

GLÁUCIO JOSÉ CARDOZO DIAS

**PLANEJAMENTO ESTRATÉGICO DE UM CENTRO DE DISTRIBUIÇÃO: UMA
APLICAÇÃO DE REDES NEURAS ARTIFICIAIS DE FUNÇÕES DE BASES
RADIAIS PARA PREVISÃO DE SÉRIES TEMPORAIS**

**Dissertação apresentada como requisito
parcial à obtenção de grau de Mestre em
Ciências, Programa de Pós-Graduação em
Métodos Numéricos em Engenharia, Setor
de Ciências Exatas e Tecnologia,
Universidade Federal do Paraná.**

**Orientador:
Prof. Dr. Anselmo Chaves Neto**

**CURITIBA
2006**

TERMO DE APROVAÇÃO

AGRADECIMENTOS

Agradecer a todos que ajudaram a construir esta dissertação não é tarefa fácil. O maior perigo que se coloca para o agradecimento seletivo não é decidir quem incluir, mas decidir quem não mencionar. Então, a meus amigos que, de uma forma ou de outra, contribuíram com sua amizade e com sugestões efetivas para a realização deste trabalho, gostaria de expressar minha profunda gratidão.

Em especial a minha querida mãe Sirlei Maria Lopes Cardozo, ao meu pai Ailton de Resende Dias e minha segunda mãe Maria do Socorro Moura, que sempre me incentivaram a pratica e a busca constante pelo conhecimento.

Ao meu grande amigo “irmão” Cassius Tadeu Scarpin, pelo constante incentivo, sempre indicando a direção a ser tomada nos momentos de maior dificuldade, interlocutor interessado em participar de minhas inquietações, co-autor em vários trechos. Agradeço, principalmente, pela confiança, mais uma vez depositada, no meu trabalho de dissertação.

A Datasul Logística, empresa na qual trabalho e que participou ativamente na elaboração deste trabalho, bem como, liberando-me em dos horários de expediente para que pudesse freqüentar as aulas, e dentro dessa empresa as pessoas que fizeram isso acontecer Ivomar Rech e Edson Luiz Vilela Veiga, os meus sinceros agradecimentos.

E a Maristela Bandil, que é muito mais que uma secretaria do mestrado, cujo papel desempenhado é de uma verdadeira amiga, que sempre esta pronta as nos ajudar da melhor maneira possível e com a maior vontade do mundo.

SUMÁRIO

1 INTRODUÇÃO	1
1.1 OBJETIVOS DO TRABALHO.....	3
1.1.1 Objetivo Geral.....	3
1.1.2 Objetivo Específico.....	3
1.2 JUSTIFICATIVA DO TRABALHO.....	4
1.3 ESTRUTURA DO TRABALHO.....	5
2 REVISÃO LITERATURA	6
2.1 REDES NEURAIS ARTIFICIAIS.....	8
2.1.1 Neurônio Biológico e Artificial	9
2.1.2 Funções de Ativação	11
2.1.3 Topologia das Redes	13
2.1.4 Aprendizado das Redes	14
2.1.5 Rede Neural Artificial de Função de Base Radial (RBF)	15
2.1.5.1 Arquitetura das Redes RBF.....	16
2.1.5.2 Processamento das Redes RBF.....	17
2.1.5.3 Parâmetros e Equações das Redes RBF.....	18
2.1.5.4 Aprendizado em Redes RBF	19
2.1.5.5 Estratégias de Treinamento	24
2.1.5.6 Desempenho das redes RBF.....	25
2.2 SÉRIES TEMPORAIS	26
2.2.1 Metodologia Box & Jenkins	28
2.2.1.1 Modelos Auto-regressivos (AR)	29
2.2.1.2 Modelos de Médias Móveis (MA).....	29
2.2.1.3 Modelos Auto-Regressivos e de Médias Móveis (ARMA)	30
2.2.1.4 Modelos Auto-Regressivos Integrados de Médias Móveis (ARIMA)	31
2.3 ARMAZENAGEM ESTRATÉGICA.....	34
2.3.1 Armazenagem	34
2.3.2 Missões de um Armazém	34

2.3.3 Funções de um Armazém	36
2.3.4 Administração da Armazenagem.....	37
2.3.5 Operações de <i>Picking</i> na Armazenagem	39
2.3.5.1 <i>Picking</i> discreto	39
2.3.5.2 <i>Picking</i> por lotes.....	40
2.3.5.3 <i>Picking</i> por zona.....	41
2.3.6 Sistemas de <i>Picking</i>	42
2.3.6.1 <i>A-Frame</i>	42
2.3.6.2 Carrossel.....	43
2.3.6.3 Sistema de estocagem e coleta automáticos	44
2.3.6.4 Separação por rádio frequência	45
2.3.6.5 Sistema de <i>picking by-light</i>	46
3 MATERIAL E MÉTODO	48
3.1 METODOLOGIAS APLICADAS.....	48
3.1.1 Previsão Utilizando Redes RBF	48
3.1.2 Parâmetro Número de Neurônios de Entrada.....	49
3.1.3 Parâmetro Número da Taxa de EG.....	50
3.1.4 Parâmetro Número da Taxa de SC	50
3.1.5 Escolha do Melhor Parâmetro	52
3.2 PREVISÃO UTILIZANDO A METODOLOGIA BOX & JENKINS	53
3.2.1 Ordem dos Parâmetros dos Modelos ARMA	54
3.2.2 Escolha do Melhor Modelo	54
3.3 MATERIAL.....	55
3.3.1 O Centro de Distribuição.....	55
3.3.2 A Área de <i>Picking</i>	56
3.3.3 Dimensionamento Atual da Área de <i>Picking</i>	57
3.3.4 Produtos e suas Sazonalidades	58
3.4 MÉTODOS	66
4 IMPLEMENTAÇÕES E RESULTADOS.....	67
4.1 TOPOLOGIAS ESCOLHIDAS	68

4.1.1 Serie Temporal - Biscoito	69
4.1.1.1 Dados <i>statgraphics</i> – metodologia box & jenkins	69
4.1.1.2 Dados <i>matlab</i> – redes RBF	71
4.1.1.3 ARMA x RBF	74
4.1.2 Serie Temporal - Macarrão	75
4.1.2.1 Dados <i>statgraphics</i> – metodologia box & jenkins	75
4.1.2.2 Dados <i>matlab</i> – redes RBF	77
4.1.2.3 ARMA x RBF	80
4.1.3 Serie Temporal - Candies	81
4.1.3.1 Dados <i>statgraphics</i> – metodologia box & jenkins	81
4.1.3.2 Dados <i>matlab</i> – redes RBF	83
4.1.3.3 ARMA x RBF	86
4.1.4 Serie Temporal - Chocolates	87
4.1.4.1 Dados <i>statgraphics</i> – metodologia box & jenkins	87
4.1.4.2 Dados <i>matlab</i> – redes RBF.....	89
4.1.4.3 ARMA x RBF	92
4.1.5 Serie Temporal - Refresco	93
4.1.5.1 Dados <i>statgraphics</i> – metodologia box & jenkins	93
4.1.5.2 Dados <i>matlab</i> – redes RBF	95
4.1.5.3 ARMA x RBF	98
4.1.6 Serie Temporal - Cereais	99
4.1.6.1 Dados <i>statgraphics</i> – metodologia box & jenkins	99
4.1.6.2 Dados <i>matlab</i> – redes RBF	101
4.1.6.3 ARMA x RBF	104
4.1.7 Serie Temporal – Panetones	105
4.1.7.1 Dados <i>statgraphics</i> – metodologia box & jenkins	105
4.1.7.2 Dados <i>matlab</i> – redes RBF	107
4.1.7.3 ARMA x RBF	110
4.2 PREVISÕES FUTURAS	111
4.2.1 Dimensionamento da área de <i>picking</i> de acordo com a previsão encontrada....	111

4.2.1.1 Dimensionamento da área de <i>picking</i> para o item Biscoito.....	113
4.2.1.2 Dimensionamento da área de <i>picking</i> para o item Macarrão.....	115
4.2.1.3 Dimensionamento da área de <i>picking</i> para o item <i>Candies</i>	117
4.2.1.4 Dimensionamento da área de <i>picking</i> para o item Chocolate	119
4.2.1.5 Dimensionamento da área de <i>picking</i> para o item Refresco	121
4.2.1.6 Dimensionamento da área de <i>picking</i> para o item Cereais	123
4.2.1.7 Dimensionamento da área de <i>picking</i> para o item Panetones	125
5 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	127
REFERÊNCIAS.....	129
ANEXOS.....	136

LISTA DE TABELAS

TABELA 4.1 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – BISCOITO	70
TABELA 4.2 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – BISCOITO.....	73
TABELA 4.3 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – MACARRÃO.....	76
TABELA 4.4 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – MACARRÃO.....	79
TABELA 4.5 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – <i>CANDIES</i>	82
TABELA 4.6 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – <i>CANDIES</i>	85
TABELA 4.7 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – CHOCOLATE.....	88
TABELA 4.8 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – CHOCOLATE.....	91
TABELA 4.9 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – REFRESCO.....	94
TABELA 4.10 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – REFRESCO.....	97
TABELA 4.11 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – CEREAIS.....	100
TABELA 4.12 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – CEREAIS.....	103
TABELA 4.13 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – PANETONES.....	106
TABELA 4.14 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – PANETONES.....	109

TABELA 4.15 – PREVISÕES DE CONSUMO – BISCOITO.....	113
TABELA 4.16 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – BISCOITO.....	114
TABELA 4.17 – PREVISÕES DE CONSUMO – MACARRÃO	115
TABELA 4.18 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – MACARRÃO.....	116
TABELA 4.19 – PREVISÕES DE CONSUMO – <i>CANDIES</i>	117
TABELA 4.20 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – <i>CANDIES</i>	118
TABELA 4.21 – PREVISÕES DE CONSUMO – CHOCOLATE.....	119
TABELA 4.22 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – CHOCOLATE.....	120
TABELA 4.23 – PREVISÕES DE CONSUMO – REFRESCO.....	121
TABELA 4.24 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – REFRESCO.....	122
TABELA 4.25 – PREVISÕES DE CONSUMO – CEREAIS.....	123
TABELA 4.26 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – CEREAIS.....	124
TABELA 4.27 – PREVISÕES DE CONSUMO – PANETONES.....	125
TABELA 4.28 – PREVISÃO DA DIMENSÃO DA ÁREA DE <i>PICKING</i> – PANETONES.....	126

LISTA DE QUADROS

QUADRO 3.1 – QUANTIDADE ATUAL DE ENDEREÇOS POR PRODUTO.....58

LISTA DE FIGURAS

FIGURA 2.1 – NEURÔNIO BIOLÓGICO: OS CONSTITUINTES DA CÉLULA...	10
FIGURA 2.2 – NEURÔNIO ARTIFICIAL.....	11
FIGURA 2.3 – EXEMPLOS DE REDES FEED-FORWARD.....	13
FIGURA 2.4 – REDE RECORRENTE.....	14
FIGURA 2.5 – ARQUITETURA DAS REDES RBF.....	17
FIGURA 2.6 – FLUXOGRAMA.....	33
FIGURA 2.7 – PAPEIS DO ARMAZÉM NA REDE DE DISTRIBUIÇÃO.....	36
FIGURA 2.8 – PICKING DISCRETO.....	39
FIGURA 2.9 – PICKING POR LOTE.....	40
FIGURA 2.10 – PICKING POR ZONA.....	41
FIGURA 2.11 - <i>A-FRAME</i>	42
FIGURA 2.12 – CARROSSEL VERTICAL.....	44
FIGURA 2.13 – <i>MINILOAD</i>	45
FIGURA 2.14 – TERMINAL DE RÁDIO FREQUÊNCIA COM LEITURA ÓTICA.....	46
FIGURA 2.15 – <i>PICKING BY-LIGHT</i>	46

LISTA DE GRÁFICOS

GRÁFICO 3.1 – OCORRÊNCIA DE DISTORÇÕES NO TREINAMENTO I.....	51
GRÁFICO 3.2 - OCORRÊNCIA DE DISTORÇÕES NO TREINAMENTO II.....	52
GRÁFICO 3.3 – GRÁFICO DE RESÍDUOS DO AJUSTE DO MODELO.....	55
GRÁFICO 3.4 – CONSUMO DO PRODUTO POR PERÍODO – BISCOITO.....	59
GRÁFICO 3.5 – CONSUMO DO PRODUTO POR PERÍODO – MACARRÃO.....	60
GRÁFICO 3.6 – CONSUMO DO PRODUTO POR PERÍODO – <i>CANDIES</i>	61
GRÁFICO 3.7 - CONSUMO DO PRODUTO POR PERÍODO – CHOCOLATES....	62
GRÁFICO 3.8 - CONSUMO DO PRODUTO POR PERÍODO – REFRESCOS.....	63
GRÁFICO 3.9 - CONSUMO DO PRODUTO POR PERÍODO – CEREAIS.....	64
GRÁFICO 3.10 - CONSUMO DO PRODUTO POR PERÍODO – PANETONE.....	65
GRÁFICO 4.1 – PERIODOGRAMA INTEGRADO – BISCOITO	69
GRÁFICO 4.2 – CONSUMO REAL X PREVISÃO BOX & JENKINS – BISCOITO.....	71
GRÁFICO 4.3 – TREINAMENTO DA REDE – BISCOITO.....	72
GRÁFICO 4.4 – CONSUMO REAL X PREVISÃO PELA RBF – BISCOITO.....	74
GRÁFICO 4.5 – PERIODOGRAMA INTEGRADO – MACARRÃO.....	75
GRÁFICO 4.6 – CONSUMO REAL X PREVISÃO BOX & JENKINS – MACARRÃO.....	77
GRÁFICO 4.7 – TREINAMENTO DA REDE – MACARRÃO.....	78
GRÁFICO 4.8 – CONSUMO REAL X PREVISÃO PELA RBF – MACARRÃO....	80
GRÁFICO 4.9 – PERIODOGRAMA INTEGRADO – <i>CANDIES</i>	81
GRÁFICO 4.10 – CONSUMO REAL X PREVISÃO BOX & JENKINS – <i>CANDIES</i>	83
GRÁFICO 4.11 – TREINAMENTO DA REDE – <i>CANDIES</i>	84
GRÁFICO 4.12 – CONSUMO REAL X PREVISÃO PELA RBF – <i>CANDIES</i>	86
GRÁFICO 4.13 – PERIODOGRAMA INTEGRADO – CHOCOLATE.....	87
GRÁFICO 4.14 – CONSUMO REAL X PREVISÃO BOX & JENKINS – CHOCOLATE.....	89

GRÁFICO 4.15 – TREINAMENTO DA REDE – CHOCOLATE.....	90
GRÁFICO 4.16 – CONSUMO REAL X PREVISÃO PELA RBF – CHOCOLATE..	92
GRÁFICO 4.17 – PERIODOGRAMA INTEGRADO – REFRESCO.....	93
GRÁFICO 4.18 – CONSUMO REAL X PREVISÃO BOX & JENKINS – REFRESCO.....	95
GRÁFICO 4.19 – TREINAMENTO DA REDE – REFRESCO.....	96
GRÁFICO 4.20 – CONSUMO REAL X PREVISÃO PELA RBF – REFRESCO.....	98
GRÁFICO 4.21 – PERIODOGRAMA INTEGRADO – CEREAIS.....	99
GRÁFICO 4.22 – CONSUMO REAL X PREVISÃO BOX & JENKINS – CEREAIS.....	101
GRÁFICO 4.23 – TREINAMENTO DA REDE – CEREAIS.....	102
GRÁFICO 4.24 – CONSUMO REAL X PREVISÃO PELA RBF – CEREAIS.....	104
GRÁFICO 4.25 – PERIODOGRAMA INTEGRADO – PANETONES.....	105
GRÁFICO 4.26 – CONSUMO REAL X PREVISÃO BOX & JENKINS – PANETONES.....	107
GRÁFICO 4.27 – TREINAMENTO DA REDE – PANETONES.....	108
GRÁFICO 4.28 – CONSUMO REAL X PREVISÃO PELA RBF – PANETONES.	110

LISTA DE SIGLAS

AR	-	Auto-regressivo
ARIMA	-	Modelo Auto-Regressivo Integrado de Médias Móveis
ARMA	-	Modelo Auto-Regressivo e de Médias Móveis
B&J	-	Box & Jenkins
CD	-	Centro de Distribuição
E	-	Erro
<i>Gb</i>	-	<i>Giga Byte</i>
<i>GHz</i>	-	<i>Giga Hertz</i>
MA	-	Médias Móveis
MRE	-	Erro Relativo Médio
MSE	-	Erro Quadrático Médio
<i>RAM</i>	-	<i>Random Access Memory</i>
<i>RBF</i>	-	<i>Radial Basis Function</i>
RMSE	-	Raiz do Erro Quadrático Médio
SARIMA	-	Modelo Auto-Regressivo Integrado Médias Móveis Sazonal
SSE	-	Soma do Erro Quadrático

LISTA DE SÍMBOLOS E VARIÁVEIS

φ	-	Função de ativação da RBF
σ_j	-	Valores da vizinhança das redes neurais de função de bases radiais
μ_j	-	Vetor de parâmetro de entrada com dimensional (n)
a_t	-	Ruído branco ou erro aleatório
C_t	-	Ciclo da serie temporal
D_t	-	Demanda
f	-	Função de ativação
ng	-	Grupos de treinamento
$npad$	-	Número de parada
ϕ_i	-	Corresponde ao i -ésimo parâmetro auto-regressivo
p	-	Quantidade de parâmetros AR
S_t	-	Sazonalidade
T_t	-	Tendência
w_k	-	Pesos sinápticos do neurônio em questão (neurônio k)
x_i	-	Sinais de entrada do neurônio
y_k	-	Saída do neurônio
Y_t	-	Previsão da serie temporal
Z_j	-	Saída das redes neurais de função de bases radiais
z_j	-	Função de base radial
δ	-	Representa o termo constante da série
θ_i	-	São os parâmetros de médias móveis
θ_j	-	“Bias”, parâmetro de entrada que ajusta a função radial
ω_t	-	Série temporal estacionária

RESUMO

O *layout* da área de *picking* assim como o seu dimensionamento são atividades de extrema importância quando se trata de um centro de distribuição de produtos com curto período de validade. A área de *picking* é uma área destinada à retirada de produtos em pequenas quantidades, ou seja, quantidades menores que um *pallet* completo. Quando seu dimensionamento é muito grande, pode ocorrer o vencimento da data de validade dos produtos na própria área de *picking*, e quando o dimensionamento é menor que o necessário, ocorre atraso no carregamento dos caminhões que transportam os itens do centro de distribuição até os centros de vendas. Com o problema de dimensionamento da área de *picking*, este trabalho propõe a utilização de técnicas de previsões de séries temporais, para a estimação do consumo, e a partir deste, fazer o dimensionamento dinâmico das áreas de *picking*, respeitando a sazonalidade dos produtos. No presente trabalho, utiliza-se de 7 (sete) séries temporais reais, que representam a demanda dos produtos alimentícios de um centro de distribuição de uma empresa brasileira, com o objetivo de ajustar o melhor modelo para que as previsões sejam feitas a curto e a longo prazo, diminuindo assim incerteza no planejamento estratégico da empresa. O trabalho contempla estudos de previsões de series temporais através das Redes Neurais Artificiais de Funções de Bases Radiais e compara seus resultados, com as previsões dos modelos ajustados através da Metodologia Box & Jenkins. Para efeito de comparação dos dois métodos utiliza-se a medida do RMSE (Raiz Quadrada do Erro Médio Quadrático). Os testes e resultados são apresentados ao longo do trabalho. Após estudos e comparações conclui-se, que as Redes Neurais Artificiais de Funções de Bases Radiais um ferramental com grande robustez e consistência para ser utilizado na previsão de demanda de series temporais.

ABSTRACT

The *layout* of the *picking area* as well as its dimensioning is an activity of extreme importance when considering a distribution center of products with a short validity period. The picking area is an area targeted to products in small quantities, that is, quantities smaller than a full *pallet*. When its dimensioning is too big, validity date of products in the picking area itself might be overdue, and when the dimensioning is smaller than necessary, there is a delay in loading the trucks that carry the items from the distribution center to the sales centers. Like the dimensioning problem of the picking area, this work proposes the use of forecast techniques of temporal series for the estimation of consumption, and from it to make the dynamic dimensioning of the picking areas, by following product seasoning. In the present work, 7 (seven) real temporal series are used, which represent the demand of food products of a distribution center of a Brazilian company aimed at adjusting the best pattern so that forecasts are done in the short and long run, lowering uncertainty in the company's strategic planning. This work covers studies of temporal series through Artificial Neural Networks of Functions of Radial Bases and compares its results to the forecasts of the patterns adjusted through the Box & Jenkins Methodology. For the effect of comparison of both methods, the RMSE (Square Root of the Root Mean Square - RMS) measure is used. The tests and results are displayed as the work is developed. After studies and comparisons it is concluded that the Artificial Neural Networks of functions of Radial Bases is a tool of great robustness and consistency to be used in the forecast of demand of temporal series.

INTRODUÇÃO

Atualmente, um dos principais objetivos do planejamento das empresas é diminuir o impacto das incertezas relacionadas ao futuro. A grande concorrência no mercado faz com que as empresas procurem maior eficiência em seus processos logísticos, onde um dos principais focos é o planejamento futuro de suas ações. A tarefa de prever demandas futuras fazendo experimentos com sistemas reais, na grande maioria das vezes é onerosa para as empresas. Isto faz com que se invista cada vez mais em modelos que sejam capazes de fazer a previsão levando em consideração as características do problema e suas propriedades.

A busca de modelos para a previsão de curto, médio e longo prazos, passou a despertar um enorme interesse, tanto para gestores quanto para pesquisadores em diversas áreas.

Os vários modelos desenvolvidos são usados em áreas como economia, *marketing*, finanças, engenharia e produção industrial, entre outras. Tais modelos de previsão são baseados em técnicas matemáticas e estatísticas que, aliados aos avanços tecnológicos que estão ocorrendo e ocorreram nas últimas duas décadas, resultam em instrumentos poderosos na tarefa de previsão. A partir de 1987 foram publicados vários artigos utilizando metodologias mais avançadas em modelos de previsão como algoritmos genéticos, lógica difusa e Redes Neurais; tais modelos têm se concentrado, em sua maioria, na área econômica com previsões de ações da bolsa de valores, em séries econômicas e na previsão de preços de petróleo (RODRIGUES, 2005); entre outras aplicações.

A modelagem pode ser, basicamente, dividida em três etapas:

- 1^a.) a formulação do problema, onde se procura levar em conta todas as suas particularidades e tenta-se determinar as restrições que a situação real impõe, de modo que se possa construir um modelo que torne aceitável a solução do mesmo;
- 2^a.) a resolução, onde se escolhe o algoritmo utilizado para solucionar o problema;
- 3^a.) a análise dos resultados, onde se interpreta a solução obtida e verifica-se a necessidade de melhoria (ou não) da solução.

Existe uma grande tendência, para os próximos anos, no crescimento das técnicas chamadas metaheurísticas. Essas técnicas são usadas para a solução de problemas estocásticos e também de forma híbrida. Os algoritmos genéticos, a lógica difusa, a modelagem probabilística, as Redes Neurais, entre outras, são alguns exemplos de técnicas metaheurística (OLIVEIRA, 2002)

No planejamento da produção industrial, a previsão de vendas e de estocagem é um problema da maior importância nas indústrias e, em alguns casos, ainda não tem solução. Levando-se em consideração que a indústria tem a informação da quantidade que será vendida no próximo período (semana, mês, etc.) de um produto, ela poderá planejar todo seu processo de produção e espaço para a estocagem, reduzindo os gastos e tornando seu produto mais barato, o que a torna mais competitiva no mercado. Baseada nessa previsão de vendas, uma empresa poderá reservar um espaço dentro do seu Centro de Distribuição (CD) para armazenar o produto de modo condizente com sua produção. Considerando que as empresas produzem dezenas, centenas e às vezes até milhares de itens diferentes, pode-se afirmar que o planejamento de espaço para armazenagem torna-se uma tarefa árdua e a otimização desse espaço é uma necessidade das empresas, já que grandes construções geram altos custos e toda parte logística dos processos fica mais difícil em espaços muito grandes.

Um desses processos logísticos dentro de um CD é a separação dos produtos para o carregamento nos meios de transporte (caminhões, trens, etc). Nesse processo de separação tem-se a necessidade de destinar um espaço para que se possa, literalmente, separar os produtos em quantidades pequenas, geralmente menores que um *pallet* (estrutura de madeira utilizada para suportar produtos), pois os pedidos muitas vezes são feitos para pequenas quantidades. Então, essa área chama-se área de *picking* e o seu dimensionamento é uma tarefa que pode auxiliar muito na otimização da área utilizada, bem como agiliza a separação dos produtos a serem carregados nos transportes. E, evidentemente, o que melhora o processo como um todo, além de proporcionar melhor gerenciamento da armazenagem.

As quantidades de produtos vendidos ao longo do tempo formam séries temporais. Essas séries podem ser sazonais ou não. E, assim, a área destinada à

armazenagem e a área de *picking* de cada produto podem levar em conta a sazonalidade com o objetivo de otimizar a utilização do espaço dessa área.

A predição das vendas pode ser feita por meio de técnicas tais como as mencionadas anteriormente e, neste trabalho, utiliza-se Redes Neurais artificiais de funções de bases radiais em comparação com modelos estatísticos. Esses modelos estatísticos são os ARIMA da metodologia Box & Jenkins. A comparação foi feita para identificar a melhor solução para a previsão e, assim, dimensionar melhor o espaço destinado à área de *picking*, auxiliando na separação dos produtos para carregamento nos transportes.

1.1 OBJETIVOS DO TRABALHO

1.1.1 Objetivo Geral

O objetivo principal deste trabalho é determinar o tamanho do espaço utilizado por cada produto dentro da área de *picking* e, respeitando a sazonalidade de cada produto, fazer com que essa área seja definida dinamicamente, possibilitando que a empresa possa prever essa mudança e fazê-la sem ônus na armazenagem.

1.1.2 Objetivos Específicos

Os objetivos específicos desse trabalho são:

- Treinar e validar várias topologias possíveis de Redes Neurais artificiais de função de base radial, utilizando o *software* MATLAB, em séries temporais retiradas de um problema real.
- Variar as topologias das Redes Neurais artificiais de função de base radial e verificar seus efeitos na previsão.

- Fazer as previsões dessas mesmas séries temporais, baseadas em modelos estatísticos da metodologia Box & Jenkins, resolvidos pelo software STATGRAPHICS.
- Comparar os resultados obtidos com as duas metodologias verificando o melhor desempenho para cada série temporal com base no RMSE.
- Definir como mudar dinamicamente em cada período o tamanho da área de *picking* de cada um dos produtos estudados de acordo com as previsões e sazonalidades.

1.2 JUSTIFICATIVA DO TRABALHO

Os custos de armazenagem representam cerca de 15% do custo total de uma empresa, sendo que o custo da área de *picking* é aproximadamente 50% desse montante. Assim sendo, quando se definem estratégias de otimização para um melhor *layout* da área de *picking*, também se reduz o custo total de armazenagem, tornando a empresa mais competitiva no mercado.

O *layout* da área de *picking* assim como o seu dimensionamento são atividades de extrema importância quando se trata de um centro de distribuição de produtos com curto período de validade. A área de *picking* é uma área destinada à retirada de produtos em pequenas quantidades, ou seja, quantidades menores que um *pallet* completo. Quando seu dimensionamento é muito grande, pode ocorrer o vencimento da data de validade dos produtos na própria área de *picking*, e quando o dimensionamento é menor que o necessário, ocorre atraso no carregamento dos caminhões que transportam os itens do centro de distribuição até os centros de vendas.

Com o problema de dimensionamento da área de *picking*, este trabalho propõe a utilização de técnicas de previsões de séries temporais, para a estimação do consumo, e a partir deste, fazer o dimensionamento dinâmico das áreas de *picking*, respeitando a sazonalidade dos produtos.

1.3 ESTRUTURA DO TRABALHO

Este trabalho é constituído, além dessa introdução, de uma revisão literatura no capítulo 2 na qual se dá ênfase na fundamentação teórica das Redes Neurais artificiais e das estratégias de armazenamento e na metodologia Box & Jenkins. No capítulo 3 aborda-se o material e o método utilizados neste trabalho. Então, define-se as escolhas dos parâmetros e modelos utilizados. No capítulo 4, apresenta-se as implementações feitas e os resultados obtidos com a técnica de Redes Neurais e metodologia Box & Jenkins. Esses resultados são discutidos e a partir deles é feita a previsão da área de *picking* do próximo período. No último capítulo encontram-se as conclusões e as sugestões para trabalhos futuros são apresentadas.

2 REVISÃO LITERATURA

Os primeiros conceitos de máquinas baseadas no comportamento das células nervosas biológicas surgiram no início da década de 40 (MINSKY; PAPERT, 1988). Em 1943, Warren McCulloch e Walter Pitts apresentaram a primeira discussão sofisticada sobre *neuro-logical network*. Em 1947 publicaram o segundo estudo, intitulado *How we know universals* (PITTS; McCULLOCH, 1947). A partir dessas idéias surgiu o movimento intelectual chamado Cybernetics, o qual tentou combinar conceitos de biologia, psicologia, engenharia e matemática.

A década de 40 terminou com a publicação do livro de Donald Hebb "The Organization of Behavior" (HEBB, 1949). Após a era Cybernetics ter aberto a perspectiva de se construir máquinas baseadas no conhecimento, surgiram, no início da década de 50, os primeiros protótipos neste campo com arquiteturas específicas para desempenhar tarefas determinadas. Contudo, tendo em vista o fato de que os animais podiam aprender a fazer muitas coisas para as quais eles não tinham sido naturalmente adaptados passou-se a ter como meta a construção de máquinas que fossem capazes de aprender. Assim, a década de 50 presenciou o surgimento de muitos sistemas que aprendiam baseados em reforço e em formas simples de aprendizado, sendo que um dos primeiros foi o desenvolvido por Minsky, em 1951.

No final dos anos 50, as pesquisas com Redes Neurais ficaram virtualmente paralisadas, sem nenhuma descoberta importante na área, enquanto que importantes avanços tinham sido alcançados com sistemas especialistas.

O interesse nas Redes Neurais ressurgiu em 1962, com a publicação do livro de Frank Rosenblatt "Principles of Neurodynamics" (ROCHA, 1992). Nesse livro Rosenblatt definiu máquinas denominadas de *perceptrons* e provou muitas teorias sobre as mesmas. Uma onda de entusiasmo dominou a área e muitos pesquisadores passaram a crer que os *perceptrons* seriam a base para uma inteligência artificial (ROSENBLATT, 1962). Contudo, esta ilusão foi logo desaparecendo, pois se constatou que essas redes falhavam na solução de alguns problemas simples, similares a outros em que elas tinham sucesso. O rápido entusiasmo foi sepultado em 1969 com

o livro de Marvin Minsky e Seymour Papert chamado "*Perceptrons*", onde eles provaram que as Redes Neurais de uma única camada de Rosenblatt eram incapazes de resolver alguns problemas elementares como o do ou-exclusivo.

O prestígio e o brilhantismo de Minsky deram grande credibilidade ao seu livro, levando à quase totalidade da comunidade científica a abandonar as pesquisas na área por um longo período.

A década de 70 e o início da de 80 foram marcadas por um silêncio quase geral na área. Alguns poucos pesquisadores como Grossberg, Kohonen, Anderson, Hopfield, Marr, von der Malsburg e Copper continuaram pesquisando e desenvolvendo trabalhos interessantes, principalmente, nas áreas de memória associativa endereçável pelo conteúdo, sistema visual e reformulações do problema de aprendizado das redes (HERTZ; KROGH; PALMER, 1991).

Em 1982, Hopfield deu uma importante contribuição com a introdução da função energia e ênfase da noção de memórias como atratores dinamicamente estáveis (HOPFIELD, 1982). Entretanto, talvez a maior influência desta época tenha vindo dos *perceptrons* de Rosenblatt, pois baseados nessa teoria vários pesquisadores desenvolveram algoritmos para os ajustes dos pesos das Redes Neurais multicamada, culminando com o surgimento do algoritmo conhecido como *Backpropagation* (retropropagação).

O *Backpropagation* primeiramente proposto por Werbos em 1974 (WERBOS, 1974) e independentemente redescoberto por volta de 1985 por Rumelhart, Hinton e Williams (RUMELHART; HINTON; WILLIAMS, 1986), tendo *Parker* (PARKER, 1985) e Le Cun também propostos algoritmos semelhantes (LE CUN, 1985).

Após a descoberta do *Backpropagation* o interesse na área voltou a crescer, desta vez de forma mais madura e consciente. Nos últimos anos, toda a teoria de Redes Neurais teve aplicação, sendo que novas corporações dedicadas à comercialização desta tecnologia têm aparecido. O crescimento da atividade de pesquisa tem sido grande, e novas áreas de aplicação das Redes Neurais têm surgido, tais como: compressão de imagem e voz (HERTZ; KROGH; PALMER, 1991), reconhecimento de caracteres manuscritos (WASSERMAN, 1993), diagnósticos médicos (ROCHA,

1992), conservação de energia (PARK, 1994) e previsões de séries temporais, em especial séries econômicas (LANDI; BARUCCI, 1993) e (PODDIG, 1993).

Atualmente as aplicações das Redes Neurais na previsão de series temporais têm se destacado. Isto pode ser atestado pela tese de doutorado (CASTRO, 2001), que apresenta uma nova técnica de predição não-linear de séries temporais em que a predição é obtida através de Redes Neurais artificiais do tipo Radial Basis Function (RBF), com atribuição dos centros Gaussianos das funções de base radial por decomposição do conjunto de dados em sub-espacos, técnica denominada de centros por Decomposição em Sub-Espacos (DSE).

A decomposição em sub-espacos – ou componentes principais – do espaco de dados é baseada na Transformada Karhunen-Loève (KLT). A predição requer menos amostras prévias conhecidas do que as técnicas convencionais. Adicionalmente é representada uma possível solução para o problema de encontrar dinamicamente a arquitetura da rede neural mais apta a acompanhar não-estacionariedades presentes em muitas séries temporais, esta heurística foi denominada como Janela de Predição Seletiva (JPS).

2.1 REDES NEURAS ARTIFICIAIS

Técnicas de programação elaboradas como as de Inteligência Artificial, vem sendo empregadas na resolução de novos e antigos problemas, pois fornecem soluções que apresentam melhores resultados, seja no produto final como na execução da tarefa trazendo economia de tempo e recursos computacionais.

Dentre estas técnicas as características das Redes Neurais Artificiais que se destacam são a capacidade de aprendizado e generalização. São empregadas no reconhecimento de padrões, composição musical, processamento de sinais digitais e imagens, otimização, visão computacional, robótica e previsão de séries temporais (BRAGA; CARVALHO; LUDERMIR, 1998).

2.1.1 Neurônio Biológico e Artificial

Uma Rede Neural Artificial é um modelo computacional que compartilha algumas das propriedades do cérebro: consiste de muitas unidades simples trabalhando em paralelo sem um controle central.

As conexões entre unidades possuem pesos numéricos que podem ser modificados pelo elemento de aprendizado (RUSSELL; NORVIG, 1995). A essas unidades damos o nome de neurônio e suas conexões sinapses.

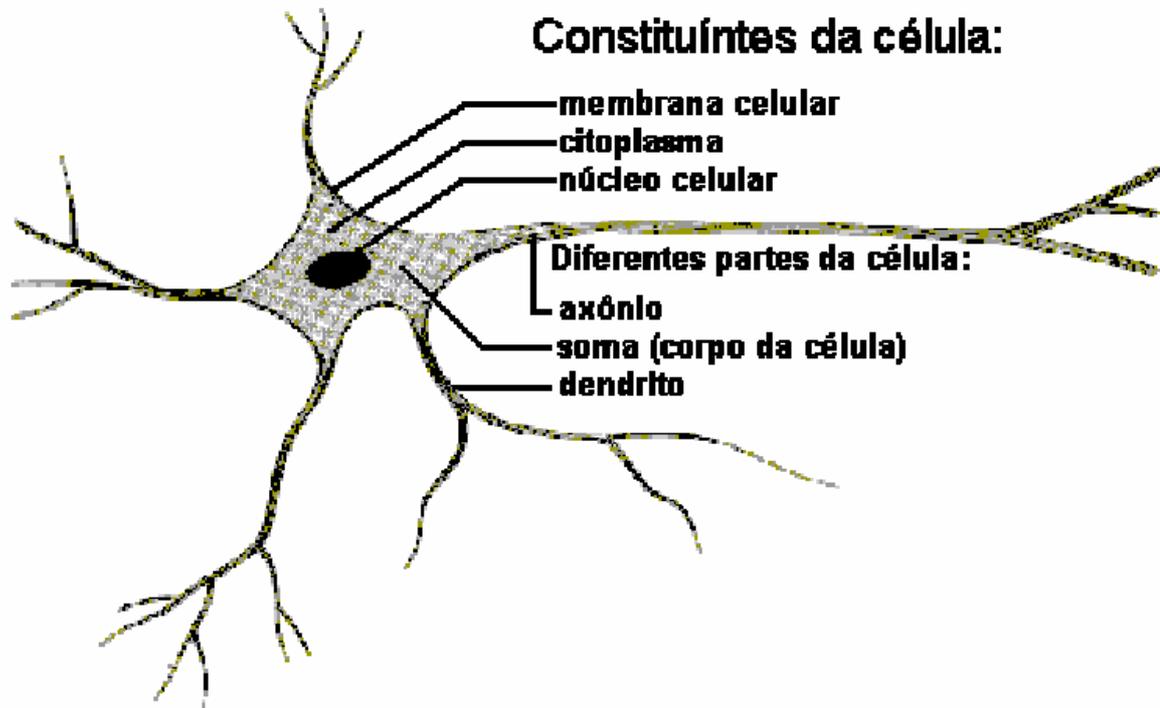
As Redes Neurais Artificiais são semelhantes ao cérebro humano em dois aspectos básicos (HAYKIN, 2001):

- A experiência é a fonte do conhecimento adquirido
- O conhecimento adquirido é armazenado nas sinapses.

O neurônio, célula constituinte do cérebro, ilustrado pela figura 2.1, é composto por um corpo celular chamado “Soma” onde se encontra seu núcleo e por axônios e dendritos.

O axônio é uma fibra nervosa de superfície lisa com poucas ramificações e maior comprimento, é responsável pela transmissão na comunicação com outros neurônios. Os dendritos, que têm aparência de árvores, possuem superfície irregular e muitas ramificações. Atuam como receptores nessa comunicação.

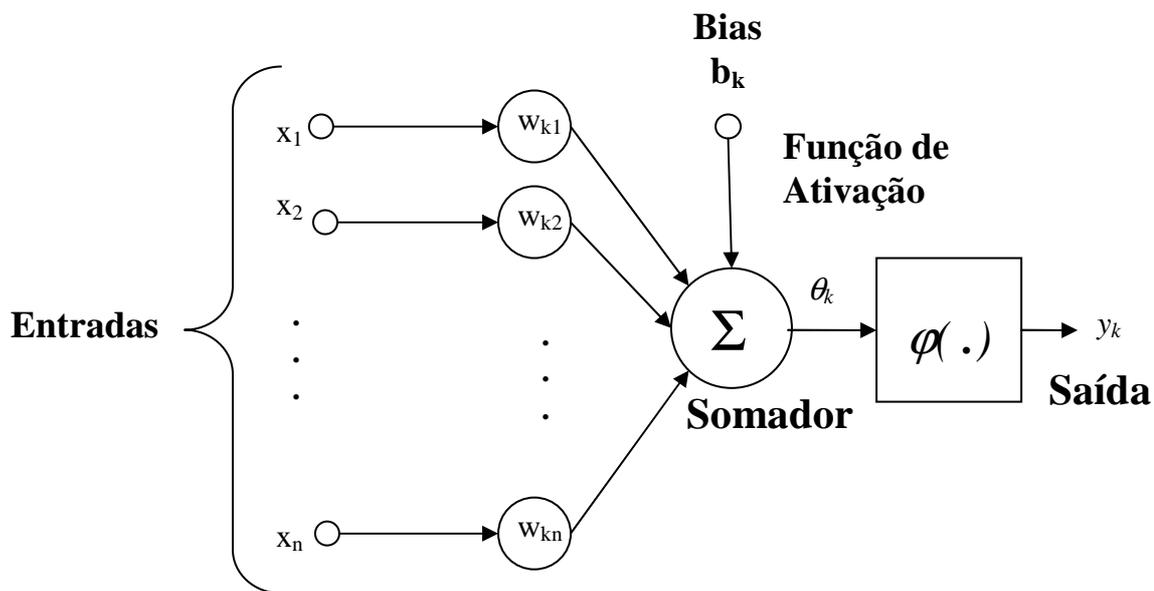
FIGURA 2.1 – NEURÔNIO BIOLÓGICO: OS CONSTITUINTES DA CÉLULA.



Tal comunicação ou interação é chamada sinapse e é caracterizada por um processo químico no qual são liberadas substâncias transmissoras que se difundem na junção sináptica entre neurônios, o que causa aumento ou queda no potencial elétrico do neurônio receptor. Resumindo, uma sinapse é a conexão entre neurônios o que implica em excitação ou inibição do neurônio receptor (HAYKIN, 2001).

De forma análoga, um neurônio artificial apresenta as mesmas características. A figura 2.2 mostra um modelo onde podem ser vistos: sinapses representadas pelas entradas e pesos sinápticos, somatório e função de ativação. Cada sinapse é caracterizada por um estímulo de entrada multiplicado pelo seu peso sináptico correspondente. Depois desta multiplicação, cada sinal de entrada é somado e o resultado é então, aplicado a uma função de ativação que restringe a saída do neurônio a um intervalo de 0 a 1 ou de -1 a $+1$.

FIGURA 2.2 – NEURÔNIO ARTIFICIAL.



fonte: HAYKIN, 2001

O neurônio artificial pode ser descrito pela equação (HAYKIN, 2001):

$$y_k = \varphi \left(\sum_{i=1}^n x_i w_{ki} \right) \quad 2.1$$

Onde, y_k é a saída do neurônio; φ é a função de ativação; x_1, x_2, \dots, x_n são os sinais de entrada do neurônio; e $w_{k1}, w_{k2}, \dots, w_{kn}$ são os pesos sinápticos do neurônio em questão (neurônio k).

Portanto, o neurônio artificial imita o funcionamento do neurônio biológico por meio das entradas, representando as sinapses e pela função de ativação que simula o processo químico que libera substâncias químicas que excitarão ou inibirão os próximos neurônios.

2.1.2 Funções de Ativação

Cada neurônio realiza um processamento simples: recebe uma entrada e computa um novo nível de ativação (RUSSELL; NORVIG, 1995). Este processamento

é composto por duas etapas: na primeira, cada entrada x_i do neurônio é multiplicada pelo peso sináptico correspondente w_{ji} (peso da entrada i do neurônio j).

O resultado de cada multiplicação é então somado. Na segunda etapa a soma é aplicada a uma função de ativação f , obtendo-se a saída do neurônio (y):

$$y = f\left(\sum x_i w_{ji}\right) \quad 2.2$$

A função de ativação deve simular as características não lineares do neurônio biológico (ABELÉM, 1994). As funções mais utilizadas são:

➤ **Função linear:** É uma equação linear da forma:

$$f(x) = ax \quad 2.3$$

➤ **Função degrau:** É uma equação utilizada para valores binários e é da forma:

$$f(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases} \quad 2.4$$

➤ **Função sigmóide:** Também chamada de função logística, é uma função contínua que permite a transição gradual entre os dois estados. É dada por:

$$f(x) = \frac{1}{1 + e^{-x}} \quad 2.5$$

➤ **Função tangente hiperbólica:** É uma função sigmóide que varia entre -1 e $+1$. É dada por:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad 2.6$$

2.1.3 Topologia das Redes

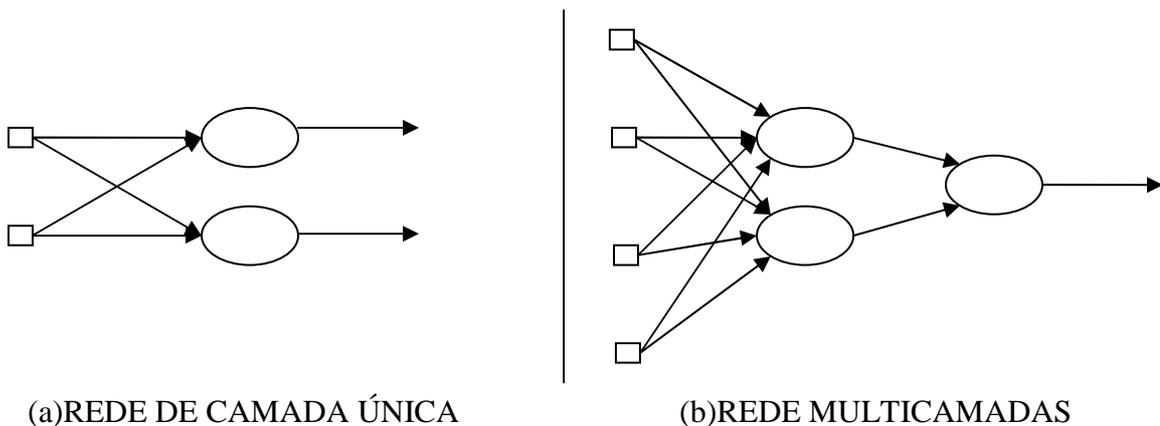
Existe uma grande variedade de redes, cada uma produzindo diferentes resultados. Elas podem ser classificadas basicamente em alimentadas a frente (*feed-forward*) e recorrentes (RUSSELL; NORVIG, 1995).

Nas redes *feed-forward* os neurônios estão dispostos em camadas, podendo haver redes com uma única camada e redes com múltiplas camadas. As redes *feed-forward* são inerentemente acíclicas, ou seja, o sinal é propagado somente da entrada para a saída da rede. Também são chamadas redes sem memória.

As redes multicamadas se distinguem das redes de camada única pela presença de uma ou mais camadas ocultas. As entradas de um neurônio são as saídas dos neurônios da camada anterior, portanto não há ligação entre neurônios de uma mesma camada. Uma rede *feed-forward* é representada pela notação $e - o_1 - o_2 - \dots - o_n - s$, onde e representa o número de neurônios nas camadas de entrada, o_1, o_2, \dots, o_n representam o número de neurônios nas camadas ocultas e s o número de neurônios na camada de saída.

A figura 2.3 ilustra uma rede *feed-forward* de camada única (a) e uma rede multicamadas (b).

FIGURA 2.3 – EXEMPLOS DE REDES FEED-FORWARD



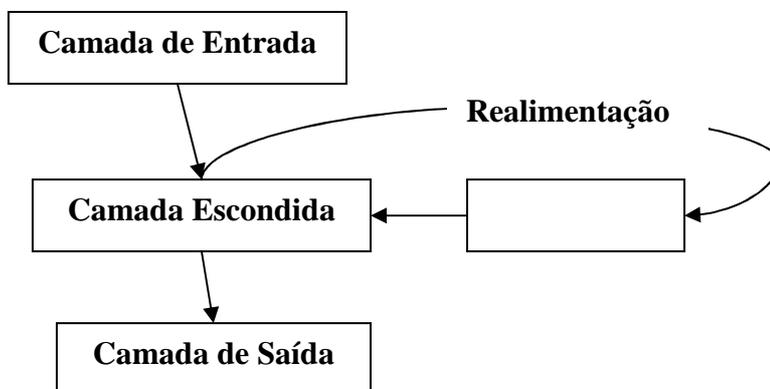
Perceptron e o MLP (*Multi-Layer Perceptron*) são, respectivamente, exemplos de modelos de rede de camada única e rede de múltiplas camadas.

Ao contrário das redes *feed-forward* as redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada para outro de uma camada precedente ou, no caso de auto-realimentação, para o próprio neurônio.

As redes recorrentes, chamadas de redes com memória, não possuem organização rígida e seus neurônios têm liberdade para se ligar a qualquer outro neurônio (RUSSELL; NORVIG, 1995) (HAYKIN, 2001) (ABELÉM, 1994).

A figura 2.4 ilustra uma rede recorrente.

FIGURA 2.4 – REDE RECORRENTE.



Como exemplos de modelos de redes recorrentes tem-se a rede de Elman, rede de Hopfield, rede de Jordan.

2.1.4 Aprendizado das Redes

O processo de aprendizagem ocorre através de um processo iterativo de ajuste dos parâmetros livres, pesos sinápticos, por estimulação do ambiente (HAYKIN, 2001). Os paradigmas de aprendizado são: aprendizado supervisionado e aprendizado não supervisionado e são descritos a seguir.

- **Aprendizado Supervisionado:** também chamado de aprendizado com professor. Esta forma de aprendizado se baseia em um conjunto de exemplos de entrada-saída que é apresentado à rede. A partir da entrada a rede realiza seu processamento e a saída obtida é comparada com a saída esperada. Caso não

sejam iguais, um processo de ajuste de pesos é aplicado buscando-se um erro mínimo aceitável. O algoritmo de aprendizado supervisionado mais comum é o *Backpropagation* (HAYKIN, 2001).

- Aprendizado não supervisionado: é caracterizado pela ausência de algum elemento externo supervisor, ou seja, um padrão de entrada fornecido permite que a rede livremente escolha o padrão de saída a partir das regras de aprendizado adotadas. Possui duas divisões:
 - Aprendizado por reforço que consiste no mapeamento entrada-saída através da iteração com o ambiente e;
 - Aprendizagem não-supervisionada ou auto-organizada onde, a partir de métricas de qualidade do aprendizado, ocorre a otimização dos parâmetros livres da rede.

Pode, por exemplo, ser utilizada a regra de aprendizagem competitiva. Os algoritmos de aprendizado não supervisionado mais importantes são: Algoritmo de *Hopfield* e Mapas de *Kohonen* (HAYKIN, 2001).

2.1.5 Rede Neural de Base Radial

São Redes Neurais com múltiplas camadas que não são treinadas por retropropagação (*backpropagation*) e que não têm unidades de processamento com função de ativação do tipo sigmoidal.

Redes que funcionam de acordo com esta estratégia, utilizam unidades com campos receptivos locais (*local receptive fields*), nos quais as unidades que recebem entradas diretamente da entrada do sistema estão habilitadas a ver apenas parte destas entradas.

Esta abordagem emprega, na maioria dos casos, treinamento supervisionado e não-supervisionado. As redes são muito empregadas como interpoladores/ aproximadores e em tarefas de classificação.

Esta abordagem é inspirada na propriedade de alguns neurônios biológicos chamada de resposta localmente sintonizada (*locally tuned response*). Tais células nervosas respondem seletivamente a um intervalo finito do espaço de sinais de entrada.

O primeiro trabalho lidando com funções de base radial foi introduzido por Medgassy (1961) cujos resultados foram posteriormente usados para interpolação (MICCHELLI; HARTMUT, 1989), para estimação de densidade (DUDA; HART; SONS, 1973) e para aproximação de funções de multivariação suave (*smooth multivariate functions*) (POGGIO; GIROSI, 1990).

Os modelos de RBF de hoje se diferenciam dos primeiros, pois são de natureza adaptativa que permite a utilização, em muitas situações, de um número relativamente menor de unidades de processamento localmente sintonizadas.

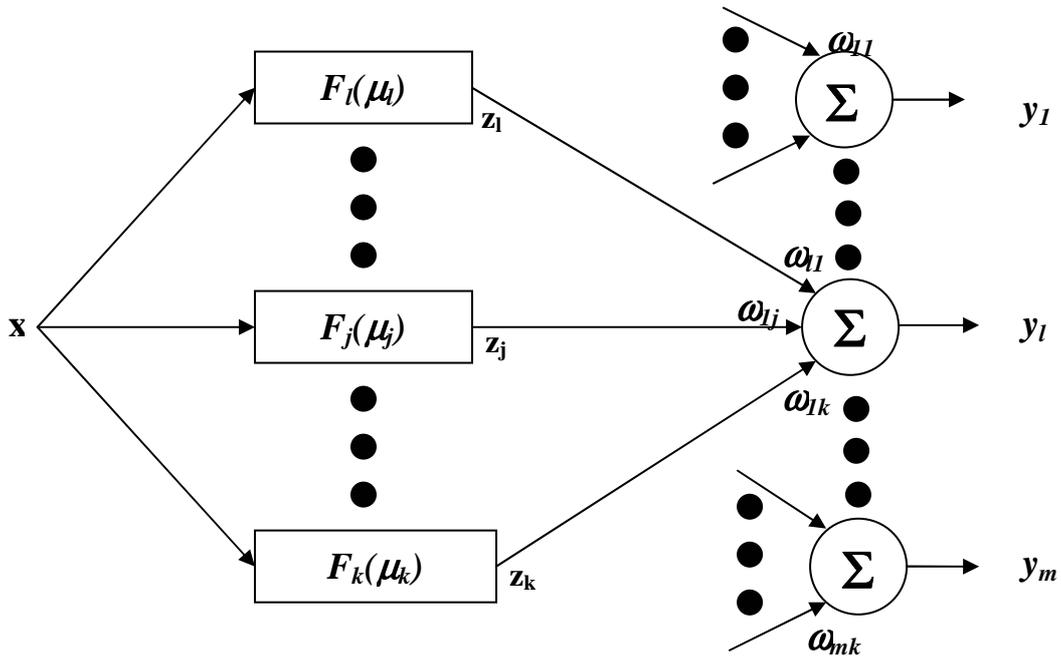
Redes RBF foram independentemente propostas por Broomhead e Lowe (1988), Lee e Kil (1988), Niranjan, Than e Frank (1990) e Moody e Darken (1989). Outros esquemas similares foram introduzidos por Lapedes e Faber (1987), Casdagli (1989), Poggio e Girosi (1990), entre outros.

2.1.5.1 Arquitetura das redes RBF

As redes RBF são redes de alimentação para diante (*feed-forward*) consistindo tipicamente de três camadas: entrada, escondida e saída. A primeira apenas propaga as entradas.

As unidades de processamento da camada escondida são localmente sintonizáveis. As unidades na camada escondida são totalmente conectadas àquelas da camada de saída. Esta última possui funções de ativação lineares.

FIGURA 2.5 – ARQUITETURA DAS REDES RBF



2.1.5.2 Processamento das redes RBF

O processamento consiste em:

- Unidades escondidas recebem o vetor de entrada x_p , $p = 1, \dots, npad$, onde $npad$ é o número de padrões ;
- Cada unidade na camada escondida produz uma saída (Z_j) considerando a proximidade entre a entrada x_p e um vetor parâmetro n -dimensional μ_j em uma dada vizinhança σ_j de acordo com a equação 2.7:

$$z_j(x_p) = F_j(x_p, \mu_j, \sigma_j) \quad 2.7$$

A função $F(v)$ deve fazer com que z_j tenha valor significativo quando o vetor de entrada estiver em sua vizinhança (delimitada pelo campo receptivo), decaindo rapidamente em caso contrário.

A saída é um vetor m -dimensional (y) cujo l -ésimo elemento é dado por:

$$y_l(x) = \sum_{j=1}^h w_{lj} z_j(x) \quad 2.8$$

onde w_{lj} é o peso entre a unidade escondida j e a unidade de saída l .

2.1.5.3 Parâmetros e equações das redes RBF

Redes RBF realizam aproximação de uma função $g(x)$ por superposição de funções de base radial não-ortogonais que têm forma de sino. O grau de precisão pode ser controlado por três parâmetros:

- Número de funções de base usadas;
- Localização;
- Largura do campo receptivo.

Funções de ativação $F(v)$ das unidades escondidas da rede RBF comuns:

- Função de base Gaussiana:

$$z_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad 2.9$$

onde μ_j é a média do campo receptivo da unidade j , σ_j é o desvio padrão do campo receptivo da unidade j e $\|x - \mu_j\|$ é uma norma Euclidiana.

- Função de base logística:

$$z_j(x) = \left[1 + \exp\left(-\frac{\|x - \mu_j\|}{\sigma_j} - \theta_j\right)\right]^{-1} \quad 2.10$$

onde θ_j é um “bias” ajustável.

➤ Função multiquadrática inversa:

$$z_j(x) = \left[\frac{1}{\left(\|x - \mu_j\|^2 + \sigma_j^2 \right)^{\frac{1}{2}}} \right] \quad 2.11$$

Redes RBF são adequadas para aproximar mapeamentos de valores reais contínuos, ou contínuos por partes $f: R^n \rightarrow R^m$, para n suficientemente pequeno.

2.1.5.4 Aprendizado em redes RBF

O método de treinamento, como os demais modelos supervisionados, deve reduzir o erro na saída da rede (E) a valores aceitáveis através da adaptação dos parâmetros livres na rede RBF:

- Os centros dos campos receptivos (μ_j);
- As larguras dos campos receptivos (σ_j) e
- Os pesos entre a camada escondida e a camada de saída (W_{lj}).

A aprendizagem pode ser supervisionada, não-supervisionada ou híbrida (que ocorre na maioria dos casos).

O treinamento híbrido combina aprendizagem não-supervisionada com supervisionada. A primeira treina a camada escondida, definindo os parâmetros desta camada (localização dos centros e larguras dos campos receptivos). A segunda etapa define os valores dos pesos entre as camadas escondidas e de saída.

Nesta segunda fase, os parâmetros definidos na primeira fase não se modificam. Este é o tipo de treinamento mais empregado pois, em geral, não se sabe que saídas se desejam para a camada escondida.

- Treinamento não-supervisionado:
 - Determina os valores dos centros por:
 - (a) seleção aleatória;
 - (b) distribuição sobre uma grade regular;
 - (c) técnica de agrupamento (*clustering*);
 - (d) outro algoritmo.
 - Determina a largura do campo receptivo através de uma heurística;
- Treinamento supervisionado
 - Determina os pesos por um método que resolva o problema de minimização do erro:
 - (a) método dos mínimos quadrados,
 - (b) método da regra delta,
 - (c) matriz pseudo-inversa.
- Treinamento não-supervisionado para a camada escondida

Esta etapa compreende a determinação dos centros das funções de base radial e das larguras dos campos receptivos.

- Métodos para determinação dos centros das funções de base radial

Os centros da camada escondida podem ser selecionados através das seguintes estratégias:

- Seleção aleatória (CHEN, 1991)

Os centros são vetores de entrada aleatoriamente selecionados. Esta técnica demanda que os padrões de treinamento representem acuradamente todo o

espaço de soluções do problema. Este método é simples e direto, no entanto pode exigir grande número de unidades intermediárias; escolher centros muito próximos uns dos outros podem acarretar funcionamento inadequado da rede;

➤ Fixação em grade regular (BISHOP; ADDISON; WESLEY, 1996)

Neste caso, os centros são fixados em uma grade regular, cobrindo todo o espaço de entrada. Em geral, este método exige muitas unidades intermediárias para vetores de entrada com dimensão alta (maldição da dimensionalidade: crescimento exponencial do número das unidades escondidas);

➤ Técnicas de agrupamento (MOODY; DARKEN, 1989)

Os centros são definidos por técnicas de agrupamento. Entre as quais destaca-se algoritmo de k -médias e mapas auto-organizáveis;

➤ Algoritmo das k -médias

Este algoritmo divide os padrões de treinamento em ng grupos, encontrando o ponto central de cada um deles através da expressão:

$$\mu_j = \frac{1}{nv_j} \sum_{x_p \in S_j} x_p \quad 2.12$$

onde nv_j é o número de vetores contidos no agrupamento S_j .

Os primeiros centros são inicializados arbitrariamente. Em seguida, os padrões de entrada vão trocando de centro (de acordo com a distância euclidiana) até se chegar a uma situação estável. O número de centros é determinado de acordo com a estratégia de treinamento: validação cruzada.

➤ Mapas auto-organizáveis

Os mapas auto-organizáveis (*SOM – Self Organizing Maps*) caracterizam-se por agrupar padrões espacialmente próximos que compartilhem micro-características. No início, os centros são aleatoriamente atribuídos. O centro

que apresentar maior produto escalar com um dado vetor de entrada adiciona uma versão ponderada deste vetor de entrada ao seu grupo.

- Heurística para determinação da largura do campo receptivo

O valor de σ_j pode ser único para todas as unidades ou pode ser diferente para cada unidade escondida. Algumas das principais heurísticas são:

- Utilização da distância euclidiana média entre centros (MOODY; DARKEN, 1989):

$$\sigma = \frac{1}{ng} \sum_{j=1}^{ng} \|\mu_j - \mu_{j(mprox)}\| \quad 2.13$$

onde ng é o número de grupos que serão formados e $\mu_{j(mprox)}$ é o centro com menor distância euclidiana com relação ao centro μ_j . Este método produz um único valor de raio.

- Utilização da distância euclidiana o entre centro e vetor de entrada (SAHA; KELLER; MORGAN, 1990):

$$\sigma_j^2 = \frac{1}{nv} \sum_{x_p \in \Psi_j} \|\mu_j - \mu_p\|^2 \quad 2.14$$

onde Ψ_j é o conjunto dos nv vetores de entrada com menor distância euclidiana para o centro μ_j .

- Utilização da distância euclidiana entre o centros (HASSOUN, 1995):

$$\sigma_j = \alpha \|\mu_j - \mu_{j(mprox)}\| \quad 2.15$$

onde $\mu_{j(mprox)}$ é o centro com menor distância euclidiana com relação ao centro μ_j e o parâmetro geralmente se situa $1,0 \leq \alpha \leq 1,5$.

- Utilização da distância euclidiana entre os centros determinados pelo método k -médias:

$$\sigma_j^2 = \frac{1}{na} \sum_{x_p \in S_j} \|\mu_j - x_p\|^2 \quad 2.16$$

onde S_j é o agrupamento contendo na vetores de entrada.

- Treinamento supervisionado para a camada de saída

Esta etapa compreende a determinação dos pesos entre a camada escondida e a de saída. A primeira etapa neste processo é o cálculo do erro. Este é função da resposta dada pela rede comparada com a resposta que se deseja dela. Existem algumas maneiras diferentes de se calcular o erro:

- Soma dos erros quadráticos (SSE – *sum of squared error*)

$$SSE = \sum_{i=1}^{npad} \|y_d^{(i)} - y_0^{(i)}\|^2 \quad 2.17$$

- Erro quadrático médio (MSE - *mean squared error*)

$$MSE = \frac{1}{npad} \sum_{i=1}^{npad} \|y_d^{(i)} - y_0^{(i)}\|^2 \quad 2.18$$

- Erro relativo médio (MRE – *mean relative error*)

$$MRE = \frac{1}{npad} \sum_{i=1}^{npad} \left\| \frac{y_d^{(i)} - y_0^{(i)}}{y_d^{(i)}} \right\|^2 \quad 2.19$$

- Raiz do erro quadrático médio (RMSE – *root mean squared error*)

$$RMSE = \sqrt{\frac{1}{npad} \sum_{i=1}^{npad} \|y_d^{(i)} - y_0^{(i)}\|^2} \quad 2.20$$

onde $y_d^{(i)}$ e $y_0^{(i)}$ são o i -ésimo padrão desejado e obtido respectivamente e n_{pad} é o número total de padrões.

Depois de calculado o erro, este é minimizado por procedimentos tais como a regra delta, o método dos mínimos quadrados, e a matriz pseudo-inversa (os dois últimos, métodos lineares) (BISHOP; ADDISON; WESLEY, 1996).

2.1.5.5 Estratégias de treinamento

O compromisso entre precisão e generalização deve ser conseguido para esta aprendizagem. Para tal, duas estratégias de treinamento podem ser empregadas: *hold-out* e validação cruzada (*crossvalidation*).

➤ *Hold-out*

Neste procedimento o conjunto de padrões é dividido em três grupos: treinamento, validação e teste. Cada topologia tem, com seus centros, seu desempenho testado com relação aos três conjuntos.

➤ Validação cruzada

Esta é uma estratégia típica de situações onde todos os padrões devem ser considerados para o treinamento (normalmente, pois eles são poucos). Neste caso, dividem-se os padrões em ng grupos. Seleciona-se aleatoriamente $ng-1$ conjuntos para treinamento e testa-se a rede com aquele conjunto que não foi selecionado. Este processo deve prosseguir até que todos os conjuntos tenham sido usados para testes. A partir daí, calcula-se o erro (E):

$$E = \frac{1}{ng} \sum_{i=1}^{ng} E_i \quad 2.21$$

2.1.5.6 Desempenho das redes RBF

As redes RBF foram aplicadas com sucesso na aproximação de funções (BROOMHEAD; LOWE, 1988) (LEE; KIL, 1988) (CASDAGLI, 1989) (MOODY; DARKEN, 1989), e em problemas de classificação (NIRANJAN; THAN; FRANK, 1990) (WETTSCHERECK; DIETERICH, 1992). Em tarefas difíceis de aproximação/interpolação (por exemplo, predição da série caótica de Mackey-Glass $T > 50$), redes RBF que empregam a técnica de agrupamento no posicionamento dos campos receptivos podem alcançar desempenho comparável ao das redes de retropropagação (redes de alimentação direta com unidades escondidas sigmoidais e treinadas por retropropagação), enquanto requerem tempo de treinamento algumas ordens de grandeza menor.

No entanto, redes RBF geralmente precisam de pelo menos dez vezes mais dados de treinamento para que atinjam o mesmo grau de acuracidade das redes retropropagação. Em tarefas difíceis de classificação, redes RBF empregando um número suficiente de padrões de treinamento e de unidades escondidas podem superar o desempenho de redes retropropagação, obtendo melhores taxas de classificação e menos erros de classificações positivas falsas.

As redes RBF têm tempo de treinamento muito menor porque apenas uma pequena fração de unidades escondidas responde a um dado padrão de entrada (pois são unidades localmente sintonizáveis, sensíveis apenas a padrões próximos de seus campos receptivos). Isto permite o uso eficiente de algoritmos auto-organizáveis no ajuste dessas unidades no modo de treinamento, que não envolve a camada de saída da rede. Por outro lado, todas as unidades de uma rede retropropagação são avaliadas e têm seus pesos ajustados para cada vetor de entrada. Outro fator que contribui para a velocidade de treinamento das redes RBF é o esquema de treinamento separado da camada escondida e da camada de saída.

Quando utilizadas em aproximação de funções as redes do tipo retropropagação conseguem maior capacidade de generalização (ou extrapolação) que as RBF, pois

ajustam globalmente os padrões de entrada enquanto estas últimas fazem um ajuste local.

Pelo mesmo motivo, em problemas de classificação, redes RBF cometem menos erros de falsa classificação positiva do que as redes do tipo retropropagação. Pode-se dizer que, em geral, é melhor o uso de redes do tipo retropropagação quando os padrões de entrada são custosos (ou difíceis de se gerar) e/ou quando a velocidade de recuperação – considerando-se a implementação em máquinas seriais – é crítica (esse tipo de rede, em geral, é menor, requer menos memória e leva a maiores velocidades de recuperação que as RBF) (CASTRO, 2001).

No entanto, se os dados são baratos e abundantes, e se é necessário treinamento *on-line* (como no caso de processamento de sinal adaptativo e controle adaptativo, onde os dados são adquiridos em altas taxas e não podem ser salvos), então as redes RBF são superiores.

2.2 SÉRIES TEMPORAIS

A Metodologia Box & Jenkins de previsão de séries temporais surgiu no início da década de 1970 e, ao contrário dos métodos existentes até então, exigem bastante conhecimento e experiência do analista. Essa exigência advém do grau de complexidade em sua aplicação. E, os pacotes computacionais ainda não conseguiram uma total flexibilidade para utilização automática.

Durante as décadas 30 e 40 considerava-se a série temporal $\{Z_t, t = 1, 2, \dots, n\}$ como composta por 4 componentes, não observáveis e distintas: T_t (tendência), S_t (sazonalidade), C_t (ciclo) e ruído aleatório (a_t) ou seja $Z_t = f(T_t, S_t, C_t, a_t)$.

As formas de decomposição dessas componentes são:

➤ Modelo aditivo:

$$Z_t = T_t + S_t + C_t + a_t; \quad 2.22$$

➤ Modelo multiplicativo:

$$Z_t = T_t \cdot S_t \cdot C_t \cdot a_t; \quad 2.23$$

➤ Modelo misto:

$$Z_t = T_t \cdot S_t \cdot C_t + a_t. \quad 2.24$$

Wold mostrou que qualquer série temporal Z_t discreta poderia ser representada por modelos AR (auto-regressivos) e MA (médias móveis). Porém, só foi possível a implementação destes métodos na década de 60 com o advento dos computadores de 2ª geração (transistor). O resultado de Wold faz parte de uma abordagem mais geral de processos estocásticos desenvolvida entre outros por Kolmogorov, Wiener e Whittle (OLIVEIRA,2002).

Os Métodos Automáticos ou “caixa-preta” surgiram na década de 60. São as metodologias que podem ser programadas no computador e que requerem pouquíssima intervenção do analista. Correspondem a métodos de ajustamento de curvas com parâmetros sequencialmente atualizados no tempo.

Dentre estas metodologias pode-se citar:

- Regressão (linear simples, múltipla);
- Modelos de médias móveis;
- Métodos de amortecimento (alisamento) exponencial. Constituem a formulação mais popular dos métodos automáticos, dos quais pode-se citar:
 - Método de Brown (para série temporal não sazonal);
 - Método de Winters (para série temporal sazonal);
 - Método de Souza & Epprecht (para série temporal sazonal ou não).

Makridakis fez em 1979 uma competição com 101 séries temporais e depois em 1982 repetiu a competição com 1001 séries temporais. Os métodos automáticos tiveram, na média, o melhor desempenho dentre todos os métodos. Makridakis & Hibon

(2000) realizaram a última competição, com 3003 séries temporais, com os métodos automáticos ainda apresentando bons resultados. A metodologia Box & Jenkins foi proposta em 1970 e se trata do mais importante trabalho na área de previsão de séries temporais. Foi esse estudo o responsável pelo grande desenvolvimento e a correspondente formalização da área de estudo de Séries Temporais.

O trabalho dos pesquisadores Box & Jenkins foi baseado no importante resultado de Wold (1938): “qualquer série temporal pode ser representada por uma estrutura de médias móveis infinita”, ou melhor, “qualquer processo estocástico estacionário Y_t pode ser representado como a soma de dois processos mutuamente interrelacionados, $Y_t = D_t + A_t$, onde D_t é linearmente determinístico (sistemático) e A_t é um processo Médias Móveis infinito ($MA(\infty)$)”.

A parte determinística pode ser uma função exata do tempo, como por exemplo $D_t = A \cos(\omega t)$ que descreve uma oscilação cosenoidal ao longo do tempo. O caso mais simples para D_t é quando se tem $D_t = \mu$. Box e Jenkins em 1970 propuseram uma classe geral de modelos lineares conhecida como ARIMA (*autoregressive integrated moving average*) para a série temporal $\{Z_t, t = 1, 2, 3, \dots, n\}$.

Após Box e Jenkins, ou seja, após 1970 surgiram outras técnicas dentre as quais pode-se citar o filtro adaptativo, o método Frsys, combinações de métodos de previsões dentre outras.

2.2.1 Metodologia Box & Jenkins

Os modelos propostos por Box e Jenkins, também conhecidos como modelos ARIMA, consistem em uma classe de modelos lineares que associam de forma conjunta uma parte auto-regressiva e uma parte médias móveis, ou seja, é feita a integração dos processos (modelos auto-regressivos, médias móveis). Uma aplicação que aborda este estudo em situação semelhante pode ser vista em (OLIVEIRA, 2002)

2.2.1.1 Modelos Auto-regressivos (AR)

Um modelo auto-regressivo (AR) pode ser representado por uma soma ponderada de p valores passados adicionados a um ruído (parte aleatória) e que, em sua forma geral, pode ser apresentado por:

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t, \quad 2.25$$

onde:

- Z_t é o valor da série temporal no instante t ;
- δ representa o termo constante da série;
- ϕ_i corresponde ao i -ésimo parâmetro auto-regressivo, $i = 1, 2, \dots, p$;
- a_t é o erro (ruído) no instante t ;

Em função da quantidade de termos auto-regressivos existente no modelo pode-se dizer que o modelo é de ordem p , $AR(p)$. Os modelos ARIMA costumam ser parcimoniosos, ou seja, têm poucos parâmetros. Os casos mais comuns desses modelos são os de ordem 1 e 2, isto é, $AR(1)$ e $AR(2)$ (MAKRIDAKIS; WHEEL; McGEE, 1983).

Quando os valores da série podem ser apresentados pelo modelo $AR(p)$, a estrutura do processo gerador da série deve ser identificada e, então, estimados os parâmetros do modelo. Então, este poderá ser utilizado para previsão de valores futuros depois da sua adequação ser analisada.

2.2.1.2 Modelos de Médias Móveis (MA)

Um modelo de Médias Móveis (MA) pode ser representado por uma soma ponderada dos ruídos (erros), observados em cada período passado. A representação geral deste modelo pode ser definida por:

$$Z_t = \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad 2.26$$

onde:

- Z_t é o valor observável da série temporal no instante t ;
- δ representa o termo constante da série;
- θ_i corresponde ao i -ésimo parâmetro auto-regressivo, $i = 1, 2, \dots, q$;
- a_t é o erro (ruído) no instante t não explicáveis pelo modelo.

Em função do número parâmetros, q , define-se a ordem do modelo da estrutura Médias Móveis e tem-se MA(q).

Da mesma forma que os modelos Auto-Regressivos, os modelos da estrutura Médias Móveis são parcimoniosos e os casos mais comuns na prática são os modelos de ordem 1 e 2, MA (1) e MA(2) (MAKRIDAKIS; WHEEL; McGEE, 1983).

A razão de se desejar modelos parcimoniosos, ou seja, com poucos parâmetros, está na necessidade de se preservar o maior número de graus de liberdade.

2.2.1.3 Modelos Auto-Regressivos e de Médias Móveis (ARMA)

Os modelos Auto-Regressivos (AR) e os modelos de Médias Móveis (MA) podem ser combinados e, com isso, gerar um novo modelo conhecido como modelo Auto-Regressivo Médias Móveis (ARMA). Os modelos puros AR e MA podem representar uma grande variedade de séries temporais, e com a combinação ARMA, aumentam em muito as possibilidades dos modelos ajustados serem parcimoniosos (MAKRIDAKIS; WHEEL; McGEE, 1983).

Da mesma forma que se aumentam as possibilidades de melhorar modelo a ser ajustado a uma determinada série temporal. A representação geral deste modelo é obtida por:

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}. \quad 2.27$$

Este modelo relaciona os valores passados observados e os erros obtidos em cada período ocorrido. A ordem do modelo é definida em função da quantidade de parâmetros auto-regressivos e de parâmetros moveis. Sendo p a ordem da parte autoregressiva e q a ordem da parte MA tem-se o modelo ARMA (p,q) (WHEEL; MARKIDRAKIS, 1985).

2.2.1.4 Modelos Auto-Regressivos Integrados de Médias Móveis (ARIMA)

Os modelos AR, MA e ARMA são válidos para representação de séries estacionárias. Séries estacionárias são aquelas que no decorrer do tempo permanecem com seus valores em torno de uma média constante, possuem variância constante e a função de covariância, γ_k , só depende da diferença de defasagem k . Muitas séries encontradas na prática não são estacionárias e necessitam ser colocadas nesta forma para serem modeladas conforme Metodologia Box & Jenkins.

Uma série não estacionaria pode ser transformada em estacionária desde que ela seja não estacionária homogênea, tornando-se um número finito de diferenças d (MORETTIN; TOLOI, 1981). A diferença é feita por meio do operador de retardo B , definido por:

$$BZ_t = Z_{t-1} \quad 2.28$$

E, então tem-se:

$$\omega_t = Z_t - Z_{t-1} = Z_t - B Z_t = (1 - B)Z_t = \nabla Z_t, \quad 2.29$$

Se a ordem da diferença é $d = 2$, tem-se:

$$\omega_t = (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) = Z_t - 2Z_{t-1} + Z_{t-2} = \nabla^2 Z_t, \quad 2.30$$

e genericamente tem-se:

$$\omega_t = \nabla^d Z_t. \quad 2.31$$

Uma série temporal estacionária (ω_t), pode ser representada por um modelo ARMA (p, q). Na maioria dos casos, uma ou duas diferenças ($d = 1, d = 2$) são suficientes para deixar as séries na forma estacionária (MORETTIN; TOLOI, 1981).

Se ω_t é uma série de diferenças de Z_t , então Z_t é uma integral de ω_t , de onde vem o modelo auto-regressivo integrado médias móveis ARIMA, que pode ser designado por ARIMA (p, d, q), onde p e q são respectivamente a quantidade de parâmetros AR e MA e d o número de diferença necessárias para transformar a série em estacionária.

O modelo em sua forma geral é representado por:

$$\omega_t = \phi_1 \omega_{t-1} + \phi_2 \omega_{t-2} + \dots + \phi_p \omega_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad 2.32$$

onde:

- ω_t é o valor da serie no instante t após a diferença ou não;
- ϕ_i são os parâmetros auto-regressivos, $i = 1, 2, \dots, p$;
- θ_i são os parâmetros de médias móveis, $i = 1, 2, \dots, q$;
- a_t representa o ruído branco, (ruído com média zero e variância σ_a^2).

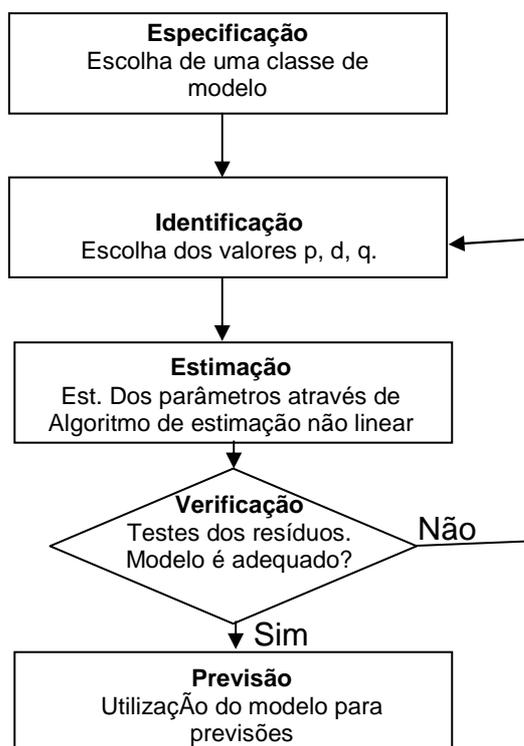
A construção do modelo está baseada num ciclo iterativo onde a determinação e estruturação do modelo, propriamente dito, está baseada nos dados. Este ciclo pode ser resumido nas seguintes etapas (MORETTIN; TOLOI, 1981) onde uma classe de modelos é considerada para análise:

- *Identificação da estrutura do processo gerador* – identifica-se com base na análise das correlogramas das auto-correlações e auto-correlações parciais as ordens p , d e q da estrutura, uma das fases críticas de método.

- *Estimação* – fase em que os parâmetros de um modelo da estrutura identificada são estimados, sendo nesta etapa é necessária a utilização de um algoritmo de programação não linear (Algoritmo de *Marquardt*);
- *Verificação* – através de uma análise de resíduos procura-se verificar se o modelo é o correto; caso seja, pode-se empregar o modelo para a fase de previsão;
- *Previsão* – com o modelo devidamente estimado e verificado. Pode-se realizar previsões para futuros valores da série.

As fases de aplicação de um modelo ARIMA podem ser vistas melhor através do fluxograma Figura 2.6. Para maiores detalhes, consultem-se Box e Jenkins (1976) E Makridakis, Wheel e Mcgee (1983).

FIGURA 2.6 – FLUXOGRAMA



2.3 ARMAZENAGEM ESTRATÉGICA

2.3.1 Armazenagem

Dentro da Cadeia de Abastecimento, uma importante função para atender com efetividade a sua gestão é a Armazenagem. Considerada por muito tempo como uma atividade menos nobre que a produção, a armazenagem passou longos anos tentando viabilizar investimentos que eram escassos (CHIAVENATO, 1989). Porém, segundo (BANZATO, 2003), com o advento dos processos de melhoria da qualidade e produtividade, bem como a elevação da logística como estratégia para um diferencial competitivo, a armazenagem ganhou destaque no gerenciamento da cadeia de abastecimento (FLEURY; WANKE; FIGUEIREDO, 2000).

Atualmente, a armazenagem influi diretamente no nível de serviço aos clientes, na produtividade organizacional, além de afetar a qualidade de produtos e serviços, aspectos esses fundamentais ao sucesso da organização (BALLOU, 1993).

A atividade de armazenagem é o elo entre o produtor e o consumidor, sendo parte integrante do sistema logístico da empresa que estoca produtos entre o ponto de origem e o ponto de consumo, proporcionando informações sobre a situação, condição e disposição dos itens estocados (CHRISTOPHER, 1997).

2.3.2 Missões de um Armazém

Em uma rede de distribuição, um armazém pode atender qualquer uma destas necessidades (COOPER; LAMBERT; PAGH, 1997):

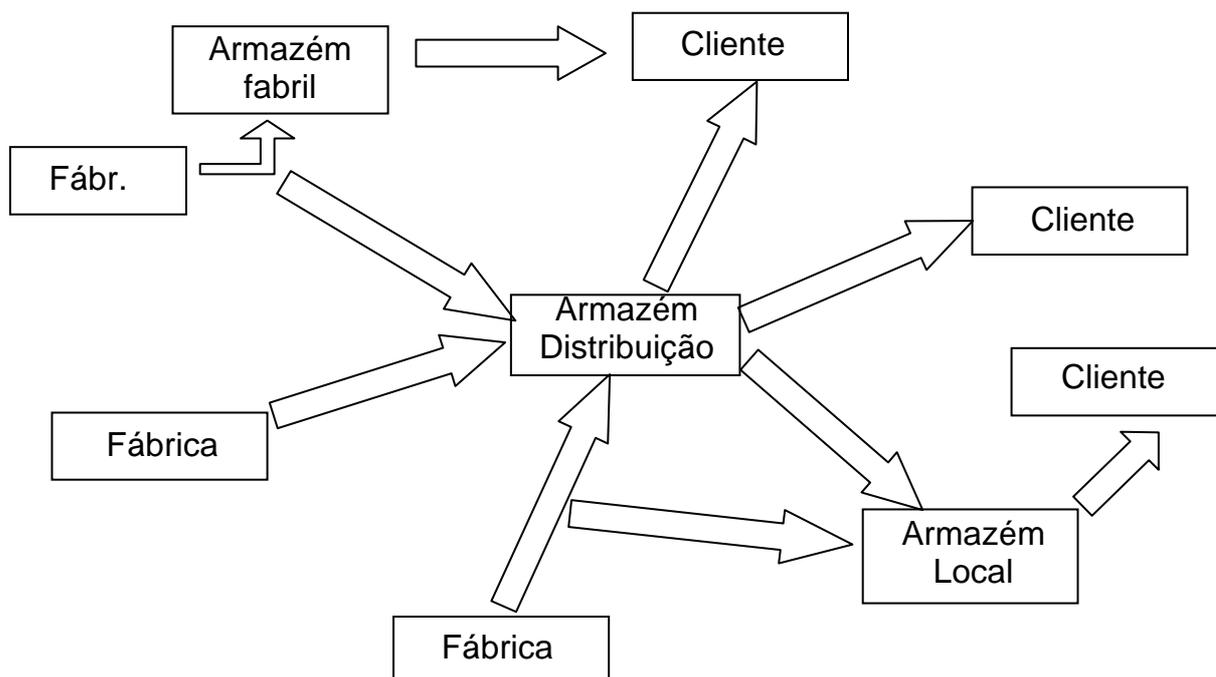
- Ele pode conter estoques usados para equilibrar e amortecer a variação entre as programações de produção e a demanda. Com esta finalidade, um armazém geralmente se localiza perto do ponto de fabricação e pode se caracterizar pelo fluxo de entrada e saída de *pallets* fechados, supondo que o tamanho e volume do produto justifique cargas do tamanho de *pallets*. Um armazém que atenda

apenas a esta função pode ter demandas variando de posições mensais a trimestrais do estoque ao próximo nível de distribuição.

- Um armazém pode ser usado para acumular e consolidar produtos de diferentes pontos de fabricação dentro da mesma empresa, ou de várias empresas, para a remessa combinada a clientes comuns. Tal armazém pode estar localizado em um ponto acessível aos locais de produção ou a base de clientes. A movimentação de produtos pode se caracterizar pela entrada de *pallets* fechados e saída de caixas fechadas. A instalação esta normalmente atendendo pedidos semanais ou mensais regulares.
- Armazéns podem ser distribuídos em campo para diminuir as distâncias de transporte a fim de permitir uma resposta rápida às exigências dos clientes. Com a frequência, itens individuais são coletados, e o mesmo item pode ser expedido ao cliente diariamente.

A Figura 2.7 mostra armazéns realizando estas funções em uma rede de distribuição típica. Em muitas das redes atuais, um item individual entrará e sairá de um armazém servindo a cada uma destas funções entre o ponto de fabricação e o cliente.

FIGURA 2.7 – PAPÉIS DO ARMAZÉM NA REDE DE DISTRIBUIÇÃO



Quando possíveis, duas ou mais missões devem ser combinadas na mesma operação de armazenagem. Mudanças atuais na disponibilidade e custo das opções de transporte tornam a combinação possível para muitos produtos (CERTO, 2003). Em particular, itens pequenos de grande valor e demanda imprevisível são com frequência expedidos para o mundo inteiro de uma única fonte usando serviços de entrega de um dia para o outro (BARROS, 2005).

2.3.3 Funções de um Armazém

Armazenagem é o processo que envolve a administração dos espaços necessários para manter os materiais estocados, que podem ser internamente, na fábrica, como em locais externos, mais próximos dos clientes. Essa ação envolve fatores como localização, dimensionamento de área, arranjo físico, equipamento de movimentação e recuperação do estoque, projeto de docas ou baías de atracação, necessidade de recursos financeiros e humanos (BOWERSOX, 1984).

Várias atividades fazem parte do processo de movimentação de materiais para dentro e para fora do armazém. As funções básicas da armazenagem conforme Moura (1998) são:

- Recebimento (descarga);
- Identificação (classificação);
- Conferência (qualitativa e quantitativa);
- Endereçamento para estoque;
- Estocagem;
- Remoção do estoque (separação de pedidos);
- Acumulação de itens;
- Embalagem;
- Expedição;
- Registro das operações.

Deve-se observar que essas funções da armazenagem nem sempre são utilizadas pelos armazéns da forma que está descrita, elas podem ser descentralizadas entre alguns prédios ou módulos, cada um tem sua própria realidade, tudo depende das necessidades particulares de cada empresa (KWASNICKA, 1987).

2.3.4 Administração da Armazenagem

Estocar mercadorias de forma eficiente utilizando o espaço nas três dimensões, ou seja, deve ser considerada a metragem cúbica do espaço utilizado, é a forma de armazenagem chamada de Administração de Espaço (LILIANE, 2005), e este espaço deve ser realmente muito bem administrado, pois o custo com o desperdício de espaço, é maior do que com mão-de-obra nas mesmas condições.

Um outro objetivo da armazenagem é o de fazer que os produtos fiquem dispostos de forma a facilitar a sua movimentação e o seu resgate, tornando a operação mais rápida e com custos menores (MAXIMIANO, 1981).

Para Banzato (2001), na essência, a principal função da armazenagem é administração do espaço e do tempo. O espaço é sempre limitado e, portanto, os bons operadores usam o espaço disponível efetivamente. O tempo e a mão-de-obra são significativamente mais difíceis de gerenciar que o espaço.

Não se tinha toda essa preocupação com armazenagem há 20 anos, pois não consideravam como parte da distribuição física, apenas como um local para estocar (LIMA, 1998). O equipamento de movimentação tinha mínima importância e a função deste profissional não era reconhecida mesmo sabendo que 20% do PIB (produto interno bruto) é gasto em armazéns e distribuição física e do custo de quase todos os produtos imagináveis, 25% decorre da movimentação física. O controle de todos esses recursos é denominado Administração de Distribuição (BARROSO, 2003).

A armazenagem em qualquer empresa, se bem administrada, pode ser sinônimo de economia, tanto no que diz respeito à economia financeira, ou seja, redução dos custos de armazenagem, quanto economia de espaço físico no armazém, podendo optar por diminuir quantidades de armazéns, se este for o caso, ou então, diminuir o tamanho do armazém (BERTAGLIA, 2003).

A ocupação do espaço físico nos armazéns há algum tempo atrás, era utilizada muito mais como armazenagem horizontal do que vertical, e as empresas, percebendo que isto era um processo que acarretava custo, partiram para a utilização das modernas estruturas metálicas verticais e os portas *pallets*.

Os conceitos de estocagem e armazenagem são similares e foram utilizados por Moura (1998) como sendo estocagem uma atividade de guarda segura e ordenada à ordem de prioridade as matérias primas, e armazenagem como uma atividade de estocagem ordenada e distribuição de produtos acabados na própria fábrica ou para os clientes.

2.3.5 Operações de *Picking* na Armazenagem

A atividade de *picking* é responsável pela coleta correta de produtos, em suas quantidades corretas da área de armazenagem para satisfazer as necessidades do consumidor.

De acordo com Rodrigues (2005), tal atividade dentro de um armazém é considerada como uma das mais críticas. Dependendo do tipo de armazém, 30% a 40% de todos os custos operacionais podem ser atribuídos ao *picking*. O segundo motivo é que a atividade de separação de pedidos se tornou cada vez mais difícil de gerir.

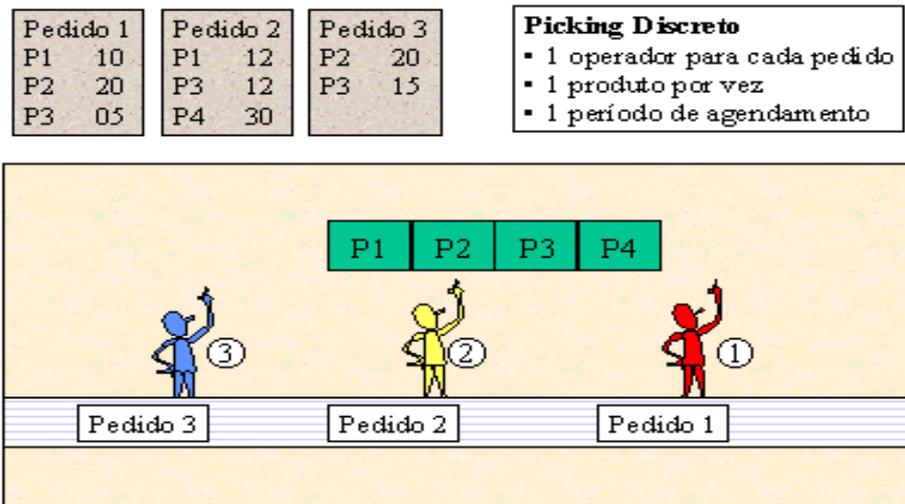
As dificuldades são resultados dos novos programas operacionais, como *just-in-time* (JIT), que requerem pedidos menores sejam entregues com mais frequência e precisão e que mais itens de estoque sejam incorporados ao sistema *picking* (NOVAES, 2001). E um terceiro motivo está na ênfase renovada nas melhorias da qualidade, forçando os gerentes de armazém reexaminarem a atividade de *picking* sob o aspecto de minimizar os danos aos produtos (STONER, 2000).

Para o planejamento de um sistema de *picking*, além dos equipamentos e sistemas envolvidos na armazenagem (SUCUPIRA, 2005), é necessário definir uma estratégia para a coleta e separação de produtos de forma a atender as exigências de produtividade e flexibilidade da linha. Entre a variedade de estratégias operacionais para melhorar a produtividade do *picking*, destacam-se:

2.3.5.1 *Picking* discreto

Conforme ilustrado na Figura 2.8 cada separador completa um pedido por vez e pega apenas um produto de cada vez. A principal vantagem é que a integridade do pedido nunca é prejudicada. Porém, o separador provavelmente terá que percorrer uma grande parte do armazém para separar o pedido;

FIGURA 2.8 – PICKING DISCRETO



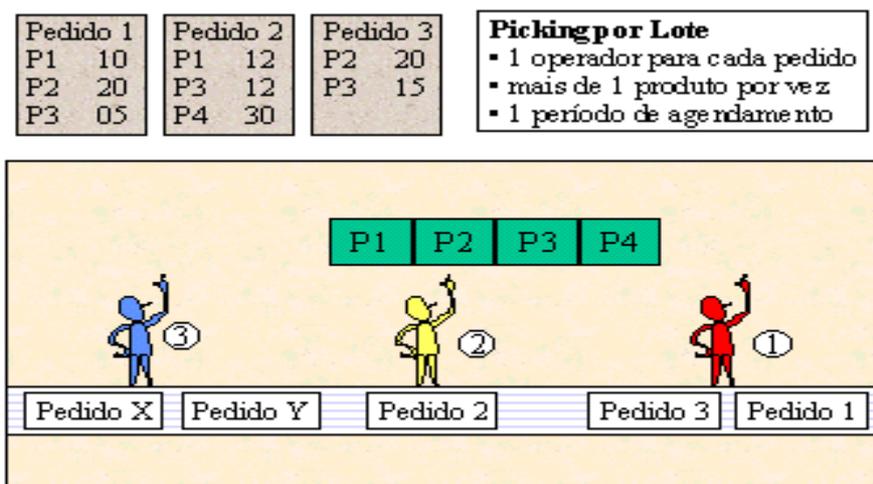
Fonte: Rodrigues (2005).

2.3.5.2 Picking por lotes

Conforme Figura 2.9, cada separador pode assumir a responsabilidade de coletar um lote de pedidos. Quando o operador faz a coleta, ele pega a soma das quantidades de cada produto, necessárias para atender todos os pedidos.

A principal vantagem será a redução do tempo de deslocamento por item individual. Porém, o esforço para restabelecer a integridade dos pedidos aumenta em relação à economia de tempo de deslocamento da separação dos lotes.

FIGURA 2.9 – PICKING POR LOTE.

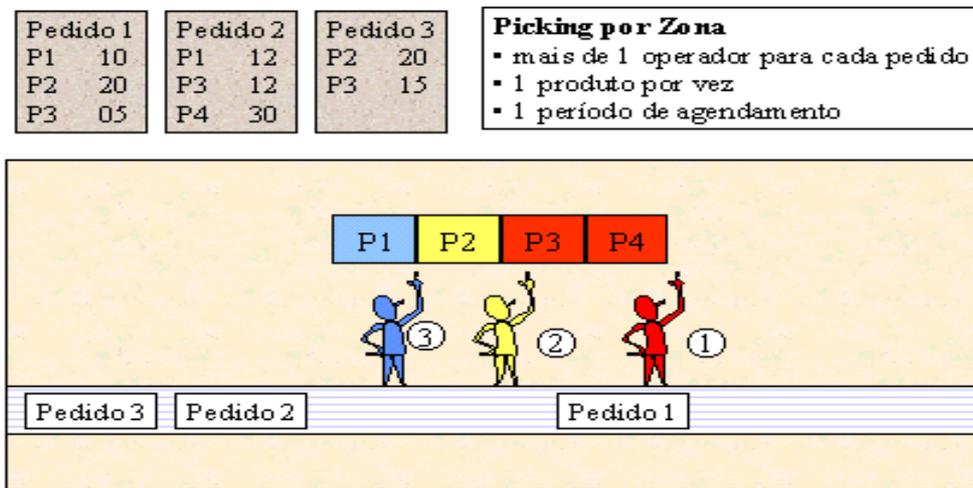


Fonte: Rodrigues (2005)

2.3.5.3 Picking por zona

Um separador de pedidos dedica-se a separar os itens individuais em sua zona atribuída, um pedido de cada vez ou em lotes (Figura 2.10). De novo, a vantagem será a redução do tempo de deslocamento por item individual, que também precisa ter essa redução do tempo comparada aos custos a triagem e potencial de erros no atendimento dos pedidos.

FIGURA 2.10 – PICKING POR ZONA



Fonte: Rodrigues (2005)

Além dos três métodos apresentados é comum a utilização do *picking* por onda. Neste, são realizadas diversas programações por turno, de maneira que os pedidos devem ser coletados em períodos específicos do dia. Esse método é similar ao *picking* discreto, a diferença está no agendamento de um certo número de pedidos ao longo do turno. O *picking* por onda é utilizado em conjunto com os métodos apresentados e a sua vantagem é permitir uma maior integração do *picking* com a área de expedição, através da programação da hora de coleta e embarque de cada pedido.

O método de *picking* utilizado pode ser uma combinação desses apresentados. Normalmente, estas combinações viabilizam um aumento de produtividade, mas também, exige maior controle.

Independente do método utilizado é fundamental a preocupação com a ergonomia. Os incentivos por produtividade e precisão também devem ser considerados como importantes instrumentos na busca por performance de separação.

2.3.6 Sistemas de *Picking*

Existe uma ampla gama de sistemas desenvolvidos para a atividade de *picking* e a sua escolha deve considerar as características específicas da operação (como variedade de itens, tamanho das unidades de separação e velocidade de operação) e os produtos manuseados (como peso, forma e grau de fragilidade), além da tolerância a erros da separação e do orçamento disponível.

2.3.6.1 *A-Frame*

O *A-Frame* Figura 2.11 é um sistema de alta produtividade capaz de separar centenas de pedidos em um curto espaço de tempo, com grande precisão e com um reduzido quadro de pessoal. Este é um sistema modular, integrado por uma esteira transportadora, sobre a qual existe uma estrutura composta de uma serie de canais que cobre ambos os lados da esteira. Cada canal trabalha com um determinado código de item, tendo capacidade de armazenar diversas unidades, que ficam empilhadas em sua respectiva estrutura.

FIGURA 2.11 - *A-FRAME*



O sistema de comando do *A-Frame* controla a ejeção dos produtos de cada canal na esteira e cada seção da esteira é associada a um determinado pedido. No transportados para as outras áreas de *picking*, ou diretamente para área de embarque, caso o pedido esteja completo.

Diversos módulos de *A-Frame* podem ser utilizados – tanto em série quanto em paralelo – para que seja aumentada a capacidade do sistema. Além disso, esta tecnologia também pode ser utilizada em conjunto com outros sistemas de separação.

Este tipo de sistema permite uma separação bastante rápida com alta produtividade, no entanto apresenta algumas restrições de uso relativas a fragilidade e/ou formato dos itens manuseados.

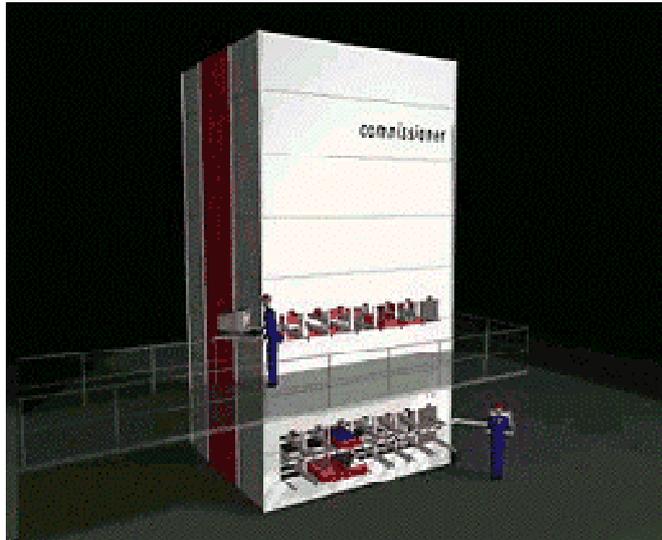
2.3.6.2 Carrossel

Os carrosséis (Figura 2.12) são equipamentos rotacionais, verticais ou horizontais, que acondicionam os produtos com a função de trazê-los até o operador, eliminando os tempos associados ao seu deslocamento e a procura de produtos.

A principal vantagem deste sistema é permitir uma operação com uma grande variedade de itens. Além disso, o carrossel vertical também permite um bom aproveitamento de espaço por aproveitar o pé direito do prédio.

A sua principal desvantagem está relacionada com a velocidade de coleta, relativamente lenta, o que o torna muitas vezes não recomendável.

FIGURA 2.12 – CARROSSEL VERTICAL



2.3.6.3 Sistema de estocagem e coleta automáticas

Os sistemas de estocagem e coleta automáticos capazes de operar com unidades de movimentação mais fracionadas são conhecidos como *miniload* Figura 2.13. No entanto, mesmo os *miniload* são capazes de operar apenas com caixas, ou itens de grande volume.

Entre as principais vantagens do *miniload* pode-se destacar a sua precisão e velocidade, além da potencialidade de operar com uma grande variedade de itens. Entre as desvantagens, destacam-se o elevado custo de implementação e manutenção, e a falta de flexibilidade desses sistemas.

FIGURA 2.13 – *MINILOAD*



2.3.6.4 Separação por rádio frequência

Este tipo de sistema se apóia na comunicação por radio frequência para auxiliar o operador na coleta dos itens. Para isso, o operador utiliza um terminal de mão ou um terminal preso ao braço Figura 2.14, que indica sempre o endereço do próximo produto e o número de unidades a serem coletadas.

Ao realizar a coleta dos itens, o operador faz a leitura do código de barra dos produtos, através do terminal manual que conferirá a coleta e indicará o endereço do próximo produto a ser coletado.

FIGURA 2.14 – TERMINAL DE RÁDIO FREQUÊNCIA COM LEITURA ÓTICA



Este tipo de tecnologia está sendo bastante utilizada no Brasil pelo seu baixo custo e alta flexibilidade. A sua grande desvantagem está relacionada a sua performance que é limitada pela velocidade de deslocamento do operador.

2.3.6.5 Sistema de *picking by-light*

Este sistema concilia *performance* e flexibilidade conseguindo, graças a isso, ser um dos sistemas mais difundidos no Brasil. O *picking by-light* Figura 2.15 integra a utilização de esteiras rolantes, leitores óticos e sensores com as tradicionais estruturas *flow racks* manuseadas por operadores.

FIGURA 2.15 – *PICKING BY-LIGHT*



A boa performance deste sistema é obtida através de uma boa disposição dos produtos ao redor dos funcionários, que coletam apenas os produtos da sua estação de trabalho. Não precisando se locomover nem movimentar as caixas dos pedidos que são transportadas de forma automática por meio de uma correia transportadora.

Além disso, os mostradores digitais de cada posição do *flow-rack* indicam automaticamente o local e o número de unidades que devem ser coletados, tornando desnecessário o *picking list*, o que acelera o processo de coleta dos operadores.

A flexibilidade é o resultado da participação dos operadores no manuseio, que além de considerar as características específicas de cada produto, inclusive a fragilidade, pode, simultaneamente, coletar e organizar os produtos nas caixas de entrega.

3 MATERIAL E MÉTODO

3.1 METODOLOGIAS APLICADAS

3.1.1 Previsão Utilizando Redes Neurais de Base Radial

O desempenho das Redes Neurais é altamente influenciado por alguns fatores, como a quantidade de dados históricos utilizados, a topologia e os parâmetros pertinentes à rede. Atualmente, não existe uma configuração ideal de Redes Neurais, para resolver qualquer que seja o problema sugerido. Para encontrar uma rede que satisfaça a exigências do problema devem ser testadas varias configurações através de processos iterativos procurando a rede ideal ou que se enquadre no perfil procurado.

Esse processo iterativo, também conhecido como tentativa e erro, consiste em constantes modificações na topologia e parâmetros da rede. Existem duas maneiras lógicas para efetuar as modificações nas redes na tentativa de encontrar uma rede adequada: uma delas é definir os parâmetros da mesma com valores pequenos, e a cada iteração aumentá-los, medir o desempenho da rede, e guardar esses históricos para que se possa decidir qual o melhor topologia da rede; uma outra maneira é o processo inverso, ou seja, determinar valores altos para os parâmetros e diminuí-los gradativamente a cada iteração até um mínimo possível, da mesma forma que o anterior, medir o desempenho de cada configuração e depois decidir qual o melhor perfil a ser utilizado.

O processo de mensurar o desempenho da rede está vinculado ao que chama-se de treinamento e teste. Para realizar essas duas fases primeiramente são separados os dados históricos em dois grupos: o primeiro grupo chamando de dados históricos para o treinamento da Rede Neural, corresponde a cerca de $2/3$ da quantidade total de dados; e o segundo é o conjunto de teste ou validação da rede neural, que consiste na utilização da rede comparando as suas saídas com a quantidade de $1/3$ restante dos dados que esta fora do conjunto de treinamento.

Para fazer esta comparação utiliza-se a medida do RMSE (*root mean squared error*). Este índice é obtido em cada uma das configurações obtidas da rede neural a cada iteração, e a configuração que apresentar o menor RMSE é a que mais se encaixa na solução do problema em questão. Este processo também é conhecido como a capacidade de generalização da rede.

Neste trabalho, utilizamos os menores parâmetros possíveis e os aumentamos gradativamente, sendo utilizados sete anos de históricos das séries temporais, onde foram utilizados os cinco primeiros anos para o treinamento da rede neural e os últimos dois anos para a validação da topologia, e é neste período de dois anos que o RMSE é calculado para decisão da melhor configuração.

3.1.2 Parâmetro Número de Ocorrências no Vetor de Entrada

O parâmetro número de ocorrências no vetor de entrada é um fator extremamente relevante para a configuração da rede neural quando estamos utilizando-a para a previsão de séries temporais, como neste trabalho o objetivo da rede neural é exatamente este, a quantidade de ocorrência no vetor de entrada, corresponde ao número de atrasos unitários no tempo que utilizaremos sobre a série temporal em questão podendo ser representado por: $N, N-1, N-2, \dots, N-K$, onde N são as ocorrências sobre a série temporal e K o número do maior atraso unitário que será considerado.

Estes atrasos serão fixo ao longo da serie temporal, e irá caminhando através da mesma compondo o vetor de entrada, formando o que se conhece como janela do tempo.

Os valores que compõem a janela do tempo serão considerados pela rede neural para efetuar o treinamento da mesma, onde o seu objetivo é calibrar os pesos internos para que seja alcançado o valor da ocorrência $N+1$, ou seja, consideraremos K períodos passado ao longo da serie temporal, para prever um período a frente.

De acordo com a série temporal o número de atrasos unitários pode variar melhorando a previsão, pois a série temporal pode conter sazonalidades em algum período ao longo do ano, e a quantidade de ocorrência no vetor de entrada pode

auxiliar a rede neural a identificar esses períodos para uma maior acuracidade em sua previsão. Depois do treinamento da rede neural, são utilizados a mesma quantidade de atrasos unitários, para fazer a validação e as previsões.

O intervalo utilizado neste trabalho foi de 2 atrasos unitários no vetor de entradas até 24 atrasos, incrementando de uma unidade a cada novo treinamento para determinar a melhor configuração.

3.1.3 Parâmetro Número da Taxa de EG

O parâmetro referente à taxa de EG é um fator utilizado para dar um objetivo no treinamento da rede neural. Um valor é atribuído ao mesmo e no decorrer do treinamento o RMSE deve ser no máximo o valor estipulado no parâmetro. Um valor muito baixo não necessariamente significará que a rede tenha um ótimo treinamento, pois pode ocorrer um super treinamento, na tentativa de alcançar o valor estipulado no parâmetro, o que pode prejudicar a capacidade de generalização da rede.

Neste trabalho utilizamos um valor pequeno e a cada treinamento com a tentativa de encontrar a rede ideal, gradativamente o aumentamos, medindo o RMSE (*root mean squared error*) no momento da validação da rede neural, ao atingir o menor erro na validação é o a taxa EG escolhida para os presentes dados da série temporal que esta sendo treinada pela rede neural com o objetivo de se fazer à previsão da mesma.

O intervalo utilizado para definir a taxa de EG foi a variação de $EG = 0,01$ até $EG = 10$, incrementando gradativamente na razão de 0,03 unidades.

3.1.4 Parâmetro Número da Taxa de SC

O parâmetro taxa de SC relaciona-se com a os raios dos campos receptivos das unidades escondidas da rede neural, e é um dos mais importantes parâmetros para o treinamento das Redes Neurais com base radial, pois o mesmo determina o ajuste da linearidade em torno da série temporal.

Se o valor atribuído a este parâmetro for extremamente pequeno pode ocorrer uma distorção na generalização da rede neural, por exemplo: caso o mesmo assuma um fator de $SC = 0.01$, veja na Gráfico 3.1 que ocorre distorções no treinamento, mesmo ocorrendo bons resultados para os pontos utilizados, mas ao utilizar um ponto intermediário aos pontos de treinamento os valores resultantes da rede não serão satisfatórios.

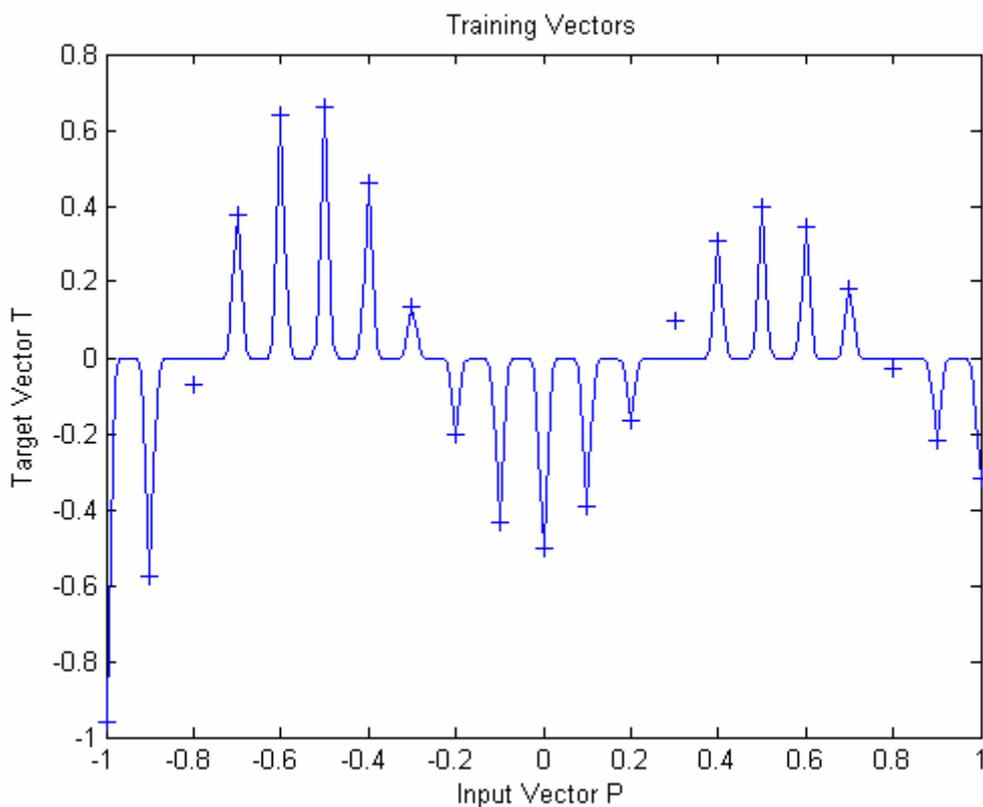


GRÁFICO 3.1 – OCORRÊNCIA DE DISTORÇÕES NO TREINAMENTO I

Por outro lado, se o valor atribuído a este parâmetro for extremamente grande também poderá ocorrer uma distorção na generalização da rede neural. Por exemplo: caso o mesmo assuma um fator de $SC = 100$, veja na figura 3.2 que ocorre distorções no treinamento, e neste caso nem mesmo nos pontos utilizados ocorrem bons resultados, e ao utilizar um ponto intermediário aos pontos de treinamento os valores resultantes da rede terão um maior insatisfatório.

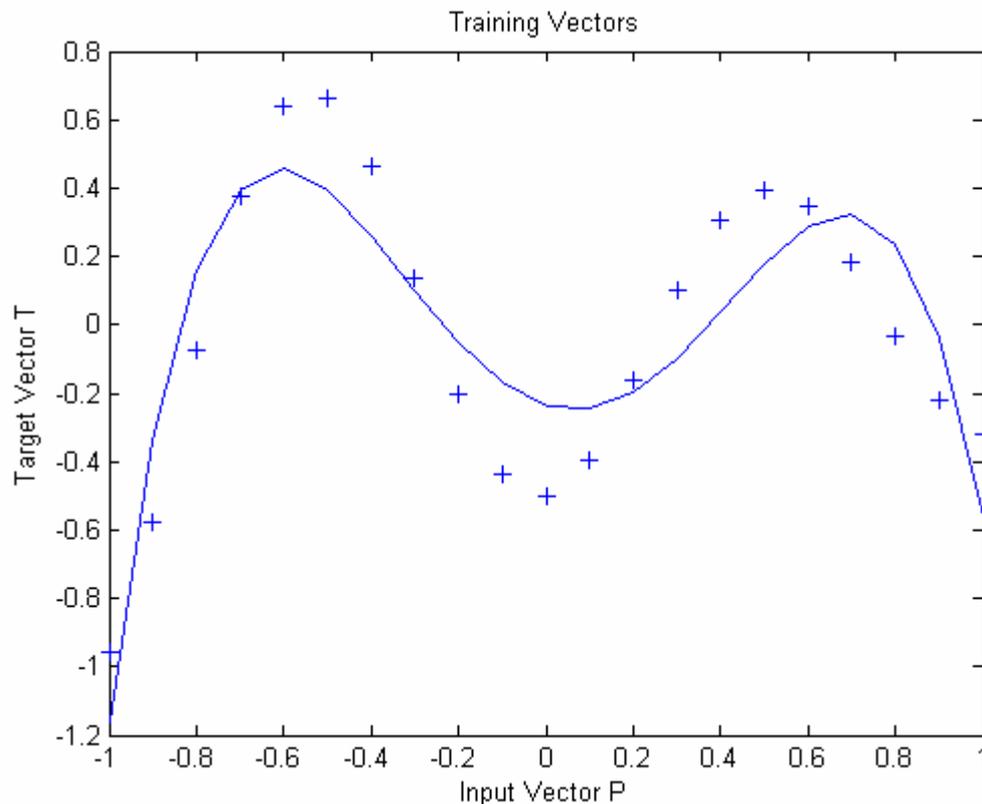


GRÁFICO 3.2 - OCORRÊNCIA DE DISTORÇÕES NO TREINAMENTO II

3.1.5 Escolha do Melhor Parâmetro

Para o efetivo treinamento da rede neural de função de base radial, há necessidade de definir primeiramente os três parâmetros que definem a melhor configuração da rede neural: número de ocorrência no vetor de entrada caracterizando os atrasos unitários ao longo da série temporal, a taxa de EG e a taxa de SC.

Para a determinação dos melhores valores destes parâmetros aplicasse o método que conhecemos por tentativa e erro, ou seja, são testados vários valores medindo o desempenho da rede neural para cada conjunto de valores e escolhendo assim o mais adequado.

Essa metodologia consiste em fixar um pequeno valor para os parâmetros e gradativamente aumentá-lo a cada treinamento efetivado pela rede neural. O primeiro parâmetro a ser especificado é o número de ocorrências no vetor de entrada. A cada incremento é efetivado um novo treinamento na rede neural e o desempenho da mesma

é medido através da utilização do conjunto de ocorrências da série temporal separado para validação.

O desempenho é medido o RMSE (*root mean squared error*), a quantidade de ocorrência no vetor de entrada que apresentar o menor RMSE, é selecionado como o parâmetro pertinente de entrada.

Após a definição do primeiro parâmetro, o mesmo é utilizado para a determinação dos próximos dois. O próximo a ser definido é a taxa EG. O procedimento é praticamente o mesmo utilizado na definição do primeiro parâmetro, a diferença é que agora já fixamos o valor do número de ocorrência no vetor de entrada. Da mesma forma ocorre com o terceiro e último parâmetro utilizado, a taxa SC. Desta vez a diferença é que os dois anteriores, número de ocorrência no vetor de entrada e taxa EG são fixados e utilizados nesta determinação.

Após a aplicação desta metodologia todos os parâmetros foram definidos encontrando a melhor configuração para a rede neural efetuar a previsão da série temporal em questão.

Os intervalos utilizados neste trabalho foram: para o número de ocorrências no vetor de entrada a variação foi de 2 até 24, incrementando na razão de 1 unidade por treinamento; para a taxa de EG e SC a variação foi de 0,01 até 10, incrementando na razão de 0,03 unidade por treinamento.

3.2 Previsão Utilizando a Metodologia *Box & Jenkins*

Para este trabalho na escolha do melhor modelo dentro da metodologia *Box & Jenkins*, foram testados os modelos ARMA com os parâmetros p e q ($ARMA(p,q)$) respeitando à ordem máxima 5. Para cada série temporal os modelo $ARMA(p,q)$, foram ajustados com a ausência do parâmetro de sazonalidade e com sua variação de 1 mês até 12 meses.

Desta forma uma gama de testes foram realizados, comparados em cada uma das séries temporais. Foram utilizados 5 primeiros anos de histórico das série para a definição do melhor modelo e 2 anos restantes para a previsão da mesma.

3.2.1 Ordem dos Parâmetros dos Modelos ARMA(p,q)

Os modelos utilizado para realizar as previsões das séries temporais foram os modelos ARMA(p,q), através da metodologia *Box & Jenkins*. Foram testados os seguintes modelos: ARMA(0,0) SARIMA(0,0) , ARMA(1,0) SARIMA(1,0), ARMA(2,1) SARIMA(2,1), ARMA(3,2) SARIMA(3,2) , ARMA(4,3) SARIMA(4,3) e ARMA(5,4) SARIMA(5,4). Para cada modelo foi utilizado sem a presença de sazonalidade e com a variação da sazonalidades de 1 mês até 12 meses.

3.2.2 Escolha do Melhor Modelo

O ajuste do melhor modelo a ser utilizado para previsão das séries temporais em questão, foi perante a utilização do período de 5 anos de histórico das séries temporais e para validar cada um dos modelos utilizou-se os 2 anos seguintes de histórico. Para cada teste de modelos foram utilizados para definição do modelo ideal dois critérios: o primeiro critério foi à análise do Periodograma Acumulado (*Integrated Periodogram*) e o segundo a análise do RMSE (*root mean squared error*) no período de validação.

O Periodograma Acumulado ilustrado na Gráfico 3.3 refere-se a um gráfico dos resíduos do ajuste do modelo, no presente período histórico da série representado pelos 5 anos. Para cada modelo é verificado o ajuste da linha dos resíduos há linha central do gráfico, o modelo que apresentar a menor oscilação em torno desta é o mais apropriado para efetuar as previsões.

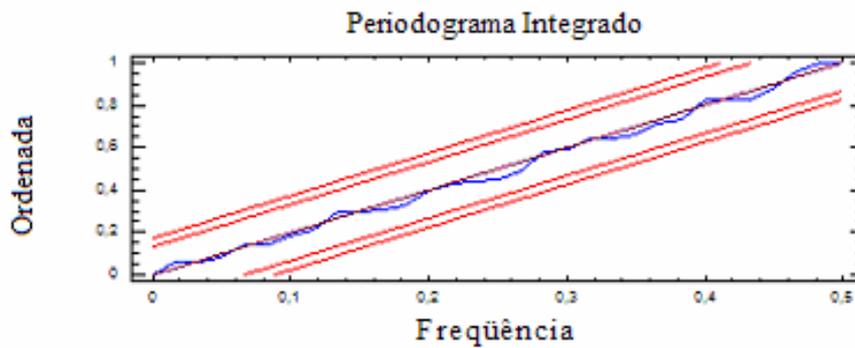


GRÁFICO 3.3 – GRÁFICO DE RESÍDUOS DO AJUSTE DO MODELO.

A medida do RMSE é em relação à previsão para o período de 2 anos seguintes, reservado para validação. Quanto menor o RMSE melhor o desempenho do modelo de previsão.

3.3 MATERIAL

Os dados utilizados neste trabalho correspondem ao histórico de sete grupo de produtos no período de 7 anos. Foi exigido sigilo pela empresa consultada, daí os dados sofreram alterações por meio de uma combinação linear, porém foram mantidas as suas proporcionalidades bem como as sazonalidades para que não houvesse distorções nos cálculos efetuados para previsão das séries temporais.

3.3.1 O Centro de Distribuição (CD)

Neste trabalho, foram considerados sete grupos de produtos alimentícios: biscoito, macarrão, *candies*, chocolates, refrescos, cereais e panetones.

O layout do CD tem as seguintes características: 12.532 m² de área total, em formato retangular; em um lado menor deste, estão localizadas as 16 docas (áreas onde os produtos são colocados, após a separação, para conferência e onde os caminhões encostam para o carregamento); são 89 colunas para armazenagem em cada prateleira, com 5 níveis de altura, do nível 0 (nível do chão) até o nível 4, o que resulta num total

de 15.110 endereços (espaço correspondente a um *pallet* de qualquer produto). *Pallet* é uma estrutura de madeira, confeccionada com tábuas de mais ou menos 5 cm de espessura, formando uma área de aproximadamente 1 m², sobre essa estrutura de madeira são colocados os produtos, para depois serem armazenados nas prateleiras.

Cada *pallet* comporta um número diferente de itens (caixas, fardos, *display* e unidade), dependendo de como cada produto é comercializado. Entre as prateleiras estão as ruas de acesso para aos endereços (são 17 ruas). Exceto as prateleiras das paredes laterais, cada uma possui endereços voltados para duas ruas distintas.

3.3.2 A Área de *Picking*

Área de *picking* é uma parte do armazém destinada à separação dos produtos de um pedido, no momento do carregamento, cuja suas quantidades não correspondem a um *pallet* completo. No armazém estudado para realização deste trabalho, os sete endereços de cada prateleira mais próximos das docas, no nível 0 (zero) em todas as colunas, compõem a área de *picking* dos produtos, totalizando 238 endereços.

A separação dos produtos é realizada da seguinte forma: relacionam-se todos os itens de um determinado produto do embarque, independente do pedido a que pertence, e gera-se uma tarefa ao funcionário que deve buscar todos esses itens, carregando-os nas paleteiras (maquinário manual utilizado para carregar um *pallet*), e levando-os para a doca. Os itens são empilhados sobre a paleteira e o funcionário que está efetuando a separação, levará os itens para doca somente quando a quantidade pré-determinada em sua tarefa estiver satisfeita.

Deste modo, são geradas as tarefas para todos os produtos do embarque e designadas para um número de funcionários suficiente para realização de toda a separação.

3.3.3 Dimensionamento Atual da Área de *Picking*

Nas áreas de *picking*, ocorre o processo de ressuprimento, processo este que consiste na reposição de um *pallet* completo de itens, quando o que se encontra na área de *picking* chega ao fim, com a separação de itens pelos usuários.

A disposição e a quantidade de produtos na área de *picking*, é um fator extremamente relevante para o processo de separação dos produtos para o embarque.

Para cada produto que esta disponível na área de *picking*, é deixado uma certa quantidade de endereços para que possa ser ocupado por *pallets* deste produto.

A empresa dispõe de vários itens, e cada um deles possui varias embalagens de tamanhos e quantidades diferentes para serem comercializados, para facilitar as vendas e os controles, à empresa utiliza uma embalagem padrão. Os itens são agrupados dentro dessas embalagens, e são essas quantidades padrões que foram fornecidas para realização deste trabalho.

Cada *pallet* comporta e 3 unidades dos dados fornecidos. Esta unidade refere-se a uma embalagem onde os itens são agrupados para que comercializados e transportados. Para cada item a quantidade varia dentro desta embalagem, e as quantidades de itens relacionados a cada produto não foram fornecidas.

O cálculo das quantidades de endereços por produtos, foi efetuado através de um somatório em unidades de *pallets* dos últimos 5 anos de todos os 7 produtos apresentados aqui neste trabalho, e realização uma media diária, e para essa media dividiu-se por 2 ressuprimento por turno de trabalho, e como a empresa funciona 3 turnos então dividiu-se por 6 e trabalhando os resultados obtidos juntos aos funcionários mais experientes chegaram a conclusão que área de *picking* ocuparia os 7 endereços mais próximos das docas de cada prateleira, no nível 0 em todas as colunas, totalizando 238 endereços. As quantidades de endereços por produto ficaram conforme o quadro 3.1 abaixo.

QUADRO 3.1 – QUANTIDADE ATUAL DE ENDEREÇOS POR PRODUTO ATUAL

Biscoito	Macarrão	<i>Candies</i>	Chocolate	Refresco	Cereais	Panetones	Total
38	38	38	38	35	30	21	238

Uma quantidade excessiva de endereços para um determinado item poderá causar problemas de vencimento de data de validade. Como os *pallets* estão dispostos um ao lado do outro formando uma fila, os separadores tendem a separar itens do primeiro *pallet*, pois o mesmo é o que está mais próximo da área de *picking*, e quando no mesmo ocorre o esvaziamento completo será ressuprido. Como possui muitos *pallets*, o ressuprimento acontecerá antes que o *pallet* que esta no ultimo endereço da fila seja consumido, e os separadores começam novamente separar itens do primeiro *pallet*, que foi o que acabou de ser ressuprido. Com isso, pode ocorrer que os últimos *pallets* daquele produto na área de *picking*, acabam não sendo consumido, provocando o vencimento da sua data de validade.

Por outro lado, se a quantidade de endereços para um determinado item for pequena demais para o nível de consumo do item, pode ocorrer que os usuários ficam parados esperando o *pallet* que foi totalmente esvaziado ser ressuprido, para que possam completar a quantidade de itens destinado em sua tarefa, causando assim, um aumento no tempo de separação e conseqüentemente no tempo de embarque, o que torna um fator negativo para a eficiência do processo, podendo ocorrer o atraso de cargas.

3.3.4 Produtos e suas Sazonalidades

Os itens deste armazém tratam-se de produtos alimentícios, que estão divididos em 7 grupos, formando o portfólio de comercialização da empresa. Cada grupo é descrito adiante com suas características de consumo e sazonalidade, os dados correspondem ao período 01/01/1999 á 31/12/2005, totalizando 7 anos de históricos.

a) BISCOITO – Esta categoria representa cerca de 25% das movimentações totais do armazém, representado a categoria com maior índice de movimentação na área de *picking*. Conforme relatos fornecidos pela empresa, o consumo deste produto possui um aumento substancial relacionado ao início do período de volta às aulas escolares do ensino fundamental, nos meses de março e agosto. Após o início das aulas, no primeiro semestre, ocorre uma demanda constante nos meses de abril, maio, junho e julho. Já no segundo semestre o aumento consiste em relação o primeiro mês e permanece constante nos meses de setembro, outubro, novembro, dezembro. Nos meses de janeiro e fevereiro o consumo cai substancialmente.

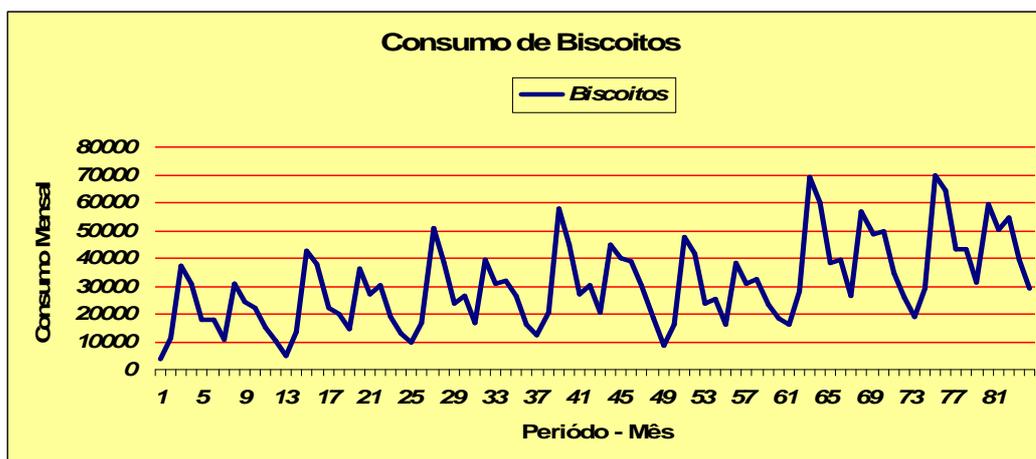


GRÁFICO 3.4 – CONSUMO DO PRODUTO POR PERÍODO - BISCOITO

Fonte: Empresa de Produtos Alimentícios

A título de ilustração são apresentados às subdivisões e percentuais de movimentação dentro da categoria Biscoito:

- 25 % Biscoito
 - 30 % Recheados
 - 22 % Wafers
 - 18 % Roscas
 - 15 % Tradicionais
 - 9 % Sortidos
 - 6 % Diversos

b) MACARRÃO – Esta categoria é responsável por cerca de 20% das movimentações de itens na área de picking, segundo dados da empresa o consumo de macarrão possui um pequeno aumento no período de inverno, nos meses de julho, agosto e setembro e uma pequena baixa de consumo no verão nos meses de dezembro, janeiro, fevereiro e março.

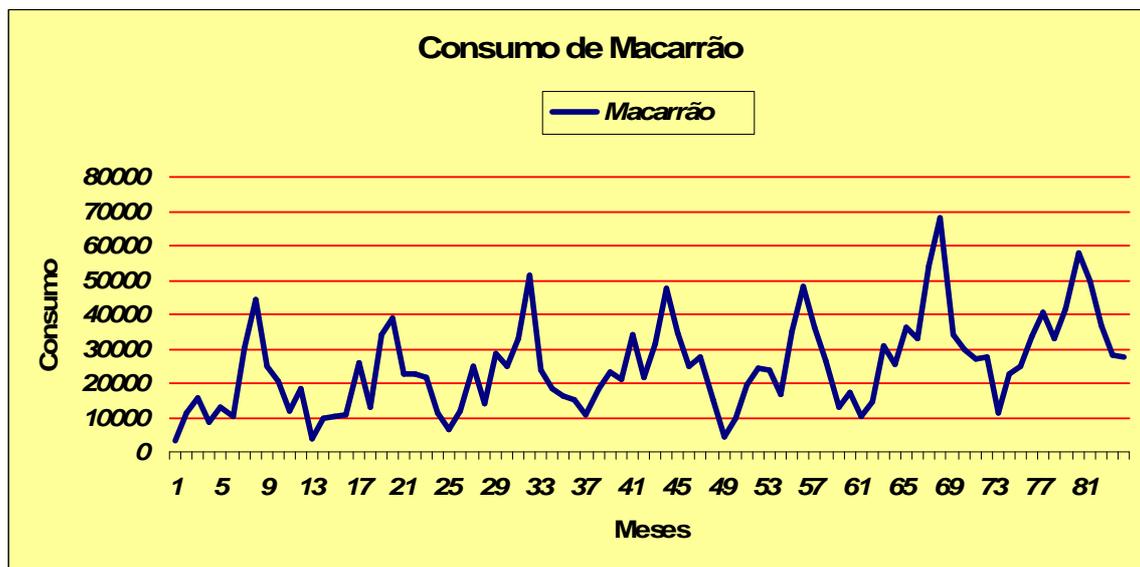


GRÁFICO 3.5 – CONSUMO DO PRODUTO POR PERÍODO - MACARRÃO

Fonte: Empresa de Produtos Alimentícios

A título de ilustração são apresentados as subdivisões e percentuais de movimentação dentro da categoria Macarrão:

- 20 % Macarrão
 - 35 % Com ovos/cortados
 - 25 % Com ovos/ninho
 - 25 % Sêmola
 - 15 % Instantâneo

c) *CANDIES* – Esta categoria é responsável por cerca de 18% das movimentações dos itens na área de picking. O consumo desses produtos é considerado constante, ou seja, as variações não são previsíveis e nem apresentam períodos sazonais aparentemente.

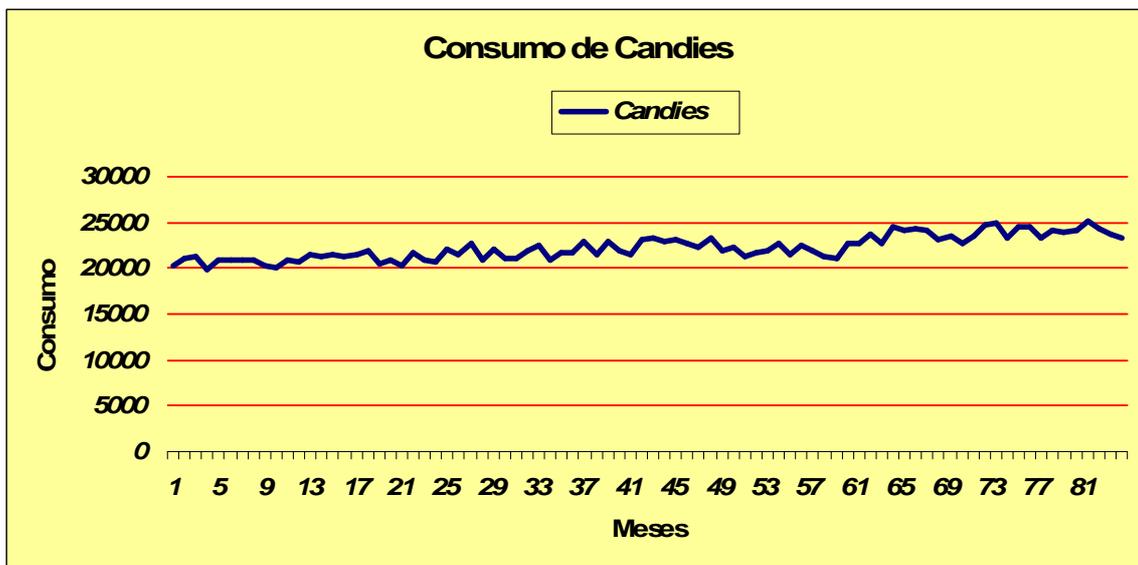


GRÁFICO 3.6 - CONSUMO DO PRODUTO POR PERÍODO - *CANDIES*

Fonte: Empresa de Produtos Alimentícios

A título de ilustração são apresentados às subdivisões e percentuais de movimentação dentro da categoria *Candies*:

- 18 % Candies
 - 43 % Balas mastigáveis
 - 37 % Balas duras
 - 20 % Pirulitos

d) CHOCOLATES – Esta categoria é responsável por cerca de 18% das movimentações dos itens na área de picking. Este produto possui uma regularidade em seu consumo, possui picos aparentes na páscoa, e uma pequena suavização dos dois últimos meses do ano.

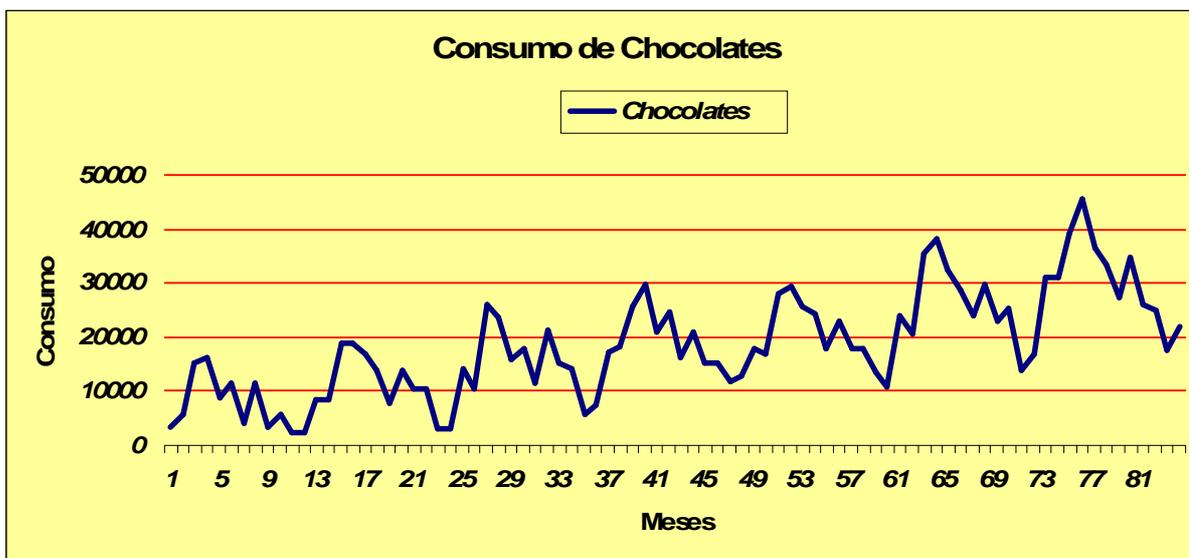


GRÁFICO 3.7 - CONSUMO DO PRODUTO POR PERÍODO - CHOCOLATES

Fonte: Empresa de Produtos Alimentícios

- 15 % Chocolates

e) REFRESCOS – Esta categoria é responsável por cerca de 12% das movimentações dos itens na área de picking. Este produto apresenta um forte aumento de consumo no verão chegando ao maior índice mais especificamente em dezembro.

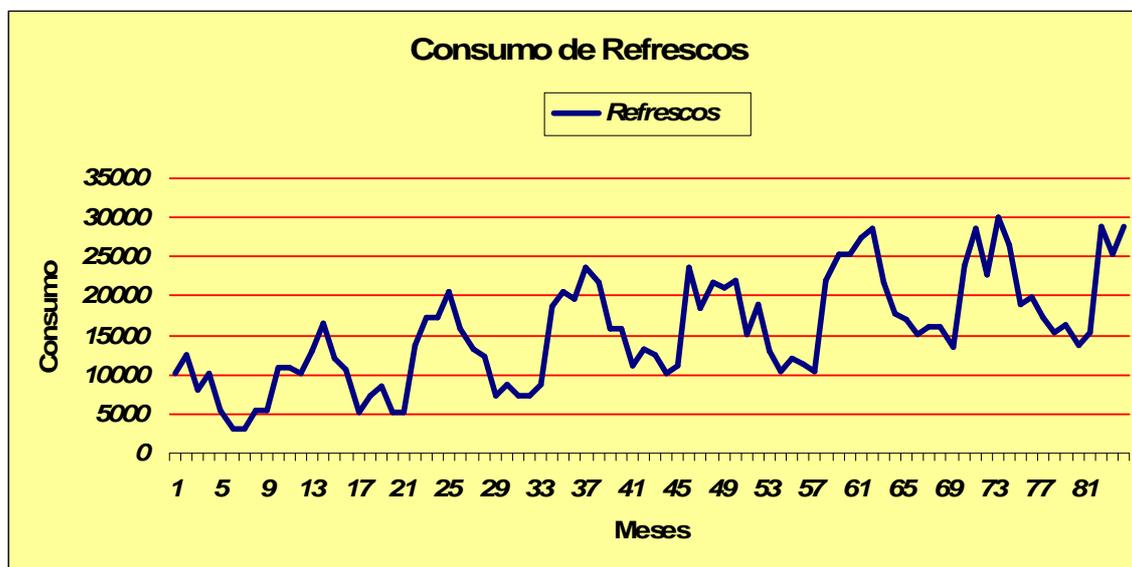


GRÁFICO 3.8 - CONSUMO DO PRODUTO POR PERÍODO - REFRESCOS

Fonte: Empresa de Produtos Alimentícios

- 12 % Refrescos

f) CEREAIS – Esta categoria é responsável por cerca de 7% das movimentações dos itens na área de picking. Este produto possui uma demanda constante sem alterações ao longo do ano e representa uma pequena parcela no consumo total.

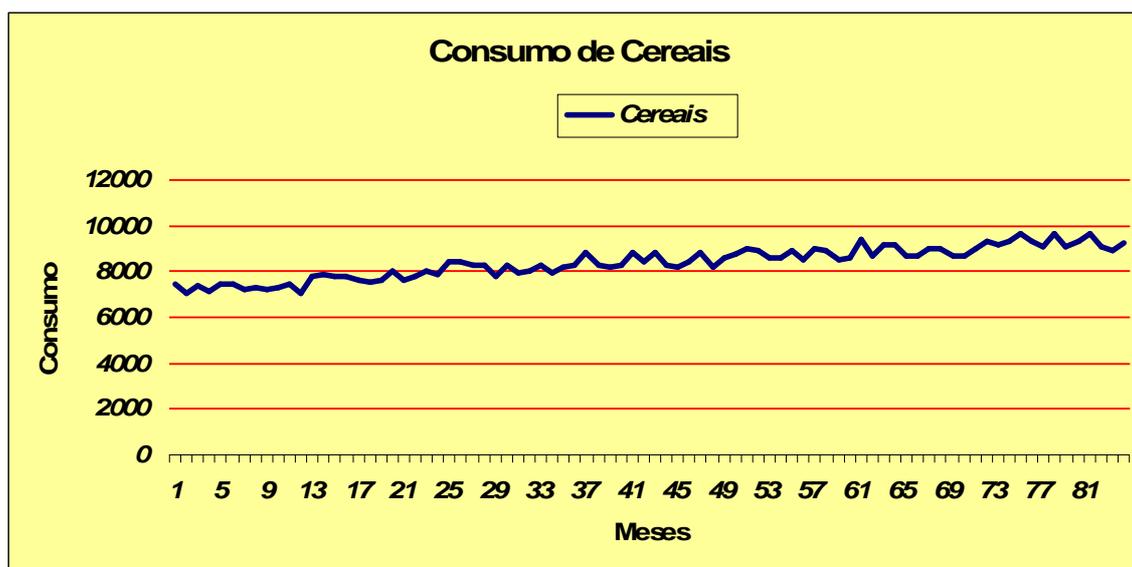


GRÁFICO 3.9 - CONSUMO DO PRODUTO POR PERÍODO - CEREAIS

Fonte: Empresa de Produtos Alimentícios

- 7 % Cereais

g) PANETONES – Esta categoria é responsável por cerca de 3% das movimentações dos itens na área de picking. Este produto possui uma grande sazonalidade nos períodos próximos do natal (mês de dezembro), com uma caída considerável nos outros meses.

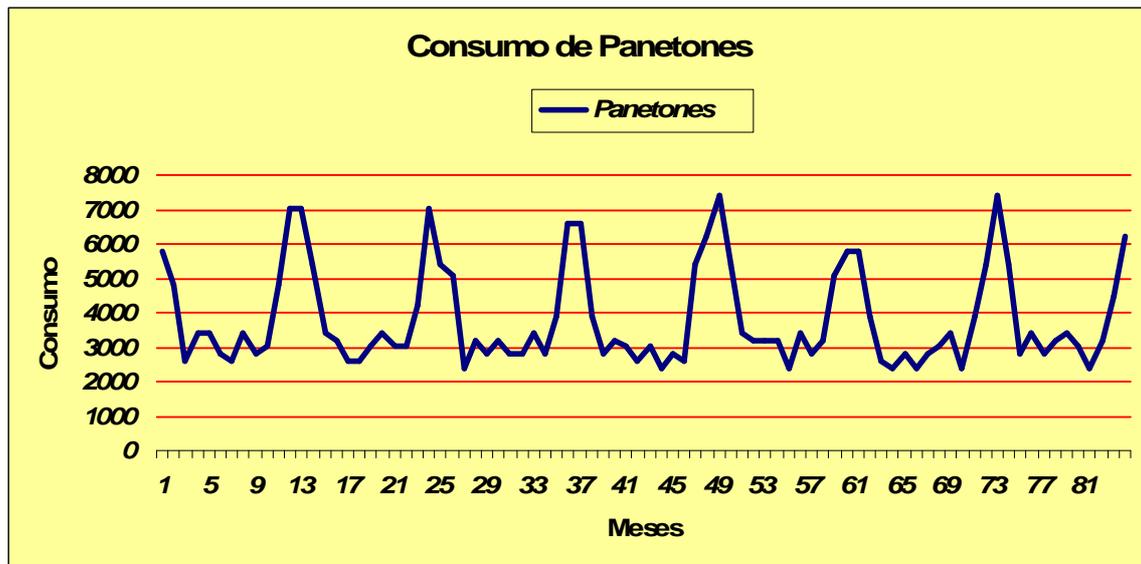


GRÁFICO 3.10 - CONSUMO DO PRODUTO POR PERÍODO - PANETONE

Fonte: Empresa de Produtos Alimentícios

- 3 % Panetones

3.4 MÉTODOS

Para utilização das Redes Neurais RBF foram utilizados:

- Funções de ativação $F(v)$ das unidades escondidas da rede RBF comuns:
 - Função de base Gaussiana:

- Aprendizado em redes RBF
 - Treinamento supervisionado
 - Método da regra delta,

- Para determinação da largura do campo receptivo
 - Utilização da distância euclidiana média entre centros

- Treinamento supervisionado para a camada de saída
 - Raiz quadrada do erro quadrático médio RMSE; Depois de calculado o erro, este é minimizado por procedimentos tais como a regra delta.

- Estratégias de treinamento
 - *Hold-out*, neste procedimento o conjunto de padrões é dividido em três grupos: treinamento, validação e teste. Cada topologia tem, com seus centros, seu desempenho testado com respeito aos três conjuntos.

Para utilização da Metodologia Box & Jenkins foram utilizados:

- Os modelos utilizado para realizar as previsões das séries temporais foram os modelos ARMA(p,q), através da metodologia *Box & Jenkins*.

4 IMPLEMENTAÇÕES E RESULTADOS

A implementação dos programas desenvolvidos neste trabalho, necessitam de dois softwares auxiliares: Matlab versão 6.5 (para desenvolver o programa contendo as Redes Neurais de função de base radial), e o Statgraphics Plus 5.1 (para analisar as séries temporais em função da Metodologia Box & Jenkins). Foi utilizado para desenvolvimento e teste um computador *NoteBook Pentium 4 Intel* com processador 3.2 GHz e 1Gb de memória RAM.

A configuração da rede neural que melhor corresponde à previsão de uma determinada série temporal deve ser obtida, fazendo teste de várias configurações variando seus parâmetros de entrada e medindo o seu desempenho de previsão, e para facilitar esse trabalho e conseguir a configuração ideal desenvolveu-se um programa automático que testa uma infinidade de configurações variando os parâmetros de entrada da rede neural. Neste desenvolvimento foi utilizado o software *Matlab*.

Os parâmetros de entrada da rede neural foram:

- Taxa SC;
- Taxa EG;
- Número de ocorrências no vetor de entrada;

A linguagem utilizada para o desenvolvimento foi à linguagem própria do *Matlab*.

Este programa que se encontra no Anexo 1, estava preparado para iniciar os parâmetros com um valor mínimo dos parâmetros e incrementando um por vez até o limite máximo estipulado para cada parâmetro. Ao encontrar o melhor valor para cada parâmetro o mesmo é fixado e utilizado na variação do próximo.

Essa seqüência é utilizada até que todos eles sejam estimados e satisfaça a melhor previsão para a determinada série temporal. A performance do programa foi considerada adequada, pois para cada série o tempo de processamento para encontrar a topologia ideal foi em média 90 segundos.

Após a escolha da configuração ideal, o programa gera os gráfico de treinamento, que para este trabalho foi utilizado 5 anos para o treinamento, e o gráfico da previsão, que foram estipulados para este trabalho os 2 últimos anos, o qual compara-se com o valor real e ainda gera-se o cálculo do RMSE (*root mean squared error*) para esta previsão.

A escolha do melhor modelo da metodologia *Box & Jenkins* foi auxiliada pelo *software* estatístico *Statgraphics*. Este software permite que seja informado a ordem máxima dos modelos ARMA(p,q) e sua sazonalidade. O software emite as simulações para cada combinação de parâmetros p e q do modelo ARMA respeitando a ordem máxima, calcula o RMSE e para o menor deles apresenta os resíduos, retirados do ajuste do modelo, que possibilita a criação do gráfico Peirodograma Integrado, utilizado para a análise da consistência do modelo para as previsões.

Da mesma forma, nas Redes Neurais são utilizados 5 anos do histórico das séries temporais para o ajuste do modelo e 2 anos para as previsões. As previsões são retiradas do *Statgraphics* e utilizadas no *Matlab* para gerar o gráfico de comparação com o consumo real nos 2 últimos anos e o cálculo do RMSE na previsão.

4.1 TOPOLOGIAS ESCOLHIDAS

Neste trabalho foi analisado sete séries temporais de consumo de produtos alimentícios, sendo utilizado como principal ferramenta de comparação entre as previsões feitas, através das Redes Neurais com bases radiais e a metodologia *Box & Jenkins*, o parâmetro RMSE. Serão apresentadas as comparações exibindo os gráficos pertinentes e as previsões em cada situação estudada. Foi utilizado 7 (sete) anos de histórico das series, dos quais foi utilizado 5 (cinco) primeiros anos para o ajuste do modelo, tanto para redes RBF quanto para metodologia Box & Jenkins, e os últimos dois (anos) para validação e escolha entres esses dois modelos para efetivamente realizar as previsões. Como foi citado logo acima, a medida do RMSE que indicara o modelo mais adequado, ou seja, nos dois últimos anos o que apresentar o menor RMSE.

4.1.1 Serie Temporal - Biscoito

O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.1.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi : SARIMA(3,2) X (3,2) com sazonalidade de 6 meses.

O gráfico do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

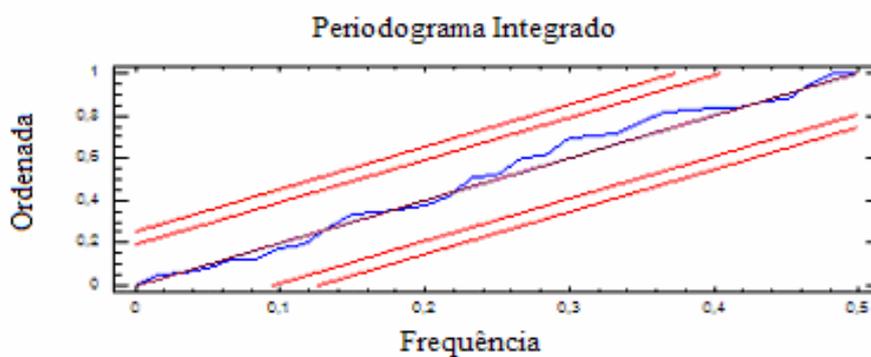


GRÁFICO 4.1 – PERIODOGRAMA INTEGRADO – BISCOITO

A tabela adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

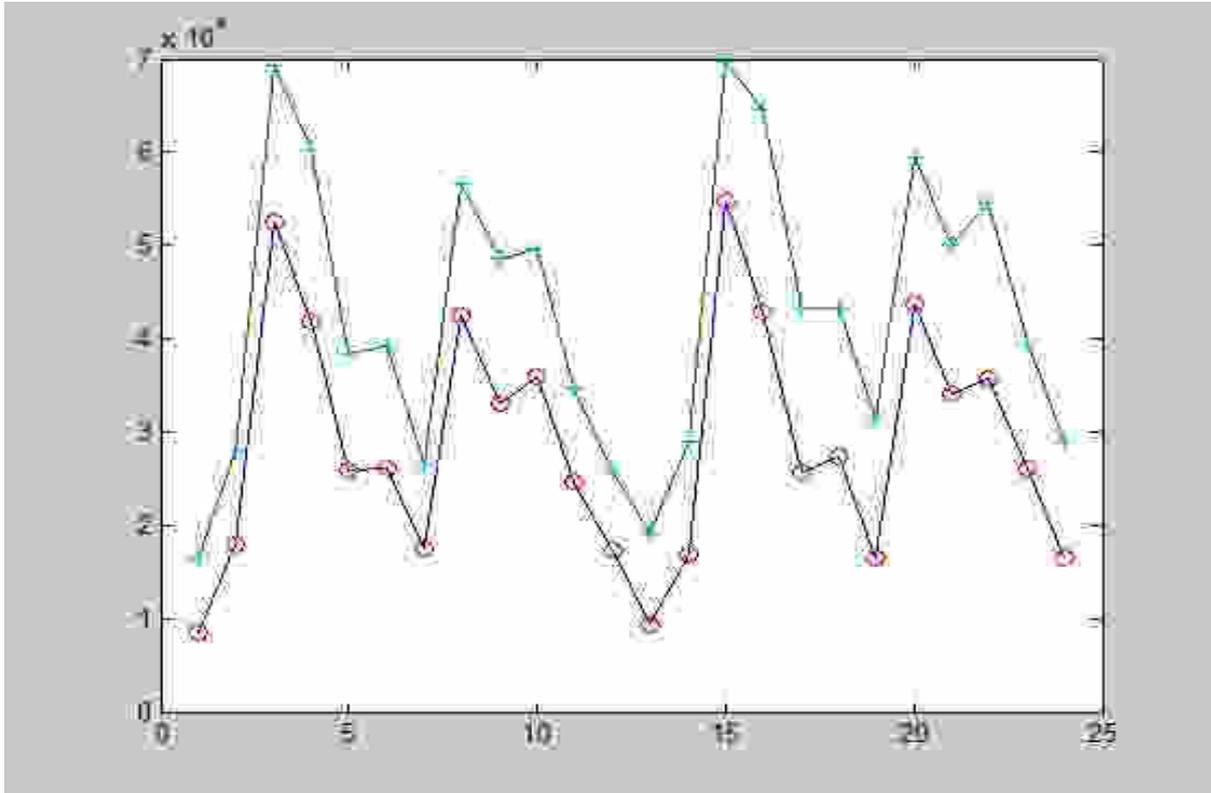
TABELA 4.1 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS - BISCOITO

Consumo real	Previsão	Consumo real	Previsão
16390	8499,23	19070	9412,01
27940	17960,4	28990	16978,9
69340	52585,9	69790	54824,3
60190	41776,8	64510	42889,2
38290	25946,4	43390	25622,4
39190	26011,3	43390	27273,5
26440	17573,6	31390	16391,8
56590	42380	59390	43682,8
48640	33107,7	50110	33977,3
49690	35894,3	54590	35813,4
34690	24692,1	39550	26073,1
25690	17303	28990	16377,7

Medida de erro RMSE: 14.317,7635

Adiante segue o gráfico da tabela 4.1 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.2 – CONSUMO REAL X PREVISÃO BOX & JENKINS – BISCOITO



— Consumo Real

— Previsão B&J

4.1.1.2 Dados *Matlab* – Redes Neurais com Bases Radiais

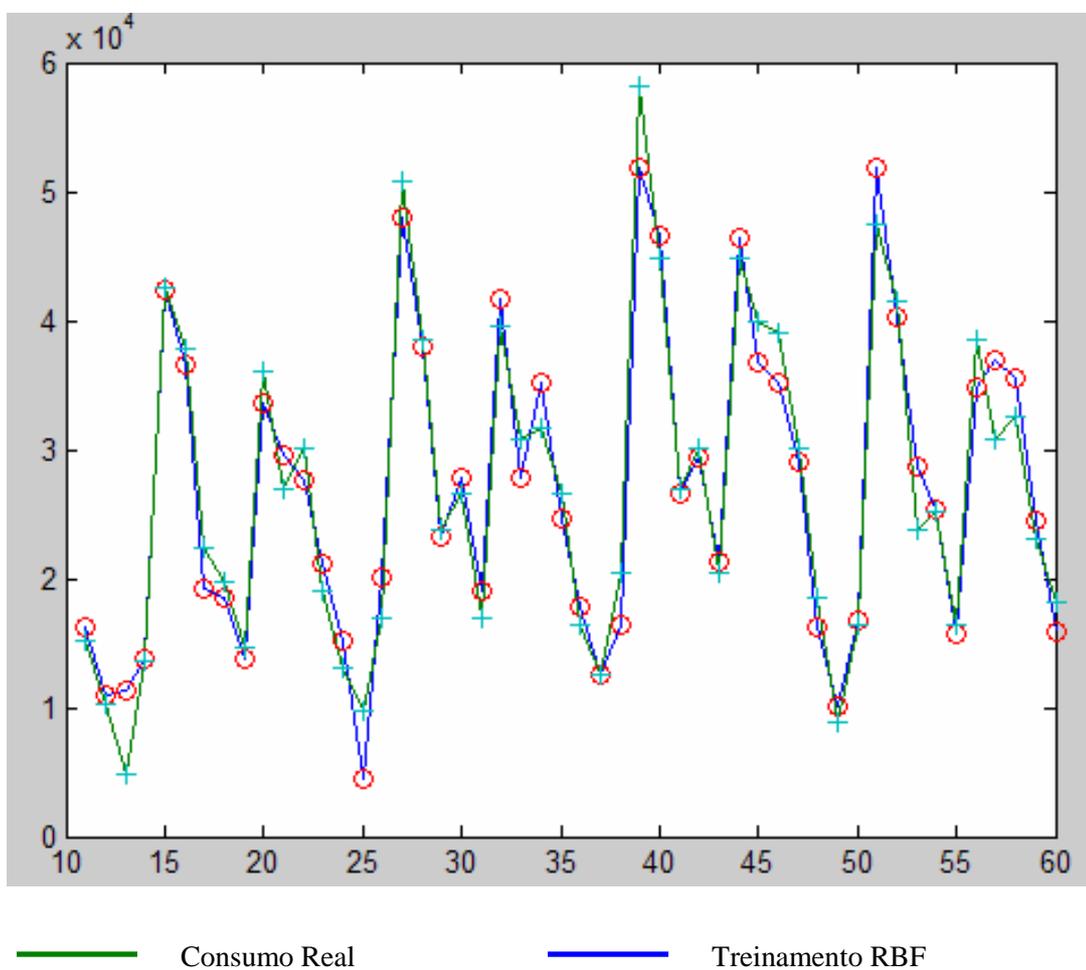
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 0,3700$;
- $sc = 2,3500$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.3 de treinamento no período dos 5 (cinco) primeiros anos de histórico das séries temporais.

GRÁFICO 4.3 – TREINAMENTO DA REDE – BISCOITO



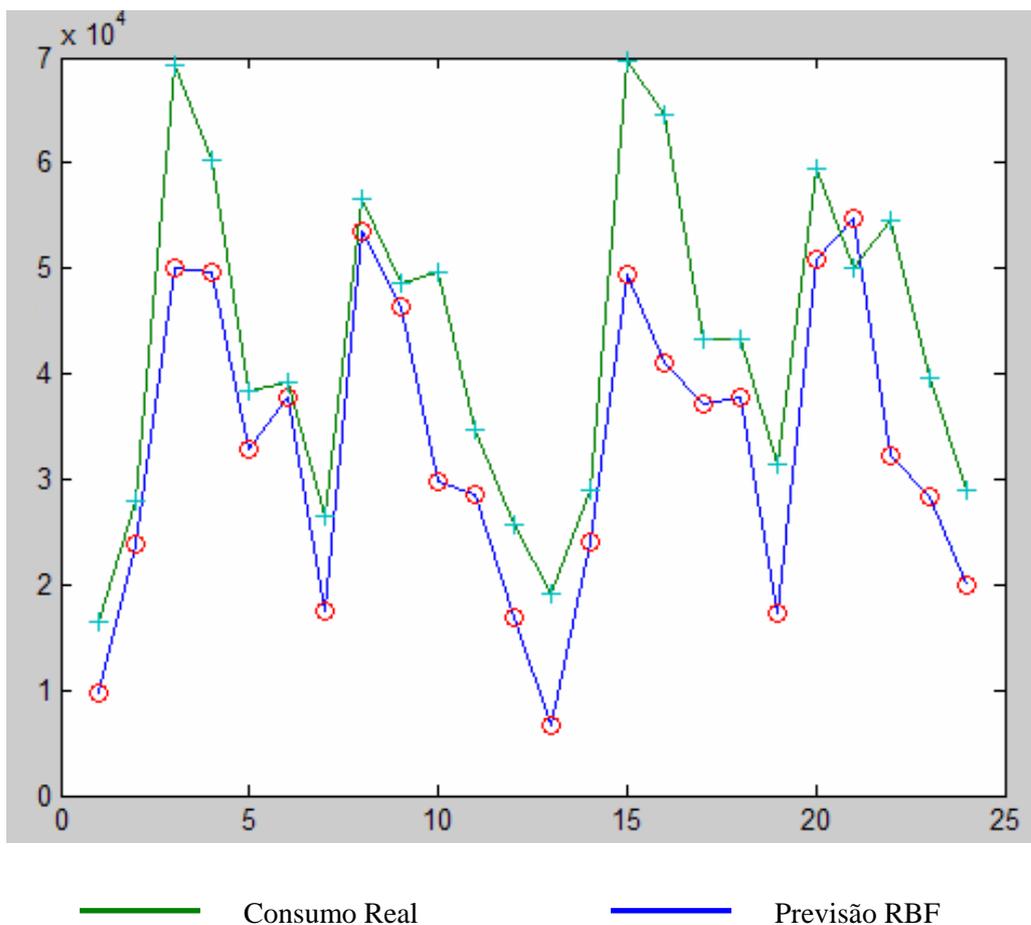
A tabela adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.2 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAS RBF - BISCOITO

Consumo real	Previsão	Consumo real	Previsão
16390	9737	19070	6623
27940	23860	28990	24040
69340	50073	69790	49378
60190	49736	64510	41067
38290	32805	43390	37071
39190	37803	43390	37726
26440	17560	31390	17246
56590	53473	59390	50923
48640	46305	50110	54725
49690	29756	54590	32258
34690	28494	39550	28253
25690	16802	28990	20004

Adiante segue o gráfico 4.4 da tabela 4.2 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.4 – CONSUMO REAL X PREVISÃO PELA RBF – BISCOITO



Erro RMSE: 11.902

4.1.1.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Biscoitos, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 14.317,7635.

RMSE da previsão através da RBF 11.902.

4.1.2 Serie Temporal - Macarrão

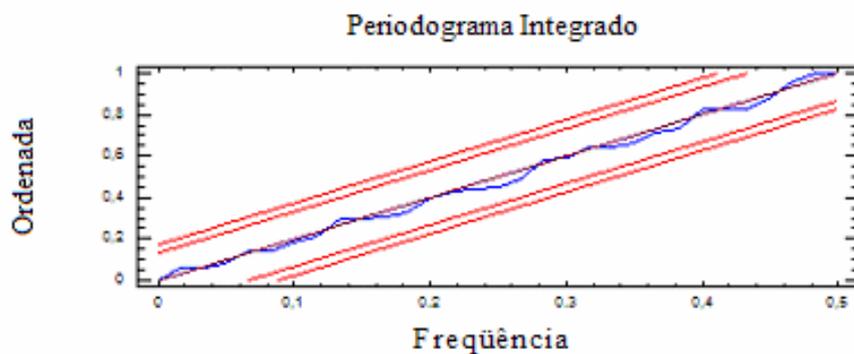
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.2.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi: SARIMA(4,3) X (4,3) com sazonalidade de 3 meses.

O gráfico do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.5 – PERIODOGRAMA INTEGRADO – MACARRÃO



A tabela 4.3 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

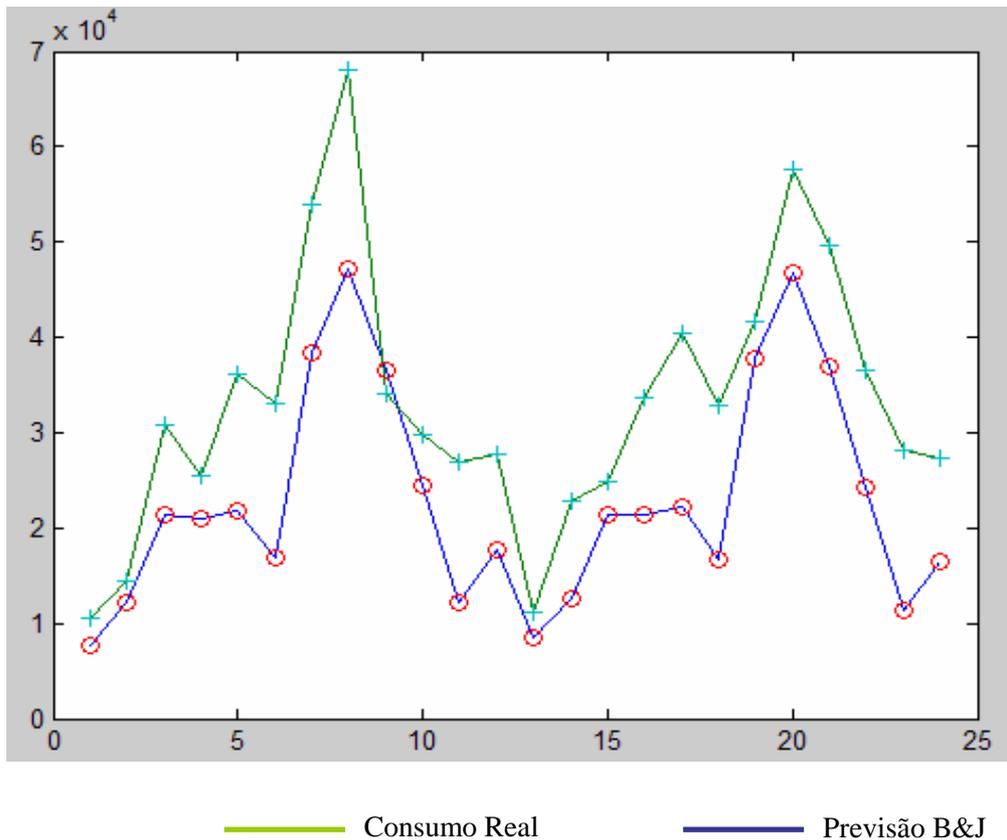
TABELA 4.3 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – MACARRÃO

Consumo real	Previsão	Consumo real	Previsão
10464	7763,39	11154	8446,67
14514	12276	22834	12545,9
30714	21454,4	24914	21310,6
25464	21011,9	33714	21425,9
36114	21882,2	40434	22197,4
32964	16810,1	32914	16769,7
53964	38443,9	41714	37813,3
68064	47203,1	57714	46674,8
34014	36634,7	49554	36975,3
29814	24419,1	36594	24338,4
26964	12255,8	28114	11412,2
27714	17675,6	27314	16536,7

Medida de erro RMSE: 11.764,09

Adiante segue o gráfico 4.6 da tabela 4.3 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.6 – CONSUMO REAL X PREVISÃO BOX & JENKINS – MACARRÃO



4.1.2.2 Dados *Matlab* – Redes Neurais com Bases Radiais

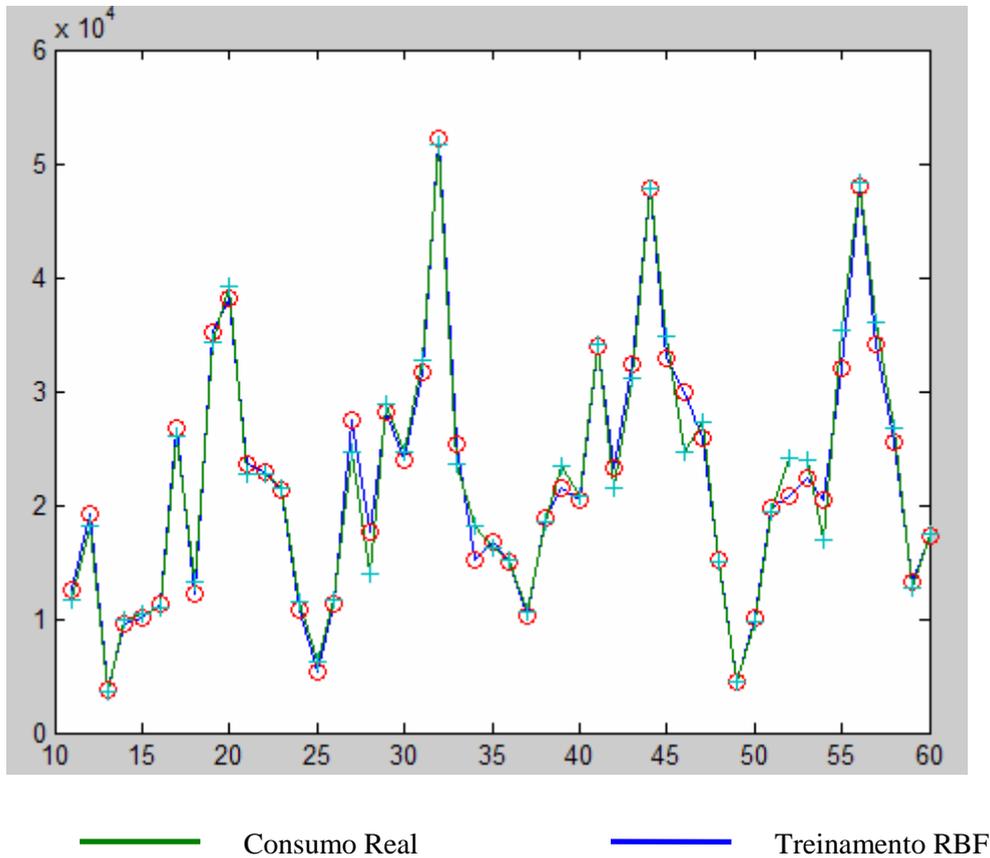
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 0.1600$;
- $sc = 1.1500$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.7 de treinamento no período dos 5 (cinco) primeiros anos de histórico das series temporais.

GRÁFICO 4.7 – TREINAMENTO DA REDE – MACARRÃO



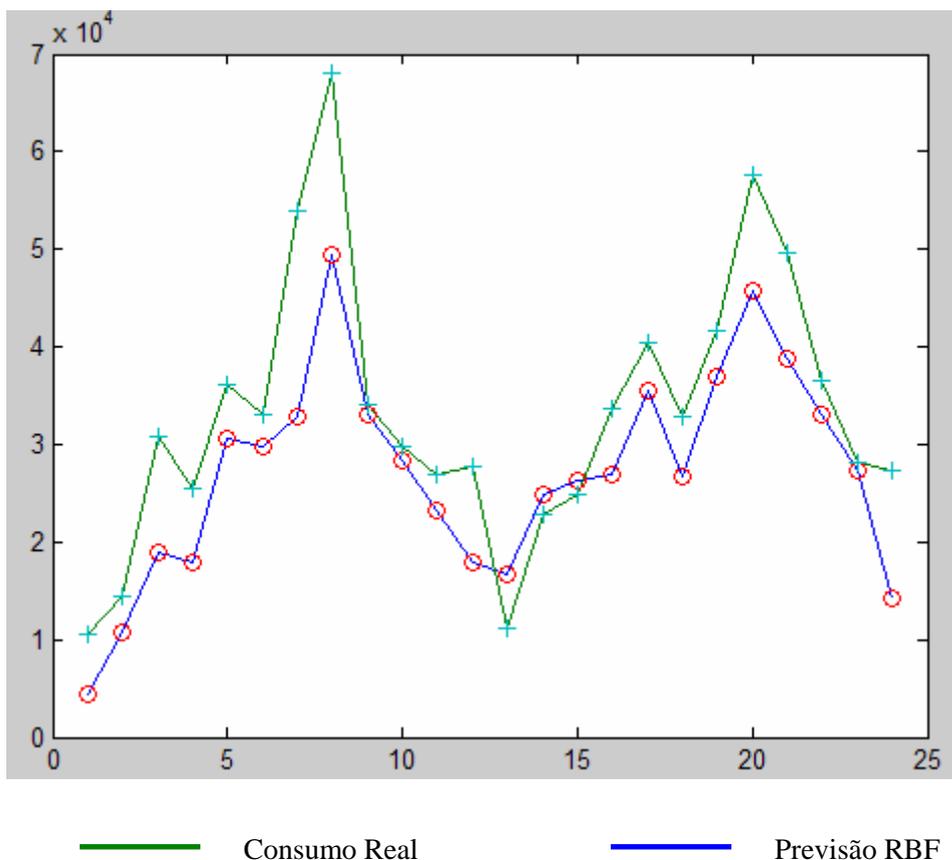
A tabela 4.4 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.4 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAS RBF – MACARRÃO

Consumo real	Previsão	Consumo real	Previsão
10464	4425	11154	16755
14514	10660	22834	24892
30714	18932	24914	26340
25464	17955	33714	26850
36114	30622	40434	35425
32964	29735	32914	26718
53964	32835	41714	36862
68064	49383	57714	45673
34014	33158	49554	38823
29814	28448	36594	33025
26964	23173	28114	27345
27714	17964	27314	14188

Adiante segue o gráfico 4.8 da tabela acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.8 – CONSUMO REAL X PREVISÃO PELA RBF – MACARRÃO



Erro RMSE: 8.689,3.

4.1.2.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Macarrão, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 11.764,09.

RMSE da previsão através da RBF 8.689,3.

4.1.3 Serie Temporal - *Candies*

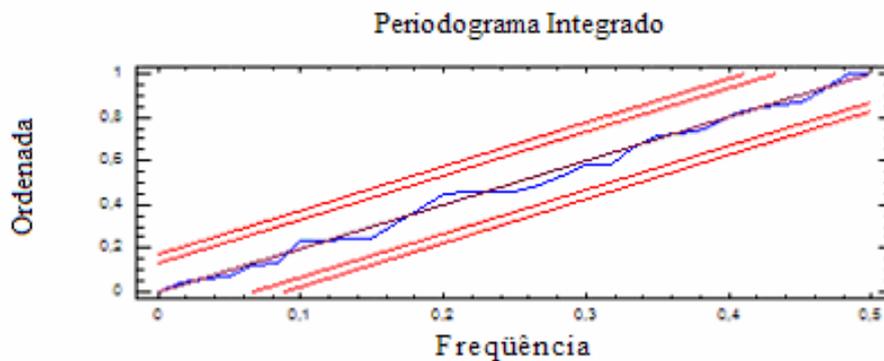
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.3.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi : ARIMA(2,1)

O gráfico 4.9 do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.9 – PERIODOGRAMA INTEGRADO – *CANDIES*



A tabela 4.5 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

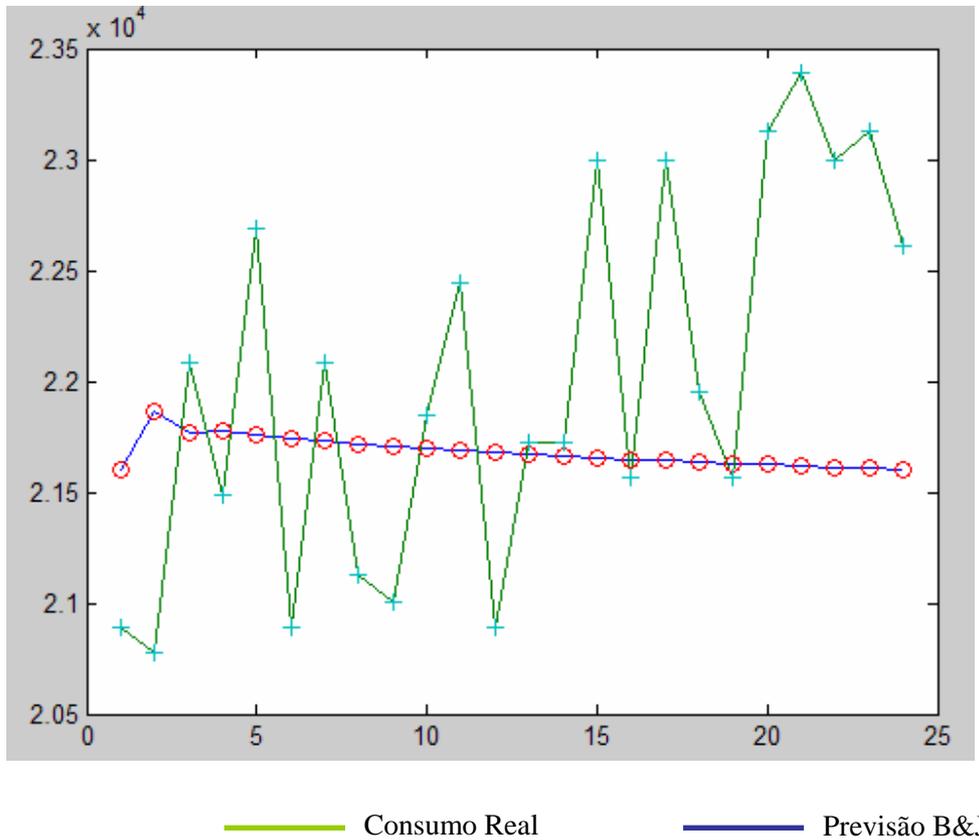
TABELA 4.5 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – *CANDIES*

Consumo real	Previsão	Consumo real	Previsão
20886	21596,8	21726	21670,5
20776	21859,7	21726	21662,5
22086	21770,5	22996	21655
21486	21774,5	21566	21647,9
22686	21755,4	22996	21641,3
20886	21743,4	21956	21635,1
22086	21730,6	21566	21629,3
21126	21719	23126	21623,8
21006	21708	23386	21618,7
21846	21697,7	22996	21613,9
22446	21688,1	23126	21609,4
20886	21679	22606	21605,1

Medida de erro RMSE: 912,9.

Adiante segue o gráfico 4.10 da tabela 4.5 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.10 – CONSUMO REAL X PREVISÃO BOX & JENKINS – *CANDIES*



4.1.3.2 Dados *Matlab* – Redes Neurais com Bases Radiais

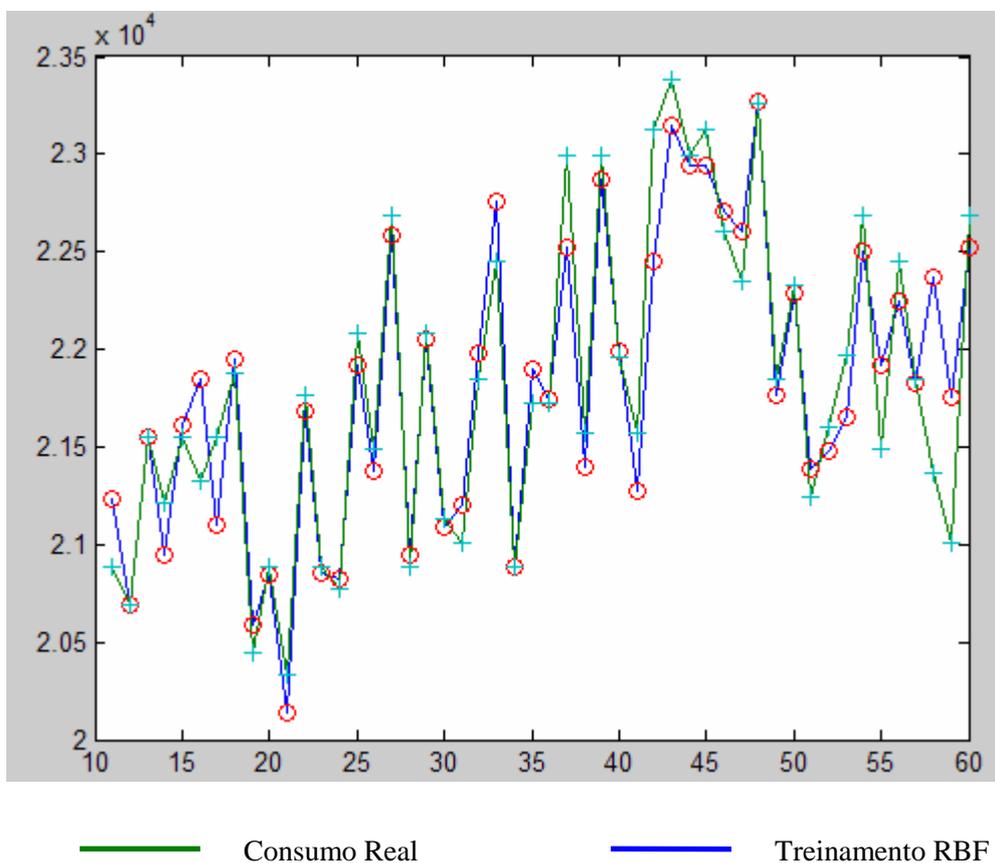
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 0.5800$;
- $sc = 0.9100$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.11 de treinamento no período dos 5 (cincos) primeiros anos de histórico das series temporais.

GRÁFICO 4.11 – TREINAMENTO DA REDE – *CANDIES*



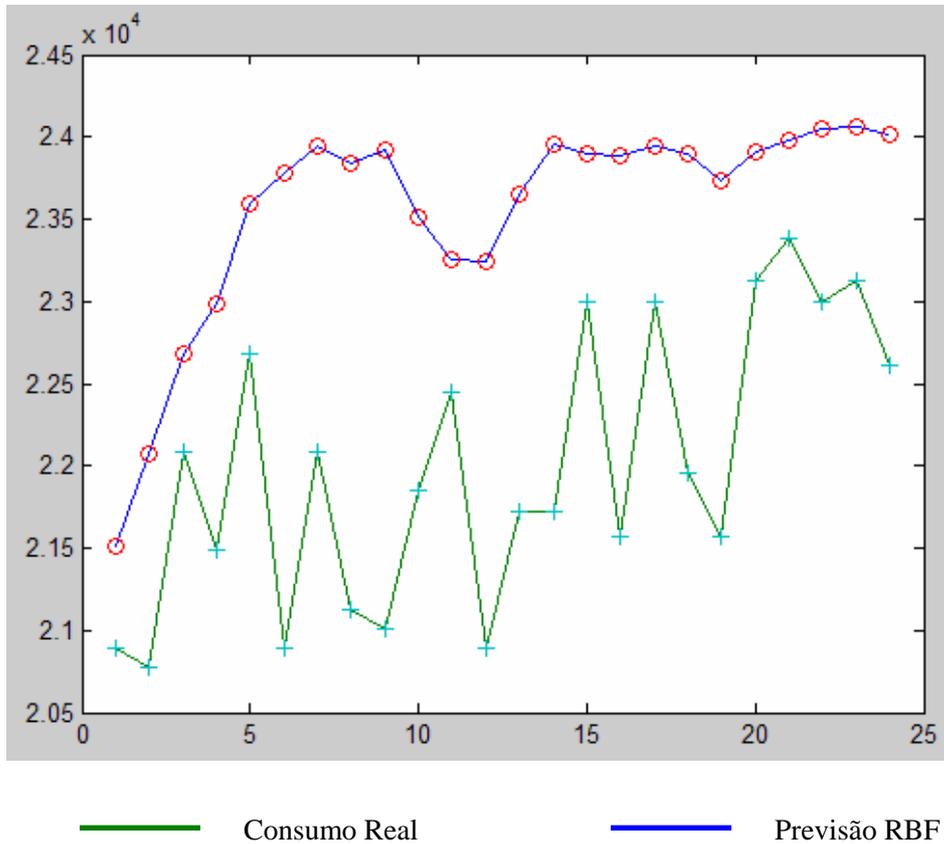
A tabela 4.6 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.6 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIIS RBF – *CANDIES*

Consumo real	Previsão	Consumo real	Previsão
20886	21508	21726	23654
20776	22078	21726	23957
22086	22682	22996	23896
21486	22990	21566	23887
22686	23594	22996	23946
20886	23781	21956	23902
22086	23942	21566	23738
21126	23843	23126	23907
21006	23924	23386	23982
21846	23516	22996	24044
22446	23256	23126	24056
20886	23238	22606	24010

Adiante segue o gráfico 4.12 da tabela 4.6 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.12 – CONSUMO REAL X PREVISÃO PELA RBF – *CANDIES*



Erro RMSE: 809.5834.

4.1.3.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Candies, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 912,9.

RMSE da previsão através da RBF 809,58.

4.1.4 Serie Temporal - Chocolate

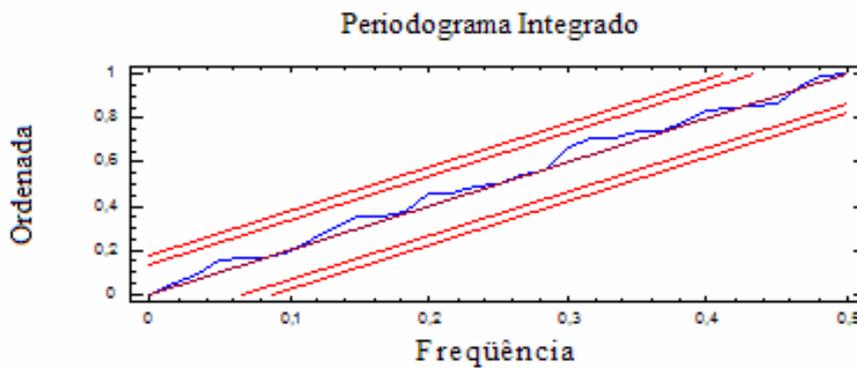
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.4.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi : SARIMA(4,3) X (4,3) com sazonalidade de 4 meses.

O gráfico 4.13 do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelo sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.13 – PERIODOGRAMA INTEGRADO – CHOCOLATE



A tabela 4.7 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

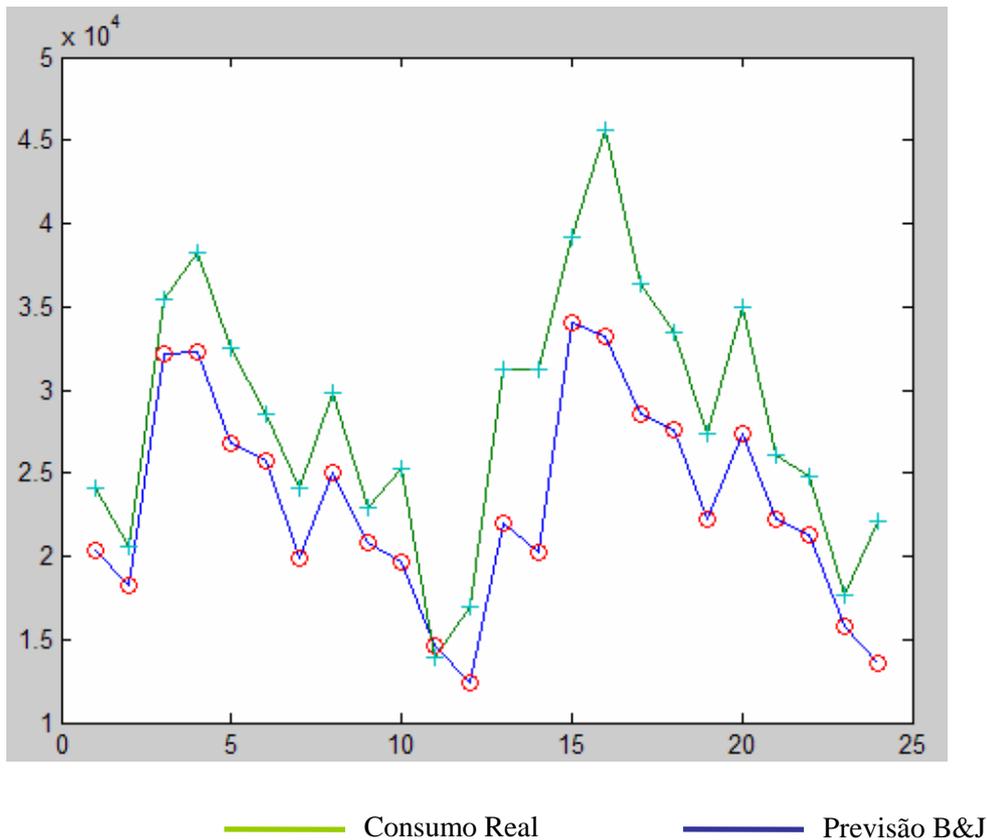
TABELA 4.7 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – CHOCOLATE

Consumo real	Previsão	Consumo real	Previsão
24075	20302,1	31235	21997,9
20599	18222,3	31234	20283,3
35387	32107,9	39239	34041,3
38286	32284,3	45635	33245,2
32484	26748,2	36360	28490,6
28571	25673,1	33481	27628,9
24080	19916,9	27397	22209,4
29876	24981,8	34916	27401,5
22915	20776,8	26115	22234,8
25239	19670,5	24840	21232,6
13926	14582	17635	15746,6
16972	12400,5	22119	13521

Medida de erro RMSE: 6.044,62.

Adiante segue o gráfico 4.14 da tabela 4.7 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.14 – CONSUMO REAL X PREVISÃO BOX & JENKINS – CHOCOLATE



4.1.4.2 Dados *Matlab* – Redes Neurais com Bases Radiais

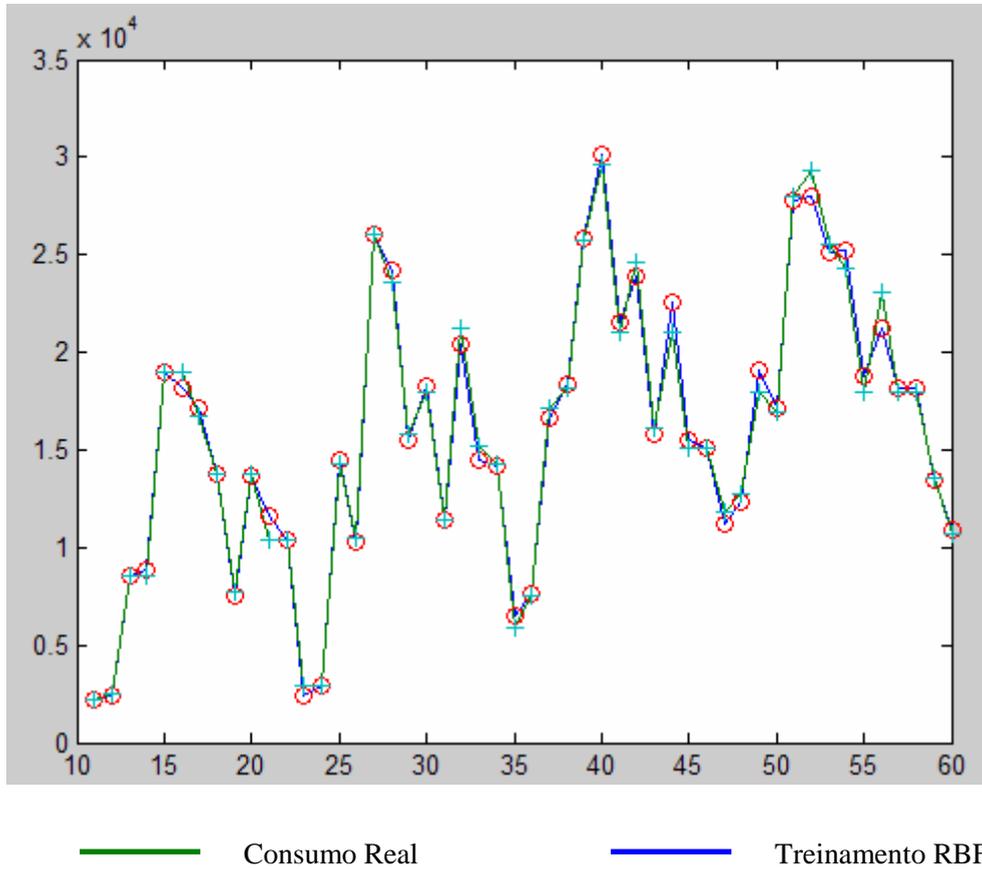
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da série temporal.

Parâmetros da rede neural base radial:

- $eg = 0.0400$;
- $sc = 0.7000$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.15 de treinamento no período dos 5 (cincos) primeiros anos de histórico das series temporais.

GRÁFICO 4.15 – TREINAMENTO DA REDE – CHOCOLATE



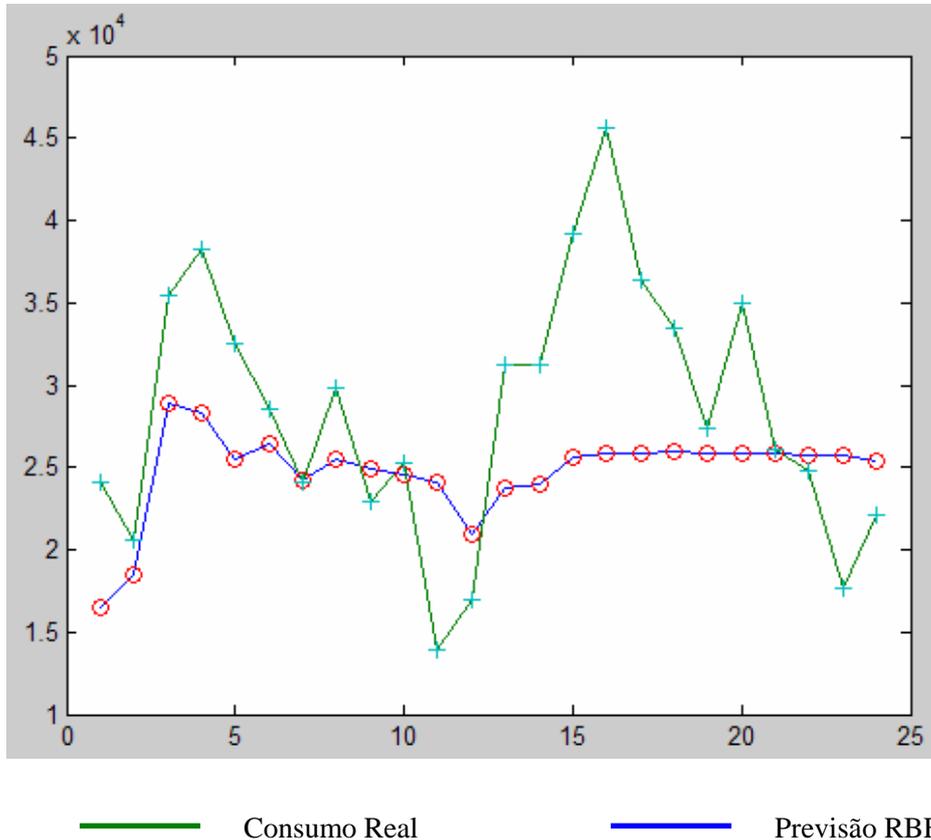
A tabela 4.8 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.8 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIAS RBF – CHOCOLATE

Consumo real	Previsão	Consumo real	Previsão
24075	16541	31235	23717
20599	18527	31234	24035
35387	28843	39239	25608
38286	28293	45635	25826
32484	25481	36360	25898
28571	26403	33481	25967
24080	24180	27397	25836
29876	25519	34916	25904
22915	24920	26115	25862
25239	24598	24840	25785
13926	24091	17635	25772
16972	20891	22119	25411

Adiante segue o gráfico 4.16 da tabela acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.16 – CONSUMO REAL X PREVISÃO PELA RBF – CHOCOLATE



Erro RMSE: 7.674,8.

4.1.4.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através do modelo ARIMA foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Chocolates, podem ser utilizadas para as próximas previsões o modelo ARIMA, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 6.044,62.

RMSE da previsão através da RBF 7.674,8.

4.1.5 Serie Temporal - Refresco

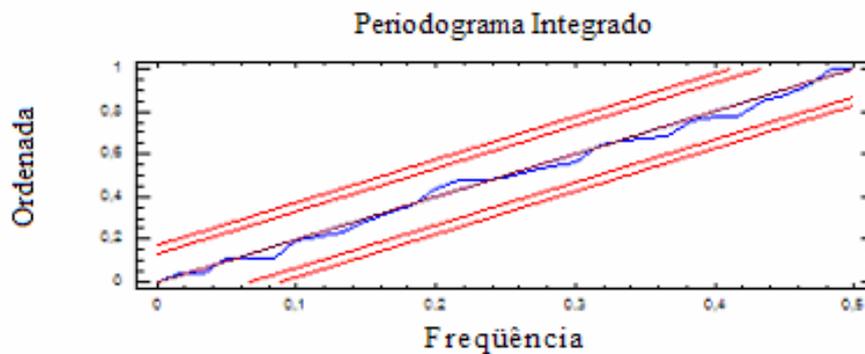
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.5.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

Modelo que melhor de adequou a previsão: ARMA (4,3) SARIMA (4,3) com sazonalidade de 6 meses.

O gráfico 4.17 do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.17 – PERIODOGRAMA INTEGRADO – REFRESCO



A tabela 4.9 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

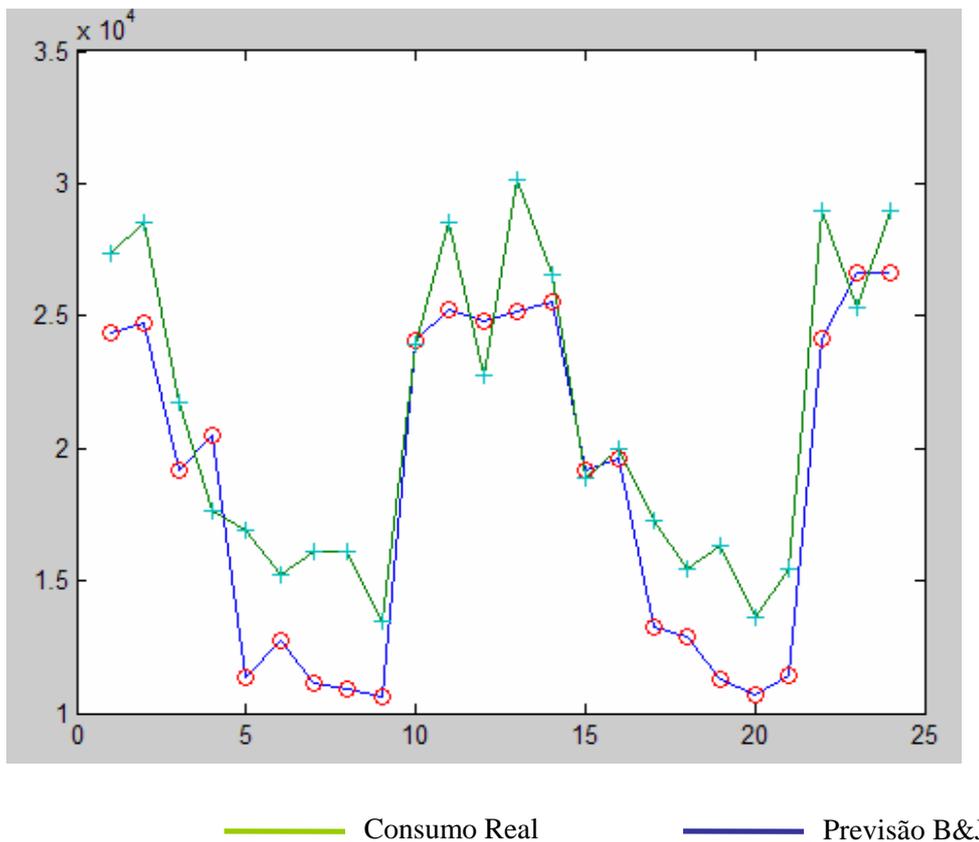
TABELA 4.9 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – REFRESCO

Consumo real	Previsão	Consumo real	Previsão
27383	24338,6	30143	25203,1
28543	24734,1	26543	25550,8
21728	19182,5	18893	19186,5
17668	20473,5	19943	19626,6
16943	11322	17243	13281,6
15203	12775,7	15443	12892
16073	11109,4	16343	11272
16073	10908,5	13643	10711,1
13463	10646,2	15443	11447,4
23903	24084	28943	24132,1
28543	25205,8	25343	26598,4
22743	24795,8	28943	26647,3

Medida de erro RMSE: 3.405,15.

Adiante segue o gráfico 4.18 da tabela acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.18 – CONSUMO REAL X PREVISÃO BOX & JENKINS – REFRESCO



4.1.5.2 Dados *Matlab* – Redes Neurais com Bases Radiais

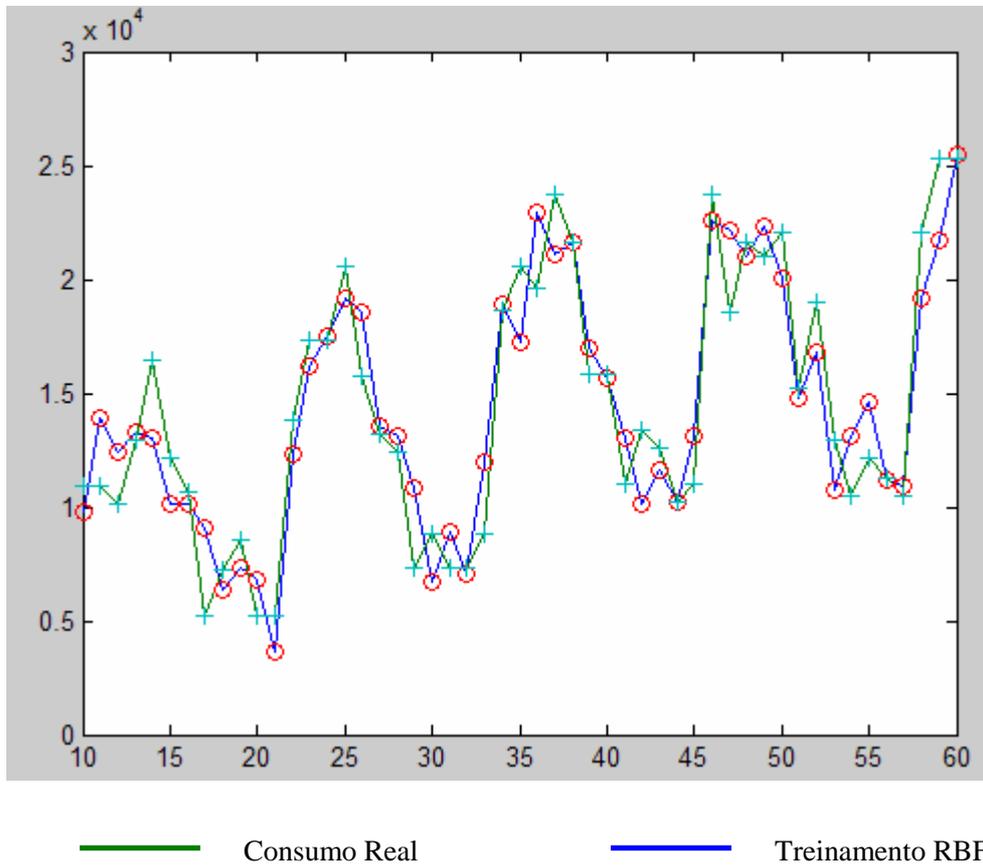
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 1.2700$;
- $sc = 4.1200$;
- $numEntrada = 9$;

Adiante segue o gráfico 4.19 de treinamento no período dos 5 (cincos) primeiros anos de histórico das series temporais.

GRÁFICO 4.19 – TREINAMENTO DA REDE – REFRESCO



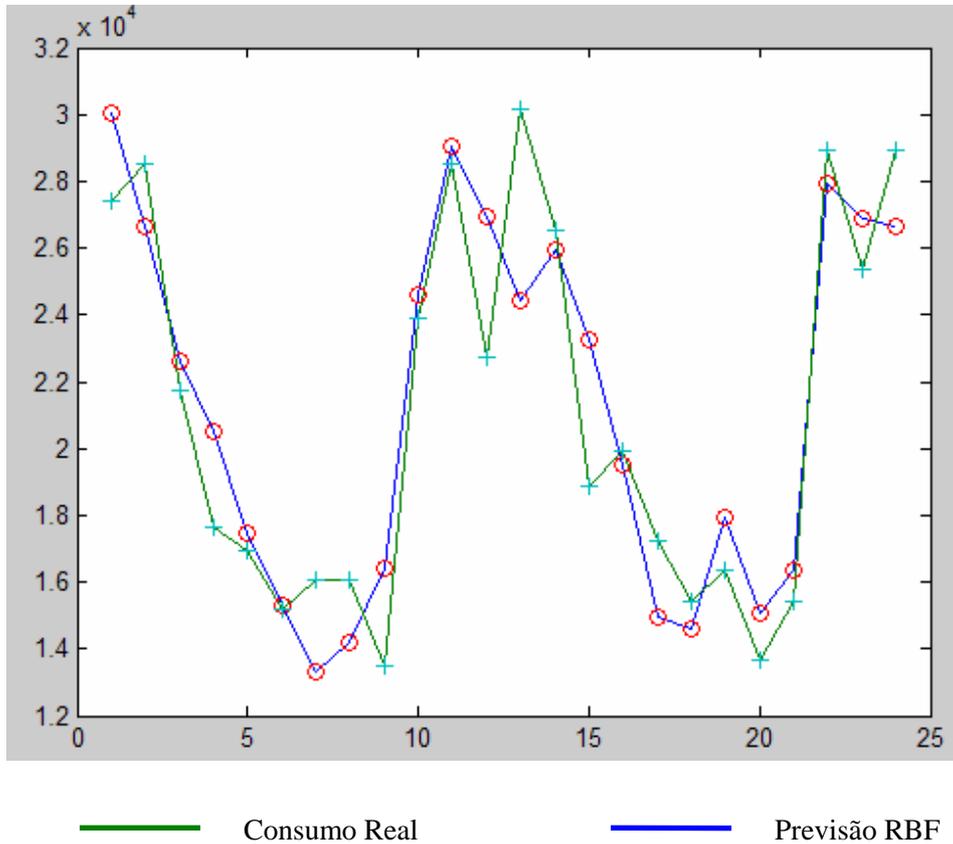
A tabela 4.10 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.10 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAS RBF – REFRESCO

Consumo real	Previsão	Consumo real	Previsão
27383	30038	30143	24407
28543	26632	26543	25972
21728	22638	18893	23264
17668	20515	19943	19538
16943	17473	17243	14943
15203	15292	15443	14598
16073	13320	16343	17943
16073	14208	13643	15048
13463	16396	15443	16349
23903	24575	28943	27960
28543	29040	25343	26888
22743	26928	28943	26621

Adiante segue o gráfico 4.20 da tabela 4.10 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.20 – CONSUMO REAL X PREVISÃO PELA RBF – REFRESCO



Erro RMSE: 2.331.

4.1.5.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Resfresco, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 3.405,15.

RMSE da previsão através da RBF 2.331.

4.1.6 Serie Temporal – Cereais

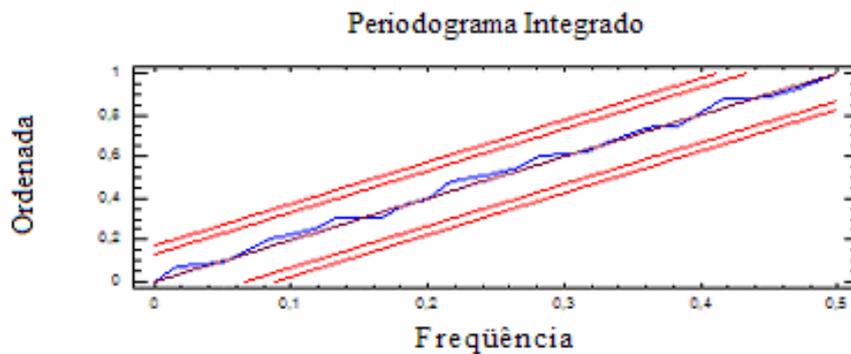
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.6.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi : SARIMA(3,2) X (3,2) com sazonalidade de 3 meses.

O gráfico 4.21 do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.21 – PERIODOGRAMA INTEGRADO – CEREAIS



A tabela 4.11 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

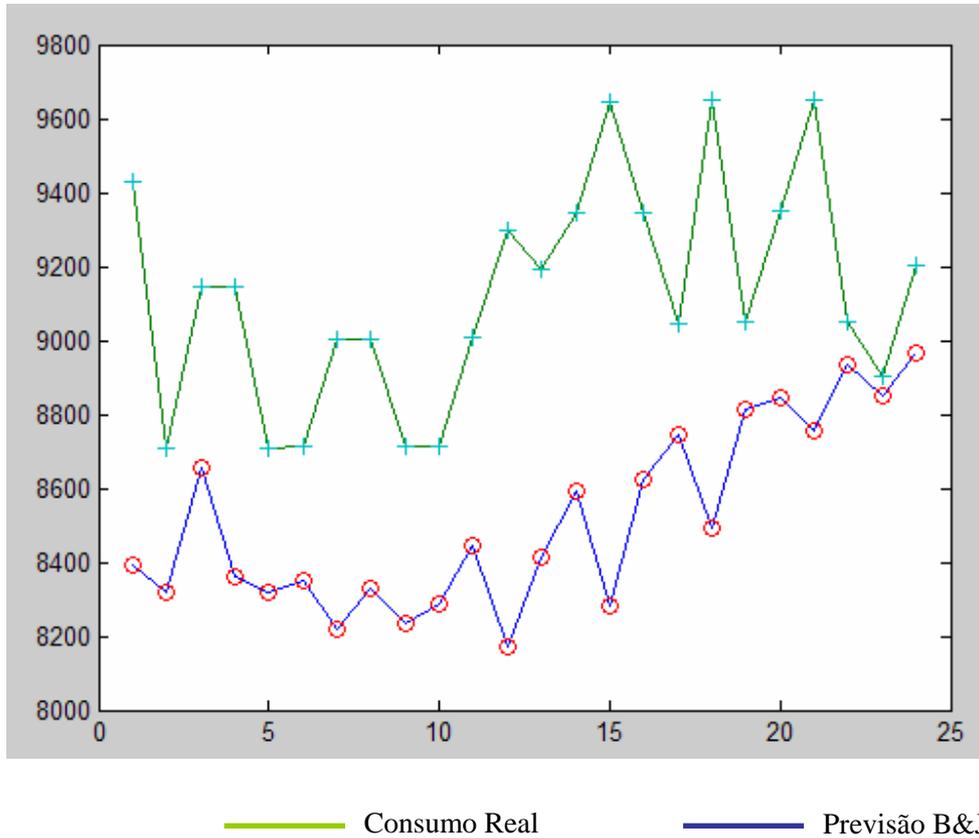
TABELA 4.11 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – CEREAIS

Consumo real	Previsão	Consumo real	Previsão
9431	8394,08	9193	8415,49
8707	8318,3	9344	8592,51
9143	8655,27	9645	8283,73
9144	8360,85	9346	8624,36
8710	8317,34	9047	8746,46
8711	8350,19	9648	8493,69
9002	8220,49	9049	8814,88
9003	8329,17	9350	8843
8714	8235,66	9651	8754,53
8715	8289,27	9052	8934,4
9006	8443,58	8903	8851,14
9297	8172,47	9204	8964,44

Medida de erro RMSE: 694,4.

Adiante segue o gráfico 4.22 da tabela 4.11 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.22 – CONSUMO REAL X PREVISÃO BOX & JENKINS – CEREAIS



4.1.6.2 Dados *Matlab* – Redes Neurais com Bases Radiais

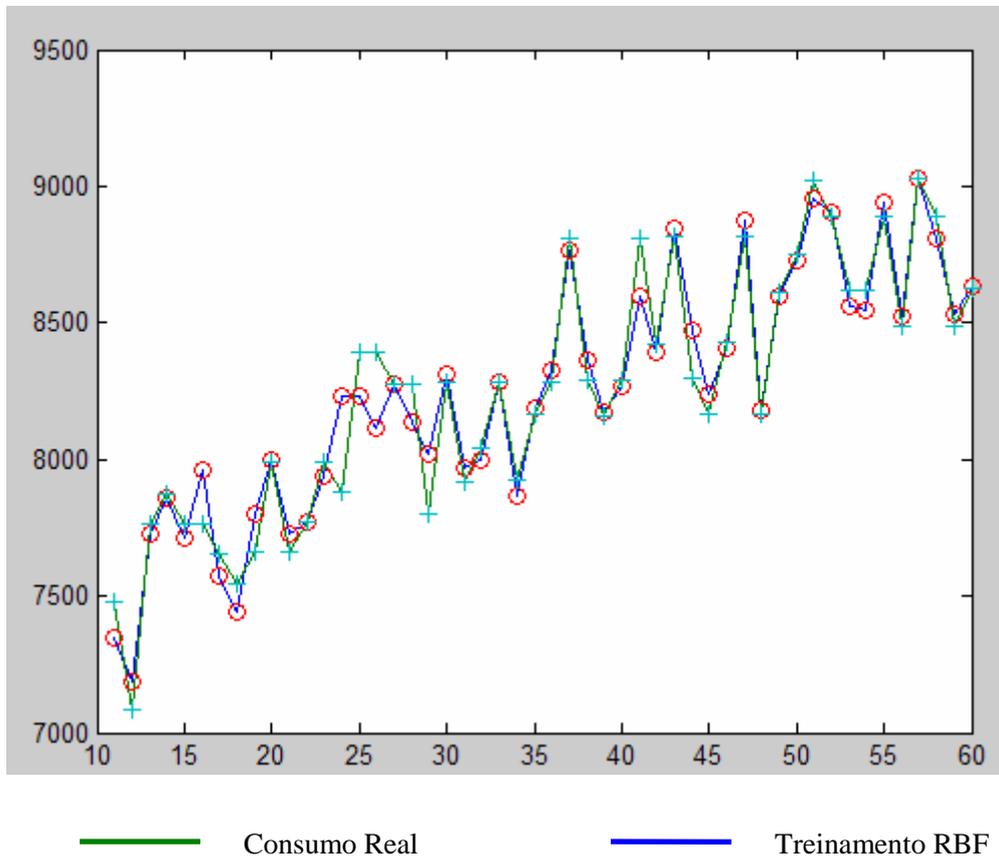
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 0.3400$;
- $sc = 2.5900$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.23 de treinamento no período dos 5 (cincos) primeiros anos de histórico das series temporais.

GRÁFICO 4.23 – TREINAMENTO DA REDE – CEREAIS



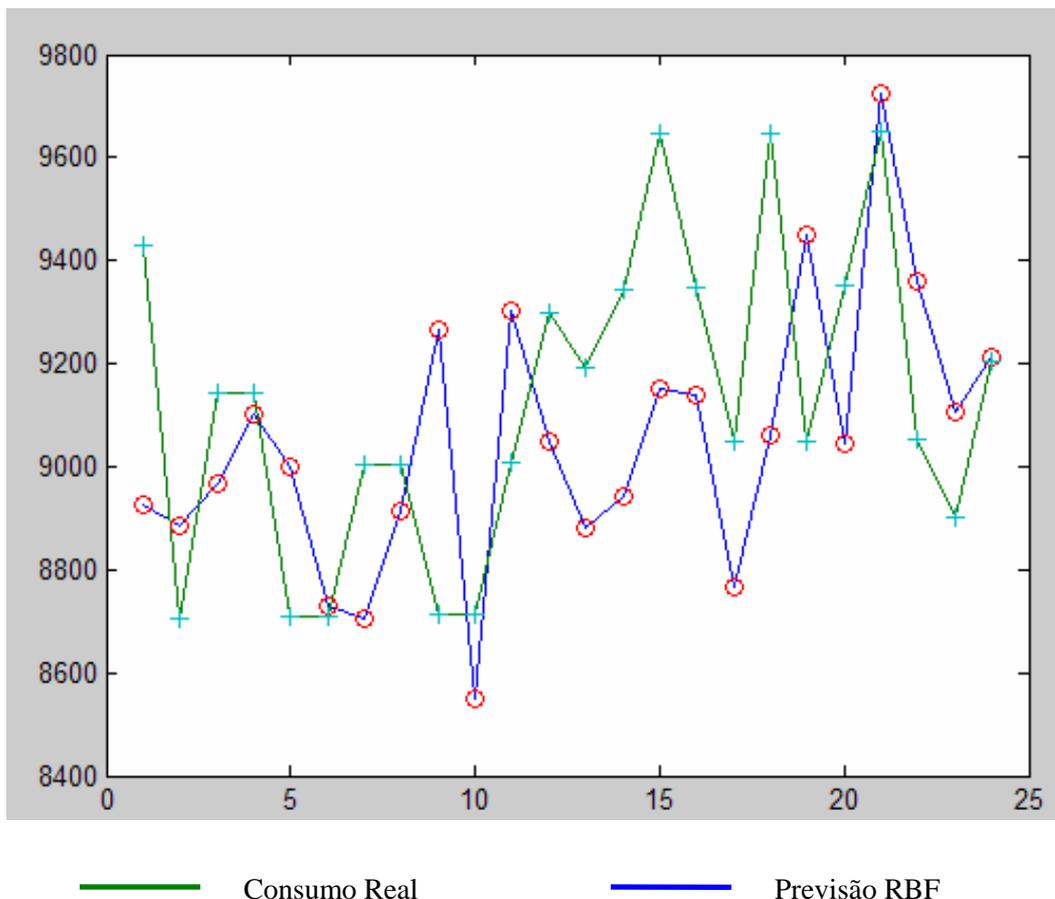
A tabela 4.12 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.12 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAIIS RBF – CEREAIS

Consumo real	Previsão	Consumo real	Previsão
9431	8924,9	9193	8879,7
8707	8883,8	9344	8944
9143	8965,1	9645	9150,2
9144	9103,2	9346	9139,3
8710	8998,2	9047	8764,5
8711	8730,4	9648	9059,9
9002	8706,5	9049	9450,2
9003	8912,2	9350	9046,7
8714	9264,5	9651	9723
8715	8547,4	9052	9359,5
9006	9301	8903	9105,7
9297	9048,7	9204	9213,9

Adiante segue o gráfico 4.24 da tabela 4.12 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.24 – CONSUMO REAL X PREVISÃO PELA RBF – CEREIAIS



Erro RMSE: 312.56.

4.1.6.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Cereais, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 694,4.

RMSE da previsão através da RBF 312,56.

4.1.7 Serie Temporal - Panetones

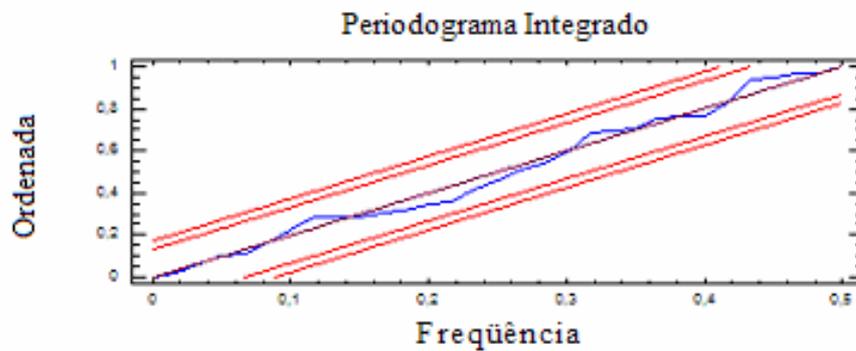
O Gráfico da série temporal foi apresentada no capítulo 3.

4.1.7.1 Dados *Statgraphics* – Metodologia *Box & Jenkins*

O modelo que melhor ajustou os dados foi : SARIMA(3,2) X (3,2) com sazonalidade de 9 meses.

O gráfico 4.25 do Periodograma Integrado, adiante, mostra que os resíduos do ajuste comportam-se como um ruído branco, ou seja, $N(0, \sigma^2)$. O gráfico foi construído sobre os resíduos do ajuste do modelos sobre os 5 (cinco) primeiros anos de histórico consumo da série.

GRÁFICO 4.25 – PERIODOGRAMA INTEGRADO – PANETONES



A tabela 4.13 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo Box & Jenkins é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

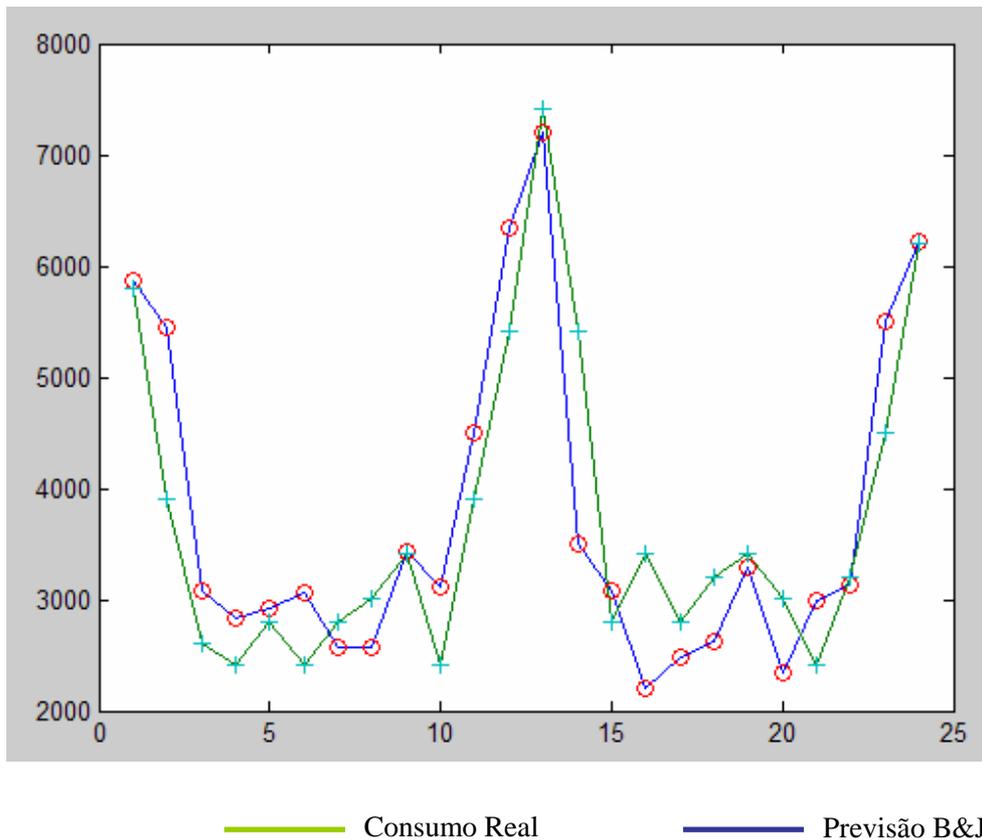
TABELA 4.13 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO BOX & JENKINS – PANETONES

Consumo real	Previsão	Consumo real	Previsão
5805	5861,91	7405	7196,03
3905	5449,08	5405	3493,5
2605	3086,73	2805	3073,46
2405	2831,78	3405	2203,96
2805	2917,17	2805	2487,98
2405	3057,37	3205	2616,92
2805	2562,39	3405	3283,89
3005	2563,22	3005	2346,39
3405	3423	2405	2984,74
2405	3111,44	3205	3125,61
3905	4501,9	4505	5502,5
5405	6343,96	6205	6220,99

Medida de erro RMSE: 726,74.

Abaixo segue o gráfico 4.26 da tabela 4.13 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.26 – CONSUMO REAL X PREVISÃO BOX & JENKINS – PANETONES



4.1.7.2 Dados *Matlab* – Redes Neurais com Bases Radiais

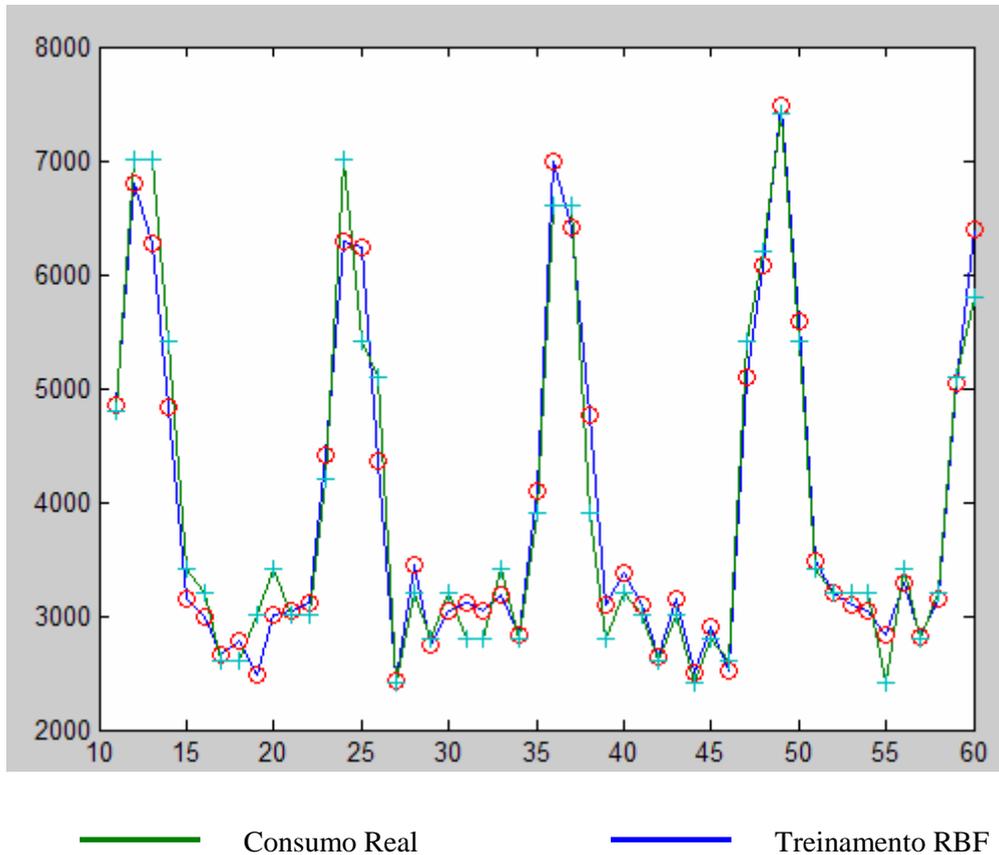
Para o ajuste dos parâmetros abaixo foi utilizado 5 (cinco) primeiros anos de histórico de consumo da serie temporal.

Parâmetros da rede neural base radial:

- $eg = 1.0000$;
- $sc = 0.8800$;
- $numEntrada = 10$;

Adiante segue o gráfico 4.27 de treinamento no período dos 5 (cincos) primeiros anos de histórico das series temporais.

GRÁFICO 4.27 – TREINAMENTO DA REDE – PANETONES



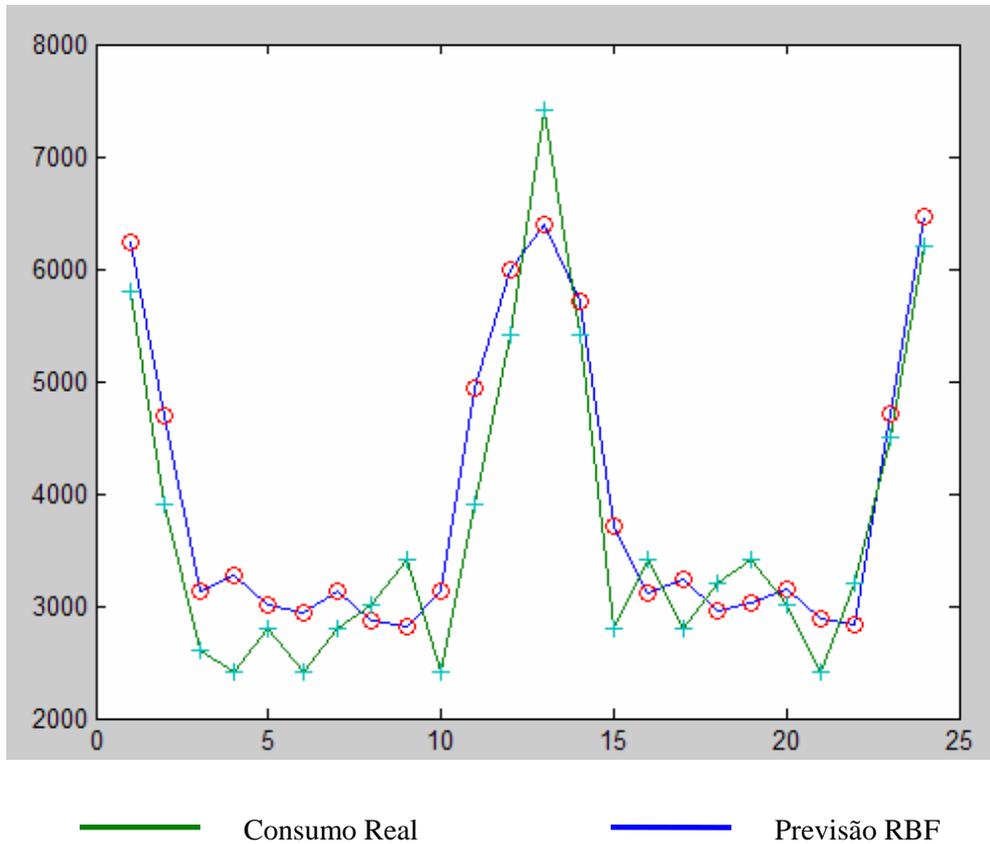
A tabela 4.14 adiante, segue a previsão dos 2 (dois) últimos anos escolhido como validação do modelo. O modelo das redes RBF é ajustado, e a previsão no período de dois anos é efetuada, comparada com o consumo real, medindo o RMSE.

TABELA 4.14 – COMPARAÇÃO ENTRE CONSUMO REAL E A PREVISÃO PELAS REDES NEURAI RBF – PANETONES

Consumo real	Previsão	Consumo real	Previsão
5805	6228,6	7405	6391,2
3905	4692,3	5405	5708,9
2605	3138,1	2805	3717,8
2405	3280,2	3405	3115,6
2805	3010,5	2805	3233,5
2405	2947,3	3205	2959,9
2805	3126,4	3405	3032,1
3005	2874,3	3005	3148,1
3405	2808,9	2405	2879,8
2405	3128,2	3205	2827,2
3905	4940,3	4505	4719,2
5405	5983,1	6205	6466,3

Adiante segue o gráfico 4.28 da tabela 4.14 acima, ou seja, o gráfico que representa a validação do modelo ajustado para a previsão.

GRÁFICO 4.28 – CONSUMO REAL X PREVISÃO PELA RBF – PANETONES



Erro RMSE: 559,5.

4.1.7.3 ARMA x RBF

Comparando as medidas do RMSE, ficou evidente que o ajuste através da RBF foi superior, devido ao seu RMSE estar com um valor menor. O que mostra que para a série temporal, representando o consumo de Panetones, podem ser utilizadas para as próximas previsões as redes RBF, como ferramenta auxiliar nas definições estratégicas da empresa.

RMSE da previsão através do modelo ARMA 726,74.

RMSE da previsão através da RBF 559,5.

4.2 PREVISÕES FUTURAS

4.2.1 Dimensionamento da área de *picking* de acordo com a previsão encontrada

O último ano do histórico de cada série temporal da demanda dos produtos foi utilizado para simularmos o novo dimensionamento da área de *picking*. As previsões foram comparadas com os valores reais para que sua consistência fosse confirmada.

As tabelas ao longo desta sessão trazem os dimensionamentos atuais para cada produto. Estes são valores são fixo, ou seja, não sofriam modificações ao longo do ano, independente da sazonalidade do produto. As tabelas contemplam também os dimensionamento com base nas previsões e ainda os dimensionamentos ideais calculados sobre os consumos reais.

A título de ilustração foram calculadas as previsões em três períodos diferentes: primeiramente para 12 meses; 6 meses e 3 meses. Cada previsão foi calculada utilizando as Redes Neurais de função de base radial e a metodologia *Box & Jenkins*. Para cada período foi calculado o RMSE da previsão, podendo assim verificar a melhor previsão. Para cada item que compõe a serie possui a sua própria área de *picking*, e conseqüentemente um dimensionamento. Em cada um dos períodos utilizado para fazer os estudos de previsões foram apresentados três resultados para efeito de comparações: o dimensionamento atual, ou seja, como a área de *picking* deste determinado produto esta dimensionada no processo corrente da empresa; o dimensionamento através do consumo real, ou seja, se conseguíssemos prever exatamente o que seria consumido sem erro algum, este dimensionamento seria o ideal; mas como toda previsão possui um determinado erro, e o que buscamos é minimizar este erro de previsão, apresentamos o dimensionamento da área de *picking* de acordo com esta previsão.

O consumo dos itens, fornecido pela empresa são em uma unidade padrão de embalagens, onde são agrupados os itens deixando-os pronto para serem transportados. Cada *pallet* consegue suportar 3 dessas embalagens padrões, então o valor do consumo fornecido é dividido por 3, e assim encontrar-se a quantidade de *pallet* que

determinado produto ocupa, como os consumos são apresentados mensalmente, divide-se a quantidade de *pallets* encontrado por 30, para que se possa obter a quantidade de consumo em *pallet* por dia. A empresa possui 3 turnos de trabalho, e em cada turno tem como regra da empresa que seja feito 2 ressuprimentos na área de *picking* por turno, logo tem-se 6 ressuprimentos por dia de trabalho. Os endereços da área de *picking* suportam apenas um *pallet* de cada produto, então para encontrar a quantidade de endereços para cada produto, deve dividir a quantidade de *pallets* consumido em um dia por 6.

4.2.1.1 Dimensionamento da área de *picking* para o item Biscoito

A tabela 4.15 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.15 – PREVISÕES DE CONSUMO – BISCOITO

PERÍODO	B&J – RMSE 5772,8		RBF – RMSE 5350,8	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	19070	19216,6	19070	13783
Fevereiro	28990	29056,2	28990	22721
Março	69790	67893,3	69790	71925
Abril	64510	57401,2	64510	56457
Maio	43390	36295,5	43390	43960
Junho	43390	37283,6	43390	43264
Julho	31390	25586,6	31390	36920
Agosto	59390	53256,8	59390	59948
Setembro	50110	44849,8	50110	57831
Outubro	54590	45349,0	54590	64315
Novembro	39550	32790,6	39550	41817
Dezembro	28990	23690,8	28990	33034
PERÍODO	B&J – RMSE 3712,6		RBF – RMSE 2676	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	31390	27239,4	31390	28919
Agosto	59390	51276,2	59390	56146
Setembro	50110	39555,5	50110	53569
Outubro	54590	42632,1	54590	56572
Novembro	39550	32726,1	39550	37635
Dezembro	28990	26401,1	28990	31594
PERÍODO	B&J – RMSE 1723,4		RBF – RMSE 1226,2	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	54590	50636,3	54590	55505
Novembro	39550	38178,4	39550	39111
Dezembro	28990	28434,1	28990	30855

A tabela 4.16 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.16 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – BISCOITO

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	35	36	35	26	38
Fevereiro	54	54	54	42	38
Março	129	126	129	133	38
Abril	119	106	119	105	38
Maio	80	67	80	81	38
Junho	80	69	80	80	38
Julho	58	47	58	68	38
Agosto	110	99	110	111	38
Setembro	93	83	93	107	38
Outubro	101	84	101	119	38
Novembro	73	61	73	77	38
Dezembro	54	44	54	61	38
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	58	50	58	54	38
Agosto	110	95	110	104	38
Setembro	93	73	93	99	38
Outubro	101	79	101	105	38
Novembro	73	61	73	70	38
Dezembro	54	49	54	59	38
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	101	94	101	103	38
Novembro	73	71	73	72	38
Dezembro	54	53	54	57	38

4.2.1.2 Dimensionamento da área de *picking* para o item Macarrão

A tabela 4.17 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.17 – PREVISÕES DE CONSUMO – MACARRÃO

PERÍODO	B&J – RMSE 5996,4		RBF – RMSE 5884	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	11154	16989,5	11154	26655
Fevereiro	22834	24171,1	22834	29507
Março	24914	31989,8	24914	31850
Abril	33714	27053	33714	31999
Mai	40434	38626,1	40434	33652
Junho	32914	29384	32914	32686
Julho	41714	51418,8	41714	41963
Agosto	57714	69391,5	57714	57596
Setembro	49554	42883,4	49554	48831
Outubro	36594	34262,4	36594	37044
Novembro	28114	30158,4	28114	33436
Dezembro	27314	26404,7	27314	25204
PERÍODO	B&J – RMSE 5414,9		RBF – RMSE 2718,4	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Mai	-	-	-	-
Junho	-	-	-	-
Julho	41714	38558,8	41714	40887
Agosto	57714	55862,9	57714	55240
Setembro	49554	40643,7	49554	46865
Outubro	36594	30747,6	36594	36388
Novembro	28114	33955,6	28114	33558
Dezembro	27314	23460,3	27314	26525
PERÍODO	B&J – RMSE 3149,9		RBF – RMSE 951,5	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Mai	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	36594	32689,5	36594	36302
Novembro	28114	24366,0	28114	29649
Dezembro	27314	21814,9	27314	26791

A tabela 4.18 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.18 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – MACARRÃO

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	21	31	21	49	38
Fevereiro	42	45	42	55	38
Março	46	59	46	59	38
Abril	62	50	62	59	38
Maio	75	72	75	62	38
Junho	61	54	61	61	38
Julho	77	95	77	78	38
Agosto	107	129	107	107	38
Setembro	92	79	92	90	38
Outubro	68	63	68	69	38
Novembro	52	56	52	62	38
Dezembro	51	49	51	47	38
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	77	71	77	76	38
Agosto	107	103	107	102	38
Setembro	92	75	92	87	38
Outubro	68	57	68	67	38
Novembro	52	63	52	62	38
Dezembro	51	43	51	49	38
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	68	61	68	67	38
Novembro	52	45	52	55	38
Dezembro	51	40	51	50	38

4.2.1.3 Dimensionamento da área de *picking* para o item *Candies*

A tabela 4.19 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.19 – PREVISÕES DE CONSUMO – *CANDIES*

PERÍODO	B&J – RMSE 768,7		RBF – RMSE 653	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	24846	23737	24846	23849
Fevereiro	23406	24021,5	23406	24327
Março	24526	23819,0	24526	23820
Abril	24526	23800,7	24526	23616
Maio	23406	23718,9	23406	23667
Junho	24206	23664,7	24206	23658
Julho	23886	23604,3	23886	23702
Agosto	24046	23549,9	24046	24243
Setembro	25166	23497	25166	24282
Outubro	24366	23446,9	24366	24122
Novembro	23726	23399,1	23726	24440
Dezembro	23406	23353,6	23406	23801
PERÍODO	B&J – RMSE 635,6		RBF – RMSE 362,2	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	23886	23817,0	23886	23706
Agosto	24046	23855,3	24046	23745
Setembro	25166	23777,3	25166	25063
Outubro	24366	23734,4	24366	23927
Novembro	23726	23684,2	23726	23718
Dezembro	23406	23638,4	23406	24085
PERÍODO	B&J – RMSE 524,9		RBF – RMSE 113,8	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	24366	24354,6	24366	24481
Novembro	23726	24519,5	23726	23691
Dezembro	23406	24417,8	23406	23562

A tabela 4.20 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.20 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – *CANDIES*

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	46	44	46	44	38
Fevereiro	43	44	43	45	38
Março	45	44	45	44	38
Abril	45	44	45	44	38
Maio	43	44	43	44	38
Junho	45	44	45	44	38
Julho	44	44	44	44	38
Agosto	45	44	45	45	38
Setembro	47	44	47	45	38
Outubro	45	43	45	45	38
Novembro	44	43	44	45	38
Dezembro	43	43	43	44	38
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	44	44	44	44	38
Agosto	45	44	45	44	38
Setembro	47	44	47	46	38
Outubro	45	44	45	44	38
Novembro	44	44	44	44	38
Dezembro	43	44	43	45	38
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	45	45	45	45	38
Novembro	44	45	44	44	38
Dezembro	43	45	43	44	38

4.2.1.4 Dimensionamento da área de *picking* para o item Chocolate

A tabela 4.21 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.21 – PREVISÕES DE CONSUMO – CHOCOLATE

PERÍODO	B&J – RMSE 2600,5		RBF – RMSE 3026,6	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	31235	26800	31235	35016
Fevereiro	31234	26783,2	31234	28994
Março	39239	39449,1	39239	39098
Abril	45635	41006,5	45635	40828
Maio	36360	34029,3	36360	39990
Junho	33481	34049,2	33481	32961
Julho	27397	27798,4	27397	30397
Agosto	34916	34371,2	34916	29715
Setembro	26115	26898,1	26115	27889
Outubro	24840	27784	24840	24413
Novembro	17635	19746,3	17635	19540
Dezembro	22119	21614,5	22119	18800
PERÍODO	B&J – RMSE 2085,3		RBF – RMSE 2376,5	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	27397	27061,3	27397	28856
Agosto	34916	32747,5	34916	30658
Setembro	26115	21833,6	26115	22666
Outubro	24840	24376,9	24840	23534
Novembro	17635	16123,9	17635	17778
Dezembro	22119	21449,8	22119	22122
PERÍODO	B&J – RMSE 851,8		RBF – RMSE 503,5	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	24840	26129,5	24840	24248
Novembro	17635	18356,3	17635	17040
Dezembro	22119	23592,5	22119	21881

A tabela 4.22 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.22 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – CHOCOLATE

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	58	50	58	65	38
Fevereiro	58	50	58	54	38
Março	73	73	73	72	38
Abril	85	76	85	76	38
Maio	67	63	67	74	38
Junho	62	63	62	61	38
Julho	51	51	51	56	38
Agosto	65	64	65	55	38
Setembro	48	50	48	52	38
Outubro	46	51	46	45	38
Novembro	33	37	33	36	38
Dezembro	41	40	41	35	38
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	51	50	51	53	38
Agosto	65	61	65	57	38
Setembro	48	40	48	42	38
Outubro	46	45	46	44	38
Novembro	33	30	33	33	38
Dezembro	41	40	41	41	38
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	46	48	46	45	38
Novembro	33	34	33	32	38
Dezembro	41	44	41	41	38

4.2.1.5 Dimensionamento da área de *picking* para o item Refresco

A tabela 4.23 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.23 – PREVISÕES DE CONSUMO – REFRESCO

PERÍODO	B&J – RMSE 2279,4		RBF – RMSE 2646,1	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	30143	26369,5	30143	25134
Fevereiro	26543	29273,3	26543	23969
Março	18893	19134,6	18893	21232
Abril	19943	18266,7	19943	18664
Maio	17243	17836,5	17243	16777
Junho	15443	15661,1	15443	13630
Julho	16343	14752,5	16343	19381
Agosto	13643	14646,9	13643	14335
Setembro	15443	13625,5	15443	12208
Outubro	28943	26134,2	28943	30833
Novembro	25343	23382,8	25343	21786
Dezembro	28943	24605,2	28943	26643
PERÍODO	B&J – RMSE 2020,1		RBF – RMSE 1980,4	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	16343	16972,2	16343	18064
Agosto	13643	15480,4	13643	15127
Setembro	15443	14893,4	15443	13875
Outubro	28943	27410,9	28943	28520
Novembro	25343	29386,8	25343	22097
Dezembro	28943	27634,8	28943	26664
PERÍODO	B&J – RMSE 1151,6		RBF – RMSE 1312,7	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	28943	27132,6	28943	28438
Novembro	25343	24067,5	25343	23346
Dezembro	28943	27195,7	28943	29906

A tabela 4.24 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.24 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – REFRESCO

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	56	49	56	47	35
Fevereiro	49	54	49	44	35
Março	35	35	35	39	35
Abril	37	34	37	35	35
Maio	32	33	32	31	35
Junho	29	29	29	25	35
Julho	30	27	30	36	35
Agosto	25	27	25	27	35
Setembro	29	25	29	23	35
Outubro	54	48	54	57	35
Novembro	47	43	47	40	35
Dezembro	54	46	54	49	35
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	30	31	30	33	35
Agosto	25	29	25	28	35
Setembro	29	28	29	26	35
Outubro	54	51	54	53	35
Novembro	47	54	47	41	35
Dezembro	54	51	54	49	35
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	54	50	54	53	35
Novembro	47	45	47	43	35
Dezembro	54	50	54	55	35

4.2.1.6 Dimensionamento da área de *picking* para o item Cereais

A tabela 4.25 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.25 – PREVISÕES DE CONSUMO – CEREAIS

PERÍODO	B&J – RMSE 302,4		RBF – RMSE 349,8	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	9193	9055,86	9193	9019,1
Fevereiro	9344	9079,35	9344	9027,3
Março	9645	9072,43	9645	9114,9
Abril	9346	9075,98	9346	9007,9
Maio	9047	9134,86	9047	8822,6
Junho	9648	9189,22	9648	9246,3
Julho	9049	9170,88	9049	9211,7
Agosto	9350	9196,93	9350	8710,2
Setembro	9651	9218,16	9651	9602,9
Outubro	9052	9231,01	9052	9245,5
Novembro	8903	9257,61	8903	9008,6
Dezembro	9204	9282,95	9204	9698,1
PERÍODO	B&J – RMSE 247,9		RBF – RMSE 311,4	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	9049	8778,14	9049	9557,6
Agosto	9350	9256,42	9350	8963,5
Setembro	9651	9765,82	9651	9724,7
Outubro	9052	9235,99	9052	9393,9
Novembro	8903	9270,57	8903	9062,4
Dezembro	9204	9527,27	9204	9366,4
PERÍODO	B&J – RMSE 153,7		RBF – RMSE 65,6	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	9052	9251,94	9052	8986,7
Novembro	8903	9007,98	8903	8971,3
Dezembro	9204	9505,31	9204	9140,8

A tabela 4.26 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.26 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – CEREAIS

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	17	17	17	17	30
Fevereiro	17	17	17	17	30
Março	18	17	18	17	30
Abril	17	17	17	17	30
Maio	17	17	17	16	30
Junho	18	17	18	17	30
Julho	17	17	17	17	30
Agosto	17	17	17	16	30
Setembro	18	17	18	18	30
Outubro	17	17	17	17	30
Novembro	16	17	16	17	30
Dezembro	17	17	17	18	30
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	17	16	17	18	30
Agosto	17	17	17	17	30
Setembro	18	18	18	18	30
Outubro	17	17	17	17	30
Novembro	16	17	16	17	30
Dezembro	17	18	17	17	30
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	17	17	17	17	30
Novembro	16	17	16	17	30
Dezembro	17	18	17	17	30

4.2.1.7 Dimensionamento da área de *picking* para o item Panetones

A tabela 4.27 apresenta as previsões de consumo através dos modelos *B&J* e das redes RBF para os períodos 12, 6 e 3 meses, com seus respectivos RMSE.

TABELA 4.27 – PREVISÕES DE CONSUMO – PANETONES

PERÍODO	B&J – RMSE 396,8		RBF – RMSE 521,1	
12 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	7405	6645,13	7405	6445,6
Fevereiro	5405	5250,33	5405	5624,2
Março	2805	3216,86	2805	3801,7
Abril	3405	3445,15	3405	3044,4
Maio	2805	2864,15	2805	3097,3
Junho	3205	2979,73	3205	3141,9
Julho	3405	2739,52	3405	2815,6
Agosto	3005	3186,59	3005	3234,7
Setembro	2405	2939,02	2405	2925,4
Outubro	3205	3052,68	3205	2791,7
Novembro	4505	5032,47	4505	4968,1
Dezembro	6205	6172,46	6205	6296,5
PERÍODO	B&J – RMSE 416,2		RBF – RMSE 396	
6 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	3405	2686,1	3405	2723,9
Agosto	3005	3102,62	3005	3163,1
Setembro	2405	2167,9	2405	2908,2
Outubro	3205	2809,6	3205	3354,3
Novembro	4505	5006,19	4505	4574
Dezembro	6205	6427	6205	6619,6
PERÍODO	B&J – RMSE 379,1		RBF – RMSE 192,4	
3 meses	REAL	PREVISÃO	REAL	PREVISÃO
Janeiro	-	-	-	-
Fevereiro	-	-	-	-
Março	-	-	-	-
Abril	-	-	-	-
Maio	-	-	-	-
Junho	-	-	-	-
Julho	-	-	-	-
Agosto	-	-	-	-
Setembro	-	-	-	-
Outubro	3205	2968,61	3205	3197,8
Novembro	4505	5077,7	4505	4732,2
Dezembro	6205	6896,85	6205	6448,9

A tabela 4.28 apresenta duas colunas com o título Previsão, nestas apresentam as previsões do dimensionamento da área de *picking*, calculadas a partir das previsões de consumo efetuadas através da metodologia *B&J* e Redes RBF. A coluna com o título Ideal apresentam os dimensionamentos ótimos, calculados a partir do consumo real do produto, e para completar, com o título Atual, é apresentado o dimensionamento atual da área de *picking*.

TABELA 4.28 – PREVISÃO DA DIMENSÃO DA ÁREA DE *PICKING* – PANETONES

PERÍODO	BOX & JENKINS		REDES RBF		Atual
	Ideal	Previsão	Ideal	Previsão	
12 meses					
Janeiro	14	12	14	12	21
Fevereiro	10	10	10	10	21
Março	5	6	5	7	21
Abril	6	6	6	6	21
Maio	5	5	5	6	21
Junho	6	6	6	6	21
Julho	6	5	6	5	21
Agosto	6	6	6	6	21
Setembro	4	5	4	5	21
Outubro	6	6	6	5	21
Novembro	8	9	8	9	21
Dezembro	11	11	11	12	21
6 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	6	5	6	5	21
Agosto	6	6	6	6	21
Setembro	4	4	4	5	21
Outubro	6	5	6	6	21
Novembro	8	9	8	8	21
Dezembro	11	12	11	12	21
3 meses					
Janeiro	-	-	-	-	-
Fevereiro	-	-	-	-	-
Março	-	-	-	-	-
Abril	-	-	-	-	-
Maio	-	-	-	-	-
Junho	-	-	-	-	-
Julho	-	-	-	-	-
Agosto	-	-	-	-	-
Setembro	-	-	-	-	-
Outubro	6	5	6	6	21
Novembro	8	9	8	9	21
Dezembro	11	13	11	12	21

5 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Neste trabalho foi apresentado o problema de dimensionamento da área de *picking* de um centro de distribuição, onde seria de extrema importância a previsão de consumo dos itens armazenados, para que decisões estratégicas possam ser tomadas, influenciando no tempo total de carregamento dos caminhões e o que pode acarretar no nível de serviço do armazém.

Quando o armazém está preparado para absorver a demanda dos produtos e a área de *picking* está dimensionada corretamente, evita-se com que a separação fique prejudicada por falta de itens na área de *picking* ou que a data de validade seja atingida por itens que não foram separados para algum carregamento.

Foram apresentadas duas ferramentas para que sejam feitas as previsões de consumos dos itens do armazém, a primeira delas são os modelos estatísticos tradicionais utilizando a metodologia *Box & Jenkins* e a segunda são os modelos utilizando as Redes Neurais artificiais através das redes de funções de bases radiais.

Após a utilização em 7 series temporais que representam o consumo dos produtos do armazém da empresa estudada, um armazém que comporta apenas produtos alimentícios, foi feito previsões para cada uma das séries em ambas as metodologias, e foi comparado a acuracidade através da medida do RMSE (*root mean squared error*).

Atualmente existe um dimensionamento da área de *picking* dos produtos no processo corrente da empresa, este dimensionamento calculado com base na experiência de funcionários antigos. Ao observar este dimensionamento e compará-lo com o consumo real que ocorre na empresa, pode se observar que o mesmo se encontra incorreto, muitas vezes a área de *picking* esta com o dimensionamento maior que o necessário o que pode causar vencimento de produtos na área de *picking*, e em outros momentos a mesa se encontra com dimensionamento menor que o necessário, causando atraso no carregamento dos pedidos nos caminhões. Outro fato que pode ser comentado é que em alguns produtos os dimensionamentos estão menores em alguns

períodos do ano e em outros estão maiores, esse fenômeno ocorre devido a forte presença da sazonalidade dos produtos.

Das 7 series analisadas, foram divididas em 3 períodos de previsão por series, no horizontes de 12 meses, 6 meses e 3 meses totalizando 21 períodos analisados. Os testes apresentaram uma grande superioridade nas previsões por Redes Neurais artificiais, sendo que em poucos momentos, ou seja, em 7 períodos ouve uma pequena superação dos modelos estatísticos sobre as redes RBF. Nos momentos que os métodos estatísticos apresentaram uma performance melhor, superando as redes RBF, foi observado através da comparação do RMSE das previsões, e como a superioridade foi muito pequena, este fato não nos impede de concluir que poderíamos utilizar as redes RBF, para efetuar previsões para que o dimensionamento da área de *picking* tenha uma boa acuracidade.

Uma vantagem que as redes RBF apresentaram sobre os modelos estatísticos é que os mesmos podem ser utilizados para qualquer series sem muitas modificações, ou seja, basta ajustar os parâmetros de entrada da rede e a mesma possui a capacidade de se adequar à série. As Redes Neurais são dinâmicas e possuem a capacidade de se adequar às mudanças ocorridas nas séries. As mesmas podem aprender novas características, mudanças como sazonalidades e tendências.

Como sugestões para novos trabalho poderia ser feito um estudo dos fatores que influenciam diretamente no consumo de cada produto, podendo assim identificar novas séries temporais paralelas as séries principais, as quais são de consumo do produto. Uma vez identificadas essas séries poderiam ser utilizadas nas previsões pelas Redes Neurais, uma vez que as mesmas possuem essa capacidade de processamento paralelo, aumentando assim a acuracidade das previsões. E para verificar os relacionamentos destas séries com as séries de consumo, tratamentos estatísticos podem ser utilizados, como a matriz de auto-correlação.

REFERÊNCIAS

ABELÉM, A. J. G. **Redes Neurais Artificiais na previsão de séries temporais.** Tese (Mestrado em Engenharia Elétrica) - Curso de Mestrado em Engenharia Elétrica, PUC-Rio, Rio de Janeiro. 1994.

BALLOU, R. H. **Logística empresarial:** transportes, administração de materiais distribuição física. São Paulo, Atlas, 1993.

BANZATO, E. **Atualidades na armazenagem.** São Paulo: Imam, 2003.

BANZATO, E. **Warehouse management system WMS:** sistema de gerenciamento de armazéns. São Paulo, Imam, 2001.

BARROS, M. C. **WMS no gerenciamento de depósitos, armazéns e centros de distribuição.** Revista Tecnológica, p. 72-77, maio, 2005.

BARROSO, F. **Operações cross-docking.** Rio de Janeiro, Coppead UFRJ, [2003.]. (Apostila do Curso de Gestão Estratégica da Armazenagem)

BERTAGLIA, P. R. **Logística e gerenciamento da cadeia de abastecimento.** São Paulo: Saraiva, 2003.

BISHOP, R.; ADDISON, WESLEY. **Pattern Recognition and Neural Networks.** 1996.

BOX, G. E. P.; JENKINS, G. M. **Times Series Analysis: forecasting and control.** Ed. Holden Day, 1976.

BOWERSOX, D. J. **Gerenciamento logístico.** São Paulo, Macmillan, 1984.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Fundamentos de Redes Neurais Artificiais**. 11ª Escola de Computação. Rio de Janeiro, RJ, 1998.

BROOMHEAD, D. S.; LOWE, D. **Multivariable functional interpolation and adaptive networks**. Complex Systems, 1988.

CASDAGLI, M. **Nonlinear Prediction of Chaotic Time Series**. Physica D, V35, pp335-356, 1989.

CASTRO, M. C. F. **Predição não-linear de séries temporais usando redes neurais rbf por decomposição em componentes principais**. Tese de doutorado, unicamp 2001.

CERTO, S. C. **Administração moderna**. São Paulo, Prentice Hall, 2003.

CHEN, J. P. **Ph.D. thesis Longitudinal and transverse response functions**, University of Virginia, 1991

CHIAVENATO, I. **Introdução à administração geral**. São Paulo, McGraw-Hill, 1989.

CHRISTOPHER, M. **Logística e gerenciamento da cadeia de suprimentos: estratégias para a redução de custos e melhoria dos serviços**. São Paulo, Pioneira Thomson Learning, 1997.

COOPER, M. C., LAMBERT, D. M., PAGH, J. D. **Supply chain management: more than a new name for logistics**. The International Journal of Logistics Management, 1997.

DUDA, R. O.; HART, J. W.; SONS. **Pattern Classification and Scene Analysis**. 1973.

FLEURY, P. F.; WANKE, P.; FIGUEIREDO, K. F. **Logística empresarial: a perspectiva brasileira**. Coleção COPPEAD de Administração. São Paulo: Atlas, 2000.

HASSOUN, S. **Logic Synthesis and Verification**. Tufts University, Medford, Massachusetts, USA, 1995.

HAYKIN, S. **Redes Neurais. Princípios e prática**. Porto Alegre, RS: Bookman, 2001.

HEBB, D. O. **The organization of behavior**. Wiley: New York, 1949.

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

HOPFIELD, J. J. **Neural network and physical systems with emergent collective computation abilities**. In: National Academy of science. EUA, 1979. /Anais/E.U.A., p. 2554-2558, 1982.

KWASNICKA, E. L. **Introdução à administração**. São Paulo: Atlas, 1987.

LANDI, L.; BARUCCI, E. **Artificial neural network for treasury bills rate forecasting**. In: Neural Network in Capital Markets,1. Londres, 18-19 novembro de 1993. /Anais/, Londres, London Business School, 1993.

LAPEDES A.; FABER R. **How Neural Nets Work**. Neural Information Processing Systems. Denver, 1987.

LE CUN, Y. **Une procédure d'apprentissage pour réseau à seuil assymétrique**. In: *Cognitiva 85: a la frontiere de l'intelligence artificielle desw sciences de la connaissance des neuroscience*, Paris 1985./ *Anais/*. Paris, p. 599-604, 1985.

LEE, S.; KIL, R. M. **Gaussian Potential Functions**. GPF, 1988.

LILIANE G. C. R. **Administração: noções gerais - conceitos básicos**. Disponível em: http://www.rits.org.br/gestao_teste/ge_testes/ge_mat01_adm_admtxt.cfm. Acesso em: 5 jun. 2005.

LIMA, M. P. C. **logísticos: uma visão gerencial**. Centro de Estudos em Logística – COPPEAD, UFRJ, 1998. Disponível em: <http://www.coppead.ufrj.br/pesquisa/cel/new/fr-custo.htm>. Acesso em: 05 jun. 2005.

MAXIMIANO, A. C. A. **Introdução à administração**. São Paulo, Atlas, 1981.

MAKRIDAKIS, S.; WHEEL W. S. C.; MCGEE, V. E. **Forecasting: Methods and Applications**. 2^a ed. Nova York: John Wile & Sons, 1983

MAKRIDAKIS, S.; HIBON, M. **The m3-Competition: Results, Conclusions and Implications**. *International Journal of Forecasting*, v. 16, p. 451-476, 2000.

McCULLOCH, W. S.; PITTS, W. **A logical Calculus of ideias immanent in nervos activity**. *Bulletin of Mathematical Biophysics*, n. 5, p. 115-133, 1943.

MEDGASSY, P. **Decomposition of Superposition of Distribution Functions**. Publishing House of the Hungarian Academy of Sciences, Budapest, 1961.

MICCHELLI, C. A.; HARTMUT P. **Uniform refinement of curves**. *Journal linear algebra appl*. 1989.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry**. 3. ed. Massachusetts: M.I.T. Press, 1988.

MOODY, J.; DARKEN, C. **Neural Computation**, 1989

MORETTIN, P. A.; TOLOI, C.M. C. **Modelos Para Previsão de Séries Temporais**. In: Colóquios Brasileiros de Matemática, 13^a, 1981, Poços de Caldas-MG, IMPA, Rio de Janeiro, 1981.

MOURA, R. A. **Manual de logística: armazenagem e distribuição física**. São Paulo: Imam, 1998. v2.

NIRANJAN, M.; THAN V. K.; FRANK F. **Sequential Adaptation of Radial Basis Function Networks**. NIPS, 1990.

NOVAES, A. G. **Logística e gerenciamento da cadeia de distribuição**. Rio de Janeiro, Campus, 2001.

OLIVEIRA, G. A. **Sistema de Controle e Otimização de Estoques Utilizando a Metodologia Box & Jenkins Para Séries Temporais**. Dissertação de mestrado, Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná. Curitiba, 2002.

PARKER, D. B. **Learning Logic**. Technical report TR-47. Center of Computational Research in Economics and Management Science, MIT, 1985.

PARK, D. C. **Electrical load forecasting using an artificial neural network**. Artificial Neural Network: forecasting time series. E.U.A., IEEE Press, p. 43-49, 1994.

PITTS, W.; McCULLOCH, W. S. **How we know universals**. Bulletin of Mathematical Biophysics. /s.l./v. 9, p 127-147, 1947.

PODDIG, T. **Short-Term forecasting of the USD/DM-exchange rate**. In: Neural Network in Capital Markets,1. Londres, 18-19 novembro de 1993. /Anais/, Londres, London Business School, 1993.

POGGIO, T.; F. GIROSI. **Network for approximation and learning**. Proc. IEEE, September 1990.

ROCHA, A. F. **A neural net for extracting knowledge from natural language data bases**. IEEE Transactions on neural network. E.U.A., v. 3, n.1, p. 1-10, 1992.

RODRIGUES, A. M. **Estratégias de *picking* na armazenagem**. Disponível em: <http://www.cel.coppead.ufrj.br/fs-busca.htm?fr-picking.htm>. Acesso em: 20 ago 2005.

ROSENBLATT, F. **Principles of neurodynamics**. New York: Spartan, 1962.

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

RUSSELL, S. J.; NORVIG, P.. **Artificial Intelligence: a modern approach**. New Jersey: Prentice-Hall Inc, 1995.

SAHA, A.; KELLER, J. D.; MORGAN K. **Neural Information Processing Systems**, San Mateo, CA, 1990.

STONER, J. A. F. **Administração**. Rio de Janeiro, Prentice Hall do Brasil, 2000.

SUCUPIRA, C. **Gestão de depósitos e centros de distribuição através dos**

softwares WMS. Disponível em: <http://www.cezarsucupira.com.br/artigos111.htm>.
Acesso em: 5 jun. 2005.

WASSERMAN, P. D. **Advanced methods in neural computing.** New York: Van Nostrand Reinhold, 1993.

WERBOS, P. J. **Beyond regression:** new tools for prediction and analysis in the behavioral Science. Havard University, 1974. Tese de PhD.

WETTSCHERE, D.; DIETTERICH, T. G. **An Experimental Comparison of the Nearest-Neighbor and Nearest-Hyperre Algorithms,** Machine Learning, v.19 n.1, p.5-27, April 1992.

WHEEL, W. S. C.; MARKIDRAKIS, S. **Forecasting Methods for Manegement.** 4^a ed, Nova York: John Wiley & Sons Inc., 1985.

ANEXO 1 – PROGRAMA EFETUADO NA LINGUAGEM MATLAB PARA PREVISÃO
DE SÉRIE TEMPORAL ATRAVÉS DAS REDES NEURAIS DE FUNÇÃO DE BASE
RADIAL

```

aux=[inserir aqui em forma de coluna o consumo da série];

aux=aux';

[auxn,minaux,maxaux] = premnmx(aux);

numEntrada    = 10;
totalOcorrencia = 84;
numTeste      = 6;

menorerro_eg = 9999999999999999999;
contaux      = 1;

w = totalOcorrencia - numTeste - numEntrada;
p = auxn(1:w);

y = totalOcorrencia - numEntrada;
p1 = auxn( (totalOcorrencia - numTeste - numEntrada + 1) : y );

for z = 2:numEntrada,
    w = w+1;
    y = y+1;
    p = [ p ; auxn(z:w)];
    p1 = [ p1 ; auxn((totalOcorrencia - numTeste - numEntrada + z) : y )];
end

t = auxn( (numEntrada + 1) : (totalOcorrencia - numTeste) );
t1 = auxn( (totalOcorrencia - numTeste + 1) : totalOcorrencia );

sc = 0.7;
eg = 0.01; % sum-squared error goal
while eg < 4,

    net = newrb(p,t,eg,sc);

    an = sim(net,p);

    [a] = postmnmx(an,minaux,maxaux);
    cont = (numEntrada+1):(totalOcorrencia - numTeste);

    cont2=1:numTeste;
    testen = sim(net,p1);
    [teste] = postmnmx(testen,minaux,maxaux);

    erro = aux( (totalOcorrencia - numTeste + 1) : totalOcorrencia ) - teste;

    rmse = sqrt(mse(erro));

```

```

veterror_eg(contaux) = rmse;
vetor_eg(contaux) = eg;

contaux = contaux + 1;

if rmse < menorerro_eg ,
    menorerro_eg = rmse ;
    numeg = eg;
end

eg = eg + 0.03;

end

menorerro_sc = 9999999999999999999;
contaux = 1;

sc = 0.01;
eg = numeg; % sum-squared error goal
while sc < 4,

    net = newrb(p,t,eg,sc);

    an = sim(net,p);

    [a] = postmnmx(an,minaux,maxaux);
    cont = (numEntrada+1):(totalOcorrencia - numTeste);

    cont2=1:numTeste;
    testen = sim(net,p1);
    [teste] = postmnmx(testen,minaux,maxaux);

    erro = aux( (totalOcorrencia - numTeste + 1) : totalOcorrencia ) - teste;

    rmse = sqrt(mse(erro));

    veterror_sc(contaux) = rmse;

    vetor_sc(contaux) = sc;

    contaux = contaux + 1;

    if rmse < menorerro_sc ,
        menorerro_sc = rmse ;
        numsc = sc;
    end
end

```

```

sc = sc + 0.03;

end

numEntrada = 2;

menorerro_ent = 9999999999999999999;
contaux = 1;

while numEntrada < 12 ,
    w = totalOcorrencia - numTeste - numEntrada;
    p = auxn(1:w);

    y = totalOcorrencia - numEntrada;
    p1 = auxn( (totalOcorrencia - numTeste - numEntrada + 1) : y );

    for z = 2:numEntrada,
        w = w+1;
        y = y+1;
        p = [ p ; auxn(z:w)];
        p1 = [ p1 ; auxn((totalOcorrencia - numTeste - numEntrada + z) : y )];
    end

    t = auxn( (numEntrada + 1) : (totalOcorrencia - numTeste) );
    t1 = auxn( (totalOcorrencia - numTeste + 1) : totalOcorrencia );

    sc = numsc;
    eg = numeg; % sum-squared error goal

    net = newrb(p,t,eg,sc);

    an = sim(net,p);

    [a] = postmnmx(an,minaux,maxaux);
    cont = (numEntrada+1):(totalOcorrencia - numTeste);

    cont2=1:numTeste;
    testen = sim(net,p1);
    [teste] = postmnmx(testen,minaux,maxaux);

    erro = aux( (totalOcorrencia - numTeste + 1) : totalOcorrencia ) - teste;

    rmse = sqrt(mse(erro));

    veterror_ent(contaux) = rmse;

```

```

vetor_ent(contaux) = numEntrada;

contaux = contaux + 1;

if rmse < menorerro_ent ,
    menorerro_ent = rmse ;
    nument = numEntrada;
end

numEntrada = numEntrada + 1;

end

sc = numsc;
eg = numeg; % sum-squared error goal
numEntrada = nument;

w = totalOcorrencia - numTeste - numEntrada;
p = auxn(1:w);

y = totalOcorrencia - numEntrada;
p1 = auxn( (totalOcorrencia - numTeste - numEntrada + 1) : y );

for z = 2:numEntrada,
    w = w+1;
    y = y+1;
    p = [ p ; auxn(z:w)];
    p1 = [ p1 ; auxn((totalOcorrencia - numTeste - numEntrada + z) : y)];
end

t = auxn( (numEntrada + 1) : (totalOcorrencia - numTeste) );
t1 = auxn( (totalOcorrencia - numTeste + 1) : totalOcorrencia );

net = newrb(p,t,eg,sc);

an = sim(net,p);

[a] = postmnmx(an,minaux,maxaux);
cont = (numEntrada+1):(totalOcorrencia - numTeste);

plot(cont,a,cont,aux((numEntrada+1):(totalOcorrencia -
numTeste)),cont,a,'o',cont,aux((numEntrada+1):(totalOcorrencia - numTeste)),'+');
pause

```

```
cont2=1:numTeste;
testen = sim(net,p1);
[teste] = postmnmx(testen,minaux,maxaux);

%plot(cont2,teste,cont2,aux((totalOcorrencia-numTeste+1):totalOcorrencia));
plot(cont2,teste,cont2,aux((totalOcorrencia-numTeste+1):totalOcorrencia),
cont2,teste,'o',cont2,aux((totalOcorrencia-numTeste+1):totalOcorrencia),'+');

erro = aux( (totalOcorrencia - numTeste + 1) : totalOcorrencia ) - teste;

rmse = sqrt(mse(erro))
```