

**CENTRO UNIVERSITÁRIO DA FEI**

**FÁBIO AUGUSTO MOLLIK ZOUCAS**

**APLICAÇÃO DE REDES NEURAIIS PARA PREVISÃO DE SÉRIES TEMPORAIS EM  
SEGMENTOS INDUSTRIAIS**

**São Bernardo do Campo**

**2009**

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

**FÁBIO AUGUSTO MOLLIK ZOUCAS**

**APLICAÇÃO DE REDES NEURAIS PARA PREVISÃO DE SÉRIES TEMPORAIS EM  
SEGMENTOS INDUSTRIAIS**

Dissertação de Mestrado apresentada ao Centro  
Universitário da FEI para obtenção do título de  
Mestre em Engenharia Mecânica com ênfase em  
Produção, orientado pela Prof. Dra. Patrícia Belfiore

**São Bernardo do Campo**

**2009**



Centro Universitário da FEI

## APRESENTAÇÃO DE DISSERTAÇÃO ATA DA BANCA JULGADORA

PGE- 10

### Programa de Mestrado de Engenharia Mecânica

Aluno: Fábio Augusto Mollik Zoucas

Matrícula: 207116-5

Título do Trabalho: Aplicação de redes neurais para previsão de séries temporais em segmentos industriais.

Área de Concentração: Produção

Orientadora: Profª. Drª. Patrícia Prado Belfiore

Data da realização da prova: 24 / junho / 2009

A Banca Julgadora abaixo-assinada, atribuiu ao candidato o seguinte:

APROVADO

REPROVADO

São Bernardo do Campo, 24, 06 / 2009

#### MEMBROS DA BANCA JULGADORA

Profª. Drª. Patrícia Prado Belfiore

Ass.: Patrícia Belfiore

Prof. Dr. Fabrizio Leonardi

Ass.: Fabrizio Leonardi

Prof. Dr. José Geraldo Vidal Vieira

Ass.: José Geraldo Vidal Vieira

#### **VERSÃO FINAL DA DISSERTAÇÃO**

ENDOSSO DO ORIENTADOR APÓS A INCLUSÃO DAS  
RECOMENDAÇÕES DA BANCA EXAMINADORA

Patrícia Belfiore

Aprovação do Coordenador do Programa de Pós-graduação

Agenor de Toledo Fleury  
Prof. Dr. Agenor de Toledo Fleury

## DEDICATÓRIA

À minha esposa Cristina e a minha filha Beatriz que compreenderam a importância deste trabalho e, mesmo que por diversas vezes elas sentissem a minha ausência, nunca deixaram de me incentivar.

## AGRADECIMENTOS

À minha orientadora Profa. Dra. Patricia Belfiore que soube conduzir de forma tranquila e assertiva, mesmo nos momentos de maior ansiedade, todas as etapas desta longa caminhada.

A todos os professores e funcionários do curso de Mestrado em Engenharia Mecânica do Centro Universitário da FEI, que de forma direta ou indireta contribuíram com este trabalho.

À minha Mãe (Maria Theresa) que está sempre ao meu lado, com todo seu carinho, incentivando e torcendo em qualquer que seja o meu projeto pessoal.

Ao amigo Douglas Valverde, que conheci no início do curso, e desde então (mesmo pelo pouco tempo de convívio) foi um dos que mais se interessou, torceu e incentivou para que este trabalho fosse concluído com sucesso.

E em especial a DEUS, que me orienta, me guarda e me acompanha em todos os passos da minha Vida.

## SUMÁRIO

<b>LISTA DE FIGURAS.....</b>	<b>09</b>
<b>LISTA DE GRÁFICOS.....</b>	<b>10</b>
<b>RESUMO.....</b>	<b>11</b>
<b>ABSTRACT.....</b>	<b>12</b>
<b>1. INTRODUÇÃO.....</b>	<b>13</b>
<b>1.1. Método e Material.....</b>	<b>16</b>
<b>1.2. Delineamento do Trabalho .....</b>	<b>17</b>
<b>2. O PROBLEMA DE PREVISÃO.....</b>	<b>18</b>
<b>2.1. Previsão de Séries de Tempo.....</b>	<b>18</b>
<b>2.2. Taxonomia dos Métodos de Previsão.....</b>	<b>20</b>
<b>2.3. Etapas para Implantação de Sistemas de Previsão.....</b>	<b>21</b>
2.3.1. Definição do Problema.....	22
2.3.2. Seleção de Dados.....	26
2.3.3. Análise de Dados.....	29
2.3.4. Definição do Método Adequado.....	30
2.3.5. Seleção do Sistema de Apoio (Software).....	33
2.3.6. Medidas de Precisão e Análise de Resultados.....	34
<b>3. REVISÃO DAS TÉCNICAS DE PREVISÃO.....</b>	<b>37</b>
<b>3.1. Modelo de Séries de Tempo (Quantitativo – Univariado).....</b>	<b>37</b>
<b>3.2. Modelo de Causa e Efeito (Quantitativo – Bivariado).....</b>	<b>40</b>
<b>3.3. Modelo de Julgamento (Qualitativos).....</b>	<b>48</b>
<b>3.4. Modelos Estratificados.....</b>	<b>49</b>
<b>3.5. Desempenho das Técnicas de Modelagem.....</b>	<b>54</b>
<b>4. DESCRIÇÃO DA TÉCNICA DE REDES NEURAIS.....</b>	<b>57</b>
<b>4.1. Conceito de Redes Neurais.....</b>	<b>57</b>
<b>4.2. Tipos de Redes Neurais.....</b>	<b>63</b>
4.2.1. Perceptron (Feedforward).....	64

4.2.2. Redes Lineares (Feedforward).....	66
4.2.3. Perceptron Multi-Camadas (Feedforward).....	66
4.2.4. Redes BAM .....	67
4.2.5. Redes ART.....	68
4.2.6. Rede Probabilística.....	69
4.2.7. Rede de Hopfield (Recurrent).....	70
4.2.8. Rede de Kohonem (Recurrent).....	71
4.2.9. Rede TDNN (Time Delay Neural Network).....	72
4.2.10. Rede de Elman e Jordan.....	73
<b>4.3. Tipos de Algoritmos.....</b>	<b>75</b>
4.3.1. Algoritmo Backpropagation.....	75
4.3.2. Algoritmo de Levenberg-Marquadt.....	76
<b>4.4. Coleta de Dados.....</b>	<b>76</b>
<b>4.5. Modelo Proposto.....</b>	<b>79</b>
<b>5. APLICAÇÃO E ANÁLISE DE RESULTADOS.....</b>	<b>82</b>
<b>5.1. Análise Preliminar dos Dados.....</b>	<b>82</b>
<b>5.2. Propostas de Estratégias de Uso das TDNN (Time Delay Neural Network).....</b>	<b>88</b>
<b>5.3. Treinamento.....</b>	<b>89</b>
<b>5.4. Definição da Quantidade de Neurônios.....</b>	<b>90</b>
<b>5.5. Definição da Tipologia das Redes Neurais.....</b>	<b>94</b>
<b>5.6. Avaliação das Estratégias de Modelagem.....</b>	<b>97</b>
<b>5.7. Avaliação das Previsões de Demanda.....</b>	<b>107</b>
<b>6. CONCLUSÃO.....</b>	<b>110</b>
<b>7. REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>112</b>
<b>APÊNDICE 01 – Tabela de Séries de produção industrial por segmento.....</b>	<b>117</b>
<b>APÊNDICE 02 – Gráficos dos Resultados das Simulações da 1ª. Estratégia.....</b>	<b>126</b>



<b>APÊNDICE 03</b> – Gráficos da Distribuição de Probabilidade e Função de Auto - Correlação - 1ª. Estratégia.....	131
<b>APÊNDICE 04</b> – Gráfico da Previsão de Demanda - 1ª. Estratégia.....	135
<b>APÊNDICE 05</b> – Tabelas de Pesos e Biases da 1ª. Estratégia.....	140
<b>APÊNDICE 06</b> – Gráficos dos Dados Transformados Aproximados pela Rede Neural (1ª. Estratégia).....	143
<b>APÊNDICE 07</b> – Gráficos dos Resultados das Simulações da 2ª. Estratégia.....	148
<b>APÊNDICE 08</b> – Gráficos da Distribuição de Probabilidade e Função de Auto – Correlação - 2ª. Estratégia.....	153
<b>APÊNDICE 09</b> – Gráficos da Previsão de Demanda - 2ª. Estratégia.....	157
<b>APÊNDICE 10</b> – Tabelas de Pesos e Biases da TDNN - 2ª. Estratégia.....	162
<b>ANEXO A</b> .....	165
<b>ANEXO B</b> .....	168

## LISTA DE FIGURAS

<b>FIGURA 01</b> – Métodos de Previsão (Adaptado de SILVA, 2003).....	21
<b>FIGURA 02</b> – Fluxo de Eventos para Planejamento de Demanda (MARIEN, 2001).....	24
<b>FIGURA 03</b> – Tendência do Uso dos Métodos de Previsão (JAIN, 2007).....	31
<b>FIGURA 04</b> – Intervalo dos Métodos de Previsão (JAIN, 2007).....	32
<b>FIGURA 05</b> – Técnicas Mais Utilizadas nos Métodos de Previsão (JAIN, 2007).....	32
<b>FIGURA 06</b> – Rede de Alimentação Neural com uma Camada Escondida (CHAKRABORTY et al., 1992).....	58
<b>FIGURA 07</b> – Tipo de Alimentação de Redes Neurais.....	60
<b>FIGURA 08</b> – Modelo de Aprendizado Supervisionado.....	61
<b>FIGURA 09</b> – Modelo de Aprendizado Não Supervisionado.....	62
<b>FIGURA 10</b> – Modelo de Neurônio de McCulloch e Pitts (1943).....	63
<b>FIGURA 11</b> – Exemplo de Função de Ativação.....	64
<b>FIGURA 12</b> – Modelo Perceptron.....	65
<b>FIGURA 13</b> – Modelo Perceptron Multicamadas.....	67
<b>FIGURA 14</b> – Diagrama Simplificado de uma Rede BAM (NARENDRA, 1990).....	68
<b>FIGURA 15</b> – Modelo Típico de Rede ART (CARPENTER e GROSS, 1990).....	69
<b>FIGURA 16</b> – Arquitetura da Rede Hopfield.....	70
<b>FIGURA 17</b> – Arquitetura da Rede Kohonen.....	71
<b>FIGURA 18</b> – Janela da Série Temporal Aplicada a Entrada de Um Neurônio.....	73
<b>FIGURA 19</b> – Ilustração de uma Rede de Elman.....	74
<b>FIGURA 20</b> – Ilustração de uma Rede de Jordan.....	74
<b>FIGURA 21</b> – Topologia de Uma TDNN com Perceptron Multicamadas.....	80
<b>FIGURA 22</b> – Resultados da análise de resíduos da primeira estratégia.....	92
<b>FIGURA 23</b> – Resultados da análise de resíduos da segunda estratégia.....	93
<b>FIGURA 24</b> – Estrutura da TDNN Utilizada na Primeira Estratégia de Análise.....	95
<b>FIGURA 25</b> – Estrutura da TDNN Utilizada na Segunda Estratégia de Análise.....	97

## LISTA DE GRÁFICOS

<b>GRÁFICO 01</b> – Comportamento das Séries de Tempo da Produção Industrial.....	78
<b>GRÁFICO 02</b> - Função de Auto-Correlação da série histórica de todos os segmentos....	83
<b>GRÁFICO 03</b> - Função de Auto-Correlação das diferenças da série histórica.....	86
<b>GRÁFICO 04</b> - Curva de aprendizado da RN em 25 épocas.....	90
<b>GRÁFICO 05</b> - Simulações para escolha da quantidade de entradas da RN.....	96
<b>GRÁFICO 06</b> - Resultados das simulações do segmento de Extrativismo Mineral.....	98
<b>GRÁFICO 07</b> - Distribuição de probabilidade e Auto-Correlação (E. Mineral).....	99
<b>GRÁFICO 08</b> - Previsão de demanda - 1ª estratégia (Extrativismo Mineral).....	100
<b>GRÁFICO 09</b> - Resultados das simulações do segmento farmacêutico.....	101
<b>GRÁFICO 10</b> - Distribuição de probabilidade e Auto-Correlação (Farmacêutico).....	102
<b>GRÁFICO 11</b> - Previsão de demanda 1ª estratégia (Farmacêutico).....	102
<b>GRÁFICO 12</b> - Dados transformados do segmento da Indústria de Bebidas.....	103
<b>GRÁFICO 13</b> – Distribuição de probabilidade e Auto-Correlação (Bebidas).....	104
<b>GRÁFICO 14</b> - Resultados das simulações do segmento de Indústria de Bebidas reconstituído a partir da serie de tempo das diferenças.....	105
<b>GRÁFICO 15</b> - Previsão de demanda - 2ª estratégia (Bebidas).....	106

## RESUMO

O planejamento de demanda tem sido um importante tema dentro das organizações industriais, especialmente no que diz respeito ao planejamento de recursos, seja ele físico ou financeiro, e os impactos deste planejamento dentro das organizações. O objetivo deste trabalho é estudar a importância da aplicação de previsão de séries de tempo, dentro do segmento industrial, utilizando como ferramenta de cálculo, a aplicação de Redes Neurais para análise do comportamento e previsão de demanda de onze segmentos industriais distintos. O trabalho passa por uma introdução sobre a importância das técnicas de previsão de séries de tempo, classificação das técnicas, etapas para implantação de previsão, revisão das principais técnicas de previsão de séries de tempo estudadas nas últimas décadas e suas estratificações. A partir da revisão das técnicas de previsão apresentadas, é feito um estudo mais detalhado sobre a aplicação de Redes Neurais, tipos de redes mais comuns em relação a sua aplicação, tais como Perceptron, Redes Lineares, Perceptron Multi-Camadas, Redes BAM e ART, Rede Probabilística, Hopfield, Kohonen, TDNN, Rede de Elman e Jordan, além dos algoritmos Backpropagation e Levenberg-Marquadt. Através da análise prévia de uma base de dados extraída do IBGE (Instituto Brasileiro de Geografia e Estatística), definiram-se aplicar uma Rede Perceptron Multi-Camadas com atraso no tempo (TDNN), para cálculo e análise da previsão de séries de tempo dos onze segmentos escolhidos do setor industrial. A Rede Neural foi então aplicada a duas estratégias de modelo estrutural, definidas através da função de auto-correlação dos dados utilizados e através dos resultados apresentados, concluí-se que o modelo de Rede Neural proposto foi eficaz na previsão de séries temporais de segmentos industriais.

Palavras-chave: Planejamento de Demanda, Previsão de Séries Temporais, Técnicas Estatísticas, Redes Neurais.

## **ABSTRACT**

The planning of demand has been an important topic within industrial organizations, especially with regard to the planning of resources, whether physical or financial, and impacts of planning within organizations. The objective is study the importance of applying the time series forecasting, within the industrial sector, using neural networks tools for behavior analysis and demand forecasting of eleven different industries. The work requires an introduction to the importance of the techniques of time series prediction, classification techniques, steps for implementation of forecasting, review of key techniques for forecasting of time series studied in recent decades and its strata. From the review of forecasting techniques presented, it made a more detailed study on the application of neural networks, most common types of networks for its implementation, such as Perceptron, Linear Networks, Multi-Layer Perceptron, ART and BAM Networks , probabilistic network, Hopfield, Kohonen, TDNN, Elman and Jordan Network, in addition to the Backpropagation and Levenberg-Marquadt algorithms. Through preliminary analysis of a database from the IBGE (Brazilian Institute of Geography and Statistics), established to implement a Multi-Layer Perceptron network with delay in time (TDNN) for calculation and analysis of time series of estimates of the eleven selected segments of the industry. The neural network was then applied to two strategies of structural model, defined by self-correlation function of the data used and by the results presented, concluded that the proposed Neural Network model was effective in predicting time series of industries .

**Key words:** Planning, Temporal Series Forecast, Demand, Statistical Techniques, Neural Network.

## 1. INTRODUÇÃO

Previsão de demanda dentro da indústria têm sido uma atividade de suma importância requerendo cuidado e atenção, pois ela é, na maioria das vezes, a grande responsável pela tomada de decisões estratégicas dentro do negócio.

Inúmeras são as ferramentas encontradas ao longo de décadas para cálculo de previsão de séries temporais, e cujo principal desafio é alcançar níveis de previsões mais próximas do real.

Martins e Laugeni (1999) definem previsão como “processo metodológico para determinação de dados futuros baseados em modelos estatísticos, matemáticos, econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida”.

O planejamento de demanda ajustado às inúmeras interferências externas e às variações de mercado é um fator preponderante no contexto geral do planejamento do negócio.

A previsão de demanda determina, na prática, o destino dos recursos financeiros que envolvem as seguintes decisões: aquisição de matérias primas, contratação ou não de mão de obra, investimento em ativos, a análise do fluxo de caixa, a iniciativa de promoções ou campanhas de acordo com as expectativas do mercado. Desta forma, o grau de acurácia da previsão de demanda tem uma enorme importância para o resultado do negócio.

Desde o início da industrialização moderna, com o avanço cada vez mais crescente do setor automotivo, e a partir da segunda metade do século XX, surgiram problemas na relação entre fornecedores e clientes de grandes indústrias de diversos segmentos, em função da falta de informação e falta de confiabilidade no fornecimento, em toda cadeia produtiva.

Os problemas de fornecimento se agravaram, principalmente ao longo dos anos 60 e 70, quando ocorreram freqüentes greves na indústria americana. Essa situação forçou as grandes montadoras da época a buscar esquemas de duplo fornecimento, a fim de se precaverem contra eventuais faltas de peças (NETO et al, 2001).

Esse problema estava associado, em grande parte, pela falta de um processo de previsão de demanda que pudesse fornecer informações consistentes para a cadeia produtiva como um todo.

Segundo Crum e Palmatier (2003), há trinta anos, o planejamento era mínimo ou inexistente dentro da maioria das empresas e, em alguns casos, a demanda era apenas previsão,

não sendo comumente utilizada para dirigir projeções financeiras ou rateios produtivos. Somente em raríssimas exceções, informações sobre demanda eram comunicadas entre clientes e seus fornecedores.

Após a década de 70, grande parte da indústria, principalmente os japoneses com a prática do sistema de gestão baseado na qualidade total e dos sistemas de produção Just in Time originados no período pós-guerra, passou a buscar maior produtividade com menores custos.

Desta forma, o conceito de previsão de demanda foi amplamente difundido, sendo relevante para a estratégia do negócio das organizações, de uma forma geral, e levando o assunto a níveis acadêmicos.

A partir das décadas de 80 e 90, o conceito de logística integrada começou a surgir nas grandes organizações e tornou-se, em pouco tempo, o principal fator competitivo dentro do modelo de integração da cadeia de suprimentos, conforme Ching (2001).

Algumas empresas passaram a se preocupar, cada vez mais, com o planejamento e o estudo da demanda através de sua série histórica. Elas entendiam que esta análise, quanto mais próxima do real, reduziria o alto custo que está agregado à própria cadeia de suprimentos, ao tempo de processo (Lead Times), ao nível de atendimento que se espera alcançar, ao grau de confiabilidade do setor e, principalmente pelo próprio gerenciamento dos seus recursos financeiros.

Para Kuo e Xue (1998) as previsões de vendas desempenham um papel predominante no suporte à decisão. Uma efetiva previsão de vendas pode ajudar a empresa no cálculo da produção, nos custos de materiais e na determinação do preço de venda do produto. Métodos de previsão de vendas convencionais que utilizam fatores ou dados de séries de tempo como variáveis independentes, e vendas como variáveis dependentes são sempre muito complicadas.

Atualmente, empresas de diversos elos da cadeia de suprimentos estão desenvolvendo novos modelos de gerenciamento de demanda e usando análises de séries históricas para planejar e dirigir seus materiais e seu planejamento financeiro, buscando planos de demanda com atualizações mensais ao invés de quadrimestral ou anualmente. Clientes e fornecedores estão colaborando para uma comunicação direta de informação de demanda (mensal, semanal e até mesmo perto do tempo real) com desenvolvimento tático para alcançar vendas (CRUM e PALMATIER, 2003).

Embora possa parecer fácil identificar tendências de mercado na análise de séries históricas, na prática é muito difícil acertar previsões futuras, pois muitas séries podem ser imperceptíveis ao olho do analista, sem que o mesmo utilize técnicas que lhe possa garantir um maior grau de confiabilidade e possibilidade de encontrar os pontos frágeis do processo.

Segundo Crum e Palmatier (2003), com os avanços tecnológicos, globalização e principalmente com a evolução da tecnologia de informação e do chamado comércio eletrônico, muitos processos melhoraram, em função da rapidez das informações em toda a cadeia. Porém, esses avanços não garantem estabilidade e melhoria nos resultados da empresa, e a informação de demanda pode ser transferida em velocidade crescente ao longo da cadeia, onde o sucesso não é predicado pela mera informação, e sim alcançado pelos seguintes fatores:

1. Confiabilidade da Informação
2. O que os sócios e gerentes fazem com esta informação, isto é, como a informação e análise das séries históricas, seja ela de demanda ou financeira, ajuda nas decisões e dirige as ações.

Para Stevenson (2001), “a melhor previsão não é necessariamente a mais exata, e nem a menos dispendiosa, na realidade, ela corresponde à melhor combinação entre a exatidão e a estimativa de custo”.

Slack (1997) cita que, “boas previsões são essenciais para o planejamento da capacidade, mas da mesma forma, também é essencial uma compreensão da incerteza da demanda, porque permite que a operação julgue os riscos para o nível de serviço”.

A importância do planejamento de demanda está cada vez mais latente dentro das organizações, e sua prática conduz a resultados de extrema relevância para toda a organização, seja na área industrial, financeira, administrativa, etc.

Segundo Kuo e Xue (1998), dados históricos podem intuitivamente fornecer uma estimativa possível para modelos de previsão. Para tal, a melhor previsão parece ser crítica e métodos estatísticos como Modelos de Regressão e ARMA têm sido os grandes candidatos a serem utilizados no processo de decisão durante décadas. Entretanto, estes métodos somente são eficientes para dados sazonais e cíclicos. Se os dados forem influenciados por casos especiais, como promoções, campanhas, eles não são adequados.

Segundo Werner e Ribeiro (2003), realizar previsões através do estudo de séries históricas é uma atividade importante, pois revela tendências de mercado, contribuí no



planejamento estratégico da empresa, auxilia na solução de problemas mais imediatos, permite maior entendimento do comportamento dos diversos clientes, e constitui fonte adicional de informação no suporte às decisões referentes a investimentos e dimensionamento da equipe.

Os aspectos de uma previsão de demanda de mercado, especialmente no segmento industrial, têm um comportamento flexível e dependente de inúmeras variáveis, e muitas vezes inerentes ao processo.

Por oferecer um conjunto de pontos que pode não ser relevante para outros tipos de técnicas já mencionadas anteriormente, o Modelo de Redes Neurais aplicados para cálculo de previsão de demanda tem sido freqüentemente utilizado nesse caso.

A proposta deste trabalho consiste em aplicar um modelo de Redes Neurais em previsões de demanda do segmento industrial, onde as variáveis são fortemente influenciadas por fatores externos e não programados, em diferentes ramos de atividades.

### **1.1. Método e Material**

O objeto de estudo desse trabalho visa alcançar um nível de previsão de demanda aceitável, partindo do histórico de séries de tempo de onze diferentes segmentos do setor industrial, e utilizando pelo menos um Modelo de Rede Neural.

A proposta é utilizar dados reais de séries de tempo dos 11 setores industriais, extraídos da base de dados do IBGE (Instituto Brasileiro de Geografia e Estatística) e que apresentem características, ciclos e comportamentos diferentes, sendo eles: Farmacêutica, Extrativismo Mineral, Indústria de transformação, Indústria Geral, Indústria Têxtil, Bens de Capital, Bens Intermediários, Bens de Consumo, Bens de Consumo Duráveis, Bens de Consumo Não Duráveis e Indústria de Bebidas.

A partir de um estudo prévio das etapas de implantação de um sistema de previsão de demanda, e pelo estudo dos principais tipos de redes neurais existentes, pretende-se analisar os dados de entrada, formados inicialmente pela série formada pelos 405 pontos que representam os dados históricos dos segmentos apresentados, entre Janeiro de 1975 a Setembro de 2008.

Através da função de auto-correlação de cada segmento, definir a melhor estrutura de rede compatível com um modelo genérico apresentado, e assim, através de um algoritmo de uso

comercial (compatível com os dados utilizados), aplicar a rede neural para cálculo da previsão de demanda utilizando o software Matlab.

Através do uso de modelos matemáticos, para cálculo de erros, analisarem então os resultados da saída da rede, aplicada em cada um dos segmentos apresentados, e assim compará-los com a saída desejada, através dos dados reais conhecidos, e com isso justificar a eficácia da aplicação da técnica de Redes Neurais, no cálculo de previsão de séries de tempo do segmento industrial.

## **1.2. Delineamento do Trabalho**

Este trabalho de mestrado consiste em 7 capítulos dedicados ao estudo de técnicas de previsão de séries temporais, para cálculo de demanda dentro de diversos ramos do setor industrial.

O capítulo 1 apresenta uma introdução ao assunto previsão de demanda utilizando séries históricas, a relevância do tema dentro das organizações, e a metodologia aplicada neste trabalho.

O capítulo 2 mostra os problemas existentes no cálculo de previsões de séries temporais e sua classificação dentro da literatura recente. São apresentadas as divisões dos modelos quantitativos e qualitativos e as etapas para implantação de um sistema de previsão.

O capítulo 3 apresenta a descrição das técnicas de previsão, os modelos mais aplicados e suas características para cada tipo de aplicação.

O capítulo 4 trata-se da descrição do modelo de pesquisa, as variações do modelo de Redes Neurais e suas aplicações, e a coleta de dados do segmento industrial para aplicação do modelo escolhido.

O capítulo 5 refere-se à aplicação e análise dos resultados experimentais de todos os testes e simulações realizadas, com base no exposto nos capítulos anteriores.

Finalmente, no capítulo 6 serão apresentadas as conclusões deste estudo.

## **2. O PROBLEMA DE PREVISÃO**

### **2.1. Previsão de Séries de Tempo**

A previsão tem sido um assunto amplamente discutido em diversos segmentos, e o planejamento de demanda tem sido usado para dirigir o planejamento financeiro e o plano de compras das empresas. A maioria dos executivos reconhece que sem um mecanismo de previsão e planejamento de demanda, é extremamente difícil reduzir inventários e demais custos da cadeia de suprimentos (CRUM e PALMATIER, 2003).

Em algumas empresas, o desenvolvimento de um modelo de previsão é visto como um evento, algo que deve ser feito uma vez por mês, apenas como uma rotina burocrática e que não faz parte do processo. Com baixo grau de importância, a previsão acaba se tornando imprecisa e não relevante para as decisões do planejamento financeiro e de compras (CRUM e PALMATIER, 2003).

Segundo Crum e Palmatier (2003), quando a qualidade da previsão sofre esta influência e passa a ser questionável, o resultado não é confiável, de forma que os responsáveis por fornecer dados para cálculo da previsão vêm seus esforços como uma perda de tempo, e a própria previsão passa a não ser confiável, gerando um ciclo vicioso.

Para Ching (2001), “quando tratamos da manufatura, o ideal seria produzir todos os dias exatamente o que foi vendido no dia, sincronizando a produção com a demanda do mercado, isto é, fazer diariamente pequenos lotes do que é requerido em ciclos regulares. Dessa forma, a manufatura teria seu fluxo balanceado, recursos minimizados, otimizados, perdas eliminadas, controle permanente do processo e alta confiabilidade”.

Para Kotler e Armstrong (1991), existem dois pontos chaves para o gerenciamento de demanda: primeiramente, é responsabilidade da área de marketing (eles consideram a função de vendas como parte da função de marketing); e segundo, a previsão de demanda é o resultado dos esforços do marketing planejado.

A definição da previsão de demanda é normalmente confundida com entrega, sendo comum às empresas utilizarem como base de sua previsão os dados históricos de entregas, o que na maioria das vezes induz a um menor nível de acurácia na sua previsão. O histórico de entrega

ao cliente não garante que sua necessidade tenha sido na mesma data (CRUM e PALMATIER, 2003).

Para Crum e Palmatier (2003), a visão mais ampla do gerenciamento de demanda é dirigir as empresas para o melhor entendimento dos seus clientes, do seu mercado e melhor compreensão das expectativas quanto a produtos, serviços, preços, o que conduz a previsões mais acuradas.

Segundo Ching (2001) as empresas tentam programar sua produção de forma que melhor atendam às demandas ou às previsões de vendas, e em geral, reclamam das constantes alterações dos clientes e, finalmente, entregam o produto, às vezes na quantidade errada, na data não combinada, no lugar errado e, em alguns casos, o produto ainda é o certo.

Segundo Crum e Palmatier (2003) a visão mais ampla do modelo de gerenciamento de demanda consiste na seqüência que segue:

- a. Planejamento de demanda, que envolve mais do que apenas prever;
- b. Comunicação da demanda, que incluem comunicar o plano de demanda para os setores financeiros, suprimentos e as áreas diretamente envolvidas;
- c. Influência da demanda que inclui táticas de vendas e marketing, posicionamento de produto, preço, promoções e outros esforços de marketing e vendas;
- d. Gerenciamento e priorização da demanda, que inclui gerenciar as ordens dos clientes para alinhar a previsão disponível;

A maior dificuldade está, realmente, em equilibrar os custos de processo, de armazenagem, de set-ups de produção, com os custos de manutenção do produto em estoque ou custo de não atendimento dentro do prazo ou da quantidade requerida pelo cliente.

De acordo com a Sociedade Americana de Controle de Produção e Estoques, a definição de previsão de demanda é simplesmente uma estimativa de venda futura.

Para Pellegrini e Fogliatto (2002), as previsões desempenham um papel fundamental na gestão das organizações, planejando recursos financeiros de médio e longo prazo, planejando recursos humanos e marketing, planejando modificações no nível da força de trabalho e no agendamento de promoções de vendas, operacionalizando e viabilizando diversos aspectos do gerenciamento da produção.

As previsões são, como um todo, um tema de consideração crítica para empresas, distribuidores, varejistas e outros membros da cadeia de suprimentos, e tal atividade torna-se elemento central para muitos executivos de nível médio e sênior no gerenciamento de suas companhias (MARIEN, 2001).

Para Marien (2001), muitas empresas acabam recorrendo a inventários em excesso e recursos fixos para compensar impactos negativos que seriam gerados no atendimento à cliente, frente a previsões pouco estruturadas e, portanto, nem sempre confiáveis.

Segundo o autor, as empresas que desejam implementar um efetivo processo de previsão deveriam responder as seguintes perguntas:

- 1) Como os clientes podem ser integrados com membros de outra cadeia de suprimentos para perceberem eficiência no abastecimento?
- 2) Qual o objetivo de compartilhar o plano de negócios na previsão de demanda?
- 3) Que tecnologias de informação permitem a realização das metas de previsão?
- 4) Como o fornecedor ou gerente de suprimentos percebe a previsão de demanda?
- 5) Como os membros da cadeia interpretam os custos de uma previsão não acurada, logística reversa, campanhas ineficazes e custos de melhoria do plano?
- 6) Como pode ser demonstrada aos executivos a oportunidade de retorno sobre investimento das técnicas e processos de previsão?

## **2.2. Taxonomia dos Métodos de Previsão**

Existem três tipos de modelos de previsão (JAIN, 2007)

1. O Modelo de Previsão de Séries de Tempo, cujas técnicas mais conhecidas são:
  - a) Médias Simples e Médias Móveis, Tendências Simples, Alisamento Exponencial e Decomposição;
2. O Modelo de Previsão de Causa e Efeito (Qualitativo Bivariado) classificado como:
  - b) Regressões, Modelos Econométricos e as Redes Neurais;
3. O Modelo de Julgamento, é classificado como:
  - c) Analog, Delphi, Diffusion, PERT, Survey e Cenário.

A descrição e revisão das principais técnicas serão apresentadas no capítulo 3.

De acordo com um modelo adaptado de Silva (2003), a classificação dos modelos de previsão segue o esquema da Figura 01:

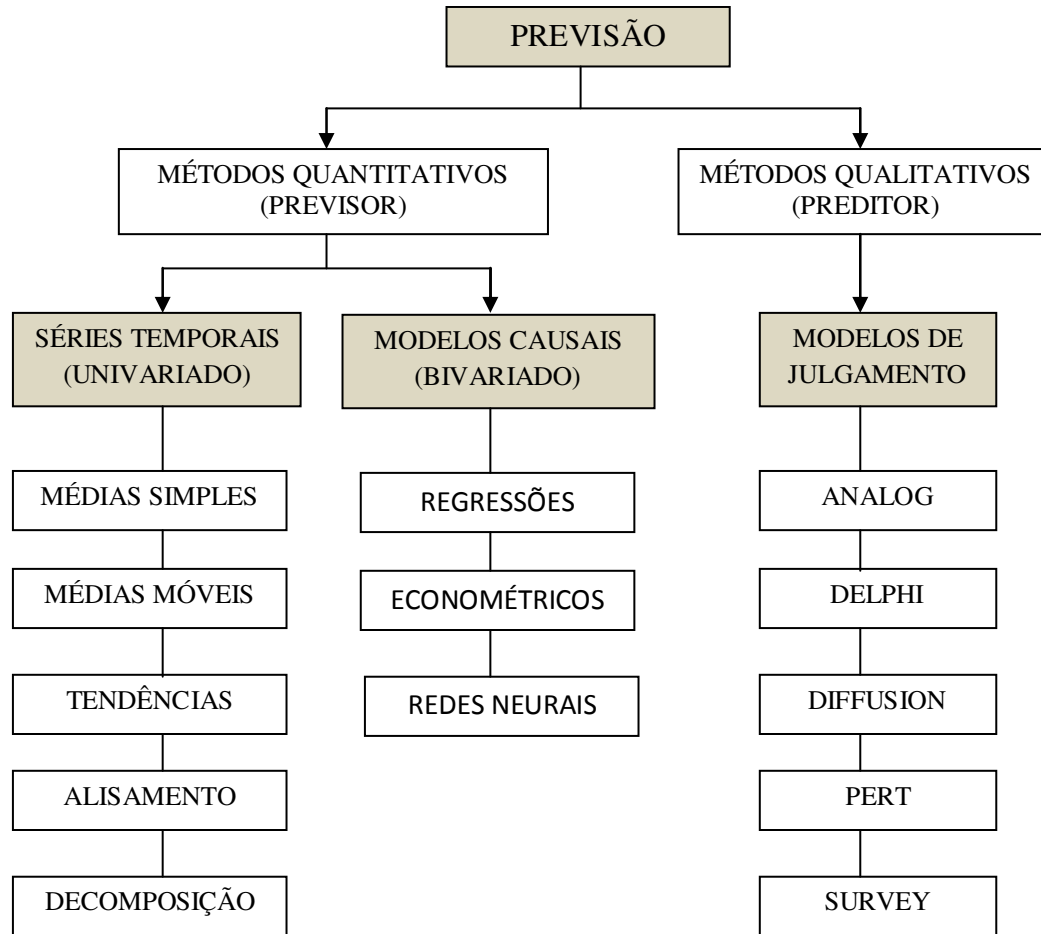


Figura 01 – Métodos de Previsão  
Fonte: Adaptado de Silva (2003)

### 2.3. Etapas para Implantação de Sistemas de Previsão

A previsão de séries de tempo tem recebido muita atenção na literatura, bem como em programas e conferências educacionais. O foco tem sido mais frequentemente tratado como (MARIEN, 2001):

- 1) Uma abordagem com foco no uso de ferramentas estatísticas;
- 2) Um planejamento de operações e orçamento de processo;

- 3) Uma aproximação, na qual sociedades comerciais compartilham programação de produção e operações, dados das atividades de vendas, e níveis de inventários;
- 4) Um passo a passo em direção ao fluxo de processo para unir e reconciliar membros da cadeia de suprimentos;

Para Pellegrini e Fogliatto (2002), a elaboração de um sistema de previsão deve estar baseada em quatro áreas básicas:

- a) Identificação e definição dos problemas a serem tratados na previsão;
- b) Aplicação dos métodos de previsão;
- c) Procedimento para seleção do método apropriado a situações específicas;
- d) Suporte Organizacional para adaptar e usar os métodos de previsão requeridos;

Segundo Makridakis et. al. (1998), a aplicabilidade de um sistema de previsão depende de três condições:

- a) Disponibilidade de informações históricas;
- b) Possibilidade da transformação de informações históricas em dados numéricos;
- c) Suposição da repetição de padrões observados em dados passados no tempo futuro;

### 2.3.1 Definição do Problema

Segundo Pellegrini e Fogliatto (2002), o problema de previsão deve estar associado a diversos fatores que devem ser analisados nesta etapa, tais como:

- 1) Como e onde a previsão será usada;
- 2) Disponibilidade de dados;
- 3) Acurácia;
- 4) Custo da análise e preferências gerenciais;
- 5) Período (tempo requerido), horizonte (número de períodos futuros cobertos pela previsão), e intervalo da previsão (frequência com a qual, novas previsões são preparadas);

O horizonte dependerá da agilidade da organização, pois quanto menos ágil for ela, maior será o horizonte requerido. O intervalo dependerá da estabilidade do processo e dos custos

de re-planejamento, e o período é o fator que mais influenciará na escolha do modelo estatístico (PELLEGRINI e FOGLIATTO, 2002).

A Universidade de Wisconsin-Madison conduziu uma pesquisa integrando vários níveis de decisão de um processo de Planejamento e Previsão. No fluxo apresentado (Figura 02), são atribuídos cinco níveis de negócios que devem ser mutuamente suportados e reconciliados para mantê-los em completo alinhamento. Essa ampla visão do negócio sugerida é crítica, pois os planos de negócio e os orçamentos dirigem o comitê de recursos para as atividades da Cadeia de Suprimentos (MARIEN, 2001).

Segundo Marien (2001), os níveis demonstrados no fluxo são classificados conforme grau de decisão, seleção de fatores e período, e segue as seguintes regras:

- ✓ Nível 1 – Planejamento Estratégico (3 a 10 anos)
- ✓ Nível 2 – Mercado/ Macro (3 a 5 anos)
- ✓ Nível 3 – Canais / Cadeia de Suprimentos (1 a 3 anos)
- ✓ Nível 4 – Tático e Gerenciamento de Inventário (2 a 12 meses)
- ✓ Nível 5 – Demanda Operacional (1 semana a 2 meses)



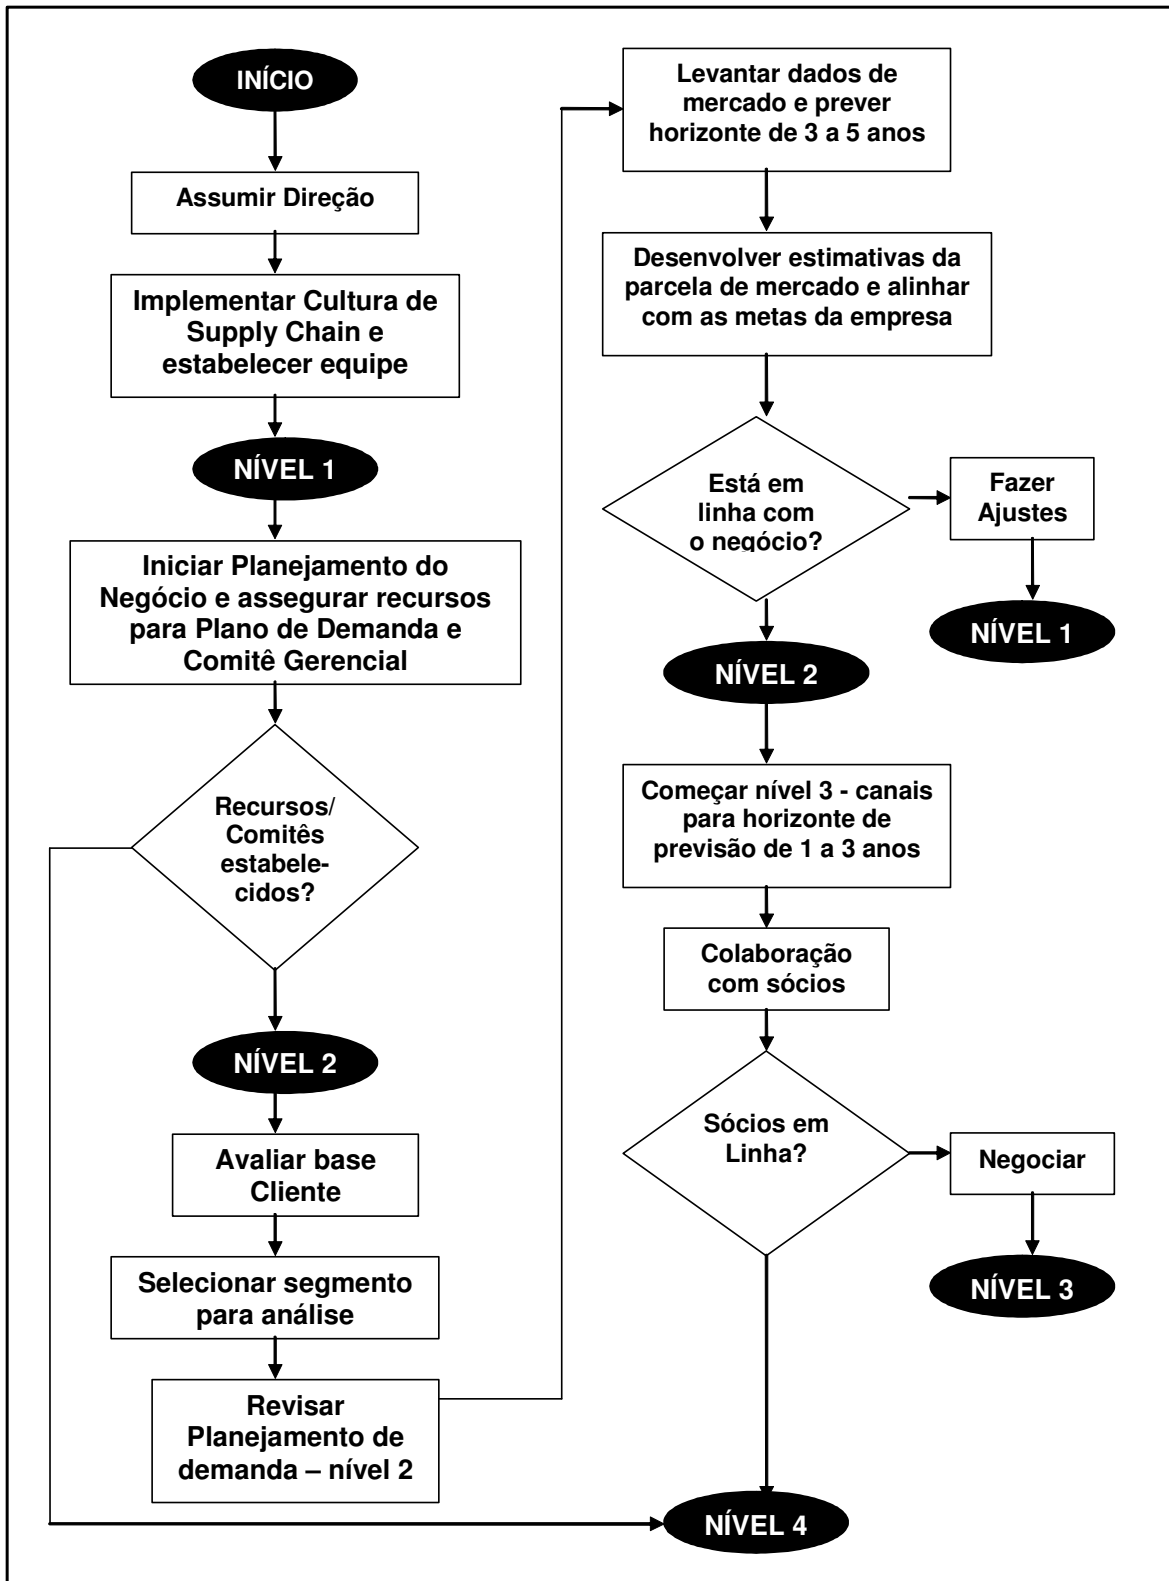


Figura 02 - Fluxo de Eventos para Planejamento de Demanda

Fonte: Marien (2001)

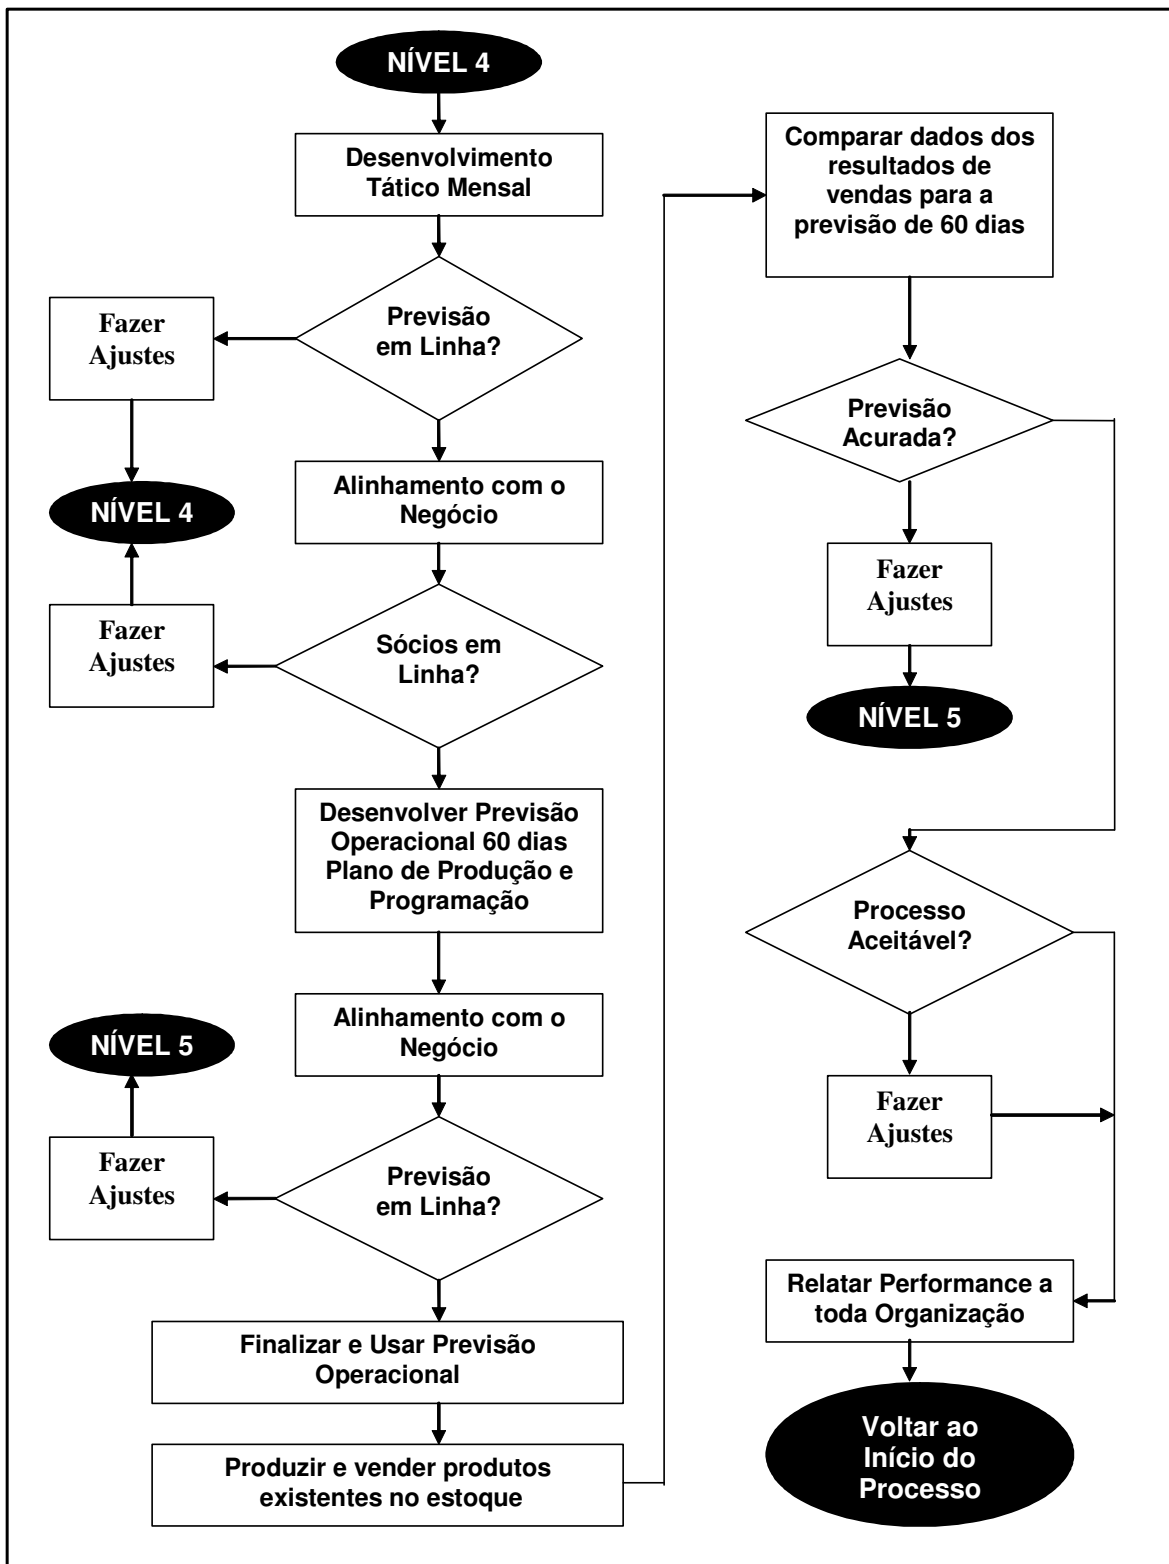


Figura 02 (Continuação) - Fluxo de Eventos para Planejamento de Demanda

Fonte: Marien (2001)

A previsão é um processo que exige um conhecimento do comportamento do mercado, o entendimento completo dos canais de vendas, do ambiente competitivo e, acima de tudo, o conhecimento dos próprios produtos. Contudo, a filosofia de previsão de demanda deve trabalhar baseada nos seguintes pilares (GORDON, 1998):

- i. O consumo dirige a remessa
- ii. O mercado é dinâmico
- iii. Previsões são importantes
- iv. Uma previsão une todo plano de atividades

Segundo Gordon (1998) existe cinco diferentes ciclos de previsão:

- i. Visão Competitiva
- ii. Planejamento estratégico do negócio
- iii. Mais recente estimativa (Mensalmente)
- iv. Gerenciamento da cadeia de suprimentos (Semanalmente)

Segundo a pesquisa feita por Tokle e Krumwiede (2006), os cinco fatores mais importantes a serem considerados sobre os erros de previsão de séries temporais são: as condições econômicas correntes, a informação do cliente, informações do fornecedor, as pesquisas de resultado de mercado e as ordens empenhadas.

### 2.3.2 Seleção de Dados

Durante anos, os profissionais de planejamento têm buscado uma melhoria das previsões de vendas e, conseqüentemente, melhoria dos modelos usados para fazer a previsão. Outro caminho, porém, para melhorar a acurácia das previsões é melhorar a qualidade dos dados usados para esta previsão (GEURTS e WHITLARK, 1996).

A seleção dos dados é extremamente importante, pois se as informações de entrada forem ruins, certamente o resultado será igualmente ruim. É importante, porém, analisar detalhadamente todos os dados de entrada antes de inseri-los no modelo (JAIN, 2007).

Segundo Makridakis et. al. (1998), dois tipos de informações devem estar disponíveis na elaboração de um sistema de previsão: Dados estatísticos (numéricos) e dados subjetivos (experiência dos especialistas para avaliação dos dados).

Para Chase (1999), esses profissionais responsáveis pela elaboração da previsão de demanda, tornam-se analistas de negócio e tem um conhecimento avançado das modelagens estatísticas, associadas com o conhecimento de como o mercado opera, além de estarem providos com ferramentas estatísticas avançadas (Softwares de apoio).

Os dados estatísticos a serem utilizados na previsão devem ser armazenados em um banco de dados que deve conter as séries de tempos e as informações que possibilitem a utilização de filtros, que podem ser os clientes, a região geográfica, os vendedores ou qualquer outro critério para agrupamento dos dados (PELLEGRINI e FOGLIATTO, 2002).

Nem sempre é necessária a análise individual de todos os produtos dentro da metodologia de precisão das séries temporais, até porque, muitas vezes, o banco de dados pode conter centenas ou milhares de produtos que podem ser agregados e analisados conjuntamente.

Segundo Pellegrini e Fogliatto (2002), a metodologia mais aplicada para agregação de produtos é a classificação ABC, no qual a importância do produto está relacionada com a demanda e seu faturamento, sendo que os produtos de classe A representam 80% do faturamento e 20% dos produtos e, neste caso, a previsão é, em geral, feita individualmente. Os produtos concentrados na classe B representam 15% do faturamento e cerca de 30% dos produtos vendidos, enquanto que os produtos de classe C contemplam 5% do faturamento e cerca de 50% dos produtos vendidos e neste último caso, é mais indicada uma previsão agregada de demanda em função do baixo percentual de resultado financeiro da empresa.

O principal ponto para os profissionais de planejamento de demanda é saber as limitações dos dados e quaisquer distorções que possa existir. A análise das séries de tempo pode ser dividida dentro de componentes ou padrões que a maioria dos pesquisadores classifica em quatro pontos, sendo eles: sazonalidade, tendência, ciclos e resíduos, e alguns consideram também um quinto componente que pode ser classificado como fator externo (GEURTS e WHITLARK, 1996).

Para Geurts e Whitlark (1996) esses fatores externos podem ser o resultado do mix de marketing tal como, um preço promocional, promoção de cliente, anúncio extraordinário que pode conter dados efetivos ou somente poucos pontos de dados.

Se os dados de vendas não forem modificados para eliminar o impacto dos fatores externos, quando os dados forem analisados, os modelos podem atribuir os efeitos destes fatores

em um dos quatro itens mencionados previamente das séries de tempo (GEURTS e WHITLARK, 1996).

Chase (1996) cita, da mesma forma, que o sucesso para a implementação de sistemas de previsão de vendas ou planejamento de demanda está diretamente relacionado com o correto levantamento das informações, tais como, análise dos padrões de sazonalidade, tendências, análises de níveis de promoções a clientes, os impactos das promoções nas vendas, entre outros.

A agregação dos dados pode, inicialmente, ser em períodos semanais e mensais, até que algum padrão possa ser identificado na série de maneira distinta, porém, há casos em que após várias agregações temporais, nenhuma característica é encontrada, significando que os dados de demanda apresentam um comportamento exclusivamente aleatório, e que pode comprometer a precisão de previsões futuras (PELLEGRINI e FOGLIATTO, 2002).

Segundo Chase (1996), muitas empresas têm, na maioria das vezes, todos os dados necessários para elaborar um planejamento de demanda ou previsão de vendas, porém, muitos desses dados são fragmentados e não interagem facilmente uns com os outros e, além disso, os sistemas construídos nunca lidam com questões complexas de uma maneira oportuna. Essas questões são trabalhadas pelo departamento de gerenciamento de informações (MIS – Management Information System) e podem levar semanas ou meses para serem completados.

Durante a seleção, os dados históricos agrupados podem ser representados graficamente para melhor identificação de possíveis valores ilegítimos que podem ser causados por erros de digitação, falta de produtos, entre outras causas, mas que segundo Pellegrini e Fogliatto (2002) podem ser tratados através dos seguintes procedimentos:

- A. Quando o valor ilegítimo encontra-se no final da série temporal e existem valores suficientes para gerar um modelo de previsão, substitui-se o valor irreal pela previsão relativa ao período correspondente ao dado excluído.
- B. Quando o valor irreal encontra-se no início da série temporal, o procedimento descrito anteriormente torna-se inviável e, portanto, deve-se fazer a substituição deste valor por um valor médio das observações imediatamente adjacentes a ele, e gerar um modelo de previsão.

### 2.3.3 Análise de Dados

A análise dos dados e o encaminhamento das ações são questões importantes que até recentemente ainda eram freqüentemente negligenciados por muitos pesquisadores e profissionais (ARMSTRONG, 2006).

Segundo Jain (2007), é nesta etapa que a limpeza e os ajustes devem ser feitos e observados, e alguns pontos podem ser seguidos para um melhor resultado da previsão:

- ✓ Se o objetivo é a previsão de séries de tempo, deve-se assegurar que todas as observações e dados estejam completos;
- ✓ Observar mudanças estruturais nos dados e pontos extremamente altos ou extremamente baixos;
- ✓ Para modelos de séries de tempo, os números fora da curva devem ser ajustados antes da modelagem, em modelos de regressão, entretanto, eles devem ser manuseados através de variáveis dummy;
- ✓ Perceber se ocorre sazonalidade nos dados. Flutuações sazonais são aquelas que ocorrem regularmente e periodicamente, e o tempo de ciclo é sempre de um ano ou menos;
- ✓ Verificar se existe tendência nos dados, e se existir, estar certo de que o modelo escolhido contempla tal característica;
- ✓ Se existir algum valor perdido, ele deve ser estimado dentro do período observado para modelos de séries de tempo, mas não em modelos de regressão;
- ✓ Decidir o número de períodos dos dados a serem usados na preparação da previsão, sendo que a quantidade de dados depende do ciclo de vida do produto;

Uma vez selecionados os dados para elaboração de uma previsão, analisam-se então os resultados dos fatores que influenciam a tomada de decisão, como padrões, tendências e sazonalidades.

A análise gráfica, como já citada por Pellegrini e Fogliatto (2002) e mencionado no item anterior, fornece subsídios auxiliares na escolha dos modelos e técnicas a serem utilizadas.

Segundo Armstrong (2006) a análise dos dados é descrita como um processo de quatro passos: Testar suposições, avaliar dados e métodos, replicar e avaliar saídas.

A base filosófica das previsões por séries de tempo é que os valores medidos, que constituem as séries, são gerados por um processo subjacente que permanece estacionado ao longo do tempo (GEURTS e WHITLARK, 1996).

Segundo Geurts e Whitlark (1996), existe um problema adicional de análise da previsão das séries temporais em que um produto pode não compor apenas uma única série de tempo, mas duas diferentes séries. As séries de tempo, para alguns meses, podem medir a necessidade do cliente e, para outros meses, pode medir a previsão do produto frente a fatores externos como, por exemplo, taxas, quotas de importação, tarifas ou capacidade produtiva e, não necessariamente, a demanda daquele ou outro cliente.

#### 2.3.4 Definição do Método Adequado

Um dos mais importantes objetivos para a implantação de um processo de previsão de demanda é determinar qual técnica de previsão é mais adequada em diferentes horizontes de tempo e níveis de previsão. A experiência mostra que o Alisamento Exponencial tende a ser mais usual para horizontes de curto prazo (menor que três meses), entretanto, modelos de regressão tendem a ser mais comum para horizontes de longo prazo (MENTZER e COX, 1984).

Jain (2007) cita que quanto maior o conhecimento do profissional, melhor será sua escolha, sendo importante seguir alguns dos fundamentos abaixo:

- ✓ Atual = Padrão + Erro – Cada série de dados forma certo padrão de dados e cada modelo assume certo padrão de dados, sendo que o objetivo é encontrar o modelo que melhor se ajuste ao padrão inerente aos dados.
- ✓ Não é necessária uma acurácia de 100%. A decisão do melhor modelo não aponta para uma previsão perfeita;
- ✓ Modelos sofisticados não são necessariamente melhores. Com muita frequência os modelos mais simples trabalham bem;
- ✓ Não existe modelo mágico. Nenhum modelo é perfeitamente adequado a todos os dados;

- ✓ Os modelos podem se desatualizar no decorrer do tempo. O modelo certo encontrado não será eterno, pois as mudanças de mercado são dinâmicas, sendo assim, é importante monitorar regularmente a performance de cada modelo;
- ✓ Cada modelo tem sua própria necessidade de dados. Um modelo pode necessitar de mais dados e/ ou observações que outro.
- ✓ Previsões estatísticas nada mais são que a linha base das previsões, não sendo somente ciência e nem somente arte, mas a combinação de ambas, sendo necessária uma análise de todos os fatores envolvidos;
- ✓ As previsões não deveriam ser elaboradas isoladamente. É necessário o envolvimento de vários profissionais, além de informações coletadas dentro e fora da empresa;

Para identificar o modelo mais apropriado, deve-se inicialmente analisar o gráfico de tempo da série em estudo. A análise deste gráfico pode indicar a presença de tendência ou alteração na variância, o que revelaria se a série é ou não estacionária; em seguida devem-se analisar as funções de auto-correlação (WERNER e RIBEIRO, 2003).

A pesquisa feita por Jain (2007), com dez empresas que utilizam técnicas e modelos estatísticos para previsão de demanda, mostra a tendência do uso dos métodos de previsão conforme Figura 03:




Figura 03 – Tendência do uso dos métodos de previsão  
Fonte: Jain (2007)



Da mesma pesquisa, resultou o intervalo mais utilizado para os modelos de previsão, conforme Figura 04 (JAIN, 2007):




Figura 04 – Intervalo dos métodos de previsão  
Fonte: Jain (2007)

A pesquisa feita por Jain (2007) mostra dentro dos diversos modelos de previsões de séries de tempo, os mais utilizados, conforme Figura 05:




Figura 05 – Técnicas mais utilizadas nos métodos de previsão  
Fonte: Jain (2007)

### 2.3.5 Seleção do Sistema de Apoio (Software)

Devido à complexidade de se trabalhar com alguns modelos de previsão de demanda, é fundamental o uso de recursos computacionais para cálculo e desenvolvimento deste trabalho, e devido a grande variedade de softwares de simulação existentes atualmente no mercado, a escolha passa a ser um dos fatores importantes dentro deste processo, porém, não é recente o uso destes recursos no desenvolvimento de previsões.

O desenvolvimento de previsões e métodos de séries de tempo pode ser encontrado antes do século XVII, quando o número de pontos solares e índices de preço era analisado pelos cientistas. Entretanto, a prática do uso de métodos estatísticos e econométricos foram possíveis a partir da invenção e expansão dos computadores digitais por volta da década de 50 (KÜSTERS et al., 2006).

Segundo Küsters et al. (2006), os primeiros sistemas de softwares que permitiram um planejamento mais próximo dos processos de previsão apareceram na década de 70. Estes ofereciam características simples de planejamento, tal como administração de séries de tempo, agregação e desagregação de séries, emissão de relatórios e funções para preparar dados e apresentar gráfico.

Até o desenvolvimento do PC em 1980, o uso de softwares de previsão ainda era pouco utilizado e seu uso era restrito a grandes empresas. A partir daí, com a redução do custo dos computadores, o estímulo ao uso de softwares de demanda incentivou a indústria de desenvolvimento de softwares (KÜSTERS et al., 2006).

Segundo Chase (1996), qualquer sistema que seja implementado para auxiliar o cálculo de previsão não é um processo, ao contrário disso, ele deve ser construído em torno de um processo de previsão de vendas já consolidado.

Alguns dos sistemas integrados de soluções oferecidos no mercado, infelizmente, assumem que o processo era desenhado em torno do sistema e não o inverso.

A partir desta análise, a maioria das empresas que adquirem um sistema integrado para previsão de demanda acaba tendo duas escolhas: fazer uma re-engenharia do processo apenas para ajustar o sistema ou redesenhar e programar o sistema para ajustar seus processos (CHASE, 1996).

Com isso, os gastos de tempo e recursos tornam-se bem maiores do que o esperado e previamente planejado na aquisição do software e, por isso, as customizações e a capacidade dos resultados tornam-se limitadas e específicas.

Chase (1996) conclui que o uso de métodos quantitativos de séries de tempo, tal como Suavização Exponencial e Winters, por serem mais facilmente sistematizados, requerem menor manutenção da base de dados.

Para Küsters et al. (2006), poucos softwares de sistema de previsão oferecem o verdadeiro estado da arte. Muitos avanços no estudo de previsão não são incorporados dentro dos sistemas em tempo razoável, e os profissionais que desenvolvem o software têm, naturalmente, que esperar para ver qual novo método sustenta o teste de tempo, tornando-se popular e aplicável. Se os pesquisadores desejam aplicar um novo método, eles devem duplicar seus esforços quanto à efetividade do mesmo, devendo reescrever códigos que já tenham sido escritos. Kuster et. al. (2006) ainda cita não ser um caminho eficiente para o progresso da ciência, pois para os pesquisadores a escolha de um método simples frente a um método complexo é feita desde que ele seja mais simples, aplicável e publicável em jornais e revistas.

Alguns pontos importantes apresentados em Makridakis et al. (1998) e Pellegrini e Fogliatto (2002) são listados abaixo para seleção do pacote computacional.

- ✓ O pacote escolhido deve aceitação no nível gerencial;
- ✓ O sistema deve ser compatível com aqueles utilizados pela empresa;
- ✓ O programa deve ser de fácil utilização e aprendizado;
- ✓ O programa deve possibilitar outros novos modelos além do escolhido;
- ✓ Deve oferecer respostas rápidas para análises de muitas séries;
- ✓ Devem apresentar resultados próximos para diferentes algoritmos (precisão dos dados deve ser comparada);

### 2.3.6 Medidas de Acurácia e Análise de Resultados

Empresas que tem tecnologias mais novas tendem a um menor erro na previsão, entretanto, aquelas que tinham maior erro são as que modificavam com mais frequência suas previsões, e aquelas empresas que mediam seus erros, conseguiam ajustar e ter uma melhor

acurácia ao longo do tempo, igualmente com as que planejavam suas vendas com base na sua previsão (TOKLE e KRUMWIEDE, 2006).

Segundo Pellegrini e Fogliatto (2002), dependendo do comportamento da série temporal que se deseja analisar, vários modelos podem ser empregados na previsão de seus valores futuros, e a escolha do modelo mais apropriado é feita a partir do somatório dos erros gerados por cada modelo. Diferentes formas de cálculo podem ser empregadas e constituem-se em critérios para escolha de modelos mais apropriados a séries temporais. Os critérios mais utilizados são os descritos abaixo e a definição do modelo mais apropriado será aquele que tiver o menor erro associado:

- ✓ Média do Quadrado dos Erros (MQE) =  $1/n \sum (e_t^2)$  (t=1 à n)
- ✓ Média Absoluta dos Erros (MAE) =  $1/n \sum |e_t|$  (t=1 à n)
- ✓ Média Absoluta Percentual dos Erros (MAPE) =  $1/n \sum (e_t / Z_t \times 100)$  (t=1 à n)

A análise dos resultados deve, necessariamente, estar associada às informações de mercado, questões econômicas, políticas governamentais, marketing e tendências do consumidor para que o planejamento fique próximo do real. Tal ferramenta nunca poderá ser utilizada de forma isolada na geração de demanda.

“Nas previsões estatísticas por séries de tempo, é perigoso assumir que o histórico se repetirá e que os clientes comprarão exatamente o que compraram no ano anterior” (CRUM e PALMATIER, 2003).

A análise dos dados compreende estatística descritiva (médias, desvios padrão, valor máximo, valor mínimo), correlações e/ou cruzamento de dados (KAHN, 1999).

Segundo Kahn (1999), as medidas de performance que a maioria das empresas seguem, são:

- ✓ Média absoluta dos percentuais de erros – A mais popular medida de acurácia;
- ✓ Erro estatístico pelo volume – Usado em grande parte das empresas;

As empresas que estão satisfeitas com seu processo de previsão de vendas distinguem-se das demais por uma série de características como (KAHN, 1999):

- ✓ Medem acurácia da previsão e/ou erros;
- ✓ Usam um consenso de aproximação em seu processo de previsão de vendas;
- ✓ Reconhecem o setor de previsão de demanda como uma entidade separada e responsável por toda função de previsão;
- ✓ Asseguram que o setor de previsão de demanda tem alta credibilidade na organização;

O resultado da análise deve ser baseado no conhecimento do analista de negócio (normalmente o responsável pela elaboração da previsão) sobre como o mercado opera, utilizando a ferramenta estatística adequada.

### **3. REVISÃO DAS TÉCNICAS DE PREVISÃO**

Cada série de dados tem um padrão próprio e cada modelo associa um padrão específico. O melhor resultado é alcançado através de uma associação correta dos dados com o modelo escolhido (JAIN, 2007).

Dentro da metodologia das Técnicas de Previsão, a previsão de vendas é um tema de extrema relevância dentro da estratégia de negócios de uma empresa. Inúmeras situações geralmente direcionam métodos de estatísticas tais como regressão ou auto-regressão e médias móveis, entretanto, tais previsões são complexas por terem influência do ambiente externo e interno (KUO e XUE, 1999).

São vários os estudos feitos sobre as técnicas de previsão. O Quadro 02, apresentada na seção 3.4, é uma adaptação do artigo de Gooijer e Hyndman (2006) que faz um resumo cronológico das principais pesquisas e publicações que ocorreram ao longo das últimas oito décadas para previsões de séries de tempo. Outros trabalhos serão abordados no decorrer deste capítulo.

Na sequência, serão descritos os modelos de séries de tempo por suas características e os modelos estratificados que partiram conforme modelos apresentados e extraídos do artigo de Gooijer e Hyndman (2006).

#### **3.1. Modelo de Séries de Tempo (Quantitativo - Univariado)**

Os métodos quantitativos ou de previsão estatística definem explicitamente como a previsão é determinada e a lógica é claramente determinada por operações matemáticas.

A técnica mais utilizada pelos profissionais da área é a de séries temporais que usa dados históricos por períodos de tempo definidos para projetar períodos futuros.

No modelo de séries de tempo, é feita a extrapolação de dados do passado, de modo que se obtenha o melhor ajuste estatístico.

Os modelos de séries de tempo utilizam o método de mudança percentual que assume o histórico percentual como projeção futura na mesma proporção. Tais modelos são de fácil

entendimento e uso e são mais bem aplicados em previsões de curto prazo. Os modelos de Séries de Tempo incluem:

- ✓ Médias Simples e Médias Móveis
- ✓ Tendências Simples
- ✓ Alisamento Exponencial
- ✓ Decomposição

Os modelos de séries de tempo podem ser classificados em modelos estacionários, não estacionários e sazonais. Os modelos estacionários assumem que o processo está em equilíbrio com média e variância constante ao longo do tempo. Nos modelos não estacionários, a média e a variância são dependentes do tempo, enquanto nos modelos sazonais ocorre auto-correlação entre os valores da série em instantes sucessivos (WERNER e RIBEIRO, 2003).

Períodos sazonais tendem a uma maior confiabilidade quando tratados em um período de tempo mais longo (meses ou anos); outro ponto a ser considerado é que esta técnica possui uma melhor aderência para grandes quantidades (centenas ou milhares) de itens oferecidos e projetados.

As técnicas de Séries de Tempo usam algoritmos matemáticos para determinar as tendências do passado para definir as projeções e tendências do futuro, e seu grau de acurácia é maior para períodos que não sofrem variações significativas influenciadas por fatores externos não programados.

Se os valores futuros de uma série temporal são determinados exatamente por alguma função matemática, esta série é denominada “determinística”. Se os valores futuros podem ser descritos apenas em termos de uma distribuição de probabilidade, a série temporal é chamada “não determinística” ou simplesmente série temporal “estocástica”.

A base de um método de previsão é a ponderação simples das observações passadas de uma série temporal, incluindo o uso de médias simples e médias móveis. As maiores vantagens destes métodos são seu baixo custo, a facilidade de aplicação e a rapidez na qual podem ser adotados. Estas características tornam-se relevantes quando o horizonte de tempo é relativamente curto, menor que um ano e quando a amostra a ser prevista é grande.

A média móvel usa dados de um número determinado de períodos para gerar a previsão, e a cada novo período, substitui o dado mais antigo pelo mais recente, conforme equação (TUBINO, 2000):

$$Mm_n = \sum D_i / n, (i= 1...n) \quad (1)$$

onde:

- ✓  $Mm_n$  = Média Móvel de n períodos
- ✓  $D_i$  = Demanda ocorrida no período i
- ✓ i = Número de períodos

Quando o número de itens produzidos pela empresa é muito elevado, usa-se a estratégia de agrupamento, no qual os itens que tenham alguma característica em comum passam a serem tratados por famílias ou categorias, facilitando assim o cálculo e, principalmente, as análises dos resultados encontrados para tal previsão.

Na análise de séries temporais tem-se, como uma das finalidades, identificar e analisar tendências, usando-as nas previsões ou removendo-as para análise de outros componentes que influencia a série.

A análise de tendência tem fator relevante na direção de longo prazo, pois determina necessidade de expansão ou retração do objeto estudado, de acordo com o resultado da previsão.

Nos dados de demanda que apresentam tendências, podem ocorrer variações nos períodos de forma crescente ou decrescente, sendo que esta tendência pode ser linear ou representada por um polinômio de grau maior. No caso de caracterizar tendência de maior graduação, utiliza-se a regressão linear ou polinomial para determinação de tendências a longo prazo de demanda.

Quando o método de Alisamento Exponencial foi proposto, muitos acreditavam que poderia ser desconsiderado por se tratar de um caso especial do modelo ARIMA. Hoje, porém, o modelo é considerado um ótimo método para várias classes gerais de modelos de estado-espço.

Segundo Gardner (2006), o método de Alisamento Exponencial foi desenvolvido por Robert G. Brown durante a década de 50 e apresentado em 1956, na Conferência da Sociedade Americana de Pesquisa Operacional, mas foi através dos trabalhos de Holt e Winters (apud Gooijer e Hyndman, 2006), que o modelo ficou mais conhecido.

Holt (apud Gooijer e Hyndman, 2006) foi o primeiro a introduzir o conceito de tendência acumulativa, desenvolvendo um método diferente para suavização de dados sazonais. Winters testou o método com dados empíricos, tornando-o amplamente conhecido como Método de Holt-Winters.



O primeiro passo para qualquer série de tempo consiste na geração de dados, e se houver alguma aparente descontinuidade nas séries, tal como uma repentina mudança de nível, é aconselhável analisá-las pela primeira quebra do segmento e verificar se existe qualquer justificativa para descartá-la (BROCKWELL e DAVIS, 2002).

Outro modelo clássico de séries de tempo é o Modelo de Decomposição, identificado por uma mudança lenta de função conhecida por um componente de tendência e sazonalidade. Se a sazonalidade e flutuações aparecerem para aumentar com o nível do processo, então uma transformação preliminar de dados é freqüentemente usada para tornar os dados mais compatíveis com o modelo (BROCKWELL e DAVIS, 2002).

### **3.2. Modelo de Causa e Efeito (Quantitativo - Bivariado)**

No modelo de causa e efeito, há uma causa (chamada de direção ou variável independente) e há um efeito (chamada de variável dependente), onde a previsão é determinada pela relação entre elas. Estes modelos são usados onde existe uma forte relação entre causa e efeito e elas não mudam significativamente ao longo do tempo. Os modelos de Causa e Efeito incluem:

- ✓ Regressões
- ✓ Modelos Econométricos
- ✓ Redes Neurais

O modelo de Auto-Regressão (AR) foi primeiramente apresentado por Yule em 1926 e posteriormente complementada por Slutsky (apud Gooijer e Hyndman, 2006) através do esquema de Média Móvel (MA).

Foi, entretanto Wold que em 1938, apud Gooijer e Hyndman (2006), que combinou os dois modelos e mostrou que o processo chamado ARMA poderia ser usado em classes das séries de tempo estacionárias. Isto significa que uma série geral pode ser modelada como uma combinação de valores e/ou erros do passado (MAKRIDAKIS e HIBON, 1997).

Segundo Makridakis e Hibon (1997), para o uso da modelagem de séries de tempo reais, são necessários quatro passos:

1. As séries de tempo originais  $X_t$  devem ser transformadas de forma a se tornarem estacionárias em torno da sua média e variância;

2. As ordens apropriadas de AR e MA devem ser especificadas;
3. Os valores dos parâmetros devem ser estimados usando algum procedimento de otimização não-linear que minimiza a soma dos erros quadrados ou alguma outra apropriação menos funcional.
4. Os caminhos de modelagem de séries sazonais devem ser pressentidos e as ordens apropriadas de forma que o modelo seja especificado.

Assume-se que auto-regressão e os parâmetros de médias móveis, satisfazem as condições estacionárias e de inversão, respectivamente. Desde que o componente de média móvel assuma a possibilidade de inversão (VALENZUELA et al., 2008).

Tradicionalmente, o modelo ARMA tem sido um dos mais frequentemente usados em modelos de previsão de tempo linear (VALENZUELA et al., 2008).

Segundo Valenzuela et al. (2008), a principal vantagem do modelo de previsão ARMA é que ele só exige dados das séries de tempo em questão, passando a ser uma característica vantajosa se a previsão contém um grande número de séries de tempo. Outros pontos relevantes são:

- ✓ Ele evita um problema que acontece às vezes com modelos multivariáveis, onde uma determinada série de tempo pode ter menor período que outras, restringindo o tempo disponível para estudo.
- ✓ Com modelos multivariáveis, a oportunidade de dados pode ser um problema, pois se um grande modelo estrutural tiver variáveis que são publicadas somente com um grande atraso, as previsões, usando este modelo, serão condicionadas e baseadas em observações indisponíveis, adicionando uma dose de incertezas.

Dentro da categoria dos Modelos de Causa e Efeito em que duas ou mais variáveis influenciam o processo, existem os Modelos Econométricos, que são utilizados para horizontes de tempo acima de três anos.

Segundo Zhou (1999), os Modelos Econométricos são escolhidos para horizontes de longo prazo por duas razões. Primeiramente, a maioria dos negócios é dirigida fundamentalmente pela economia. Mas as previsões gerais por séries de tempo, em período longo, seguem indefinidamente para cima ou para baixo. Nos Modelos Econométricos, pode-se usar a diferenciação de variáveis. Sendo a maioria das variáveis macroeconômicas não estacionárias

(suas média e variância não são constantes), diferenciando ou tendendo, deve-se evitar o problema chamado de regressão espúria que ocorre quando a estatística tradicional é incorretamente aplicada para séries de tempo não estacionárias. A segunda razão é porque, com este tipo de modelagem, pode-se facilmente identificar sazonalidades ou mudanças de estrutura pelo uso de variáveis aleatórias (dummy).

Os Modelos Econométricos de séries de tempo são modelos de regressão multivariada que usam variáveis econômicas e, em geral, necessitam de muito esforço para construção de um modelo de previsão; além disso, o responsável pela previsão tem que alcançar, através dos testes estatísticos, a variável econômica mais relevante (ZHOU, 1999).

Outro Modelo de Causa e Efeito, baseado nas equações de auto-regressão e médias móveis é o Modelo ARIMA também conhecido como Modelo Box e Jenkins.

Makridakis e Hibon (1997) cita que o uso do modelo ARIMA foi popularizado por Box e Jenkins (1976, edição original 1970), contendo as seguintes características:

1. Fornece diretriz para ações de séries de tempo estacionárias na média e variância;
2. Sugere o uso de auto-correlações, e coeficientes de auto-correlações parciais para determinar valores apropriados de AR e MA (e seu equivalente sazonal P e Q quando a série exibiu sazonalidade);
3. Fornece um conjunto de programas de computador para ajudar usuários a identificar valores apropriados para AR e MA, como também para P e Q, e estimar os parâmetros envolvidos;
4. Uma vez que os parâmetros do modelo eram estimados, o diagnóstico era proposto para determinar se os resíduos eram ou não coerentes, e em que caso a ordem do modelo não era considerado final (caso contrário, outro modelo era considerado repetindo-se os passos 2, 3 e 4);

A proposta de Box e Jenkins tornou-se então conhecida como Metodologia de Box Jenkins para modelos ARIMA, onde a letra I, entre AR e MA, permaneceu para a “Integração” e refletiu a necessidade de diferenciação para fazer séries estacionárias (MAKRIDAKIS e HIBON, 1997).

Como os dados de uma série temporal são coletados sequencialmente ao longo do tempo, espera-se que ela apresente correlação seriada no tempo. Os modelos de Box\_Jenkins,

(ARIMA – Auto Regressive Integrated Moving Averages) ou modelos Auto-regressivos Integrados de Médias Móveis, são modelos matemáticos que visam captar o comportamento da correlação seriada ou auto-correlação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras. Se essa correlação for bem modelada, fornecerá boas previsões (WERNER e RIBEIRO, 2003).

É importante frisar que o uso de modelos auto-regressão com médias móveis exigem uma influência humana para especificação dos tipos de modelos a serem usados nas séries de tempo. Alguns problemas são percebidos quando utilizamos tais modelos (ARMA/ARIMA) na previsão (VALENZUELA et al., 2008).

- ✓ O resultado da metodologia Box Jenkins depende fortemente da competência e experiência da análise profissional e é afetada por esta dependência.
- ✓ A identificação do modelo pode exigir um tempo excessivamente alto.
- ✓ O modelo Box Jenkins não é introduzido em qualquer modelo teórico subjacente ou com relações estruturais, portanto, não é possível simular políticas dirigidas com modelo ARIMA, diferentemente dos modelos estruturais.
- ✓ Modelos ARIMA são modelos lineares, mas no mundo real, as séries de tempo, raramente, são combinações puramente lineares.

Quando os dados nos modelos ARIMA são observados em períodos inferiores a um ano, a série também pode apresentar auto-correlação para uma estação de sazonalidade “s”. Para essas séries que apresentam auto-correlação sazonal, o modelo é chamado de SARIMA, e compõem uma parte não sazonal e uma sazonal (WERNER e RIBEIRO, 2003).

Existe também o modelo Bayesiano - BATS (Bayesian time series analysis) para a previsão de demanda, que comparado com ARIMA (Auto regressive integrated moving average) tem as seguintes características (SPEDDING e CHAN, 2000):

1. Tem boa acurácia para previsões de médio e curto prazo;
2. A probabilidade condicional na teoria Baysiana é ideal para análises de séries de tempo estocásticas;
3. Tem um comportamento que permite uma atualização mais recente de informações;

4. Previsão Bayesiana facilita o gerenciamento por exceção;
5. Processo de intervenção dinâmica pode lidar com mudanças estruturais da série de tempos devido a mudanças de comportamento da demanda;
6. Análise Bayesiana tem uma aproximação mais intuitiva para solucionar problemas da vida real;
7. Diferentes modelos de previsão podem ser construídos automaticamente;

As desvantagens, segundo Spedding e Chan (2000), são:

1. Requer entrada de dados e análises de especialista;
2. A manutenção do modelo de previsão requer certo nível de expertise;
3. A solução obtida pode não ser favorável;
4. Não é um método estabelecido no mercado e, portanto existem referências limitadas;

O Quadro 01 mostra a comparação feita por Spedding e Chan (2000):

Quadro 01 – Comparação dos modelos BATS e ARIMA

	<b>BATS</b>	<b>ARIMA</b>
<b>ESTRUTURA DE DADOS</b>		
Valores perdidos	Teorema de Bayer	FiltroKalman
Transformação de dados	Flexível	Flexível
Desvio de pontos	Bom	Ruim
Externos	Bom	Ruim
Mudança estrutural	Bom	Ruim
Montante de dados	Baixo	50-100
Memória	Sim	Sim
Período relevante dos dados	Sim	Sim
Modificação do período relevante	Sim	Sim
Outras variáveis (regressão)	Sim	Sim
<b>CRITÉRIO DE PREVISÃO</b>		
Tipos de series de tempo	Estocástico	Estocástico
Modelo	Dinâmico	Estático
Redes de tempo	Curto-Médio Prazo	Curto-Médio
Custo de manutenção	Médio	Alto
Acurácia da previsão	Alto	Médio
Simplicidade	Baixa	Alta
Procedimento da previsão	Médio	Difícil
Entendimento	Fácil/ Intuitivo	Médio
Complexidade do Modelo	Médio	Simples
<b>VALIDAÇÃO</b>		

Subjetivismo	Flexível	Médio
Monitoramento e Atualização	Fácil	Baixo
Necessidade de entrada subjetiva	Flexível	Médio
Estacionaridade e Inversão	Não	Sim
Interação	Sim	Sim
Crítérios de convergência	Não	Sim
Processo de aprendizagem	Sim	Não
Conceito de gerenciamento	Gerenciamento por Exceção	Não
Ambiente operacional	Estável e Instável	Estável
Atualização seqüencial	Sim	Não
Intervenção subjetiva	Sim	Não
Prognóstico	Incertezas aumentando com o tempo	Fórmula fixa

Fonte: Spedding e Chan (2000)

Outro modelo baseado na técnica Bayesiana, muito utilizado em previsões de produtos com demanda esporádica e com mudanças repentinas é o DLM (Dynamic Linear Modeling) ou Modelagem Linear Dinâmica.

Este modelo tem vantagens superiores às técnicas existentes, como por exemplo, a habilidade para reagir a mudanças externas. Devido ao largo número de séries de tempo que necessitam de processamento automático, a técnica DLM tem sido adaptada para automatizar o processo que exigiria intervenção manual (PICKSLEY e BRENTNALL, 1999)

Segundo Picksley e Brentnal (1999), quando as séries de tempo mostram significativas mudanças no seu padrão geral, outros modelos podem ter maiores dificuldades na leitura da mudança manifestando maiores variâncias, e com isso o DLM é melhor adaptável a esse tipo de situação.

A DLM parte de alguma quantificação do modelo estimado (linguagem Bayesiana, uma pré-distribuição) antes de qualquer histórico processado. Ele então produz um conjunto de modelos estimados para cada ponto, usando a informação de cada dado para suavizar aquela estimativa inicial. Essencialmente, para cada dado histórico, a DLM produz uma previsão, usando o modelo estimado produzido para o ponto imediatamente anterior a ele, comparando assim a previsão do ponto atual. A diferença entre uma previsão e um dado ponto atual representa a distribuição que é usada pelo DLM para suavizar a estimativa de período a período. Se, por exemplo, existissem 36 períodos de históricos mensais, então teríamos 36 modelos estimados ao invés de apenas um. A primeira estimativa não será muito boa por estar baseada em somente uma

observação, mas as últimas estimativas entrarão com a base de todos os 36 meses e, portanto, terão melhor acurácia (PICKSLEY e BRENTNALL, 1999).

Quando uma mudança é esperada no futuro, intervenções manuais podem ser usadas, e neste caso, a mudança é forçada no modelo estimado, associada com o componente de tendência da previsão. A seqüência da previsão continua, habitualmente, até encontrar tal mudança, incorporando a intervenção do modelo estimado e continuando com a nova tendência.

Para Picksley e Brentnal (1999), devido à complexidade desta técnica, ela é importante para obtenção de previsões mais acuradas e medidas de variâncias, sem a necessidade de perda de tempo para gerenciar cada modelo. Este modelo trabalha automaticamente com bom rendimento e previsões seguras.

O primeiro modelo artificial baseado em neurônio biológico foi desenvolvido originalmente na década de 1940, pelo trabalho de Warren McCulloch e Walter Pitts (1943)

O trabalho de McCulloch e Pitts (1943) concentrou-se muito mais em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais, do que em apresentar técnicas de aprendizado (BRAGA et. al, 2007)

O final da década de 1980 foi que marcou o ressurgimento da área de **redes neurais** artificiais (RNAs), também conhecidas como conexionismo ou sistemas de processamento paralelo e distribuído, com estruturas desenhadas de acordo com a aplicabilidade, tais como: Perceptron, Adaline (ou Redes Lineares), Perceptron Multicamadas, Redes BAM (Memória Bidirecional Associativa) e ART (Adaptive Resonance Theory), Probabilística, Rede de Hopfield e Rede de Kohonem. Os tipos de redes serão tratados em detalhes no capítulo 4.3.

Essa forma de computação não algorítmica é caracterizada por sistemas que, em algum nível, relembram a estrutura do cérebro humano. Por não ser baseada em regras, a computação neural se constitui em uma alternativa à computação algorítmica convencional (BRAGA et. al.; 2007).

O trabalho de McCulloch e Pitts (1943) consistia em uma analogia entre células nervosas vivas em um processo eletrônico binário. Atualmente, encontramos modelos de redes artificiais bem diferentes e mais complexos que aquele apresentado por eles. Entre os mais populares, podemos citar: Perceptron, Adaline e Madaline, Backpropagation, Rede de Hopfield e Mapas de Kohonon (AGUIAR et al., 2007).

Atualmente, os métodos quantitativos têm se tornado uma importante ferramenta em decisões e investimentos dentro do mercado financeiro. As Redes Neurais (ANN – Artificial Neural Networks) são estruturas flexíveis que podem ser aplicadas para uma vasta extensão de problemas de previsão e com um alto grau de acurácia. Entretanto, as Redes Neurais necessitam de uma grande quantidade de dados históricos para alcance do maior nível de acurácia dos resultados obtidos, porém, tem como principal vantagem a capacidade de modelagem de sistemas não-lineares. (KHASHEI et al., 2008).

As **Redes Neurais** são sistemas computacionais contendo muitas unidades não lineares simples ou nós interconectados por links e será abordado em maior detalhe nos capítulos seguintes, sendo o **escopo principal deste trabalho**, com o objetivo de verificação da efetiva aplicação desta ferramenta dentro do campo de previsão de demanda para o segmento industrial. Serão vistos em maiores detalhes a construção das redes e os modelos existentes para diversos campos de atividades.

Em situações reais e especificamente dentro do mercado financeiro, onde o ambiente é cheio de incertezas, as mudanças ocorrem rapidamente, e o futuro deve ser regularmente previsto de tal forma a usar o limite de dados que possa ser avaliado no curto espaço de tempo.

O chamado Modelo de Lógica Fuzzy surgiu para ajudar o planejador a trabalhar eficientemente com dados incompletos, porém segundo Khashei et al. (2008), ele nem sempre tem um desempenho satisfatório.

Dessa forma, como as Redes Neurais têm sido aplicadas para análises de dados de séries de tempo e ainda necessitam de melhorias, a utilização de Lógica Fuzzy tem sido eficientemente aplicada nestes modelos (KUO e XUE, 1999).

As análises de séries de tempo Fuzzy têm sido introduzidas pelas chamadas técnicas de modelagem Fuzzy, onde os padrões característicos são os de tendência, sazonalidade e comportamentos cíclicos (CHANG, 1997)

Segundo Kuo e Xue (1999), o sistema de previsão proposto consiste em quatro partes:

1. Coleta de dados;
2. Modelo padrão geral;
3. Modelo único padrão;
4. Integração da decisão;



Para Kuo e Xue (1999), o resultado do modelo avaliado mostra que o sistema proposto gera uma maior acurácia do que o método estatístico convencional e único de Redes Neurais Artificiais. O padrão geral das vendas é previsto pelas Redes Neurais Artificiais enquanto que a Lógica Fuzzy considera os efeitos nas vendas caso uma promoção seja conduzida, e, finalmente, as decisões destas duas redes e o efeito do tempo são integradas através de outra rede neural.

O Modelo Fuzzy é aplicado para unir as decisões de diferentes variáveis, e requer o conhecimento adquirido pela experiência, entretanto, ele não é muito objetivo, pois não é simples associar experiência adquirida com um vasto conhecimento da sistemática.

Na arquitetura Fuzzy existem as variáveis de precondição e consequência, sendo que o primeiro representa o fator efetivo, enquanto as vendas representam a variável consequência. Os dados são obtidos através do método Delphi, e depois deste processo os dados coletados podem ser aplicados para treinar a proposta de Rede Neural Fuzzy (KUO e XUE, 1999).

Os modelos de séries de tempo Fuzzy evoluíram de domínio independente para domínios específicos. Pode-se usar também a integração chamada de modelo Heurístico, com objetivo de melhorar os resultados da previsão (HUARNG, 2001).

Segundo Huarng (2001), o modelo Heurístico tem sido amplamente usado em estudos de inteligência artificial e representa diferentes significados. Na área técnica é usualmente considerado regra e é usado para alcançar soluções satisfatórias em problemas de domínio específico e nas áreas estratégicas é usado como guia de pesquisa.

Os modelos de Lógica Fuzzy são modelos de operações complexas que requerem inúmeros cálculos, sendo que no caso do modelo Heurístico, sua implementação tem uma maior aderência, pois melhor reflete as flutuações nas séries de tempo Fuzzy, razão pela qual é mais fácil de implementar, melhorando o resultado final (HUARNG, 2001).

### **3.3. Modelos de Julgamento (Qualitativos)**

As vantagens observadas no Modelo Qualitativo é que o profissional responsável pela previsão incorpora a ele seu domínio de conhecimento, que pode vir de várias fontes como a experiência com produto similar, informações de vendas e pesquisa com clientes, além de não ser necessário um conhecimento estatístico ou histórico de dados (MARIEN, 2001).

Esses modelos são usados quando não há dados históricos, como no caso de novos produtos; não são aplicáveis por um longo período (moda) e atendem mercados altamente voláteis. Entre os modelos Qualitativos, os mais comuns são:

- ✓ Analog (Previsão por analogia de produtos)
- ✓ Delphi (Grupo de especialistas)
- ✓ Diffusion (Dispersão – Planejadores seguem o ciclo de vida do produto para previsão)
- ✓ PERT (Performance Evaluation Review Technique)
- ✓ Survey (Pesquisa)
- ✓ Scenario (Previsão baseado em diferentes cenários)

O escopo deste trabalho está direcionado para as técnicas quantitativas de previsão de séries de tempo e, portanto, o modelo Qualitativo será apenas citado como um dos modelos observados e disponíveis.

### **3.4 Modelos estratificados**

A partir dos modelos de previsão, vários outros estudos foram surgindo com base nos inicialmente propostos, e chamados de modelos estratificados, derivando novas técnicas de previsão, para facilitar ou melhorar cada vez mais a acurácia dos resultados.

Vários pesquisadores propuseram métodos subjacentes aos modelos inicialmente propostos, tais como: Método de Holt e método Theta, derivados do Alisamento ou Suavização Exponencial Simples, método de Holt e Winters que derivaram o equivalente ao modelo ARIMA e os métodos derivados de si próprios para finalidades específicas, como ARARMA, modelo vetor VARIMA, modelos ARFIMA para integração fracionária, métodos de decomposição sazonal X-11 e versões mais recentes como X-12-ARIMA e suas variantes (GOOIJER e HYNDMAN, 2006).

O Quadro 02 adaptada do artigo “25 Years of Time Series Forecasting” (Gooijer e Hyndman, 2006) no International Institute of Forecasters (IIF) cita os principais autores e os estudos desenvolvidos para análises e previsões de séries de tempo, e sua influencia na literatura

e desenvolvimento das metodologias aplicadas, e que são descritas brevemente nos parágrafos seguintes.

O estudo das primeiras séries de tempo e seu postulado através de um processo estocástico foi desenvolvido por G.U Yule por volta de 1910 (apud Gooijer e Hyndman, 2006), em conjunto com Galton e Person, através do livro “Uma Introdução a Teoria de Estatística”, dividido em três partes, a teoria dos atributos, a teoria das variáveis e a teoria de amostragem.

Segundo Burgess, o tratamento cuidadoso e detalhado de Yule sobre o assunto foi um fator importante no uso crescente dos mais avançados métodos estatísticos em vários campos de atuação e estudo (GOOIJER e HYNDMAN, 2006).

Os estudos de Yule, foram iniciados em 1927 com auto-correlações parciais para modelos auto-regressivos, e Slutsky que em 1930 introduz mudanças nos modelos de médias e inicia estudos de como estes modelos poderiam se ajustar em séries cíclicas, e posteriormente seguidas por Walker durante toda a década de 30 (BELL e HILLMER, 1984).

O professor Tong (1983) estuda os modelos de limites de ciclos auto-regressivos e dados cíclicos. Durante a década de 90 surgem os modelos SETAR (Self-exciting Threshold Autoregressive) ou Auto-regressivo com Limiar Auto-excitado com a proposta de modelagem dos rateios de taxas, limitando-o a uma única variável decisória.

Brown em 1959, apud Gooijer e Hyndman (2006), desenvolve estudos sobre as técnicas de Alisamento ou Suavização Exponencial Simples que são adequadas para estimar o valor de um único coeficiente em processos localmente constantes. Tal técnica consiste em calcular um segundo valor exponencialmente alisado.

O desenvolvimento do modelo de Suavização Exponencial partiu do trabalho de Robert Brown (apud Gooijer e Hyndman, 2006), que foi nomeado em 1944 para o regimento anti-submarino com o intuito de desenvolver um modelo para informação de controle de fogo na localização de submarinos.

Quadro 02 – Relação de autores e estudos sobre técnicas de previsão

ANO	Postulado de Séries de Tempo	Auto regressão (AR) e Média Móvel (AM)	Alisamento Exponencial	Modelo Arima e Derivações (Arama, Varma, Arfima)	Redes Neurais
1927	Yule				
1930	Volterra	Slutsky   Walker			
		Yaglom e Yule			
1941	Kolmogorov				
1957			HOLT	Quenouille	
1958	Wiener				
1959			Brown		
1960	Kalman		Winters   Muth		
1963			Brown		
1965	Schweppe				
1969	Bates e Granger		Pegels		
1970				Box e Jenkins	
1971				Zellner	
1972	Croston				
1974	Newbold e Granger				
1978	Koehler e Basset				
1979					
1980				Granger e Joyeux	
1982	Shumway e Stoffer	Engle	Roberts	Roberts   Cholette   Parzen	
1983	Winker e Makridakis	Tong   Newbold		Abraham e Ledolter   Koreisha	
1984			Abraham e Ledolter	Hill e Fildes   Riise e Tjostheim	
			McKenzie	Edlund	
1985			Snyder   Gardner	Meade e Smith   Kling e Bessler	
1986			McKenzie	Litterman   Cholette e Lamy	
	Poskitt e Tremayne		Johnston e Harrison	Lutkepohl	
1987		Pemberton		Poulos, Kvanli e Pavur   Gupta	
1988			Gardner e Mckenzie	Chatfield   Ashley	Adya e Collopy
1989		Al Qassem e Lane	Bartolomei e Sweet	Landsman e Damodaran   Texter e Ord	
			Pfeffermann e Allon	Ledolter   Hafer e Sheehan	
1990			Archibald		
			Carreno e Madinaveitia	Funke	
1991		Hastie e Tibshirani	Makridakis   Hibon	Geriner e Ord   Guerreiro   De Gooijer	
1992		Bollerslev et al.	Collopy e Armstrong		
1993	Granger e Terasvirta	Chen e Tsay	Gardner	De Alba   Hotta	Chatfield
1994			Rosas e Guerreiro	Newbold et al.   Liu, Gerlow e Irwin	Gorr
				Box et al.	Hill et al.
1995	Brannäs		Satchell e Timmermann	Simkins	Callen et al.
1996	Johnston e Boylan		Tashman e Kruk	West	Church e Curram
1997		Clements e Smith	Ord et al.	Del Moral e Valderrama	Swanson e White
1998		Enders e Falk	Lawton	Dhrymes e Thomakos	Zhang et al.
					Brooks
1999			Williams e Miller	Bhansali   Meade	
2000	Grunwald et al.	Cai et al.	Assimakopoulos e Nikopoulos	Ariño e Franses	Darbellay e Slama
		Sarantis	Koehler et al.   Masa		Hippert
2001			Chatfield et al.		Pedreira e Souza
2002	Diggle et al.		Hyndman et al.		
			Koehler e Snyder		
2003			Archibald e Koehler	Kim   Kang	Olson e Mossman
2004		De Gooijer e Vidiella			Heravi et al.
2005		Fok et al.   Harvill e Ray		Hansson et al.	Ghiassi et al.
				Wieringa e Horváth	Espinola e Plazas

Fonte: Adaptação de Gooijer e Hyndman (2006)

Durante a década de 50, o autor estendeu seu trabalho para dados discretos e desenvolveu métodos para tendência e sazonalidade (GARDNER, 2006).

Entre 1957 e 1960, Holt e Winters descrevem as técnicas de suavização exponencial com até quatro fatores: nível, tendência linear, fator sazonal e um elemento residual não previsível, também chamado de erro aleatório. Na estimativa desses fatores, usa-se o método de ajustamento exponencial, também chamado de “suavização exponencial” (GARDNER, 2006).

Pegels em 1969, apud Gooijer e Hyndman (2006) fornece uma simples, mas útil classificação de padrões de tendência e sazonalidade na dependência de que elas sejam aditivas (lineares) ou multiplicativas (não-lineares).

Snyder (1985), por sua vez, mostra que a Suavização Exponencial poderia ser considerada como decomposição de um modelo de inovação com um recurso único de erro e Gardner (1988) inclui uma classificação de tendência reduzida no modelo aplicado.

Bartolomei e Sweet (1989) e Makridakis e Hibon (1991), entre outros citados na tabela, fazem novas propostas de inicialização e estimação estudando as propriedades empíricas do método de suavização exponencial.

Box e Jenkins (1970), apud Gooijer e Hyndman (2006), através de estudos e com a publicação do livro “Time Series Analysis: Forecast and Control”, integraram o conceito de Auto-regressão e Média Móvel.

O desenvolvimento e publicação deste estudo foram de larga importância, e representou uma radical partida na metodologia de previsão de séries de tempo (NEWBOLD, 1975).

Parzen (1982), a partir da idéia de transformar uma série de tempo com filtro auto-regressivo de memória longa para filtro de memória curta, através do estudo de um modelo ARIMA Univariado, introduz o conceito do modelo ARARMA.

Tal metodologia é estudada por outros pesquisadores, como Meade e Smith (1985) que comparam o desempenho da previsão e aplicabilidade do modelo ARARMA automatizado e não automatizado.

Vetores Auto-regressivos (VAR's) constituem um caso especial da classe mais geral do modelo VARMA, um modelo que apresenta uma aproximação muito irrestrita (flexível) para a forma reduzida da larga variedade de modelos econométricos dinâmicos (GOOIJER e HYNDMAN, 2006).

Funke (1990) apresentou cinco diferentes especificações de VAR e comparou o desempenho da previsão, usando séries de produção industrial

Os Modelos Estruturais Não Gaussiano apresentados por Smith (1979) são aplicados para modelos fixos de previsões de séries de tempo de proporções.

A classe de modelos ARCH (Autoregressive Conditional Heteroscedastic), já comentada anteriormente, foi introduzida por Engle (1982) que descreve a mudança dinâmica numa variância condicional como uma função determinística do passado. O modelo derivado dele e chamado de GARCH (Autoregressive Conditional Heteroscedastic Generalized) tem sido, por sua extensão e generalidade, muito pesquisada ao longo dos últimos anos, como citado por Chou et. al. (1992), Bollerslev (1994), Sabatine e Linton (1998), entre outros, tendo como principal característica permitir dependências adicionais de variância.

Para Gooijer e Hyndman (2006), outra classe particular de modelos espaciais é o DLM (Dynamic Linear Model) ou Modelo Linear Dinâmico que é uma extensão da classe de modelos com estimativa não Baysiana, sendo renomeado como “Modelo Estrutural” (BSM - Basic Structural Model).

Embora os últimos artigos tenham usado o termo “Modelos de Componentes Despercebidos”, os Modelos Estruturais são muito similares ao Método de Alisamento Exponencial, porém, com múltiplos recursos de erros aleatórios. Em particular, o Modelo Estrutural Básico é um modelo mais próximo do método de Holt-Winters para dados sazonais (GOOIJER e HYNDMAN, 2006).

Modelos como FCAR (Functional Coefficient Autoregressive) ou Modelo de Coeficiente Funcional Auto-regressivo e (V)FCAR (que usa os coeficientes univariáveis e multivariáveis) são outros exemplos de modelos derivados.

A característica chave para séries de tempo financeiras com períodos que demonstram volatilidade (alta ou baixa), chamada de agrupamento volátil em condições econométricas e financeiras, é tratada por uma classe de modelo ARCH (Autoregressive Conditional Heteroscedastic) no qual a variância é conhecida no período (t-1) e as previsões são prontamente conhecidas a uma etapa adiante. Um modelo mais cauteloso que o ARCH é o chamado GARCH (Autoregressive Conditional Heteroscedastic Generalized) em que dependências adicionais são permitidas em defasagem de variâncias condicionais (GOOIJER e HYNDMAN, 2006).

As técnicas apresentadas mostram que os modelos qualitativos são baseados na experiência do planejador, através do conhecimento do mercado ou analogia histórica de produto, enquanto que os modelos quantitativos (Séries de Tempo e Modelos Causa e Efeito) são baseados no histórico e comportamento do produto e do mercado para previsão de comportamento futuro.

Segundo Spedding e Chan (2000), as previsões existentes e as técnicas de gerenciamento têm as seguintes limitações:

1. Eles não conseguem lidar com as mudanças dinâmicas e estruturais da série de tempo;
2. Eles falham em caracterizar o problema de inventário com dados limitados historicamente;
3. Eles não relacionam adequadamente questões relacionadas a produtos com ciclo de vida curto, não sazonal e com lead time relativamente longo;

O método de Previsão por Redes Neurais, igualmente apresentadas no Quadro 02 e amplamente estudadas por diversos pesquisadores nos últimos 10 anos, é o objeto de estudo deste trabalho e, portanto será tratado com maiores detalhes ao longo do mesmo.

### **3.5. Desempenho das Técnicas de Modelagem**

Mentzer e Cox (1984) fizeram uma pesquisa sobre a familiaridade, aplicação e desempenho dos inúmeros métodos de previsão de vendas, através de um questionário enviado a mais de 500 empresas nos Estados Unidos.

O resultado desta pesquisa identificou que a maioria dos profissionais relacionados diretamente ao uso das técnicas de previsão de vendas estava mais familiarizada com Análises de Regressão, Suavização Exponencial, Média Móvel, Análise de Linha de Tendência, Decomposição Clássica e Simulação.

Para Makridakis e Hibon (1997), a popularidade da Metodologia de Box-Jenkins para modelos ARIMA era polêmica, e o uso de dados reais mostrou que métodos simples eram igualmente ou mais acurados que Box-Jenkins, quando as comparações de amostras eram feitas.

A pesquisa feita por Mentzer e Cox (1984) cita, porém, que a única técnica com a qual a maioria dos entrevistados estava insatisfeita era Box-Jenkins. Entretanto, não somente a maioria

dos entrevistados não estava familiarizada com esta técnica, como a maioria daqueles que tinham familiaridade com a mesma dizia estar insatisfeito com os resultados de desempenho.

Mentzer e Cox (1984) concluíram que somente 10% dos entrevistados estavam familiarizados e satisfeitos com a técnica de análise de séries de tempo Box-Jenkins.

A mesma pesquisa mostra que as técnicas mais usadas para períodos de tempo abaixo de três meses foram Suavização Exponencial e Média Móvel. Para o caso de intervalos entre três meses e dois anos, as mais usadas eram Regressão e Análises de Linha de Tendência, e para períodos acima de dois anos a técnica mais utilizada, continuava sendo a Regressão.

Atualmente, após vários debates, segundo uma larga maioria de pesquisadores com testes empíricos, o método de Box-Jenkins não é acurado para amostras de previsões de séries de tempo, pelo menos em domínio de negócios e aplicações econômicas onde o nível de aleatoriedade é alto e a estabilidade do padrão ou relacionamentos não pode ser assegurada (MAKRIDAKIS e HIBON, 1997).

A solução de problemas por meio de Redes Neurais Artificiais (RNAs) é bastante atrativa, já que a forma como são representados internamente pela rede e o paralelismo natural inerente à arquitetura das RNAs criam a possibilidade de um desempenho superior ao dos modelos convencionais (BRAGA et al., 2007).

Toda tomada de decisão, entretanto, em qualquer que seja o ambiente de negócios (industrial, financeiro, marketing, etc), requer uma velocidade de resposta muitas vezes não encontrada ou não absorvida nos modelos de previsões convencionais, o que também ocorre na aplicação de Redes Neurais.

Para Khashei et al. (2008), um dos problemas na aplicação de Redes Neurais é a necessidade de se conhecer um grande número de dados históricos para uma maior eficiência nos resultados do cálculo da previsão.

Atualmente, os Modelos de Redes Neurais têm sido extensivamente estudados e utilizados em previsões de séries de tempo e a combinação de Redes Neurais com Fuzzy tem como principal objetivo superar as limitações de cada um deles tratado de forma isolada (KHASHEI et al., 2008).

O Modelo de Rede Neural que reconhece entradas definindo propósitos de saída, não tem, geralmente, a habilidade para ser desenvolvido para uma dada tarefa dentro de um tempo



razoável. Por outro lado, a Modelagem Fuzzy que é aplicada para fundir as decisões de diferentes variáveis requer uma abordagem do aprendizado pela experiência (KUO e XUE, 1998).

Os Modelos de Redes Neurais e Lógica Fuzzy têm sido usados em muitas aplicações, cada um com suas próprias vantagens e desvantagens, entretanto a combinação dos dois tem se tornado uma preocupação relevante de estudos recentes (KUO e XUE, 1998).

Porém, segundo Braga et al (2007), a generalização, que está associada à capacidade de uma Rede Neural aprender por meio de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que, a capacidade das Redes Neurais vai muito, além do que simplesmente mapear relações de entrada e saída.

## 4. DESCRIÇÃO DA TÉCNICA DE REDES NEURAIS

### 4.1. Conceito de Redes Neurais

As Redes Neurais Artificiais são sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não lineares). Tais unidades são dispostas em uma ou mais camadas interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos essas conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pelo modelo e servem para ponderar a entrada recebida por cada neurônio da rede (BRAGA et. al, 2007).

A característica mais relevante do uso das Redes Neurais é a capacidade de aprendizado por meio de exemplos, no qual a rede consiste de um processo iterativo de ajuste de parâmetros e está relacionado com a melhoria do desempenho da rede, sendo que o erro deve diminuir na medida em que o aprendizado prossiga.

A Rede Neural possui duas fases de processamento, a de aprendizado e a de utilização ou aplicação e ambas as fases são distintas e ocorrem em momentos diferentes.

Segundo Terasvirta et. al. (2005), construir um modelo de Rede Neural, envolve duas escolhas principais: primeiro, selecionar as variáveis de entrada do modelo e segundo, encontrar o número de pontos ou unidades escondidas neste modelo.

O aprendizado é um processo de ajuste dos pesos das conexões em resposta ao estímulo apresentado à rede neural, ou seja, a rede possui a propriedade de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada. Já o processo de utilização é a maneira pela qual a rede responde a um estímulo de entrada sem que ocorram modificações na sua estrutura (AGUIAR et al., 2007).

Uma Rede Neural é composta por um número de neurônios artificiais organizados em camadas. A primeira camada chamada de camada de entrada serve para a entrada dos dados e não para qualquer tipo de processamento.

As Entradas (Inputs) dos ambientes são os dados que entram na primeira camada e as Saídas (outputs) da rede, são declaradas no último nó. Uma carga ou forte conexão é associada com cada link e uma rede é descoberta pela modificação destes pesos, modificando assim a rede

pelos mapas de inputs para outputs. A Figura 06 demonstra uma rede com 4 entradas (inputs), 3 unidades na camada intermediária escondida e uma unidade na camada de saída (output). (CHAKRABORTY et al., 1992).

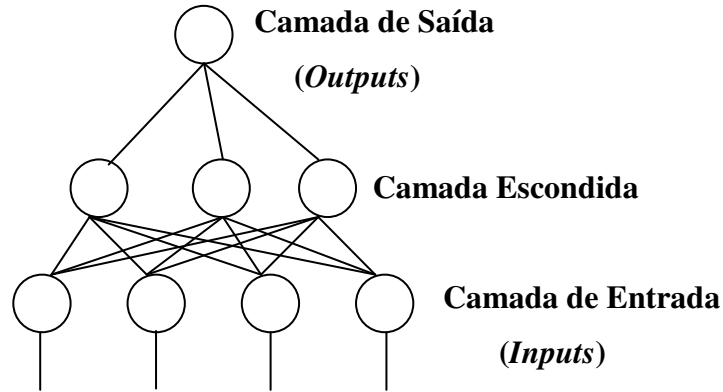


Figura 06 – Rede de alimentação neural com uma camada escondida  
Fonte : Chakraborty et al. (1992).

Segundo Khashei et al. (2007), a relação entre as chamadas saídas (outputs -  $y_t$ ) e as entradas (inputs -  $y_{t-1}, \dots, y_{t-p}$ ) tem a seguinte representação matemática:

$$y_t = w_0 + \sum_{(j=1 \text{ a } q)} w_j \cdot g \left( w_{0,j} + \sum_{(j=1 \text{ a } q)} w_{i,j} \cdot y_{t-1} \right) + \varepsilon_t, \quad (2)$$

Onde  $w_{i,j}$  ( $i = 0, 1, 2, \dots, p$ ,  $j = 1, 2, 3, \dots, q$ ) e  $w_j$  ( $j = 0, 1, 2, \dots, q$ ) são modelos de parâmetros freqüentemente chamados de conexão de importância;  $p$  é o número de nós de entrada e  $q$  é o número de nós escondidos. A função logística é freqüentemente usada como:

$$\text{Sig}(x) = 1 / (1 + \exp(-x))$$

Portanto, o modelo de Rede Neural de (2), mapeando um desempenho funcional não-linear de observações do passado para o futuro, vale:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, \mathbf{w}) + \varepsilon_t \quad (3)$$

Onde,  $w$  é um vetor de valores de todos os parâmetros que representa as chamadas conexões de importância e  $f(\cdot)$  é uma função determinada pela estrutura de rede.

Segundo Wray et al. (1994), a análise de Redes Neurais tem três vantagens primárias sobre análise de regressão:

1. O desenvolvimento de Redes Neurais não necessita de conhecimento das relações fundamentais entre as variáveis de entrada (inputs) e saídas (outputs), sendo ambas lineares e não lineares, desde que elas estejam embutidas nos

dados. Estas relações complexas são descobertas e automaticamente assimiladas dentro das conexões entre os nós da rede.

2. A habilidade associativa das Redes Neurais faz com que ela seja mais robusta em situações onde existem perdas ou incertezas nos dados, desde que o conhecimento das relações entre as variáveis seja distribuído através de uma numerosa rede de conexões. As Regressões não toleram perda de dados e não trabalham bem com dados não acurados.
3. O desempenho das Redes Neurais não é prejudicado por problemas de multicolinearidade. Em situações onde as condições não oferecem padrão, ocorrem violações das suposições, existem pontos de alta influência e transformações, mas ainda assim, elas podem ser trabalhadas pelos modelos de Redes Neurais.

Como já mencionado e segundo Wray et al. (1994), existem duas fases principais na análise de Redes Neurais: “Aprendizagem” e “Prognóstico”. Durante a fase chamada, de aprendizado na rede, ocorre o ajuste do peso entre seus nós. Os dados de entrada devem ser mostrados várias vezes para a rede de trabalho. Na fase de prognóstico, existem duas medidas separadas, a satisfação do cliente e a confiança do cliente em seus agentes, e a diferença entre o nível de prognóstico de satisfação e o nível atual observado, sendo calculada para todos os pontos de dados do conjunto analisado.

Existe uma infinidade de caminhos para construir uma rede de trabalho neural. Neurodinâmica e Arquitetura são dois termos usados para descrever o caminho no qual a rede neural é organizada. A combinação de neurodinâmica e arquitetura definem o paradigma da rede neural. Neurodinâmica descreve a propriedade de um neurônio individual, tal como ele transfere função e como as entradas são combinadas. A arquitetura da rede define sua estrutura, incluindo o número de neurônios em cada camada e o número de tipo de conexões (KAASTRA e BOYD, 1996).

Na teoria, a rede neural com uma camada escondida e com um número suficiente de Neurônios escondidos atende a qualquer função continua. Na prática, redes neurais com um e ocasionalmente duas camadas são largamente usadas e tem um rendimento muito bom (KAASTRA e BOYD, 1996).

A estrutura de uma Rede Neural depende de vários fatores como a complexidade do problema, dimensionamento e a representatividade dos dados, e o número de camadas está

relacionado com a separação linear da estrutura, de tal forma que problemas de maior complexidade dependem da composição da sua estrutura em camadas sucessivas.

Para as redes de uma única camada, o erro é o resultado da diferença entre a saída desejada e a saída da rede, porém, para redes de múltiplas camadas, esse procedimento pode ser aplicado apenas para a camada de saída, e assim sendo, o erro das camadas intermediárias passa a ser um problema de difícil análise.

A classificação fundamental das estruturas neurais pode ser feita em relação ao método de propagação da informação recebida, conforme figura 07. A distinção está no tipo de alimentação apresentada, ou seja, propagação para frente (Feedforward) e redes realimentadas (Recurrent).

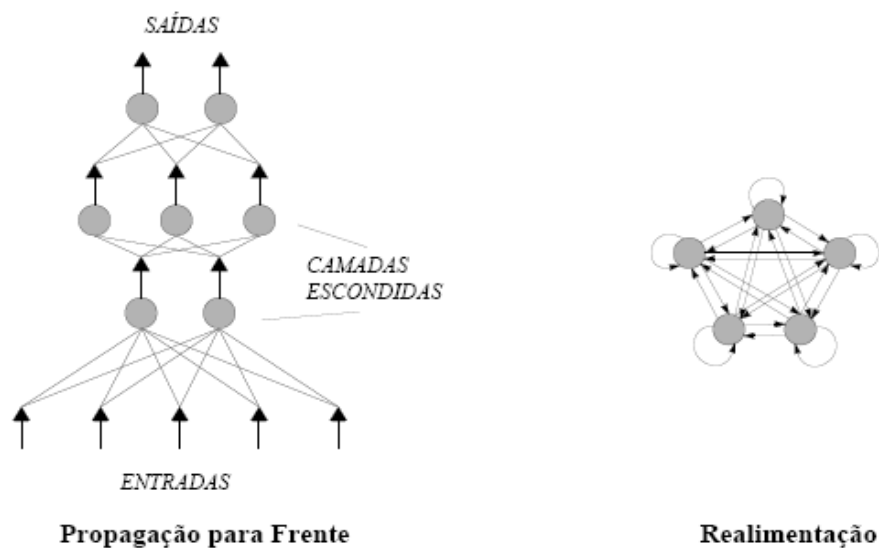


Figura 07 - Tipo de Alimentação de Redes Neurais

A propriedade mais importante das Redes Neurais é a habilidade de aprender e, portanto melhorar seu desempenho. O aprendizado é feito através de um ajuste aplicado a seus pesos e ocorre quando a rede atinge uma solução generalizada para uma classe de problemas.

O aprendizado (ou treinamento) de uma rede consiste no ajuste dos seus parâmetros, de forma que esta produza o resultado esperado, dada a apresentação de um conjunto de padrões específicos. Os padrões de treinamento contêm as informações que se deseja que uma rede aprenda. Os parâmetros a ajustar são os pesos das conexões que interligam os neurônios.

As Redes Neurais caracterizam-se pela utilização de diferentes técnicas de treinamento. Esse treinamento pode ser classificado como Supervisionado ou Não Supervisionado (AGUIAR et al., 2007).

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem através de exemplos.

O Aprendizado Supervisionado implica, necessariamente, a existência de um supervisor ou professor externo, o qual é o responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada pela mesma, comparando com a saída desejada.




Figura 08 - Modelo de aprendizado supervisionado

Segundo Braga et al. (2007) o Aprendizado Supervisionado pode ser implementado basicamente de duas formas: off-line e on-line. Para treinamento off-line, os dados do conjunto de treinamento não mudam, e uma vez obtida uma solução para a rede, esta deve permanecer fixa. Caso novos dados sejam adicionados, um novo treinamento, envolvendo também os dados anteriores, deve ser realizado para se evitar interferência no treinamento anterior. Por sua vez, no aprendizado on-line o conjunto de dados muda continuamente, e a rede deve estar em um contínuo processo de adaptação.

Quando a única informação disponível são os valores de entrada, a tarefa de aprendizagem é descobrir correlações entre os exemplos de treino, portanto não há um professor ou supervisor externo para acompanhar o processo de aprendizado. Neste caso o processo passa a ser classificado como Não Supervisionado.




Figura 09 - Modelo de aprendizado não supervisionado

Durante o processo de aprendizado os padrões de entrada são apresentados continuamente à rede, e a existência de regularidades nesses dados faz com que o aprendizado seja possível. Regularidade e redundância nas entradas são características essenciais para haver aprendizado não supervisionado (BRAGA et al., 2007).

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema. Todo conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. Existem diversas técnicas de aprendizado das quais as mais utilizadas são (SIMPSON, 1990):

Adaptação dos Pesos ou Reforço, o aprendizado supervisionado onde os pesos são recompensados quando o sistema executa ações apropriadas e punidos o caso contrário;

- Regra de Hebb, o aprendizado onde o ajuste dos pesos das conexões é realizado em função da relação de valores dos dois neurônios que ela conecta, podendo ser aplicado tanto ao aprendizado supervisionado quanto ao aprendizado não-supervisionado;
- Regra Delta, uma regra de adaptação de pesos onde a rede calcula na saída uma função  $y_i$ , numa aprendizagem supervisionada onde se conhece o valor desejado de  $y$  que ela deve calcular. O objetivo é minimizar o erro entre os valores calculados pela rede.
- Competitiva, onde um único neurônio pode ser ativo ao mesmo tempo, tal que todos os outros neurônios tenham uma ativação igual a zero e somente o vencedor emite um sinal de ativação igual a um.

Para Braga et al. (2007) as Redes Neurais podem ser aplicadas a diversos tipos de tarefas como, classificação, categorização (clustering), aproximação, otimização e previsão e

dentro de inúmeras áreas dos mais diversos setores tais como financeiro, elétrico, automação, controle, industrial, comércio eletrônico, telecomunicações, etc.

Neste trabalho estaremos aplicando Redes Neurais para problemas de previsão do setor industrial, na qual se caracteriza tipicamente pela estimativa de situações futuras com base nos estados atuais e anteriores do sistema. A solução envolve um aprendizado supervisionado em que estados passados, atuais e futuros serão apresentados às entradas e saídas da rede durante o treinamento. A Rede deverá então, aprender a estimar situações futuras com base nos estados anteriores do sistema.

#### 4.2. Tipos de Redes Neurais

O primeiro modelo de neurônio artificial proposto por McCulloch e Pitts (1943) era uma simplificação do que se sabia na época a respeito do neurônio biológico, onde o disparo do neurônio se fazia em função da soma dos impulsos que ele recebe até ultrapassar o limiar de excitação (threshold), conforme figura 09.

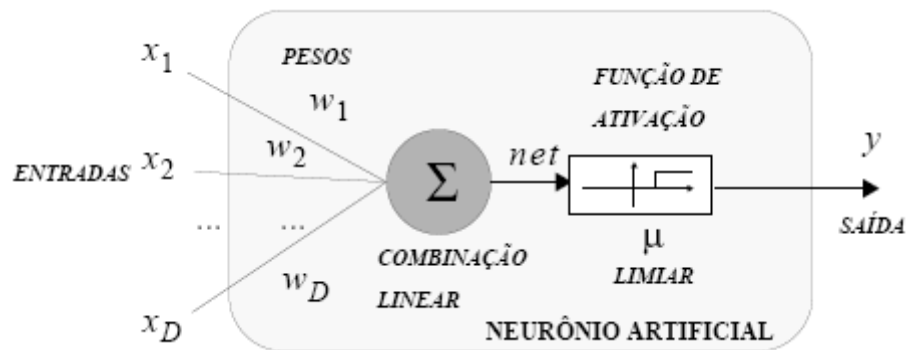


Figura 10: Modelo de neurônio de McCulloch e Pitts (1943)

Sendo:  $x_i$  = Entradas,  
 $w_i$  = Peso para a Entrada Especificada e  
 $\gamma$  = Saída da Rede



Tal comportamento era por sua vez representado no modelo artificial por um mecanismo simples, que faz a soma dos valores  $x_i w_i$  recebidos pelo neurônio, (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 1 ou 0), comparando a soma obtida ao limiar ou threshold do neurônio. No modelo de McCulloch e Pitts (1943), a ativação do neurônio é obtida através da aplicação de uma função de ativação, que ativa ou não a saída, dependendo do valor da soma das suas entradas.

A função de ativação é, portanto a responsável por gerar a saída  $\gamma$  do neurônio a partir dos vetores de peso  $W = (\omega_1, \omega_2, \omega_3 \dots \omega_n)^t$  e de entradas  $\chi = (\chi_1, \chi_2, \dots \chi_n)^t$ . A Figura 11 abaixo mostra exemplos de funções de ativação mais comuns, como funções lineares ou radiais:

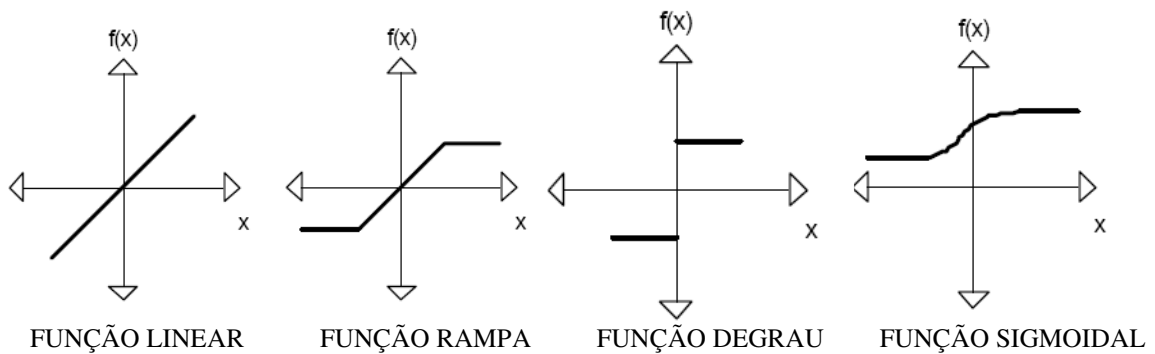


Figura 11: Exemplos de Função de Ativação

#### 4.2.1 PERCEPTRON (Feedforward)

O Perceptron foi desenvolvido por Rosenblatt (1958) e é caracterizado por uma rede com uma única camada cujos pesos e erros podem ser treinados para se obter um vetor esperado, dado um vetor de entrada  $(p(1); p(2); \dots p(R))$ , onde  $R$  é o número de entradas.

Este tipo de rede, caracterizado por um modelo de aprendizagem supervisionada com redes de propagação para frente eram chamados de Perceptron, e o caso mais simples era o Perceptron com uma única camada.




Figura 12 - Modelo Perceptron

Cada entrada é ponderada com peso  $w_{ij}$ , e a soma das entradas ponderadas é a entrada da função de transferência cuja saída é 0 ou 1.

A regra de aprendizado do perceptron usa a diferença entre a resposta da rede ( $a$ ) e o vetor de saída desejado ( $t$ ), sendo o vetor  $t$ , binário.

$$e = t - a \quad (4)$$

Sendo:  $a$  = Resposta da Rede

$t$  = Vetor de Saída

A cada varredura de treinamento, o perceptron tem melhor chance de calcular corretamente a saída  $a = t$ , dado vetor de entrada  $P$ . Os pesos iniciais são aleatórios e as regras e os aprendizados são usados repetidamente através da mudança de pesos até obtenção de um erro aceitável.

O Perceptron é um sistema de uma rede neural simples guiado pela adaptação de pesos, e onde o aprendizado é conseguido de acordo com o treino e sua capacidade de cálculo está limitada a linearidade das classes. Técnicas mais sofisticadas exigem o uso do Perceptron multicamadas.

#### 4.2.2 REDES LINEARES (Feedforward)

Neste tipo de rede também chamado de modelo Adaline (Adaptative Linear Network), os neurônios têm função de transferência linear, possibilitando que a saída seja um número real e não apenas 0 ou 1. Ela é inicializada com pesos aleatórios e a rede calcula os pesos de acordo com os dados de entrada e saída.

A solução é obtida pelo valor do somatório dos erros ao quadrado e a regra de treinamento, é feita pelo cálculo das mudanças dos pesos de uma camada linear que façam decrescer a soma dos quadrados dos erros da camada. Calcula-se repetidamente o erro entre as entradas e saídas até que a soma do quadrado dos erros atinja um valor aceitável.

Tal regra se baseia na magnitude e no sinal do gradiente do erro para obter a direção e o valor do ajuste a ser aplicado ao vetor de pesos.

Este algoritmo, conhecido como regra Delta, deu origem anos mais tarde ao primeiro algoritmo para treinamento de redes Perceptron de múltiplas camadas, o Backpropagation.

O modelo utiliza o erro quadrático como critério de desempenho, a partir de um valor inicial para o vetor de pesos e o objetivo é tal que o vetor de pesos se aproxime gradativamente de um mínimo global, resultante de uma função Gaussiana e com superfície de formato parabólico.

#### 4.2.3 PERCEPTRON MULTI-CAMADAS (Feedforward)

No caso de redes com múltiplas camadas não é possível obter o erro diretamente através da diferença entre a saída desejada e a saída recorrente da rede, pois não existem saídas desejadas definidas para camadas intermediárias. O problema é calcular ou estimar o erro das camadas intermediárias.

Qualquer Perceptron com pelo menos uma camada escondida é um Perceptron Multicamada. Cada neurônio recebe várias entradas da camada anterior e calcula uma combinação linear dessas variáveis.




Figura 13 - Modelo Perceptron Multi Camadas

O algoritmo capaz de treinar as redes perceptron de multicamadas é o algoritmo de retropropagação ou Backpropagation, onde o princípio do seu cálculo é utilizar o gradiente descendente e estimar o erro das camadas intermediárias pela estimativa do resultado encontrado no erro da camada de saída.

O Backpropagation é um tipo de algoritmo supervisionado que utiliza pares de entrada e saída da rede para, por meio de um mecanismo de correção de erros, ajustarem os pesos da rede. O erro da saída da rede é calculado, sendo retroalimentado para as camadas intermediárias, possibilitando o ajuste desses pesos.

As redes multi-camadas têm um potencial computacional muito maior que os perceptrons de uma camada, justamente por conseguirem tratar dados não linearmente separáveis. É o número de camadas da rede que define a potencialidade de processamento da rede.

#### 4.2.4 REDES BAM

As Redes BAM (Memória Bi-Direcional Associativa) são redes hetero-associativa e de conteúdo endereçável, consistindo de duas camadas. Ela usa o fluxo de informação *forward* e *backward* para produzir uma pesquisa associativa em resposta a um estímulo.

A Figura 14 mostra um diagrama simplificado de uma Rede BAM, extraído de Narendra (1990) para uma rede que tem  $n$  unidades na camada  $x$  (entrada) e  $m$  unidades na camada  $y$  (saída). Todas as conexões são bidirecionais, sendo que a informação passa e volta de uma camada para outra, seguindo a seguinte equação na matriz de pesos:

$$W = x_1x_1t + x_2x_2t + \dots x_Lx_Lt \quad (5)$$

Neste caso a matriz de peso é quadrada e simétrica e as camadas operam de modo alternativo.

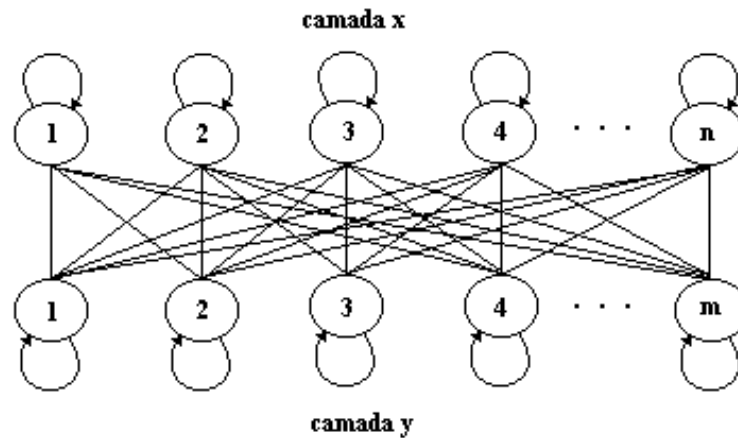


Figura 14: Diagrama Simplificado de uma Rede BAM

Fonte: Narendra (1990)

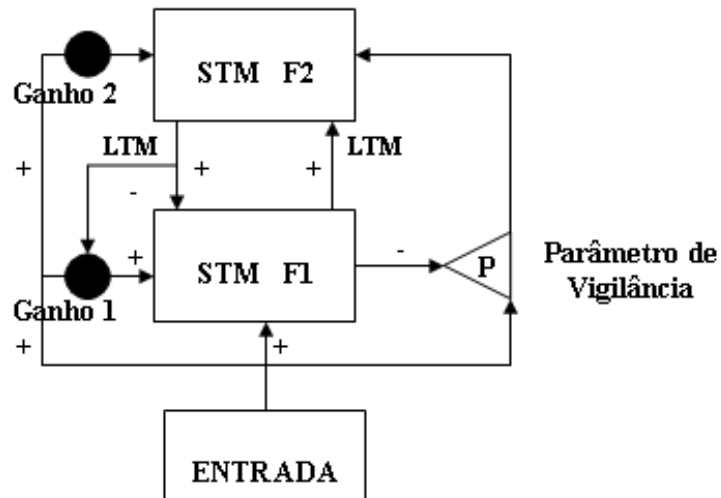
#### 4.2.5 REDES ART

As redes ART (Adaptive Resonance Theory) são redes de arquitetura que aprendem em tempo real os códigos de representação estável em resposta a uma sequência arbitrária de padrões de entrada.

Neste tipo de rede, o aprendizado é não supervisionado e é tratado como uma ação dinâmica e incremental, com objetivo de alcançar novos padrões na entrada.

A Rede ART tem a capacidade de formar representações internas para codificação de suas entradas, através de um conjunto de unidades de saídas, sendo que o usuário controla o grau de similaridade entre os padrões agrupados na mesma unidade de saída. Tal controle permite uma maior segurança em relação às diferenças existentes entre os padrões de entrada e com isso gerar melhores grupos em resposta a esse controle.

A Figura 15 mostra um modelo típico de Rede ART (Adaptive Resonance Theory), extraído do artigo de Carpenter e Grossberg (1990).



**STM – Memória de Longo Termo**  
**LTM – Memória de Curto Termo**

Figura 15 - Modelo típico de Rede ART

Fonte: Carpenter e Grossberg (1990)

#### 4.2.6 REDE PROBABILÍSTICA

Esta é uma rede usada para classificação, e quando uma entrada é apresentada, a primeira camada calcula as distâncias entre os vetores de entrada e os esperados e obtém um vetor cujos elementos indicam a distância entre a entrada e o exemplar usado para treinamento.

A segunda camada soma essas contribuições para cada classe de entradas e obtém um vetor de probabilidades.

Uma função de transferência na saída da camada 2 exibe o máximo dessas probabilidades e assume 1 para essa classe e 0 para as demais.

#### 4.2.7 REDE DE HOPFIELD (Recurrent)

O modelo de Hopfield é uma rede com realimentação, onde os valores de entrada são realimentados pelo resultado da rede através de um comportamento dinâmico.

Nesse modelo de rede as entradas  $x_j$  e saídas  $x_i$  do neurônio  $i$  são valores binários, onde o valor 1 é configurado para estado ativo e o valor -1 ao estado inativo. O neurônio é do modelo de McCulloch-Pitts (1943).

A atualização da rede pode ser feita de forma síncrona ou assíncrona, onde a primeira regula a transição de entrada de intervalo de tempo  $(t)$  e  $(t + dt)$ , e a segunda atualiza a rede independente dos outros neurônios, mas com a mesma frequência.

O objetivo desse modelo de rede é memorizar  $n$  padrões  $x(p)$  de um conjunto de padrões estabelecidos de  $x$ , para responder na saída, o estado  $x(t) = x(p)$  apresentado inicialmente à rede, de forma a imitar a própria capacidade de memória associativa do ser humano.




Figura 16 - Arquitetura da Rede de Hopfield

Na rede de Hopfield os pesos entre os neurônios são simétricos e define-se um peso nulo da realimentação do próprio neurônio.

A rede de Hopfield tem a capacidade de associar informações incompletas e transformá-la em resultado concreto através do próprio modelo condicionado. Assim conseguir, por exemplo, memorizar imagens através de posições binárias, e por recuperação de uma imagem corrompida, pela qual foi apresentado como estímulo inicial, chegar ao estado final da imagem memorizada como a mais parecida.

#### 4.2.8 REDE DE KOHONEM (Recurrent)

O Modelo de Kohonem é uma rede neural não supervisionada que usa neurônios adaptativos para receber sinais de um evento espacial, consistindo em medidas ou dados, como freqüência ou situação. Tal modelo tem os neurônios da camada de saída disputando entre si a representação da informação apresentada aos neurônios de entrada.

O sistema funciona com os pesos iniciais contendo valores aleatórios baixos e um sinal de entrada (qualquer que seja a informação) é provido à rede sem especificação de saída desejada conforme Figura 17.




Figura 17 - Arquitetura da Rede de Kohonen

Conforme o sinal de entrada  $x$ , um neurônio de saída  $y$  deverá responder melhor, sempre que seus pesos forem ajustados para uma melhor resposta ao sinal anterior.

A rede será considerada treinada, depois de todo o conjunto de treinamento tiver sido apresentado à rede e os critérios de treinamento tiverem sido satisfeitos.

Para que o teste seja mais apurado, a rede poderá receber como entrada, além dos pontos anteriormente apresentados, outros que não fizerem parte do conjunto.

O ajuste dos pesos acontece quando o neurônio vencedor (aquele que responde melhor ao estímulo recebido) é descoberto e, portanto reajustado para responder ainda melhor a esses estímulos.



#### 4.2.9 REDE TDNN (Time Delay Neural Network)

Muitos dos problemas reais em qualquer que seja a situação estudada, se depara com a questão do tempo e isso faz deste parâmetro um importante ponto na área de redes neurais. As estruturas computacionais convencionais ainda não são ricas o suficiente para lidar com reconhecimento de padrões que mudam com o tempo, ou padrões dinâmicos, pois, não são capazes de representá-lo de forma adequada (BRAGA et. al, 2007).

As redes Perceptron Multi-Camadas, por exemplo, não possuem estrutura adequada para lidar com padrões dinâmicos, portanto, são necessários alguns ajustes em seu treinamento. Uma maneira de adaptar o treinamento é transformar os dados originalmente dinâmicos em dados estáticos através do uso de janelas de tempo.

As arquiteturas dinâmicas devem possuir memória para que os processamentos realizados em momentos anteriores sejam considerados e existem basicamente duas formas para isso, introduzir atraso de tempo através da técnica TDNN (Time Delay Neural Network) e FIR (Finite Impulse Response) ou utilizar arquiteturas de redes recorrentes como as redes de Elman e redes de Jordan (KOSKIVAARA, 2000).

Redes Neurais com Atraso no Tempo ou TDNN (Time Delay Neural Networks) são do tipo múltiplas camadas cujos neurônios das camadas intermediárias e de saída são replicados ao longo do tempo.

As redes TDNN recebem este nome porque os dados da série temporal passam por atrasos de tempo, de forma que nas entradas dos neurônios seja apresentada uma seqüência de dados correspondente a uma janela de tempo fixo, que se desloca ao longo da série, conforme a Figura 18.




Figura 18 - Janela da série temporal aplicada a entrada de um neurônio.

A topologia da rede TDNN é basicamente a de uma rede Perceptron Multi-Camadas onde a conexão possui uma memória associada ou filtro FIR (Finite Impulse Response), e o treinamento aplicado, criam a cada etapa, uma rede estática equivalente através do desdobramento da rede no tempo. Com a replicação das camadas, o modelo dinâmico de RNA é criado e o algoritmo destinado ao treinamento dessas redes é o Backpropagation.

Nas redes RNN, além da memória externa proporcionada por um delay-line como ocorre nas TDNN, elas apresentam malhas de realimentação das saídas dos neurônios para as entradas de rede, proporcionando uma memória interna. Dependendo do tipo de realimentação, as RNN podem ser denominadas Elman ou Jordan.

#### 4.2.10 REDE DE ELMAN E JORDAN

As RNN tipo Elman são em geral aplicadas em processos de reconhecimento de voz, e as RNN do tipo Jordan são em geral aplicadas no modelamento de robôs articulados.

As Redes de Elman são redes criadas para processamento temporal e possuem um diferencial em relação às redes Perceptron Multicamadas, pois possuem uma camada de contexto além das camadas de entrada, intermediárias e saída convencionais.

A Figura 19 mostra uma rede de Elman e nela é destacado o fluxo de ativação das camadas, sendo que em um determinado tempo  $t$ , o resultado da camada intermediária gerada em  $t-1$  e as unidades de entrada correntes são utilizados como entradas da rede.

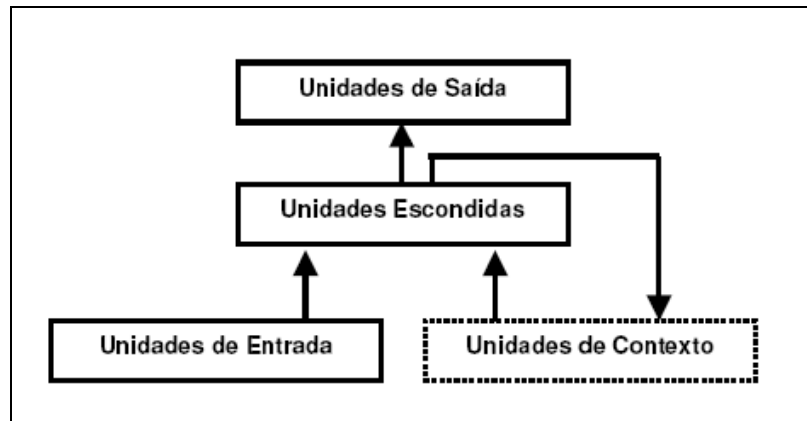


Figura 19 – Ilustração de uma Rede de Elman

A rede de Elman é treinada com algoritmo Backpropagation padrão através da rede para produzir uma saída.

Tudo que foi dito para a Rede de Elman se aplica à rede de Jordan, sendo que a diferença entre elas está no armazenamento dos resultados, onde a primeira armazena os resultados da sua camada intermediária na sua camada de contexto, enquanto que a segunda (Rede de Jordan) armazena os resultados de saída na sua camada intermediária. Enquanto a recorrência da rede de Elman é feita da camada intermediária para a de entrada, a recorrência da rede de Jordan é feita da camada de saída para a de entrada, conforme Figura 20.

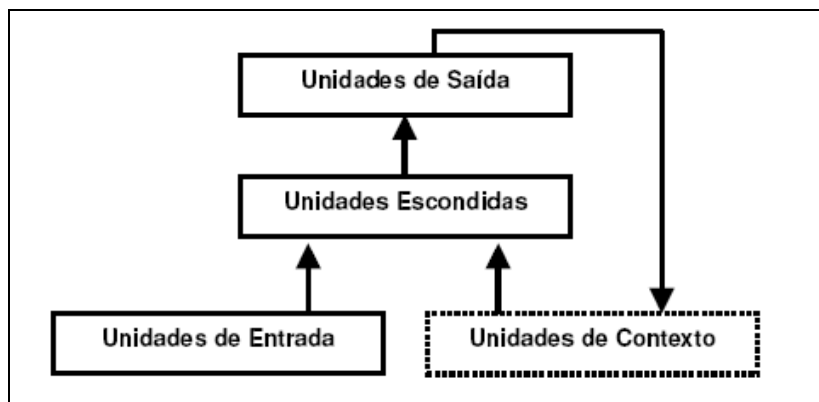


Figura 20 – Ilustração de uma Rede de Jordan

### 4.3. Tipos de Algoritmos

Existem diversos tipos de algoritmos para diversos tipos de redes neurais, em inúmeros setores de aplicação. Neste tópico serão abordados os dois algoritmos de maior aplicação na previsão de séries temporais e cujas estruturas fazem parte do pacote de aplicativos do software (Matlab) que será utilizado na simulação dos dados.

#### 4.3.1 Algoritmo Backpropagation

O algoritmo Backpropagation foi criado pela generalização da regra de aprendizagem de Widrow-Hoff para redes multicamadas e não lineares. As entradas de vetores e os correspondentes vetores alvo são usados para treinar a rede até que se possa aproximar uma função, associando ou classificando vetores de entrada de forma adequada para os resultados específicos. Redes com “bias” de uma camada sigmóide, e uma camada de saída linear, são capazes de aproximar qualquer função com um número finito de descontinuidades (BATTITI, 1992).

O termo Backpropagation refere-se ao modo em que o gradiente é calculado para redes multicamadas e não lineares, e tendem a dar respostas razoáveis quando se apresenta entradas que nunca foram vistas. Normalmente, uma nova entrada conduz a uma saída similar à saída correta, para vetores de entrada usados no treinamento e que sejam similares a nova entrada apresentada.

Uma das limitações do algoritmo Backpropagation é o fato dele requerer pequenas taxas de aprendizagem estável e, portanto torna-se lento para muitos casos de aplicações práticas onde as redes são menores e com menor estabilidade. Para pequenas e médias redes o algoritmo mais usual é o Levenberg-Marquadt (HAGAN et al., 1996).

As redes multicamadas são capazes de realizar praticamente qualquer cálculo linear ou não linear, podendo aproximar qualquer função de forma bem razoável, no entanto, embora a rede treinada pode teoricamente ser capaz de executar corretamente retropropagação e suas variações, ela não podem sempre encontrar uma solução. (HAGAN et al., 1996)

Existem outras variações do algoritmo Backpropagation que muda conforme parametrização do mesmo, e de acordo com o caminho que ele pode ser implementado. Entre eles, podemos citar: Batch Training, Batch Gradient Descent, Batch Gradient Descent with Momentum.

#### 4.3.2 Algoritmo de Levenberg-Marquadt

O modelo de Levenberg-Marquardt é uma técnica de algoritmo iterativa que detecta o mínimo de uma função multivariada que se expressa como a soma dos quadrados de uma função não linear e por isso tornou-se uma técnica padrão para problemas de não linearidade de mínimos quadrados, sendo amplamente aprovada num amplo espectro de aplicações (LOURAKIS, 2005).

Este modelo de rede é caracterizado como sendo um dos métodos mais rápidos para o treinamento de Redes Neurais de tamanho moderado, além disso, é eficaz na minimização de funções com um pequeno número de parâmetros. Todavia, aumentando-se o número de parâmetros, aumenta-se também a complexidade computacional do modelo tornando-se inviável em algumas aplicações. Uma característica importante do Modelo de Levenberg-Marquardt é que o tempo de convergência da rede tende a ser menor quando comparado com outros modelos (ARAUJO e MELO, 2006).

O método de Levenberg-Marquadt é uma aproximação ao método de Newton e uma segunda ordem derivada para uma melhor convergência do comportamento da rede, sendo que este algoritmo consegue extrair o melhor parâmetro de mudança de vetor, e muito utilizado em redes menores. (EFE e KAYNAK, 2002)

### 4.4. Coleta de Dados

Neste trabalho serão analisadas as séries de tempo de dados reais da produção industrial mensal brasileira, de janeiro de 1975 a setembro de 2008.

Os índices foram extraídos do site do IBGE (Instituto Brasileiro de Geografia e Estatística) que divulga índices mensais de produção física desde a década de 1970. A Pesquisa Industrial Mensal de Produção Física (PIM-PF), divulgada pelo IBGE, é a quantidade produzida de um conjunto de produtos selecionados, junto às unidades produtivas das empresas industriais.

Os dados de cada série de tempo referem-se a um tipo de categoria de produção industrial classificado conforme seu segmento de mercado, como segue abaixo:

1. Farmacêutica
2. Extrativa Mineral
3. Indústria de transformação
4. Indústria Geral
5. Indústria Têxtil
6. Bens de Capital
7. Bens Intermediários
8. Bens de Consumo
9. Bens de Consumo Duráveis
10. Bens de Consumo Não Duráveis
11. Indústria de Bebidas

O IBGE faz um levantamento mensal de aproximadamente 830 produtos em 3.700 unidades locais, por intermédio de questionário eletrônico disponível diretamente do seu *site* oficial, e adota na seleção de atividades a Classificação Nacional de Atividades Econômicas (CNAE) e, na seleção de produtos, a Lista de Produtos Industriais (PRODLIST), derivada da Nomenclatura Comum do Mercosul (NCM) e ordenada por classe do CNAE.

Para o Brasil, além dos resultados para as indústrias extrativas minerais e de transformação, a PIM-PF gera resultados para vinte e seis segmentos da indústria de transformação e leva em conta a participação de atividades e produtos na estrutura do Valor da Transformação Industrial (VTI).

As séries históricas podem ser consultadas diretamente no SIDRA (Sistema IBGE de Recuperação Automática), no próprio *site* do IBGE.

Os valores para cada uma das séries são adimensionais e sua ordem de grandeza está calculada proporcionalmente pela média dos valores extraídos do ano de 2002 iguais a 100 (Cem), utilizando como base referencial para cada uma das séries.

A tabela de Séries de Produção por Segmento de Mercado (APÊNDICE 01) mostra os valores mensais de cada uma das séries propostas entre janeiro de 1975 e setembro de 2008.

Os gráficos 01 demonstram o comportamento de cada uma das séries ao longo do período mensal definido, nos quais serão aplicadas as técnicas para cálculo de demanda.

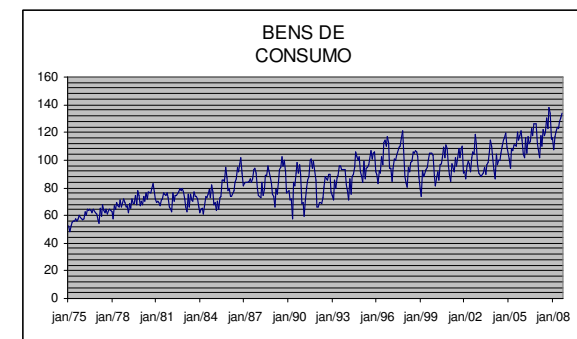


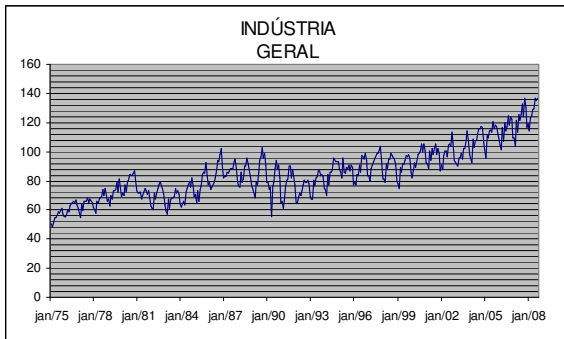





Gráfico 01 – Comportamento das Séries de Tempo da Produção Industrial

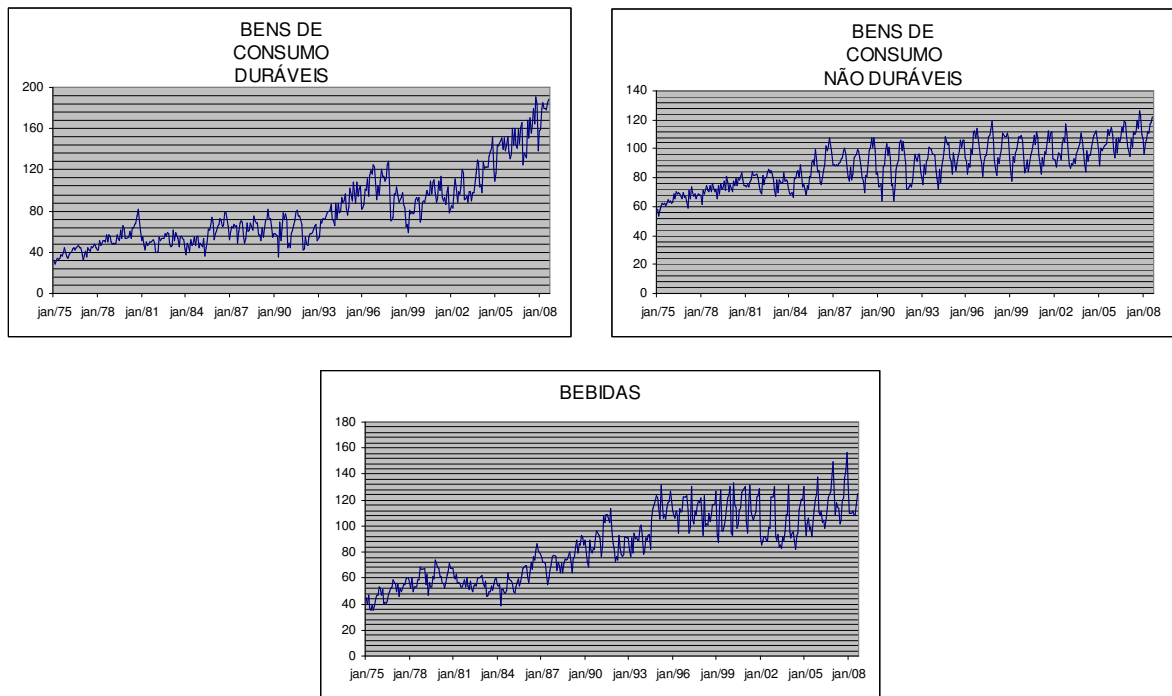


Gráfico 01 (Continuação) – Comportamento das Séries de Tempo da Produção Industrial

#### 4.5. Modelo proposto

Nesta seção será utilizada a técnica de Rede Neural (RN) para se fazer a previsão de demanda dos onze segmentos de mercado, que foram apresentados na seção anterior em séries históricas com dados mensais desde 1975 até 2008, que correspondem a um período de 405 meses.

Para o modelamento de séries temporais são utilizados basicamente dois tipos de redes neurais chamadas de TDNN (Time Delay Neural Network) e RNN (Recurrent Neural Network), já apresentados no decorrer deste capítulo.

Segundo o resultado de alguns trabalhos, como o trabalho de Marques et al. 2005, não há uma diferença muito grande de desempenho em utilizar TDNN e RNN. As redes RNN tendem a serem um pouco melhores, porém são mais difíceis de se implementar e treinar. Como regra prática, é melhor começar aplicando uma TDNN, e somente se o seu desempenho não for aceitável, parte-se a aplicação da RNN.



O tipo de RN utilizado neste trabalho foi uma TDNN formada por Perceptron multi-camadas ou feedforward, cujas entradas são amostras da seqüência temporal dos dados históricos de curto-tempo do tipo delay-line, e a saída é a previsão para o próximo mês, conforme descrito na Figura 21.




Figura 21 - Topologia da uma TDNN com perceptron multi-camadas.

A topologia da RN utilizada consiste em 13 entradas conectadas a uma camada escondida com “N” neurônios, que por sua vez conectam-se a 1 neurônio de saída. Todos os neurônios têm uma entrada conectada a um valor constante chamado de “bias”. A quantidade “N” de neurônios escondidos será estimada a partir de uma análise dos resíduos.

A quantidade de treze entradas foi obtida empiricamente. Percebeu-se que com a utilização de menos entradas, a rede perde eficiência na capacidade de modelar as variações dos dados. Com mais entrada, fica mais difícil o processo de treinamento, que leva sempre a resultados de mínimos locais. Do ponto de vista da aplicação, a utilização de treze entradas engloba um período completo de 12 meses e ainda compara o último mês do período anterior com o período presente, o que é bem apropriado. Por exemplo, o padrão descrito pelos valores do período presente pode dar uma boa idéia dos padrões do período a ser previsto, e a diferença de um mês do período presente e um período anterior pode mostrar uma tendência para os dados a serem previstos.

A função de ativação dos neurônios da camada escondida é do tipo sigmoideal e a do neurônio de saída é linear, dado que a saída da rede deve representar valores contínuos que deverão ser estimados. Portanto não se trata de uma pura identificação de padrões com saídas binárias como: certo ou errado, verdadeiro ou falso, pertence ou não pertence; caso em que a função de ativação da saída também seria do tipo sigmoideal.

O modelo de RN utilizado apresenta uma memória de curto-tempo, que guarda eventos passados relevantes, e um associador, que usa o conteúdo da memória para classificar ou prever novos dados. Um modelo com estas duas características, segundo MOZER<sup>1</sup> apud MAKRIDAKIS et al. (1998), é adequado para processar padrões que variam no tempo.

O software para aplicação do modelo de rede neural utilizado neste trabalho, bem como o algoritmo de simulação inserido no próprio banco de dados deste aplicativo, será todo trabalhado no Matlab.

---

<sup>1</sup> MOZER, M.C. Neural Net Architectures for Temporal Sequence Processing, 1993.

## 5. APLICAÇÃO E ANÁLISE DOS RESULTADOS

### 5.1. Análise Preliminar dos Dados

Uma primeira análise a ser feita numa série temporal é a verificação de sua estacionaridade. Numa série temporal estacionária a média e a variância da variável aleatória é invariante ao longo do tempo. Se as características de um processo estocástico se alteram com o tempo, isto é, se o processo é não-estacionário, será difícil representar a série temporal futura a partir de dados do passado. Por outro lado, se o processo estocástico é fixo no tempo, ou seja, se ele é estacionário, então se podem modelar o processo via uma equação com coeficientes fixos que podem ser estimados a partir de dados passados.

Enquanto é praticamente impossível se obter uma descrição completa de um processo estocástico (isto é, realmente especificar a distribuição de probabilidade que o fundamenta), é possível utilizar a função de auto-correlação para fornecer uma descrição parcial do processo para propósitos de modelagem. A função de auto-correlação nos diz quanta correlação existe (e por implicação quanta interdependência existe) entre pontos de dados vizinhos ou deslocados no tempo por uma porção definida pela variável  $k$ , de uma série temporal  $y_t$ . A função de auto-correlação é definida com respeito ao deslocamento de tempo  $k$  como (PINDYCK e RUBINFELD, 1991):

$$\rho_k = \frac{E[(y_t - \mu_y)(y_{t+k} - \mu_y)]}{\sqrt{E[(y_t - \mu_y)^2] E[(y_{t+k} - \mu_y)^2]}} = \frac{Cov(y_t, y_{t+k})}{\sigma_{y_t} \sigma_{y_{t+k}}} \quad (6)$$

Esta é a representação puramente teórica da função de auto-correlação, onde  $\mu_y$  é a média da série temporal  $y_t$ , e  $\sigma_{y_t}$  é o seu desvio padrão. Contudo, na prática tem-se apenas um número limitado de observações da série temporal, e por isso calcula-se uma estimativa da função de auto-correlação, conforme segue (PINDYCK e RUBINFELD, 1991):

$$\hat{\rho}_k = \frac{\sum_{t=1}^{T-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (7)$$

A partir do cálculo da estimativa da função auto-correlação para todas as séries temporais dos diversos segmentos, verificou-se que todas as séries históricas consideradas neste trabalho são séries temporais não-estacionárias. Uma série temporal estacionária apresenta uma função de auto-correlação semelhante à de um sinal de ruído-branco (curva de cor azul nos gráficos 02), o coeficiente de correlação cai rapidamente conforme  $k$  aumenta (PINDYCK e RUBINFELD, 1991).

No caso destes gráficos, a variável  $k$  representa o deslocamento do tempo em meses. Por outro lado, as funções de auto-correlação da série histórica de todos os segmentos apresentam uma forma diferente, caindo lentamente e oscilando com ou aumento de  $k$ , conforme mostram as curvas na cor vermelha nos gráficos 02. Além disso, na maioria dos gráficos, as curvas onduladas apresentam picos que se repetem com o deslocamento no tempo,  $k$ , múltiplo de 12 meses, mostrando claramente aspectos de sazonalidade que ocorrem dentro dos períodos de um ano.

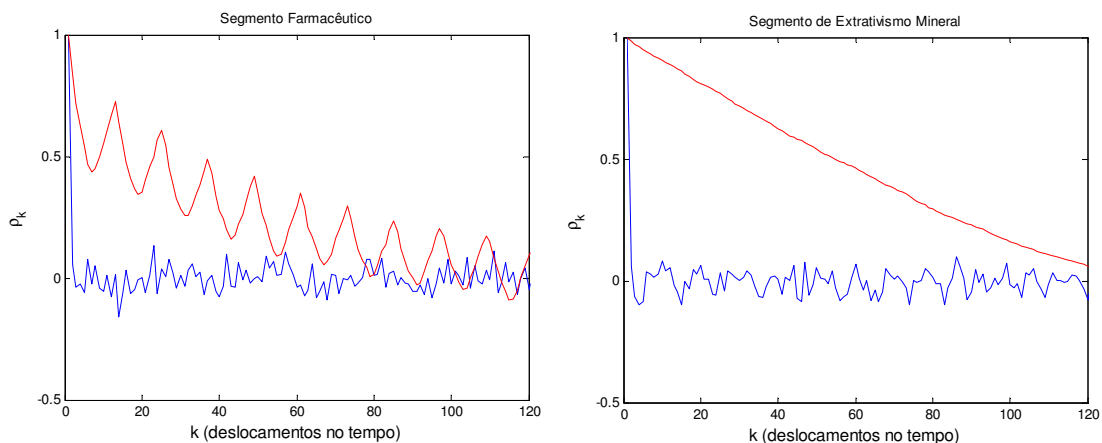


Gráfico 02 - Função de auto-correlação da série histórica de todos os segmentos.

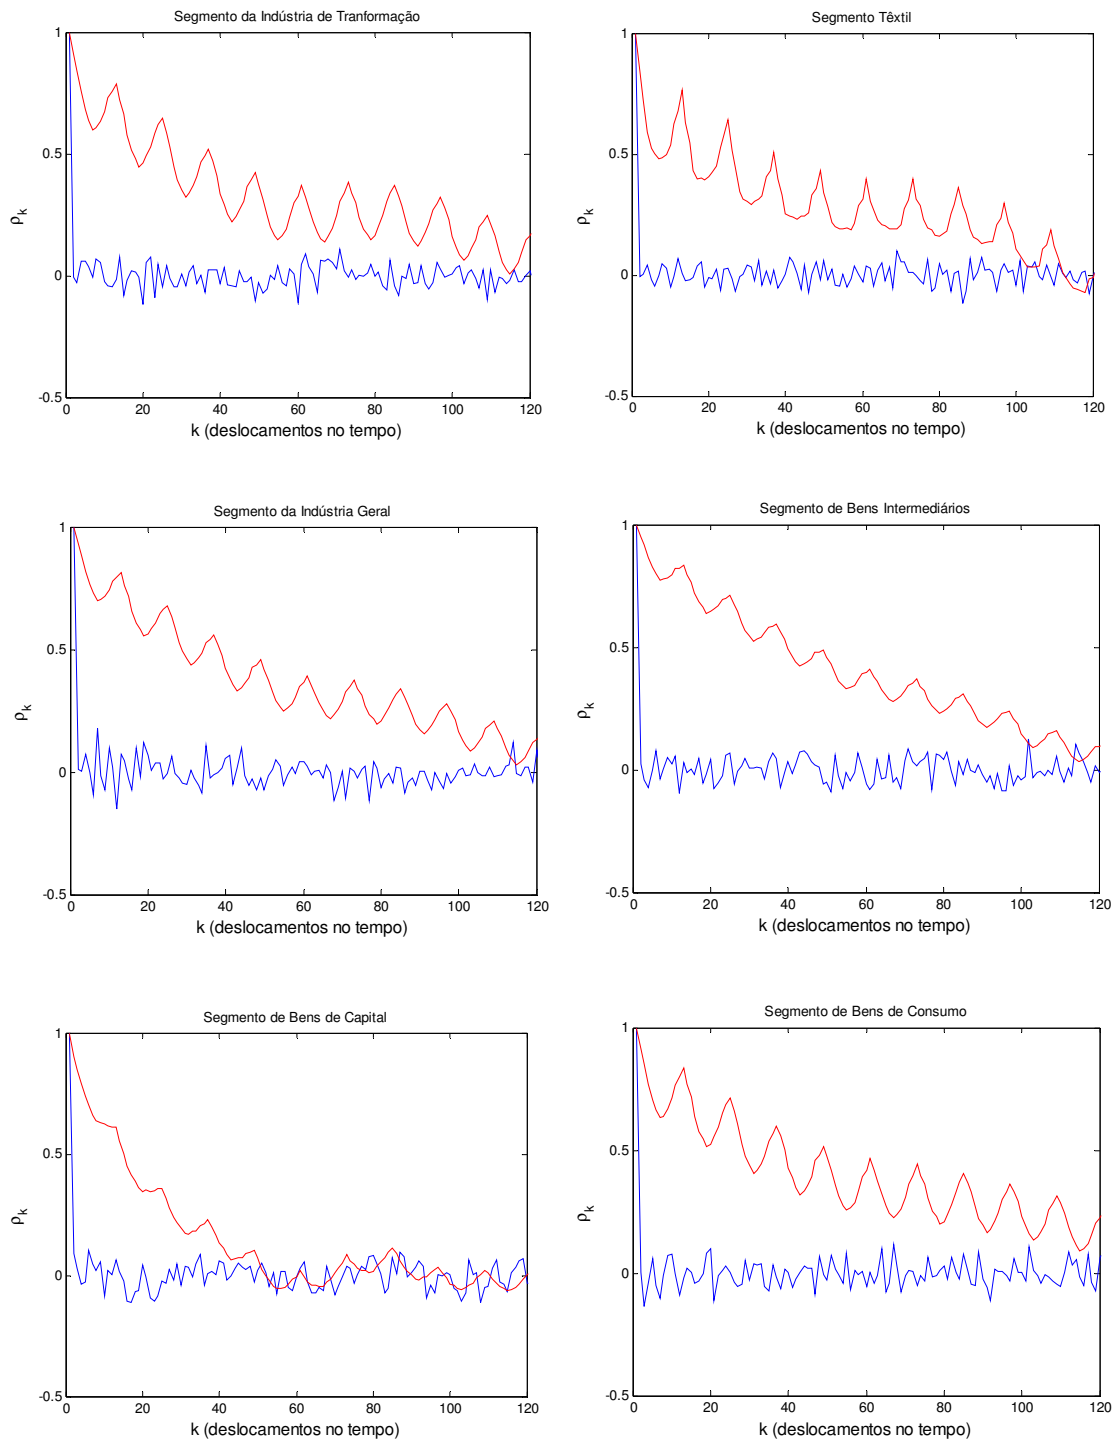


Gráfico 02 (Continuação) - Função de auto-correlação da série histórica de todos os segmentos.




Gráfico 02 (Continuação) - Função de auto-correlação da série histórica de todos os segmentos.

Apesar de modelos de previsão do tipo ARMA só serem efetivos para séries temporais estacionárias (PINDYCK e RUBINFELD, 1991), as TDNN são capazes de trabalhar com séries não-estacionárias diretamente (sem um tratamento prévio dos dados), e até mesmo que apresentam comportamento sazonal. Um exemplo disso é o trabalho de TÁPIA (2000), que utilizou uma RN perceptron multicamadas para previsão de preços de ovos, e que apresentou resultados satisfatórios.

Entretanto, considerando uma série de tempo mensal  $y_t$  com sazonalidade anual, conforme o dado de vários segmentos analisados existe um método relativamente simples de se eliminar o efeito da sazonalidade. Para isso, basta calcular a variação das séries temporais em

intervalos de 12 meses, por exemplo,  $\text{delta} = \text{valor}(\text{jan}/86) - \text{valor}(\text{jan}/85)$ , e se estes valores de variação (diferenças) forem colocados de forma a definir uma nova seqüência de dados no tempo, o resultado será uma serie temporal praticamente estacionária. Isto foi confirmado pela aplicação desta transformação em todas as séries históricas, cujo resultado está apresentado nos gráficos 03, onde a curva em azul é a função de auto-correlação de um sinal de ruído-branco e a curva em vermelho é a função de auto-correlação da série temporal transformada. Os gráficos 03 mostram uma semelhança muito grande entre as duas funções.

Esta mudança gerada na série temporal pela transformação dos dados de entrada pode ser entendida sob dois aspectos: o primeiro está relacionado à eliminação do fator de sazonalidade anual, que é bastante significativo na maioria dos segmentos; e o segundo está relacionado à tendência de crescimento ou decrescimento das séries que também é eliminado depois da transformação. Assim, a série temporal resultante apresenta-se como um sinal que varia em torno do valor zero e não apresenta uma componente sazonal clara, como ocorre nas séries originais.




Gráfico 03 - Função de auto-correlação da seqüência temporal das diferenças dos valores em intervalos de 12 meses da série histórica de todos os segmentos.

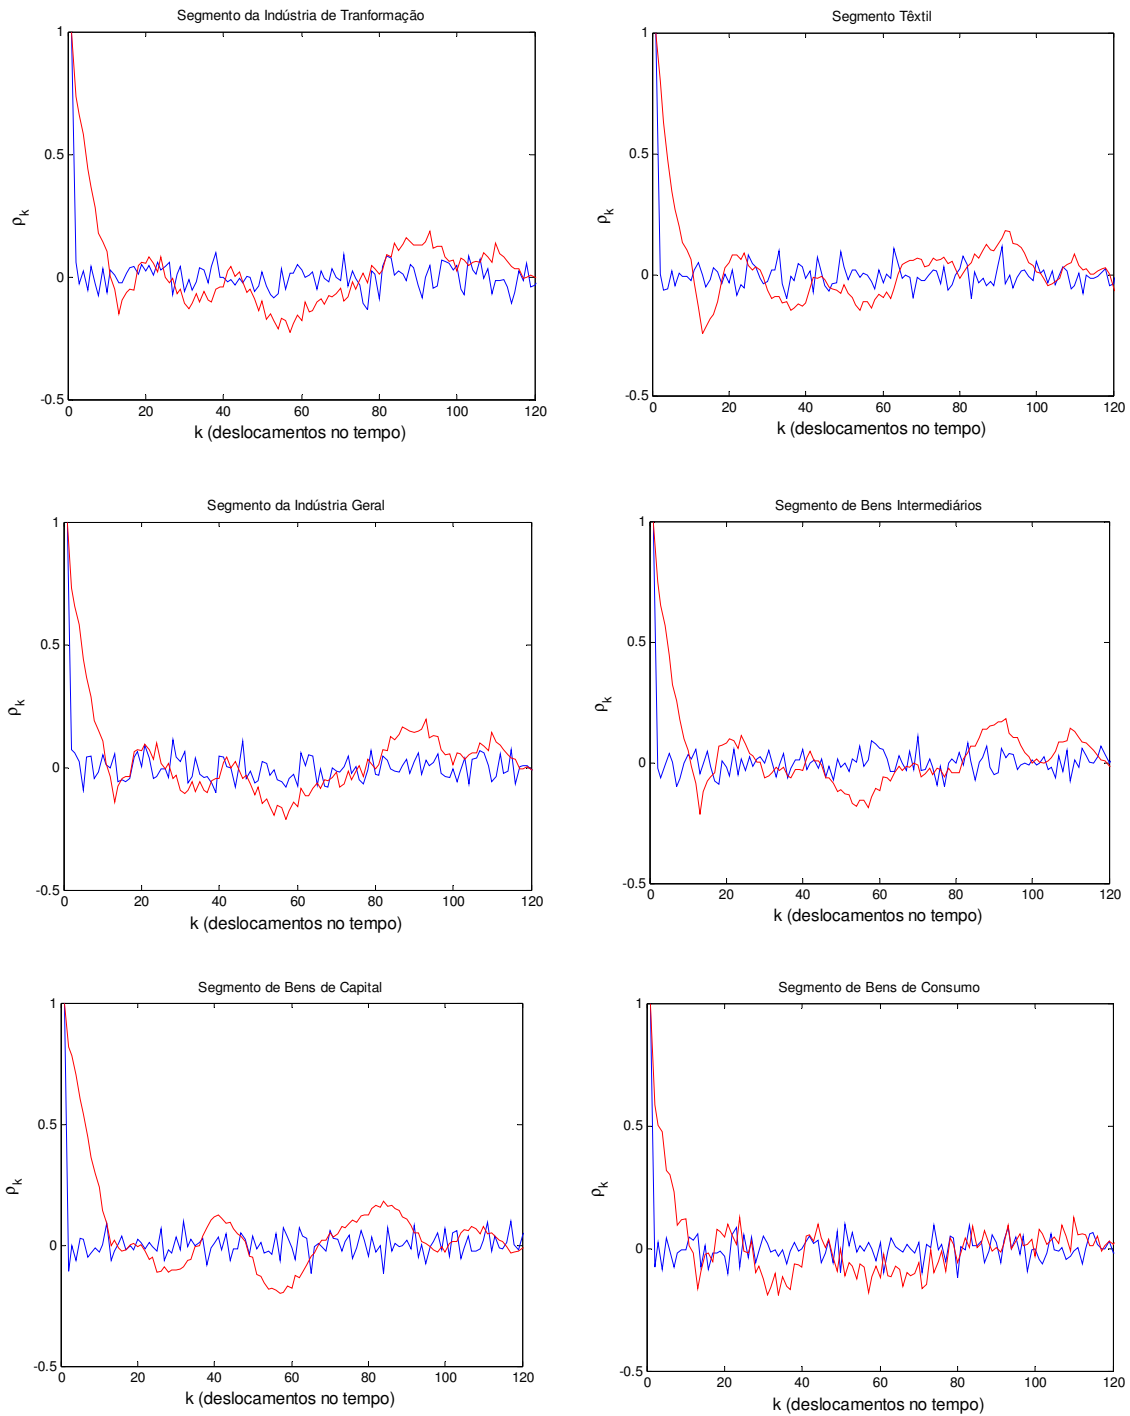


Gráfico 03 (Continuação) - Função de auto-correlação da seqüência temporal das diferenças dos valores em intervalos de 12 meses da série histórica de todos os segmentos.



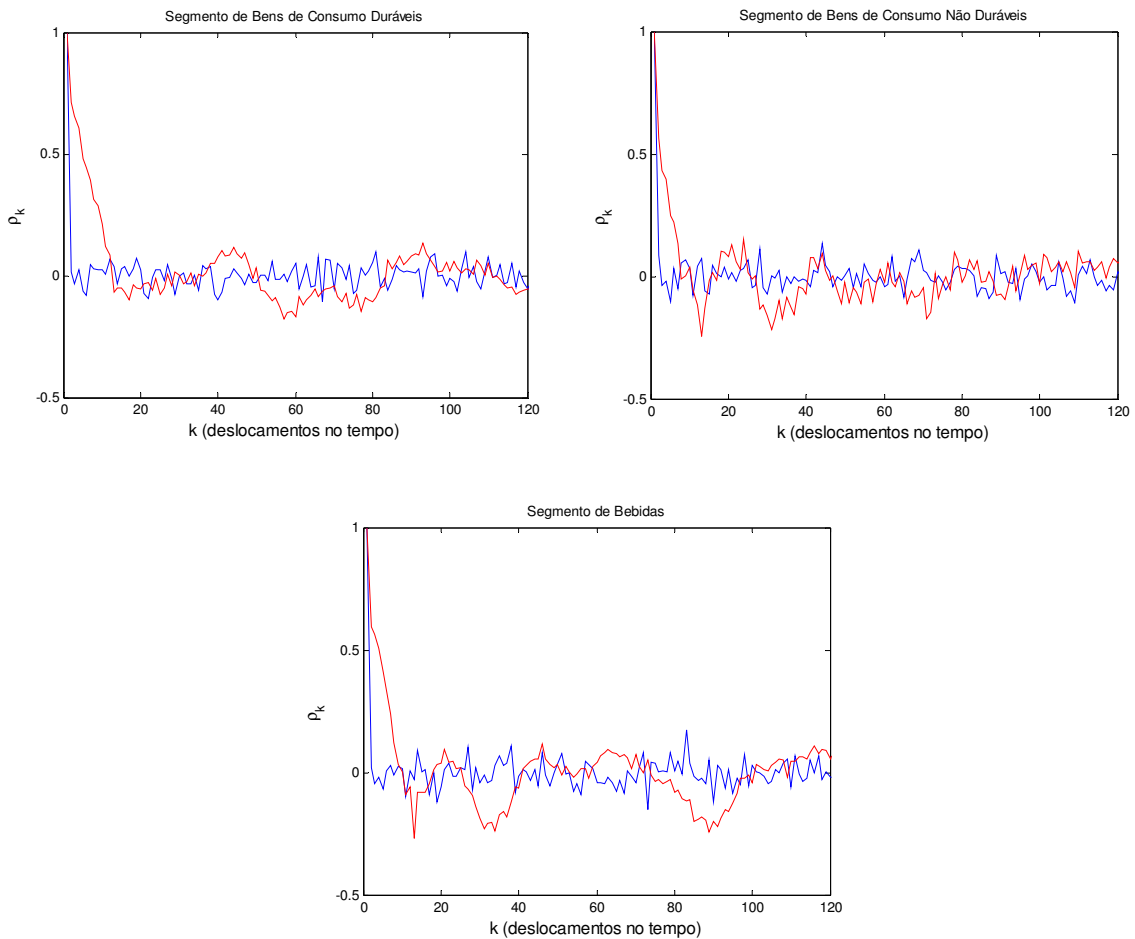


Gráfico 03 (Continuação) - Função de auto-correlação da seqüência temporal das diferenças dos valores em intervalos de 12 meses da série histórica de todos os segmentos.

## 5.2. Propostas de Estratégias de Uso das TDNN (Time-Delay Neural Network)

Como resultado da análise preliminar dos dados, foi proposta inicialmente a utilização de duas estratégias para a utilização da TDNN baseada em uma rede de perceptron-multi-camadas. Uma estratégia é utilizar a TDNN diretamente nos dados reais da produção industrial mensal brasileira, de forma similar ao trabalho de TÁPIA (2000). A outra estratégia é aplicar a mesma topologia de RN sobre os dados transformados, conforme descrito na seção 5.1, ou seja, sobre séries temporais estacionárias. Nesta segunda estratégia, tanto os dados de entrada como o

de saída são diferenças entre dois meses, separados por um intervalo de 12 meses, ou seja, diferenças entre mesmo mês em anos consecutivos.

Como o tipo de RN adotado requer um treinamento supervisionado, os dados devem ser compostos por informações de entrada e saída. O conjunto de dados de treinamento foi dividido em duas partes: um para treinamento, e outro para simulação (validação), ambos com dados de entrada e de saída.

No caso da primeira estratégia, foram considerados 13 meses para a entrada, portanto o respectivo dado de saída para treinamento só pode ser considerado a partir do 14º mês. Considerou-se também um período de previsão de demanda para 12 meses (1 ano), portanto este foi o intervalo de dados utilizado para simulação, ou seja, os últimos 12 meses foram simulados pela RD treinada, e o resultado foi comparado com os últimos 12 meses dos dados de demanda reais.

Assim, a quantidade de dados para treinamento das RN na primeira estratégia foi o total, menos os primeiros 13 meses e menos os últimos 12 meses, portanto  $405-25=380$  meses. Como na segunda estratégia há o cálculo da diferença dos valores de demanda entre um período de 12, ela perde mais 12 meses de dados, o que resulta em 368 meses para treinamento da RN, o que ainda é bastante razoável.

### **5.3. Treinamento**

O algoritmo utilizado para o treinamento foi o Levenberg-Marquardt, que é bastante eficiente para este tipo de aplicação. Para os dados de treinamento utilizado foram necessárias apenas 25 épocas de treinamento para se atingir uma boa convergência da rede neural. Uma época de treinamento corresponde uma passagem completa por todos os dados disponíveis para o treinamento.

O gráfico 04 mostra um exemplo da evolução do processo de aprendizado da RN. O erro total é avaliado pelo somatório das diferenças entre a saída calculada da rede e o dado real, ao quadrado. O valor do erro total parte de um valor de aproximadamente 4.000 e até ser reduzido a aproximadamente 8 depois de 25 épocas de treinamento.

Verificou-se que a utilização de mais épocas de treinamento reduziu ainda mais o erro total, porém isso levou a um overfit, ou seja, a RN aprendeu excessivamente, ficando muito

especializada nos dados de treinamento e menos capaz de extrapolar o aprendizado para outras situações.

Na prática, verificou-se a alta eficiência do algoritmo Levenberg-Marquardt, visto que permitiu processos de treinamento muito rápidos (com apenas 25 épocas). Só para comparação, no trabalho de Tapia (2000), foram necessárias 200.000 épocas de treinamento. A desvantagem do algoritmo Levenberg-Marquardt é que ele utiliza muita memória do computador, e para redes muito grandes ele torna-se inviável, não sendo este, o caso observado neste trabalho.




Gráfico 04 - Curva de aprendizado da RN em 25 épocas.

#### 5.4. Definição da Quantidade de Neurônios

Nesta análise, parte-se do pressuposto de que as séries de tempo são geradas por processos estocásticos, ou seja, cada dado da série é descrito aleatoriamente a partir de uma distribuição de probabilidade. No modelamento de tal processo, tenta-se descrever as características da sua aleatoriedade da seguinte forma:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}) + \varepsilon_t \quad (8)$$

Onde  $f(\bullet)$  é uma função linear ou não-linear de dados anteriores e  $\varepsilon_t$  é um ruído branco, ou seja, um sinal aleatório que segue uma distribuição normal com média zero, e que não é auto-correlacionado, isto é,  $E(\varepsilon_t \cdot \varepsilon_s) = 0$  para  $t \neq s$ .

Como o objetivo da RN é aproximar-se da função  $f(\bullet)$ , um indicativo de que isso foi conseguido é analisar se a diferença entre os dados reais e os dados estimados, chamado de resíduo, apresenta as mesmas características de  $\varepsilon_t$ .

Para se definir a quantidade de neurônios na camada escondida da rede, foram analisados os resíduos de simulações realizadas com a quantidade destes neurônios variando de 1 a 25. Os resíduos passaram por um teste estatístico de normalidade para avaliar se apresentam distribuição normal, e foi calculada a sua função de auto-correlação. O objetivo é escolher a quantidade de neurônios cujos resíduos que atendam as características acima e que apresente a menor variância.

Na Figura 22 estão os resultados da análise dos resíduos gerados na simulação RN baseada na primeira estratégia descrita no item 5.2. aplicada ao segmento farmacêutico.

A escolha do segmento farmacêutico, para a identificação da melhor quantidade de neurônios da rede, foi baseada no fato deste segmento apresentar um conjunto completo de características comuns aos demais segmentos (análise dos gráficos 02) e, portanto oferecer melhor condição de adaptabilidade do modelo para todo o pacote de dados do objeto estudado (Setor Industrial).

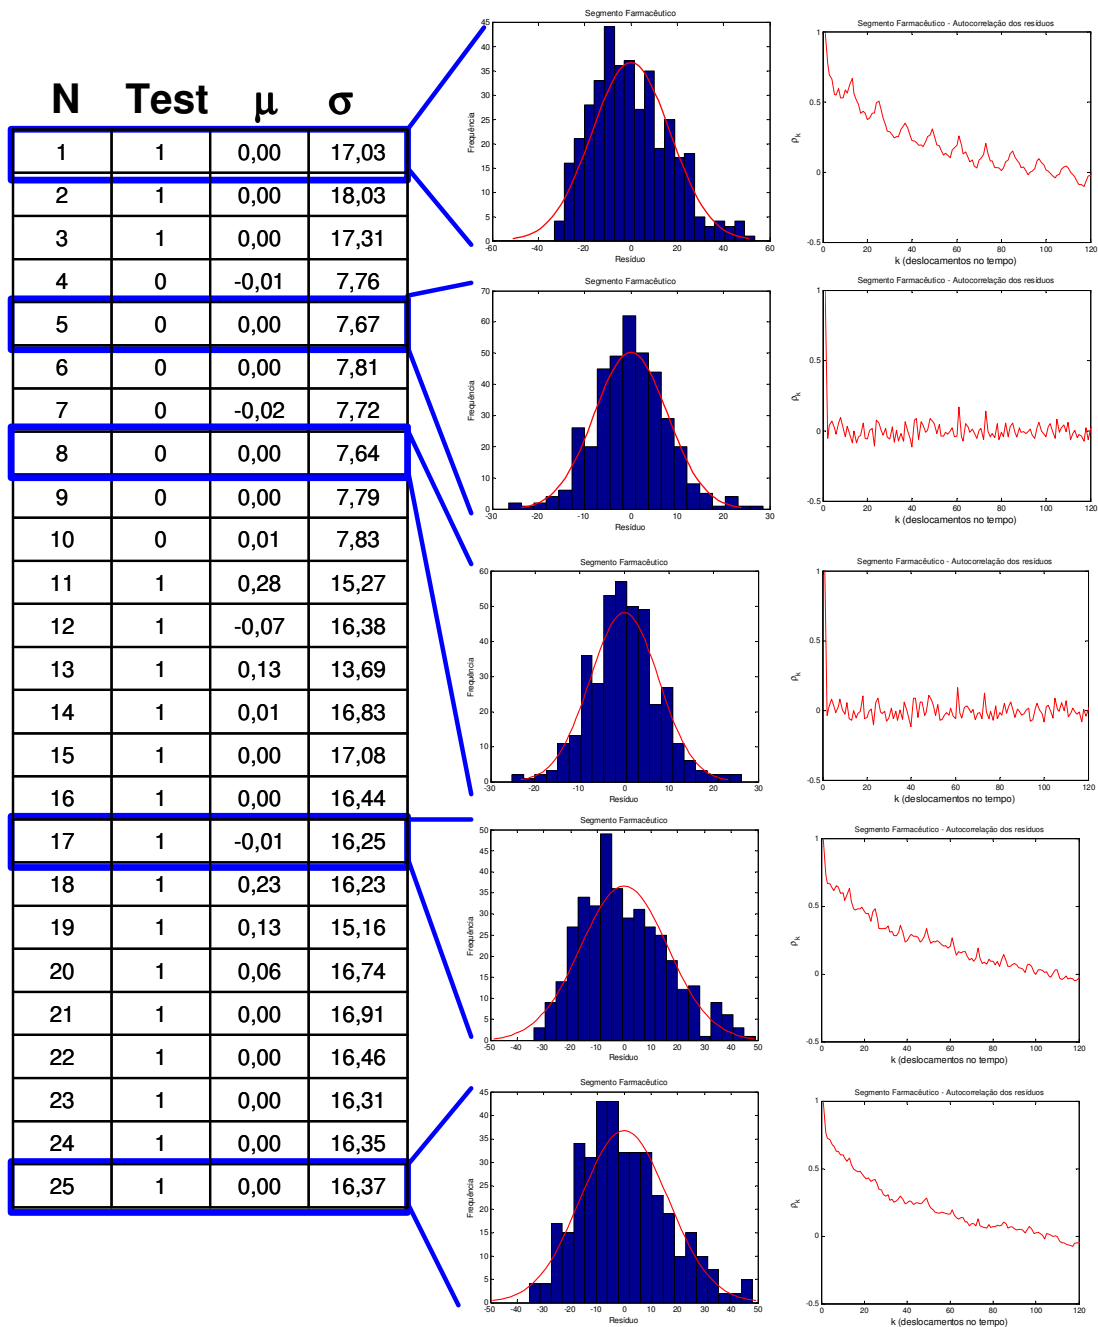


Figura 22 - Resultados da análise de resíduos da primeira estratégia.

Na Figura 22 ‘N’ é a quantidade de neurônios na camada escondida, ‘Test’ é o resultado de testes estatístico de normalidade (‘0’ indica que há 95% de certeza de que seja normal),  $\mu$  e  $\sigma$  são respectivamente a média e o desvio padrão do resíduo.

Na Figura 23 estão os resultados da análise de resíduos da RN baseada na segunda estratégia definida no item 5.2:

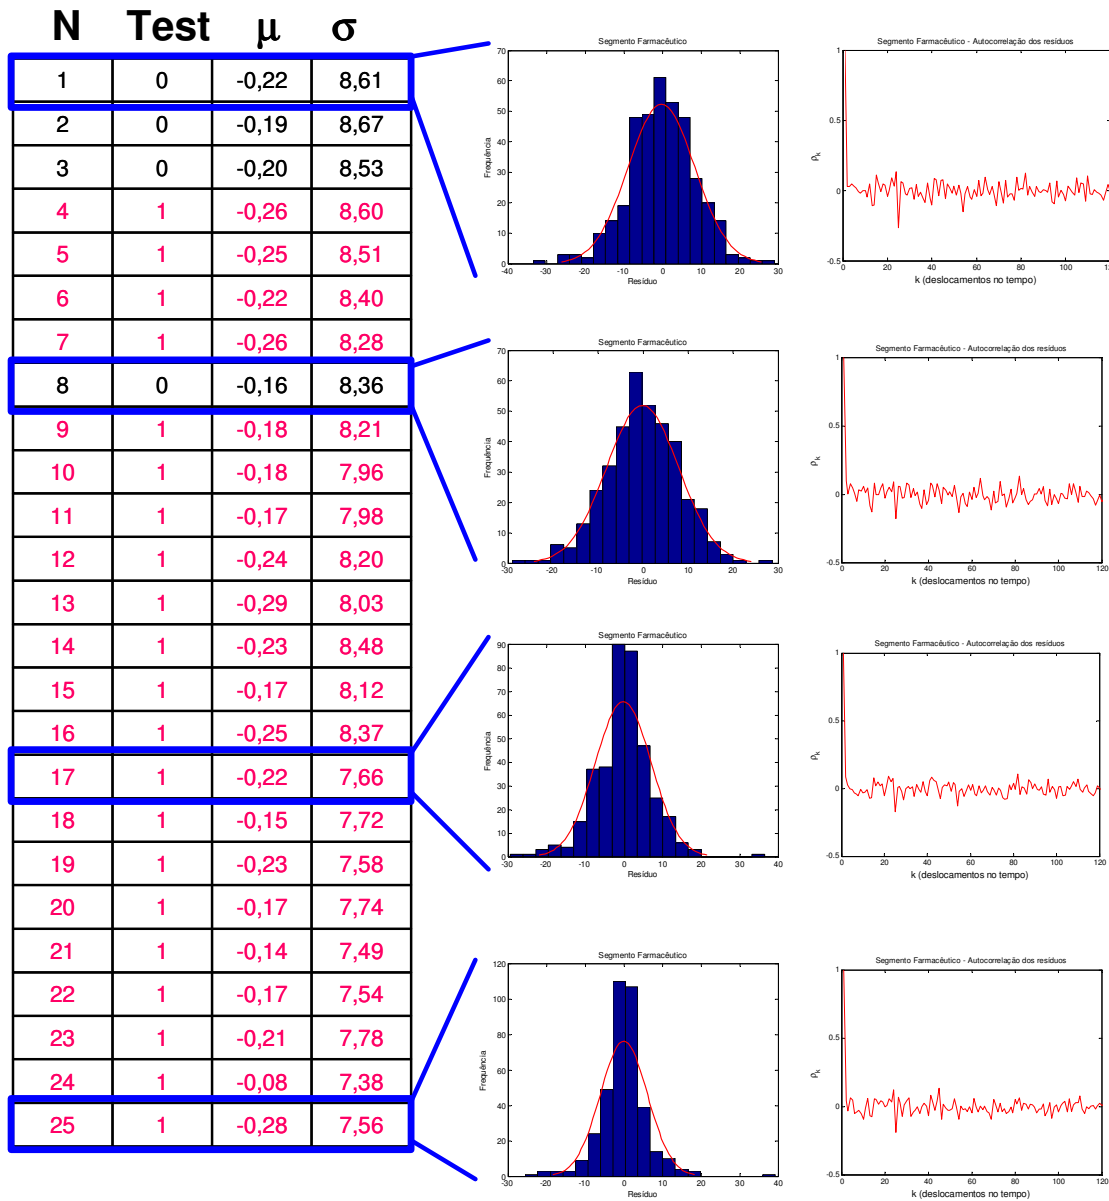


Figura 23 - Resultados da análise de resíduos da segunda estratégia.

Através destas análises, verificou-se que no caso da primeira estratégia, foi necessária uma quantidade mínima de neurônios para se atingir a capacidade da RN de aproximar a função  $f(\bullet)$ , dado que os resíduos não apresentaram uma distribuição normal e ainda eram bastante

auto-correlacionados. A partir de 5 até 10 neurônios, foi possível obter-se resíduos com distribuição normal e com auto-correlação desprezível.

Neste caso escolheu-se a quantidade de 5 neurônios, cujo resíduo apresentou a segunda menor variância na média das observações realizadas perdendo apenas para a rede com 8 neurônios. Como os resultados foram muito próximos escolheu-se a rede com menor número de neurônios, pois, na prática, estruturas de redes mais simples, que têm uma pequena quantidade de neurônios na camada escondida, freqüentemente trabalham bem com as previsões de informações fora dos dados de treinamento (KHASHEI et al., 2008)

Para quantidade superior a 10 neurônios houve dificuldade de se atingir um ponto mínimo na curva de aprendizado da rede, que está relacionado em parte à quantidade limitada de dados para treinamento, associado ao fato de se estar trabalhando com um sinal altamente auto-correlacionado e com ‘deriva’.

No caso do uso da segunda estratégia, apesar de poucos resíduos passarem no teste de normalidade, praticamente todos apresentaram padrões de distribuição muito próximos de uma curva normal. Curiosamente a normalidade dos resíduos foi obtida com uma quantidade pequena de neurônios (1 a 3), e depois também foi obtida com 8 neurônios. Em todas as análises os resíduos não apresentaram auto-correlação, portanto, a escolha da quantidade de neurônio ficou baseada no resultado com menor quantidade de neurônios, que apresentou normalidade na distribuição de resíduos e a menor variância. Neste caso foi escolhida a quantidade de 3 neurônios na camada escondida, visto que é que apresentou a menor variância do resíduo das três RN com menos neurônios.

### **5.5. Definição da Tipologia das Redes Neurais**

Para a aplicação da primeira estratégia ficou então definida uma rede TDNN com 13 entradas, 5 neurônios na camada escondida, e um neurônio na saída, cuja nomenclatura utilizada para identificá-la é  $N^{13-5-1}$ . A estrutura desta rede está apresentada na figura 22.




Figura 24 – Estrutura da TDNN Utilizada na Primeira Estratégia de Análise

No caso da primeira estratégia não foi possível utilizar uma quantidade menor de entradas porque com menos entradas não foi possível capturar o comportamento sazonal de 12 meses que a maioria das séries temporais analisadas apresenta. No entanto, no caso da segunda estratégia, como o comportamento sazonal foi eliminado das séries temporais através dos cálculos das diferenças, foi possível utilizar uma quantidade menor de entradas na RN.

Para encontrar a quantidade ideal de entradas, foram realizados cinco treinamentos e simulações para cada um dos onze segmentos de mercado, e para cada quantidade de entradas que variou de 13 até 3. Em cada processamento foram analisados a normalidade dos resíduos e calculados os erros MSE (“mean square error”) e MAE (“mean absolute error”) conforme equações a seguir:

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (9)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (10)$$



Onde  $N$  é a quantidade de dados analisados na simulação da RN e  $e_i$  é a  $i$ -ésima diferença entre o dado estimado e o dado real.

Os resultados destas análises, para cada segmento foi normalizado, e todas as informações foram consolidadas a partir da definição de uma variável de penalização relacionada à normalidade dos resíduos e aos erros encontrados nas simulações. Assim a quantidade de entradas que apresentasse o menor fator de penalização seria a escolhida para a estrutura da RN aplicada na segunda estratégia. O resultado desta análise está apresentado no Gráfico 05.




Gráfico 05 - Resultados da análise das simulações para escolha da quantidade de entradas da RN para aplicação na segunda estratégia.

O cálculo para definição de entradas conforme apresentado no Gráfico 05 foi baseado numa série de testes na segunda estratégia. Para cada simulação, foram calculados:

- Teste de normalidade da distribuição de probabilidade dos resíduos;
- Média do resíduo
- Desvio padrão do resíduo
- Média dos valores absolutos da função de auto-correlação para deslocamento maior que zero
- Os Erros MSE e MAE;

Os valores médios das 10 simulações de cada topologia analisada foram planificadas e os valores de desvio padrão do resíduo, a média da função de auto-correlação e a média dos erros foram normalizados, ou seja, dividindo-se pelo maior valor de cada coluna. Do resultado desta coluna gerada pela normalização dos dados, foi feita a média que foi plotada no Gráfico 05.

Como pode ser observada, a quantidade de quatro entradas, e que corresponde a média apresentou os menores erros nas simulações e maior normalidade nas distribuições de probabilidade dos resíduos. Desta forma a tipologia da RN para a segunda estratégia ficou sendo 4 entradas, 3 neurônios na camada escondida, e um neurônio na saída, cuja nomenclatura utilizada para identificá-la é  $N^{4-3-1}$ . A estrutura desta rede está apresentada na Figura 25.

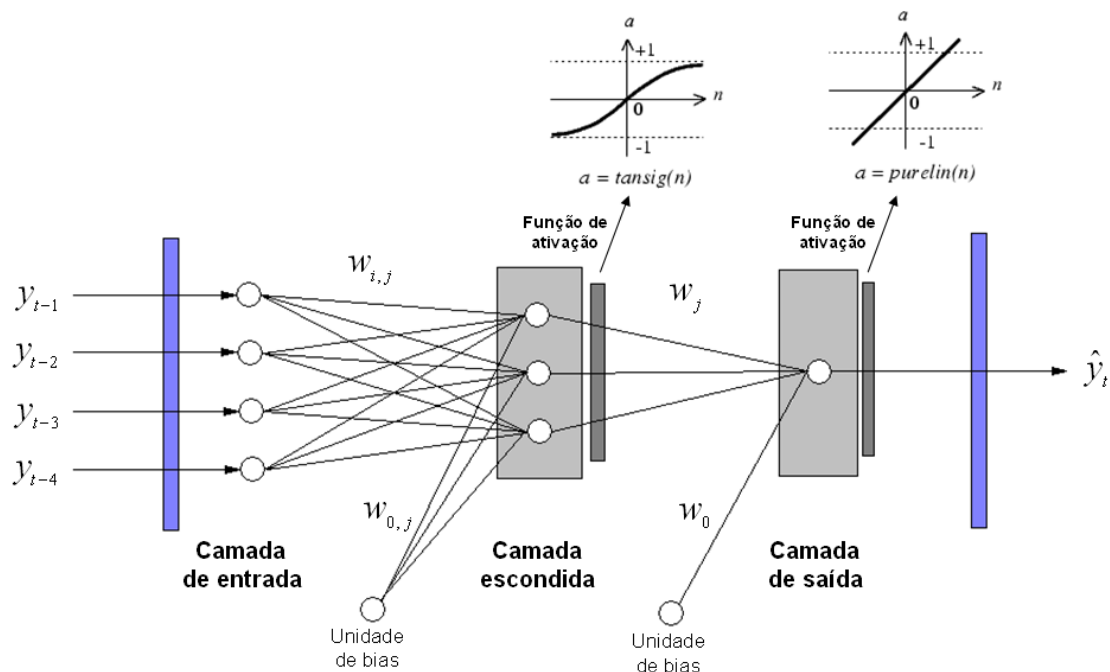


Figura 25 – Estrutura da TDNN Utilizada na Segunda Estratégia de Análise

## 5.6. Avaliação das Estratégias de Modelagem

Nesta seção, as duas estratégias de análise serão avaliadas em dois segmentos de mercado: o segmento de extrativismo mineral, que apresenta pouca sazonalidade e um crescimento constante, e o segmento farmacêutico, que apresenta uma sazonalidade bastante evidente e um crescimento mais lento.

Começando-se pela primeira estratégia de análise, com o treinamento e simulação sobre os dados do segmento de extrativismo mineral, chegou-se aos resultados apresentados no Gráfico 06. A curva na cor azul mostra os dados reais. Na cor magenta é apresentado o resultado da saída da rede a partir da introdução de dados reais nas entradas, e por isso a curva na cor magenta inicia-se apenas no 14° mês. A curva na cor magenta é o resultado da simulação da rede. Os resíduos são as diferenças entre a curva azul e a magenta.

A partir do mês 394 inicia-se a previsão da demanda, onde se pressupõe que os dados dos meses 395 até 405 não estão disponíveis, e desta forma cada valor de demanda estimada é introduzido na entrada da rede para se obter a estimativa do mês seguinte. Portanto a estimativa de demanda do mês 405, que corresponde ao mês de setembro de 2008, é feita com 11 dados estimados e apenas 2 dados reais (agosto e setembro de 2007). Estes resultados aparecem na curva na cor verde no Gráfico 06.




Gráfico 06 - Resultados das simulações do segmento de extrativismo mineral.

Legenda Gráfico 06:

- |                |   |   |
|----------------|---|---|
| Linha Azul     | - | Dados Reais da 1ª. Estratégia                                 |
| Linha Magenta- |   | Saída da Rede pela Introdução dos dados Reais (Transformados) |
| Linha Verde    | - | Previsão de Demanda   |

A análise dos resíduos (Gráfico 07) mostrou uma distribuição próxima da normal, porém com excesso de ocorrência dos dados próximos da média, porém ainda aceitável. A função de auto-correlação também ficou em níveis aceitáveis. O desvio padrão do resíduo é utilizado para o cálculo das incertezas nos valores estimados de demanda.

Para a primeira previsão utiliza-se o mesmo  $\sigma$  do resíduo, e para as previsões subsequentes utiliza-se  $\sigma\sqrt{l}$ , onde  $l$  é a quantidade de períodos à frente na previsão. Este cálculo é baseado no fato de que as variâncias ( $\sigma^2$ ) de cada estimativa vão se somando, e pelos resíduos estarem descorrelacionados no tempo (OJA, 1982).




Gráfico 07 - Distribuição de probabilidade do resíduo com  $\mu = -0,0142$  e  $\sigma = 2,8765$  (à esquerda) e Função de Auto-correlação (à direita) do Extrativismo Mineral

O gráfico 08 apresenta uma comparação entre os valores reais de demanda (em preto) e os valores estimados pela RN (em verde) no período compreendido entre os meses 393 e 405. As barras na cor magenta mostram o intervalo de um desvio padrão ( $\sigma$ ) e as barras vermelhas, intervalos de dois desvios padrão.




Gráfico 08 - Previsão de demanda do segmento de Extrativismo Mineral utilizando a 1ª estratégia de análise. MSE=5,8403 e MAE=16,6178

Legenda Gráfico 08:

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural

Como resultado desta primeira análise, é possível perceber no Gráfico 06 que a previsão (cor verde) se distanciou mais dos dados reais (cor azul) do que os dados da simulação (cor magenta). Isto mostra certa dificuldade da RN em generalizar o comportamento dos dados utilizando a primeira estratégia. Apesar da RN conseguir representar as características de sazonalidade, ela não pode acompanhar o crescimento da demanda. Além disso, o gráfico 10 mostra que a variação dos dados reais em relação à previsão extrapolou os limites de incerteza, mostrando que a RN foi incapaz de ter uma boa representação deste processo estocástico. Estes fatos são indícios de que ocorreu certo overfit da RN, que é difícil de se evitar utilizando-se a primeira estratégia.

Os pesos da TDNN que fez a previsão da demanda para o segmento de extrativismo Mineral estão apresentados na tabela 01

Tabela 01 – Pesos e Biases da TDNN ( $N^{13-5-1}$ ) na 1ª estratégia do Extrativismo Mineral

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
-0,0017	-6,9300	-0,4944	18,5079	1,7358	126,5049	-0,6073	28,6583	
0,0039	-6,3551	0,6830	51,0023	-3,5346	0,8638	-125,1319		
-0,0011	22,0324	0,1007	-10,2418	2,2065	18,0697	8,4731		
0,0006	-3,5472	-2,2646	18,6822	3,2288	-0,1158	-100,9507		
0,0000	-14,0444	0,2887	10,1820	-0,5146	-27,1206	-2,9353		
-0,0008	29,2165	-0,1688	7,2768	6,7214				
0,0014	3,5420	-0,3529	11,8190	-18,8722				
-0,0001	-19,3653	0,5940	-42,0550	8,8137				
-0,0009	18,8064	-0,3146	-25,7108	1,6403				
0,0008	-20,8188	0,8716	26,1314	-4,5609				
0,0014	-29,6160	1,3460	-60,9601	4,8853				
0,0020	3,8463	-1,0612	13,9632	-14,0026				
0,0031	23,9751	1,7118	-23,1733	-0,8097				

Os Gráficos 09, 10, 11, mostram uma repetição destas análises, porém feitas agora sobre os dados do segmento Farmacêutico, onde ocorrem de forma mais evidente os ciclos sazonais anuais.




Gráfico 09 - Resultados das simulações do segmento farmacêutico.

Legenda Gráfico 09:

- Linha Azul - Dados Reais da 1ª. Estratégia
- Linha Magenta- Resultado da Saída da Rede pela Introdução dos dados Reais
- Linha Verde - Previsão de Demanda

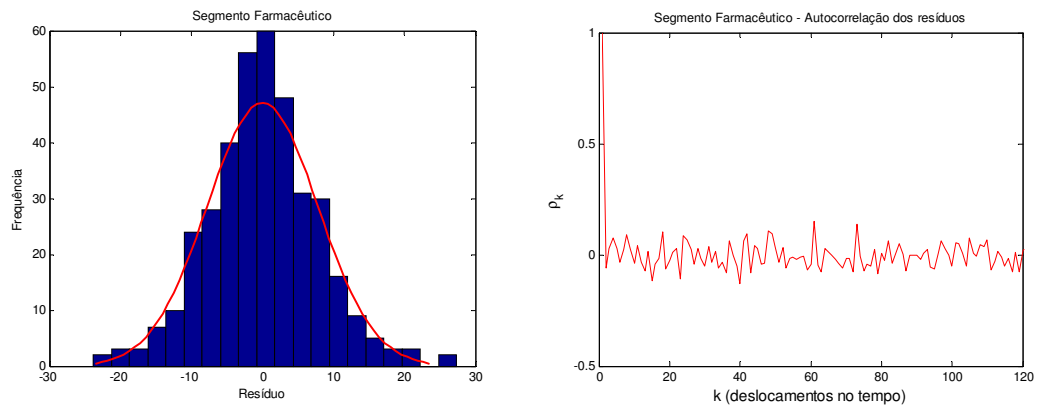


Gráfico 10 - Distribuição de probabilidade do resíduo com  $\mu=0,0031$  e  $\sigma=7,8158$  (à esquerda) e função de auto-correlação (à direita) do Segmento Farmacêutico.




Gráfico 11 - Previsão de demanda do segmento Farmacêutico utilizando a 1ª estratégia de análise.

MSE=5,8403 e MAE=16,6178.

Legenda Gráfico 11:

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural

Tabela 02 - Pesos e Biases da TDNN ( $N^{13-5-1}$ ) na 1ª estratégia do segmento Farmacêutico

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
97,83995	-0,21902	-1,02725	-0,00474	4,89337	-0,08996	246,29189	85,51668	
-98,78128	-1,99744	-1,44104	0,00750	-7,05858	-0,42920	285,89226		
91,35870	-1,56001	5,27727	0,00387	7,23419	0,97392	-19,46200		
-42,85439	1,31064	0,92957	-0,00191	-1,88510	62,15531	-1,48335		
106,12335	0,46509	-5,49845	0,00208	5,34686	-2,84345	68,98586		
-75,41247	0,10952	5,70046	-0,00247	-12,75571				
-86,43458	-0,73637	-0,75436	0,00159	7,05579				
-90,95014	-0,20782	0,04243	0,00063	-0,96218				
32,58869	0,76141	-1,47557	-0,00155	-1,31476				
334,34178	-1,95373	-4,25216	0,00069	2,13308				
-89,57207	-1,88741	3,44475	-0,00014	-0,02269				
-211,33687	-3,08808	1,73796	0,00243	-0,13788				
71,38521	1,02377	-0,98157	0,00888	-4,76130				

Como conclusão, percebe-se a presença dos mesmos indícios de overfit da RN. De fato, isto é resultado da estratégia de se tentar aproximar cuja média e variância se alteram com o tempo, ou seja, a RN é treinada sobre um conjunto de dados cujo padrão no tempo não se repete no futuro. Neste sentido a segunda estratégia, que trabalha com os diferenciais no tempo ao invés da série de tempo original, deve apresentar melhores resultados.

Analisando-se segunda estratégia, onde a RN foi treinada com os dados transformados pela regra de diferenças de dados de demanda entre intervalos de 12 meses. Esta “nova” série temporal está apresentada por linhas tracejadas azuis no Gráfico 12. No mesmo gráfico é apresentada a aproximação feita pela RN (na cor vermelha).




Gráfico 12 - Dados transformados do segmento de Indústria de Bebidas (azul tracejado) aproximados pela Rede Neural (vermelho contínuo).



Pelo resultado apresentado no Gráfico 12, a RN conseguiu uma boa aproximação do comportamento da série de tempo das diferenças, porém suavizando os picos do sinal gerado a partir dos dados reais.

Analisando-se os resíduos, cujo resultado está apresentado nos Gráficos 13, conclui-se que a distribuição dos dados segue uma curva normal com 95% de certeza, e o resíduo não apresenta auto-correlação significativa para deslocamentos entre 1 e 120 intervalos de tempo.

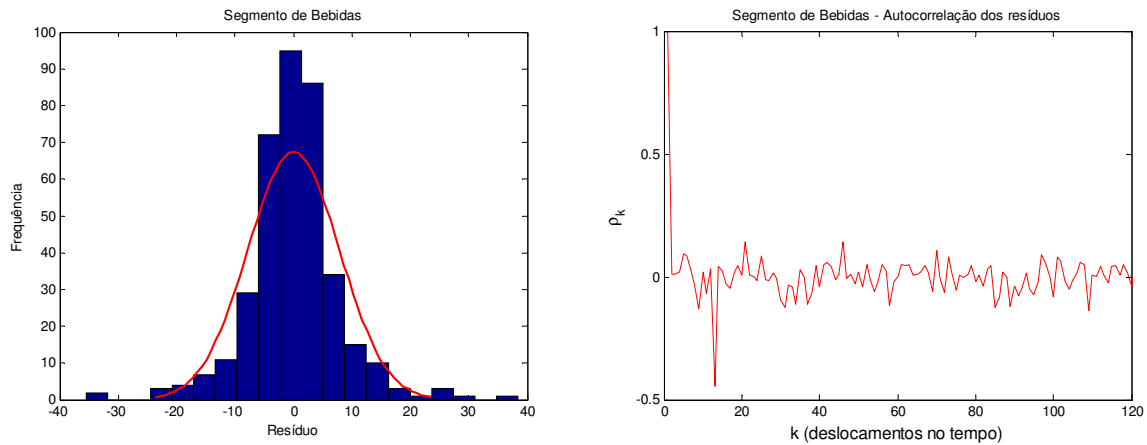


Gráfico 13 - Distribuição de probabilidade do resíduo com  $\mu=0,0158$  e  $\sigma=7,8261$  (à esquerda) e função de auto-correlação (à direita) do Segmento de Bebidas.

Fazendo-se a recomposição do sinal a partir das diferenças estimadas na simulação da RN, obtiveram-se os resultados apresentados no Gráfico 14. Percebe-se que de forma geral a simulação conseguiu acompanhar e descrever o comportamento dos dados reais de forma bastante aproximada. Além disso, o resultado na previsão (cor verde) apresentou uma melhor generalização do comportamento sazonal e de crescimento dos dados reais.




Gráfico 14 - Resultados das simulações do segmento de Indústria de Bebidas reconstituído a partir da serie de tempo das diferenças.

Legenda Gráfico 14:

Linha Azul	-	Dados Reais da 2ª. Estratégia
Linha Magenta-		Saída da Rede pela Introdução dos dados Reais (Transformados)
Linha Verde	-	Previsão de Demanda

O Gráfico 15 apresenta uma comparação entre os valores reais de demanda (em preto) e a previsão de demanda realizada pela RN (em verde). Além disso, este gráfico também mostra as barras de incerteza das previsões (um e dois desvios padrão), onde se verifica que praticamente todas as variações ficaram dentro do intervalo de um desvio padrão, onde é a maior probabilidade de ocorrência. A diferença entre os dados da previsão e os dados reais é medida através do cálculo do valor do MSE (“mean square error”), que é a raiz quadrada da soma dos quadrados dos 12 dados estimados na previsão dividida por 12. Neste caso o valor do MSE é de apenas 2,2. Como critério de avaliação, adotou-se que a previsão de demanda é considerada válida se o valor de MSE é menor que 5% do valor de partida da estimativa (que no exemplo é aproximadamente 120). A estimativa é considerada boa se MSE é menor que 3% do valor de partida. No exemplo do segmento da Indústria de Bebidas obteve-se um percentual menor que 2%, portanto considerou-se a previsão da RN muito boa.




Gráfico 15 - Previsão de demanda do segmento de Bebidas utilizando a 2ª estratégia de análise.

MSE=1,7104 e MAE=4,8085

Legenda Gráfico 15:

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural

Tabela 03 - Pesos e Biases da TDNN ( $N^{13-5-1}$ ) na 2ª estratégia do segmento de Bebidas

Pesos das entradas			Pesos da camada escondida	Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
-0,5738	-0,0001	4,4431	1,1910	0,1802	8,1884
4,7981	-0,0013	-7,5446	-44,9871	0,1768	
-6,3155	-0,0090	4,6509	-0,7493	-2,8697	
4,7502	-0,0063	-1,2710			

## 5.7. Avaliação das Previsões de Demanda

O cálculo de erros para o segmento Farmacêutico e Extrativismo Mineral aplicado na 1ª. Estratégia já foi visto no capítulo 5.6, e igualmente a aplicação do segmento da indústria de bebidas, na aplicação da 2ª. Estratégia, como análise prévia da estrutura de rede neural escolhida.

Analogamente foram simulados os dados reais e consequentemente estimada a previsão de demanda pela Rede Neural aos demais segmentos na primeira estratégia, e seus respectivos gráficos demonstrados no Apêndice 02.

Percebe-se pela análise dos gráficos de previsão de demanda, aplicados para a 1ª. Estratégia que para todos os segmentos, o comportamento da previsão segue basicamente o mesmo traçado dos dados reais, mas com certa dificuldade em acompanhar crescimento ou decréscimo no tempo, com maiores diferenças apresentadas no segmento de Bens de Capital.

Todos os segmentos resultaram em previsões que apresentaram normalidade dos dados e função de auto-correlação desprezível, conforme demonstrado nos gráficos do Apêndice 03, e pelos quais foram calculadas as médias e desvio padrão em cada um dos segmentos analisados.

No segmento de Bens Intermediários houve, porém uma maior aproximação dos dados de previsão com os dados reais e isso é claramente percebido nos gráficos de previsão de demanda apresentados no Apêndice 04.

No Apêndice 04 estão os gráficos de todos os segmentos, sendo que para cada um deles foram feitas as comparações dos valores reais com seus respectivos pontos de previsão e seus erros médios quadrados e absolutos calculados em cada um dos segmentos estudados.

No caso do segmento de Bens Intermediários e Bens de Consumo Não Duráveis foram os que apresentaram os menores erros pela diferença de valores da previsão e dos dados reais, seguido pelos segmentos da Indústria Geral e da Indústria de Transformação que também apresentaram erros abaixo de 3%.

A diferença entre os valores reais e os da previsão mostradas nos gráficos do Apêndice 04, demonstra que todos os segmentos tiveram uma previsão que ficou dentro de 2 desvios padrão, e o que caracteriza uma boa aproximação dos dados e, portanto aceitável dentro dos padrões de mercado, com 95% de probabilidade ocorrência.

No Apêndice 05 estão expostas as tabelas dos pesos de entradas, camadas intermediárias e biases utilizadas nas simulações de cada um dos segmentos, para a 1ª. Estratégia, conforme configuração de rede escolhida, TDNN ( $N^{13-5-1}$ ).

No desenvolvimento da 2ª. Estratégia foi trabalhada os dados dos demais segmentos e apresentados no Apêndice 06, onde os dados transformados pela regra da diferença de períodos de 12 meses são aproximados pela Rede Neural para posterior simulação de dados e previsão de demanda.

A aplicação da Rede Neural na 2ª. Estratégia foi bastante eficaz no resultado apresentado pelas previsões de cada um dos segmentos industriais conforme demonstrado nos gráficos do Apêndice 07.

Igualmente ao cálculo da 1ª. Estratégia, foram feitas as análises de normalidade dos dados e a função de auto-correlação apresentado nos gráficos do Apêndice 08. O resíduo, de todos os segmentos, segue uma distribuição normal e as médias e desvio padrão, foram calculados e colocados no Apêndice 08. Não existe auto-correlação significativa na distribuição apresentada em qualquer um dos segmentos na aplicação da 2ª. Estratégia.

Todos os pontos comparativos dos dados reais com a previsão de demanda foram calculados e estão demonstrados nos gráficos do Apêndice 09. Houve uma aproximação maior de pontos que entraram dentro de uma variação máxima de 1 desvio padrão, comprovando a maior habilidade da rede neural em descrever uma melhor previsão na 2ª. Estratégia conforme descrito durante a avaliação da estratégia de modelagem.

Os segmentos que obtiveram o melhor resultado na análise de resíduos foram os da indústria de Bens Intermediários, Extrativismo Mineral e os de Bens de Consumo Não Duráveis pela Média dos Erros Quadrados (MSE).

Os índices da Indústria Farmacêutica e da indústria de Bens de Capital, foram os que apresentaram maiores variações, muito embora ainda dentro do limite máximo de 1 desvio padrão e portanto dentro de um padrão considerado ótimo para previsão, pois a probabilidade de erro fica inferior a 2%.

As tabelas de pesos e biases de cada segmento para cálculo da 2ª. Estratégia foi colocada no Apêndice 10 conforme configuração de rede em TDNN ( $N^{4-3-1}$ ) previamente estabelecida.

Na Tabela 04 estão demonstrados os valores de Erros para cada uma das duas tipologias de redes neurais TDNN aplicadas nas respectivas estratégias:

Tabela 04 – Comparação dos erros MSE e MAE entre a TDNN ( $N^{13-5-1}$ ) na 1ª estratégia de análise e a TDNN ( $N^{4-3-1}$ ) na 2ª estratégia de análise

Segmentos de Mercado	1ª Estratégia ( $N^{13-5-1}$ )		2ª Estratégia ( $N^{4-3-1}$ )	
	MSE	MAE	MSE	MAE
Farmacêutico	5,8403	16,6178	4,6268	12,2761
Extrativismo Mineral	2,8893	8,7925	1,1954	3,9105
Indústria de Transformação	2,6381	7,2603	1,5740	4,3921
Têxtil	2,7127	6,8294	1,4719	4,2742
Indústria Geral	2,5098	6,997	1,5276	4,2792
Bens Intermediários	1,7803	5,1607	1,2272	3,3421
Bens de Capital	5,8575	17,906	4,9333	12,9632
Bens de Consumo	2,8293	7,3447	1,4335	4,0253
Bens de Consumo Duráveis	5,3399	15,2202	3,4348	9,0343
Bens de Consumo Não-duráveis	2,3334	6,708	1,1670	3,5839
Bebidas	4,1866	10,5392	1,7104	4,8085

Para todos os segmentos, percebe-se, como já citado nos parágrafos anteriores, que a segunda estratégia foi a mais bem sucedida na previsão de demanda, conforme mostram os valores menores dos erros MSE e MAE.

A primeira estratégia, mesmo utilizando uma rede neural mais complexa, foi incapaz de alcançar o desempenho da segunda estratégia que utilizou uma RN bem mais simples. A principal razão deste resultado é a complexidade dos dados originais das séries temporais que são não estacionários, apresentando média e variâncias dependentes do tempo e sazonalidades.

Na segunda estratégia, com a diferenciação das séries temporais com intervalos de 12 meses, além de eliminar os efeitos das sazonalidades, também deixou as séries de tempo praticamente estacionárias. Esta foi a principal razão pela qual a 2ª estratégia foi melhor e mais bem sucedida.

No entanto, o fato dela permitir a utilização de uma RN mais simples (com menos neurônios e conseqüentemente menos parâmetros) resultou num maior potencial de generalização dos dados, ou seja, a RN foi capaz de assimilar a regra intrínseca de variação temporal dos dados, não ficando especializada em descrever pequenos detalhes irrelevantes do sinal original. A proporção dos dados para treinamento em relação a quantidade de parâmetros da RN (pesos) também melhorou, proporcionando um aprendizado mais consistente.

## 6. CONCLUSÕES

Ao longo deste trabalho, buscou-se descrever as principais técnicas para o cálculo de previsão de séries temporais estudadas no decorrer das últimas décadas, e com isso mostrar, embora de forma abrangente, os diversos tipos de aplicações e métodos adequados a cada situação requerida no estudo da previsão.

Verificou-se, através de uma revisão da literatura, uma gama de aplicações da técnica de Redes Neurais em diversos segmentos distintos nos últimos anos, desde a aplicação em robótica até cálculos de previsões em sistemas financeiros. O presente trabalho buscou uma abordagem mais detalhada desta técnica, aplicada ao cálculo de previsões de demanda em segmentos industriais.

O trabalho buscou relacionar uma sistemática para aplicação de modelos de séries de tempo, usando como base a utilização de Redes Neurais no cálculo de previsão de demanda de diferentes segmentos do setor industrial

O objetivo foi encontrar e validar a aplicação de pelo menos um modelo de rede neural que fosse capaz de prever a demanda de uma amostra de 11 segmentos industriais, dentro de um limite aceitável de erro pela comparação de dados históricos conhecidos.

Pela análise prévia dos dados e pelo estudo de estrutura existentes de redes neurais, foi definido como modelo de aplicação, o uso de duas estratégias cujas estruturas variavam conforme número de entradas e número de camadas na camada intermediária em função da auto-correlação dos dados.

Como uma análise imediata da utilização de redes neurais para previsão de séries temporais em segmentos industriais, pôde-se comprovar e validar a efetiva aplicação da rede neural, usando a técnica de RN - Perceptron Multi-Camadas, através de um modelo de algoritmo do tipo Levenberg-Marquadt, com uma boa margem de aceitação frente aos erros apresentados, em quaisquer das duas estratégias propostas.

Entretanto, e conforme abordado na avaliação das previsões de demanda para cada um dos segmentos, há de se levar em consideração que os efeitos da não-estacionaridade dos dados, e que apresentaram sazonalidade com médias e variâncias com dependência no tempo, dificultou o treinamento da rede na primeira estratégia, cujos dados originais não foram trabalhados.

Considerando os efeitos da não-estacionaridade, ocorreu em alguns casos um overfit na RN, resultado de sua incapacidade de se aproximar a valores cuja média e variância se alteram com o tempo, ou seja, como já foi citado anteriormente, a RN é treinada sobre um conjunto de dados cujo padrão no tempo não consegue repetir no futuro.

A aplicação do modelo de rede a dados reais não foi totalmente eficaz em um primeiro instante. Portanto, a estratégia de aplicação da rede proposta levou a uma análise mais significativa do efeito da sazonalidade presente nos dados, e na busca de uma solução que fosse capaz de suavizar os dados, eliminando os efeitos de overfit ocorridos na primeira estratégia e, conseqüentemente, um melhor treinamento da rede, resultando numa melhor margem de erro aceitável.

A aplicação do modelo estrutural de rede na 2ª. Estratégia demonstrou uma melhor aderência e com valores de resíduos abaixo do apresentado na 1ª. Estratégia. A comparação dos pontos dos dados reais com o resultado da previsão mostra que a rede aproximou os dados, deixando-os dentro de um limite máximo de 1 desvio padrão.

Entretanto, se fizermos uma análise da aplicação de Redes Neurais, levando-se em consideração não somente o resultado da rede em cada segmento, mas também o próprio processo exposto no capítulo 2.2, sobre as etapas para implantação de previsão de demanda, podemos considerar aceitáveis os resultados encontrados em cada uma das estratégias.

Se levarmos também em consideração a experiência de quem conduz o processo de previsão e conhece o modelo de negócio, pode-se afirmar que a aplicação de Redes Neurais alcançou o objetivo, quando comparamos os resultados encontrados com o histórico conhecido

Por tudo o que foi apresentado e analisado durante o decorrer deste trabalho, e de acordo com os erros apresentados nas duas estratégias, com valores de MSE (mean square error) inferiores a 5%, com exceção de três segmentos da primeira estratégia, podemos concluir que os resultados obtidos neste estudo garantem a validação da utilização de Redes Neurais para cálculo de previsão de demanda no segmento industrial.

**Sugestões para Trabalhos Futuros:** O modelo de Rede Neural proposto apresentou-se bastante útil para o cálculo de previsão de demanda nos segmentos industriais, porém, algumas modificações dos dados na segunda estratégia foram necessárias para uma melhor aderência do modelo. Desta forma, sugere-se que novos modelos ou algoritmos sejam testados de forma a compará-los na busca de uma melhor eficiência dos resultados.



## 7. REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, H.; CALDEIRA, A. M.; MACHADO, M. A. S.; SOUZA, R. C.; TANSCHKEIT, R.; **Inteligência Computacional Aplicada à Administração, Economia e Engenharia em Matlab**. Ed. Thomson Learning, 2007

ARAÚJO, R. B.; MELO, P. L. S. Protótipo de Software para Aprendizagem de Redes Neurais Artificiais – **XXXIV Congresso Brasileiro de Ensino de Engenharia**. Ed. UPF, 2006.

ARMSTRONG, J. S. Findings from Evidence Based Forecasting: Methods for Reducing Forecast Error. **International Journal of Forecasting**, v.22, p.583-598, 2006.

BARTOLOMEI, S. M.; SWEET, A. L. A Note on a Comparison of Exponential Methods for Forecasting Seasonal Series. **International Journal of Forecasting**, p. 111-116, 1989.

BATTITI, R. **First and Second Order Methods for Learning: Between Steepest Descent and Newton's Method**. Neural Computation, v.4. no.2, p. 141-166, 1992

BELL, W. R.; HILLMER, S. C. Issues Involved with Seasonal Adjustment of Economic Time Series. **Journal of Business and Economic Statistics**, p. 526 – 534, 1984.

BOLLERSLEV, T.; ENGLE, R. F. **ARCH Models**. Handbook of Econometrics, vol.IV, p. 2959-3038, 1994

BOX, G. E. P.; JENKINS, G. M. Time Series Analysis Forecasting and Control. San Francisco **Holden Day**. Ed.1976.

BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes Neurais Artificiais, Teoria e Aplicações**. 2ª. Edição, Ed. LTC, 2007.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to Time Series Forecasting**. Springer-Verlag New York, NetLibrary. Ed.II. 2002

CARPENTER, G. A.; GROSSBERG, S. Art: Hierarchical Search Using Chemical Transmitters in Self-Organizing Pattern Recognition Architectures. **Neural Networks**, v.3, p. 129-152, 1990

CHAKRABORTY, K.; MEHROTRA, K.; MOHAN, C. K.; RANKA, S. Forecasting the Behavior of Multivariate Time Series using Neural Networks. **Neural Networks**, v.5, p. 961-970, 1992.

CHANG, P. T. Fuzzy Seasonality Forecasting. **Fuzzy Sets and Systems**, p1-10, 1997.

CHASE, C. W. JR. What You Need to Know When Building a Sales Forecasting System. **The Journal of Business Forecasting Methods & Systems**, v.15, p. 22, 1996.

CHASE, C. W. JR. Sales Forecasting at the Dawn of the New Millennium? **The Journal of Business Forecasting Methods & Systems**, v.18, p.2, 1999.

CHING, H. Y. **Gestão de Estoques na Cadeia de Logística Integrada**, Ed. Atlas, São Paulo, SP 2001

CHOU, R.; ENGLE, R. F.; KANE, A. Measuring Risk Aversion from Excess Returns on Stock Index. **Journal of Econometrics**, v.52 p.201-224, 1992

CRUM, C.; PALMATIER, G. E. Principles of Demand Planning. **Demand Management Best Practices**. Cap.4. p. 25, 2003.

EFE, O. M., KAYNAK, O. **A Novel Optimization Procedure for Training of Fuzzy Inference Systems by Combining Variable Structure Systems Technique and Levenberg Marquadt Algorithm**. Bogazici University, Istanbul - Turquia, 2002.

ENGLE, R. F. Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K. Inflation. **Econometrica**, v.50, p.987-1008, 1982.

FUNKE, M. Assessing the Forecasting Accuracy of Monthly Vector Autoregressive Models. **International Journal of Forecasting**, v.6, p.363-378, 1990

GARDNER, E. S. JR. The Space of Interactions in Neural Network Models. **Journal of Physics A: Mathematical and General**, v.21, p.257-260, 1988.

GARDNER, E. S. JR. Exponential Smoothing: The State of the Art – Part II. **International Journal of Forecasting**, v.22, p.637-666, 2006.

GEURTS, M. D.; WHITLARK, D. Improving Sales Forecast by Improving the Input Data. **The Journal of Business Forecasting Methods & Systems**, v.15, p.15, 1996.

GOOIJER, J. G. D.; HYNDMAN, J. R. 25 Years of Time Series Forecasting. **International Journal of Forecasting**, v.22, p. 443-473, 2006.

GORDON, R. A Role for the Forecasting Function. **The Journal of Business Forecasting Methods & Systems**, v.16, p.3, 1997/1998.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. **Neural Network Design**. Publicação PWS, Boston, MA, 1996

HUARNG, K. Heuristic Models of Fuzzy Time Series for Forecasting. **Fuzzy Sets and Systems**, p. 369-386, 2001.

JAIN, C. L. Benchmarking Forecasting Model. **The Journal of Business Forecasting**, p. 15-35, 2007.

KAASTRA, I.; BOYD. Designing a Neural Network for Forecasting Financial and Economic Time Series. **Neurocomputing**, Elsevier Science. p.215-236, 1996.

KAHN, K. B. Benchmarking Sales Forecasting Performance Measures. **The Journal of Business Forecasting Methods & Systems**, v.17, p.19, 1998/1999.

KHASHEI, M.; HEJAZI, S. R.; BIJARI, M. A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. **Fuzzy Sets and Systems**, p. 769-786, 2008.

KOSKIVAARA, E. Artificial Neural Network Models for Predicting Patterns In Auditing. **Journal of Operational Research Society**, p.1060-1069, 2000

KOTLER, P.; ARMSTRONG, G. **Princípios de Marketing**, Editora Prentice/Hall, Englewood Cliffs, New Jersey, 1991.

KUO, R. J.; XUE, K. C. A Decision Support for Sales Forecasting through Fuzzy Neural Networks with Asymmetric Fuzzy Weights. **Decision Support Systems**, v.24, p105-126, 1998.

KUO, R. J.; XUE, K. C. Fuzzy Neural Networks with Application to Sales Forecasting. **Fuzzy Sets and Systems**, p.123-143, 1999.

KÜSTERS, U.; McCULLOUGH, B.D.; BELL, M.; Forecasting Software: Past, Present and Future. **International Journal of Forecasting**, p. 599-615, 2006

LOURAKIS, M. I. A. – A Brief Description of the Levenberg-Marquardt Algorithm Implemented by Levmar – **Institute of Computer Science** – Foundation for Research and Technology. Greece, 2005

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

MAKRIDAKIS, S.; HIBON, M. Exponential Smoothing: The Effect of Initial Values and Loss Functions on Post-Sample Forecasting Accuracy. **International Journal of Forecasting**, v.7, p.317-330, 1991.

MAKRIDAKIS, S.; HIBON, M. ARMA Models and Box Jenkins Methodology. **Journal of Forecasting**, v.16, p.147-163, 1997.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. J. **Forecasting Methods and Applications**, John Wiley & Sons, 3a. Edição, New York, 1998.

MARIEN, E. J. **Demand Planning and Sales Forecasting: A Supply Chain Essential**. The Supply Chain Yearbook, p. 3-16, 2001.

MARTINS, P. G.; LAUGENI, F. P. **Administração da Produção**, Editora Saraiva, São Paulo, 1999.

MEADE, N.; SMITH, I. ARARMA vs ARIMA – A Study of the Benefits of a New Approach to Forecasting, **Omega**, p. 519-534, 1985.

MENTZER, J. T.; COX JR, J. E. Familiarity, Application, and Performance of Sales Forecasting Techniques. **Journal of Forecasting**, v. 3, p. 27-36, 1984.

NARENDRA, K. S. **Neural Networks for Control**, Cambridge: MIT Press, 1990

NETO, J. A.; MARINHO, B. L.; BREMER, C. F.; LAURINDO, F. J. B.; D'ANGELO, F.; CORRÊA, G. N.; ROZENFELD, H.; PESSOA, M. S. P.; OLAVE, M. E.; CARVALHO, M.M., COSTA, R. P.; PIRES, S. R. I. **Manufatura Classe Mundial, Conceitos, Estratégias e Aplicações**, Editora Atlas, São Paulo, SP, 2001.

NEWBOLD, P. **Operational Research Quaterly**, Edição Operational Research Society, v. 26, no.02, p. 397-412, 1975.

OJA, E. Neural Networks: A Simplified Neuron Model as a Principal Components Analyzer, **Journal of Math. Biology**, 15, p. 267-273, 1982.

PARZEN, E. ARARMA Models for Time Series Analysis and Forecasting. **Journal of Forecasting**, p. 67-82 , 1982.

PELLEGRINI, F. R.; FOGLIATTO, F. S. **Metodologia para Implantação de Sistemas de Previsão de Demanda**. Universidade Federal do Rio Grande do Sul (UFRGS), 2002.

PICKSLEY, J. D.; BRETNALL, G. J. Bayesian Modeling Enhances Supply Chain. **Forecasting and Planning**, v.18, p.19, 1999.

PINDYCK, R. S; RUBINFELD, D. L. **Econometric Models and Economic Forecasts**, 3<sup>rd</sup> edition, McGraw-Hill, ISBN 0-07-050098-3, 1991.

SABBATINI, M.; LINTON, O. GARCH Model of Implied Volatility of Swiss Market Index from Option Prices. **International Journal of Forecasting**, p.159-170, 1998.

SILVA, C.S., **Previsão Multivariada da Demanda Horária de Água em Sistemas Urbanos de Abastecimento**. Tese de Doutorado da Universidade Estadual de Campinas – Faculdade de Engenharia Civil, 2003

SIMPSON, P. **Artificial Neural Systems: Foundations, Paradigms, Applications and Implementations**, Pergamon Press Inc., 1990.

SLACK, N. **Administração de Produção**. 1<sup>a</sup>. Edição. Ed. Atlas, São Paulo, 1997.

SNYDER, R. D. Recursive estimation of Dynamic Linear Statistical Models. **Journal of the Royal Statistical Society**. p. 272-276, 1985.

SPEDDING, T. A.; CHAN, K. K. Forecasting Demand and Inventory Management Using Bayesian Time Series. **Integrated Manufacturing Systems**. p.331-339, 2000.

STEVENSON, W. J. **Administração das Operações de Produção**, Rio de Janeiro, Editora LTC, 2001.

TAPIA, M.; ROISENBERG, M.; BARRETO, J. M. Aplicação de Redes Neurais diretas na previsão de preços de ovos. InfoAgro 2000 - **Congresso e Mostra de AgroInformática**, 18 a 20 de outubro de 2000, Ponta Grossa, PR, 2000

TERASVIRTA, T.; DIJK, V. D., MEDEIROS, M. C. Linear models, Smooth Transition Autoregressions, and Neural Networks for Forecasting Macroeconomic Time Series: A Re-examination. **International Journal of Forecasting**. p. 755-774, 2005.

TOKLE, J.; KRUMWIED, D. An Overview of Forecasting Error Among International Manufacturers. **Journal of International Business Research**, v.5, n.2 p. 97-105, 2006.

TONG, H.. **Threshold Models in Non-Linear Time Series Analysis**, Lecture Notes in Statistics, Ed. Springer-Verlag. V.21, New York, 1983.

TUBINO, D. F. **Manual de planejamento e controle da produção**. 2ª ed. São Paulo: Atlas, 2000.

VALENZUELA, O.; ROJAS, I.; ROJAS, F.; POMARES, H.; HERRERA, L. J., GUILLEN, A.; MARQUEZ, L.; PASADAS, M. Hybridization of Intelligent Techniques and Arima Models for Time Series Prediction. **Fuzzy sets and Systems**, p 821-845, 2008.

WERNER, L.; RIBEIRO, J. L. D. Previsão de Demanda: Uma aplicação dos modelos Box-Jenkins. **Gestão & Produção**, v10, n.1, p.47-67, 2003.

WINTERS, P. Forecasting Sales by Exponentially Weighted Moving Averages. **Management Science**, v.6, p.324, 1960.

WRAY, B.; PALMER, A.; BEJOU, D. Using Neural Network Analysis to Evaluate Buyer-Seller Relationships. **European Journal of Marketing**, p.32, 1994.

ZHOU, W. Integration of Different Forecasting Models. **The Journal of Business Forecasting Methods & Systems**, v.18, p.26, 1999.

## APÊNDICE 01

### Tabela de Séries de Produção Industrial por Segmento

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-75	51,696	16,75	55,19	95,89	51,01	43,37	84,55	52,65	31,71	58,11	44,93
fev-75	51,192	15,91	51,77	86,55	47,86	40,48	87,17	48,07	27,88	53,33	39,24
mar-75	57,34	17,8	56,01	104,8	51,83	43,79	94,05	52,27	31,74	57,62	46,65
abr-75	57,216	18,06	59,09	126,9	54,61	46,46	98,56	55,23	34,52	60,62	37,3
mai-75	59,38	18,93	59,22	128,4	54,81	46,85	94,04	56,04	33,07	62,03	35,46
jun-75	67,781	17,99	61,31	119,8	56,62	48,25	102,16	56,17	34,46	61,83	39,73
jul-75	68,49	18	63,68	117,1	58,76	50,97	103,55	57,18	37,1	62,4	35,31
ago-75	61,259	18,06	62,49	110,1	57,69	50,29	100,16	55,59	36,58	60,54	38,88
set-75	64,834	17,06	64,17	111,8	59,14	50,89	107,25	57,55	39,28	62,29	43,93
out-75	66,18	17,53	66,41	119,2	61,18	51,66	114,23	60,38	43,76	64,68	46,97
nov-75	55,864	17,02	62,2	109,6	57,35	48,11	103,6	58,28	39,42	63,42	46,44
dez-75	51,214	17,98	60,23	107	55,65	46,71	95,39	57,77	35,2	63,66	53,15
jan-76	48,648	18,02	59,6	108,1	55,09	47,49	90,67	56,62	34,38	62,42	52,51
fev-76	63,007	16,88	61,27	105,3	56,5	46,96	102,07	57,97	38,06	63,14	46,39
mar-76	64,249	17,69	65,48	125,5	60,36	50,88	104,98	62,68	40,03	68,58	51,02
abr-76	68,541	16,79	64,08	128,5	59,03	50,07	103,66	59,83	39,65	65,38	39,69
mai-76	75,245	17,94	67,65	129,1	62,33	52,12	108,95	64,39	42,8	70,32	41,37
jun-76	78,586	17,83	69,8	122,5	64,26	54,81	113,36	63,76	44,01	68,88	40,71
jul-76	78,455	18,87	71,06	119,4	65,47	56,27	116,47	64,22	42,1	69,98	42,17
ago-76	75,918	19,22	71,75	119,3	66,12	57,48	118,25	63,62	44,44	68,59	47,65
set-76	67,174	18,13	70,65	115,5	65,05	57,31	114,57	61,94	46,65	65,89	49,54
out-76	66,53	19,19	72,87	117,4	67,13	59,07	118,36	64,06	43,78	69,32	52,59
nov-76	62,049	18,08	68,55	107,7	63,16	55	106,72	62,08	44,19	66,71	53,11
dez-76	57,852	18,24	66,52	104	61,34	53,36	104,88	61,12	39,22	66,82	58,4
jan-77	43,888	16,57	61,56	101,5	56,74	51,31	87,84	56,68	32,3	63,05	55
fev-77	48,918	15,79	59,62	98,6	54,94	48,46	92,14	54,54	36,83	59,13	49,86
mar-77	64,213	18,66	69,88	140,5	64,4	57,16	105,45	64,83	40,46	71,17	55,39
abr-77	55,849	17,6	64,86	127	59,79	53,94	94,27	59,28	35,69	65,44	45,52
mai-77	67,145	18,28	71,51	136,8	65,84	57,33	108,73	67,36	44,03	73,42	52,47
jun-77	63,569	17,93	71,5	127,3	65,8	59,08	108,59	63,47	42,33	69,27	49,87
jul-77	58,459	17,48	71,24	118,7	65,54	60,35	105,27	61,69	40,85	67,42	52,07
ago-77	59,029	17,54	74,12	118,7	68,14	61,65	116,07	64,12	45,9	68,83	54,88
set-77	54,263	16,82	71,19	114,6	65,44	59,86	109,88	60,82	43,95	65,2	54,74
out-77	56,361	18,19	73,35	119,2	67,48	61,74	107,91	63,7	46,58	68,12	59,78
nov-77	55,432	17,11	71,1	115,6	65,37	58,76	102,78	64,45	47,7	68,78	59,92
dez-77	48,692	17,39	67,73	112,7	62,12	55,75	94,89	63,14	43,9	68,13	60,15
jan-78	45,116	16,91	65,88	114,5	60,66	54,63	87,39	62,35	42,16	67,85	56,05
fev-78	45,679	16,54	62,5	112,8	57,59	52,2	88,9	57,61	41,5	61,79	52,15
mar-78	61,362	18,95	71,82	141,5	66,17	59,03	103,58	67,01	50,91	71,14	60,21
abr-78	53,919	18,83	69,36	138,1	63,93	57,54	98,87	64,15	47,09	68,56	49,24
mai-78	60,513	19,32	73,37	136,2	67,58	59,46	104,29	69,44	51,1	74,17	53,13
jun-78	61,296	18,83	73,94	129,1	68,06	61,64	103,05	66,98	51,47	70,97	53,24
jul-78	62,948	19,84	75,04	123,2	69,13	63,66	103,53	66,03	50,47	70,05	53,38
ago-78	66,552	20,17	80,56	129,1	74,13	67,41	116,22	70,98	56,8	74,61	58,19
set-78	60,462	19,1	76,34	125,5	70,25	65,3	106,74	66,45	49,86	70,72	58,54
out-78	63,665	19,88	81,23	132,3	74,72	68,64	113,67	71,96	56,87	75,83	68,13
nov-78	57,223	18,61	76,23	124,5	70,12	63,17	106,72	69,34	56,1	72,74	66,55
dez-78	46,659	18,07	72	117,9	66,27	59,83	102,63	66,43	50,45	70,55	66,92

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

Tabela de Séries de Produção Industrial por Segmento (Continuação).

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-79	46,22	19,41	72,87	123,8	67,15	61,32	101,44	66,97	47,2	72,08	67,27
fev-79	48,516	14,68	68,27	124,9	62,65	56,9	100,12	62,02	49,28	65,29	54,46
mar-79	58,737	19,94	75,82	160,2	69,85	65,23	106,08	68,63	47,53	74,1	63,18
abr-79	62,765	19,73	73,06	149,8	67,35	62,35	106,84	64,97	49,3	69,01	46,99
mai-79	67,057	21,35	79,45	156	73,23	67,27	112,22	71,83	56,32	75,82	56,52
jun-79	66,64	22,01	79,4	138,9	73,23	69,16	110,26	68,25	53,28	72,11	52,79
jul-79	67,773	22,04	80,66	136,6	74,36	70,49	114,09	68,51	51	73,04	52,85
ago-79	68,3	23,31	85,66	140,2	78,97	72,89	122,97	74,52	61,15	77,93	61,59
set-79	62,261	21,86	78,72	129,1	72,68	68,59	109,64	67,36	52,89	71,08	59,12
out-79	65,456	23,32	88,27	141,2	81,32	74,5	125,54	77,55	65,67	80,56	74,24
nov-79	61,098	22,13	81,18	133,2	74,85	67,13	115,79	74,37	63,04	77,24	70,93
dez-79	48,472	22,4	75,02	119,9	69,31	63,75	107,05	67,1	53,62	70,55	68,05
jan-80	54,233	21,56	77,6	131	71,57	65,49	109,82	70,43	53,22	74,87	67,37
fev-80	55,279	22,36	75,95	141,2	70,15	64,84	108,34	67,32	54,9	70,49	61,46
mar-80	64,301	23,75	83,96	169,6	77,46	71,62	123,23	73,89	59,79	77,5	61,61
abr-80	64,79	23,48	77,98	159	72,06	68,35	98,75	69,86	53,16	74,16	56,08
mai-80	68,87	24,83	85,79	163,8	79,2	73,14	121,12	76,2	64,2	79,25	55,83
jun-80	77,036	24,07	87,01	144,4	80,24	75,83	123,06	72,26	64,11	74,3	51,77
jul-80	74,872	25,12	91,26	146,3	84,15	78,73	130,01	76,64	67,12	79,04	56,38
ago-80	69,996	25,61	90,18	143,5	83,22	77,99	125,64	76,25	67,85	78,34	61,7
set-80	76,335	24,48	92,64	145,2	85,35	77,85	135,49	79,5	74,81	80,62	65,21
out-80	71,465	24,72	94,4	152,2	86,96	78,63	134,52	83,1	81,68	83,32	70,67
nov-80	70,91	23,19	87,53	139,5	80,65	72,8	126,23	77,45	71,45	78,9	67,12
dez-80	59,541	21,38	79,66	125,8	73,42	67,45	109,99	71,57	59,93	74,54	67,54
jan-81	62,378	22,03	77,7	130,9	71,68	67,01	103,05	69,6	50,94	74,42	61,58
fev-81	65,514	22,87	77,23	126,4	71,34	64,59	111,07	70,13	55,05	73,73	59,05
mar-81	63,109	23,95	77,99	127,8	72,12	66,58	110,8	69,36	46,6	75,58	62,86
abr-81	67,51	22,44	72,84	118,3	67,35	61,57	100,49	66,61	42,3	73,41	55,84
mai-81	74,748	24,27	75,39	122,5	69,81	62,72	103,86	71,23	49,7	77	57,1
jun-81	75,859	22,97	78,48	126,6	72,48	65,91	104,8	71,8	47,09	78,63	55,52
jul-81	80,407	22,45	81,5	134,5	75,13	67,76	107,46	76,08	47,24	84,21	53,1
ago-81	74,287	22,89	79,26	129,5	73,16	67,21	90,62	75,11	50,22	81,93	52,8
set-81	71,37	22,71	77,02	127,5	71,14	64,95	82,68	74,77	49,7	81,64	56,17
out-81	68,256	24,88	78,94	133,1	73,05	67,01	91,1	76	52,17	82,44	58,58
nov-81	70,347	23,57	73,94	124,3	68,46	61,76	87,6	72,74	49,13	79,17	53,47
dez-81	54,665	23,18	67,41	118,1	62,56	58,55	71,62	66,18	39,51	73,79	60,5
jan-82	52,903	24,54	65,44	121,4	60,91	57,82	70,54	64	40,23	70,67	54,32
fev-82	64,71	23,28	64,93	120,1	60,34	56,84	73,6	62,7	41,08	68,68	51,73
mar-82	77,424	25,16	77,19	142	71,51	65,39	92,41	76,03	54,14	81,81	57,76
abr-82	64,425	24,5	72,48	131,5	67,22	62,69	85,16	70,51	51,09	75,58	52,33
mai-82	77,234	25,84	76,96	138,7	71,36	66,67	87,28	74,51	53,05	80,18	49,28
jun-82	71,963	24,47	81,02	140	74,88	72,07	87,08	74,86	53,65	80,45	53,96
jul-82	72,292	26	83,83	145,6	77,55	74,96	86,88	77,38	53,91	83,65	55,29
ago-82	75,062	24,02	85,89	145,2	79,22	74,92	94,08	79,93	58,24	85,57	53,85
set-82	70,193	21,79	83,17	134,8	76,58	72,57	87,77	77,62	55,64	83,39	59,21
out-82	69,521	26	81,08	134	75,08	70,64	82,33	79,35	58,73	84,63	60,58
nov-82	73,293	26,33	75,93	124,7	70,48	64,99	77,67	77,38	58,16	82,23	60,15
dez-82	65,346	25,55	68,14	118	63,43	58,19	67,86	72,15	48,03	78,78	61,83

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

**Tabela de Séries de Produção Industrial por Segmento (Continuação).**

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-83	53,612	27,33	63,38	116,9	59,31	57,13	53,12	66,04	45,42	71,61	55,8
fev-83	61,223	24,14	61,25	107,7	57,12	54,21	58,33	62,78	46,36	67	52,8
mar-83	74,88	27,29	72,45	130,1	67,45	62,83	71,73	75,19	60,81	78,46	57,49
abr-83	60,448	25,7	65,53	115,2	61,1	59,2	60,62	66,12	51,02	69,83	46,28
mai-83	77,124	28,85	72,61	127	67,72	63,08	73,23	75,06	59,33	78,79	46,99
jun-83	68,234	28,07	73,25	123,2	68,23	65,55	71,27	71,45	53,43	76,02	49,27
jul-83	62,78	29,73	73,9	122,3	68,97	68,09	66,52	70,15	45,68	76,93	49,3
ago-83	68,482	27,94	80,15	127,9	74,41	72,15	72,26	77,45	54,5	83,56	54,38
set-83	62,948	29,35	77,08	123	71,78	70,2	70,62	73,31	55,37	77,82	50,19
out-83	59,314	30,12	78,74	122,3	73,35	72,98	69,96	73,48	52,96	78,85	55,22
nov-83	66,786	31,49	75,63	112,1	70,67	69,49	68,41	72,22	51,81	77,59	58,82
dez-83	53,502	33,43	68,54	98,95	64,49	63,87	65,63	65,84	43,69	71,94	59,94
jan-84	58,927	35,66	65,15	102,4	61,64	62,74	62,62	61,98	37,06	69,08	54,65
fev-84	63,233	35,02	68,15	105,8	64,28	63,79	69,9	64,53	48,45	68,6	54,2
mar-84	63,672	35,45	69,97	110,4	65,95	66,99	70,49	64,81	45,44	69,98	54,62
abr-84	59	35,06	67,38	104,3	63,6	64,45	71,6	61,13	41	66,63	38,33
mai-84	82,498	37,69	76,97	117,8	72,44	71,14	81,65	73,57	52,49	79,13	51,45
jun-84	65,478	35,47	79,53	115,8	74,53	74,89	77,16	72,41	46,49	79,63	51,62
jul-84	70,829	37,1	82,51	119,2	77,35	77,37	78,57	75,44	47,91	83,13	48,23
ago-84	81,562	37,57	84,9	123,6	79,54	78,46	85,23	78,71	54,34	85,27	48,21
set-84	74,156	37,51	80,3	116,1	75,4	75,45	79,37	72,67	46,84	79,85	50,45
out-84	84,245	41,06	87,2	127	81,91	80,11	87,29	81,81	54,39	89,34	63,99
nov-84	71,056	39,93	80,98	122,6	76,23	74,41	81,94	77,18	55,25	82,97	59,63
dez-84	62,846	40,63	72,7	109,8	68,86	68,89	74,43	67,32	44,38	73,65	57,74
jan-85	64,344	39,7	74,91	121,3	70,76	70,47	78,97	69,47	49,06	74,89	56,24
fev-85	59,731	35,29	69,45	114,6	65,47	65,47	72,84	63,62	45,8	68,29	49,08
mar-85	70,866	40,66	77,45	128,5	73,13	73,22	85,54	70,41	53,49	74,63	49,04
abr-85	64,418	39,97	69,17	119,6	65,64	66,57	71,05	64,16	36,4	72,16	53,2
mai-85	72,226	42,54	78,43	130,8	74,18	74,84	78,44	72,96	44,22	81,11	56,81
jun-85	65,69	41	81,21	123,7	76,53	76,82	80,92	74	50,03	80,52	59,23
jul-85	80,129	42,82	90,04	136,7	84,62	82,64	92,54	85,16	62,71	90,94	53,86
ago-85	81,35	42,54	91,89	139,4	86,25	84,47	94,25	85,71	61,1	92,21	57,59
set-85	80,509	41,88	90,39	133,8	84,85	82,19	96,18	84,42	66,42	88,71	62,71
out-85	89,356	44,98	98,79	145,6	92,67	88,74	102,75	94,85	74,4	99,75	67,86
nov-85	80,473	43,67	89,07	138,3	83,83	79,78	94,8	86,8	68,2	91,25	68,48
dez-85	72,27	45,07	81,32	128,4	77	75,95	85,91	77,53	51,89	84,54	68,89
jan-86	69,243	44,91	83,15	141,2	78,62	77,2	89,9	79,46	58,03	85,03	69,05
fev-86	77,928	40,35	78,43	129,6	73,99	71,96	89,15	73,88	59,74	77,08	60,27
mar-86	74,236	43,62	79,98	136,8	75,67	74,67	93,13	73,88	65,31	75,2	56,8
abr-86	81,167	42,91	83,52	139,8	78,77	75,88	103,05	78,02	67,49	79,92	64,07
mai-86	86,76	43,76	87,17	144,6	82,13	79,3	99,54	83,62	72,55	85,58	72,05
jun-86	102,318	42,68	92,65	145	86,94	83,13	113,14	86,06	70,77	89,4	66,45
jul-86	108,415	43,23	100,55	159,4	94,08	89,33	114,03	94,43	65,08	102,34	76,89
ago-86	108,225	42,31	99,66	157,5	93,21	89,7	110,05	91,84	66,03	98,61	74,07
set-86	101,506	42,99	105,11	158,8	98,15	93,18	119,7	97,01	78,22	101,3	80,6
out-86	98,699	44,61	109,78	166,5	102,5	97,26	123,34	101,76	78,46	107,48	86,41
nov-86	94,583	42,61	97,03	151,4	90,87	85,97	111,55	90,76	65,2	97,48	80,81
dez-86	79,625	44,61	87,19	141	82,22	80,68	94,01	81,03	52,29	89,01	78,51

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)



**Tabela de Séries de Produção Industrial por Segmento (Continuação).**

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-87	86,826	44,86	88,73	148,6	83,63	81,88	97,84	82,78	58,83	89,11	75,93
fev-87	98,45	39,12	88,7	144,4	83,08	79,24	101,18	83,54	64,24	88,28	71,83
mar-87	90,24	42,37	91,93	151,8	86,27	83,71	106,04	84,18	64,03	89,21	72,44
abr-87	100,607	40,99	91,12	148	85,43	82,28	106,15	83,9	66,68	87,95	70,89
mai-87	93,442	42,44	92,13	151,2	86,46	83,41	106,26	84,8	64,87	89,74	63,51
jun-87	103,744	41,42	94,39	146,4	88,4	84,89	106,82	85,98	65,61	91,04	55,05
jul-87	94,29	43,55	93,9	148,6	88,14	86,72	104,74	83,41	48,65	93,38	59,12
ago-87	92,287	42,69	94,73	145,5	88,82	86,84	96,89	86,63	60,14	93,74	65,38
set-87	91,059	42,63	99,29	147,8	92,9	89,21	104,5	92,72	68,67	98,88	70,53
out-87	85,057	44,88	101,57	153,9	95,14	91,59	108,17	94,15	70,15	100,26	76,92
nov-87	90,708	44,32	94,49	146,9	88,75	83,28	106,4	90,67	69,32	95,97	76,96
dez-87	81,664	45,4	83,7	128,2	79,16	76,23	93,12	79,67	54,69	86,41	77,74
jan-88	68,263	44,88	80,46	131,2	76,21	76,72	88,27	74,1	48,88	81,04	76,48
fev-88	79,018	42,42	80,4	129,5	75,93	74,96	96,15	72,69	53,77	77,53	65,94
mar-88	91,505	45,74	91,68	144,9	86,36	83,89	112,66	84,1	68,68	87,52	72,13
abr-88	75,223	43,01	83,51	131,6	78,77	77,96	100,65	74,78	59,7	78,29	69,02
mai-88	80,875	41,36	86,73	136,9	81,52	80	101,28	78,77	61,82	82,83	63,46
jun-88	91,476	41,23	96,08	142,4	89,89	87,21	106,68	89,01	67,99	94,22	71,36
jul-88	82,9	43,68	95,86	146,7	89,92	87,77	103,34	88,58	61,27	95,92	63,87
ago-88	86,914	43,33	101,98	152,5	95,38	92,81	106,95	95,26	75,45	99,94	70,99
set-88	81,05	41,89	98,01	145,1	91,69	88,44	103,06	92,53	69,92	98,21	74,83
out-88	82,169	43,46	93,27	139,6	87,57	85,01	98,77	88,33	68,19	93,27	73,81
nov-88	69,923	41,98	87,78	133	82,51	77,78	102,77	83,05	68,42	86,25	74,43
dez-88	61,961	43,61	80,91	120	76,49	75,44	91,73	75,1	56,34	79,84	80,05
jan-89	61,435	45,2	78,72	126,6	74,67	74,71	89,1	73,57	56,58	77,75	73,11
fev-89	59,249	39,59	72,39	119,2	68,49	68,53	84,8	65,89	51,05	69,5	64,33
mar-89	71,772	42,75	83,29	134,6	78,55	78,04	87,19	78,4	63,51	81,77	74,79
abr-89	77,848	41,14	81,62	132,8	76,92	77,33	83,25	75,4	54,84	80,74	76,55
mai-89	87,36	44,64	91,44	144,1	86,03	84,77	95,95	84,95	63,04	90,56	84,82
jun-89	101,938	43,78	100,33	150	93,93	90,08	112,73	93,25	71,62	98,58	88,77
jul-89	100,329	45,67	103,08	149,7	96,57	92,94	113,24	94,89	71,27	100,87	79,57
ago-89	103,429	47,05	109,6	157,5	102,54	96,92	122,02	102,8	82,24	107,57	86,09
set-89	82,71	46,12	102,16	145,8	95,79	91,12	113,75	95,32	71,78	101,25	85,65
out-89	91,227	47,56	105,21	147,2	98,64	93,82	110,33	100,31	72,41	107,6	92,55
nov-89	86,373	45,99	96,74	138,9	90,91	86,17	108,49	91,1	66,17	97,59	90,46
dez-89	72,072	47,55	83,08	115,2	78,8	77,53	94,76	76,53	54,03	82,51	85,58
jan-90	65,119	47,44	82,68	126,4	78,42	77,12	91,51	78,07	58,5	83,03	88,82
fev-90	61,266	43,42	78,51	118,8	74,33	73,67	91,09	71,07	58,34	73,87	79,18
mar-90	68,417	47,13	79,89	123,7	75,89	77,53	87,83	71,65	55,31	75,65	73,11
abr-90	48,275	44,16	57,59	87,73	55,62	56,14	55,48	57,38	35,07	63,69	68,68
mai-90	66,969	44,6	81,08	129,1	76,74	72,8	83,15	83,85	69,11	87,06	89,2
jun-90	81,021	43,69	83,11	135,4	78,47	76,86	79,66	81	51,08	89,39	81,59
jul-90	88,771	45,27	94,2	144,1	88,57	86,17	87,77	90,42	62,09	98,07	79,42
ago-90	92,316	46,7	100,12	150,7	94,01	88,33	103,15	98,6	77,86	103,53	82,46
set-90	88,135	46,43	93,97	135,8	88,46	85,65	93,75	90,75	71,8	95,23	82,14
out-90	93,252	46,64	97,01	139	91,22	86,9	96,4	96,72	77,69	101,1	91,37
nov-90	83,368	47,66	86,81	120,6	82,16	77,56	86,74	89,75	72,13	93,79	95,92
dez-90	62,151	48,59	67,85	82,17	65,23	64,88	70,81	68,19	44,48	74,76	92,79

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

Tabela de Séries de Produção Industrial por Segmento (Continuação).

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-91	59,68	48,3	69	94,56	66,23	66,68	67,72	69,66	48,93	75,18	89,91
fev-91	49,87	43,81	63,36	103,9	60,75	61,45	71,34	59,59	44,17	63,66	76,6
mar-91	62,29	45,59	70,24	139,5	66,97	66,3	76,72	70,93	57,47	74,4	85,92
abr-91	77,81	46,43	80,82	151,5	76,32	75,97	85,15	80,63	61,17	85,75	107,84
mai-91	80,38	48,81	85,62	153,5	80,8	79,57	87,46	85,38	67,09	90,14	102,42
jun-91	74,87	47,08	86,66	141,2	81,51	78,21	91,88	87,99	70,05	92,65	108,45
jul-91	89,4	48,37	95,86	148,6	89,69	86,1	97,48	99,53	79,62	104,68	108,94
ago-91	88,02	47,5	96,82	144,8	90,42	87,1	94,11	100,98	80,23	106,37	106,31
set-91	83,34	36,67	89,14	129,6	82,36	77,83	95,67	93,59	74,76	98,47	102,27
out-91	85,31	50,82	93,27	127,8	87,73	84,48	93,69	98,71	74,54	105,07	113,8
nov-91	74,02	48	81,99	107,2	77,53	74,47	87,12	85,13	67,23	89,78	96,7
dez-91	52,32	48,4	66,48	77,46	64,02	64,62	65,8	65,71	42,46	71,96	86,61
jan-92	50,08	50,15	67,39	91,82	65,02	66,5	65,11	65,92	42,82	72,12	82,97
fev-92	62,78	45,57	71,96	111,3	68,44	68,08	80,85	69,66	54,51	73,6	73,14
mar-92	67,84	46,55	75,04	138,3	71,27	73,58	77,15	69,39	47,38	75,28	76,1
abr-92	67,35	45,14	74,09	138	70,25	71,94	79,29	68,31	46,99	74	73,65
mai-92	70,88	47,33	77	135,8	73,07	74,8	75,1	73,17	54,43	78,12	92,79
jun-92	70,55	45,32	81,61	130,7	76,86	76,31	80,1	80,58	57,71	86,66	82,92
jul-92	77,83	47,57	85,53	127,6	80,56	78,32	84,26	87,97	57,49	96,16	78,15
ago-92	65,16	47,39	83,69	124,5	78,94	77	80,4	86,34	59,02	93,65	76,67
set-92	66,71	46,34	83,51	120,4	78,66	76,84	82,8	85,55	62,59	91,63	78,45
out-92	61,5	47,54	85,06	117,6	80,17	77,38	83,87	89,69	66,05	95,94	91,69
nov-92	67,85	46,78	82,25	114,8	77,62	73,52	82,87	89,97	67,42	95,92	90,94
dez-92	50,09	48,09	72,14	99,67	68,95	66,45	72,79	77,43	51,33	84,43	90,83
jan-93	51,22	47,25	70,86	104,6	67,71	67,35	66,01	74,2	53,57	79,68	81,44
fev-93	61,74	42,93	71,3	111,5	67,57	67,48	72,17	71,24	54,61	75,6	76,57
mar-93	80,84	46,09	85,72	142	80,55	79,84	90,71	85,3	70,71	89,02	90,45
abr-93	81,84	44,43	80,86	131	76,12	75,98	83,26	79,38	68,14	82,19	79,35
mai-93	97	46,43	87,57	130,2	82,22	80,9	87,35	87,53	72,67	91,32	94,77
jun-93	98,17	45,48	88,39	124,1	82,82	80,98	86,57	89,04	71,93	93,46	89,72
jul-93	86,97	47,66	92,43	128,9	86,62	83,94	87,17	95,43	73,12	101,29	91,36
ago-93	77,74	49,24	92,76	125	87,11	83	95,75	95,62	80,07	99,57	89,18
set-93	63,63	47,55	89,24	119,1	83,84	79,03	96,07	93,13	79,52	96,55	89,51
out-93	58,49	50,05	89,34	119,2	84,24	80,42	89,68	93,37	80,21	96,67	98,69
nov-93	61,32	48,59	88,17	116,2	83,02	78,19	94,51	93,53	86,16	95,2	100,85
dez-93	55,95	50,76	78,47	100	74,82	71,79	86,21	82,34	71,37	85,06	92,34
jan-94	53,47	48,92	77,34	104,1	73,58	72,54	81,27	77,26	70	78,97	78,25
fev-94	57,53	47,04	73,57	105,4	70,06	69,63	81,23	70,77	65,82	71,86	79,69
mar-94	75,16	49,83	89,71	132,7	84,51	82,72	103,62	86,44	86,98	85,9	90,88
abr-94	62,77	48,85	81,2	123,6	76,95	77,53	86,74	75,74	72,61	76,29	88,84
mai-94	68,67	50,34	91,72	130,4	86,32	84,22	101,09	88,42	87,75	88,22	92,87
jun-94	74,26	48,86	91,75	120,6	86,18	82,79	101,04	90,14	78,27	93,07	94,01
jul-94	78,4	49,43	93,76	125,6	88,02	83,72	100,39	94,75	79,87	98,52	81,9
ago-94	83,43	52,66	102,5	133,8	96,06	89,91	114,93	105,5	92,95	108,57	105,85
set-94	77,89	47,63	100,19	133,3	93,41	86,91	115,07	102,19	89,14	105,42	113,72
out-94	73,43	48,59	99,68	135,4	93,09	87,8	113,25	100,15	89,64	102,67	115,74
nov-94	80,34	48,26	99,81	136	93,14	87,22	116	102,52	96,57	103,74	122,99
dez-94	68,06	53,08	93,3	126,5	88,06	84,57	114,1	91,49	82,86	93,51	121,34

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

Tabela de Séries de Produção Industrial por Segmento (Continuação).

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-95	67,03	53,64	90,92	127,3	86,05	82,74	111,56	88,39	76,68	91,29	114,18
fev-95	74,42	48,38	87,02	121,8	82,02	78,23	111,18	83,39	84,29	82,77	105,15
mar-95	94,9	53,33	102,01	145,3	95,7	90,73	131,44	98,7	102,8	97,12	131,36
abr-95	90,11	51,61	91,05	135,2	85,92	84,03	108,89	86,6	89,91	85,29	118,82
mai-95	97,62	30,88	93,18	144	85,18	79,27	113,05	94,29	108,04	90,01	105,93
jun-95	94,17	52,4	94,94	122,7	89,4	84,97	108,17	95,14	96,46	94,36	108,67
jul-95	94,75	54,47	93,61	115,5	88,5	83,61	103,74	96,7	87,08	98,98	105,59
ago-95	86,61	54,86	96,49	104,8	91,06	84,16	97,96	106,73	108,12	105,87	114,73
set-95	74,75	51,75	92,45	100,6	87,15	81,39	91,02	100,43	94,83	101,56	118,27
out-95	81,1	55,58	96,1	107,4	90,81	86,16	88,08	105,34	101,49	105,96	119
nov-95	83,86	53,67	94,14	106,4	88,87	82,72	91,17	105,95	105,11	105,73	126,87
dez-95	69,01	51,69	81,5	88,77	77,57	73,66	75,59	91,38	81,4	93,78	121,03
jan-96	65,9	56,39	81,84	94,44	78,45	75,86	76,37	89,88	83,41	91,31	111,79
fev-96	65,46	53,03	80,53	98,31	76,88	74,99	82,91	83,33	85,93	82,23	108,05
mar-96	78,87	54,11	89,12	114,8	84,52	82,42	89,82	92,33	100,79	89,55	106,31
abr-96	80,95	53,87	88,42	118,6	83,88	82,69	85,67	90,63	100,07	87,57	111,21
mai-96	88,51	56,13	95,97	121,9	90,76	87,1	91,8	102,34	110,92	99,49	107,88
jun-96	73,53	54,08	91	110,8	86,17	82,6	84,44	96,27	93,96	96,49	94,78
jul-96	88,39	56,33	103,54	121,4	97,39	92,1	95,2	112,66	115,11	111,47	113,17
ago-96	79,24	54,67	103,03	121,8	96,75	90,93	90,83	114,13	118,79	112,31	110,5
set-96	76,13	54,84	100,46	114,5	94,55	89,68	89,61	109,74	115,6	107,6	112,02
out-96	79,9	58,64	104,83	118,4	98,82	92,99	93,47	116,76	124,76	113,99	122,49
nov-96	77,8	57,41	99,86	111,6	94,33	88,01	93,83	112,28	123,03	108,76	122,01
dez-96	67,2	61,39	87,32	90,67	83,87	81,02	84,66	93,77	91,27	94,06	123,1
jan-97	68,6	59,08	87,67	99,66	83,88	82,07	77,19	94,26	104,28	91,04	112,3
fev-97	74,66	53,65	83,42	98,9	79,5	78,09	83,91	84,37	95,57	80,85	94,73
mar-97	86,33	61,02	93,05	108,8	88,84	87,84	90,84	94,15	109,09	89,54	98,83
abr-97	93,99	58,64	95,89	117,8	91,01	88,55	91,19	100,52	120,69	94,41	130,06
mai-97	84,83	61,79	98,18	114,2	93,42	92,19	87,56	100,17	114,06	95,82	105,18
jun-97	94,69	59,92	100,02	111,5	94,8	91,17	99,32	103,57	113,41	100,34	101,69
jul-97	94,51	62,23	104,27	116,2	98,78	95,57	97,65	109,01	109,07	108,5	111,17
ago-97	85,41	61,14	104,51	109,3	98,88	94,6	97,53	109,97	112,02	108,91	109,16
set-97	89,38	59,25	107,26	107,3	101,04	94,79	103,2	116,2	125,11	113,18	116,3
out-97	92,32	56,37	110,64	106	103,63	95,97	105,47	121,19	128,17	118,69	119,96
nov-97	89,55	57,82	98,13	93,15	92,89	87,1	96,32	106,87	106,12	106,61	118,1
dez-97	72,35	66,25	83,54	69,09	81,16	79,4	79,34	87,85	70,21	92,43	121,6
jan-98	64,59	63,34	83,55	79,42	80,82	80,77	80,02	83,23	71,51	86,17	108,55
fev-98	73	58,66	81,83	84,26	78,74	78,17	82,62	80,69	74,42	82,09	92,95
mar-98	84,46	65,59	95,66	99,28	91,67	90,02	101,67	95,15	96,9	94,25	123,18
abr-98	85,36	62,73	92,07	97,85	88,19	86,84	95,58	91,29	96,14	89,53	99,82
mai-98	94,68	67,28	98,83	106,8	94,66	92,37	102,1	98,44	103,77	96,51	101,56
jun-98	98,49	65,26	99,12	102,3	94,65	92,62	97,39	99,23	95,3	99,9	101,17
jul-98	105,92	68,49	103,48	103,9	98,86	95,61	103,38	106,11	88,46	110,61	109,67
ago-98	96,22	70,05	101,06	103,9	96,94	94,27	93,74	105,22	92,73	108,27	103,8
set-98	92,27	66,09	100,12	102,1	95,64	91,9	91,78	106,35	97,22	108,45	108,68
out-98	95,26	69,46	98,73	105,7	94,85	91,45	89,38	105,71	86,76	110,57	115,95
nov-98	99,67	70,96	94,23	102,2	91,1	87,68	83,98	102,83	83,51	107,81	117,13
dez-98	77,99	76,45	79,89	79,75	79,26	78,09	70,58	87,09	65,11	92,88	127,31

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

**Tabela de Séries de Produção Industrial por Segmento (Continuação).**

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-99	63,38	75,36	78,67	84,93	78,07	79,66	71,38	79,05	66,53	82,23	93,17
fev-99	73,48	65,63	76,39	83,98	74,87	76,29	74,07	74,06	59,12	77,94	87,49
mar-99	97,1	72,95	91,76	101,1	89,18	89,59	88,92	92,06	80,48	94,91	112,26
abr-99	90,28	70,27	88,4	97,28	85,95	87,16	79,71	88,15	76,82	90,95	127,82
mai-99	99,97	71,39	94,93	105,3	91,8	92,88	83,21	93,49	79,07	97,13	96,6
jun-99	103,74	69,32	95,22	104,2	91,78	91,72	86,94	94,87	77,62	99,31	96,12
jul-99	97,16	73,08	97,02	106,4	93,83	93,65	82,79	99,54	78,08	105,14	99,57
ago-99	92,16	73,95	100,76	106,3	97,18	96,43	84,47	104,65	90,72	108,11	106,3
set-99	93,29	72,55	99,71	105,1	96,12	94,24	84,75	105,15	93,57	107,94	113,03
out-99	88,92	74,63	101,43	106,8	97,88	96,84	86,21	105,2	89,57	109,13	121,87
nov-99	85,24	74,71	98,77	106,2	95,57	94,42	88,38	103,45	92,91	105,96	124,59
dez-99	78,76	78,78	87,31	84,73	86,06	86,67	82,06	88,81	69,66	93,8	130,69
jan-00	57,38	77,3	82,75	91,05	81,89	84,97	71,82	81,11	73,03	83,03	92,43
fev-00	76,16	71,18	89,25	101,4	86,8	87,39	87,76	87,47	88,5	86,8	92,45
mar-00	82,98	79,3	94,88	109,6	92,74	94,94	89,73	91,63	89,27	91,88	133,04
abr-00	82,35	75,65	91,02	105,3	88,91	92,27	83,32	85,8	88,83	84,56	116,07
mai-00	97,9	77,81	100,79	114,3	97,71	99,15	95,7	96,68	99,92	95,34	114,46
jun-00	93,25	78,69	101,73	107,5	98,63	99,4	96,86	97,64	95,34	97,85	98,43
jul-00	96,74	80,33	103,54	112,3	100,42	101,08	94,8	101,49	95,8	102,64	101,75
ago-00	101,7	81,61	108,59	113,2	104,98	103,29	106,25	109,3	109,05	108,9	112,84
set-00	87,42	84,44	101,95	106,5	99,54	98,34	102,07	101,56	96,8	102,45	113,75
out-00	96,68	87,94	107,69	109,5	105	103,11	101,03	111,03	107,59	111,5	125,93
nov-00	96,92	87,94	102,67	106,3	100,61	97,57	102,54	108,4	110,77	107,25	128,55
dez-00	72,74	93,12	92,82	88,05	92,66	91,66	90,74	96,02	97,7	95,14	130,9
jan-01	58,47	87,37	92,71	94,46	91,83	93,05	94,32	89,95	88,52	89,95	103,37
fev-01	65,68	80,02	90,05	96,28	88,6	89,41	96,8	84,96	91,89	82,64	94,7
mar-01	83,44	84,02	103,12	109,1	100,51	100,97	112,13	97,62	109,48	93,87	119,5
abr-01	78,65	81,38	96,54	100,6	94,43	95,04	105,08	91,04	99,78	88,18	131,74
mai-01	94,55	80,95	105,76	108,5	102,44	101,68	113,86	101,91	113,09	98,32	111,12
jun-01	91,45	82,82	100,09	100,4	97,73	97,2	107,1	95,82	92,98	96,19	106,72
jul-01	92,33	86,07	104,49	100,6	101,97	100,95	112,44	101,35	89,39	104,27	104,3
ago-01	106,85	85,21	108	105,3	104,93	101,16	123,32	108,31	92,93	112,16	108,2
set-01	84,71	83,59	100,42	96,37	98,12	95,44	107,16	101,27	86,85	104,88	111,01
out-01	90,36	79,36	105,3	105,1	101,85	97,69	110,6	108,76	98,92	111,05	122,71
nov-01	94,37	85,86	101,03	101	98,93	93,82	102,58	110,13	102,96	111,66	123,68
dez-01	91,31	92,04	86,14	79,42	86,69	85,2	88,41	90,55	78,91	93,43	129,06
jan-02	67,17	93,47	90,61	92,78	90,75	91,39	90,71	91,04	85,07	92,3	92,06
fev-02	92,65	88,19	87,83	93,51	87,85	88,75	88,46	86,64	83,25	87,36	85,13
mar-02	104,23	101,36	96,82	101,2	97,04	98,46	100,27	95,39	100,89	94,22	89,32
abr-02	110,46	99,56	100,13	106,3	100,11	99,88	106,17	99,37	111,57	96,78	92,2
mai-02	94,67	102,12	100,39	101,7	100,48	102,96	103,38	97,55	101,61	96,68	91,71
jun-02	100,02	101,7	96,54	95,57	96,8	101,14	95,84	91,57	88,74	92,17	89,03
jul-02	105,19	105,43	104,49	99,9	104,53	106,05	105,89	101,92	99,32	102,47	88,53
ago-02	111,68	106,1	105,3	103,5	105,34	105,21	100,78	105,78	96,9	107,67	99,09
set-02	94,97	100,39	104	101	103,82	102,87	100,58	104,49	103,95	104,6	97,98
out-02	114,97	105,64	113,57	112,3	113,18	108,46	110,78	118,24	120,81	117,69	122,7
nov-02	101,59	100,29	106,61	108	106,3	102,06	104,15	111,66	117,32	110,46	122,06
dez-02	102,36	95,69	93,65	84,18	93,75	92,71	92,91	96,31	90,51	97,54	130,15

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

Tabela de Séries de Produção Industrial por Segmento (Continuação).

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-03	61,3	102,5	91,68	90,29	92,22	95,58	87,75	90,51	92,39	90,11	92,06
fev-03	91,77	94,98	90,01	92,59	90,26	91,85	92,37	88,2	94,64	86,83	89,43
mar-03	86,44	107,4	95,45	97,63	96,04	103,2	91,57	89,6	88,68	89,8	94,02
abr-03	90,69	103,31	94,97	92,73	95,38	100,2	94,45	90,47	98,86	88,69	83,41
mai-03	97,11	109,4	98,73	95,75	99,26	104,15	97,54	94,48	99,27	93,46	85,38
jun-03	93,96	99,14	94,8	92	95,02	100	92,93	89,68	89,99	89,61	82,42
jul-03	98,45	105,56	101,7	94,99	101,9	105,79	101,79	96,49	97,38	96,3	91,52
ago-03	99,74	109,57	102,06	98,47	102,44	105,35	101,17	98,49	98	98,6	88,24
set-03	107,41	106,05	108,07	100,8	107,97	107,96	110,69	106,22	116,91	103,95	95
out-03	97,77	109,2	114,16	108,5	113,92	111,15	124,24	114,25	129,02	111,11	109,28
nov-03	102,14	104,19	108,11	102	107,92	102,74	125,05	109,63	127,32	105,87	108,21
dez-03	82	105,31	97,87	80,28	98,23	96,31	106,37	99,96	103,08	99,3	131,66
jan-04	65,56	102,42	95,38	89,83	95,73	98,26	101,78	92,85	106,12	90,03	95,64
fev-04	67,69	99,14	91,73	90,85	92,09	96,19	102,25	86,57	97,9	84,16	90,66
mar-04	101,3	106,95	109	105,7	108,9	110,68	128,07	103,72	127,77	98,61	94,11
abr-04	98,21	104,08	102,51	100,3	102,59	105,73	117,68	96,5	121,52	91,18	95,31
mai-04	108,36	106,98	108,09	106,1	108,03	111,85	125,25	100,09	122,56	95,31	89,02
jun-04	97,6	108,36	107,83	109,8	107,86	111,31	124,66	100,26	122,22	95,59	82,33
jul-04	91,65	113,25	112,55	115,8	112,58	116,73	127,77	104,79	123,1	100,9	92,69
ago-04	105,64	117,76	116,03	117,5	116,11	117,32	132,37	110,43	133,43	105,55	94,4
set-04	104,22	112,75	116,22	113,3	116,05	115,08	127,3	114,33	137,53	109,4	112,92
out-04	101,79	115,93	117,71	116,8	117,62	116,64	130,2	116,13	140,63	110,93	120,29
nov-04	92,24	110,41	116,59	111,2	116,29	111,27	130,55	119,12	152,02	112,13	119,38
dez-04	85,09	112,43	106,1	84,81	106,41	103,57	119,57	108,86	120,62	106,37	130,76
jan-05	77,04	109,95	101	91,42	101,45	102,22	109	100,55	109,65	98,62	106,46
fev-05	75,65	100,6	95,64	95,68	95,89	97,16	103,46	93,63	117,37	88,59	92,5
mar-05	116,56	113,83	110,65	103,5	110,81	110,5	127,93	108,02	144,4	100,29	101,58
abr-05	111,5	118,4	108,63	106,1	109,12	109,81	120,77	106,84	143,26	99,11	105,87
mai-05	113,39	125,53	113,46	107,7	114,06	115	130,33	110,51	148,97	102,34	97,15
jun-05	107,97	124,94	114,24	106,6	114,77	114,73	135,07	111,17	151,05	102,7	98,6
jul-05	107,06	125,54	112,68	106,5	113,32	114,76	123,8	110,14	139,3	103,95	91,99
ago-05	128,98	127	120,05	110,6	120,39	118,03	137,19	120,1	151,11	113,51	104,36
set-05	111,33	124,66	115,54	107,3	115,99	114,03	136,03	114,4	138,19	109,34	112,71
out-05	114,85	128,43	117,39	107,7	117,94	116,02	132	118,03	144,26	112,45	120,91
nov-05	110,22	121,99	117,16	107,1	117,4	110,97	136,27	121,33	151,79	114,86	125,15
dez-05	106,41	123,12	108,62	85,36	109,34	103,86	128,02	114,18	138	109,12	137,65
jan-06	70,44	125,11	103,5	94,6	104,58	105,06	116,17	104,24	130,44	98,68	110,28
fev-06	108,15	113,47	100,42	98,29	101,07	99,45	114,7	101,4	135,62	94,13	107,79
mar-06	125,15	128,63	116,06	111,7	116,68	113,96	140,82	115,97	160,52	106,51	111,7
abr-06	100,08	123,98	106,34	101,8	107,21	108,06	120,47	105,06	143,93	96,8	102,51
mai-06	120,62	133,87	118,81	111,6	119,55	119,53	138,34	116,73	160,37	107,47	104,54
jun-06	116,98	126,22	113,5	105	114,13	114,3	132,36	111,4	144,77	104,32	98,43
jul-06	112,94	133,81	116,41	109,5	117,27	118,78	134,34	113,39	140,82	107,56	104,01
ago-06	121,71	134,06	123,79	114,5	124,3	122,08	146,5	122,74	159,3	114,98	113,74
set-06	112,73	130,8	117,18	107,4	117,86	115,02	136,41	117,83	145,48	111,95	121,58
out-06	121,98	134,58	123,22	111,6	123,78	118,14	144,54	126,43	161,92	118,89	126,46
nov-06	122,34	132,75	121,7	106,9	122,25	114,57	146,8	126,35	165,66	118	136,14
dez-06	104,06	132,86	108,44	81,7	109,65	105,49	135,77	111,79	125,25	108,93	149,45

Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)


**Tabela de Séries de Produção Industrial por Segmento (Continuação).**

MÊS / ANO	FARMACEUTICA	EXTRATIVA MINERAL	INDÚSTRIA DE TRANSFORMAÇÃO	TEXTIL	INDÚSTRIA GERAL	BENS INTERMEDIÁRIOS	BENS DE CAPITAL	BENS DE CONSUMO	BENS DE CONSUMO DURÁVEIS	BENS DE CONSUMO NÃO DURÁVEIS	BEBIDAS
jan-07	79,97	131,5	108,06	93,77	109,22	108,37	136,75	107,24	136,22	101,08	124,47
fev-07	100,62	120,57	103,21	98,8	104,07	102,9	131,25	101,43	132,08	94,92	108,73
mar-07	108,71	135,85	120,45	113,7	121,21	119,42	158,65	117,76	168,26	107,04	117,63
abr-07	100,21	130,92	112,68	105,7	113,58	113,67	142,27	109,71	151,63	100,81	114,73
mai-07	127,05	138,25	124,82	115,7	125,48	123,16	165,99	121,95	169,96	111,75	113,08
jun-07	128,69	137,05	120,81	110,7	121,61	120,31	154,91	118,08	156,24	109,98	102,05
jul-07	121,44	143,37	124,56	114,6	125,5	124,62	160,02	120,62	162,53	111,72	104,25
ago-07	131,67	143,12	131,97	118	132,52	127,39	176,25	130,45	180,02	119,92	119,41
set-07	113,72	135,98	123,58	111,3	124,19	118,99	164,85	123,07	164,49	114,28	121,34
out-07	119,74	140,17	136,66	119,5	136,83	128,62	184,73	137,79	191,43	126,39	136,49
nov-07	121,68	137,41	130,11	112,8	130,47	120,04	182,01	133,81	184	123,15	142
dez-07	109,26	146,98	115	88,07	116,58	112,65	162,73	115,31	138,27	110,43	156,98
jan-08	91,33	141,96	117,54	94,27	118,75	117,08	157,32	115,92	157,55	107,08	133,59
fev-08	77,7	132,1	113,24	104,5	114,18	113,59	163,52	107,09	159,33	96	109,57
mar-08	107,65	140,27	122,15	110	123,04	120,09	179,64	117,06	179,34	103,83	109,48
abr-08	128,74	136,33	124,36	112	124,96	120,25	184,47	120,37	185,58	106,52	110,19
mai-08	136,71	148,55	127,49	109,4	128,53	126,02	177,75	123,5	179,41	111,62	111,81
jun-08	134,22	146,93	128,6	110,5	129,51	126,61	189,68	122,77	179,99	110,62	107,71
jul-08	141,74	155,6	135,5	117,4	136,5	134,06	198,13	128,17	178,5	117,48	108,55
ago-08	154,43	155,35	134,03	114,8	135,09	129,6	195,57	130,09	185,09	118,41	116,82
set-08	147,42	149,11	135,69	113,7	136,36	126,86	207,37	133,91	188,92	122,22	125,37


Fonte: IBGE (Instituto Brasileiro de Geografia e Estatística)

## APÊNDICE 02

### Gráficos dos Resultados das Simulações da 1ª. Estratégia.




Segmento da Indústria de Transformação




Segmento da Indústria Têxtil

**Legenda:**

- Linha Azul - Dados Reais da 1ª. Estratégia
- Linha Magenta- Resultado da Saída da Rede pela Introdução dos dados Reais
- Linha Verde - Previsão de Demanda



Segmento da Indústria Geral




Segmento da Indústria de Bens Intermediários


**Legenda:**

- Linha Azul - Dados Reais da 1ª. Estratégia
- Linha Magenta - Resultado da Saída da Rede pela Introdução dos dados Reais
- Linha Verde - Previsão de Demanda






Segmento da Indústria de Bens de Capital




Segmento da Indústria de Bens de Consumo

**Legenda:**

- Linha Azul - Dados Reais da 1ª. Estratégia
- Linha Magenta- Resultado da Saída da Rede pela Introdução dos dados Reais
- Linha Verde - Previsão de Demanda




Segmento da Indústria de Bens de Consumo Duráveis



Segmento da Indústria de Bens de Consumo Não Duráveis

**Legenda:**

- |                |   |  |
|----------------|---|--|
| Linha Azul     | - | Dados Reais da 1ª. Estratégia                              |
| Linha Magenta- |   | Resultado da Saída da Rede pela Introdução dos dados Reais |
| Linha Verde    | - | Previsão de Demanda  |





Segmento da Indústria de Bebidas

**Legenda:**



- Linha Azul - Dados Reais da 1ª. Estratégia
- Linha Magenta- Resultado da Saída da Rede pela Introdução dos dados Reais
- Linha Verde - Previsão de Demanda

### APÊNDICE 03



#### Gráficos da Distribuição de Probabilidade (Direita) e Função de Auto-Correlação (Esquerda) - 1ª. Estratégia





Segmento da Indústria de Tranformação -  $\mu = 0,0003$  e  $\sigma = 3,7683$




Segmento da Indústria Têxtil -  $\mu = -0,0247$  e  $\sigma = 6,5051$





Segmento da Indústria Geral -  $\mu = -0,0063$  e  $\sigma = 3,4469$





Segmento da Indústria de Bens Intermediários -  $\mu = 0,0000$  e  $\sigma = 3,1508$





Segmento da Indústria de Bens de Capital -  $\mu = 0,0039$  e  $\sigma = 6,9899$



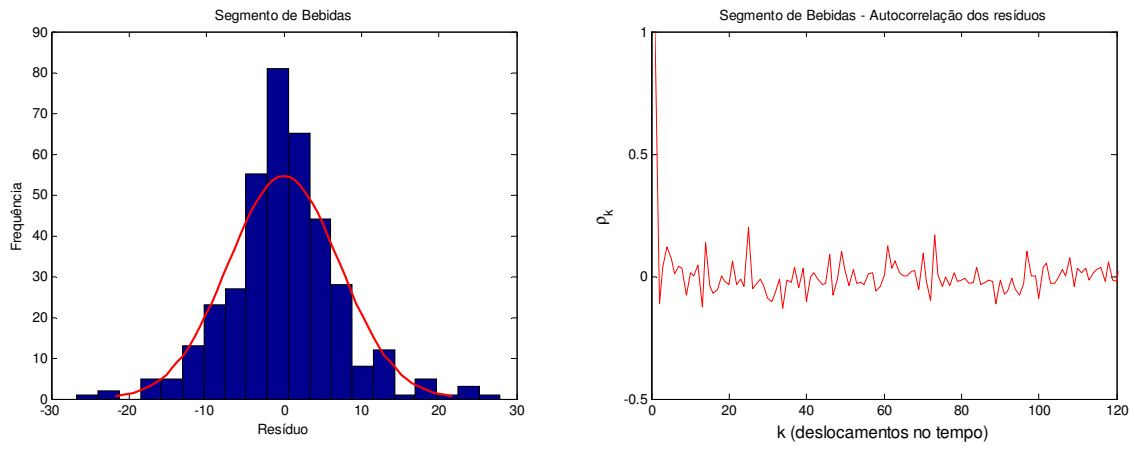
Segmento da Indústria de Bens de Consumo -  $\mu = 0,0256$  e  $\sigma = 4,1866$



Segmento da Indústria de Bens de Consumo Duráveis -  $\mu = -0,0031$  e  $\sigma = 7,3921$




Segmento da Indústria de Bens de Consumo Não Duráveis -  $\mu = -0,0104$  e  $\sigma = 3,7914$




Segmento da Indústria de Bebidas -  $\mu = -0,0026$  e  $\sigma = 7,2130$

## APÊNDICE 04

### Gráficos da Previsão de Demanda - 1ª. Estratégia



Segmento da Indústria de Transformação - MSE= 2,6381 e MAE= 7,2603




Segmento da Indústria Têxtil - MSE= 2,7127 e MAE= 6,8294


#### **Legenda:**

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural






Segmento da Indústria Geral - MSE= 2,5098 e MAE= 6,9970




Segmento da Indústria de Bens Intermediários - MSE= 1,7803 e MAE= 5,1607

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural



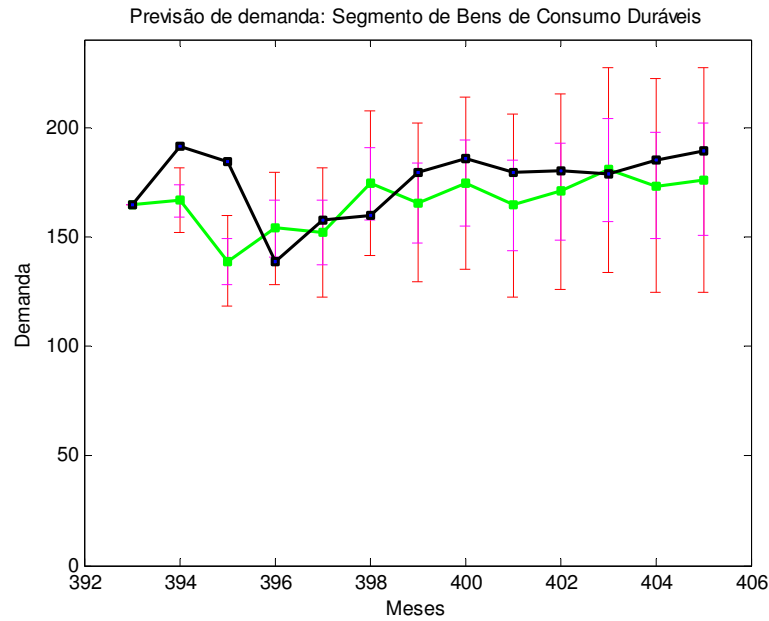
Segmento da Indústria de Bens de Capital - MSE= 5,8575 e MAE= 17,9060




Segmento da Indústria de Bens de Consumo - MSE= 2,8293 e MAE= 7,3447

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural




Segmento da Indústria de Bens de Consumo Duráveis - MSE= 5,3399 e MAE= 15,2202



Segmento da Indústria de Bens de Consumo Não Duráveis - MSE= 2,3334 e MAE= 6,7080.

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural



Segmento da Indústria de Bebidas - MSE= 4,1866 e MAE= 10.5392

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 1ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural

**APÊNDICE 05**  
**Tabelas de Pesos e Biases da TDNN (N<sup>13-5-1</sup>) - 1ª. Estratégia**

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
-390,4265	23,9804	-0,0073	52,6552	-84,0099	-1,1198	-47,0621	100,9712	
413,2948	-49,6199	0,0089	-24,2953	66,2948	0,2394	-26,9383		
-101,3802	-65,7118	0,0017	1,5740	24,7167	70,0174	-1,5439		
284,2329	-24,0077	-0,0009	-58,0945	29,9015	-2,1111	-12,9099		
-183,5243	36,1077	-0,0010	28,2239	-13,5069	1,4051	-219,1752		
1040,1358	121,8816	0,0029	-22,9102	-30,0108				
466,8085	92,1376	0,0009	-20,4794	-76,3998				
-1148,0853	-49,8771	-0,0026	-10,5001	43,9443				
121,7586	-34,4623	0,0019	-11,4562	6,9144				
-546,2254	55,9992	-0,0013	9,5264	10,7631				
402,3025	-19,1649	-0,0018	-9,2397	2,7307				
-419,8201	-63,1352	0,0037	2,1282	7,2565				
-276,2237	-39,6516	0,0099	40,4204	9,5781				

**Segmento da Indústria de Transformação**

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
0,1773	9,5214	0,8376	0,0103	0,8290	1,6383	-381,9420	-24,8062	
0,7854	14,4473	-0,5737	-0,0142	-1,2337	-2,0828	-492,6268		
16,6878	-12,6425	0,5077	0,0009	1,6275	-2,1248	39,9494		
-15,1476	6,9799	0,1767	-0,0019	0,0850	-51,1153	2,2608		
-2,3167	8,9693	-0,4961	0,0003	-1,5312	-142,6525	-68,2414		
2,6235	8,4300	-0,1063	-0,0023	1,0676				
1,3977	-15,0090	-0,2968	0,0032	1,2660				
10,7494	3,8049	0,9592	-0,0004	-0,7150				
-12,1375	-0,3319	-0,6680	-0,0024	-1,2227				
-11,7073	-6,3000	0,4273	-0,0011	-0,1339				
6,2082	2,9690	-0,2292	0,0047	0,6591				
16,7663	-12,5780	0,1034	-0,0009	-1,0116				
-12,4079	-6,8520	-0,9575	-0,0152	0,7338				

**Segmento da Indústria Têxtil**

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
-15,2787	1,2348	0,0089	-9,8705	0,0882	-0,1609	-3,5451	99,8336	
-77,1481	8,6561	-0,0093	-8,1589	0,2916	0,0034	-5,8117		
-38,4362	-23,1439	-0,0015	-4,4533	0,1332	-68,3235	1,5335		
7,0567	20,7016	-0,0002	11,9074	-0,3198	-1,2163	5,4497		
-16,9171	15,4006	-0,0003	5,0712	-0,3536	0,6570	-21,5878		
57,0345	-34,3017	-0,0011	-3,8540	0,5301				
-39,4815	19,0636	0,0005	9,5571	0,6358				
36,7384	-3,8472	-0,0001	12,9359	-1,5839				
-40,7583	-1,3076	-0,0014	0,4426	1,0190				
-42,6667	20,1669	0,0009	21,9844	-0,1724				
38,4159	6,4452	0,0018	1,5588	-0,1721				
22,0374	2,3775	-0,0042	0,7291	0,0691				
75,6616	-33,5260	-0,0093	-35,5094	0,1194				

**Segmento da Indústria Geral**

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
-4,0275	-0,1000	-0,0044	44,2416	-1,8369	22,1179	-11,6298	53,0024	
1,1878	115,8002	0,0055	30,8867	2,6324	-1,0421	60,8327		
-2,3794	-20,3202	0,0002	43,2205	4,0430	119,7507	-0,8572		
1,6663	-80,9197	0,0008	-39,1343	-1,7705	-0,0387	-25,8022		
0,8209	-30,7948	-0,0004	-8,1597	-1,9446	24,4368	6,5779		
-3,9920	80,8334	0,0003	-39,0167	3,3269				
2,8216	-83,2994	0,0003	-68,6691	0,9977				
2,9092	-26,4947	-0,0009	-14,7118	-2,4782				
0,8407	-18,4615	0,0004	-2,1926	0,6684				
1,5923	90,2734	-0,0003	45,4161	0,3293				
-2,5721	-40,9935	-0,0007	-112,2378	-0,5717				
-1,0530	22,3915	0,0019	64,9809	-3,5963				
4,2098	-27,9374	0,0058	69,4663	2,2338				

### Segmento da Indústria de Bens Intermediários

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
1,0060	-1,6769	2,5278	0,0060	-3,1324	2,9047	0,4820	32,7911	
-4,3210	2,4532	-3,7488	-0,0065	3,6057	74,8821	-10,4854		
0,1488	-0,0022	0,5737	-0,0012	-0,0896	1,6636	-133,3261		
0,8102	1,3412	-4,4849	0,0007	0,5814	-97,1243	1,3947		
1,0505	-0,0737	4,1114	0,0003	0,9302	-16,2042	-36,2316		
0,4825	-0,2346	4,0131	-0,0006	-0,2494				
0,0768	-0,3948	-11,7087	-0,0011	-1,5489				
5,6346	-2,6272	6,1845	0,0020	-0,9633				
1,0815	1,8139	8,7832	-0,0003	-2,2228				
0,3880	-1,8006	-1,4049	0,0006	0,4856				
-1,1319	2,7202	-4,4185	0,0002	1,9559				
1,7654	-0,3995	1,6795	-0,0026	-0,8463				
-4,6765	0,9902	-0,0221	-0,0083	-0,3702				

### Segmento da Indústria de Bens de Capital

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
73,7721	-5,3209	-0,0086	118,7621	2,6765	0,4562	2,6098	90,6310	
0,6240	14,6412	0,0109	-104,1440	-0,6896	0,8915	-139,0483		
-121,0734	0,4752	0,0024	189,0710	-3,9421	56,4101	-1,7795		
107,5683	-3,5070	-0,0002	389,2163	1,3968	0,4404	23,9372		
8,4234	-6,1234	0,0007	-230,1662	1,7845	4,2933	3,2865		
-36,5049	-1,8121	0,0024	135,3945	-0,3958				
-373,4260	1,7173	-0,0008	-533,6203	0,5727				
368,5912	4,9933	-0,0032	120,9423	-0,3955				
156,5063	0,3814	0,0026	61,0417	0,5211				
-42,0556	0,0183	-0,0019	279,5233	0,2080				
-166,7881	5,0504	-0,0012	-348,4535	-0,4772				
267,6924	-7,7509	0,0044	-219,0971	4,2727				
-236,4097	-0,8625	0,0112	190,8257	-4,4189				

### Segmento da Indústria de Bens de Consumo

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
3,0845	-0,0030	-4,3298	19,7956	-21,2081		8,0111	-0,8302	106,6726
-6,2970	0,0031	2,6936	10,1440	36,4522		182,0469	-0,6490	
4,7327	0,0009	-19,9567	-46,0008	-22,6515		-0,1284	23,6964	
-7,8911	0,0001	45,6912	29,1586	42,0601		0,6745	137,0733	
5,7495	-0,0005	19,1357	197,9607	54,3875		-0,4506	-1,3418	
0,1649	0,0001	35,3661	-64,4800	-24,4045				
6,5403	-0,0001	-6,2504	-107,6320	-4,5887				
1,6563	0,0002	8,3497	20,8596	-2,2499				
-3,8204	0,0008	3,3077	48,6138	8,8416				
-4,6907	-0,0004	37,8112	-180,8745	16,1331				
-1,3756	-0,0001	28,8316	-17,7954	-39,6040				
14,1952	0,0012	-19,6794	19,4752	1,2140				
-4,9885	0,0035	10,5385	66,8994	-25,7417				

### Segmento da Indústria de Bens de Consumo Duráveis

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
5,1537	-0,0066	17,1558	34,3933	4,1688		0,5912	-18,1639	101,8686
-105,9451	0,0097	-24,1782	20,5168	5,9735		61,9289	-1,6157	
119,1945	0,0020	8,1205	-57,9579	-0,7016		-1,7052	-23,4869	
-28,3482	0,0004	-8,5135	-48,5865	-6,3507		0,4331	4,4195	
-5,1555	0,0002	1,3597	50,2665	1,8848		-3,6568	-0,3310	
-51,3217	0,0022	3,5201	-4,2461	-2,6495				
53,2182	-0,0016	12,0627	93,5029	6,0661				
68,5470	-0,0029	-25,4644	-52,7794	2,2599				
-44,9766	0,0013	-10,2586	-26,5303	-5,0924				
-6,4553	-0,0010	-2,3600	-80,2091	-4,0195				
-2,9643	0,0007	14,2535	80,9148	-3,1478				
-45,5687	0,0030	7,7841	-13,9161	6,3941				
61,4576	0,0091	10,0328	10,4795	-1,8556				


### Segmento da Indústria de Bens de Consumo Não Duráveis

Pesos das entradas					Pesos da camada escondida		Biases	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_{i,4}$	$w_{i,5}$	$w_j$	$w_{0,j}$	$w_0$	
-0,7470	142,6295	9,6608	-25,8420	-0,0045		19,4027	31,9766	61,1538
-0,9787	-351,9726	-28,3491	-25,5998	0,0072		-0,7888	-353,3203	
-3,5125	847,3674	17,0408	57,9135	0,0031		0,9192	129,4692	
1,8254	-170,9407	12,7026	7,6007	-0,0020		0,7863	-2297,7500	
-0,5264	-231,3697	3,2293	-10,5183	0,0000		77,7844	-1,0426	
-1,7140	-42,7133	-1,3152	8,1344	-0,0002				
2,7856	-385,2289	-2,8299	-10,1909	0,0003				
-2,1208	-88,5138	-0,6612	-31,7800	-0,0013				
0,1200	437,1058	-10,5787	44,4624	0,0016				
1,7528	-16,9325	7,2692	-16,2587	-0,0002				
0,5300	238,5355	-12,1442	23,7017	0,0003				
2,6920	-320,1272	4,5117	-11,2091	0,0005				
2,0496	47,0537	6,0684	15,9693	0,0085				


### Segmento da Indústria de Bebidas

## APÊNDICE 06

### Gráficos dos Dados Transformados (Azul Tracejado) Aproximados pela Rede Neural (Vermelho Contínuo) - 2ª. Estratégia



#### Segmento da Indústria Farmacêutica




#### Segmento da Indústria de Extrativismo Mineral


#### **Legenda:**

- |                         |   |   |
|-------------------------|---|---|
| Linha Tracejada Azul    | - | Dados Transformados pela Regra da Diferença |
| Linha Contínua Vermelha | - | Valores Aproximados pela Rede Neural        |






Segmento da Indústria de Transformação




Segmento da Indústria Têxtil

**Legenda:**

Linha Tracejada Azul - Dados Transformados pela Regra da Diferença  
 Linha Contínua Vermelha - Valores Aproximados pela Rede Neural




Segmento da Indústria Geral




Segmento da Indústria de Bens Intermediários

**Legenda:**

Linha Tracejada Azul - Dados Transformados pela Regra da Diferença  
 Linha Contínua Vermelha - Valores Aproximados pela Rede Neural




Segmento da Indústria de Bens de Capital




Segmento da Indústria de Bens de Consumo

**Legenda:**

Linha Tracejada Azul	-	Dados Transformados pela Regra da Diferença
Linha Contínua Vermelha	-	Valores Aproximados pela Rede Neural



Segmento da Indústria de Bens de Consumo Duráveis



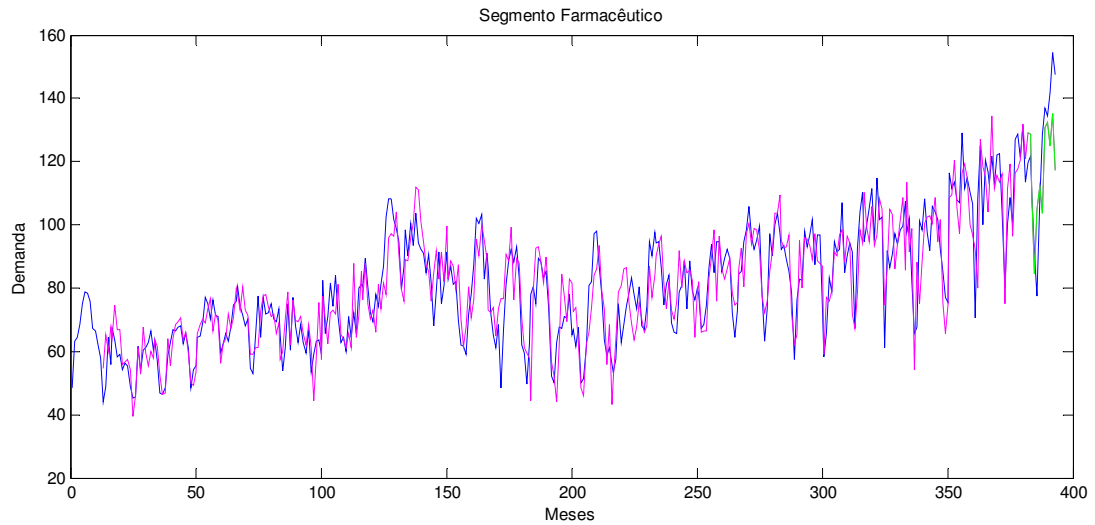
Segmento da Indústria de Bens de Consumo Não Duráveis

**Legenda:**


- |                         |   |   |
|-------------------------|---|---|
| Linha Tracejada Azul    | - | Dados Transformados pela Regra da Diferença |
| Linha Contínua Vermelha | - | Valores Aproximados pela Rede Neural        |

## APÊNDICE 07

### Gráficos dos Resultados das Simulações da 2ª. Estratégia.




#### Segmento da Indústria Farmacêutica




#### Segmento da Indústria de Extrativismo Mineral

#### **Legenda:**

- Linha Azul - Dados Reais (Transformados) na 2ª. Estratégia
- Linha Magenta - Resultado da Rede pela Introdução de dados Reais (Transformados)
- Linha Verde - Previsão de Demanda




Segmento da Indústria de Transformação




Segmento da Indústria Têxtil

**Legenda:**

- Linha Azul - Dados Reais (Transformados) na 2ª. Estratégia
- Linha Magenta- Resultado da Rede pela Introdução de dados Reais (Transformados)
- Linha Verde - Previsão de Demanda




Segmento da Indústria Geral



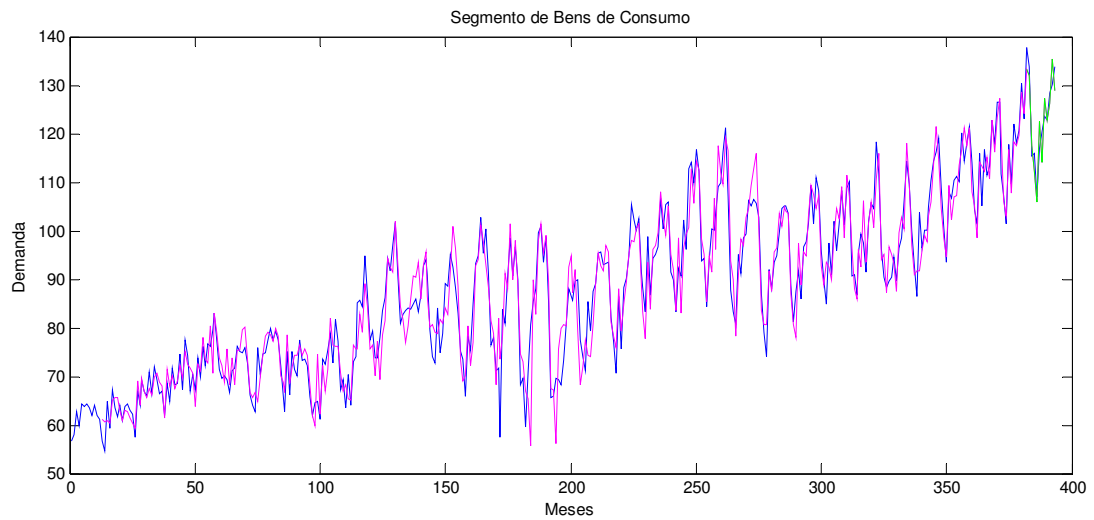
Segmento da Indústria de Bens Intermediários

**Legenda:**

- Linha Azul - Dados Reais (Transformados) na 2ª. Estratégia
- Linha Magenta- Resultado da Rede pela Introdução de dados Reais (Transformados)
- Linha Verde - Previsão de Demanda



Segmento da Indústria de Bens de Capital

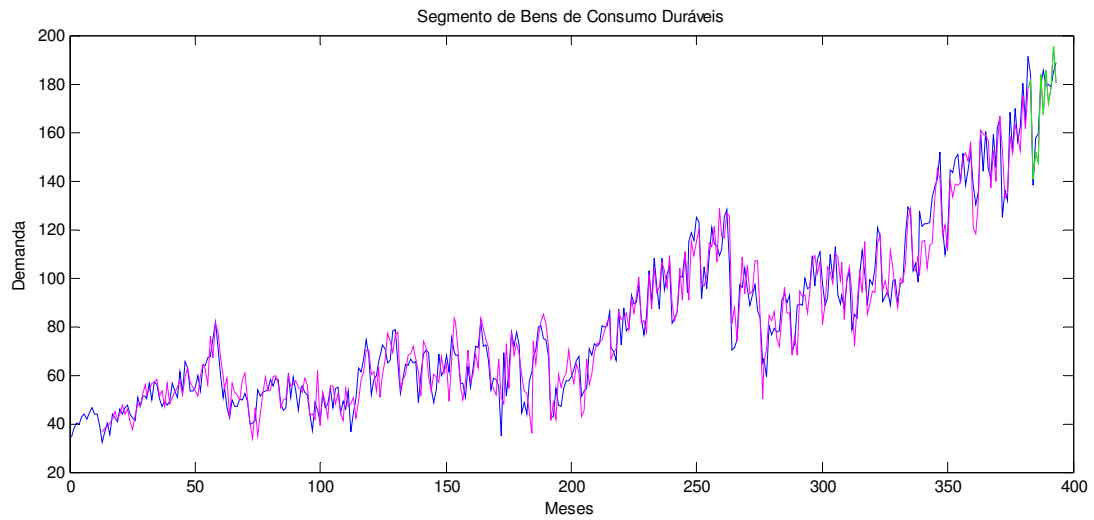


Segmento da Indústria de Bens de Consumo


**Legenda:**

- Linha Azul - Dados Reais (Transformados) na 2ª. Estratégia
- Linha Magenta- Resultado da Rede pela Introdução de dados Reais (Transformados)
- Linha Verde - Previsão de Demanda





Segmento da Indústria de Bens de Consumo Duráveis





Segmento da Indústria de Bens de Consumo Não Duráveis

**Legenda:**



- Linha Azul - Dados Reais (Transformados) na 2ª. Estratégia
- Linha Magenta- Resultado da Rede pela Introdução de dados Reais (Transformados)
- Linha Verde - Previsão de Demanda

## APÊNDICE 08



### Gráficos da Distribuição de Probabilidade (Direita) e Função de Auto-Correlação (Esquerda) - 2ª. Estratégia





Segmento da Indústria Farmacêutica -  $\mu = 0,029$  e  $\sigma = 8,66$





Segmento da Indústria de Extrativismo Mineral -  $\mu = -0,0937$  e  $\sigma = 3,3346$





Segmento da Indústria de Transformação -  $\mu = -0,0062$  e  $\sigma = 4,0627$





Segmento da Indústria Têxtil -  $\mu = 0,0112$  e  $\sigma = 7,0978$





Segmento da Indústria Geral -  $\mu = 0,0192$  e  $\sigma = 3,7498$





Segmento da Indústria de Bens Intermediários -  $\mu = -0,0151$  e  $\sigma = 3,3068$





Segmento da Indústria de Bens de Capital -  $\mu = 0,0120$  e  $\sigma = 7,5427$



Segmento da Indústria de Bens de Consumo -  $\mu = -0,0008$  e  $\sigma = 4,5048$




Segmento da Indústria de Bend de Consumo Duráveis -  $\mu = 0,0190$  e  $\sigma = 7,9266$



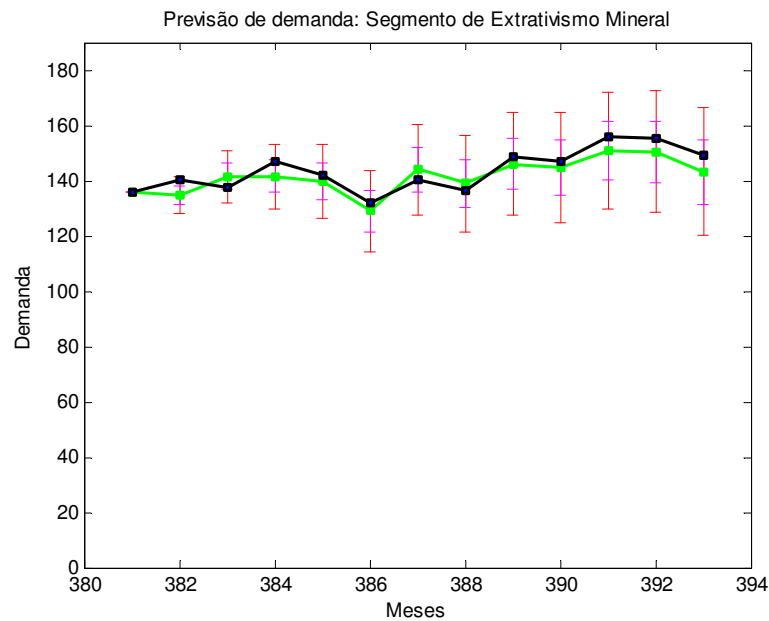
Segmento da Indústria de Bens de Consumo Não Duráveis -  $\mu = 0,0008$  e  $\sigma = 4,0310$

## APÊNDICE 09

### Gráficos da Previsão de Demanda - 2ª. Estratégia




Segmento da Indústria Farmacêutica - MSE= 4,6268 e MAE= 12,2761




Segmento da Indústria de Extrativismo Mineral - MSE= 1,1954 e MAE= 3,9105

#### **Legenda:**

- Linha Preta - Valores Reais de Demanda da 2ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural




Segmento da Indústria de Transformação - MSE= 1,5740 e MAE= 4,3921




Segmento da Indústria Têxtil - MSE= 1,4719 e MAE= 4,2742

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 2ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural



Segmento da Indústria Geral - MSE= 1,5276 e MAE= 4,2792




Segmento da Indústria de Bens Intermediários - MSE= 1,2272 e MAE= 3,3421


**Legenda:**

- Linha Preta - Valores Reais de Demanda da 2ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural






Segmento da Indústria de Bens de Capital - MSE= 4,9333 e MAE= 12,9632




Segmento da Indústria de Bens de Consumo - MSE= 1,4335 e MAE= 4,0253

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 2ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural



Segmento da Indústria de Bens de Consumo Duráveis - MSE= 3,4348 e MAE= 9,0343



Segmento da Indústria de Bens de Consumo Não Duráveis - MSE= 1,1670 e MAE= 3,5839

**Legenda:**

- Linha Preta - Valores Reais de Demanda da 2ª. Estratégia
- Linha Verde - Valores Estimados pela Rede Neural

**APÊNDICE 10**  
**Tabelas de Pesos e Biases da TDNN ( $N^{4-3-1}$ ) - 2ª. Estratégia**

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
0,6088	0,0211	-0,1805	2,1048	2,0177	2,2097
0,1947	0,0010	0,1833	-7,9416	1,0252	
0,0789	-0,0630	-0,0364	3,7663	2,3094	
0,1675	-0,0662	0,2028			

Segmento da Indústria Farmacêutica

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
0,0073	-0,2382	-0,0068	-5,5529	1,2855	4,1816
-0,0311	-0,8378	0,0462	-0,6853	-0,0173	
0,0161	-1,0382	-0,1712	-2,1747	-0,6595	
-0,1808	-6,0958	0,0790			

Segmento da Indústria de Extrativismo Mineral

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
1,7542	0,0253	-1,0479	1,3346	-8,4162	-2,6061
1,0061	-0,0043	0,7420	-9,9490	-0,4760	
5,1919	0,0091	0,6395	1,5409	-4,3376	
-7,1584	-0,1087	1,4055			

Segmento da Indústria de Transformação

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
-0,0006	-17,4389	-4,9352	32,8717	0,0809	-2,4917
-0,0031	3,9766	4,6192	-0,0042	51,9181	
-0,0057	-16,3122	8,0871	1,7359	4,1617	
0,0386	2,8483	-10,4041			

Segmento da Indústria Têxtil

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
-0,0377	-0,2543	-0,2262	-2,9556	1,3310	0,6145
-0,0438	-0,0564	0,1652	2,0481	-0,0896	
-0,0926	0,4203	-0,1710	2,9463	1,7761	
-0,0608	0,8200	0,5013			

### Segmento da Indústria Geral

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
0,7851	-0,0270	0,1153	1,4306	-6,6780	-1,8364
0,4104	0,0677	0,1607	7,3848	0,5058	
0,2144	0,0092	-0,0399	-2,0976	-0,0166	
0,5789	0,0682	-0,2161			

### Segmento da Indústria de Bens Intermediários

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
-1,7948	-0,0001	-0,0194	2,7182	5,3821	-6,1740
0,7199	0,0138	0,0051	13,1381	-1,0004	
-2,0773	0,0456	0,0268	17,4542	1,5535	
5,7707	0,0145	0,0502			

### Segmento da Indústria de Bens de Capital

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
2,1549	0,0145	-1,4573	-0,9723	12,8434	0,4873
-0,6293	-0,0357	0,0635	-7,6119	-0,0140	
-9,5385	0,0168	3,5708	0,8445	2,9520	
0,5991	-0,1010	-2,8842			

### Segmento da Indústria de Bens de Consumo

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
-0,0700	0,0023	-0,1865	7,1129	-1,6186	-3,0466
0,1212	-0,0190	0,8689	-10,9107	-1,2917	
0,0886	0,0042	-0,3879	-1,2551	-2,6991	
0,0671	-0,0902	-0,5189			

Segmento da Indústria de Bens de Consumo Duráveis

<b>Pesos das entradas</b>			<b>Pesos da camada escondida</b>	<b>Biases</b>	
$w_{i,1}$	$w_{i,2}$	$w_{i,3}$	$w_j$	$w_{0,j}$	$w_0$
7,0788	-0,0083	1,6552	-2,0643	-11,5095	3,0836
-3,2634	-0,0207	-11,7437	-9,7696	0,3221	
-0,6354	-0,0216	-11,8639	1,2497	-4,2665	
-10,8542	-0,0249	-2,2694			

Segmento da Indústria de Bens de Consumo Não Duráveis

**ANEXO A**  
**(MÓDULO MATLAB – REDE TDNN – 1ª. ESTRATÉGIA)**

```

%*****
%*
%* Rede TDNN - 1ª estratégia
%*
%*****

% Abre o arquivo da dados
load dados1.txt -ascii

% Parâmetros
r=13;% # de entradas na rede
h=12;% # de meses da previsão
m=5;% # de neurônios na camada escondida
s=11;% segmento de mercado

% Prepara o treinamento da rede: entradas pt e saídas yt
len=length(dados1(:,1));
d1=dados1(:,s+1)';
p=[];
y=[];
for k=1:r
    p=[p;d1(k:len-r-1+k)];
end
y = d1(1:len);
pt=p(:,1:(len-h-r));
ps=p(:,(len-h-r+1):(len-r));
yt=y((r+1):(len-h));
ys=y((len-h-r+1):(len));

erro=1e6;
while erro > 100, % Aceita o treinamento de o erro for inferior a 100
% Cria e inicializa a rede neural feedforward
    net=newff(minmax(p), [m,1], {'tansig' 'purelin'}, 'trainlm');

% Define os parâmetros do treinamento
    net.trainParam.show = 5;
    net.trainParam.goal = 1;
    net.trainParam.epochs = 25;

% Executa o treinamento da rede
    [net,tr]=train(net,pt,yt);
    erro=tr.perf(length(tr.perf));
end
pause % pausa para visualizar o gráfico

% Simula a rede com os dados do treinamento
a = sim(net,pt);

```

```

% Simula a rede com novos dados
a1=a(length(a));
ps=[pt(2:r,length(pt));a1];
as=a1;
for k=1:h
    ps=[ps(2:r);a1];% Acrescenta cada previsão na entrada da rede para obter
uma nova previsão.
    a1 = sim(net,ps);
    a = [a,a1];
    as = [as,a1];
end

% Desenha o gráfico da simulação do sinal integrado em comparação com os dados
reais
L=length(y);
clf
plot(1:L,y,'b')
hold
plot((r+1):L,a,'m')
plot((L-h):L,as,'g')
title(gettit(s))
ylabel('Demanda')
xlabel('Meses')
hold
pause % pausa para visualizar o gráfico
clf

% Cálculo do resíduo
res=y(r+1:L-h)-a(1:L-h-r);

% Teste estatístico a respeito da normalidade da distribuição dos dados
teste=lillietest(res)

% plota o histograma do resíduo com a curva normal (boca de sino)
histfit(res)
title(gettit(s))
ylabel('Frequência')
xlabel('Resíduo')

% Calcula a estimativa da média e do desvio padrão
[mu,sigma] = normfit(res)

pause % pausa para visualizar o gráfico
clf

c1=xcov(res,'coeff');
klen=length(c1);
plot(c1((klen/2):klen),'r')
title([gettit(s),' - Autocorrelação dos resíduos'])
xlabel('k (deslocamentos no tempo)','FontSize',12)
ylabel('\rho_k','FontSize',12)
axis([0,120,-.5,1])

pause % pausa para visualizar o gráfico
clf

```

```

% Desenha o gráfico da previsão de demanda com as barras de incerteza
t=1:L;
as(1)=y(L-h);
errorbar(t(L-h:L),as,2*sqrt(0:12)*sigma,'r')
hold on
errorbar(t(L-h:L),as,1*sqrt(0:12)*sigma,'m')
hg=plot(t(L-h:L),as,'gs',t(L-h:L),y(L-h:L),'ks');
set(hg,'LineWidth',2,{'LineStyle'},{'--';':'},{'MarkerFaceColor'},{'g';'b'},'MarkerSize',3)
title(['Previsão de demanda: ',gettit(s)])
ylabel('Demanda')
xlabel('Meses')
axis([392,406,0,190])

% Calcula o MSE (mean square error)
MSE=norm(as-y(L-h:L))/12;
% Calcula o MAE (mean absolute error)
MAE=norm(as-y(L-h:L),1)/12;
% Vetor dos resultados
vet=[s,teste,mu,sigma,MSE,MAE]
fn=['res_sl_' num2str(s) '.txt'];
save(fn,'-ascii','vet')

% Salva os valores dos pesos da RN num arquivo texto
InputW=net.IW{1,1};
HiddenW=net.LW{2,1};
BiasesW=[net.b{1,1},[net.b{2,1};zeros(m-1,1)]];
Ws=[InputW',[HiddenW';zeros(r-m,1)],[BiasesW;zeros(r-m,2)]];
fn=['net_sl_' num2str(s) '.txt'];
save(fn,'-ascii','Ws')

```



**ANEXO B**  
**(MÓDULO MATLAB – REDE TDNN – 2ª. ESTRATÉGIA)**

```

%*****
%*
%* Rede TDNN - 2ª estratégia
%*
%*****

% Abre o arquivo da dados
load dados1.txt -ascii

% Parâmetros
r=4;% # de entradas na rede
h=12;% # de meses da previsão
m=3;% # de neurônios na camada escondida
s=1; % segmento de mercado

% Calcula as diferenças
len1=length(dados1(:,1));
dd=dados1(13:len1,:)-dados1(1:(len1-12),:);
len=length(dd(:,1));
d1=dd(:,s+1)';

% Prepara o treinamento da rede: entradas pt e saídas yt
p=[];
y=[];
for k=1:r
    p=[p;d1(k:len-r+k)];
end
y = d1((r+1):len);
yy=dados1(h+1:len1,s+1)';
pt=p(:,1:(len-h-r));
ps=p(:,(len-h-r+1):(len-r));
yt=y(1:(len-h-r));
ys=y((len-r-h+1):(len-r));

erro=1e6;
while erro > 62, % Aceita o treinamento de o erro for inferior a 62
% Cria e inicializa a rede neural feedforward
    net=newff(minmax(p),[m,1],{'tansig' 'purelin'},'trainlm');

% Define os parâmetros do treinamento
    net.trainParam.show = 5;
    net.trainParam.goal = 1;
    net.trainParam.epochs = 25;

% Executa o treinamento da rede
    [net,tr]=train(net,pt,yt);
    erro=tr.perf(length(tr.perf));
end

```

```

pause % pausa para visualizar o gráfico

% Simula a rede com os dados do treinamento
a = sim(net,pt);

% Simula a rede com novos dados
ps=pt(:,length(pt));
a1=a(length(a));
as=[];
for k=1:h
    ps=[ps(2:r);a1]; % Acrescenta cada previsão na entrada da rede para obter
    uma nova previsão.
    a1 = sim(net,ps);
    a = [a,a1];
    as = [as,a1];
end

% Desenha o gráfico da simulação do sinal das diferenças
L=len;
clf
plot((1:L-r-h),a(1:L-r-h),'r',(1:L-r-h),y(1:L-r-h),'b:')
title(gettit(s))
ylabel('Diferenças da Demanda')
xlabel('Meses')
pause % pausa para visualizar o gráfico

% Desenha o gráfico da simulação do sinal integrado em comparação com os dados
reais
clf
plot(1:L,yy,'b')
hold
plot((r+1):L,yy(r-11:L-12)+a,'m')
plot((L-h+1):L,yy((L-h-11):L-12)+as,'g')
title(gettit(s))
ylabel('Demanda')
xlabel('Meses')
hold
pause % pausa para visualizar o gráfico
clf

% Cálculo do resíduo
res=a(1:L-r-h)-y(1:L-r-h);

% Teste estatístico a respeito da normalidade da distribuição dos dados
teste=lillietest(res)

% plota o histograma do resíduo com a curva normal (boca de sino)
histfit(res)
title(gettit(s))
ylabel('Frequência')
xlabel('Resíduo')

% Calcula a estimativa da média e do desvio padrão
[mu,sigma] = normfit(res)

```

```

pause % pausa para visualizar o gráfico
clf

c1=xcov(res, 'coeff');
klen=length(c1);
plot(c1(round(klen/2):klen), 'r')
title([gettit(s), ' - Autocorrelação dos resíduos'])
xlabel('k (deslocamentos no tempo)', 'FontSize', 12)
ylabel('\rho_k', 'FontSize', 12)
axis([0, 120, -.5, 1])

pause % pausa para visualizar o gráfico
clf

% Desenha o gráfico da previsão de demanda com as barras de incerteza
t=1:L;
as(1)=0;
errorbar(t(L-h:L), [yy(L-h), yy(L-h-11:L-12)+as], 2*sqrt(0:12)*sigma, 'r')
hold on
errorbar(t(L-h:L), [yy(L-h), yy(L-h-11:L-12)+as], 1*sqrt(0:12)*sigma, 'm')
hg=plot(t(L-h:L), [yy(L-h), yy(L-h-11:L-12)+as], 'gs', t(L-h:L), yy(L-h:L), 'ks');
set(hg, 'LineWidth', 2, {'LineStyle'}, {'--'; ':'}, {'MarkerFaceColor'}, {'g'; 'b'}, 'MarkerSize', 3)
title(['Previsão de demanda: ', gettit(s)])
ylabel('Demanda')
xlabel('Meses')
axis([380, 394, 0, 240])

% Calcula o MSE (mean square error)
MSE=norm([yy(L-h), yy(L-h-11:L-12)+as]-yy(L-h:L))/12
% Calcula o MAE (mean absolute error)
MAE=norm([yy(L-h), yy(L-h-11:L-12)+as]-yy(L-h:L), 1)/12
% Vetor dos resultados
vet=[s, teste, mu, sigma, MSE, MAE]
fn=['res_s2_' num2str(s) '.txt'];
save(fn, '-ascii', 'vet')

% Salva os valores dos pesos da RN num arquivo texto
InputW=net.IW{1,1};
HiddenW=net.LW{2,1};
BiasesW=[net.b{1,1}, [net.b{2,1}; zeros(m-1,1)]];
Ws=[InputW', [HiddenW'; zeros(r-m,1)], [BiasesW; zeros(r-m,2)]];
fn=['net_s2_' num2str(s) '.txt'];
save(fn, '-ascii', 'Ws')

```

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)