0,55690
13-fev-04	0,42728
20-fev-04	0,37922
27-fev-04	0,38709
05-mar-04	0,40189
12-mar-04	0,37579
19-mar-04	0,37687
26-mar-04	0,39838
02-abr-04	0,45819
08-abr-04	0,50477
16-abr-04	0,47306
23-abr-04	0,44345
30-abr-04	0,45531
07-mai-04	0,47275
14-mai-04	0,49044
21-mai-04	0,58482
28-mai-04	0,64984
04-jun-04	0,63035
11-jun-04	0,62917
18-jun-04	0,62590
25-jun-04	0,62765
02-jul-04	0,62608
08-jul-04	0,63257
16-jul-04	0,66426
23-jul-04	0,74523
30-jul-04	0,75956
06-ago-04	0,75971
13-ago-04	0,76052
20-ago-04	0,75302
27-ago-04	0,75209
03-set-04	0,74621
10-set-04	0,75220
17-set-04	0,75448

Álcool Anidro SP - ASP	
Data	Valor (R\$)
24-set-04	0,80019
01-out-04	0,83666
08-out-04	0,88509
15-out-04	0,90224
22-out-04	0,94940
29-out-04	0,95999
05-nov-04	0,97736
12-nov-04	0,98752
19-nov-04	0,98215
26-nov-04	0,97776
03-dez-04	0,92732
10-dez-04	0,91328
17-dez-04	0,89861
23-dez-04	0,88204
30-dez-04	0,88418

ANEXO C - TAXA DE CÂMBIO COMERCIAL

Taxa de câmbio - TCC	
Data	Valor (R\$)
07-jul-00	1,7972
14-jul-00	1,8106
21-jul-00	1,7921
28-jul-00	1,7828
04-ago-00	1,7919
11-ago-00	1,7959
18-ago-00	1,8174
25-ago-00	1,8213
01-set-00	1,8218
08-set-00	1,8224
15-set-00	1,8438
22-set-00	1,8594
29-set-00	1,8437
06-out-00	1,8520
13-out-00	1,8764
20-out-00	1,8796
27-out-00	1,9240
03-nov-00	1,9286
10-nov-00	1,9566
17-nov-00	1,9609
24-nov-00	1,9560
01-dez-00	1,9795
08-dez-00	1,9695
15-dez-00	1,9678
22-dez-00	1,9524
29-dez-00	1,9554
05-jan-01	1,9484
12-jan-01	1,9508
19-jan-01	1,9553
26-jan-01	1,9740
02-fev-01	1,9934
09-fev-01	1,9884
16-fev-01	1,9940
23-fev-01	2,0436
02-mar-01	2,0355
09-mar-01	2,0599
16-mar-01	2,1217
23-mar-01	2,1586
30-mar-01	2,1616
06-abr-01	2,1521
12-abr-01	2,1573
20-abr-01	2,2364
27-abr-01	2,2180
04-mai-01	2,2187

Taxa de câmbio - TCC	
Data	Valor (R\$)
11-mai-01	2,2863
18-mai-01	2,2941
25-mai-01	2,3403
01-jun-01	2,3833
08-jun-01	2,3619
15-jun-01	2,4079
22-jun-01	2,3296
29-jun-01	2,3049
06-jul-01	2,4943
13-jul-01	2,5538
20-jul-01	2,4573
27-jul-01	2,4971
03-ago-01	2,4884
10-ago-01	2,4842
17-ago-01	2,5235
24-ago-01	2,5500
31-ago-01	2,5517
06-set-01	2,5927
14-set-01	2,6986
21-set-01	2,8007
28-set-01	2,6713
05-out-01	2,7540
11-out-01	2,7799
19-out-01	2,7573
26-out-01	2,7290
01-nov-01	2,6820
09-nov-01	2,5347
16-nov-01	2,5392
23-nov-01	2,5134
30-nov-01	2,5287
07-dez-01	2,4005
14-dez-01	2,3840
21-dez-01	2,3311
28-dez-01	2,3204
04-jan-02	2,3101
11-jan-02	2,4168
18-jan-02	2,3752
25-jan-02	2,4046
01-fev-02	2,4161
08-fev-02	2,4691
15-fev-02	2,4380
22-fev-02	2,4273
01-mar-02	2,3596
08-mar-02	2,3582

Taxa de câmbio - TCC	
Data	Valor (R\$)
15-mar-02	2,3542
22-mar-02	2,3508
28-mar-02	2,3236
05-abr-02	2,2924
12-abr-02	2,2988
19-abr-02	2,3269
26-abr-02	2,3558
03-mai-02	2,4149
10-mai-02	2,4838
17-mai-02	2,4763
24-mai-02	2,5240
31-mai-02	2,5220
07-jun-02	2,6708
14-jun-02	2,7181
21-jun-02	2,7910
28-jun-02	2,8444
05-jul-02	2,8746
12-jul-02	2,8147
19-jul-02	2,8671
26-jul-02	3,0177
02-ago-02	3,0302
09-ago-02	2,9964
16-ago-02	3,1620
23-ago-02	3,1136
30-ago-02	3,0223
06-set-02	3,1783
13-set-02	3,1506
20-set-02	3,4277
27-set-02	3,8541
04-out-02	3,6593
11-out-02	3,9235
18-out-02	3,8759
25-out-02	3,8015
01-nov-02	3,6113
08-nov-02	3,5271
14-nov-02	3,6797
22-nov-02	3,5616
29-nov-02	3,6365
06-dez-02	3,7526
13-dez-02	3,7342
20-dez-02	3,4278
27-dez-02	3,5413
03-jan-03	3,4698
10-jan-03	3,2918

Taxa de câmbio - TCC	
Data	Valor (R\$)
17-jan-03	3,3632
24-jan-03	3,5923
31-jan-03	3,5258
07-fev-03	3,5802
14-fev-03	3,6580
21-fev-03	3,6097
28-fev-03	3,5632
07-mar-03	3,5010
14-mar-03	3,3958
21-mar-03	3,4462
28-mar-03	3,3757
04-abr-03	3,2469
11-abr-03	3,2147
17-abr-03	3,0289
25-abr-03	3,0123
02-mai-03	2,9159
09-mai-03	2,8802
16-mai-03	2,9731
23-mai-03	2,9445
30-mai-03	2,9656
06-jun-03	2,8491
13-jun-03	2,8570
20-jun-03	2,8933
27-jun-03	2,8812
04-jul-03	2,8299
11-jul-03	2,9029
18-jul-03	2,8774
25-jul-03	2,8885
01-ago-03	3,0006
08-ago-03	2,9892
15-ago-03	2,9930
22-ago-03	2,9926
29-ago-03	2,9665
05-set-03	2,9216
12-set-03	2,8959
19-set-03	2,9065
26-set-03	2,9373
03-out-03	2,8875
10-out-03	2,8401
17-out-03	2,8635
24-out-03	2,8695
31-out-03	2,8562
07-nov-03	2,8699
14-nov-03	2,9418

Taxa de câmbio - TCC	
Data	Valor (R\$)
21-nov-03	2,9301
28-nov-03	2,9494
05-dez-03	2,9398
12-dez-03	2,9420
19-dez-03	2,9278
26-dez-03	2,8994
02-jan-04	2,8862
09-jan-04	2,8422
16-jan-04	2,8184
23-jan-04	2,8435
30-jan-04	2,9409
06-fev-04	2,9500
13-fev-04	2,9085
20-fev-04	2,9878
27-fev-04	2,9138
05-mar-04	2,8790
12-mar-04	2,9063
19-mar-04	2,9000
26-mar-04	2,9410
02-abr-04	2,8930
08-abr-04	2,8802
16-abr-04	2,9153
23-abr-04	2,9173
30-abr-04	2,9447
07-mai-04	3,0504
14-mai-04	3,0982
21-mai-04	3,2051
28-mai-04	3,0961
04-jun-04	3,1335
11-jun-04	3,1402
18-jun-04	3,1388
25-jun-04	3,1096
02-jul-04	3,0502
08-jul-04	3,0475
16-jul-04	3,0021
23-jul-04	3,0465
30-jul-04	3,0268
06-ago-04	3,0489
13-ago-04	3,0235
20-ago-04	2,9742
27-ago-04	2,9571
03-set-04	2,9289
10-set-04	2,8988
17-set-04	2,8744

Taxa de câmbio - TCC	
Data	Valor (R\$)
24-set-04	2,8735
01-out-04	2,8513
08-out-04	2,8251
15-out-04	2,8623
22-out-04	2,8489
29-out-04	2,8565
05-nov-04	2,8186
12-nov-04	2,7991
19-nov-04	2,7637
26-nov-04	2,7332
03-dez-04	2,7095
10-dez-04	2,7867
17-dez-04	2,7247
23-dez-04	2,7067
30-dez-04	2,6544

ANEXO D – BARRIL DE PETRÓLEO WTI SPOT E EUROPE BRENT SPOT

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
07-jul-00	30,26	30,62
14-jul-00	31,31	30,82
21-jul-00	28,56	26,68
28-jul-00	28,22	25,96
04-ago-00	29,94	28,01
11-ago-00	31,02	29,44
18-ago-00	31,97	30,76
25-ago-00	34,01	33,26
01-set-00	33,42	35,09
08-set-00	33,62	36,27
15-set-00	35,87	33,68
22-set-00	32,66	31,59
29-set-00	30,87	28,42
06-out-00	30,86	29,62
13-out-00	34,96	33,50
20-out-00	34,31	30,16
27-out-00	32,78	31,31
03-nov-00	32,62	30,81
10-nov-00	34,05	32,26
17-nov-00	35,62	33,09
24-nov-00	36,06	33,35
01-dez-00	32,06	31,59
08-dez-00	28,31	26,85
15-dez-00	28,86	24,44
22-dez-00	26,16	22,23
29-dez-00	26,72	22,58
05-jan-01	28,02	24,77
12-jan-01	30,07	25,63
19-jan-01	32,12	26,29
26-jan-01	29,79	27,04
02-fev-01	31,27	28,90
09-fev-01	30,93	29,53
16-fev-01	29,22	26,61
23-fev-01	28,83	26,12
02-mar-01	27,89	25,28
09-mar-01	27,97	25,78
16-mar-01	26,68	23,84
23-mar-01	27,31	23,94
30-mar-01	26,37	23,50
06-abr-01	27,07	24,02
12-abr-01	28,75	27,12
20-abr-01	27,00	25,57
27-abr-01	28,35	26,85
04-mai-01	28,41	27,59
11-mai-01	28,59	27,97
18-mai-01	29,90	29,30

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
25-mai-01	28,08	28,69
01-jun-01	27,88	28,86
08-jun-01	28,43	28,88
15-jun-01	28,52	28,13
22-jun-01	27,02	26,86
29-jun-01	26,37	26,21
06-jul-01	28,10	26,55
13-jul-01	26,57	24,02
20-jul-01	25,67	23,43
27-jul-01	26,98	24,82
03-ago-01	27,51	25,60
10-ago-01	28,12	25,78
17-ago-01	26,65	24,68
24-ago-01	28,34	26,33
31-ago-01	26,65	26,80
06-set-01	27,54	26,61
14-set-01	29,59	29,22
21-set-01	25,46	25,17
28-set-01	23,44	21,87
05-out-01	22,32	21,46
12-out-01	22,49	20,57
19-out-01	21,99	19,91
26-out-01	22,07	20,31
02-nov-01	20,24	18,63
09-nov-01	22,23	20,72
16-nov-01	18,09	16,86
21-nov-01	18,38	18,44
30-nov-01	19,46	18,92
07-dez-01	19,08	17,81
14-dez-01	19,31	18,54
21-dez-01	19,30	18,73
28-dez-01	20,42	19,77
04-jan-02	21,47	21,20
11-jan-02	19,67	20,08
18-jan-02	18,02	18,17
25-jan-02	19,80	19,04
01-fev-02	20,40	19,70
08-fev-02	20,25	20,01
15-fev-02	21,47	20,76
22-fev-02	20,92	20,14
01-mar-02	22,37	21,83
08-mar-02	23,87	22,32
15-mar-02	24,47	23,90
22-mar-02	25,56	24,83
28-mar-02	26,21	25,34
05-abr-02	26,21	25,39

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
12-abr-02	23,51	23,25
19-abr-02	26,43	25,86
26-abr-02	27,12	26,32
03-mai-02	26,75	25,80
10-mai-02	27,92	26,89
17-mai-02	28,19	25,45
24-mai-02	26,69	23,76
31-mai-02	25,37	23,87
07-jun-02	24,72	22,99
14-jun-02	25,90	23,97
21-jun-02	25,51	24,14
28-jun-02	26,79	25,33
03-jul-02	26,82	25,59
12-jul-02	27,48	26,11
19-jul-02	27,83	26,37
26-jul-02	26,55	25,10
02-ago-02	26,87	25,17
09-ago-02	26,87	25,49
16-ago-02	29,24	27,33
23-ago-02	29,99	27,51
30-ago-02	28,97	27,56
06-set-02	29,51	28,36
13-set-02	29,83	28,53
20-set-02	29,65	28,61
27-set-02	30,53	29,00
04-out-02	29,65	28,32
11-out-02	29,36	28,18
18-out-02	29,56	28,20
25-out-02	27,09	25,96
01-nov-02	27,04	25,78
08-nov-02	25,83	23,54
15-nov-02	25,50	23,33
22-nov-02	27,73	24,79
27-nov-02	26,87	25,11
06-dez-02	27,03	25,67
13-dez-02	28,39	27,64
20-dez-02	30,57	29,59
27-dez-02	32,68	31,49
03-jan-03	33,26	31,43
10-jan-03	31,59	30,07
17-jan-03	33,88	31,57
24-jan-03	34,98	31,62
31-jan-03	33,51	31,57
07-fev-03	35,05	32,23
14-fev-03	36,61	33,26
21-fev-03	36,76	32,76

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
28-fev-03	36,76	34,00
07-mar-03	37,76	34,47
14-mar-03	35,41	31,48
21-mar-03	27,18	25,59
28-mar-03	30,21	27,66
04-abr-03	28,41	25,62
11-abr-03	28,28	24,39
17-abr-03	30,10	25,36
25-abr-03	25,92	24,29
02-mai-03	25,74	23,73
09-mai-03	27,65	25,55
16-mai-03	29,07	27,18
23-mai-03	29,74	27,14
30-mai-03	29,56	26,58
06-jun-03	31,26	28,38
13-jun-03	30,63	27,39
20-jun-03	30,63	27,13
27-jun-03	29,18	27,45
03-jul-03	30,39	28,63
11-jul-03	31,33	29,36
18-jul-03	31,96	29,20
25-jul-03	30,31	28,30
01-ago-03	32,23	29,63
08-ago-03	32,23	30,59
15-ago-03	31,01	29,18
22-ago-03	31,64	30,22
29-ago-03	31,76	30,38
05-set-03	28,93	27,72
12-set-03	28,26	26,52
19-set-03	26,93	25,51
26-set-03	28,21	27,02
03-out-03	30,37	29,14
10-out-03	32,01	31,13
17-out-03	30,61	30,27
24-out-03	29,99	30,01
31-out-03	29,24	27,88
07-nov-03	30,73	28,73
14-nov-03	32,31	29,78
21-nov-03	32,26	29,79
26-nov-03	30,33	28,23
05-dez-03	30,68	28,87
12-dez-03	33,06	30,24
19-dez-03	32,81	31,03
24-dez-03	32,99	29,45
31-dez-03	32,51	30,30
09-jan-04	34,38	31,91

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
16-jan-04	35,16	31,26
23-jan-04	34,94	32,08
30-jan-04	33,16	29,53
06-fev-04	32,49	29,26
13-fev-04	34,51	30,96
20-fev-04	35,80	31,22
27-fev-04	36,08	32,94
05-mar-04	37,31	34,40
12-mar-04	36,21	32,76
19-mar-04	38,09	34,33
26-mar-04	35,61	32,51
02-abr-04	34,39	31,19
08-abr-04	37,14	33,98
16-abr-04	37,70	33,85
23-abr-04	37,22	33,78
30-abr-04	37,31	35,23
07-mai-04	39,98	37,25
14-mai-04	41,42	39,04
21-mai-04	39,83	37,60
28-mai-04	39,90	37,00
04-jun-04	38,44	35,97
10-jun-04	38,45	35,75
18-jun-04	38,68	35,43
25-jun-04	37,34	34,25
02-jul-04	38,37	35,36
09-jul-04	39,90	37,58
16-jul-04	41,10	38,49
23-jul-04	41,82	39,59
30-jul-04	43,72	41,47
06-ago-04	43,95	42,63
13-ago-04	46,61	44,13
20-ago-04	47,60	45,46
27-ago-04	43,11	40,72
03-set-04	43,94	41,07
10-set-04	42,84	41,03
17-set-04	45,63	43,08
24-set-04	48,86	46,13
01-out-04	50,16	46,86
08-out-04	53,40	49,41
15-out-04	54,89	51,02
22-out-04	55,83	52,28
29-out-04	51,78	48,16
05-nov-04	49,65	44,37
12-nov-04	47,30	41,33
19-nov-04	48,90	42,29
24-nov-04	49,14	42,62

Data	WTI Spot (US\$)-PNA	Europe Brent Spot (US\$) - PEB
03-dez-04	42,56	38,57
10-dez-04	40,71	37,24
17-dez-04	46,31	43,06
23-dez-04	42,19	40,29
30-dez-04	43,36	39,80

ANEXO E - CONTRATO FUTURO DE AÇÚCAR BRUTO Nº11 DA CSCE/NYBOT

Data	Sugar nº11 Nybot - SNY	Data	Sugar nº11 Nybot - SNY	Data	Sugar nº11 Nybot - SNY
07-jul-00	8,68	25-mai-01	8,96	12-abr-02	5,55
14-jul-00	9,20	01-jun-01	8,60	19-abr-02	6,17
21-jul-00	10,41	08-jun-01	8,63	26-abr-02	5,83
28-jul-00	10,89	15-jun-01	8,87	03-mai-02	5,36
04-ago-00	10,80	22-jun-01	9,38	10-mai-02	5,49
11-ago-00	10,65	29-jun-01	9,59	17-mai-02	5,86
18-ago-00	10,70	06-jul-01	8,38	24-mai-02	5,65
25-ago-00	10,82	13-jul-01	8,56	31-mai-02	5,90
01-set-00	10,82	20-jul-01	8,60	07-jun-02	5,62
08-set-00	10,67	27-jul-01	8,49	14-jun-02	5,26
15-set-00	9,78	03-ago-01	7,80	21-jun-02	4,99
22-set-00	9,56	10-ago-01	7,65	28-jun-02	5,91
29-set-00	9,77	17-ago-01	7,96	03-jul-02	5,60
06-out-00	10,08	24-ago-01	8,29	12-jul-02	5,99
13-out-00	11,00	31-ago-01	7,91	19-jul-02	6,06
20-out-00	10,87	07-set-01	7,86	26-jul-02	5,81
27-out-00	9,53	10-set-01	7,87	02-ago-02	5,78
03-nov-00	9,57	21-set-01	7,05	09-ago-02	5,89
10-nov-00	9,15	28-set-01	6,70	16-ago-02	5,87
17-nov-00	9,63	05-out-01	6,57	23-ago-02	5,78
22-nov-00	9,93	12-out-01	6,44	30-ago-02	5,98
01-dez-00	9,66	19-out-01	6,73	06-set-02	6,33
08-dez-00	9,75	26-out-01	6,72	13-set-02	6,92
15-dez-00	9,31	02-nov-01	6,63	20-set-02	6,92
22-dez-00	9,81	09-nov-01	7,11	27-set-02	7,12
29-dez-00	10,20	16-nov-01	7,31	04-out-02	6,91
05-jan-01	10,27	21-nov-01	7,52	11-out-02	7,20
12-jan-01	10,00	30-nov-01	7,68	18-out-02	7,60
19-jan-01	10,09	07-dez-01	7,75	25-out-02	7,28
26-jan-01	10,00	14-dez-01	7,41	01-nov-02	7,64
02-fev-01	10,14	21-dez-01	7,12	08-nov-02	7,70
09-fev-01	9,80	28-dez-01	7,39	15-nov-02	7,24
16-fev-01	9,64	04-jan-02	7,64	22-nov-02	7,65
23-fev-01	9,39	11-jan-02	7,76	27-nov-02	7,61
02-mar-01	9,11	18-jan-02	7,30	06-dez-02	7,64
09-mar-01	9,00	25-jan-02	7,13	13-dez-02	7,61
16-mar-01	8,77	01-fev-02	6,35	20-dez-02	7,51
23-mar-01	8,37	08-fev-02	6,18	27-dez-02	7,40
30-mar-01	7,75	15-fev-02	6,25	03-jan-03	7,40
06-abr-01	8,16	22-fev-02	6,31	10-jan-03	7,67
12-abr-01	8,31	01-mar-02	5,97	17-jan-03	7,87
20-abr-01	8,71	08-mar-02	6,18	24-jan-03	7,97
27-abr-01	9,37	15-mar-02	6,26	31-jan-03	8,64
04-mai-01	8,98	22-mar-02	5,91	07-fev-03	8,93
11-mai-01	9,10	28-mar-02	5,93	14-fev-03	8,86
18-mai-01	8,85	05-abr-02	5,70	21-fev-03	8,97

Data	Sugar nº11 Nybot - SNY
28-fev-03	8,90
07-mar-03	8,22
14-mar-03	7,85
21-mar-03	7,80
28-mar-03	7,71
04-abr-03	7,66
11-abr-03	7,23
17-abr-03	7,45
25-abr-03	7,85
02-mai-03	7,17
09-mai-03	6,87
16-mai-03	6,91
23-mai-03	7,34
30-mai-03	7,08
06-jun-03	6,71
13-jun-03	6,52
20-jun-03	6,58
27-jun-03	6,22
03-jul-03	6,39
10-jul-03	6,44
17-jul-03	6,70
24-jul-03	6,88
01-ago-03	7,24
08-ago-03	6,62
15-ago-03	6,49
22-ago-03	6,54
29-ago-03	6,29
05-set-03	6,05
12-set-03	6,05
19-set-03	5,97
26-set-03	5,95
03-out-03	6,23
10-out-03	5,50
17-out-03	5,55
24-out-03	5,62
31-out-03	5,44
07-nov-03	5,55
14-nov-03	5,77
21-nov-03	5,62
26-nov-03	5,35
05-dez-03	5,80
12-dez-03	5,80
19-dez-03	4,05
24-dez-03	3,20
31-dez-03	1,52
09-jan-04	5,93

Data	Sugar nº11 Nybot - SNY
16-jan-04	5,79
23-jan-04	5,77
30-jan-04	5,86
06-fev-04	5,45
13-fev-04	5,48
20-fev-04	5,64
27-fev-04	6,03
04-mar-04	6,13
12-mar-04	6,68
19-mar-04	6,76
26-mar-04	6,09
02-abr-04	6,36
08-abr-04	6,78
16-abr-04	6,69
23-abr-04	6,51
30-abr-04	6,58
07-mai-04	6,59
14-mai-04	6,35
21-mai-04	6,58
28-mai-04	7,06
04-jun-04	7,19
10-jun-04	6,75
18-jun-04	6,82
25-jun-04	7,28
02-jul-04	7,96
09-jul-04	8,27
16-jul-04	8,25
23-jul-04	8,01
30-jul-04	8,28
06-ago-04	8,17
13-ago-04	7,87
20-ago-04	7,73
27-ago-04	7,66
03-set-04	8,13
10-set-04	7,81
17-set-04	7,59
24-set-04	7,79
01-out-04	8,90
08-out-04	9,02
15-out-04	9,15
22-out-04	8,93
29-out-04	8,60
05-nov-04	8,48
12-nov-04	8,52
19-nov-04	8,75
24-nov-04	8,97

Data	Sugar nº11 Nybot - SNY
03-dez-04	8,80
10-dez-04	8,69
17-dez-04	8,64
23-dez-04	8,86
30-dez-04	9,04

