

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ

SACHA TADEU BRANCO

**ESPECIFICAÇÃO DE UMA FERRAMENTA DE PREVISÃO DE
DEMANDA PARA EQUIPAMENTOS DE INFRA-ESTRUTURA DE
TELECOMUNICAÇÕES**

CURITIBA

2008

SACHA TADEU BRANCO

**ESPECIFICAÇÃO DE UMA FERRAMENTA DE PREVISÃO DE
DEMANDA PARA EQUIPAMENTOS DE INFRA-ESTRUTURA DE
TELECOMUNICAÇÕES**

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Prof. Dr. Raimundo José Borges de Sampaio

CURITIBA

2008

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR

B816e
2008 Branco, Sacha Tadeu
Especificação de uma ferramenta de previsão de demanda para equipamentos de infra-estrutura de telecomunicações / Sacha Tadeu Branco ; orientador, Raimundo José Borges de Sampaio. -- 2008.
102 f. : il. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2008

Bibliografia: f. 94-102

1. Telecomunicações – Equipamentos e acessórios. 2. Telecomunicações -. Regulamentação. 3. Redes neurais (Computação). I. Sampaio, Raimundo José Borges de. II. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas. III. Título.

CDD 20. ed. – 621.382

Dedico este trabalho à minha querida esposa
pelo amor, carinho, constante incentivo e
compreensão.

AGRADECIMENTOS

A minha esposa Alessandra pela felicidade que compartilhamos, paciência, incentivo e compreensão pelas minhas ausências.

Aos meus pais, Índio, e Clarissa, pelo amor dedicado e que ensinaram os valores do estudo e dedicação, indispensáveis para o desenvolvimento deste trabalho.

A minha irmã Tatiana pelo companheirismo, respeito e apoio.

Ao Prof. Dr. Raimundo José Borges de Sampaio pela orientação, apoio, cobranças, incentivo, amizade e ensinamentos passados para o desenvolvimento deste trabalho.

Ao Prof. Dr. Leandro dos Santos Coelho pelo apoio, incentivo, e valiosos conhecimentos passados para a realização deste trabalho.

Aos amigos do PPGEPS, professores, colegas de mestrado que compartilham da luta pela busca do conhecimento e auxiliam a superar as dificuldades para a conclusão do trabalho realizado.

Ao amigo Prof. Dr. Hugo Vieira Neto pelo exemplo de dedicação, pela amizade, apoio e auxílio nesta empreitada.

Ao amigo César Augusto Alves, pelos ensinamentos de vida e profissionais trocados, amizade e incentivo para a realização do mestrado.

Aos colegas de trabalho pelo apoio, respeito, exemplos e companheirismo nos 18 anos de convívio.

A todos, muito obrigado!

RESUMO

O mercado de telecomunicações está cada vez mais desregulamentado e competitivo, enquanto cada vez mais tecnologias de telecomunicações estão disponíveis aos usuários. Empresas que operam nestes mercados têm que confiar na previsão de demanda para justificar seus níveis de investimento e assegurar a disponibilidade da capacidade de atendimento da demanda no momento certo. Como esse mercado tem uma enorme quantidade de variáveis, a previsão de demanda é uma atividade cada vez mais desafiadora. Este trabalho propõe um modelo de previsão de demanda adequado ao mercado de equipamentos de infraestrutura de telecomunicações. Este modelo supera em desempenho o modelo de previsão atualmente utilizado. O trabalho trata da problemática da previsão de demanda e indica em que etapa do processo de previsão de demanda um método de previsão é necessário. Através de características encontradas nos principais métodos de séries temporais e causais e na inteligência artificial, é proposto, com base em ampla fundamentação bibliográfica, que as redes neurais é um método capaz de tornar tais previsões acuradas. Após a pesquisa e a definição das entradas, saídas e parâmetros dos modelos, são realizadas previsões de demanda e estas comparadas com a qualidade da previsão de demanda realizada pela empresa em estudo. Os resultados mostram que as redes neurais, de fato, apresentam um desempenho superior em relação à previsão realizada pela empresa e tem um grande potencial de utilização para este tipo de mercado.

Palavras-chave: Previsão de demanda em telecomunicações, redes neurais.

ABSTRACT

Over the past decades the telecommunication market has been more and more deregulated and competitive, while more and more telecommunications technologies are available for the users. Companies operating in these markets have to rely on demand forecasts to justify their level of investments and ensure the capacity availability at the right time. With so many variables in this market, forecasting is becoming more challenging. This work presents a quantitative demand forecast model suitable to the market of telecommunication infrastructure equipments. It begins with the research of demand forecasting and shows in which step of a forecasting process forecast tools shall be used. Through an analysis on the characteristics of some of time series, causal and artificial intelligence forecasting tools, a neural network forecast model is recommended to be the appropriate method for accurate forecast. After a research and the definition of the inputs, outputs and parameters, forecast simulations are performed and compared to the forecast quality method currently obtained by the company under study. The results show that the use of neural networks approach has a better performance than the current company forecast method and also that it has a high potential usage for this kind of market.

Key Words: Forecast for telecommunication market, artificial neural networks.

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Sistema genérico de previsão de demanda.....	26
Figura 2.2 – Mapa das áreas de prestação de serviço celular.....	32
Figura 2.3 – Número total de assinantes de celular no Brasil.....	34
Figura 2.4 – Participação de mercado por tecnologia celular	35
Figura 2.5 – Histórico da demanda da ERB GSM	37
Figura 2.6 – Histórico da demanda de Transceptores GSM.....	37
Figura 2.7 – Estrutura geral do neurônio genérico.....	42
Figura 2.8 – Modelo de um neurônio artificial	43
Figura 2.9 – Exemplo de rede <i>feedforward</i> de camada única.....	46
Figura 2.10 – Exemplo de rede <i>feedforward</i> de múltiplas camadas	47
Figura 2.11 – Exemplo de rede recorrente	48
Figura 2.12 – Classificação do Processo de Aprendizagem.....	49
Figura 2.13 – Exemplo de uma rede perceptron de múltiplas camadas	50
Figura 2.14 – Exemplo de rede de função de base radial	56
Figura 3.1 – Modelo para o projeto de pesquisa.....	63
Figura 3.2 – Processo de elaboração de previsão de demanda da empresa.....	70
Figura 4.1 – Comportamento normalizado das cinco variáveis de entradas	77
Figura 4.2 – Gráfico da função de transferência da rede RBF.....	80
Figura 4.3 – Gráfico saída real x saída estimada das redes MLP.	84
Figura 4.4 – Gráfico saída real x saída estimada das redes RBF.....	87
Figura 4.5 – Gráfico saída real x saída estimada – melhor MSE.....	88
Figura 4.6 – Gráfico saída real x saída estimada – melhor MAPE.	89

LISTA DE TABELAS

Tabela 2.1 – Principais características dos métodos de previsão de demanda quantitativos	28
Tabela 2.2 – Algumas tecnologias disponíveis no Brasil por tipo de serviço	29
Tabela 2.3 – Lista das operadoras de prestação de serviço celular	33
Tabela 2.4 – Casos especiais de telefonia celular.....	33
Tabela 2.5 – Municípios e percentual da população atendidos	34
Tabela 2.6 – Exemplos de função de ativação	45
Tabela 2.7 – Comparação entre redes neurais MLP e RBF	57
Tabela 3.1 – Regras para definição da probabilidade de ganho de um contrato.....	72
Tabela 4.1 – Lista de variáveis obtida através das entrevistas.....	75
Tabela 4.2 – Exemplo de informações qualitativas utilizadas na previsão de demanda.....	76
Tabela 4.3 – Erro treinamento x Erro validação.....	82
Tabela 4.4 – Resultados obtidos pelas redes MLP.....	83
Tabela 4.5 – Resultados obtidos pelas redes RBF com 3 meses de histórico	85
Tabela 4.6 – Resultados obtidos pelas redes RBF com 4 meses de histórico	86
Tabela 4.7 – Resultados obtidos pelas redes RBF com 6 meses de histórico	86
Tabela 4.8 – Comparação dos modelos de RNA com a empresa em estudo – melhor MSE.....	88
Tabela 4.9 – Comparação dos modelos de RNA com a empresa em estudo – melhor MAPE	90

LISTA DE ABREVIATURAS

ADSL – *Asymmetric Digital Subscriber Line*

AMPS – *Advanced Mobile Phone System* (Tecnologia de Comunicação Móvel)

ANATEL – Agência Nacional das Telecomunicações

ARPU – *Average Revenue Per User* (Média de Faturamento por Usuário)

CDMA – *Code Division Multiple Access* (Tecnologia de Comunicação Móvel)

Churn – Termo usado para descrever a rotatividade da clientela de serviços de uma empresa

EBITDA – *Earnings Before Interest, Taxes, Depreciation and Amortization* (Lucros antes de juros, impostos, depreciação e amortização)

ERB – Estação Radio Base

ERP – *Enterprise Resource Planning*

FTTB – *Fiber to the Building*

GSM – *Global System for Mobile Communications* (Tecnologia de Comunicação Móvel)

IBGE – Instituto Brasileiro de Geografia e Estatística

IP – *Internet Protocol*

MATLAB – *Software da The MathWorks*

MAD – *Mean Absolute Deviation* (Desvio Absoluto Médio)

MAPE – *Mean Absolute Percentage Error* (Erro Percentual Absoluto Médio)

MLP – *Multi Layer Perceptron* (Perceptron de Múltiplas Camadas)

MOU – *Minutes Of Use* (média mensal de Minutos de Uso por usuário)

MRP – *Material Requirements Planning*

MSE – *Mean Squared Error* (Erro Quadrático Médio)

PIB – Produto Interno Bruto

RBF – *Radial Basis Function* (Função de Base Radial)

RNA – Rede Neural Artificial

SAC – *Subscriber Acquisition Cost* (Custo de Aquisição de Cliente)

SMC – Serviço Móvel Celular

SMP – Serviço Móvel Pessoal

SKU – *Stock Keeping Unit*

SSE – *Sum-Squared Error* (Soma do quadrado dos erros)

TDMA – *Time Division Multiple Access* (Tecnologia de comunicação móvel)

TRX – Transceptor de radio frequência

WCDMA – *Wideband Code Division Multiple Access* (Tecnologia de comunicação móvel da terceira geração)

WLAN – *Wireless Local Area Networks*

WLL – *Wireless Local Loop*

WIMAX – *Worldwide Interoperability for Microwave Access*

SUMÁRIO

1.	INTRODUÇÃO	14
1.1.	Definição do problema de pesquisa	16
1.2.	Justificativa da pesquisa	16
1.2.1.	Importância da Previsão em uma Empresa.....	16
1.2.2.	Dificuldades da Previsão de Demanda no Mercado de Telecomunicações	17
1.2.3.	Sucesso na Utilização de Redes Neurais em Previsão de Demanda	18
1.2.4.	Motivação do pesquisador	19
1.3.	Objetivos da pesquisa	20
1.3.1.	Objetivo Geral	20
1.3.2.	Objetivos Específicos	20
2.	REFERENCIAL TEÓRICO	22
2.1.	Previsão de Demanda.....	22
2.2.	Fatores que Afetam a Precisão da Previsão de Demanda.....	22
2.3.	Sistema de Previsão de Demanda	24
2.4.	Previsões: Métodos de Tratamento de Informações	26
2.5.	Previsão de Demanda para o Mercado de Telecomunicações	29
2.6.	O Mercado de Telefonia Celular no Brasil.....	32
2.7.	Características da Demanda da Estação Rádio Base de uma Empresa Fornecedora de Equipamentos de Infra-estrutura de Telecomunicações ...	35
2.8.	Método que Poderia ser Aplicada para a Previsão de Demanda.....	38
2.9.	Redes Neurais Artificiais	39
2.9.1.	Conceituação de redes neurais.....	39
2.9.2.	Evolução da teoria sobre RNA	40
2.9.3.	Elementos de uma rede neural	41

2.9.3.1. Neurônio biológico.....	41
2.9.3.2. Neurônio artificial.....	43
2.9.3.3. Função de ativação.....	44
2.9.3.4. Arquiteturas da rede.....	46
2.9.4. Aprendizagem.....	48
2.9.5. Rede neural artificial do tipo perceptron de múltiplas camadas (RNA MLP)	50
2.9.6. Rede neural artificial de função de base radial (RNA RBF)	55
2.10. Redes Neurais Artificiais aplicadas à previsão de demanda.....	57
3. METODOLOGIA.....	61
3.1. Proposta Metodológica para a Solução do Problema	63
3.2. Características do Modelo de RNA a Serem Utilizadas no Experimento	65
3.2.1. Arquitetura da rede.....	65
3.2.1.1. Número de camadas escondidas e nós	65
3.2.1.2. Número de nós de entrada.....	66
3.2.1.3. Número de nós de saída	66
3.2.1.4. Interconexão dos nós	67
3.2.1.5. Inicialização dos pesos	67
3.2.2. Função de ativação	68
3.2.3. Algoritmo de treinamento	68
3.3. Avaliação dos Modelos	69
3.4. Método de Previsão de Demanda da Empresa Fornecedora de Equipamentos de Telecomunicações.....	70
4. DESENVOLVIMENTO	74
4.1. Definição dos parâmetros das redes neurais	74
4.1.1. Pré-processamento dos dados.....	74
4.1.2. Seleção das variáveis de entrada	75

4.1.3.	Seleção da variável de saída	77
4.1.4.	Análise de sensibilidade.....	78
4.1.5.	Organização dos dados	78
4.1.6.	Construção do modelo	79
4.1.6.1.	Definição do modelo de RNA MLP	79
4.1.6.2.	Definição do modelo de RNA RBF	80
4.2.	Análise dos resultados	81
4.2.1.	Resultados das redes MLP	81
4.2.2.	Resultado das redes RBF	84
4.2.3.	Comparação dos resultados obtidos com o da empresa em estudo.....	87
5.	CONCLUSÃO.....	91
	REFERÊNCIAS	95

1. INTRODUÇÃO

O mercado de telecomunicações tem passado por um grande número de mudanças nas últimas décadas. Mudanças regulatórias estão ocorrendo em vários países. São várias as tecnologias de transmissão para serviços de voz e de dados desenvolvidas e implantadas (FILDES e KUMAR, 2002). Em paralelo a todas estas mudanças existem os usuários, operadoras de serviços de telecomunicações e seus fornecedores. As operadoras procuram manter certo nível de qualidade de serviço, enquanto buscam aumentar a participação no mercado e maximizar seus lucros. Para realizar o seu planejamento futuro, as empresas necessitam prever qual será o seu faturamento, a quantidade de produtos ou serviços necessária para atender o mercado, como estará o câmbio no ano seguinte, se a eleição do novo presidente influenciará na demanda do seu produto, etc.

Para satisfazer esta necessidade, as empresas buscam realizar a previsão de um evento futuro. Em se tratando de uma empresa de manufatura, esta previsão é denominada previsão de demanda. Com as mudanças que o mercado de telecomunicações está passando, esta atividade é ainda mais desafiadora.

No dia a dia de uma empresa de manufatura, o tema previsão de demanda é importante. Em um horizonte de longo prazo guiará as decisões estratégicas de pesquisa e desenvolvimento de produto e a necessidade de aumentar ou diminuir o número de unidades de fabricação. Já para um horizonte de curto e médio prazo guiará o dimensionamento operacional da linha de produção, sua capacidade, desenho e política de gestão de estoques. A previsão no curto e médio prazo implicará também diretamente nos indicadores financeiros da empresa, como giro de estoque, eventuais riscos de sucata e de demanda não atendida (*stock out*), afetando o resultado financeiro e o volume das vendas. Com o aumento da concorrência e da competição, a pressão por um preço competitivo é grande. Nesse ambiente, alcançar bons resultados financeiros é altamente desafiador. Para atingi-los, uma otimização dos recursos na cadeia de suprimentos é necessária. A qualidade do planejamento e execução desta otimização depende da qualidade da previsão de demanda futura.

Para realizar a previsão da demanda, existem diversos métodos de previsão quantitativos (p.ex.: modelos causais, métodos estatísticos, inteligência artificial, dentre outros) e qualitativos (p.ex.: pesquisa de mercado, força de vendas, etc.).

Este trabalho busca um método quantitativo de previsão de demanda para um produto de infra-estrutura do mercado de telecomunicações, cuja demanda de uma empresa de manufatura é utilizada como base para a previsão. O produto a ser considerado é o transceptor de rádio para infra-estrutura de telefonia celular da tecnologia de transmissão GSM. Este transceptor é um módulo presente em cada estação rádio base que as operadoras de celular possuem instaladas em sua área de cobertura.

O presente trabalho está organizado da seguinte forma:

Na pesquisa do referencial teórico (capítulo 2) foi levantada a teoria sobre previsão de demanda. É mostrado em que etapa de um processo de previsão de demanda uma ferramenta de previsão pode ser aplicada. São pesquisadas algumas ferramentas (métodos) de previsão de demanda reportadas na literatura. A seguir são explicadas as características do mercado de telecomunicações e em específico o mercado de telefonia celular no Brasil. Em função destas características, foi escolhido um método de previsão de demanda cujas características são adequadas à previsão de demanda de um produto do mercado de telefonia celular. A pesquisa realizada encontra, nos modelos de previsão com redes neurais, características que tornam possível a previsão da demanda do produto selecionado. Após esta seleção, é realizada uma busca mais detalhada sobre aplicação das redes neurais em previsão de demanda, bem como os conceitos sobre redes neurais utilizados pela pesquisa.

No capítulo 3 é descrita a metodologia a ser utilizada na pesquisa, bem como o detalhamento da modelagem e o detalhamento das definições das características das redes neurais artificiais que necessitam ser definidas para a execução da previsão de demanda. A pesquisa irá comparar os resultados obtidos com o modelo proposto versus os resultados da previsão obtida com o modelo de previsão atualmente adotado pela empresa, de forma a evidenciar a superioridade do modelo.

O capítulo 4 apresenta os modelos e discute os resultados obtidos dentro da metodologia proposta com a utilização das ferramentas selecionadas para a previsão de demanda para o produto estudado.

O capítulo 5 apresenta as conclusões sobre os resultados obtidos, as dificuldades enfrentadas na pesquisa e algumas propostas de continuidade.

1.1. Definição do problema de pesquisa

Especificar uma ferramenta de previsão de demanda de curto prazo para o mercado brasileiro para o produto estação rádio base de uma empresa fabricante de produtos de infra-estrutura de telecomunicações.

1.2. Justificativa da pesquisa

1.2.1. Importância da Previsão em uma Empresa

A previsão de demanda é uma área de atividade considerada como das mais desafiadoras pelos profissionais de logística.

A previsão da demanda a ser atendida no futuro é base para as decisões estratégicas e de planejamento em uma empresa, considerando a análise para as duas estratégias clássicas de produção conhecidas: a puxada e a empurrada. Na produção empurrada o processo é desempenhado com a antecipação do desejo do cliente. Deve-se então dimensionar a quantidade a ser produzida visando atender uma demanda futura com um estoque de produtos acabados adequados a esta demanda. Já na estratégia de produção puxada deve-se dimensionar o nível da capacidade de produção que será disponibilizada para o atendimento dos pedidos. Em ambos os casos, a primeira medida que os gerentes devem tomar é prever qual será a demanda de fornecimento futura (CHOPRA, 2003).

Uma hipótese comumente aceita é que a previsão fornece informações importantes para uma melhor tomada de decisão, em qualquer dos casos.

Já com o foco na gestão de uma cadeia de suprimentos, Chopra (2003) diz que as previsões de demanda futura são essenciais para os processos de decisão e planejamento da cadeia de suprimentos conduzidos pelos gerentes.

Haida *et al* (1994) observaram que erros na previsão, tanto positivos quanto negativos, resultam em um aumento nos custos operacionais. Para a sobrevivência num mercado tão competitivo, as empresas devem eliminar custos desnecessários, pois eles conduzem a prejuízos e reduzem a sua competitividade.

Poucas empresas podem gerir suas fábricas e cadeias de suprimento em consonância com a demanda corrente dos clientes sem alguma forma de planejamento, que requer algum grau de previsão. A importância da previsão é confirmada em estudo conduzido por Ross (2004) para melhoria do desempenho da cadeia de suprimento. Gerentes necessitam criar um modelo do futuro próximo, e então fazer a previsão de demanda, que lhes possibilite configurar da melhor forma possível os recursos da cadeia de suprimentos (ROSS, 2004).

1.2.2. Dificuldades da Previsão de Demanda no Mercado de Telecomunicações

O mercado de telecomunicações tem passado por várias mudanças nos últimos anos. Algumas delas são:

- a evolução tecnológica está mais rápida do que no passado;
- em muitos casos existe mais de uma tecnologia para prover a mesma solução de telecomunicações ao usuário final;
- privatização das operadoras de telecomunicações;
- criação de agências governamentais de controle das operadoras de telecomunicações;
- aumento da competitividade entre as operadoras e os fornecedores.

As mudanças mencionadas geraram problemas para as operadoras e fornecedores do mercado de telecomunicações. Fildes e Kumar (2002) colocam que

o número de empresas geradoras de previsões não foi acompanhado pela correspondente pesquisa acadêmica sobre a previsão para este tipo de mercado.

A característica do mercado de insumos dos equipamentos de infra-estrutura de telecomunicações também nos leva a tentar obter uma alta qualidade na previsão de demanda. As compras são feitas via pedido de compra, onde os fornecedores possuem um alto prazo de atendimento, sendo em média 90 dias¹. Uma boa previsão é essencial para se realizar uma compra com tal antecedência e assim reduzir o risco de falta de material e também não exceder os níveis de estoque das empresas fabricantes destes equipamentos.

1.2.3. Sucesso na Utilização de Redes Neurais em Previsão de Demanda

As redes neurais têm sido utilizadas em várias aplicações na indústria, nos negócios entre outras. As aplicações são principalmente nas áreas de: reconhecimento de padrões; predição e análise financeira; e otimização e controle (WIDROW *et al*, 1994).

Através de um levantamento bibliográfico, Zhang (1998) observa as seguintes características que fazem das redes neurais uma valiosa e atraente técnica para a realização de previsões:

1. Ao contrário dos métodos tradicionais, redes neurais são voltadas aos dados (*data-driven*), é um método auto-adaptativo e necessita de poucas pré-suposições iniciais para a solução do problema em estudo. Assim resolvem problemas cujas soluções clássicas requerem conhecimento que é difícil de especificar;
2. Redes Neurais podem generalizar;
3. Redes Neurais são aproximadoras universais de funções não lineares;
4. Redes Neurais são não lineares.

¹ Dados obtidos da empresa em estudo. Média da soma dos prazos de atendimento do fornecedor, transporte e desembaraço aduaneiro.

Os melhores resultados obtidos, em uma competição de previsão de demanda, foram obtidos por pesquisadores que utilizaram modelos de redes neurais (GERSHENFELD e WEIGEND, 1993). Patrocinada pelo Instituto Santa Fé, eles promoveram uma competição de previsão entre vários pesquisadores para 6 conjuntos de séries temporais, com objetivo de comparar resultados e orientar futuras pesquisas na escolha de um método de previsão que, pelos estudos realizados, mais se adequasse ao seu problema, já que previsão de séries temporais é um problema em várias áreas de aplicação. Alguns atributos contidos nas séries temporais utilizadas são: estacionárias ou não; mais ou menos ruidosas; séries curtas e longas; escalares ou vetoriais; mais ou menos não lineares.

Alguns dos métodos utilizados nesta competição foram: média móvel; modelos AR (auto-regressivos); modelos ARMA (auto-regressivo de média móvel); modelos ARIMA (auto-regressivo integrado de média móvel); e modelos de redes neurais. Eles citam que as redes neurais podem representar uma função espacial com poucos parâmetros e podem prever tanto séries temporais simples quanto complexas.

O uso de Redes Neurais em previsão tem se mostrado muito útil, principalmente quando a série de dados usada tem comportamento não linear, ou existem poucos dados disponíveis.

1.2.4. Motivação do pesquisador

A atuação do pesquisador no planejamento e aquisição de insumos foi um fator importante na decisão do tema da pesquisa. Tentar aliar os interesses financeiros da empresa com baixos estoques e a necessidade de um alto nível de serviço pelo departamento de vendas é o desafio de todo dia.

Conhecendo-se a baixa qualidade de previsão de demanda realizada pelo departamento de vendas, fica caracterizada a necessidade de se estruturar um processo de previsão de demanda, onde a análise com base em dados históricos é o ponto central. Esta análise dos dados do passado até é realizada empiricamente, porém sem nenhum método matemático testado e que realmente possa obter a

confiança das pessoas que participam da definição da previsão de demanda da empresa.

As pessoas de manufatura têm pouca influência na decisão da previsão futura, que orienta a aquisição de insumos para a produção. A manufatura apenas sofre as conseqüências de tal decisão e tenta atender os clientes da forma mais rápida possível.

Considerando estes fatores, o pesquisador busca pesquisar uma ferramenta que possa auxiliar na decisão da demanda futura, bem como uma definição de um processo de previsão de demanda.

1.3. Objetivos da pesquisa

1.3.1. Objetivo Geral

O objetivo desta pesquisa é estruturar e propor a aplicação de um método de previsão de demanda mensal de equipamentos de infra-estrutura de telecomunicações (transceptores de estações rádio base), visando melhorar o planejamento e a tomada de decisão para a fabricação deste tipo de produto.

1.3.2. Objetivos Específicos

A pesquisa tem como objetivos específicos:

- Identificar, na literatura, um método de previsão de demanda adequado à previsão do produto estação rádio base.

- Desenvolver um modelo com o método escolhido que possa ser utilizado para a previsão de demanda para os equipamentos de infra-estrutura estação radio base;
- Selecionar variáveis de entrada, cujas informações sejam disponíveis e que tenham relação com a demanda do produto estudado;
- Propor um modelo de previsão de demanda para curto prazo com base nos dados levantados, comparando os resultados obtidos com a qualidade da previsão realizada atualmente pela empresa.

2. REFERENCIAL TEÓRICO

Este capítulo apresenta os principais conceitos utilizados nesta pesquisa. A pesquisa conceitua previsão de demanda, comentando os fatores que afetam sua qualidade e a participação de uma ferramenta de previsão de demanda em um sistema de previsão de demanda. Ela continua buscando na literatura métodos de previsão de demanda utilizados e suas características.

Após a descrição das características do mercado de telecomunicações (em estudo nesta pesquisa), busca-se um método de previsão de demanda possível de ser aplicado na previsão de demanda para este mercado.

Ao final são apresentados os principais conceitos das redes neurais artificiais, que são aplicadas para previsão de demanda nesta pesquisa.

2.1. Previsão de Demanda

Dentre os principais usos da previsão de demanda, destaca-se o citado por Makridakis (1990), que afirma que a previsão serve para melhorar a qualidade e o valor da decisão. Ele também afirma que a previsão gera consenso entre os membros da direção da empresa sobre os caminhos que a organização deve seguir.

2.2. Fatores que Afetam a Precisão da Previsão de Demanda

A qualidade da previsão de demanda é determinada pela quantidade de mudanças de padrões e relações, e o quanto as pessoas, as organizações e os competidores podem influenciar nos eventos futuros (MAKRIDAKIS, 1990).

Os padrões ou as relações entre variáveis podem mudar com o tempo. Todavia uma suposição crítica que permeia os modelos de previsão de demanda é que padrões e relacionamentos, uma vez identificados e medidos, permanecem constantes. Pessoas podem influenciar eventos futuros. Por exemplo, em um ano de eleição, as pessoas tentarão alterar o ambiente para que os tempos pós-eleição sejam previstos como bons. Similarmente, uma oportunidade de investimento atrativa poderá trazer grandes prejuízos se os concorrentes chegam a esta mesma previsão. O próprio fato de que a previsão de demanda em si mesmo pode influenciar os eventos futuros e assim fazendo mudar o curso dos acontecimentos complica ainda mais a atividade de fazer previsões. Não é mais suficiente predizer com exatidão o que irá acontecer. Gerentes devem também prever o que os competidores irão fazer em resposta a tal predição.

Makridakis (1990) lista outros fatores que afetam a previsão de demanda:

1. *Horizonte de tempo da previsão.* Quanto maior o horizonte de tempo da previsão, maior a chance de mudança de estabelecidos padrões e relações, invalidando a previsão. Neste período, há mais tempo para os competidores reagirem para predizer eventos e influenciar eventos futuros em seu próprio benefício. Assim, menor será a exatidão da previsão quanto maior for o horizonte de tempo desta previsão.
2. *Mudança tecnológica.* Quanto maior a mudança tecnológica dada pela indústria, e *ceteris paribus*, maior será a chance de que os padrões estabelecidos e os relacionamentos irão mudar, e maior a chance de que competidores irão estar aptos a influenciar a indústria através de inovações tecnológicas. Um exemplo claro é a indústria de alta tecnologia, onde prever é quase impossível, enquanto empresas lutam para criar o futuro de acordo com seus próprios conceitos. Trazendo novas tecnologias, eles esperam moldar o futuro em uma determinada direção a fim de alcançar vantagem competitiva. Assim, menor será a exatidão da previsão quanto maior for a taxa de mudança tecnológica.
3. *Barreiras para entrada.* Quanto maiores as barreiras de entrada em um mercado ou cliente, mais impreciso será a previsão, onde competidores podem mudar padrões estabelecidos e relacionamentos em seu próprio benefício.

4. *Disseminação da informação.* Quanto maior for a disseminação da informação, e o restante permanecendo o mesmo, menos valor terá a previsão, já que todos terão a mesma informação e podem chegar às mesmas previsões. Desta forma é impossível obter vantagens de uma previsão. Isto quer dizer que uma previsão exata não necessariamente é útil, já que não é sempre entendida ou aceita, apesar dos exemplos disponíveis.
5. *Elasticidade da demanda.* Quanto maior a elasticidade da demanda, mesmo com outros fatores permanecendo inalterados, menor a exatidão da previsão. Assim, a demanda por artigos de necessidades básicas são mais fáceis de serem previstos comparados com os artigos supérfluos.
6. *Produtos industriais versus produtos para o consumidor final.* A previsão para produtos destinados ao consumidor final, considerando outros fatores constantes, é mais exata do que para os produtos destinados às indústrias. Produtos industriais são vendidos a poucos clientes. Se um destes clientes é perdido, este erro na previsão pode-se tornar uma parcela importante das vendas. Estes clientes são bem informados e podem receber ofertas de descontos de competidores em função do alto valor de venda.

Segundo Chopra (2003), as empresas e os gerentes da cadeia de suprimento devem estar atentos para as seguintes características das previsões:

- As previsões estão quase sempre erradas;
- As previsões de longo prazo são normalmente menos precisas que as de curto prazo;
- As previsões agregadas² são normalmente mais precisas que as previsões desagregadas.

2.3. Sistema de Previsão de Demanda

Um sistema de previsão de demanda é um conjunto de procedimentos de coleta, tratamento e análise de informações que visa gerar uma estimativa das vendas futuras, medidas em unidades de produtos em uma unidade de tempo. As

² Previsão agregada é a soma da previsão de vários produtos (modelos) ou serviços da empresa.

principais informações que devem ser consideradas pelo sistema de previsão são (CORRÊA, 2004):

- Dados históricos de vendas;
- Informações relevantes que expliquem comportamentos atípicos das vendas passadas;
- Dados de variáveis correlacionadas às vendas que ajudem a explicar o comportamento das vendas passadas;
- Situação atual das variáveis que podem afetar o comportamento das vendas no futuro;
- Previsão da situação futura de variáveis que podem afetar o comportamento das vendas no futuro;
- Conhecimento sobre a conjuntura econômica atual e previsão para o futuro;
- Informações de clientes que possam indicar seu comportamento de compra futuro;
- Informações relevantes sobre a atuação de concorrentes que influenciam o comportamento das vendas;
- Informações sobre decisões da área comercial que podem influenciar o comportamento das vendas.

Na Figura 2.1 está mostrada uma estrutura genérica de um sistema de previsão de demanda. A idéia principal é conseguirem dados e informações que ajudem à diretoria a alcançar um consenso sobre previsão da demanda futura. Para tal, a equipe que prepara os dados deve fazer uma análise dos dados do passado e utilizar um método de previsão de demanda que forneça um volume de previsão para o início das discussões com as áreas de vendas. Com base neste volume analisam-se as variáveis relacionadas acima, como por exemplo, conjuntura econômica, dados dos clientes e concorrentes e decisões das áreas comerciais. A equipe então ajusta o volume previsto pelo método ou ferramenta de previsão de demanda considerando estas informações e apresenta estes volumes e considerações para a diretoria que deverá chegar a um consenso do volume prognosticado para o futuro. Este consenso é importante para gerar um comprometimento, cumplicidade na decisão e alinhamento dos departamentos.

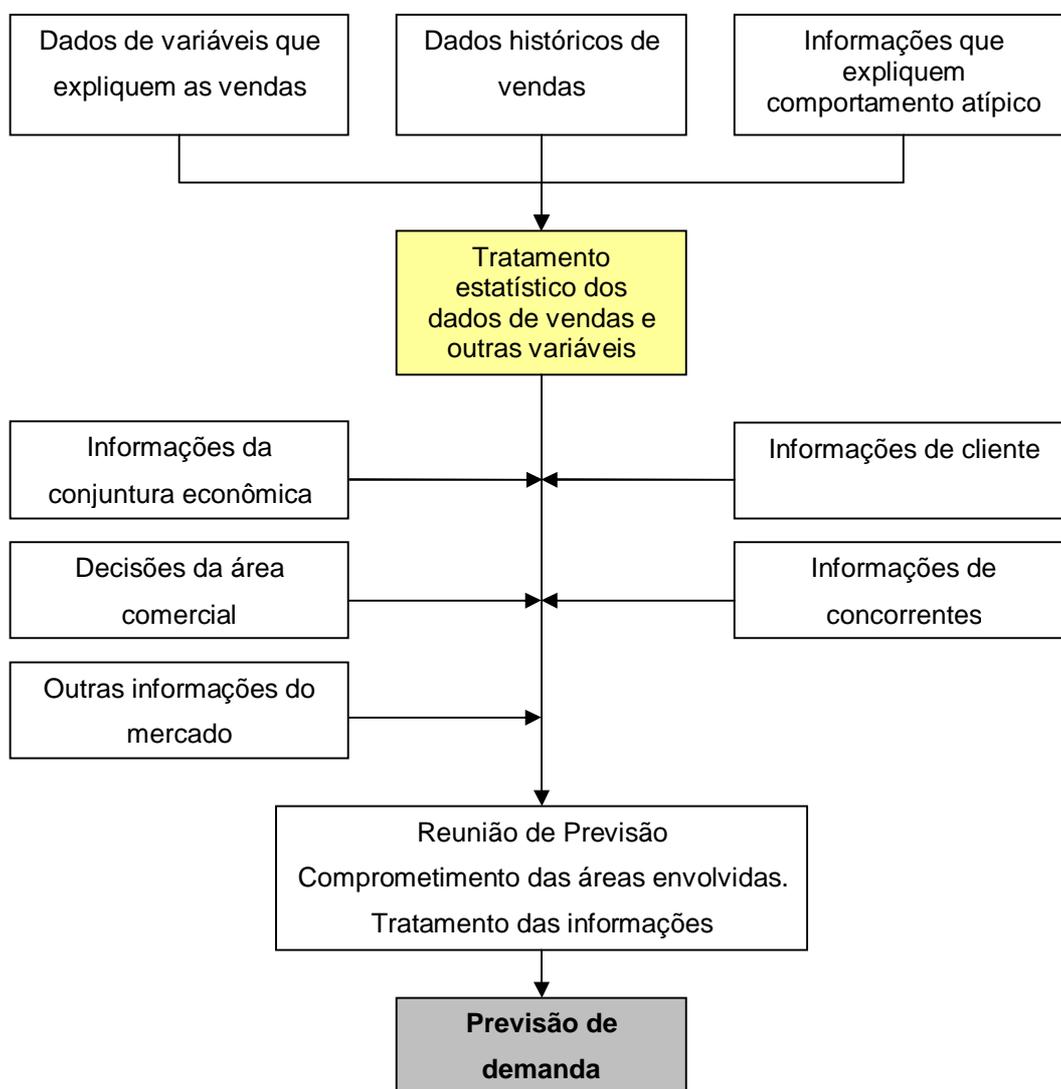


Figura 2.1 – Sistema genérico de previsão de demanda
Fonte: Adaptado de CORRÊA, 2001

2.4. Previsões: Métodos de Tratamento de Informações

Os métodos de previsão de demanda são classificados basicamente em dois tipos: qualitativos e quantitativos.

Os métodos qualitativos são baseados em fatores subjetivos, como opiniões de especialistas, pesquisa de campo, julgamento, intuição ou experiências dos envolvidos, sendo considerados métodos de predição. São especialmente úteis para

criar cenários futuros, de produtos novos ou lançamentos, quando não se tem dados históricos longos, ou estes dados estão incompletos ou imprecisos.

Os métodos quantitativos são os métodos de previsão baseados em séries de dados históricos nas quais se procura, através de análises, identificar padrões de comportamento para que estes sejam projetados para o futuro. Os métodos de previsão quantitativos necessitam de históricos. Como sua base é dada do passado, pressupõe-se que os padrões identificados no passado permanecerão no futuro. Alguns métodos quantitativos de previsão de demanda são:

- Média móvel;
- Suavização exponencial;
- Box-Jenkins;
- Regressão linear;
- Métodos econométricos;
- Redes Neurais Artificiais;
- Lógica Fuzzy;
- entre outros.

A escolha da utilização de métodos quantitativos ou qualitativos na geração de uma previsão depende do horizonte da previsão: quanto maior o horizonte de previsão, menos válida é a hipótese de que os padrões do passado se repetirão no futuro. Isso significa que modelos quantitativos tendem a ser mais adequados a previsões de curto prazo (CORRÊA, 2004).

A previsão combina dados via um modelo matemático para estimar eventos futuros, já a predição estima eventos futuros com base em considerações subjetivas, sem combinações predeterminadas (SILVA, 2003).

As principais componentes de análise de dados históricos temporais são:

1. Tendência: é a orientação geral, para cima ou para baixo, dos dados históricos. Também pode ocorrer a ausência de tendência (orientação em torno de um patamar), chamada de “permanência”.
2. Ciclicidade: são padrões de variação dos dados de uma série que se repetem a cada determinado intervalo de tempo. Ciclicidade anual caracteriza uma sazonalidade.

3. Aleatoriedade: são incertezas quanto ao resultado de um evento estocástico. Popper (1996) conceitua aleatoriedade como a ausência de regularidades. Mas deve-se ter cuidado, pois talvez uma seqüência não possua teste conhecido que exclua a presença de todas as regularidades. Daí diz-se que ela é aleatória, apesar de eventualmente poder não ser.

Da literatura buscaram-se algumas características de alguns métodos quantitativos de previsão de demanda. Um resumo das características encontradas está representado na Tabela 2.1.

Tabela 2.1 – Principais características dos métodos de previsão de demanda quantitativos

Método de previsão	Característica e utilização
Média móvel	Demanda apresenta comportamento estável (TUBINO, 2000) Uso se o produto não for relevante (TUBINO, 2000) Modelo simples (CORREA <i>et al</i> , 2001) Reduz o impacto da aleatoriedade dos dados (MAKRIDAKIS, 1977)
Suavizamento exponencial	Pesos maiores às demandas mais recentes (RITZMAN, 2004) Possui variações para inclusão de padrões de tendência e sazonalidade (RITZMAN, 2004 e MAKRIDAKIS, 1977)
Box-Jenkins	Considera que a série é gerada por processo estocástico e o método busca identificar este gerador. (MONTANES <i>et al</i> , 2002) Considera tendência e sazonalidade (MONTANES <i>et al</i> , 2002)
Regressão Linear	Identifica o efeito da variável de previsão sobre a demanda do produto em análise (TUBINO, 2000) Usa-se quando os dados históricos são disponíveis e as relações entre o fator a ser previsto e outros fatores são conhecidos (RITZMAN, 2004)
Modelos Econométricos	Melhor representação da realidade, já que captura a complexa inter-relação entre fatores que devem ser conhecidos. (MAKRIDAKIS, 1977) Usado para planejamento de longo prazo (MAKRIDAKIS, 1977)
Redes Neurais	Consegue representar modelos não lineares (RAO, 2002; SILVA, 2003) Aproximador universal de função (HILL <i>et al</i> , 1996) Necessita menor extensão de dados observados (HILL <i>et al</i> , 1996)

Fonte: do autor

A vantagem teórica das redes neurais como uma ferramenta de previsão de demanda é que as relações entre as variáveis não necessitam ser especificadas, já que o método estabelece estas relações através do processo de aprendizado. Elas são especialmente valiosas quando as entradas são altamente correlacionadas, não conhecidas ou os sistemas são não lineares (KUO e REITSCH, 1995).

2.5. Previsão de Demanda para o Mercado de Telecomunicações

A indústria de telecomunicações está enfrentando mudanças tecnológicas e regulatórias constantes. Enquanto a distância entre operadoras de curta e longa distância está cada vez menor, novos competidores das indústrias de TV a cabo, elétricas e gás têm aparecido. Como a indústria se tornou mais competitiva, consumidores conseguem menores preços, o que tem estimulado a demanda de serviços de telecomunicações em níveis sem precedentes.

A Tabela 2.2 mostra várias tecnologias implantadas no Brasil, agrupadas em serviços de voz e dados. Cada uma delas com suas vantagens, desvantagens e aplicações específicas que não serão analisados nesta dissertação. Isto evidencia a grande variedade de tecnologias disponíveis para as operadoras comprarem e instalarem, o que aumenta o desafio do profissional que realiza a previsão de demanda nas empresas fornecedoras destes tipos de equipamentos.

Tabela 2.2 – Algumas tecnologias disponíveis no Brasil por tipo de serviço

Tipo de serviço	Tecnologia
Voz	Telefonia fixa (cabo)
	Telefonia fixa (WLL)
	Telefonia móvel primeira geração (AMPS)
	Telefonia móvel segunda geração (TDMA, CDMA, GSM)
	Telefonia móvel terceira geração (WCDMA)
	Voz sobre IP (VoIP)
Dados	Linha discada
	Linha ADSL
	Dados via satélite
	WIMAX (dados via rádio em fase de regulamentação no Brasil)
	WLAN (dados via rádio, conhecidos como <i>Wi-Fi</i>)
	Fibra ótica (FTTB)

Fonte: do autor

Essas mudanças e novas tecnologias no cenário de equipamentos de telecomunicações criaram a necessidade do desenvolvimento de novas técnicas de previsão de demanda. Métodos tradicionais de previsão de demanda como séries temporais e modelos econométricos têm se tornado menos precisos porque o comportamento do mercado não possui a mesma relação entre o passado e o presente e há necessidade que a confiabilidade seja alta. A realidade do mercado de telecomunicações não atende estes requisitos. O planejador de demanda necessita incorporar a dinâmica da indústria de telecomunicações no seu modelo de previsão (OZTURKMEN, 2000).

O conceito principal dos modelos de previsão de demanda em telecomunicações é simples: o uso esperado do usuário final determina a demanda de acesso e estes, então, determinam a necessidade de equipamentos de infraestrutura (FILDES e KUMAR, 2002).

No contexto do mercado de telecomunicações atual, devemos considerar as operadoras de linha fixa, as operadoras de linhas móveis e também as operadoras de TV a cabo. Estão ocorrendo várias fusões no mercado e os serviços estão se fundindo, sendo oferecidos por todas estas operadoras. Atualmente a fronteira entre televisão, o uso do computador e de telecomunicações está aos poucos desaparecendo em função do aumento do uso da internet, os serviços oferecidos e as caixas inteligentes acopladas à televisão para prover algo semelhante do que os computadores e serviços de telecomunicações podem oferecer.

Fildes e Kumar (2002) ressaltam que os fornecedores de equipamentos às operadoras (como a empresa estudada na pesquisa) enfrentam uma dificuldade maior. Enquanto a demanda por um produto específico está aumentando, seus clientes potenciais são poucos. Isto nos leva ao fato do mercado de telecomunicações estar sofrendo várias fusões de empresas, o que faz com que o número de clientes diminua.

Além das várias tecnologias existentes, as compras de equipamentos de infraestrutura de telecomunicações no Brasil são feitas através de editais de oferta. A operadora coloca neste edital qual tecnologia deseja instalar, os requisitos técnicos, capacidade desejada e nível de serviço. Com base nestas informações as empresas fornecedoras elaboram uma proposta comercial e técnica contendo a descrição do equipamento utilizado para atender a necessidade do cliente, bem como o preço para esta venda. Com as ofertas de vários fornecedores em mãos, a

operadora faz a escolha do fornecedor, com base em critérios variados. A experiência mostra que atualmente o item de maior importância para a escolha do fornecedor, após o atendimento dos requisitos técnicos, é o preço da oferta. Como os preços não são divulgados anteriormente, fica difícil prever qual será a empresa ganhadora da oferta.

Prever demanda em mercados de proposta é uma das atividades mais desanimadoras enfrentadas pelos planejadores de demanda. A dificuldade em prever ofertas aparece porque ela envolve um alto grau de julgamento na ausência de uma forma familiar de gerenciar incertezas (LATTA, 2002).

Ainda segundo Latta (2002), proposta ou oferta é um acordo para comprar (vender) uma quantidade específica de produtos ou serviços a um preço específico durante um período de tempo especificado. Em função das restrições da oferta, ela resulta na escolha e eliminação de um produto para um usuário final ou consumidor, e revendedores são classificados em papéis como único fornecedor, fornecedor preferencial, fornecedor não preferencial ou não fornecedor.

A incerteza na previsão ocorre quando o vendedor não conhece os seguintes parâmetros (LATTA, 2002):

- o valor da oferta para o comprador;
- o lucro que pode ser atingido com a oferta; e
- o valor da oferta dos concorrentes.

Em função da incerteza envolvida, o sucesso da oferta é difícil de prever. Assim ofertas não envolvem conhecimento racional ou histórico de vendas, mas é resultado de julgamento, senso comum e intuição.

O mercado de consumidor final e o industrial são diferentes. Por definição, as empresas que atuam no mercado de consumidor final procuram consumidores, famílias e lares que compram para consumo pessoal. Empresas do mercado industrial procuram organizações que adquirem bens (e/ou serviços) para usar em uma produção ou para ofertar outros produtos (ou serviços). Em geral, as diferenças entre estes dois tipos de empresas são: o mercado industrial tem menos compradores que o mercado de consumidor final; mercado industrial reflete uma relação próxima entre cliente e vendedor; mercado industrial tem demanda inelástica no curto prazo, mas no longo prazo, a demanda do mercado industrial pode flutuar drasticamente como um resultado de uma leve flutuação na demanda do usuário final. Isto se traduz em práticas únicas de negócio para cada tipo de mercado.

2.6. O Mercado de Telefonia Celular no Brasil

Após a introdução do Serviço Móvel Pessoal (SMP) em 2000, quando foram criadas 3 Regiões, que coincidem com as da Telefonia Fixa e permitida a troca de controle acionário das operadoras, deu-se início ao processo que resultou nas oito operadoras de telefonia celular existentes hoje no país.

Para prestar serviço celular no Brasil é necessário possuir uma autorização de Serviço Móvel Pessoal (SMP). O SMP dividiu o Brasil em 3 regiões como apresentado na Figura 2.2. Todas as operadoras de Celular no Brasil possuem autorizações para Serviço Móvel Pessoal (SMP), tendo migrado para SMP em várias áreas onde possuíam originalmente permissões para o Serviço Móvel Celular (SMC). Suas áreas de prestação de serviço correspondem portanto, em muitos casos, às áreas de prestação de serviço definidas pelo SMC.

Existem ainda alguns casos especiais correspondentes à área de prestação de serviços das operadoras de Banda A antes da privatização.



Figura 2.2 – Mapa das áreas de prestação de serviço celular
Fonte: TELECO, 2008.

Com a licitação do SMP de Set/07 o Brasil passou a ter 4 operadoras de celular em todo o país e cinco na Amazônia, Nordeste e interior de São Paulo. Na

Tabela 2.3 e Tabela 2.4 estão listadas as operadoras que prestam serviço celular no Brasil.

Tabela 2.3 – Lista das operadoras de prestação de serviço celular

ÁREA SMP	ÁREA SMC	OPERADORA POR ÁREA E BANDA				
		Banda A	Banda B	Banda D	Banda E	Outras
I	3 (RJ, ES)	Vivo	Claro	Oi	TIM	-
	8 (Amazônia)	Amazônia	Vivo			Claro *
	4 (MG)	Telemig	TIM		Claro **	-
	9 (BA, SE)	Vivo	TIM		Claro	-
	10 (Nordeste)	TIM	Claro		-	Vivo *
II	5 (PR, SC)	TIM	Vivo	Claro	Brasil Telecom	**
	6 (Rio G Sul)	Vivo	Claro	TIM		
	7 (C. Oeste)					
III	1 (SP Metro)	Vivo	Claro	TIM	Unicel *	Oi *
	2 (SP Interior)				Oi *	-

* ainda não entraram em operação.

** Casos Especiais (Tabela 2.4)

Fonte: TELECO, 2008.

Tabela 2.4 – Casos especiais de telefonia celular

Banda	Operadora	Cidades
A	CTBC Cel.	Cidades de Minas Gerais, São Paulo, M. Grosso do Sul e Goiás.
	Sercomtel Celular	Londrina e Tamarana, PR
	TIM	Pelotas e região RGS.
D	TIM	Londrina e Tamarana, PR.
E	Telemig Celular	Cidades de Minas Gerais correspondentes à área da CTBC Celular em MG
Outra	Options	Cidades atendidas pela CTBC em Mato G Sul

Fonte: TELECO, 2008.

A Tabela 2.5 mostra a quantidade de municípios e o percentual da população cobertos pelo serviço celular, agrupado por operadora. O número de assinantes de celular vem aumentando todos os anos. A Figura 2.3 mostra o comportamento desta evolução. Percebe-se que as adesões aumentaram de 2004 até hoje. O Brasil, com seus 122 milhões de assinantes de celular, é o quinto país com maior número de assinantes do mundo. Os países com mais assinantes que o Brasil são (em ordem

crescente): Rússia, Índia, Estados Unidos e China. Este último possui 547 milhões de assinantes de celular (em Dezembro de 2007).

Tabela 2.5 – Municípios e percentual da população atendidos

Operadora	Municípios	% da população
Tim	2668	87
Vivo	2323	67
Claro	2359	78
Oi	896	39
Amazônia	137	6
Telemig	430	9
CTBC	84	1
Sercomtel	2	<1
Brasil Telecom	822	21

Fonte: TELECO, 2008

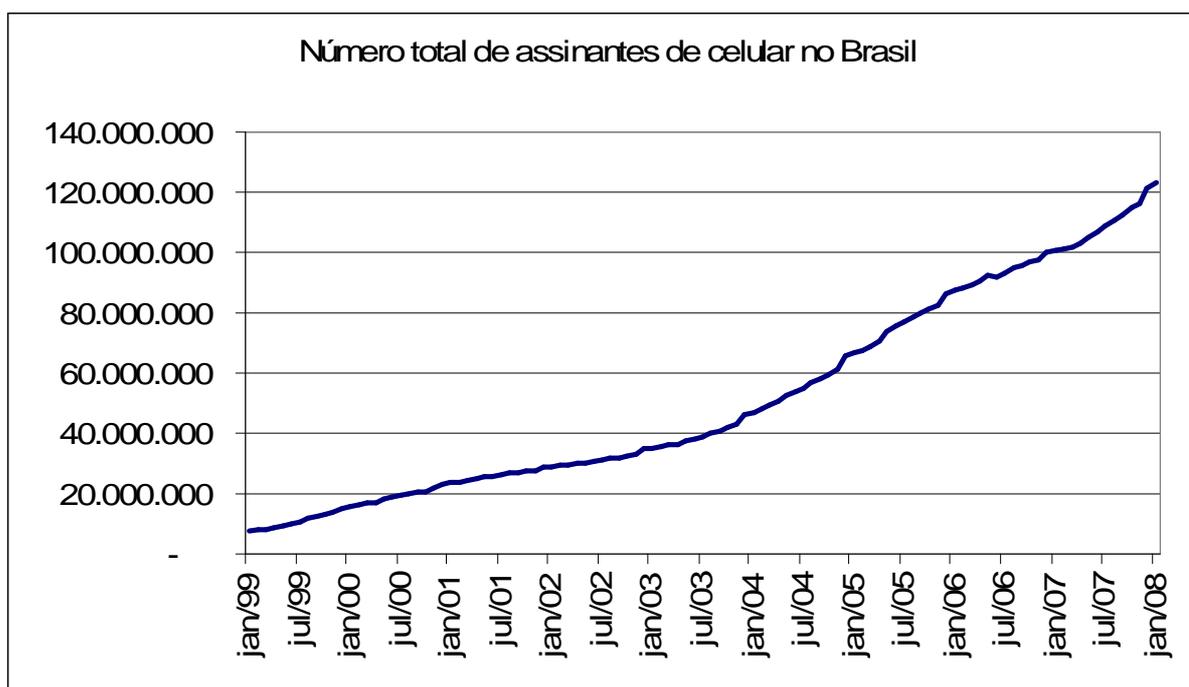


Figura 2.3 – Número total de assinantes de celular no Brasil
Fonte: Adaptado de TELECO, 2008.

Quanto à tecnologia, o GSM firmou-se como a tecnologia mais usada, atingindo a 79,7% de mercado, seguida pelo CDMA com 16,4%, que é utilizado somente pela Vivo. O TDMA vem reduzindo sua participação ao longo do tempo e

terminou o ano com 3,9%. Em janeiro de 2008, a participação de mercado por tecnologia era a mostrada na Figura 2.4.

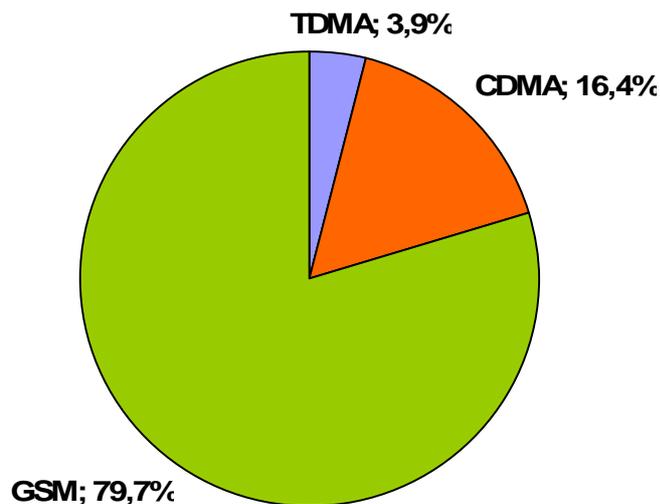


Figura 2.4 – Participação de mercado por tecnologia celular
Fonte: Adaptado de TELECO, 2008.

2.7. Características da Demanda da Estação Rádio Base de uma Empresa Fornecedora de Equipamentos de Infra-estrutura de Telecomunicações

Dentre os fatores que afetam a exatidão da previsão de demanda listada por MAKRIDAKIS (1990), percebe-se que a empresa em estudo é afetada fortemente pelos fatores: barreiras na entrada; elasticidade da demanda e produtos industriais. A mudança tecnológica listada por Makridakis também afeta a precisão da previsão da empresa, mas este fator tem uma influência menor quando comparados à indústria de computadores ou aparelhos celulares, onde o ciclo de vida é bem menor ao dos equipamentos de infra-estrutura. A empresa possui uma grande dificuldade na elaboração de uma previsão de curto e médio prazo mais exata devido à grande incerteza nos eventos futuros no curto prazo.

Para analisar a característica da demanda da empresa fornecedora de equipamentos de infra-estrutura de telecomunicações foi levantado o histórico de fornecimento de um produto. O produto escolhido foi transceptor (TRX) de telefonia celular GSM, presente em todas as estações rádio base (ERB). O transceptor é o módulo responsável pela comunicação entre a rede de telecomunicações da empresa e seus assinantes do serviço de telefonia GSM. O sinal de rádio frequência é transmitido do TRX para a antena e então captado pelo aparelho celular. No sentido inverso, o celular transmite o sinal, que é captado pela antena da ERB. Este sinal é recebido pelo TRX, que o decodifica e transmite para a rede de telecomunicações da operadora de telefonia celular.

Este produto possui um consumo mensal, cujos volumes de fornecimento reais de ERB e TRX estão mostrados na Figura 2.5 e Figura 2.6. Os dados estão normalizados entre -1 e 1, para proteger os números da empresa.

É uma demanda que possui uma flutuação grande e nos últimos meses apresenta um consumo baixo, quando compararmos aos volumes de 2003 a 2005. Esta empresa já realizou grandes fornecimentos em função de ofertas ganhas no passado para a instalação destes equipamentos para determinadas operadoras de telefonia celular em determinadas regiões geográficas do Brasil. Agora as redes de telefonia já estão instaladas e demanda ocorre em função de ampliações da rede para atendimento de determinadas regiões ainda não atendidas e também para aumentar a capacidade de conversação de regiões de alta demanda de conversação. Estas ampliações também ocorrem de forma inconstante, pois depende da evolução dos assinantes da operadora e orçamento para investimento. Há uma grande incerteza do volume e periodicidade desta demanda. O desafio da empresa é conseguir prever esta demanda para evitar o risco de *stock out* (não atendimento da demanda do cliente).

A empresa estudada utiliza a força de vendas como fonte geradora de Previsão de demanda de vendas. Esta fonte é a mais comumente utilizada pelas empresas conforme dados de Armstrong (2001).

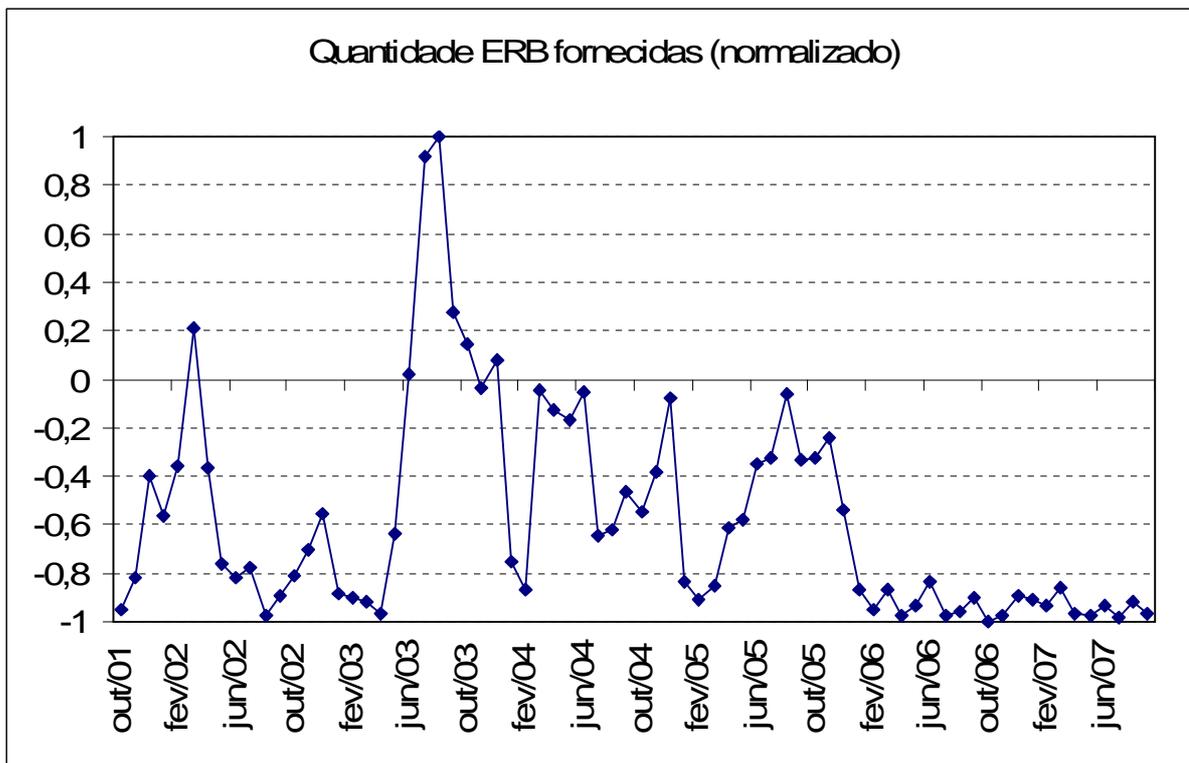


Figura 2.5 – Histórico da demanda da ERB GSM
 Fonte: Empresa de equipamentos de telecomunicações.

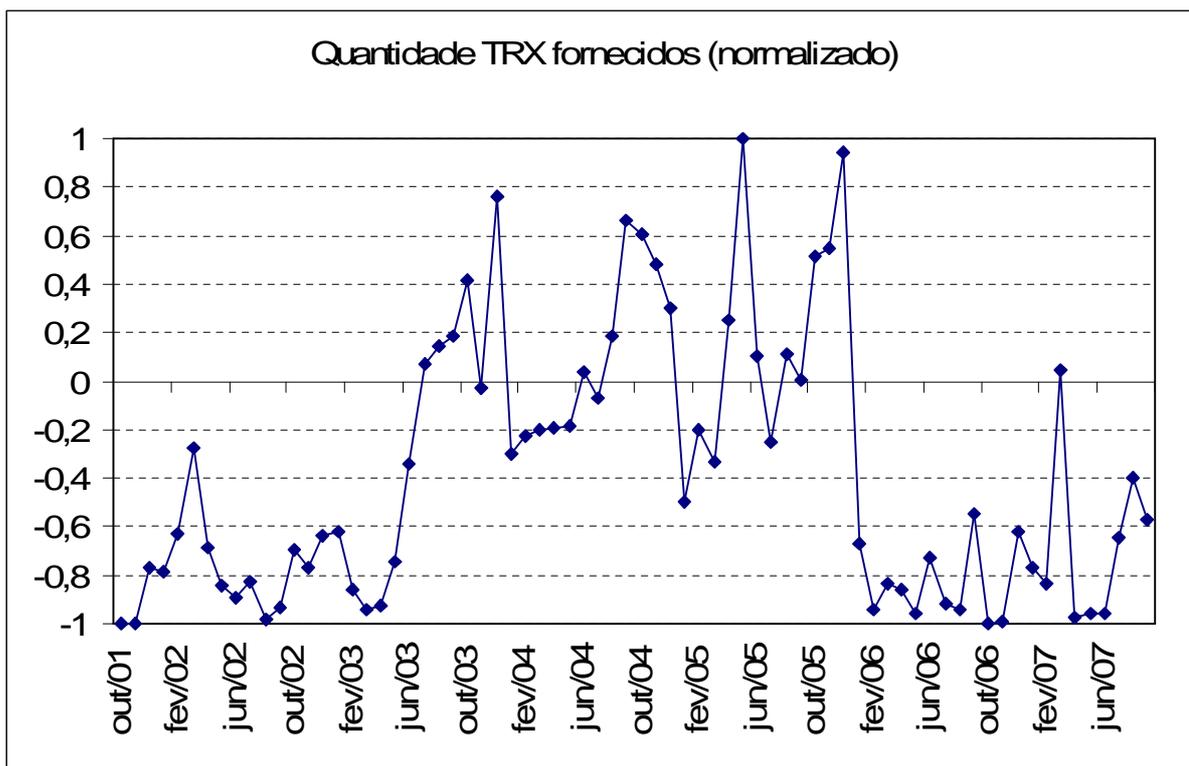


Figura 2.6 – Histórico da demanda de Transceptores GSM
 Fonte: Empresa de equipamentos de telecomunicações.

2.8. Método que Poderia ser Aplicada para a Previsão de Demanda

Com uma análise nas características do mercado de telecomunicações e a demanda real fornecida pela empresa de equipamentos de telecomunicações, observa-se que o produto ERB / TRX não possui uma tendência e sazonalidade evidente. A Figura 2.5 e Figura 2.6 mostram o comportamento dos fornecimentos de ERB e TRX normalizados, para proteger os dados da empresa. Isto torna ineficiente o uso das técnicas estatísticas tradicionais. Para uma solução deste problema de previsão, é proposto o uso de redes neurais. A rede neural tem a capacidade de aprender o padrão de comportamento desta demanda, resultando na melhora da qualidade da previsão.

Os métodos preditivos de séries temporais são deficientes com componentes ruidosos e não lineares que são comuns em situações do mundo real (SHONEBURG, 1990 apud CORTEZ, 2002).

Uma ERB é fornecida para localidades novas. Um TRX pode tanto ser fornecido para localidades novas (juntamente com as ERB), bem como para localidades onde já há equipamento (ERB) instalado. Neste caso a necessidade da operadora é uma ampliação de capacidade de chamadas simultâneas desta localidade. Não se pode instalar os transceptores em equipamentos de empresas concorrentes. A compatibilidade existe apenas na interface aérea (tecnologia GSM) e não nos módulos TRX, que são de desenvolvimento específico de cada empresa.

Na presente pesquisa será realizada a previsão de demanda de fornecimento de TRX (transceptores), já que ele é influenciado pelo aumento de assinantes e demanda por ligações telefônicas.

2.9. Redes Neurais Artificiais

O estudo das Redes Neurais Artificiais (RNAs) é parte de uma área de estudo denominada de Inteligência Artificial e as RNA têm sido aplicadas para auxiliar a interpretação de problemas em diversas áreas do conhecimento.

Nesta seção serão abordados os conceitos básicos de uma RNA, sua evolução nas últimas décadas, o modelo de rede Perceptron de Múltiplas Camadas (MLP) e o modelo Função de Base Radial (RBF) que são utilizados nesta pesquisa, e as características de arquitetura das redes neurais necessárias para a construção dos modelos de previsão.

2.9.1. Conceituação de redes neurais

Zhang (2004) define uma RNA como um modelo computacional para o processamento de informação e identificação de padrões. Uma RNA é uma rede de muitas unidades computacionais simples chamadas neurônios, que são interconectadas e organizadas em camadas. Cada neurônio executa uma tarefa simples de processar a informação convertendo entradas recebidas em saídas processadas. Através da conexão de arcos entre estes neurônios, um conhecimento pode ser gerado e armazenado em função da forte relação entre os nós.

Haykin (2001) compara o cérebro humano a um computador, considerando o cérebro como um sistema de processamento de informações altamente complexo, não linear, e paralelo:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ele se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.”

Zhang (2004) diz que apesar dos modelos RNA usadas serem mais simples do que os sistemas neurais reais, elas são capazes de executar uma variedade de tarefas e alcançar bons resultados.

2.9.2. Evolução da teoria sobre RNA

A evolução teórica das RNA está baseada nos trabalhos de Haykin (2001) e Hagan (1996).

Os primeiros estudos sobre redes neurais artificiais vieram do campo da psiquiatria e da neuro-anatomia através de Warren McCulloch que associado ao matemático Walter Pitts publicaram, em 1943, o artigo pioneiro sobre redes de neurônios artificiais comparando o processo de comunicação das células nervosas com a transmissão de sinais elétricos entre elas e criando o primeiro modelo matemático de neurônio artificial. Eles mostram que um neurônio artificial pode, a princípio, computar qualquer função aritmética ou lógica. Este trabalho é reconhecido como a origem do campo das redes neurais.

Em 1958, Frank Rosenblatt desenvolveu uma rede perceptron para reconhecimento de padrões que colocou as RNA em evidência nas pesquisas científicas. Foi provado mais tarde que uma rede perceptron básica só resolvia uma gama limitada de problemas. Nesta mesma época, Bernard Widrow e Ted Hoff (1960) apresentaram um novo algoritmo de aprendizado usado para treinar redes lineares adaptativas, mas com limitações similares às de Rosenblatt. Em 1969 Marvin Minsky e Seymour Papert provaram que as RNAs, até então existentes, não resolviam um simples problema de 'ou exclusivo'. Essas limitações fizeram reduzir o interesse nas pesquisas sobre RNA durante quase duas décadas, pois se acreditava que não haveria solução para fazê-las funcionar.

Alguns trabalhos continuaram durante os anos 70 e um importante trabalho surgiu em 1972 de Teuvo Kohonen (1972) e James Anderson (1972), que independentemente, desenvolveram novas redes neurais que poderiam atuar como memória. Stephen Grossberg (1980) também investigou redes auto-organizáveis.

A partir de 1980, com o aparecimento de computadores mais poderosos, as pesquisas e aplicações de RNAs retomaram um crescimento acelerado com o surgimento de vários tipos de redes com aplicações em vários campos do conhecimento.

Dois novos conceitos são responsáveis pelo renascimento das redes neurais. O primeiro de John Hopfield, em 1982, foi o uso de mecanismos estatísticos para explicar a operação de certa classe de rede recorrente, que poderia ser utilizada como uma memória associativa. O segundo desenvolvimento foi o algoritmo de *backpropagation* para treinamento de redes perceptron de múltiplas camadas, cuja publicação principal é de David Rumelhart e James McClelland em 1986. Este algoritmo resolveu o problema do “ou-exclusivo” apresentado por Minsky e Papert em 1969.

Após esta descoberta, milhares de artigos têm sido escritos e as redes neurais vêm sendo usadas em várias aplicações.

2.9.3. Elementos de uma rede neural

2.9.3.1. Neurônio biológico

O sistema nervoso é formado por um conjunto extremamente complexo de neurônios. Nos neurônios a comunicação é realizada através de impulsos, quando um impulso é recebido, o neurônio o processa, e passado um limite de ação, dispara um segundo impulso que produz uma substância neuro-transmissora o qual flui do corpo celular para o axônio (que por sua vez pode ou não estar conectado a um dendrito de outra célula). O neurônio que transmite o pulso pode controlar a frequência de pulsos aumentando ou diminuindo a polaridade na membrana pós sináptica. Eles têm um papel essencial na determinação do funcionamento, comportamento e do raciocínio do ser humano. Ao contrário das redes neurais artificiais, redes neurais naturais não transmitem sinais negativos, sua ativação é

medida pela frequência com que emite pulsos, frequência esta de pulsos contínuos e positivos. As redes naturais não são uniformes como as redes artificiais, e apresentam uniformidade apenas em alguns pontos do organismo. Seus pulsos não são síncronos ou assíncronos, devido ao fato de não serem contínuos, o que a difere de redes artificiais.

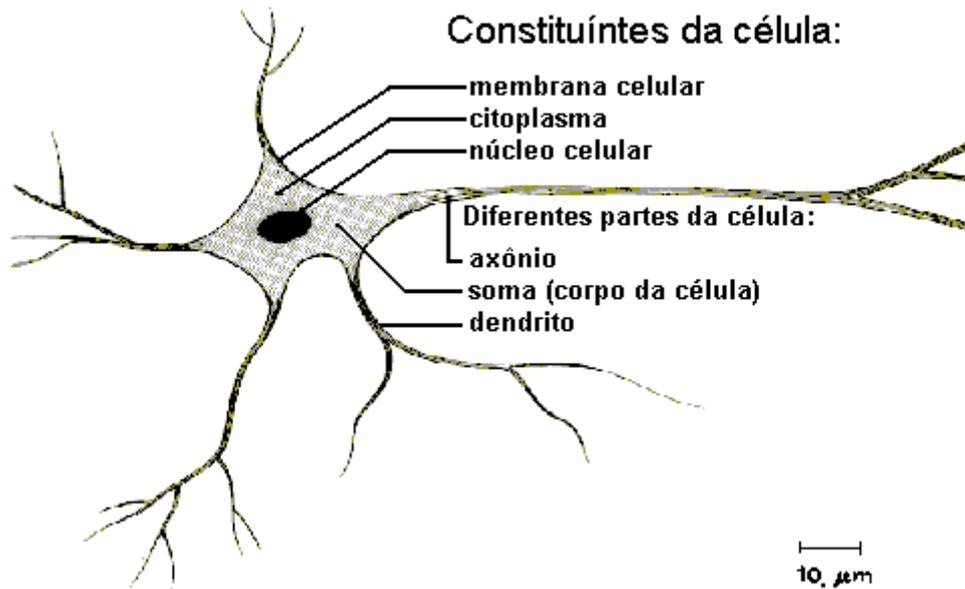


Figura 2.7 – Estrutura geral do neurônio genérico

Fonte: <http://www.din.uem.br/ia/neurais/#neural> – 10/04/2007

Os principais componentes dos neurônios são:

- Os dendritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios;
- O corpo de neurônio, também chamado de soma, que é responsável por coletar e combinar informações vindas de outros neurônios;
- E finalmente o axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.

2.9.3.2. Neurônio artificial

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. O diagrama em blocos da Figura 2.8 mostra o modelo de um neurônio artificial, que forma a base para o projeto de redes neurais artificiais. Aqui nós identificamos três elementos básicos (HAYKIN, 2001):

1. Conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} , aonde k representa o neurônio em questão e j representa ao terminal da entrada da sinapse à qual o peso se refere.
2. Somador para somar os sinais de entrada, ponderados pelas respectivas sinapses de neurônio. Constitui um combinador linear.
3. Função de ativação para restringir a amplitude de saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

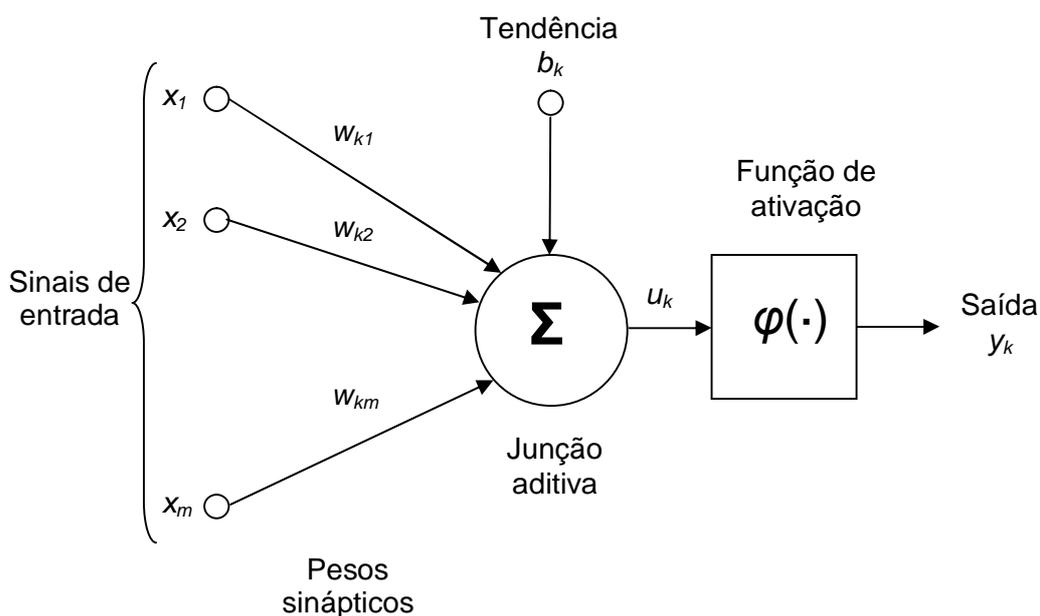


Figura 2.8 – Modelo de um neurônio artificial
Fonte: KAYKIN, 2001

No modelo neural da Figura 2.8 também é apresentado uma tendência (*bias*) aplicado externamente, representado por b_k . A tendência b_k é como um peso e tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação.

Em termos matemáticos, podemos descrever um neurônio k escrevendo o seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

e

$$y_k = j(u_k + b_k) \quad (2.2)$$

onde:

x_j são os sinais de entrada;

w_{kj} são os pesos sinápticos do neurônio k ;

u_k é a saída do combinador linear devido aos sinais de entrada;

b_k é a tendência;

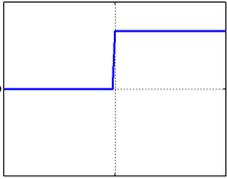
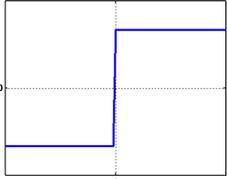
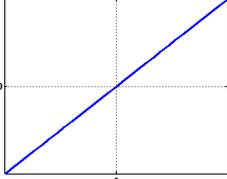
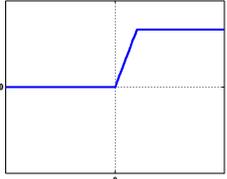
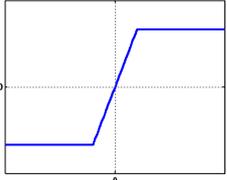
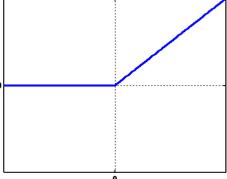
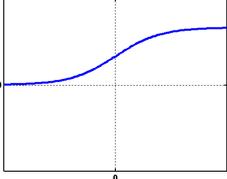
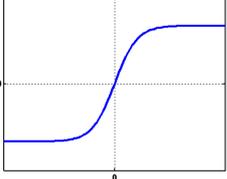
$\varphi(\bullet)$ é a função de ativação;

y_k é o sinal de saída do neurônio.

2.9.3.3. Função de ativação

A função de ativação define a saída de um neurônio em termos do campo local induzido v . Uma função de ativação é escolhida para satisfazer algumas especificações do problema que o neurônio está tentando resolver. Uma função de ativação pode ser linear ou não linear. Na Tabela 2.6 são mostrados vários exemplos de funções de ativação existentes. As mais utilizadas são a degrau, linear e log-sigmóide (HAGAN, 1996). O projetista de uma RNA pode, se desejar, definir uma função de ativação específica para seu problema.

Tabela 2.6 – Exemplos de função de ativação

Nome	Relação Entrada/Saída	Gráfico
Degrau	$y = 0 \quad v < 0$ $y = 1 \quad v \geq 0$	
Degrau simétrica	$y = -1 \quad v < 0$ $y = 1 \quad v \geq 0$	
Linear	$y = v$	
Linear por partes	$y = 0 \quad v < 0$ $y = v \quad 0 \leq v \leq 1$ $y = 1 \quad v > 1$	
Linear por partes simétrica	$y = -1 \quad v < -1$ $y = v \quad -1 \leq v \leq 1$ $y = 1 \quad v > 1$	
Linear positiva	$y = 0 \quad v < 0$ $y = v \quad v \geq 0$	
Logística	$y = \frac{1}{1 + e^{-v}}$	
Sigmóide tangente hiperbólica	$y = \frac{e^v - e^{-v}}{e^v + e^{-v}}$	

Fonte: HAGAN, 1996

2.9.3.4. Arquiteturas da rede

As redes neurais são compostas de vários neurônios, interligados entre si. Em função da forma em que os neurônios são interligados, as redes são classificadas em (HAYKIN, 2001):

- Redes feedforward de camada única;
- Redes feedforward de múltiplas camadas;
- Redes recorrentes.

Em uma rede neural em camadas, os neurônios são organizados em camadas. Numa RNA de camada única (ilustrado na Figura 2.9) temos uma camada de entrada, que são as entradas para os neurônios da camada de saída.

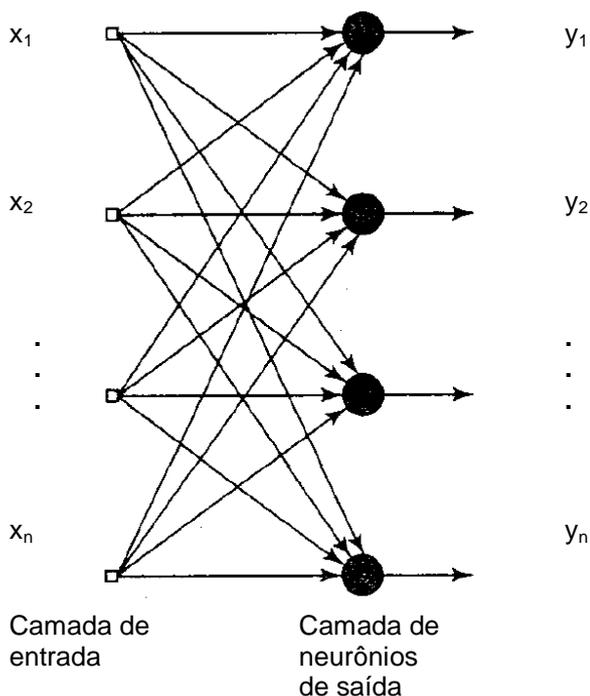


Figura 2.9 – Exemplo de rede feedforward de camada única
Fonte: HAYKIN, 2001

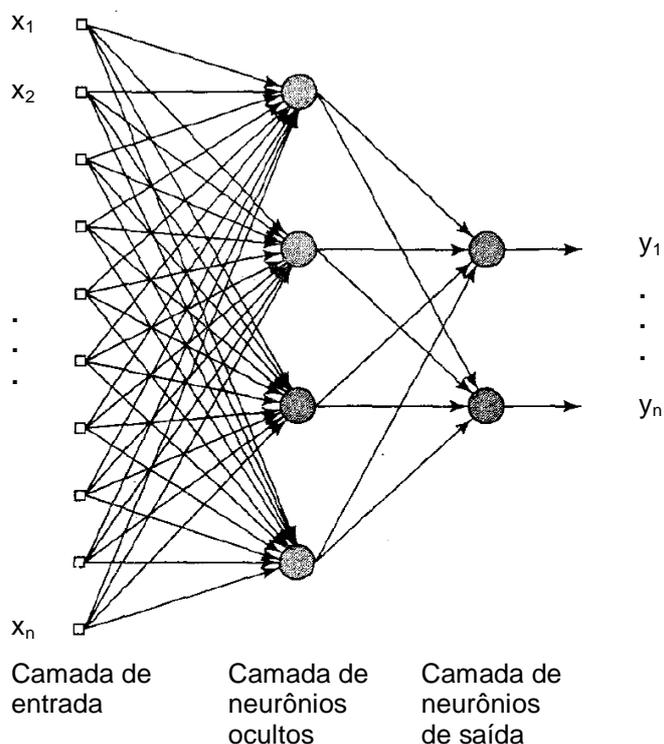


Figura 2.10 – Exemplo de rede feedforward de múltiplas camadas
Fonte: HAYKIN, 2001

Já numa rede de múltiplas camadas, ilustrada na Figura 2.10, existem camadas de neurônios ocultas, além das camadas de entrada e saída (HAYKIN, 2001).

As redes recorrentes se diferenciam das redes *feedforward* quando existe pelo menos uma realimentação na rede (*feedback loop*). Isto significa que algumas saídas estão ligadas às entradas. Nestas redes estão presentes elementos de atraso, o que faz com que a rede apresente um comportamento dinâmico não linear. Redes de Elman e de Hopfield são exemplos de RNA recorrentes (BISHOP, 1995).

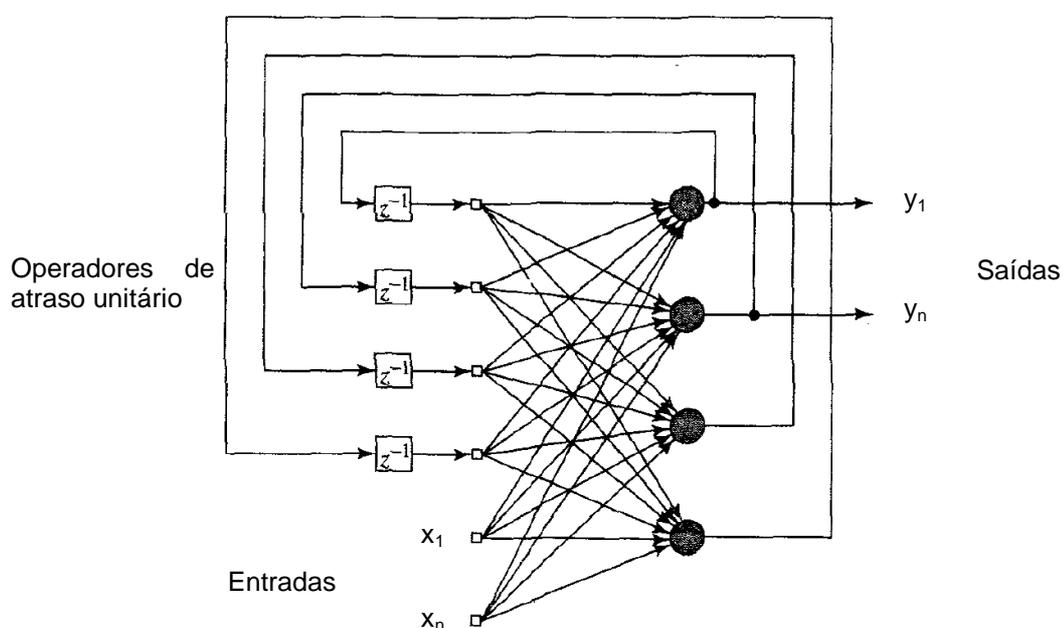


Figura 2.11 – Exemplo de rede recorrente
 Fonte: HAYKIN, 2001

A arquitetura da rede é muito importante para as capacidades de convergência e generalização das RNA. Existem várias técnicas que tentam encontrar a arquitetura ideal, porém nenhuma apresenta resultados convincentes para todas as aplicações (HERTZ, 1991 apud SILVA, 2003). A arquitetura ideal das RNA's continua sendo determinada principalmente pela experimentação e pela experiência do projetista (ABELÉM *et al* 1995 apud SILVA, 2003).

2.9.4. Aprendizagem

A capacidade de aprendizado é uma das características mais importantes das RNA. É a habilidade de adaptar-se, ajustar-se a partir de seu ambiente, de acordo com as regras pré-estabelecidas, melhorando seu desempenho ao longo do tempo. O treinamento é feito através de um processo iterativo de ajustes aplicados a seus pesos e tendência. O processo consiste basicamente na rede ser estimulada por um

ambiente, sofrer modificações nos seus parâmetros livres como resultado desta estimulação e finalmente responder de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna (HAYKIN, 2001). O conhecimento aprendido pela rede é armazenado nos arcos e nós na forma de pesos dos arcos e tendência dos nós (ZHANG, 1998).

Na Figura 2.12 é apresentada algumas das regras básicas e os paradigmas de aprendizagem. As regras de aprendizagem representam o algoritmo de aprendizagem, ou seja, as regras para a solução de um problema de aprendizagem. Não há um processo de aprendizagem único e cada ferramenta apresenta vantagens específicas. Elas diferem na forma do ajuste do peso sináptico. O paradigma de aprendizagem se refere a um modelo do ambiente no qual a rede neural opera.

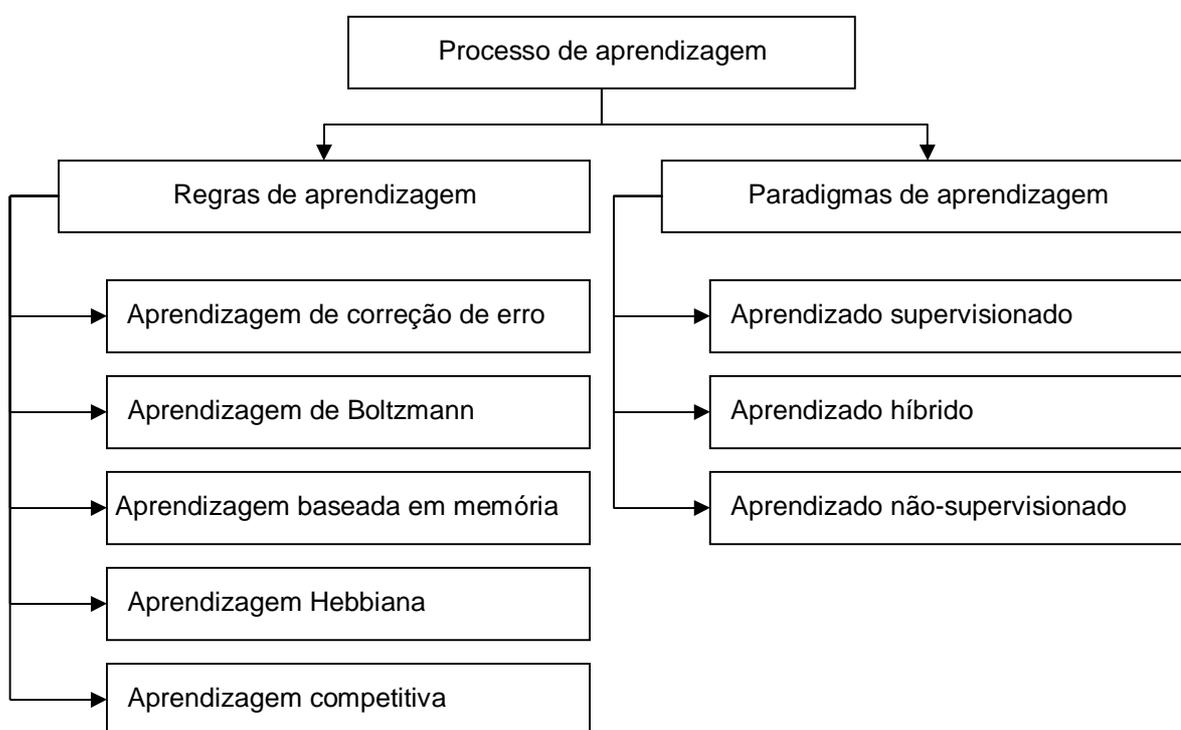


Figura 2.12 – Classificação do Processo de Aprendizagem
Fonte: HAYKIN, 2001

A seguir detalham-se as redes do tipo *perceptron* de múltiplas camadas e a rede de função de base radial que são tipos de redes neurais utilizadas para previsão de demanda (ZHANG, 1998). Essas RNA foram as utilizadas no desenvolvimento deste trabalho.

2.9.5. Rede neural artificial do tipo perceptron de múltiplas camadas (RNA MLP)

Tipicamente, esta arquitetura consiste de um conjunto de camadas compostas de uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Um exemplo de uma RNA MLP de duas camadas ocultas pode ser visto na Figura 2.13. Os sinais de entrada se propagam para frente, ou seja, da esquerda para a direita, de camada em camada.

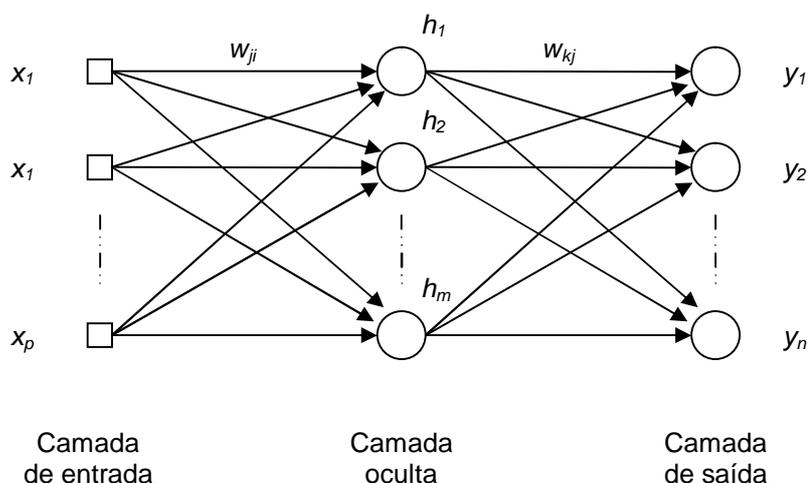


Figura 2.13 – Exemplo de uma rede perceptron de múltiplas camadas
Fonte: HAYKIN, 2001

A classificação de cada uma das camadas, de acordo com a sua posição, é:

- Camada de entrada: os neurônios propagam as informações de entrada para a camada seguinte, sem que ocorram modificações;
- Camada(s) intermediária(s) ou escondida(s): transmitem as informações por meio de interconexões entre as unidades de entrada e saída. Os neurônios dessas camadas são denominados unidades intermediárias ou escondidas;

- Camada de saída: os neurônios são denominados de unidades de saída, propagam a resposta da RNA.

Para uma rede MLP com uma única camada, apresentando-se o n -ésimo valor da entrada $x(n) = [x_1(n) \ x_2(n) \ \dots \ x_p(n)]^T$, a função que representa o neurônio da camada de saída k e a função que representa o neurônio da camada escondida j , respectivamente, são dadas por:

$$y_k(n) = j_k \left(\sum_{j=0}^m w_{kj}(n) \cdot h_j(n) \right) \quad (2.3)$$

$$h_j(n) = j_j \left(\sum_{i=0}^p w_{ji}(n) \cdot x_i(n) \right) \quad (2.4)$$

Onde:

x_i são os sinais de entrada;

w_{kj} são os pesos sinápticos do neurônio k (camada de saída);

w_{ji} são os pesos sinápticos do neurônio j (camada oculta);

$\varphi(\bullet)$ é a função de ativação;

h_j é a saída do neurônio j da camada oculta;

y_k é a saída do neurônio k da camada de saída;

p é o número de neurônios na camada de entrada;

m é o número de neurônios na camada oculta;

q é o número de neurônios na camada de saída;

As redes MLP têm sido aplicadas com sucesso para resolver diversos problemas difíceis (HAYKIN, 2001; CYBENKO, 1989) e previsão de demanda (ZHANG, 1998), através do seu treinamento de forma supervisionada com um algoritmo popular conhecido como algoritmo de retropropagação de erro (*error back-propagation*). Este algoritmo é baseado na regra de aprendizagem por correção de erro. Este algoritmo se tornou mais popular após a publicação do livro de Rumelhart e McClelland em 1986. O processo de retropropagação consiste em dois passos através da rede:

- Propagação: no passo para frente (*forward*), onde um padrão de atividade é aplicado na entrada e seu efeito propaga através da rede, camada por camada. Um conjunto de saída é produzido como a resposta real da rede. Durante este processo os pesos sinápticos estão fixos.
- Retropropagação: no passo para trás (*backward*) os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro. Este erro encontrado é então propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos sinápticos são ajustados para fazer com que a resposta real da rede convirja para a resposta desejada.

Esta técnica é baseada também na aprendizagem supervisionada, onde se compara a saída real com uma desejada, comparando os erros para o ajuste da rede.

O método de treinamento de rede neural utilizado nesta pesquisa foi o método Levenberg-Marquardt (LEVENBERG, 1944; MARQUARDT, 1963). Esse treinamento consiste em um aperfeiçoamento do método de Gauss-Newton, que é uma variante do método de Newton. O método de Newton usa a informação da derivada parcial de segunda ordem do índice de desempenho utilizado para corrigir os pesos \bar{w} . Isso permite que além da informação do gradiente ∇ seja usada a informação sobre a curvatura da superfície do erro (RANGANATHAN, 2008)

O método de Newton pode ser usado para resolver a equação:

$$\nabla V(\bar{w}) = 0 \quad (2.5)$$

Expandindo o gradiente de V em uma série de Taylor em torno dos pesos w_0 , obtém-se:

$$\nabla V(\bar{w}) = \nabla V(\bar{w}_0) + (\bar{w} - \bar{w}_0)^T \nabla^2 V(\bar{w}_0) + \mathbf{K} \quad (2.6)$$

Desprezando-se os termos de ordem superior a 2, a solução da equação 2.6 em relação a $\Delta \bar{w}$ fornece a regra de atualização de \bar{w} . O resultado é dado pela equação 2.7 ou de forma mais geral, pela equação 2.8.

$$\Delta w = -[\nabla^2 V(w_0)]^{-1} \nabla V(w_0) \quad (2.7)$$

$$\Delta \bar{w} = -[\nabla^2 V(\bar{w})]^{-1} \nabla V(\bar{w}) \quad (2.8)$$

Ao desprezarem-se os termos de ordem superior, assumindo-se a aproximação quadrática para o gradiente. Embora a convergência seja rápida, pode ser bastante sensível a posição inicial na superfície do erro, função dos valores dos pesos iniciais em w_0 . O índice de desempenho V pode ser definido como a soma do quadrado do erro e_i , associado ao i -ésimo padrão de treinamento da rede (equação 2.9).

$$V(\bar{w}) = \sum_{i=1}^N e_i^2(\bar{w}) \quad (2.9)$$

Então, o gradiente e o Hessiano podem ser expressos como funções do Jacobiano J (derivadas parciais) do índice de desempenho V , como:

$$\nabla V(\bar{w}) = J^T(\bar{w}) \cdot \bar{e}(\bar{w}) \quad (2.10)$$

$$\nabla^2 V(\bar{w}) = J^T(\bar{w}) \cdot J(\bar{w}) + S(\bar{w}), \quad (2.11)$$

em que

$$S(\bar{w}) = \sum_{i=1}^N e_i(\bar{w}) \nabla^2 e_i(\bar{w}) \quad (2.12)$$

A avaliação do hessiano pode ser extremamente complexa. Para contornar esse problema, foram propostos métodos que utilizam aproximações, denotados Quasi-Newton, dentre os quais se situam os métodos de Gauss-Newton, e de

Levenberg-Marquardt. No método de Gauss-Newton assume-se $S(\bar{w}) \approx 0$, então a regra de atualização de Newton passa a ser:

$$\Delta \bar{w} = -[J^T(\bar{w}) \cdot J(\bar{w})]^{-1} J^T(\bar{w}) \cdot \bar{e} \cdot (\bar{w}) \quad (2.13)$$

O problema com esse método é que a matriz $H = [J^T(\bar{x})J(\bar{x})]$ pode não ter inversa. Para contornar essa situação, Levenberg propôs somar a parcela mI a essa matriz, onde m é um escalar e I é a matriz identidade, resultando na seguinte regra de atualização (HAGAN e MENHAJ, 1994):

$$\Delta \bar{w} = -[J^T(\bar{w}) \cdot J(\bar{w}) + mI]^{-1} J^T(\bar{w}) \cdot \bar{e} \cdot (\bar{w}) \quad (2.14)$$

A matriz $[J^T(\bar{w}) \cdot J(\bar{w}) + mI]$ sempre possuirá inversa (RANGANATHAN, 2008).

Após uma atualização, se o valor do índice de desempenho diminui, m deve ser reduzido para diminuir a influência do gradiente descendente. Se ao contrário, o valor do índice de desempenho aumenta, então, deve-se seguir a direção do gradiente descendente que é a melhor escolha e o valor de m deve ser aumentado.

Se m tornar-se muito grande, a informação dada pela aproximação H para o hessiano não será útil no cálculo da atualização de \bar{w} . Para contornar esse problema, Marquardt propôs substituir a matriz identidade pela matriz $diag[H]$ (matriz diagonal de H), resultando na seguinte regra de atualização (RANGANATHAN, 2008 e ROWEIS, 2008):

$$\Delta \bar{w} = -[J^T(\bar{w})J(\bar{w}) + m \cdot diag[J^T(\bar{w})J(\bar{w})]]^{-1} J^T(\bar{w}) \cdot \bar{e} \cdot (\bar{w}) \quad (2.15)$$

É fundamental que o cálculo da matriz $J^T(\bar{w})$ seja realizado de forma eficiente. Essa matriz é formada pelo cálculo dos gradientes, para cada padrão de treinamento apresentado à rede. Hagan e Menhaj (1994) propuseram uma modificação no algoritmo de retropropagação que permite utilizar esse algoritmo para calcular o jacobiano.

O método Levenberg-Marquardt pode ser resumido pelos quatro passos seguintes:

- (a) obtenha uma atribuição inicial de pesos;
- (b) calcule uma atualização dos pesos de acordo com a equação 2.15 e avalie o erro, propagando os padrões na rede;
- (c) se o erro aumentar desfaça a atualização de \bar{w} e diminua m , senão valide a atualização de \bar{w} e incremente m ;
- (d) se convergir encerre; senão volte para (b).

2.9.6. Rede neural artificial de função de base radial (RNA RBF)

As redes RBF fazem parte de uma classe de técnicas denominadas *Gaussian Potential Functions* para classificação e aproximação de função (HAYKIN, 2001). Moody e Darken (1989) propuseram seu uso em um novo tipo de RNA, chamada rede de função de base radial (RBF). A princípio, as redes RBF podem ser multicamadas e terem funções de ativação na saída não-lineares. Contudo, redes neurais RBF têm tradicionalmente sido associadas com funções radiais em uma única camada escondida e funções de saída lineares (ORR, 1996).

A rede RBF envolve três camadas (Figura 2.14):

- na primeira camada os padrões de entrada são apresentados. Não existem pesos entre a primeira e a segunda camada, sendo os padrões de entrada repassados para os neurônios da segunda camada.
- a segunda camada (camada escondida) tem função de ativação radial. Cada neurônio j desta camada é responsável pela criação de um campo receptivo no espaço de entradas centrado em um vetor m_j , chamado de centro da unidade radial. A unidade radial j tem ativação de acordo com a distância entre o vetor de entrada e o centro da unidade radial. Quanto mais próximos forem os dois vetores, maior será a ativação do neurônio. Entre a segunda e a terceira camadas existem pesos sinápticos.

- A terceira camada apresenta ativação linear. A saída da rede neural RBF (de saída única) para o n -ésimo ($n=1, \dots, n_p$) vetor de entrada x_n , que é dada por:

$$y(n) = \sum_{j=0}^m w_j h_j(n) \quad (2.16)$$

Onde h_j é a ativação da unidade radial j da camada escondida e w_j é o peso entre a unidade radial j e o neurônio de saída. A ativação das unidades da camada escondida é definida por uma função radial. Uma função radial de ativação comum é a Gaussiana. Aplicando tal função na unidade radial j , a ativação desta unidade para o n -ésimo vetor de entrada x é dada por:

$$h_j(n) = e^{-\left(\frac{\|x(n) - m_j\|^2}{2s^2}\right)} \quad (2.17)$$

na qual σ determina o tamanho do campo receptivo da unidade radial j .

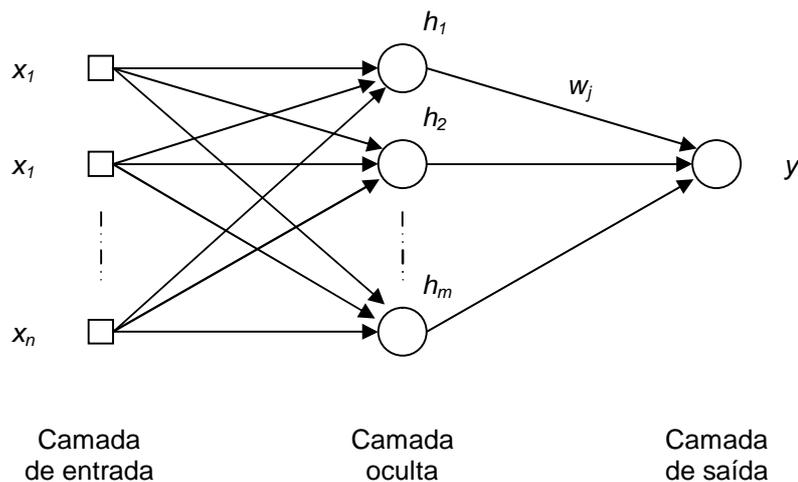


Figura 2.14 – Exemplo de rede de função de base radial
Fonte: HAYKIN, 2001

O treinamento da rede RBF requer dois estágios, ou seja, o treinamento da camada escondida, seguido pelo treinamento da camada de saída. Para o treinamento da camada escondida, utiliza-se tipicamente um método não

supervisionado, isto é, um algoritmo de agrupamento, com o intuito de ajustar os centros de cada Gaussiana em regiões onde os vetores de entrada tenderão a se agrupar. O treinamento da camada de saída é executado somente após a determinação dos parâmetros das funções base que foi executada no treinamento da camada escondida. A camada de saída é treinada utilizando-se do mesmo algoritmo usado na saída da rede MLP, sendo que o conjunto de treinamento será formado por partes de entrada/saída (m, d) , onde os vetores m são especificados após o treino da primeira camada (HAYKIN, 2001).

As redes de função de base radial (RBF) e as perceptrons de múltiplas camadas (MLP) são exemplos de redes em camadas alimentadas. Ambos são aproximadores universais, entretanto, essas duas redes diferem entre si em alguns aspectos importantes mostrados na Tabela 2.7.

Tabela 2.7 – Comparação entre redes neurais MLP e RBF.

MLP	RBF
Possuem uma ou mais camadas intermediárias	Geralmente possuem apenas uma camada intermediária
Nós de camadas intermediárias e de saída podem ter funções semelhantes	Nós de camadas intermediárias têm funções diferentes dos nós da camada de saída
Entrada da função de ativação é o produto interno dos vetores de entrada e de pesos	Entrada da função de ativação é a distância euclidiana entre os vetores de entrada e os pesos
Separa padrões de entrada com hiperplanos	Separa padrões de entrada com hiperelipsóides
Melhor em problemas complexos	Melhor em problemas bem definidos
Constrói aproximadores globais para mapeamento entrada-saída	Constrói aproximadores locais para mapeamento entrada-saída

Fonte: Adaptado de COSTA, 2006

2.10. Redes Neurais Artificiais aplicadas à previsão de demanda

Identifica-se na literatura que redes neurais possuem um grande potencial de utilização para previsão onde vários fatores afetam esta demanda, porém não se consegue identificá-los e nem mapeá-los. Como as redes neurais são um

aproximador universal de função, ela pode ser capaz de aprender o comportamento da característica desta demanda.

Muitas empresas obtiveram sucesso na utilização de redes neurais para antecipar mudanças no mercado, ao invés do uso de modelos estatísticos tradicionais (SKAPURA, 1996). Kartalopoulos (1996) também identifica a aplicação de redes neurais para predição.

Previsões de comportamento de sistemas complexos tem sido um domínio da larga aplicação para redes neurais. Aplicações como previsão de carga elétrica, previsão econômica, previsões de fenômenos físicos e naturais, têm sido amplamente estudados (ATIYA *et al*, 1999).

Num estudo em que HILL *et al* (1996) queriam determinar em que condições as redes neurais forneciam uma melhor previsão que séries temporais. Eles concluem que, apesar dos métodos estatísticos tradicionais de séries temporais terem um bom desempenho, muitos têm limitações. Primeiro, sem o conhecimento necessário é possível deixar de especificar a forma funcional relacionando as variáveis dependentes e independentes e falhar na transformação necessária dos dados. Segundo, não especialistas podem polarizar a geração de parâmetros do modelo. Adicionalmente, modelos de séries temporais são normalmente lineares e assim não podem capturar comportamentos não lineares. Outra desvantagem dos métodos estatísticos tradicionais é que eles não aprendem incrementalmente com novos dados chegando. Ao contrário, eles devem ser reestimados periodicamente.

Por que, na maioria dos casos, as redes neurais têm desempenho superior aos modelos tradicionais? A literatura aponta muitas vantagens das redes neurais sobre os métodos estatísticos tradicionais.

Redes neurais têm sido matematicamente mostradas como aproximadoras universais de função (FUNAHASHI, 1989 apud HILL *et al*, 1996, CYBENKO, 1989, HORNIK *et al*, 1989) e seus derivados (WHITE *et al*, 1992 apud HILL *et al*, 1996). Redes neurais são inerentemente não lineares (RUMELHART e MCCLELLAND, 1986, WASSERMAN, 1989 apud HILL *et al*, 1996). Eles estimam bem funções não lineares e extraem elementos não lineares residuais. Redes neurais podem particionar um espaço amostral e construir diferentes funções em diferentes porções daquele espaço (WASSERMAN, 1989 apud HILL *et al*, 1996). Assim, redes neurais são capazes de construir partes de modelos não lineares incluindo modelos com descontinuidades.

Hill *et al* (1996) percebeu que redes neurais, em comparação com outros sete métodos de previsão, tiveram desempenho superior em previsões mensais em relação à previsão anual. Quanto menor a periodicidade, melhor o desempenho da rede neural. Para modelos descontínuos, o modelo de redes neurais teve desempenho significativamente superior.

Alfares *et al* (2002) conclui após um levantamento de vários métodos de previsão em sua pesquisa que há uma clara tendência na direção de novas técnicas estocásticas e dinâmicas de previsão de demanda. Parece haver muito esforço em pesquisas em sistemas *fuzzy*, sistemas inteligentes e particularmente redes neurais. Carbonneau (2008) conclui em sua pesquisa que redes neurais apresentam resultados melhores que um modelo de regressão linear, porém sua aplicação deve ser avaliada em função da complexidade computacional que as RNA apresentam. Ele também menciona que RNA são incluídas em estudos de previsão de demanda em função dos fabricantes considerarem a demanda uma série caótica. Xu *et al* (2003) verifica viabilidade de aplicação de redes RBF (Função de Base Radial) para previsão de demanda.

Hill *et al* (1996) notam que em previsão de produtos e estoques, a incidência de não linearidade e descontinuidade é relativamente alta (LAWRENCE *et al*, 1994 apud HILL *et al*, 1996). Assim, neste tipo de aplicação, a utilização de rede neural pode ser altamente desejável.

A não linearidade é um problema que pode ser tratado convenientemente por Redes Neurais. Se por um lado a rede neural não pode resolver tudo, nos casos em que métodos clássicos de previsão não conseguem resultados bons devido a não linearidades, a rede pode conseguir performances significativas (CALÔBA *et al*, 2002).

Apesar de suas séries de dados possuírem características de séries temporais, Silva (2003) observa que as Redes Neurais Artificiais têm sido destaque na previsão por sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como sazonalidade, periodicidade, tendências, entre outras, na maioria das vezes camufladas por ruídos, sem necessidade de laboriosos passos da formulação teórica, imprescindível para os procedimentos estatísticos.

Estudos mostram que empresas do mercado industrial utilizam a força de vendas como fonte geradora da previsão de demanda (devido à proximidade entre a força de vendas e o cliente) (LYNN *et al*, 1999). O estudo de Kahn e Mentzer (1995) mostra que algumas empresas preferem utilizar indicadores, modelos econométricos e regressão múltipla.

A pesquisa também mostrou a familiaridade das empresas com as técnicas de previsão de demanda existentes na época. A técnica menos familiar é a utilização de redes neurais para previsão de demanda, onde para 64% das empresas do mercado industrial esta ferramenta não era familiar. O estudo também mostra que apenas 13% utilizam a técnica de redes neurais para previsão de demanda de médio prazo.

Em uma pesquisa do IBF (*Institute of Business Forecasting & Planning*) de 1999 reportada em Jain (2000) mostra, em outra amostragem, que 1,6% das empresas usam redes neurais como modelo de previsão de demanda. Esta mesma pesquisa mostra que redes neurais não são usadas pelas empresas de Telecomunicações avaliadas. Isto nos mostra o quanto a ferramenta de redes neurais é pouco utilizada pelas empresas.

3. METODOLOGIA

Este capítulo aborda a metodologia de pesquisa utilizada neste trabalho e, também, detalha as características utilizadas dos modelos de redes neurais artificiais aplicadas à previsão de demanda que foram utilizados no desenvolvimento do trabalho.

O método trata do conjunto de processos pelos quais se torna possível conhecer uma determinada realidade, produzir determinado objeto ou desenvolver certos procedimentos ou comportamentos.

O método quantitativo é muito utilizado no desenvolvimento das pesquisas descritivas, na qual se procura descobrir e classificar a relação entre variáveis, assim como na investigação da relação de causalidade entre os fenômenos causa e efeito (OLIVEIRA, 1997). Esse método também é empregado no desenvolvimento das pesquisas de âmbito social, econômico, dentre outras, de forma a garantir a precisão dos resultados e evita com isto distorções de análise e interpretações.

Yin (1994) afirma que é possível identificar situações em que todas as estratégias de pesquisa são relevantes, e outras situações em que duas estratégias podem ser consideradas igualmente atrativas. É permitido utilizar mais de uma estratégia em um estudo.

O método indutivo é um processo mental por intermédio do qual, partindo de dados particulares, suficientemente constatados, infere-se uma verdade geral ou universal, não contida nas partes examinadas (LAKATOS, 2001).

Já no método dedutivo, partindo-se de várias premissas verdadeiras, chega-se a uma conclusão, por dedução, que deve ser verdadeira (LAKATOS, 2001).

Alguns métodos lógicos serão utilizados na pesquisa:

O princípio da contradição informa que duas proposições contraditórias não podem ser ambas falsas ou ambas verdadeiras ao mesmo tempo.

O método de redução ao absurdo consiste no seguinte (PINTO, 2007):

- admite-se que aquilo que se quer provar é falso;
- por raciocínio dedutivo, chega-se a uma conclusão absurda, concluindo-se então que o que se quer provar é verdadeiro.

Descobrir, medir, analisar, otimizar, decidir, observar os resultados e os fenômenos e começar o ciclo novamente são maneiras pelas quais a tomada de decisão nas pesquisas deveriam ser executadas através de métodos científicos.

De acordo com Nakano e Fleury (1996) e Villares e Nakano (1998) a pesquisa pode ser classificada como sendo uma pesquisa quantitativa (empírica, ou método científico tradicional), com o propósito de previsão e baseado em dados históricos existentes. Quantitativa por ser baseada em coleta, análise e interpretação matemática de dados numéricos coletados ao longo do tempo em um sistema existente. Este projeto de pesquisa pode ainda ser classificado segundo esses autores como teórico conceitual.

De acordo com Silva (2000) a pesquisa também pode ser classificada como uma pesquisa quantitativa, onde considera que tudo pode ser quantificável, o que significa traduzir em números opiniões e informações para classificá-las e analisá-las. Requer o uso de recursos e de técnicas estatísticas (percentagem, média, moda, mediana, desvio padrão, coeficiente de correlação, análise de regressão, etc.).

Silva (2000) define uma classificação pela natureza da pesquisa, onde esta ser classificada como uma pesquisa aplicada, onde objetiva gerar conhecimentos para aplicação prática e dirigidos à solução de problemas específicos. Envolve verdades e interesses locais.

Do ponto de vista de seus objetivos Gil (1991) diz que a pesquisa pode ser classificada como uma pesquisa exploratória, pois envolve um levantamento bibliográfico, visando tornar o problema mais explícito ou a construção de hipóteses. O mesmo autor também classifica a pesquisa do ponto de vista dos procedimentos técnicos, aonde pode ser classificada como uma pesquisa experimental que visa através de um objeto de estudo (a demanda de equipamentos), selecionar as variáveis que podem ser capazes de influenciá-lo, definir as formas de controle e de observação dos efeitos que as variáveis produzem no objetivo.

A Figura 3.1 apresenta esquematicamente as etapas de um processo de pesquisa segundo Bryman (1989), que será utilizada nesta pesquisa.

As etapas de teoria-conceitos e hipóteses-diretrizes correspondem ao projeto de pesquisa, em que a articulação de hipóteses e diretrizes de pesquisa é o principal objetivo. As definições associadas à definição do tema da pesquisa e a articulação do problema que irá sustentar a formulação de hipóteses caracterizam estas fases.

As etapas de observação, coleta, análise e conclusão correspondem à pesquisa que irá articular, nos níveis teórico e prático, as hipóteses e diretrizes levantadas. Estas fases correspondem ao trabalho experimental, caracterizam o teste das hipóteses e diretrizes.

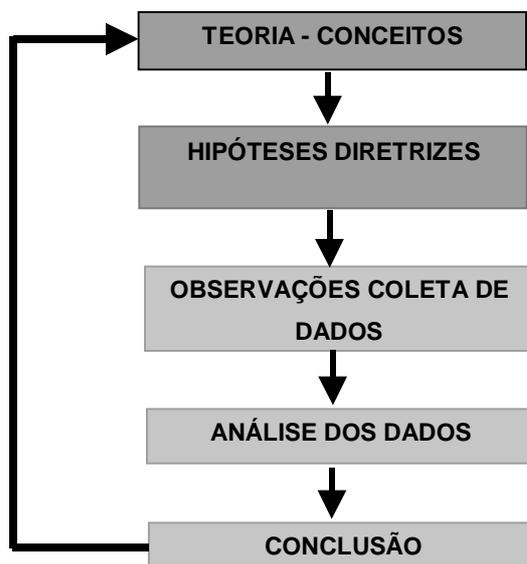


Figura 3.1 – Modelo para o projeto de pesquisa
Fonte: BRYMAN (1989)

3.1. Proposta Metodológica para a Solução do Problema

Neste trabalho utilizou-se a seqüência de abordagem sugerida por Yao e Tan (2001), que é:

1. **Pré-processamento dos dados.** É a etapa de preparação dos dados. Análise da periodicidade, existência dos dados e também valores absolutos dos dados. Estudos mostram que é melhor normalizar os dados de entrada para evitar problemas computacionais (LAPEDDES e FARBER, 1988), para atender às necessidades do algoritmo (SHARDA e PATIL, 1992) e para facilitar o aprendizado da rede (SRINIVASAN *et al*, 1994). Redes de retro propagação requerem que a entrada tenha valores na faixa de zero e um.

Desta forma, os valores deverão ser normalizados antes de serem utilizados nas redes (SKAPURA, 1996, PALMER *et al*, 2006). Weigend *et al* (1992) também cita a utilização da normalização estatística para uso na normalização dos dados para as RNA. A função é definida no experimento.

2. **Seleção das variáveis de entrada e saída.** A princípio, além do histórico da demanda como variável de entrada, está previsto, também, a utilização de outras variáveis de entrada para o modelo de previsão que serão escolhidas durante a pesquisa. A variável de saída será a previsão de demanda futura.
3. **Análise de sensibilidade.** Aqui será verificado se as variáveis escolhidas não possuem uma correlação entre si a fim de que se possa eliminar alguma, assim reduzindo o número de variáveis de entrada e também o processamento computacional.
4. **Organização dos dados.** Nesta etapa serão analisados os dados e organizados quais períodos serão utilizados para o treinamento e teste, bem como o alcance da previsão desejada.
5. **Construção do modelo.** Nesta etapa serão definidas as características do modelo de rede neural utilizado no experimento. As características serão discutidas na seção 3.2.
6. **Pós análise.** Os resultados do experimento serão analisados em função do seu desempenho. Os critérios estão definidos na seção 3.3.
7. **Recomendação do modelo.** Concluir qual o modelo mais adequado para o tipo de mercado experimentado.

O programa MATLAB (www.mathworks.com) foi utilizado como instrumento computacional para a realização do experimento. O MATLAB possui o pacote de redes neurais, com várias arquiteturas de rede e algoritmos de treinamento pré-programados que facilitarão a execução do experimento. Não faz parte do escopo desta pesquisa alterar parâmetros que não sejam os padrões oferecidos pelo pacote MATLAB.

3.2. Características do Modelo de RNA a Serem Utilizadas no Experimento

Nesta parte do trabalho é feita uma revisão na literatura referente às arquiteturas e parâmetros para a modelagem de redes neurais artificiais aplicadas à previsão de demanda.

3.2.1. Arquitetura da rede

3.2.1.1. Número de camadas escondidas e nós

O número de camadas escondidas e de nós é muito importante para o sucesso da utilização da rede neural. Baseado nos estudos que uma camada é suficiente para uma RNA aproximar qualquer função não linear complexa (CYBENKO, 1989; HORNIK *et al*, 1989), muitos autores utilizam apenas uma camada para realizar a previsão (VALVERDE RAMIREZ *et al*, 2005; PALMER *et al*, 2006). Entretanto, uma camada requer um grande número de nós, o que não é desejável (ZHANG, 1998).

Duas camadas podem prover mais benefícios para alguns tipos de problemas (BARRON, 1994 apud ZHANG, 1998). Zhang (1994) concluiu que duas camadas podem ser mais precisas do que uma camada apenas. Ele também testou mais de duas camadas e nenhuma melhoria foi encontrada.

Quanto aos nós das camadas escondidas, Zhang (1998) relata que a maneira mais comum de determinar seu número é por experimentação, ou tentativa e erro.

Para o caso de uma camada escondida, alguns guias práticos existem para a determinação da quantidade dos nós da camada escondida (n como sendo o número de nós de entrada):

- “ $2n+1$ ” (LIPPMANN, 1987 e HECHT-NIELSEN, 1990 apud ZHANG, 1998)
- “ $2n$ ” (WONG, 1991 apud ZHANG, 1998; VALVERDE RAMIREZ *et al*, 2005)
- “ n ” (TANG e FISHWICK, 1993 apud ZHANG, 1998)

- “n/2” (KANG, 1991 apud ZHANG, 1998)

Zhang (1998) diz que nenhuma destas escolhas heurísticas funciona bem para todos os problemas. Ele ressalta que redes com o número de nós iguais ao número de nós de entrada relatam ter uma melhor previsão em vários estudos (DE GROOT e WURTZ, 1991; SHARDA e PATIL, 1992; CHAKRABORTY *et al*, 1992 e TANG e FISHWICK, 1993 apud ZHANG, 1998).

3.2.1.2. Número de nós de entrada

Na opinião de Zhang (1998) o número de nós de entrada é, provavelmente, a variável de decisão mais crítica para o problema de previsão de séries temporais, já que contém a importante informação sobre a complexa autocorrelação da estrutura dos dados de entrada. Da pesquisa, Zhang (1998) conclui que poucos ou muitos nós de entrada podem afetar tanto a capacidade de treinamento quanto de predição da rede neural.

O número de nós de entrada será determinado durante a realização do experimento.

3.2.1.3. Número de nós de saída

Zhang (1994) relata que para o problema de previsão de séries temporais o número de nós de saída corresponde ao horizonte de previsão que se deseja estimar.

Outra possibilidade de se obter a mesma previsão é realizar a previsão com apenas um nó de saída, representando a estimação do próximo período. Para estimar o período subsequente, utiliza-se este valor como entrada e assim obtém o período +2. Zhang (1994) chega a conclusão que este método é melhor do que ter vários nós de saída, cada um representado um período de estimação. Ao contrário, Weigend *et al* (1992) e Hill *et al* (1994) chegaram a conclusão que vários nós de saída tem um desempenho melhor do que realizar vários passos de previsão.

3.2.1.4. Interconexão dos nós

Zhang (1998) relata em sua pesquisa que tanto para previsão, bem como em outras aplicações, as redes estão totalmente conectadas. Todos os nós estão conectados à todos os nós da próxima camada, com exceção da camada de saída.

3.2.1.5. Inicialização dos pesos

A inicialização dos pesos de uma rede neural é um dos fatores relevantes com vista ao melhor ajuste dos pesos sinápticos e limiares decorrentes do treinamento por retropropagação do erro. Uma escolha inicial errada dos parâmetros livres pode levar a rede a um fenômeno conhecido como saturação prematura (*premature saturation*) (LEE *et al*, 1991). Este fenômeno refere-se a um determinado procedimento que ocorre durante o treinamento à rede, em que o erro médio quadrático permanece quase constante por alguns períodos de tempo durante o processo de aprendizagem da rede, com isso, mascarando a existência do erro mínimo. Neste caso, o processo de aprendizagem pode ser interrompido impedindo a busca do provável erro mínimo da função fazendo com que a convergência ocorra prematuramente.

Uma regra muito utilizada baseia-se em inicializar uma rede com pesos aleatórios numericamente pequenos. A motivação para este procedimento é que valores absolutos muito grandes de pesos induzem os nós escondidos a serem altamente ativos ou inativos para toda a amostra de treinamento e, então, indiferentes para o processo de treinamento. Outro processo recomendado de inicialização não-aleatória é linearizar a rede, e então calcular os pesos iniciais por meio de regressão linear. Esta estratégia torna-se vantajosa se o problema for mais ou menos linear, então, a maior parte do treinamento é feita antes do ajustamento iterativo dos pesos a ser iniciado (LEONDES, 1998).

3.2.2. Função de ativação

Vários exemplos de função de ativação foram mostrados na seção 2.9.3.3. Na teoria, todas elas poderiam ser utilizadas. Zhang (1998) diz que as mais comumente usadas são as funções: logística, tangente hiperbólica, seno e co-seno e a função linear. Entre estas, a função logística é a mais comumente usada (ZHANG, 1998; VALVERDE RAMIREZ *et al*, 2005).

BORS (2007) cita que para a utilização de redes RBF, a função *thin-plate* é indicada para previsão de séries temporais.

A função de ativação a ser usada será definida durante a execução do experimento.

3.2.3. Algoritmo de treinamento

Zhang (1998) relata que não há um algoritmo de treinamento disponível que garanta a solução ótima global para o problema de otimização não linear. O mesmo autor conclui em sua pesquisa que o algoritmo de retropropagação é o mais utilizado pelos pesquisadores. Mas os parâmetros para o aprendizado são usualmente escolhidos por experimentação. De Groot e Wurtz (1991) testaram vários algoritmos de otimização conhecidos, como quasi-Newton, BFGS, Levenberg-Marquardt e métodos de gradiente conjugado e obtiveram melhoras no tempo de treinamento e precisão para séries temporais.

Não há uma fórmula para definir o conjunto de treinamento e validação. Cada autor realiza sua escolha baseada no modelo, nos dados e no tipo de problema que possui. Nam e Schaefer (1995) concluem que quanto maior o conjunto de treinamento, melhor é o desempenho da rede neural. A literatura mostra que a maior parte da amostra (entre 60% a 90%) é utilizada para treinamento (DOBRZANSKI e TRZASKA, 2004; TSENG *et al*, 2007; MURAT e CEYLAN, 2006; ZHANG *et al*, 1998). Já há pesquisas na utilização de algoritmos para definir o melhor conjunto de treinamento da rede neural. (REEVES E TAYLOR, 1998 e REEVES E BUSH, 2001)

Os algoritmos de treinamento a serem utilizados serão definidos durante o experimento.

3.3. Avaliação dos Modelos

Os modelos serão avaliados pela medida de erro de previsão de demanda. As medidas do erro mais utilizadas são (HANKE *et al*, 2001; CHOPRA e MEINDL, 2004):

- Erro quadrático médio (Mean Square Error – MSE)
- Desvio absoluto médio (Mean Absolute Deviation – MAD)
- Erro absoluto médio percentual (Mean Absolute Percentage Error – MAPE)

O Erro de previsão no período t (E_t) é dado pela diferença entre a previsão para o período f (F_t) e a demanda real no período t (D_t). Esta medida é mostrada na equação 3.1.

$$E_t = F_t - D_t \quad (3.1)$$

O erro médio quadrático (MSE) mostrado na equação 3.2 calcula a variância dos erros de previsão e é obtido pela somatória dos erros (E_t) ao quadrado dividido pelo número de amostras (n) avaliadas.

$$MSE_n = \frac{1}{n} \sum_{t=1}^n E_t^2 \quad (3.2)$$

O desvio absoluto médio (MAD) é calculado pela média dos valores absolutos do erro (E_t) no período de amostragem (n). A equação 3.3 mostra a fórmula.

$$MAD_n = \frac{1}{n} \sum_{t=1}^n |E_t| \quad (3.3)$$

Todas as medidas anteriores resultam em valores absolutos de erros. Também se deve medir um erro através de valores percentuais, para assim saber se é relevante ou não em relação à grandeza que está sendo medida. O erro absoluto médio percentual (MAPE), mostrado na equação 3.4, é a medida mais utilizada e facilmente compreendida no meio industrial.

$$MAPE_n = \frac{\sum_{t=1}^n \left| \frac{E_t}{D_t} \right| \times 100}{n} \quad (3.4)$$

Este trabalho avaliará os modelos de previsão estudados dentro de cada um dos critérios anteriormente citados.

3.4. Método de Previsão de Demanda da Empresa Fornecedora de Equipamentos de Telecomunicações

A empresa estudada possui um processo para a elaboração da previsão de demanda para os produtos de infra-estrutura de telecomunicações. O diagrama em blocos está mostrado na Figura 3.2.

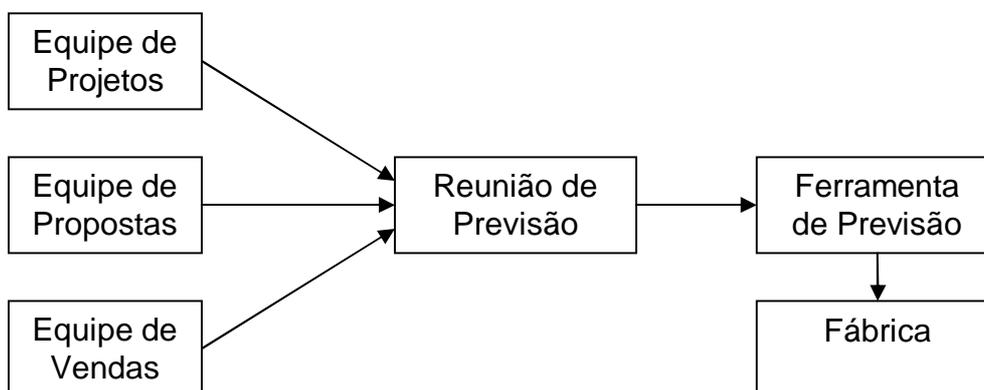


Figura 3.2 – Processo de elaboração de previsão de demanda da empresa
Fonte: do autor

A reunião de previsão de demanda ocorre mensalmente, nos primeiros dias do mês, visando ter uma visão do mês corrente, mas o foco principal é prever a quantidade a ser fornecida a partir do próximo mês. A previsão tem um horizonte de 12 meses e é discutida no nível agregado. Para os equipamentos estudados (ERB), o resultado é apresentado em número de estações novas e também em transceptores (TRX).

Após a reunião, os dados são colocados na ferramenta de previsão de demanda, que realiza a explosão da previsão em módulos (SKU). Esta ferramenta é desenvolvida pela empresa matriz, e considera o ciclo de vida do produto nesta explosão, de modo que as novas versões de módulos sejam consideradas na lista.

A fábrica recebe então a previsão de demanda da ferramenta descrita acima e coloca os dados no módulo de gestão de demanda da sua ferramenta de ERP. Desta forma, através do MRP, é realizada a encomenda de insumos necessários para a produção e atendimento das quantidades planejadas.

Conforme mostrado no diagrama em blocos da Figura 3.2, a previsão possui três fontes de informação:

1. Equipe de Projetos: Fornecem a informação do que tem que ser fornecido num curto prazo (máximo de 6 meses). São consideradas as quantidades dos projetos e instalações em andamento, que já foram discutidas e acordadas com os clientes. O grau de acerto em relação às quantidades é alto. O grau de acerto em relação ao tempo não é muito bom. Esta avaliação é pela experiência e não há dados para realizar esta estatística. A equipe de projetos relata que este erro em relação ao tempo é devido às grandes incertezas existentes no projeto, como liberação dos locais de instalação pela operadora (quando as etapas anteriores à instalação são realizadas pela operadora), etapas de construção civil (influências do tempo e atrasos nas obras), liberação do local de instalação do equipamento (licença da prefeitura e negociação de locação com o proprietário do imóvel).
2. Equipe de Propostas: Fornecem a informação do que deve ser fornecido num curto e médio prazo (máximo de 9 meses). Pela equipe são consideradas as quantidades das propostas em andamento. As operadoras consideram cada etapa de ampliação das redes como um projeto novo e sempre realizam uma consulta de preço antecipada, considerando também, quando possível, outros fornecedores. Após o recebimento das propostas dos fornecedores, o cliente,

de acordo com seu processo interno, decide qual será o fornecedor dos equipamentos. Para este caso, o grau de incerteza das quantidades é alto, pois ou se ganha todo o projeto ou nada. Outro fator que aumenta a incerteza na quantidade é que o projeto para a proposta é realizado com base em uma estimativa da instalação. O projeto final só é realizado após a empresa ganhar a venda e as quantidades e configurações podem mudar. Quanto ao tempo, a incerteza também é grande, pois além das incertezas já mencionadas pelos projetos, não está sob domínio da empresa quanto tempo o cliente levará para decidir a compra ou não.

3. Equipe de vendas: Responsáveis pela previsão de médio e longo prazo (geralmente superior a 6 meses). Estes consideram as informações mercadológicas, econômicas e dos clientes para realizar suas previsões. Uma informação considerada é estimar, do valor que será investido pela operadora, a quantidade de equipamentos ERB que será necessária no futuro. O grau de acerto fica bastante a desejar, já que é uma pura estimativa e esta equipe não utiliza nenhuma ferramenta estatística ou matemática e nenhum método para realizar esta previsão.

Tabela 3.1 – Regras para definição da probabilidade de ganho de um contrato

Critério de probabilidade	Probabilidade de ganho (AW)
• Idéia de negócio.	$AW < 20\%$
• Decisão de realizar proposta;	$20\% \leq AW < 40\%$
• Proposta entregue.	
• Ampliação de base instalada;	$40\% \leq AW < 80\%$
• Empresa está entre as 3 finalistas.	
• Carta de intenção escrita disponível;	$80\% \leq AW \leq 100\%$
• Contrato “guarda chuva”.	
• Pedido de compra recebido.	100%

Fonte: Empresa em estudo.

Como as informações das quantidades previstas disponíveis são totalizadas, não temos como avaliar o grau de acerto de previsão por equipe. A totalização da previsão é efetuada somando-se a demanda de todos os projetos existentes e

prospecções pela probabilidade de sua ocorrência. A probabilidade é subjetivamente estimada pela equipe de vendas, tendo como referência a regra definida na Tabela 3.1. Esta regra é definida pela equipe de planejamento, e é utilizada pelas equipes de vendas de todos os países.

4. DESENVOLVIMENTO

Este capítulo contempla o desenvolvimento, a implementação e a avaliação dos resultados de cada um dos modelos de previsão construídos com redes neurais artificiais. Descreve a definição das variáveis de entrada e saída, topologia das redes neurais, bem como seus parâmetros.

Foram desenvolvidos 15 modelos utilizando a RNA MLP e 36 modelos utilizando a RNA RBF.

4.1. Definição dos parâmetros das redes neurais

Nesta parte da pesquisa são definidos os parâmetros utilizados para a modelagem das redes neurais artificiais utilizadas no experimento.

4.1.1. Pré-processamento dos dados

O pré-processamento consiste na preparação dos dados para a utilização deles nas redes neurais. Para os dados de telecomunicações, foi definida a utilização da normalização entre -1 e 1. Ela é realizada pela fórmula a seguir.

$$p_n = \frac{2 \times (p - \min p)}{(\max p - \min p)} - 1 \quad (4.1)$$

onde:

p_n – dado normalizado;

p – dado a ser normalizado;

$\min p$ – valor mínimo da série a ser normalizada;

$\max p$ – valor máximo da série a ser normalizada.

4.1.2. Seleção das variáveis de entrada

A escolha das variáveis de entrada é importante para que o modelo consiga simular o comportamento do mercado que se está querendo obter. Para obter uma lista de variáveis, foi realizada uma entrevista com os vendedores da empresa em estudo (os que realizam a previsão de demanda atualmente). O resultado destas entrevistas foi a lista de variáveis (Tabela 4.1) que poderiam ser utilizadas no modelo. Com a lista das variáveis possíveis, foi feita pesquisa na internet, envio de questionamentos à ANATEL, IBGE, operadoras de telefonia celular. Também foi adquirido o relatório de telefonia celular no Brasil 2007 (www.teleco.com.br). O objetivo do trabalho é buscar dados disponíveis ao público em geral a fim de identificar quais variáveis estão disponíveis no período de amostra. O período de amostra que temos é de dezembro de 2001 a setembro de 2007. Este é o período que a empresa realizou fornecimentos dos equipamentos de infra-estrutura de telefonia celular.

Tabela 4.1 – Lista de variáveis obtida através das entrevistas.

Variável	Fonte disponível	Disponibilidade da informação
Número total de assinantes de celular	ANATEL SIS SMP	Mensal, de jan/99 a jun/07
Número total de assinantes pré pago	ANATEL SIS SMP	Mensal, de jun/02 a jun/07
Número total de assinantes pós pago	ANATEL SIS SMP	Mensal, de jun/02 a jun/07
Número total de assinantes da tecnologia GSM	ANATEL	Mensal, de jun/02 a jun/07
Total ERBs	ANATEL	Mensal, de jun/02 a jun/07
Participação Mercado TIM+OI+Claro	ANATEL	Mensal, de abr/05 a jun/07
ARPU	TELECO/operadoras	Anual e trimestral
MOU	TELECO/operadoras	Anual e trimestral
SAC	TELECO/operadoras	Anual e trimestral
Churn	TELECO/operadoras	Anual e trimestral
Receita Líquida	TELECO/operadoras	Anual e trimestral
Margem EBITDA	TELECO/operadoras	Anual e trimestral
Valor de Investimento	TELECO/operadoras	Anual e trimestral
Fornecimento TRX	Empresa em estudo	Mensal, de dez/01 a jun/07
Rendimento médio mensal	IBGE	Mensal, de fev/02 a jun/07
PIB Brasileiro	IBGE	Trimestral
Previsão de demanda realizada pela empresa	Empresa em estudo	Mensal, de jul/03 a jun/07

Fonte: do autor.

Outras informações são usadas para realizar a previsão de demanda da empresa, mas estas informações são qualitativas e não podem ser transformadas em variáveis para ser adicionadas no modelo. Alguns exemplos das informações listadas nas entrevistas estão listados na Tabela 4.2.

Tabela 4.2 – Exemplo de informações qualitativas utilizadas na previsão de demanda.

Informação
<ul style="list-style-type: none"> • Probabilidade de ocorrência de um projeto; • Conversas e reuniões com as operadoras; • Tipo do contrato de fornecimento; • Liberação de licenças; • Autorização de construção de novos sites; • Resultado de testes de equipamento com o cliente; • Oportunidades de prospecções futuras; • Informativos e notícias do mercado;

Fonte: Empresa em estudo.

Para realizar a simulação, necessitamos de dados mensais e que preencha o período de amostras do fornecimento de TRX. As variáveis com dados trimestrais disponíveis poderiam ser utilizadas, realizando-se algum método de interpolação para os meses faltantes. Esta opção foi descartada pois poderia diminuir a precisão da previsão de demanda. As variáveis listadas a seguir são as que foram escolhidas, pois atendiam o critério acima. As demais foram descartadas, por não preencher estes requisitos.

- Percentual de assinantes pós pago. Variável calculada dividindo-se o número de assinantes pós pago pelo total de assinantes de celulares no Brasil.
- Número de assinantes da tecnologia GSM. Esta variável é importante, pois a empresa em estudo fornece apenas equipamentos desta tecnologia de transmissão de celular.
- Total de ERB. Total de estações rádio base instaladas no Brasil por todas as operadoras de celular do Brasil.
- Fornecimento TRX. Total de TRX (transceptores de GSM) fornecidos pela empresa em estudo.

- Rendimento médio mensal. Rendimento médio mensal da população brasileira. Os valores comparáveis na série toda, cálculo já considerado na tabela fornecida pelo IBGE.

A Figura 4.1 apresenta o comportamento normalizado das 5 variáveis de entrada definidas para o modelo a ser simulado.

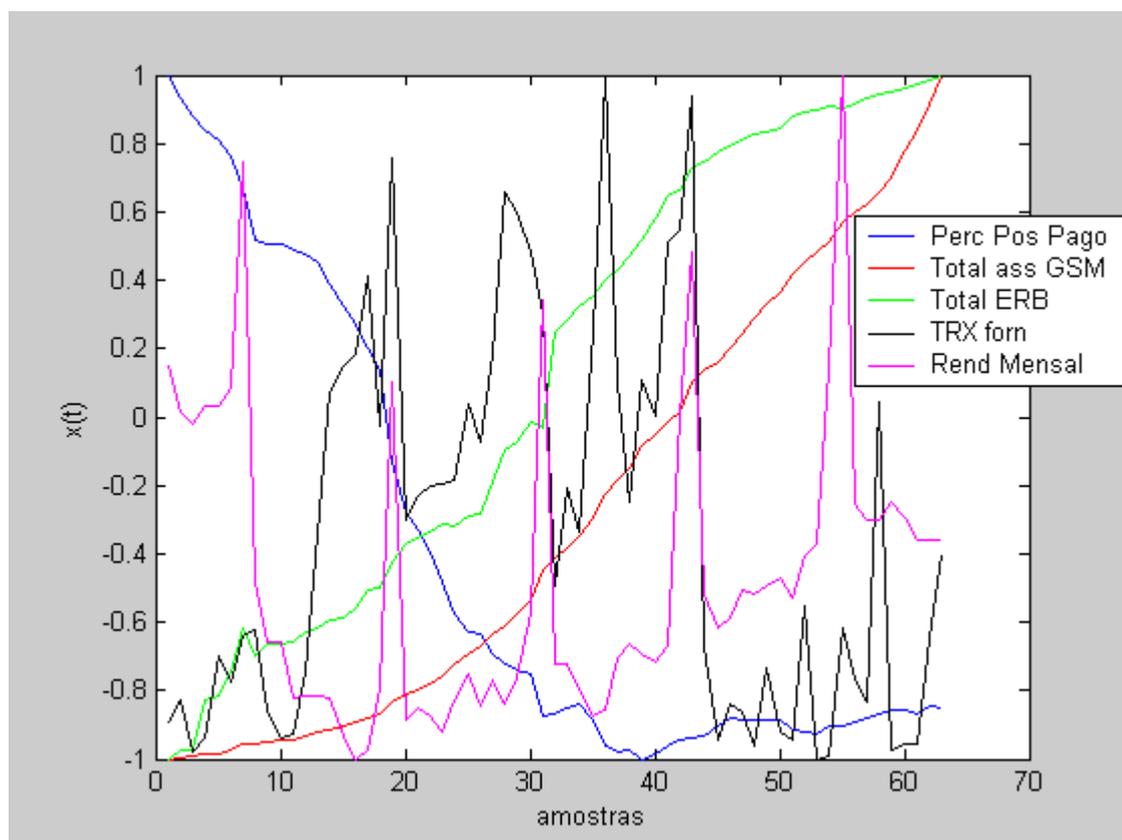


Figura 4.1 – Comportamento normalizado das cinco variáveis de entradas
Fonte: do autor

4.1.3. Seleção da variável de saída

O resultado da simulação é a previsão de demanda para o período $t+1$ da série de dados. Para tal, a camada de saída é a variável Fornecimento TRX.

4.1.4. Análise de sensibilidade

Com a conclusão da escolha das variáveis, foi avaliada a possibilidade da aplicação de uma análise de componente principal, com o objetivo de eliminar variáveis correlacionadas entre si. Esta medida foi descartada após os primeiros testes. Estes mostraram que a rede é treinada rapidamente (tempo menor que dois segundos) com os dados das cinco variáveis escolhidas. Para a finalidade que o experimento se propõe, o tempo é considerado curto, pois a frequência da simulação é mensal. Este critério teria que ser reavaliado, caso a aplicação exigisse um treinamento e simulação em tempo real.

4.1.5. Organização dos dados

Para desenvolver o treinamento e validação das redes neurais, é necessário separar os dados em conjuntos de treinamento e de validação. O conjunto de treinamento é usado durante o desenvolvimento do modelo de RNA. O conjunto de validação é utilizado para a avaliação da habilidade de previsão do modelo treinado.

Para o conjunto de dados do problema, 70% foram utilizados para treinamento, sendo que o restante (30% dos dados) foi utilizado para a validação da rede.

A previsão será realizada para o período $t+1$ (*one step-ahead forecast*).

4.1.6. Construção do modelo

4.1.6.1. Definição do modelo de RNA MLP

Para os modelos MLP, foram definidas as seguintes características de rede para a realização do experimento.

A rede possui três camadas, sendo uma de entrada, outra oculta e a camada de saída.

A camada de entrada é composta pela série de dados históricos de 3, 4 e 6 meses das cinco variáveis de entrada definidas. Isto nos leva a um número de 15 a 30 nós de entrada.

A camada oculta será composta de 14 a 30 neurônios. Foi definido um intervalo de 4 neurônios entre cada experimento. Estes valores foram obtidos, considerando fixo o número de neurônios de teste, e que abrangesse a faixa de $n/2$ e $2n$ (n como sendo o número de nós de entrada). A função de ativação mais utilizada é a logística. Como os dados de entrada possuem valores negativos, a função de ativação definida para esta camada é a sigmóide tangente hiperbólica.

A camada de saída é composta de um neurônio, ou seja, a previsão do período F_{t+1} . É realizada uma previsão um passo a frente usando um modelo de previsão série-paralelo (NARENDA e PARTHASARATHI, 1990). A função de ativação definida para esta camada é a linear.

O treinamento da rede MLP é realizado com o algoritmo de Levenberg-Marquardt (SHEPHERD, 1997). Este algoritmo de otimização não linear possui uma convergência muito rápida e é recomendada por outros autores (TAN E VAN CAUWENBERGHE, 1999; ANCTIL E RAT, 2005). Trautwein (2004), em seu experimento, conclui que o algoritmo de Levenberg-Marquardt tem o melhor desempenho em tempo e na previsão em relação à outros algoritmos de treinamento disponíveis no programa MATLAB. O treinamento foi limitado a 200 épocas. Mas em todos os treinamentos realizados, o algoritmo parou antes da época 50, quando o erro MSE do treinamento não diminuía mais. Esta também é um critério de

encerramento do treinamento pelo algoritmo de Levenberg-Marquardt do programa MATLAB.

4.1.6.2. Definição do modelo de RNA RBF

A rede RBF foi simulada utilizando a rotina do MATLAB *newrb*. Esta rotina cria interativamente uma rede de função de base radial adicionando neurônios a cada interação, até que o valor da soma dos quadrados dos erros seja inferior ao erro que se especifica.

A rede RBF utilizada no programa MATLAB possui a camada interna de função gaussiana definida pela equação 4.2. A camada de saída possui a função de transferência linear.

$$a = e^{-n^2} \quad (4.2)$$

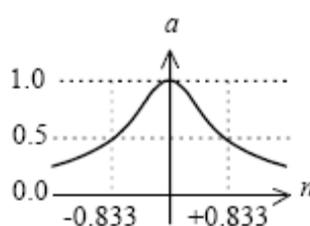


Figura 4.2 – Gráfico da função de transferência da rede RBF.
Fonte: DEMUTH e BEALE, 2000

O fator distância de centro (*spread*) é variado entre 0,25 a 3. Este fator faz a função gaussiana cruzar o ponto 0,5 quando a entrada da função (considerando o peso sináptico) for +/- a distância de centro especificada. Esta distância foi definida considerando que a distância entre os valores extremos dos vetores de entrada normalizados é 2. O gráfico da Figura 4.2 mostra o comportamento da função de transferência, para a distância de centro igual a 1,0.

O número máximo de neurônios a ser criado foi definido como 200, sendo que o passo de cada interação foi definido de 2 em 2 neurônios. O MATLAB utiliza o

erro SSE (Soma dos quadrados dos erros) como meta de treinamento. O erro máximo (SSE) foi definido como $1e-10$.

4.2. Análise dos resultados

A análise dos resultados é realizada em 3 etapas:

- Análise dos resultados das redes neurais MLP, escolhendo a que apresentou melhor desempenho na validação;
- Análise dos resultados das redes neurais RBF, escolhendo a que apresentou melhor desempenho na validação;
- Comparação dos melhores desempenhos das redes neurais com o desempenho da previsão atualmente executada pela empresa em estudo.

4.2.1. Resultados das redes MLP

Definidas as redes MLP, as amostras de treinamento e validação, são realizados o treinamento e a simulação com os dados para a comparação dos resultados.

Durante o treinamento, percebeu-se uma grande diferença entre os resultados, dependendo dos valores de inicialização dos pesos da rede. Estes são inicializados com valores randômicos, a cada criação da rede pelo programa MATLAB. Cada inicialização faz com que o algoritmo de otimização chegue a uma solução diferente para a mesma amostra de treinamento.

Inicialmente optou-se em escolher o menor erro médio quadrático de treinamento como melhor solução do problema e com esta rede então, realizar a validação. Após realizar os testes com os resultados de treinamento e simulação, chegou-se à conclusão que, para a amostra selecionada, o menor erro médio quadrático de treinamento não resulta no menor erro médio quadrático na validação.

Tabela 4.3 – Erro treinamento x Erro validação

Índice de treinamento	MSE Treinamento	Número de épocas de treinamento	MSE validação
1	9,039E-32	20	1,16E+06
2	1,6379E-31	16	2,18E+06
3	1,1307E-31	20	2,27E+06
4	1,9374E-31	19	2,00E+06
5	1,8615E-31	14	8,48E+05
6	1,6942E-31	11	1,54E+06
7	1,5652E-31	17	1,24E+06
8	1,2042E-31	17	2,18E+06
9	1,4285E-31	18	2,83E+06
10	2,2684E-31	16	2,32E+06
11	2,4984E-31	13	1,75E+06
12	1,5139E-31	13	2,25E+06
13	2,0828E-31	13	1,58E+06
14	3,6559E-31	14	2,22E+06
15	1,6214E-31	15	1,23E+06
16	2,6706E-31	16	2,06E+06
17	1,3701E-31	14	1,14E+06
18	1,0351E-31	18	2,31E+06
19	1,136E-31	20	2,44E+06
20	1,5992E-31	15	1,17E+06
21	2,241E-31	13	9,44E+05
22	1,8821E-31	16	1,71E+06
23	1,3092E-31	15	1,83E+06
24	1,246E-31	20	1,29E+06
25	1,4858E-31	14	2,09E+06
26	1,1064E-31	21	1,93E+06
27	1,4033E-31	21	1,43E+06
28	1,5631E-31	20	2,20E+06
29	1,1636E-31	16	1,29E+06
30	4,9559E-31	13	1,36E+06
31	1,8402E-31	18	2,47E+06
32	1,7138E-31	14	7,38E+05
33	1,3685E-31	13	4,98E+05
34	3,6535E-31	14	2,04E+06
35	1,7938E-31	20	1,70E+06
36	1,9609E-31	21	1,37E+06
37	2,1365E-31	15	1,73E+06
38	1,8268E-31	13	2,51E+06
39	1,6E-31	17	2,11E+06
40	2,9638E-31	12	1,54E+06
41	2,8921E-31	16	2,45E+06
42	1,7857E-31	19	1,84E+06
43	2,0606E-31	13	2,05E+06
44	3,494E-31	13	8,08E+05
45	1,1838E-31	15	2,00E+06
46	2,1181E-31	20	1,89E+06
47	1,9816E-31	15	1,82E+06
48	4,0798E-31	13	1,57E+06
49	1,8773E-31	16	4,34E+05
50	2,4367E-31	20	2,07E+06

Fonte: do autor.

Esta constatação pode ser observada na Tabela 4.3, onde há a compilação dos MSE de treinamento e validação para 50 inicializações randômicas diferentes da rede MLP com 4 meses de histórico (20 entradas) e 22 neurônios na camada oculta. Percebe-se que o primeiro treinamento teve o menor MSE, 9,039e-32. Porém este treinamento obteve o oitavo menor MSE da validação. Já o menor MSE de validação, 4,34e+5, foi obtido pelo treinamento, cujo MSE é o trigésimo melhor. Em função desta constatação, foi decidido realizar o treinamento e validação para todas

as iterações de treinamento, escolhendo-se a rede com o menor MSE de validação para a avaliação do desempenho final. Zhang (2004) sugere a utilização de várias inicializações randômicas para a obtenção da melhor solução.

Definido o critério de seleção do melhor desempenho para cada alteração da rede, as simulações realizadas produziram os resultados que podem ser vistos na Tabela 4.4. Os erros calculados nesta tabela são medidos com os dados não normalizados e referentes apenas ao período de validação.

Tabela 4.4 – Resultados obtidos pelas redes MLP

Histórico da entrada da rede	Neurônios na camada oculta	Índice de treinamento para menor MSE validação	MSE	MAD	MAPE
3 meses	14	32	7,48E+05	673,07	158,0%
	18	2	1,11E+06	814,20	147,2%
	22	1	9,30E+05	723,04	102,0%
	26	28	7,19E+05	669,26	150,1%
	30	33	6,49E+05	565,00	108,9%
4 meses	14	10	5,30E+05	558,16	98,9%
	18	37	9,47E+05	687,90	93,6%
	22	49	4,34E+05	499,41	81,8%
	26	26	7,90E+05	702,32	70,7%
	30	48	6,19E+05	557,06	103,9%
6 meses	14	26	7,40E+05	678,51	202,1%
	18	50	7,16E+05	609,50	182,1%
	22	4	6,94E+05	618,28	160,1%
	26	48	3,91E+05	534,29	147,5%
	30	6	8,50E+05	646,38	93,2%

Fonte: do autor.

As simulações (Tabela 4.4) mostram que o modelo com 6 meses de histórico obteve o menor MSE (3,91E+05). Já o modelo com 4 meses de histórico obteve o menor MAPE e MAD: 81,8% e 499,41, respectivamente.

Observa-se nos resultados que não há uma relação entre número de neurônios na camada interna e o desempenho. Para 3 meses de histórico, o melhor desempenho (MSE) ocorreu com 30 neurônios na camada interna. Para 4 meses de histórico, o melhor desempenho (MSE) ocorreu com 22 neurônios. Já para a

simulação com 6 meses de histórico, o melhor desempenho (MSE) ocorreu com 26 neurônios.

Os gráficos da Figura 4.3 mostram o comportamento da simulação com os melhores desempenhos para as redes neurais MLP. A escala do gráfico mostrada está normalizada, para proteger os dados da empresa. A validação da rede, e onde são realizadas as medições de erro, ocorre entre os intervalos 28 a 47.

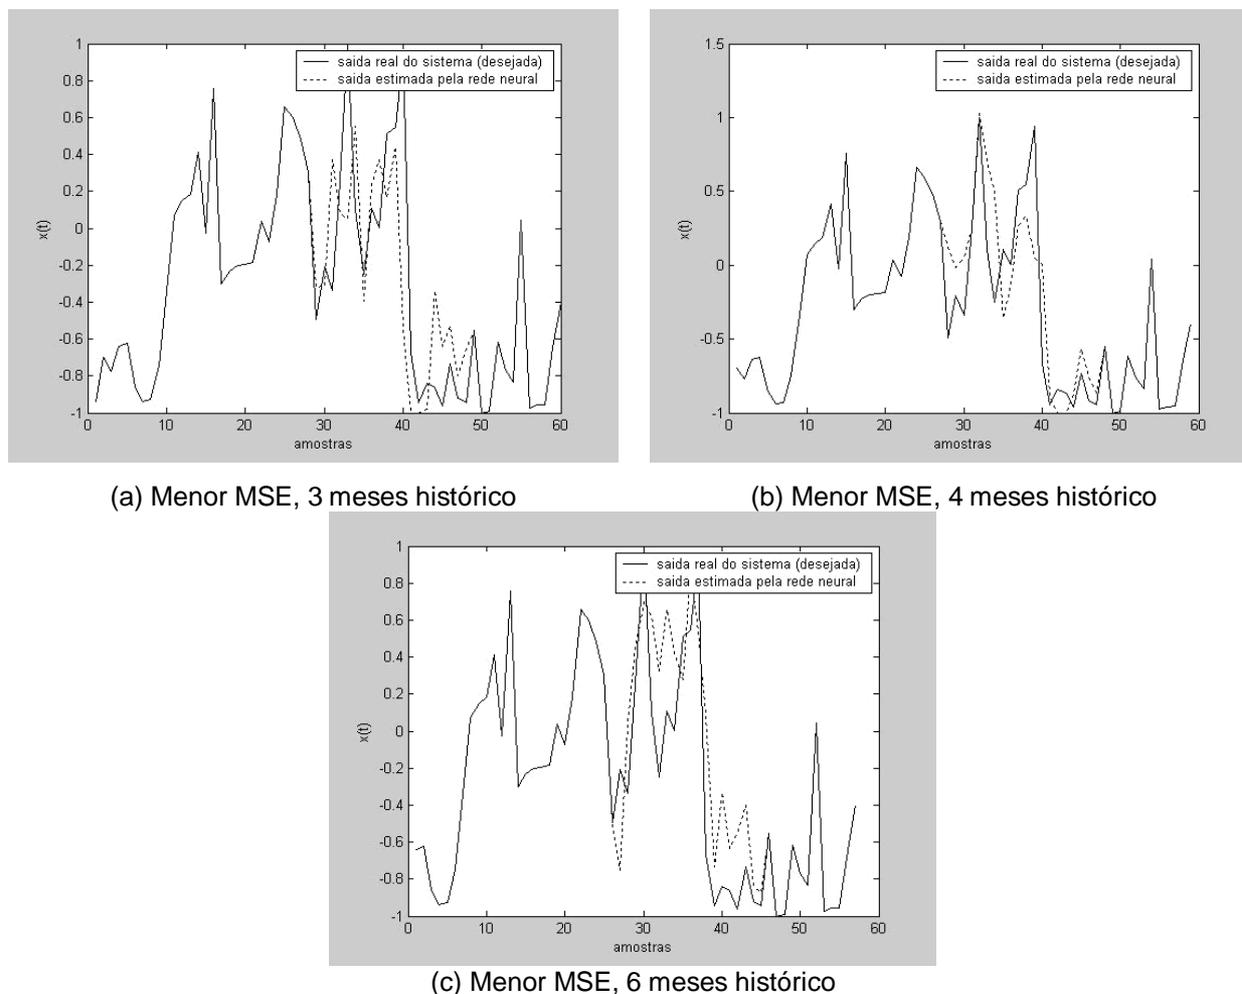


Figura 4.3 – Gráfico saída real x saída estimada das redes MLP.
Fonte: do autor

4.2.2. Resultado das redes RBF

Definidas as redes RBF, as amostras de treinamento e validação, é realizado o treinamento e a simulação com os dados para a comparação dos resultados.

O treinamento é executado pelo programa MATLAB, sendo incrementado o número de neurônios até que seja atingido um SSE menor que a meta estabelecida (no caso $1e-10$). Após o treinamento é realizada uma simulação e uma medição dos erros. Concluído, é realizada a próxima iteração de treinamento e simulação, incrementando-se a distância do centro (*Spread*) da rede.

Os resultados foram divididos em 3 tabelas:

- Tabela 4.5: Resultado da simulação com 3 meses de histórico de entrada da rede (ou seja, 15 variáveis de entrada). O melhor resultado foi obtido com a distância do centro 1,50, com MSE $8,79e+5$. Neste parâmetro também ocorreu o melhor MAPE, 150,76%.
- Tabela 4.6: Resultado da simulação com 4 meses de histórico de entrada da rede (ou seja, 20 variáveis de entrada). O melhor resultado foi obtido com a distância do centro 1,75, com MSE $8,28e+5$. Já o melhor MAPE (80,92%) foi obtido com uma distância do centro de 2,25.
- Tabela 4.7: Resultado da simulação com 6 meses de histórico de entrada da rede (ou seja, 30 variáveis de entrada). O melhor resultado foi obtido com a distância do centro 1,00, com MSE $9,21e+5$. Com a distância do centro em 1,50 ocorreu o melhor MAPE, de 91,15%.

Tabela 4.5 – Resultados obtidos pelas redes RBF com 3 meses de histórico

Histórico da entrada da rede	Distância do Centro	Número Neurônios camada oculta	MSE	MAD	MAPE
3 meses	0,25	39	9,11E+05	803,26	300,05%
	0,50	39	1,18E+06	916,63	354,80%
	0,75	39	3,61E+06	1649,70	537,06%
	1,00	39	7,42E+07	7841,70	1810,80%
	1,25	39	1,52E+06	1022,40	309,96%
	1,50	39	8,79E+05	702,52	150,76%
	1,75	39	1,23E+06	826,94	189,11%
	2,00	39	1,47E+06	889,70	208,63%
	2,25	39	8,16E+06	2373,10	634,66%
	2,50	39	4,68E+06	1743,10	481,50%
	2,75	39	1,35E+06	820,25	178,12%
	3,00	39	9,79E+06	2446,20	690,68%

Fonte: do autor.

Com a variação do número de entradas da rede RBF de 15, 20 e 30, o número de neurônios atingidos para o treinamento foi praticamente o mesmo, variando de 36 a 39.

Os gráficos da Figura 4.4 mostram o comportamento da simulação dos melhores desempenhos (MSE) das redes RBF. A escala do gráfico mostrada está normalizada, para proteger os dados da empresa.

Tabela 4.6 – Resultados obtidos pelas redes RBF com 4 meses de histórico

Histórico da entrada da rede	Distância do Centro	Número Neurônios camada oculta	MSE	MAD	MAPE
4 meses	0,25	38	1,08E+06	900,05	405,36%
	0,50	38	8,58E+05	784,07	279,70%
	0,75	38	8,32E+05	765,61	270,53%
	1,00	38	9,57E+05	830,94	292,37%
	1,25	38	2,37E+06	1286,10	413,40%
	1,50	38	8,56E+06	2575,90	696,95%
	1,75	38	8,28E+05	665,26	136,93%
	2,00	38	1,00E+06	743,91	148,47%
	2,25	38	1,15E+06	703,52	80,92%
	2,50	38	1,21E+06	746,82	91,15%
	2,75	38	1,33E+06	798,05	91,08%
3,00	38	1,86E+07	3460,40	997,73%	

Fonte: do autor.

Tabela 4.7 – Resultados obtidos pelas redes RBF com 6 meses de histórico

Histórico da entrada da rede	Distância do Centro	Número Neurônios camada oculta	MSE	MAD	MAPE
6 meses	0,25	36	1,07E+06	867,08	408,53%
	0,50	36	9,91E+05	807,11	363,18%
	0,75	36	1,14E+06	851,77	411,52%
	1,00	36	9,21E+05	780,70	270,87%
	1,25	36	2,55E+06	1156,60	95,00%
	1,50	36	2,55E+06	1151,40	91,15%
	1,75	36	1,08E+06	711,90	107,11%
	2,00	36	1,57E+06	985,53	440,12%
	2,25	36	5,37E+06	1933,80	776,62%
	2,50	36	1,16E+07	2868,30	1098,80%
	2,75	36	1,58E+07	3350,10	1270,40%
3,00	36	1,13E+08	9200,60	3222,80%	

Fonte: do autor.

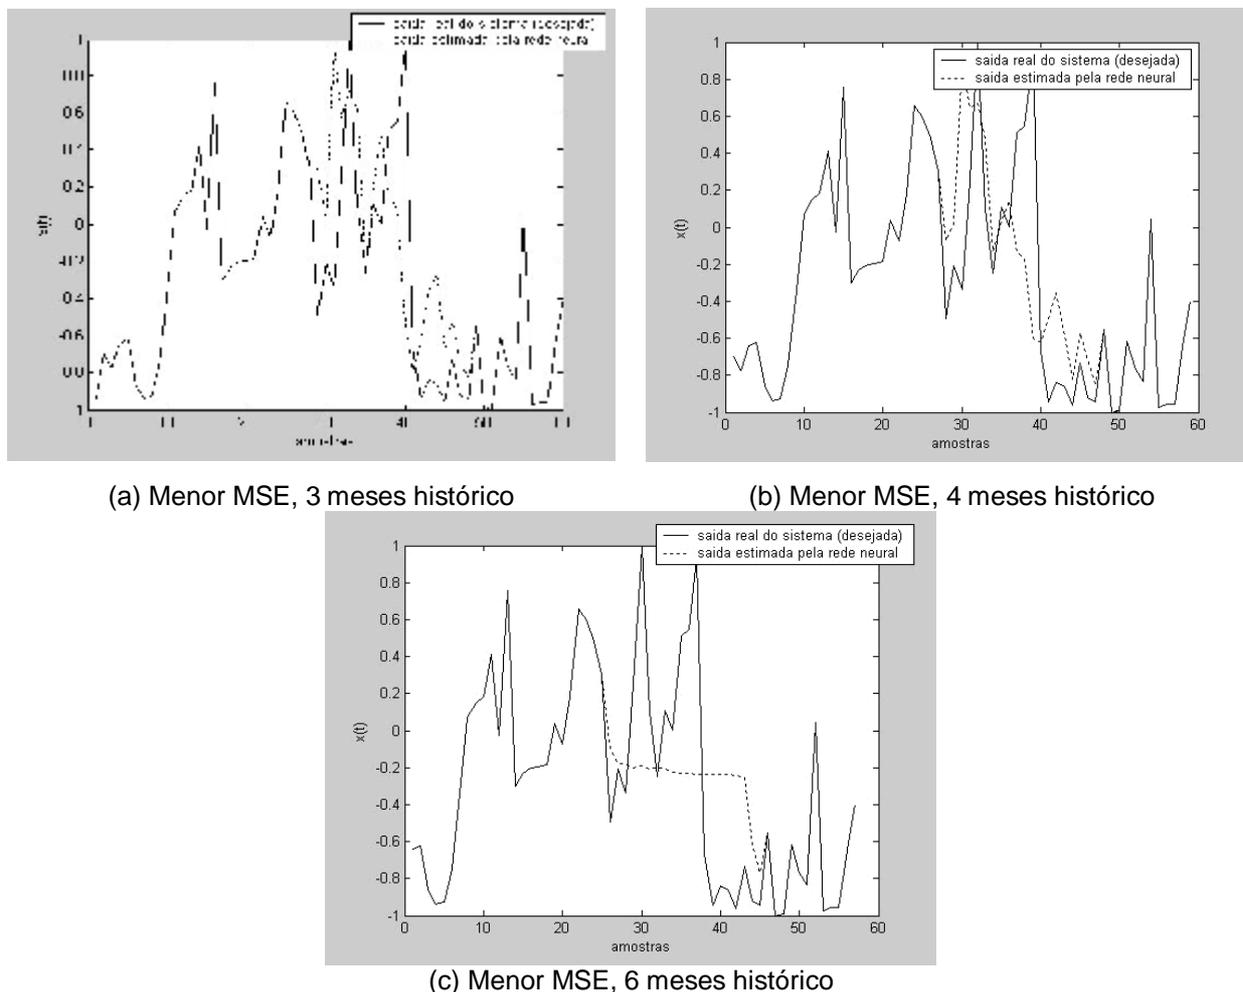


Figura 4.4 – Gráfico saída real x saída estimada das redes RBF.
Fonte: do autor

4.2.3. Comparação dos resultados obtidos com o da empresa em estudo

Nesta etapa realiza-se a comparação entre os melhores erros entre as redes MLP, RBF e os erros da empresa em estudo. Além do melhor MSE, a comparação também foi feita com o melhor MAPE de cada tipo de rede neural.

Para poder comparar as medições, os erros medidos da empresa em estudo são medidos nos mesmos meses das amostras do período de validação. Os gráficos da Figura 4.5 (c) e Figura 4.6 (c) mostram esta amostra. Fora deste período não foi realizado o cálculo de erro.

Na Tabela 4.8 está a comparação do melhor desempenho MSE obtido com a rede MLP, RBF e a previsão realizada pela empresa. As redes neurais obtiveram um melhor desempenho nas 3 medidas de erro, em comparação ao desempenho da previsão de demanda realizada pela empresa em estudo.

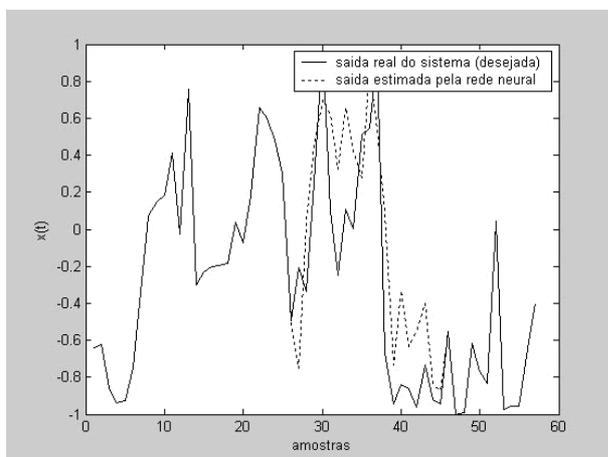
A maior diferença percentual ocorreu no MSE, onde a rede RNA MLP obteve um desempenho 72% melhor que a previsão da empresa em estudo. Os indicadores MAD e MAPE tiveram uma diferença percentualmente menor, 37% e 13% respectivamente.

Na Figura 4.5 está o gráfico das três previsões com melhor MSE (elaborada pela RNA MLP, RNA RBF e pela empresa em estudo). Em uma análise visual, percebe-se que o gráfico de saída estimada pela rede neural MLP está mais próxima da curva da saída real (desejada).

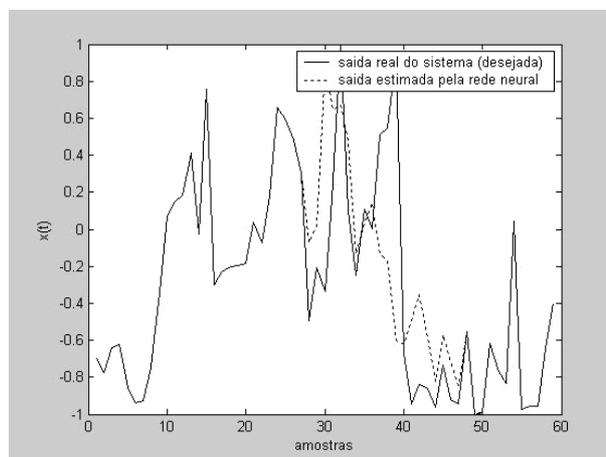
Tabela 4.8 – Comparação dos modelos de RNA com a empresa em estudo – melhor MSE

Método de previsão	MSE	MAD	MAPE
RNA MLP	3,91E+05	534,28	147,50%
RNA RBF	8,28E+05	780,70	136,93%
Empresa em estudo	1,36E+06	846,15	155,99%

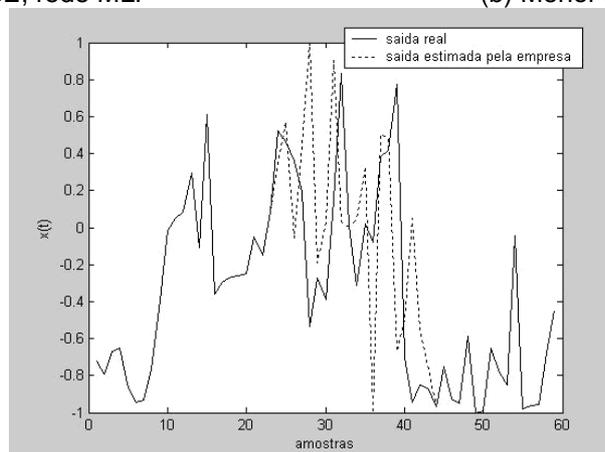
Fonte: do autor.



(a) Menor MSE, rede MLP



(b) Menor MSE, rede RBF



(c) empresa em estudo

Figura 4.5 – Gráfico saída real x saída estimada – melhor MSE.

Fonte: do autor

Na Tabela 4.9 está a comparação do desempenho das redes neurais em relação à empresa em estudo. Nesta comparação, as redes neurais também obtiveram melhor desempenho nos três indicadores de erro em relação aos da empresa em estudo.

A diferença mais significativa está no MAPE, onde as redes obtiveram um MAPE aproximadamente 50% menor, em relação à previsão da empresa em estudo. Já no MSE e MAD as diferenças foram percentualmente menores, 42% e 18% respectivamente.

Na Figura 4.6 está o gráfico das três previsões com melhor MAPE (elaborada pela RNA MLP, RNA RBF e pela empresa em estudo). Em uma análise visual, percebe-se que o gráfico de saída estimada pela rede neural MLP está mais próxima da curva da saída real (desejada).

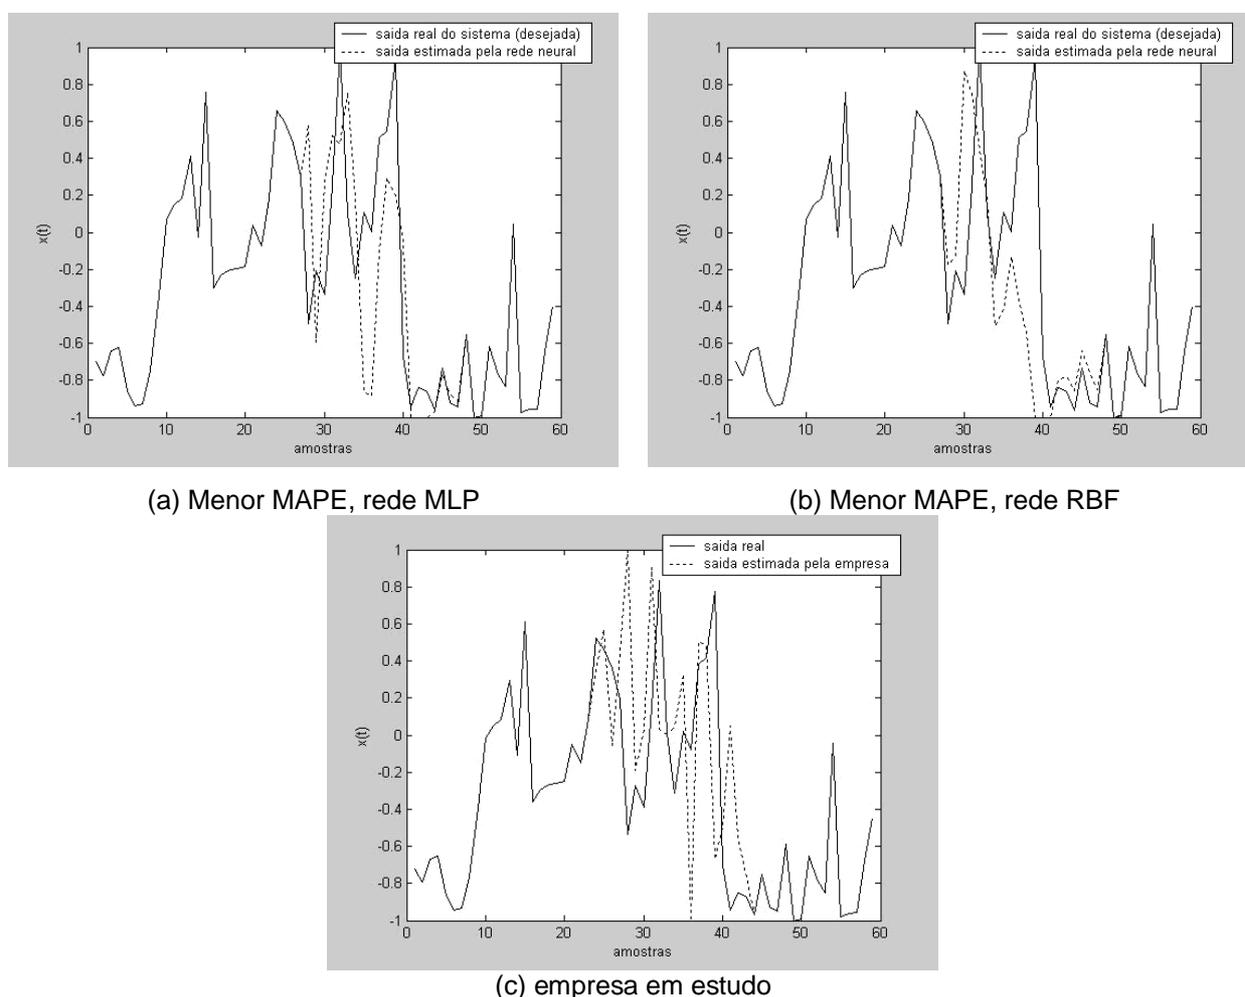


Figura 4.6 – Gráfico saída real x saída estimada – melhor MAPE.
Fonte: do autor

Tabela 4.9 – Comparação dos modelos de RNA com a empresa em estudo – melhor MAPE

Método de previsão	MSE	MAD	MAPE
RNA MLP	7,90E+05	702,32	70,70%
RNA RBF	1,15E+06	703,52	80,92%
Empresa em estudo	1,36E+06	846,15	155,99%

Fonte: do autor.

5. CONCLUSÃO

A pesquisa realizada buscou na literatura um método de previsão de demanda que pudesse auxiliar na definição da previsão de demanda futura de uma empresa fornecedora de equipamentos de telecomunicações. Mais especificamente, de equipamentos de transmissão para tecnologia celular GSM. Desta pesquisa inicial, concluiu-se que o método de previsão de demanda que utiliza redes neurais poderia ser utilizado com vantagem sobre os outros modelos para o mercado de telecomunicações.

As séries históricas utilizadas possuíam uma amostragem pequena (64 amostras), quando comparamos com outras séries utilizadas para previsões em outras aplicações, com centenas de amostras disponíveis. Esta pequena amostra é função do início recente da instalação destes equipamentos no Brasil.

Pelos resultados obtidos na pesquisa, a aplicação das redes neurais artificiais para a previsão de demanda dos equipamentos de transmissão para tecnologia celular GSM é promissora. Dois modelos de redes neurais foram estudados: redes neurais MLP e redes neurais RBF.

As redes neurais MLP têm uma melhor precisão nas previsões, porém exigem mais recursos computacionais para a realização do treinamento.

As redes neurais RBF apresentam um rápido treinamento. Para a previsão de demanda dos equipamentos estudados, ela não se mostrou tão eficiente quanto às redes MLP.

As redes neurais podem ter seu desempenho melhorado com um projeto de otimização dos parâmetros de definição das arquiteturas das redes neurais do MATLAB. Com algoritmos desenvolvidos manualmente, pode-se alterar outros parâmetros além dos oferecidos pelo programa MATLAB para redes neurais, além de agregar outros algoritmos, como algoritmos evolutivos, visando melhorar o desempenho.

Redes *neuro-fuzzy* também podem ser utilizadas para previsão de demanda, na tentativa de uma melhora de desempenho.

Reverendo os objetivos específicos iniciais da pesquisa, pode-se considerar:

- a pesquisa identificou um método de previsão de demanda que fosse adequado ao comportamento e disponibilidade da informação do produto estação rádio base;
- a pesquisa desenvolveu um modelo para o método de previsão de demanda escolhido para a realização da previsão de demanda de curto prazo. Nesta pesquisa o método escolhido foi o das redes neurais artificiais;
- durante a pesquisa foram selecionadas, através de entrevista, possíveis variáveis de entrada para o modelo. Após a listagem destas variáveis, realizou-se a busca de dados históricos para elas.
- a pesquisa propôs um modelo de previsão de demanda para curto prazo, comparando os resultados obtidos com o desempenho da previsão de demanda realizada pela empresa.

Reverendo o objetivo geral pode-se considerar que:

- a pesquisa estruturou e propôs a aplicação de um método de previsão de demanda mensal de equipamentos de infra-estrutura de telecomunicações (estação radio base).

Considerando os resultados obtidos na pesquisa, a previsão de demanda através de redes neurais para a demanda analisada não apresentou resultados precisos. Percentualmente, os melhores MAPE obtidos foram em torno de 70 a 80%. Mesmo com esse desempenho, os resultados obtidos ainda estão melhores que a previsão realizada pela empresa em estudo.

Apesar desses resultados, as redes neurais podem ser utilizadas para realizar a previsão de demanda. Considerando o sistema genérico de previsão de demanda apresentado na Figura 2.1, a presente ferramenta proposta seria utilizada no passo “Tratamento estatístico dos dados de vendas”. Estes dados seriam analisados e com base em outras informações, como por exemplo, dos clientes, dos concorrentes e do mercado, a empresa poderia decidir melhor qual seria a demanda futura para fins de planejamento de vendas, fábrica e suprimentos.

Quanto à aplicação prática em uma empresa, pode-se considerar:

- uma vez treinada e definida a rede neural, sua utilização é fácil e rápida. Pode-se utilizar um módulo para entrada dos dados e sua saída poderá, então, ser analisada em uma reunião de previsão de demanda.
- a compreensão dos dados da rede neural não é uma tarefa simples. Como a rede neural é uma “caixa preta”, não há como fazer uma análise da razão da saída ter tal comportamento. Este fator pode gerar um desconforto na defesa ou não das previsões realizadas pela ferramenta. Na prática, o desempenho da previsão de demanda da ferramenta seria o fator que influenciaria o grau de credibilidade que os gestores teriam nesta ferramenta de previsão.
- não existe a necessidade de possuir computadores velozes para realizar a simulação. Computadores mais rápidos são necessários na etapa de treinamento e construção do modelo.
- a empresa necessitaria manter uma pessoa com conhecimento em redes neurais artificiais para o gerenciamento da ferramenta. Isto é necessário, pois apenas esta pessoa poderia realizar novos treinamentos e aperfeiçoamentos na rede neural. Pessoas leigas em redes neurais não teriam esta capacidade.

Este estudo constatou que existe pouca quantidade de pesquisa sobre a demanda de produtos de telecomunicações e a demanda em negócios entre empresas (*business to business*). Isto gera oportunidade para pesquisas nesta área, na determinação do comportamento deste mercado o que auxiliaria no aprimoramento das ferramentas de previsão e até na pesquisa de outras ferramentas de previsão para este tipo de mercado.

Durante o desenvolvimento da presente pesquisa foram encontradas algumas dificuldades, cuja finalidade é auxiliar trabalhos futuros:

- a obtenção de dados para a seleção de variáveis é extremamente difícil. Empresas não divulgam dados a terceiros, alegando sigilo de informação. Caso haja uma variável que explique o comportamento da variável de saída, mas a informação não é disponível, a empresa terá que optar em realizar a medição por conta própria, o que implica em custos adicionais para a empresa.
- a utilização de dados (entrada) apenas disponíveis ao público pode limitar o desempenho de um modelo de previsão de demanda.

- para a implantação de um modelo de previsão de demanda, a fim de auxiliar na tomada de decisão da demanda futura é necessário uma mudança de paradigma na empresa, o que geraria resistência nas pessoas para a adoção do modelo, não havendo o aproveitamento dos benefícios de sua utilização.
- pelo histórico ruim da previsão de demanda da empresa, as pessoas que realizam a previsão de demanda crêem que a demanda nunca pode ser prevista e é muito incerta. Este pré-conceito também geraria uma resistência na implantação de novas ferramentas de previsão.

Este trabalho abre a oportunidade para um futuro aprofundamento na pesquisa de:

- separar componentes de tendência e sazonalidade da série de dados na tentativa de melhora do desempenho;
- buscar outras variáveis de entrada que possam ser utilizadas no modelo;
- aplicar modelos paralelos e maior alcance da previsão (por exemplo: $t+2$, $t+3$);
- avaliar o desempenho de outros métodos de previsão não abordados neste trabalho como, por exemplo, ajuste exponencial, Box-Jenkins.

REFERÊNCIAS

ACTIL, F.;RAT, A. Evaluation of neural network streamflow forecasting on 47 watersheds. **Journal of Hydrologic Engineering**, v.10, n.1, p.85-88, 2005.

ALFARES, H. K.; NAZEERUDDIN, M. Electric load forecasting: literature survey and classification of methods. **International Journal of Systems Science**, v.33, n.1, p.23-34, 2002.

ANDERSON, J. A. A simple neural network generating an interactive memory. **Mathematical Biosciences**, v.14, n.3-4, p 197-200, 1972.

ARMSTRONG, J. S. Selecting Forecasting Methods. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Dordrecht: Kluwer Academic Publishers, 2001.

ATIYA, A.F.; EL-SHOURA, S. M.; SHAHEEN, S. I.; EL-SHERIF, M. S. A comparison between neural-network forecasting techniques - Case study: River flow forecasting. **IEEE Trans. on Neural Networks**, v.10, n.2, p.402-409, 1999.

BISHOP, C.M. **Neural networks for pattern recognition**. 1. ed. Oxford: Oxford University Press, 1995.

BORS, A.G. **Introduction to radial basis function (RBF) networks**. YORK, UK. Disponível em: <http://users.rsise.anu.edu.au/%7EEdaa/courses/GSAC6017/rbf.pdf>
Acesso em: 20 abr 2007.

BRYMAN, A. **Research methods and Organization studies**. Unwin Hyman: London, 283p, 1989.

CALÔBA, G.; CALÔBA, L.; SALIBY, E. Cooperação entre redes neurais artificiais e técnicas clássica para previsão de demanda de uma série de vendas de cerveja na Austrália. **Pesquisa Operacional**, v.22, n.3, p.345-358, jul-dez 2002.

CARBONNEAU, R.; LAFRAMBOISE, K.; VAHIDOV, R. Application of machine learning techniques for supply chain demand forecasting. **European Journal of Operational Research**, v.184, n.3, p.1140-1154, 2008.

CHOPRA, S.; MEIDL, P. **Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação**. São Paulo: Prentice Hall, 2003.

CORRÊA, H.L.; CORRÊA, C.A. **Administração de produção e operações: manufatura e serviços: uma abordagem estratégica**. São Paulo: Atlas, 2004.

CORRÊA, H., GIANESI, I., CAON, M. **Planejamento, Programação e Controle da Produção**. São Paulo: Atlas, 2001.

CORTEZ, P.; ROCHA, M.; ALLEGRO, F.; NEVES, J. Real-Time Forecasting by Bio-inspired Models. **Proceedings of the Second IASTED International Conference on Artificial Intelligence and Applications (AIA 2002)**. Málaga, Espanha, p. 52-57, Set 2002.

COSTA, H.R.N. **Aplicação de técnicas de inteligência artificial em processos de fabricação de vidro**. São Paulo, 2006, 271 f. Tese (Doutorado em Engenharia de Sistemas), Universidade de São Paulo.

CYBENKO, G. Approximation by superposition of a Sigmoidal Function. **Mathematics of Control Signals and Systems**, Springer, London, v.2, n.4, p. 303-314, Dez 1989.

DE GROOT, C.; WURTZ, D. Analysis of univariate time series with connectionist nets: a case study of two classical examples. **Neurocomputing**, v.3, n.4, p. 177-192, 1991.

DEMUTH, H.; BEALE, M. **Neural Network Toolbox User's Guide**. Natick: The Mathworks Inc, 2000.

DOBZANSKI, L.A.; TRZASKA, J. Application of neural networks for the prediction of continuous cooling transformation diagrams. **Computational Materials Science**, v.30, n.3-4, p.251-259, 2004.

FILDES, R.; KUMAR, V. Telecommunications demand forecasting—a review. **International Journal of Forecasting**, v.18, n.4, p.489-522, Oct-Dec 2002.

GERSHENFELD, N.A.; WEIGEND, A.S. The future of time series: learning and understanding. In: GERSHENFELD, N.A., WEIGEND, A.S. **Time Series Prediction: Forecasting the Future and Understanding the Past**. Addison-Wesley, Reading, MA, p. 1-70, 1993.

GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 1991.

GROSSBERG, S. How does a brain build a cognitive code? **Psychological Review**, v.87, p.1-51, 1980.

HAGAN, M.; MENHAJ, M. Training feedforward networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v.5, n.6., p.989-993, 1994.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. **Neural Network Design**. Boston: PWS Publishing Company, 1996.

HAIDA, T.; MUTO, S. Regression based peak load forecasting using a transformation technique. **IEEE Transactions on Power Systems**, v.9, n.4, p.1788-1794, 1994.

HANKE J.E.; WCHERN D.W.; REITSCH, A.G. **Business Forecasting**. New York, Practice Hall, 2001.

HAYKIN, S. **Redes Neurais: princípios e práticas**, 2.ed, Porto Alegre: Editora Bookman. 2001.

HILL, T.; MARQUEZ, L.; O'CONNOR, M.; REMUS, W. Artificial neural networks for forecasting and decision making. **International Journal of Forecasting**, v.10, p.5-15, 1994.

HILL, T.; O CONNOR, M.; REMUS, W. Neural Network Models for Time Series Forecasts. **Management Science**, v.42, n.7, p.1082-1092, Jul 1996.

HIPPERT, H.; PEDREIRA, C. Estimating temperature profiles for short-term load forecasting: neural networks compared to linear models. **IEE Proc.-Gener. Transmission Distribution**, v.151, n.4, p.543-547, Jul 2004.

HOPFIELD, J.J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Science**. v. 79, p. 2554-2558, 1982.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v.2, n.5, p. 359-366, 1989.

JAIN, C. L. Which forecasting model should we use? **Journal of Business Forecasting Methods & Systems**, v.19, n.3, p.2-6, 2000.

KAHN, K. B.; MENTZER, J. T. Forecasting in consumer and industrial markets. **Journal of Business Forecasting Methods & Systems**; v.14, n.2, p.21-28, 1995

KARTALOPOULOS, S. **Understanding neural networks and fuzzy logic**: basic concepts and applications. New York: IEEE, 1996.

KOHONEN, T. Correlation matrix memories. **IEEE Transactions on Computers**. v. C-21, p. 353-359, 1972.

KUO, C.; REITSCH, A. Neural networks vs. conventional methods of forecasting. **Journal of Business Forecasting Methods & Systems**; v. 14, n. 4, p.17-22, Dez 1995 - Mar 1996.

LAKATOS, E.M.; MARCONI, M.A. **Fundamentos de metodologia científica**. São Paulo: Atlas, 2001.

LAPEDES, A.; FARBER, R. How neural nets work in Anderson, D.Z., **Neural Information Processing Systems, American Institute of Physics**, New York, p. 442-456, 1988.

LATTA, M. How to Forecast Demand in Tender Markets. **The Journal of Business Forecasting**, v.21, n.1, p.8-11, 2002.

LEE, S. e KIL, R. A gaussian potential function network with hierarchically self-organizing learning. **Neural Networks**, v.4, n.2, p.207-224, 1991.

LEONDES, C. **Algorithms and architectures**. San Diego: Academic Press, vol. 1, 1998.

LEVENBERG, K. A method for the solution of certain problems in least squares. **Quart. Appl. Math.**, v.2, p.164-168, 1944

LYNN, G.S.; SCHNAARS, S.P.; SKOV, R.B. Survey of new products forecasting practices in industrial high technology and low technology businesses. **Industrial Marketing Management**, v.28, n.6, p.565-571, 1999.

MAKRIDAKIS, S.G. **Forecasting, planning, and strategy for the 21st century**. New York: The Free Press, 1990.

MAKRIDAKIS, S.G.; WHEELWRIGHT, S.C. Forecasting: Issues & Challenges for Marketing Management. **Journal of Marketing**, v.41, n.4, p.24-38, 1977.

MARQUARDT, D. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v.11, n.2, p.431-441, 1963.

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

MINSKY, M.L.; PAPERT, S.A. **Perceptrons**. Cambridge: MIT Press, 1969.

MOODY, J.; DARKEN, C. Fast learning in networks of locally-tuned processing units. **Neural Computation**. v.1, n.2, p.281-294, 1989.

MONTANES, E.; QUEVEDO, J.; PRIETO, M.; MENENDEZ, C. Forecast Time Series Combining Machine Learning and BOX-Jenkins Time Series. **Advantages in Artificial Intelligence – IBERAMIA 2002**, v.2527, p.491-499, 2002

MURAT, Y.S., CEYLAN, H. Use of artificial neural networks for transport energy demand modeling. **Energy Policy**, v.34, n.17, p. 3165-3172, 2006.

NAKANO, D.N.; FLEURY, A.C.C. **Métodos de Pesquisa na Engenharia da Produção**. Escola Politécnica da Universidade de São Paulo, 1996.

NAM, K.; SCHAEFER, T. Forecasting international airline passenger traffic using neural networks. **Logistics and Transportation**, v.31, n.3, p. 239-251, 1995.

NARENDA, K.S.; PARTHASARATHY, K. Identification and control of Dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, v.1, n.1, p.4-27, 1990.

OLIVEIRA, S. L. **Tratado de Metodologia Científica**. São Paulo: Pioneira, 1997

ORR, M.J.L. **Introduction to radial basis function networks**. Technical Report, Centre for Cognitive Science, Edinburgh University, Scotland, UK, 1996. Disponível em <http://www.anc.ed.ac.uk/rbf/intro/intro.html>. Acesso em 20/02/2007.

OZTURKMEN, Z. Forecasting in the rapidly changing telecommunications industry: AT&T experience. **The Journal of Business Forecasting**, v.19, n.3, p.3-5, 2000.

PALMER, A.; MONTAÑO, J.J.; SESÉ, A. Designing an artificial neural network for forecasting tourism time series. **Tourism Management**, v.27, n.5, p.781–790, 2006.

PINTO, J. **Métodos de demonstrações 2**. Disponível em: http://membros.aveiro-digital.net/pinto/matematica/escola/05-06/12_Ano/Dem/demonstracoes_2.pdf. Acesso em: 30/04/2007.

POPPER, K. R. **A Lógica da Pesquisa Científica**. São Paulo: Cultrix, 1996.

RAO, C., ALI, J. Neural Network model for database marketing in the new global economy. **Marketing Intelligence and Planning**, v.20, n.1, p. 35-43, 2002

RANGANATHAN, A. **The Levenberg-Marquardt Algorithm**. Disponível em <http://www.cc.gatech.edu/~ananth/docs/lmtut.pdf>. Acesso em: 26/02/2008.

REEVES, C.R., BUSH, D.R. Using genetic algorithms for training data selection in RBF networks. In: LIU, H., MOTODA, H., **Instance selection and construction for data mining**. Massachusetts: Kluwer Academic Publishers, 2001.

REEVES, C.R., TAYLOR, S.J. Selection of training sets for neural networks by a genetic algorithm. In: EIDEN, A.E., BÄCK, T. SCHOENAUER, M., SCHWEFEL, H.P., **Parallel problem solving from nature**. Berlin: Springer, 1998.

RITZMAN, L.; KRAJEWSKI, L. **Administração da Produção e Operações**. São Paulo: Practice Hall, 2004.

ROSENBLATT, F. The Perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v.65, n.6, p.386- 408, 1958.

ROSS, A. Why bad forecasts can be good for business. **IEE Manufacturing Engineer**, v.83, n.3, p.26-29, Jun-Jul 2004.

ROWEIS, S. **Levenberg Marquardt Optimization**. Disponível em www.cs.toronto.edu/~roweis/notes/lm.pdf. Acesso em 20/02/2008.

RUMELHART, D.E.; McCLELLAND, J.L. Parallel Distributed Processing: Explorations. In: **Microstructure of Cognition**, v. 1. Cambridge: MIT Press, 1986.

SHARDA, R.; PATIL, R.B. Neural Networks as forecasting experts: An empirical test. **Proceedings of the International Joint Conference on Neural Networks**, Washington, v.II, p. 491-494, 1990.

SHEPHERD, A.J.. **Second-order Methods for Neural Networks**. New York: Springer, 1997.

SILVA, C.S. **Previsão Multivariada da Demanda horária de Água em Sistemas Urbanos de Abastecimento**. São Paulo, 2003, 303 f. Tese (Doutorado em Engenharia Civil) - Faculdade de Engenharia Civil, Universidade Estadual de Campinas.

SILVA, E.L.; MENEZES, E.M. **Metodologia da pesquisa e elaboração da dissertação**. Florianópolis: LED/UFSC, 2000.

SIPPER, D.; BULFIN, R. **Production: planning, control and integration**. Singapura: McGraw-Hill, 1997.

SKAPURA, D. **Building Neural Networks**. New York: ACM Press, 1996.

SRINIVASAN, D.; LIEW, A.C.; CHANG, C.S. A neural network short-term load forecaster. **Electric Power Systems Research**, v. 27, n.3 , p.227-234, 1994.

TATIBANA, C.Y.; KAETSU, D. Y. **Homepage de Redes Neurais**. Disponível em: <http://www.din.uem.br/ia/neurais/#neural>. Acesso em: 10 de abril de 2007

TAN, Y.; VAN CAUWENBERGHE, A. Neural-network-based d-step-ahead predictors for nonlinear systems with time delay. **Engineering Applications of Artificial Intelligence**, v.12, n.1, p. 21-35, 1999.

TELECO. Disponível em www.teleco.com.br. Acesso em 21/02/2008.

TRAUTWEIN JR., B. **Avaliação de Métodos para Previsão de Consumo de Água para Curtíssimo Prazo**: Um Estudo de Caso em Empresa de Saneamento. Curitiba, 2004, 123f. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Pontifícia Universidade Católica do Paraná, Programa de Pós-Graduação em Engenharia de Produção e Sistemas.

TSENG, C.M.; JAN, C.D.; WANG, J.S.; WANG, C.M. Application of artificial neural networks in typhoon surge forecasting. **Ocean Engineering**, n.34, p. 1757-1768, 2007.

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

TUDE, E.; SOUZA, J.; VIEIRA, D. **Telefonia Celular no Brasil: Dados 2000-2006**. Relatório TELECO, 2007.

VALVERDE RAMIREZ, M.C.; CAMPOS VELHO, H.; FERREIRA, N.J. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. **Journal of Hydrology**, v.301, n.1-4, p.146-162, 2005

VILLARES, R.M.; NAKANO, D.N. **Metodologia de Pesquisa e a Engenharia da Produção**. Escola Politécnica da Universidade de São Paulo, ENEGEP 1998.

WEIGEND, A.S.; HUBERMAN, B.A.; RUMELHART, D.E. Predicting sunspots and exchange rates with connectionist networks. In CASDAGLI, M. EUBANK, S. **Nonlinear Modeling and Forecasting**. Redwood City: Addison-Wesley, p.395-432, 1992.

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. **IRE WESCON Convention Record**, v.4, p.96-104, 1960.

WIDROW, B.; RUMELHART, D.E.; LEHR, M.A. Neural Networks: Applications in industry, business and science. **Communications of the ACM**, v.37, n.3, p.93-105, 1994.

XU, K.; XIE, M.; TANG, L.C.; HO, S.L.. Application of neural networks in forecasting engine systems reliability. **Applied Soft Computing**, v.2, n.4, p. 255-268, 2003.

YAO, J.T.; TAN, C.L. Guidelines for financial forecasting with neural networks. **Proceedings of International Conference on Neural Information Processing**, Shanghai, p. 772-777, 2001.

YIN, R. K. **Case study research: design and methods**. Thousand Oaks, SAGE Publications, 1994.

ZHANG, G.P. Business Forecasting with Artificial Neural Networks: An Overview. In: **Neural Networks in Business Forecasting**. Hershey, USA: IDEA GROUP PUBLISHING, 2004.

ZHANG, G.; PATUWO, B.E.; HU, M.Y. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, v.14, n.1, p.35-62, Mar 1998

ZHANG, X. Time series analysis and prediction by neural networks. **Optimization Methods and Software**, v.4, n.2, p.151-170, 1994.