

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ADMINISTRAÇÃO
DEPARTAMENTO DE CIÊNCIAS ADMINISTRATIVAS**

GRACE LISSARASSA DOS SANTOS

**ANÁLISE DE MÉTODOS DE PREVISÃO DE DEMANDA PARA
EMPRESA FABRICANTE DE PRODUTOS DE TRANSMISSÃO E
DISTRIBUIÇÃO DE ENERGIA**

Porto Alegre

2010

GRACE LISSARASSA DOS SANTOS

**ANÁLISE DE MÉTODOS DE PREVISÃO DE DEMANDA PARA
EMPRESA FABRICANTE DE PRODUTOS DE TRANSMISSÃO E
DISTRIBUIÇÃO DE ENERGIA**

Trabalho de Conclusão de Curso apresentado ao Departamento de Ciências Administrativas de Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do grau de Bacharel em Administração.

Orientador: Prof^a Denise Lindstrom Bandeira

Porto Alegre

2010

Dedico este trabalho, com todo o meu amor, à minha mãe, que sempre esteve ao meu lado e ao de minhas irmãs, dando suporte e carinho.

À minha irmã Graziela, agradeço o incentivo que me impulsionou em diversos momentos da vida.

AGRADECIMENTOS

Em primeiro lugar, agradeço à Professora Denise Lindstrom Bandeira que, como orientadora e amiga, dedicou seu tempo e partilhou de seu conhecimento para me auxiliar, colaborando com grandes ideias e sugestões para o desenvolvimento do presente trabalho, esclarecendo dúvidas e norteando minhas ações para melhor executá-lo.

À Escola de Administração da Universidade Federal do Rio Grande do Sul e a todos seus professores e funcionários que, de modo geral, contribuem para que este curso de graduação seja reconhecido como um dos melhores do país.

Aos meus familiares e amigos que participaram, cada um de sua maneira, na conquista deste sonho. Sonho iniciado em 2006, quando ingressei na UFRGS, e que agora se concretiza, com a obtenção do diploma de graduação no curso de Administração.

“Um dia uma criança chegou diante de um pensador e perguntou-lhe: “Que tamanho tem o Universo?”. Acariciando a cabeça da criança, ele olhou para o infinito e respondeu: “O Universo tem o tamanho do seu mundo”. Perturbada, ela novamente indagou: “Que tamanho tem meu mundo?” O pensador respondeu: “Tem o tamanho dos seus sonhos.” Se seus sonhos são pequenos, sua visão será pequena, suas metas serão limitadas, seus alvos serão diminutos, sua estrada será estreita, sua capacidade de suportar as tormentas será frágil. Os sonhos regam a existência com sentido. Se seus sonhos são frágeis, sua comida não terá sabor, suas primaveras não terão flores, suas manhãs não terão orvalho, sua emoção não terá romances. A presença dos sonhos transforma os miseráveis em reis, faz dos idosos, jovens, e a ausência deles transforma milionários em mendigos, faz dos jovens idosos. Os sonhos trazem saúde para a emoção, equipam o frágil para ser autor da sua história, fazem os tímidos terem golpes de ousadia e os derrotados serem construtores de oportunidades. Sonhe!”

Augusto Cury

LISTA DE FIGURAS

Figura 1 – Previsão como parte integrante do planejamento dos negócios	27
Figura 2 – Exemplos de tendências temporais.....	33
Figura 3 – Esquema básico do sistema nervoso	38
Figura 4 – A célula piramidal	39
Figura 5 – O limiar de disparo de um neurônio.....	40
Figura 6 – Modelo de neurônio artificial.....	41
Figura 7 – Hiperplano demonstrando o limiar de decisão	42
Figura 8 – Arquiteturas de redes neurais artificiais.....	43
Figura 9 – Esquema de seleção de método de previsão.....	50
Figura 10 – Correlação entre variáveis - linhas em foco	63
Figura 11 – Definição dos dados para o modelo RNA	65
Figura 12 – Definição da configuração para treinamento da RNA	66
Figura 13 – Obtendo as previsões por meio da RNA	66

LISTA DE TABELAS

Tabela 1 – Média móvel e índice sazonal da série histórica de vendas no período de 2007 a 2009	57
Tabela 2 – Índices sazonais normalizados.....	58
Tabela 3 – Cálculo dos coeficientes angular e linear	60
Tabela 4 – Recomposição para o período de 2007 a 2009	61
Tabela 5 – MAPE das previsões geradas com treinamento de 90% dos dados - RNA.....	69

LISTA DE QUADROS

Quadro 1 – Evolução anual das vendas.....	56
Quadro 2 – Coeficientes angular e linear	59
Quadro 3 – Variáveis independentes para a rede neural.....	62
Quadro 4 – Média MAPE das previsões - treinamento	64
Quadro 5 – MAPE das previsões - Decomposição clássica.....	68
Quadro 6 – MAPE das previsões - RNA	69
Quadro 7 – Comparativo dos erros das previsões	71

LISTA DE GRÁFICOS

Gráfico 1 – Correlação entre variáveis dependentes e independentes	63
Gráfico 2 – Comparativo previsto e realizado - decomposição clássica.....	67
Gráfico 3 – Comparativo previsto e realizado - RNA.....	70

GLOSSÁRIO

ABDIB	Associação Brasileira de Infraestrutura e Indústrias de Base
ABINEE	Associação Brasileira da Indústria Elétrica e Eletrônica
AIE	Agência Internacional de Energia
BACEN	Banco Central do Brasil
BNDES	Banco Nacional do Desenvolvimento
COFINS	Contribuição para o Financiamento da Seguridade Social
FIPE	Fundação Instituto de Pesquisas Econômicas
FOB	Free On Board, em português, Livre a bordo
FOT	Free On Truck, em português, Livre no caminhão ou trem
GRNN	Generalized Regression Neural Network, em português, Rede neural de regressão generalizada
GTD	Geração, Transmissão e Distribuição
ICMS	Imposto sobre Circulação de Mercadorias e Serviços
IF	Instrução Financeira
II	Imposto de Importação
IPI	Imposto sobre Produtos Industrializados
ISO	International Organization for Standardization, em português, Organização internacional para padronização
KC	Selling Costs, em português, Custos de venda
KF	Other Production Overheads, em português, Outros custos produtivos indiretos
KG	Administrative Overheads, em português, Despesas administrativas
KM	Sourcing Overheads, em português, Custos operacionais de suprimentos
KPM	Other Production Overheads, em português, Outros custos produtivos indiretos
KS	Management Fees Recovery, em português, Custos operacionais de gerenciamento
KT	Research and Development Costs, em português, Custos com pesquisa e desenvolvimento
LME	London Metal Exchange

MAPE	Mean Absolute Percentual Error, em português, Média do erro percentual absoluto
MCP	McCulloch e Pitts
MDIC	Ministério do Desenvolvimento, Indústria e Comércio Exterior
MLF	Multi-Layer Feedforward, em português, Perceptron de múltiplas camadas
MSQ	Mean Square, em português, Média quadrática
MVA	Mega Volt Ampère
OHSAS	Occupational Health e Safety Advisory Services, em português, Serviços de avaliação de saúde e segurança ocupacional
ONS	Operador Nacional do Sistema Elétrico
PIS	Programa de Integração Social
PNB	Produto Nacional Bruto
PTR	Power Transformers and Reactors, em português, Transformadores de poder e reatores
RBNF	Radial Basis Function Network, em português, Rede neural de base radial
RNAs	Redes Neurais Artificiais
SECEX	Secretaria de Comércio Exterior
SRZD	Sidney Rezende
TCT	AREVA T&D Brasil, unidade de Canoas - RS
WEO	World Energy Outlook

RESUMO

Atualmente, a previsão de demanda é uma atividade crítica e, ao mesmo tempo, essencial no contexto instável em que as empresas atuam. Sendo assim, uma previsão eficaz é sinônimo de decisões mais assertivas e seguras para seus tomadores de decisão. O presente trabalho tem por finalidade realizar uma análise comparativa e identificar, entre dois métodos quantitativos selecionados, aquele que gera o menor erro de previsão de demanda para os produtos de transmissão e distribuição de energia da empresa em questão. Com o intuito de selecionar um modelo sistemático prático, simples e, acima de tudo, mais assertivo, ou seja, um possível substituto para o modelo subjetivo atualmente empregado pela empresa, optou-se por contrapor as previsões obtidas por meio dos métodos de decomposição clássica e redes neurais artificiais. A amostra utilizada na modelagem contempla 72 observações mensais do resultado de vendas, combinada com duas variáveis independentes selecionadas após investigação, as quais são aplicadas somente no modelo de inteligência artificial. Os resultados obtidos pela aplicação da técnica de redes neurais artificiais mostraram uma precisão superior à técnica de decomposição clássica, o que sinaliza que tal método pode servir como uma boa ferramenta para a geração de previsões e auxílio no planejamento e tomada de decisões da empresa.

Palavras-chave: decomposição clássica, erro, método, previsão, redes neurais.

ABSTRACT

Nowadays, demand forecast is a critical issue, whereas it is also essential information on the unstable context organizations do business. Therefore, an efficient forecast means more accurate and safer decisions to be made. This study aims at comparing and identifying, between two quantitative methods, the one that leads to minor forecasting errors for transmission and distribution equipment. It also aims to select a practical, simple, and, above all, more accurate systematic model, in other words, a tool that is going to likely replace the subjective method of forecasting currently used by the company, thus it has been decided to confront classical decomposition and artificial neural networks methods. The sample used contains 72 monthly observations of sales, combined with carefully selected numeric independent variables, which in this case are only applicable to the artificial intelligence method. Artificial neural networks resulted to be more accurate than classical decomposition, which means that this method can be used as a good predictive tool, supporting company planners and decision makers.

Keywords: classical decomposition, error, method, forecast, neural networks.

SUMÁRIO

1. INTRODUÇÃO.....	16
1.1 A EMPRESA	17
1.2 DEFINIÇÃO DO PROBLEMA	20
1.3 JUSTIFICATIVA	21
1.4 OBJETIVOS	23
1.4.1 Geral.....	23
1.4.2 Específicos.....	23
2. REVISÃO TEÓRICA	24
2.1 DEMANDA	24
2.2 TOMADA DE DECISÃO.....	25
2.3 PREVISÃO DE DEMANDA.....	25
2.4 ABORDAGENS PARA ELABORAÇÃO DE PREVISÕES.....	27
2.4.1 Métodos qualitativos	29
2.4.2 Métodos matemáticos ou quantitativos.....	30
2.5 DECOMPOSIÇÃO CLÁSSICA.....	31
2.5.1 Componentes de uma série temporal	32
2.5.1.1 Componente de tendência.....	32
2.5.1.2 Componente cíclica	34
2.5.1.3 Componente sazonal.....	35
2.5.1.4 Componente irregular ou residual.....	35
2.5.1.5 Médias móveis.....	36
2.6 REDES NEURAIS ARTIFICIAIS	37
2.6.1 O modelo de neurônio biológico	38
2.6.2 O modelo de neurônio artificial	41
2.6.3 Principais arquiteturas de RNAs	42
2.6.4 Aprendizado supervisionado.....	44
2.6.5 Rede neural de função radial.....	46
2.6.6 Rede neural de regressão generalizada	46
2.6.7 Redes neurais aplicadas à previsão	47
2.7 MEDIDAS DE PERFORMANCE PREDITIVA.....	48
3. PROCEDIMENTOS METODOLÓGICOS	50

3.1 TIPO DE ESTUDO	50
3.2 PROCEDIMENTOS	50
3.2.1 Coleta de dados	50
3.2.2 Processamento dos dados	51
3.2.3 Aplicação dos modelos	51
3.2.4 Análise dos resultados.....	51
4. ELABORANDO AS PREVISÕES.....	53
4.1 COLETA E PROCESSAMENTO DOS DADOS	53
4.2 EXECUTANDOS OS MODELOS.....	56
4.2.1 Decomposição clássica	56
4.2.2 Redes neurais artificiais.....	61
4.3 ANÁLISE DOS MODELOS	67
5. CONSIDERAÇÕES FINAIS.....	72
REFERÊNCIAS BIBLIOGRÁFICAS	74
ANEXO I – Amostra: variáveis dependentes e independentes	77
ANEXO II – Etapas da elaboração do modelo de decomposição clássica	78
ANEXO III– Exercícios para definição da configuração de treinamento	79
ANEXO IV– Previsão para 2007 a 2009 – decomposição clássica	82
ANEXO V – Previsão para 2007 a 2009 – previsão 10 RNA.....	83

1. INTRODUÇÃO

Desde a sua descoberta, a energia elétrica sempre ocupou posição de destaque na história da humanidade, proporcionando trabalho, produtividade e desenvolvimento à sociedade, além de conforto, comodidade, bem-estar e praticidade aos seus cidadãos.

A dependência da qualidade de vida e do progresso econômico à energia elétrica, aliada ao crescimento da população mundial e da economia nos países em desenvolvimento implicam, necessariamente, o aumento do consumo de energia.

As perspectivas para o setor brasileiro são positivas. Conforme divulgação da agência Reuters¹, um crescimento de 5% na demanda por energia no país é previsto pelo Operador Nacional do Sistema Elétrico (ONS) para o ano de 2010 (REUTERS, 2010). Até julho de 2009, só na área de energia elétrica, os projetos aprovados pelo BNDES apresentaram um aumento de 192%, atingindo R\$ 10,9 bilhões. No mesmo período do ano de 2008, o total foi de R\$ 3,7 bilhões, segundo notícia publicada pela Redação SRZD² (2009).

A demanda por energia elétrica no cenário mundial também se mostra bastante favorável, esta crescerá 2,5% ao ano até 2015, segundo projeções realizadas pela Agência Internacional de Energia, em inglês, *International Energy Agency* (IEA)³ em sua publicação *World Energy Outlook* (WEO, 2009)⁴.

Com vistas a se beneficiar deste aquecimento econômico previsto para o setor energético, torna-se vital a uma organização a ele pertencente adotar um processo racional de busca de informações acerca das vendas futuras, capaz de propiciar aos seus gestores de negócios a redução das dificuldades e obstáculos encontrados na trajetória de planejamento de suas atividades.

O presente trabalho tem por finalidade identificar o melhor método de previsão de demanda para uma empresa de grande porte fabricante de produtos de transmissão e distribuição de eletricidade, localizada na região da Grande Porto

¹ A Reuters é uma das mais famosas e antigas agências de notícias do mundo.

² SRZD é o portal eletrônico do jornalista Sidney Rezende.

³ *International Energy Agency* (IEA) é uma organização intergovernamental autônoma focada na política conhecida como “3Es”: *energy security*, *economic development* e *environmental protection*, em português, segurança energética, desenvolvimento econômico e proteção meio ambiental, respectivamente.

⁴ WEO é uma publicação anual da Agência Internacional de Energia reconhecida por suas projeções globais e análises referentes ao setor energético.

Alegre que, por uma questão de ausência de amparo mais técnico, tem sofrido os reflexos da falta de uma sistemática para este fim em suas decisões.

O assunto abordado neste trabalho é uma das principais preocupações das empresas que atuam no país nos dias de hoje. No mundo nervoso e instável em que vivemos, caracterizado pelo rápido avanço da globalização, aumento da competição via inovação e pela instabilidade política e econômica, as atividades de previsão de vendas ou previsão de demanda se tornam cada vez mais críticas para o bom desempenho empresarial (WANKE e JULIANELLI, 2006).

A decisão do melhor método será resultado de análise, comparação e verificação de eficiência de métodos quantitativos como a decomposição clássica e as redes neurais artificiais. O método de decomposição clássica faz parte das séries temporais, sendo amplamente difundido em diversas áreas, entre elas economia, administração e contabilidade. As redes neurais artificiais, por sua vez, fazem parte da área de inteligência artificial e representam uma tecnologia de raízes diversas, como neurociência, matemática, estatística, física, ciência da computação e engenharia, com aplicabilidade em campos que vão além da análise de séries temporais, como reconhecimento de padrões e processamento de sinais e controle.

A definição do problema dá início ao estudo. A seguir, apresenta-se a descrição da empresa e caracterização do negócio. Mais adiante, faz-se a contextualização do trabalho com a revisão teórica, que busca elementos capazes de estabelecer a compreensão dos pontos de interesse e a relação com a temática abordada. Ao final, são apresentadas as análises resultantes da aplicação das técnicas selecionadas e as conclusões obtidas.

1.1 A EMPRESA

As unidades da AREVA T&D Brasil localizadas em nosso país são parte integrante do Grupo AREVA, líder mundial em energia, que provê seus clientes com soluções tecnológicas de alta confiança nos segmentos de geração de energia nuclear, transmissão e distribuição de eletricidade e interligação de sistemas nas áreas de telecomunicações, informática e mercado da mobilidade.

Com presença industrial em 43 países e uma rede de vendas localizada em mais de 100, a AREVA é a única companhia que cobre atividades industriais no

campo de energia nuclear. Seus mais de 75.000 empregados estão comprometidos com a melhoria contínua dia a dia, fazendo do desenvolvimento sustentável o foco principal da estratégia industrial do Grupo.

Um dos segmentos do Grupo AREVA, o de Transmissão & Distribuição, é formado por quatro subdivisões: Serviços, Sistemas, Automação e Produtos.

A AREVA T&D presta suporte altamente qualificado para o gerenciamento das instalações elétricas, de modo a garantir segurança e eficiência ao longo do ciclo da energia, sendo esse o papel da subdivisão *Serviços*.

Em *Sistemas*, soluções standardizadas ou customizadas para subestações (Projetos *Turnkey*) são desenvolvidas com a união dos produtos de T&D, da engenharia especializada e com o gerenciamento completo do projeto.

A divisão *Automação*, por sua vez, é encarregada de prover soluções de informação em tempo real, garantindo a eficiência, confiabilidade e segurança nas operações de T&D e infraestruturas de distribuição e mercados.

Na subdivisão *Produtos*, uma gama completa de produtos de alta a média tensão é desenvolvida, fabricada e instalada para transmitir e distribuir energia, da geração ao usuário final. Dentro dessa subdivisão, encontra-se o negócio PTR, de transformadores e reatores. Há oito unidades industriais no mundo focadas na fabricação da gama de produtos da PTR, cada uma com um leque próprio de produtos, capacidades de manufatura e mercados de atuação.

Nas Américas, a AREVA Transmissão & Distribuição de Energia Ltda., que atua em nosso país com o nome fantasia AREVA T&D Brasil, é a única fábrica do negócio. A unidade brasileira fabricante de produtos de transmissão e distribuição de energia é conhecida como TCT (sigla sem definição formal) e está localizada no município de Canoas, Rio Grande do Sul.

A TCT atende basicamente ao Ocidente, entretanto, dependendo da demanda, explora outros mercados. Sendo uma das maiores indústrias de Transmissão & Distribuição de energia, a AREVA T&D Brasil é forte atuante no mercado nacional e internacional, produzindo transformadores, autotransformadores e reatores de alta tensão, além de prestar amplos serviços e soluções sob medida para todos os segmentos de mercado.

A AREVA T&D Brasil assegura em seus produtos e sistemas de transmissão e distribuição de energia a confiabilidade, a qualidade e a segurança do fluxo de

energia, operando redes eficientes através do gerenciamento de informação, consolidando assim cada vez mais sua expansão no mercado interno e externo.

Juntamente com seus 435 colaboradores, a AREVA T&D Brasil compromete-se a melhorar continuamente os seus processos relacionados a Qualidade, Segurança, Saúde e Meio Ambiente, através de rigorosa análise de não-conformidades, condições adversas, incidentes, acidentes e doenças ocupacionais, com a efetiva implementação de apropriadas ações corretivas e preventivas.

Desde sua fundação em 1960, época em que iniciou suas atividades como empresa integrante do grupo ANSALDO COEMSA, passando a pertencer à ALSTOM em 2001 e a, finalmente, ser adquirida pela AREVA em 2004, a unidade TCT vem conquistando espaço no mercado através de expansão de sua capacidade produtiva, inicialmente em 2001 e com previsão para nova ampliação em 2010, combinada com as certificações ISO 9001, ISO 14001 e OHSAS 18000 obtidas para seus produtos e atividades.

Nos últimos anos, já como parte integrante do Grupo AREVA, a unidade TCT está entre os principais fabricantes do mercado de transmissão e distribuição no mercado brasileiro e vem competindo por uma maior fatia de mercado dentro de países como Estados Unidos e Canadá. É pequeno o número de indústrias concorrentes no Brasil, entretanto, em relação à concorrência internacional, esta tem se tornado cada vez mais acirrada, devido, principalmente, à forte penetração de empresas coreanas e chinesas nas oportunidades dentro da América Latina e da América do Norte.

Em termos de mercado, a área de Geração, Transmissão e Distribuição de Energia Elétrica (GTD) apresentou uma retração de 8% no primeiro trimestre de 2010 em relação ao mesmo período de 2009, segundo avaliação setorial divulgada pela Associação Brasileira da Indústria Elétrica e Eletrônica (ABINEE). A queda foi causada pela redução das encomendas de equipamentos de distribuição de energia elétrica, em virtude da própria retração da atividade econômica e, também, da elevada base de comparação do ano passado, uma vez que o faturamento naquele período correspondia a contratações realizadas antes da crise econômica. Apesar disso, as perspectivas da área são positivas tendo em vista os planos de investimento tanto para os segmentos de Geração e Transmissão de energia elétrica, como para Distribuição.

1.2 DEFINIÇÃO DO PROBLEMA

Uma das dificuldades que a área comercial da AREVA T&D Brasil enfrenta é a falta de um processo sistematizado para a determinação dos níveis de demanda de seus produtos. Atualmente, a empresa adota métodos qualitativos para prever suas vendas, como as opiniões de executivos e força de vendas. Todavia esses métodos não têm demonstrado o nível de acurácia desejado, o que tem criado problemas para a gestão operacional de suas atividades.

A previsão ineficaz da demanda dificulta o planejamento das necessidades da empresa e impacta a formação dos preços de seus produtos, subestimando ou superestimando coeficientes utilizados em sua elaboração, que podem assim levar à redução da competitividade ou a perdas financeiras. Os coeficientes são elaborados a partir das estimativas de gastos com variáveis como mão de obra, matéria-prima, energia elétrica, água, instalações, entre outros.

O aumento da concorrência e a incerteza nas condições de mercado impõem um constante processo de adaptação às empresas, que precisam buscar novas alternativas para melhor direcionarem suas ações frente aos obstáculos previstos, visando alcançar os objetivos almejados. Desta maneira, decisões calcadas em alicerces sólidos tendem a construir caminhos mais seguros àqueles que pretendem seguir adiante, rumo ao destino idealizado. Para Moreira (2008) é necessário saber quanto à empresa planeja vender de seus produtos ou serviços no futuro, pois essa expectativa é o ponto de partida, direto ou indireto, para praticamente todas as decisões dentro de uma organização.

O papel das previsões, entre elas a previsão de demanda, é fornecer subsídios para o planejamento estratégico da organização. Os planos de capacidade, vendas, fluxo de caixa, estoques, mão de obra e compras são todos baseados na previsão de demanda. A previsão de demanda permite que os administradores das organizações antecipem o futuro e planejem de forma mais conveniente suas ações (TUBINO, 2000).

O planejamento eficaz da demanda do cliente é um dos principais responsáveis pelo sucesso da cadeia de suprimentos, que se inicia com as estimativas da demanda futura referente a produtos e serviços, as quais se tornam entradas tanto para a estratégia de negócios como para as previsões de recursos de produção. As previsões são utilizadas principalmente para se fazer estimativas de

lucros, de receitas, de custos, mudanças nos níveis de produtividade, de preços, de disponibilidade de energia, mão de obra e matéria-prima. Se realizada de maneira inadequada, uma previsão pode gerar efeitos prejudiciais e até mesmo irreversíveis ao longo de toda a organização. Prever eventos e resultados com a maior exatidão possível é, portanto, uma responsabilidade fundamental para uma administração estratégica eficaz, além de uma tarefa difícil, porque a demanda por bens e serviços pode variar de maneira expressiva (RITZMAN e KRAJEWSKI, 2004).

A previsão de demanda é essencial para a redução dos custos de uma empresa, uma vez que, quanto melhor a qualidade das estimativas, maior a capacidade de maximização da produção e menor os níveis de estoques, disponibilizando um número maior de recursos para investimentos. Além disso, a previsão de demanda está relacionada à satisfação do cliente, pois à medida que esse processo se integra ao processo logístico da empresa, ele acaba por orientar a produção, níveis de estoque e, conseqüentemente, garante ou não o atendimento ao mercado, ou seja, a entrega do produto ou serviço ao cliente, dentro das expectativas de prazo e condições almejadas.

O propósito deste trabalho é realizar a análise comparativa e identificar, entre os métodos de regressão estatística e redes neurais artificiais, o mais adequado para a categoria de produtos da AREVA T&D Brasil, isto é, aquele que gera o menor erro de previsão de demanda. O método selecionado pode servir como ferramenta de apoio a todo seu planejamento estratégico, proporcionando aos gerentes a possibilidade de tomar melhores e mais precisas decisões, além de contribuir para uma maior assertividade na elaboração de coeficientes e taxas utilizadas na formação dos preços que pratica.

1.3 JUSTIFICATIVA

A proposta do presente trabalho é determinar, através dos resultados da aplicação das metodologias de decomposição clássica e redes neurais nos dados históricos de venda coletados, o método que apresenta o menor grau de erro associado à previsão. Para a medição do erro será utilizado o método estatístico MAPE, que mede o erro absoluto percentual da média. O resultado deste trabalho é relevante para a empresa analisada, uma vez que contribuirá para agregar mais precisão a suas operações e atividades de planejamento.

Não obstante, a seleção da metodologia com previsões mais assertivas contribuirá para o aumento da competitividade da empresa, visto que tende a proporcionar maior precisão à elaboração dos coeficientes e taxas aplicados e utilizados em seus preços. Tais coeficientes e taxas são elaborados com base na previsão de ordens da unidade do ano fiscal seguinte e são, obrigatoriamente e homogeneamente, utilizados por todas as unidades pertencentes à divisão T&D, tendo seus cálculos preestabelecidos por meio de Instrução Financeira (IF) e seu permanente controle realizado pelo Grupo AREVA.

Os coeficientes introduzidos na formação dos preços de venda são: *Sourcing Overheads* (KM), *Other Production Overheads* (KF & KPM), *Research and Development Costs* (KT), *Selling Costs* (KC), *Administrative Overheads* (KG) e *Management Fees Recovery* (KS). As taxas, por sua vez, dizem respeito aos valores da mão de obra por hora trabalhada (do inglês, *labor hourly rates*), estabelecidos para cobrir a proporção de horas utilizadas no projeto, gestão e fabricação de cada encomenda.

Sourcing Overheads (KM) são limitados aos custos operacionais do departamento de suprimentos, cobrindo também os custos referentes à recepção e à inspeção dos produtos.

Other Production Overheads (KF & KPM) são determinados de acordo com o tipo de fabricação e incluem os custos relacionados ao gerenciamento da cadeia de suprimentos como a determinação das necessidades de compra; custos operacionais da atividade de engenharia; despesas de manuseio dos materiais, tempo indireto de pessoas diretamente envolvidas no processo produtivo; despesas com qualidade (excluindo qualidade da matéria-prima, que é coberta pelo coeficiente KM); manutenção da planta da empresa (limpeza, segurança, consumo de energia elétrica e água, aluguel, depreciação, etc.) e seguro de equipamentos da empresa.

Research and Development Costs (KT) correspondem ao trabalho de Pesquisa & Desenvolvimento (P&D) realizado pelas unidades, setores e negócios, por conta própria, os quais não se relacionam a um contrato ou cliente específicos.

Selling Costs (KC) referem-se aos custos relacionados, principalmente, à rede de vendas, marketing, desenvolvimento de negócios e departamentos comerciais. Cobrem também as despesas com processos de elaboração de propostas (*tendering*) e comunicação (publicidade e propaganda).

Administrative Overheads (KG) incluem as despesas administrativas da unidade nas áreas de Diretoria, Financeiro, Jurídico, entre outros.

Management Fees Recovery (KS) dividem-se em diferentes níveis, cobrem os custos operacionais corporativos do uso dos nomes AREVA e ALSTOM, das atividades setoriais e de gerenciamento do negócio.

Labor hourly rates dizem respeito aos custos relacionados com salários dos empregados diretos dos departamentos de produção e gestão, calculados proporcionalmente às horas direcionadas para cada encomenda.

1.4 OBJETIVOS

1.4.1 Geral

Realizar uma análise comparativa e identificar, entre os métodos de decomposição clássica e redes neurais artificiais, aquele que gera o menor erro de previsão de demanda para os produtos da AREVA T&D Brasil. Espera-se que o método validado possa vir a servir como ferramenta para a geração de previsões e auxílio no planejamento e tomada de decisões da empresa.

1.4.2 Específicos

Os objetivos específicos do presente trabalho são:

- identificar, coletar e analisar as variáveis necessárias para os modelos de previsão a serem utilizados;
- aplicar os métodos selecionados e obter previsões para comparação com as vendas realizadas;
- realizar estudo comparativo e verificar a eficiência das metodologias analisadas através dos erros de previsão encontrados;
- identificar e sugerir o método mais apropriado para aplicação na empresa e seu tipo de negócio.

2. REVISÃO TEÓRICA

A fim de estabelecer uma melhor compreensão acerca do tema proposto, faz-se necessária a apresentação dos pressupostos básicos que o cercam. Inúmeras perspectivas merecem destaque no campo teórico, as principais delas serão aqui abordadas.

2.1 DEMANDA

Em economia, demanda ou procura é a quantidade de um bem ou serviço que os consumidores desejam adquirir por um preço definido em um dado mercado, durante uma unidade de tempo.

Entre os fatores que afetam a demanda podemos citar: o preço do produto; os preços de outros produtos, substitutos ou complementares; a renda dos consumidores; os gostos e preferências; as expectativas de variação de preços, entre outros.

Existem três tipos de demanda: demanda regular, que acontece quando a necessidade de materiais é constante ao longo do tempo ou tem pequenas oscilações de tal forma que podemos identificar um comportamento regular ao longo do tempo; demanda crescente ou decrescente, que ocorre quando se nota um crescimento ou decréscimo do consumo ao longo do tempo; demanda irregular, que ocorre quando há a influência da sazonalidade. Esses três tipos de demanda ocorrem simultaneamente para as organizações, principalmente no longo prazo e no acompanhamento do ciclo de vida dos produtos (DIAS, 1993). Outros autores citam outros tipos de demanda, como, por exemplo, a demanda pontual, a demanda independente e dependente, a demanda de produtos perecíveis e a demanda da cadeia de suprimentos.

2.2 TOMADA DE DECISÃO

Em ambientes organizacionais, as decisões têm se tornado um exercício cada vez mais difícil para os executivos, devido à crescente complexidade de um conjunto de fatores e variáveis que afetam a gestão empresarial. Se antes as empresas se preocupavam somente com produção e sustentabilidade financeira, atualmente têm que se preocupar também com impactos socioambientais, motivação dos funcionários e colaboradores e satisfação de necessidades e desejos dos clientes e mercados consumidores.

Um dos pilares básicos da boa tomada de decisão é reunir o maior número de informações e dados relevantes que cercam uma determinada decisão (GOMES, 2007). Logo, como o número de fatores e variáveis tem aumentado, a quantidade de dados e informações necessários para uma boa decisão tende a aumentar.

As decisões dentro das organizações ainda estão sendo tomadas, em grande parte, de forma puramente intuitiva, sem que sejam utilizadas informações geradas a partir de aplicação de ferramentas de análise de dados. Não que a intuição não seja um componente integrante do processo de tomada de decisão, mas decidir somente de forma intuitiva pode levar as organizações a caminhos desastrosos (CLANCY e KRIEG, 2007).

Para se contrapor a decisões puramente intuitivas, as áreas do conhecimento têm buscado progressivamente desenvolver suas conclusões com base em dados e, nesse contexto, os modelos de previsão são ferramentas importantes para utilização por parte do gestor ou tomador de decisões em várias áreas da administração. Eles certamente foram desenvolvidos para orientar as tomadas de decisões (DIEBOLD, 2004).

2.3 PREVISÃO DE DEMANDA

A previsão dos níveis de demanda é vital para a empresa como um todo, à medida que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais. Os níveis de demanda e os momentos em que ocorrem afetam

fundamentalmente os índices de capacidade, as necessidades financeiras, as decisões administrativas e a estrutura geral de qualquer negócio (BALLOU, 2006).

Segundo Ritzman e Krajewski (2004):

Uma previsão é uma avaliação de eventos futuros utilizada para fins de planejamento. Alterações nas condições dos negócios resultantes de concorrência global, mudança tecnológica acelerada e preocupações ambientais crescentes exercem pressão sobre a capacidade de uma empresa gerar previsões precisas.

É a partir da demanda futura prevista que todas as decisões estratégicas e de planejamento em uma cadeia de suprimento são tomadas. As previsões ajudam a reduzir parte das incertezas permitindo que as empresas desenvolvam planos mais realistas (STEVENSON, 2001).

Gaither e Frazier (2002) salientam que:

Os gerentes de operações necessitam de previsões de longo prazo para tomar decisões estratégicas a respeito de produtos, processos e instalações. Também necessitam de previsões de curto prazo para ajudá-los a tomar decisões a respeito de questões de produção mais imediatas.

O estabelecimento das ações a serem executadas, dos recursos a serem consumidos, bem como as atribuições de responsabilidades deverão ser previstos para um período futuro determinado, para que sejam alcançados os objetivos fixados. Desta forma, a previsão é condição básica para a empresa iniciar suas atividades.

Segundo Gaither e Frazier (2002), a previsão é uma parte integrante do planejamento dos negócios. As entradas são processadas por meio de modelos ou métodos de previsão para desenvolver estimativas da demanda. A Figura 1 mostra o processo em que as previsões servem como entradas para a estratégia de negócios e previsão de recursos.

PREVISÃO COMO PARTE INTEGRANTE DO PLANEJAMENTO DOS NEGÓCIOS

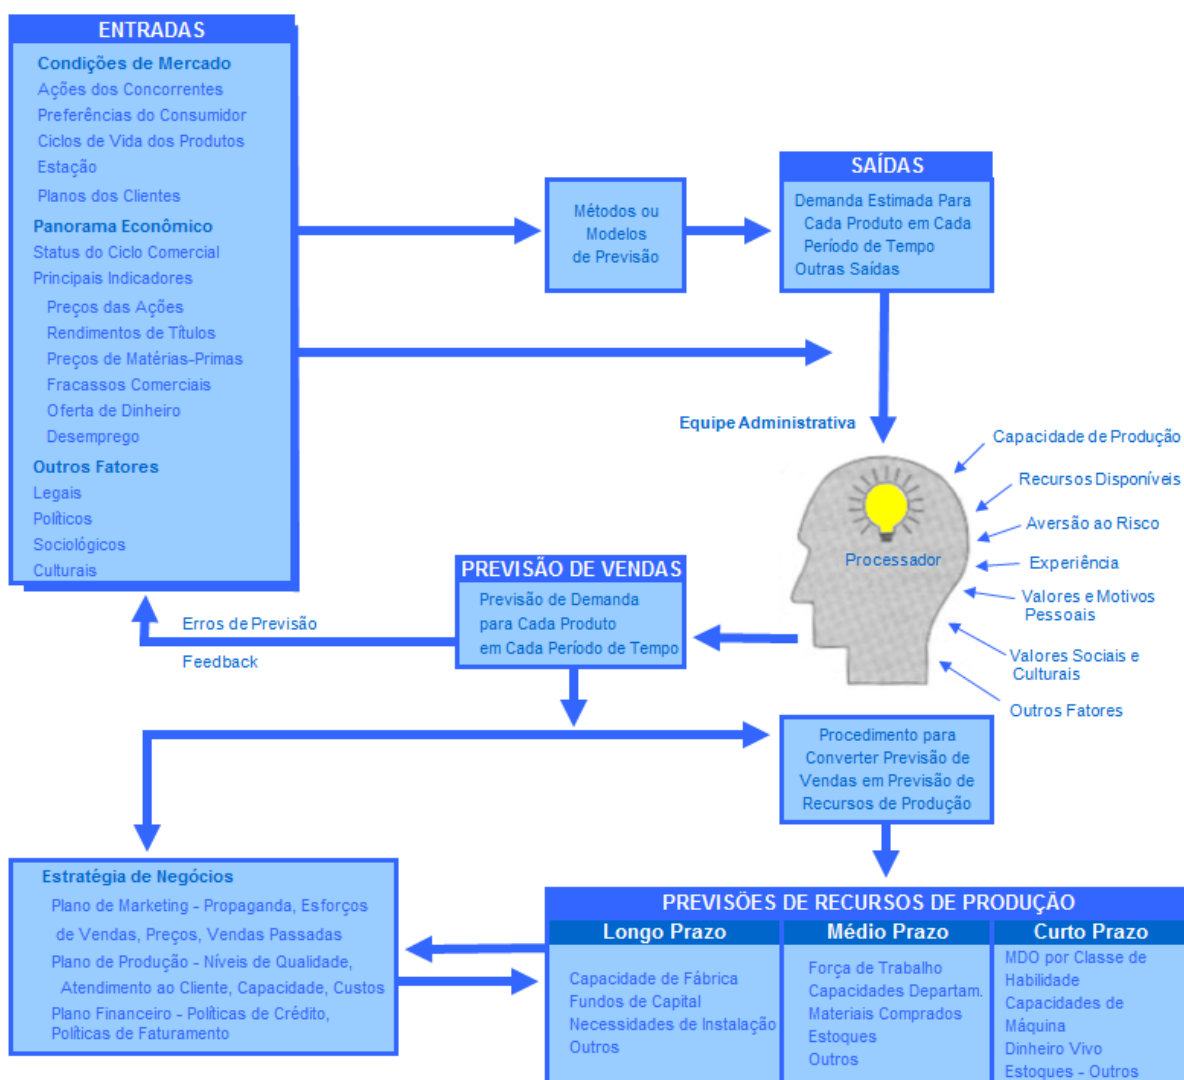


Figura 1 – Previsão como parte integrante do planejamento dos negócios

Fonte: Adaptado de Gaither e Frazier (2002)

2.4 ABORDAGENS PARA A ELABORAÇÃO DE PREVISÕES

Existem vários métodos disponíveis para se obter uma previsão. Segundo SLACK (2002), os modelos e as técnicas de previsão podem ser classificados em termos de objetividade e subjetividade, e relações causais e não-causais. As técnicas objetivas utilizam procedimentos especificados e sistemáticos, enquanto que as subjetivas envolvem aspectos como intuição e julgamento pessoal baseado em experiências. Já as técnicas não causais utilizam valores passados de uma

variável para prever seus valores futuros, ao passo que as técnicas causais fazem previsões através de equações que mostram a relação causa-efeito.

Há variados critérios possíveis para se classificar os métodos de previsão, mas a classificação mais simples provavelmente é aquela que leva em conta o *tipo de abordagem* usado, ou seja, o tipo de instrumentos e conceitos que formam a base da previsão. Por esse critério, os métodos podem ser (MOREIRA, 2008):

I) Qualitativos – são métodos que repousam basicamente no julgamento de pessoas que, de forma direta ou indireta, tenham condições de opinar sobre a demanda futura, tais como gerentes, vendedores, clientes, fornecedores, etc. Não se apóiam em nenhum modelo específico, embora possam ser conduzidos de maneira sistemática. São muito úteis, por exemplo, quando da ausência de dados (ou presença de dados não confiáveis) ou do lançamento de novos produtos.

II) Matemáticos – são aqueles que utilizam modelos matemáticos para se chegar aos valores previstos. Permitem controle do erro, mas exigem informações quantitativas preliminares. Os métodos matemáticos subdividem-se em:

Métodos causais: a demanda de um item ou conjunto de itens é relacionada a uma ou mais variáveis internas ou externas à empresa. Essas variáveis são chamadas de *variáveis causais*. A população, o PNB (Produto Nacional Bruto), o número de alvarás expedidos para construção, o consumo de certos produtos etc. são alguns exemplos de variáveis causais. Na verdade, o que determina a escolha de uma particular variável causal para a previsão da demanda é a sua ligação lógica com essa última. Se tivermos uma boa estimativa desse valor será possível obter a projeção desejada para um produto ou grupo de produtos em estudo.

Séries temporais: a análise de séries temporais nada exige além do conhecimento de valores passados da demanda. O termo série temporal indica apenas uma coleção de valores da demanda tomados em instantes específicos de tempo, geralmente com igual espaçamento. A expectativa é a de que o padrão observado nos valores passados forneça informação adequada para a previsão de valores futuros da demanda.

Dentro das duas categorias de modelos matemáticos citadas, contam-se algumas subdivisões. No caso dos modelos causais, um dos mais populares é a regressão da demanda sobre a(s) variável(eis) causal(is). Na regressão, tenta-se descobrir, utilizando pares de valores da demanda e da(s) variável(is) causal(is), alguma lei que as ligue, lei essa expressa por uma equação matemática. Podemos ter:

- *Regressão simples*: é o caso em que se considera a demanda ligada a apenas *uma* variável causal.
- *Regressão múltipla*: é o caso em que são consideradas duas ou mais variáveis causais supostamente ligadas à demanda.

Dentro das séries temporais, por sua vez, são muito conhecidas e usadas algumas classes de *médias* que podem ser extraídas de valores passados da demanda. Também são muito úteis os *modelos de decomposição* das séries temporais. Estes envolvem a determinação da *linha de tendência* obtida por meio de uma regressão que considera o tempo como uma variável ligada à demanda. Valores previstos pela linha de tendência podem então ser corrigidos para responder por outras características da demanda.

2.4.1 Métodos qualitativos

Os métodos qualitativos consistem principalmente em insumos subjetivos, cuja descrição numérica precisa constitui, muitas vezes, um desafio (STEVENSON, 2001). Eles permitem a inclusão de informações, *subjetivas* (por exemplo, fatores humanos, opiniões pessoais, intuição) no processo de previsão. Estes fatores são frequentemente omitidos ou ignorados quando os métodos quantitativos são utilizados, porque são difíceis, se não impossíveis, de quantificar.

Moreira (2008) apresenta como técnicas qualitativas mais comuns a Opinião de Executivos, a Opinião da Força de Vendas, a Pesquisa Junto a Consumidores e o Método Delphi. Gaither e Frazier (2002), por sua vez, citam entre os métodos qualitativos de previsão o Consenso do Comitê Executivo, o Método Delphi, a Previsão da Equipe de Vendas, a Pesquisa de Clientes, a Analogia Histórica e a Pesquisa de Mercado.

Atualmente, a empresa estudada projeta suas expectativas de vendas com base na opinião de seus executivos e força de vendas, ou seja, no julgamento e experiência de pessoas que possam, através de suas características e conhecimento adquirido, emitir opiniões sobre eventos futuros de interesse. A grande dificuldade da adoção destes métodos reside em questões como influência pessoal e imposição por parte de determinada(s) pessoa(s) do grupo executivo; dificuldade para definir o que os clientes exatamente farão, o que difere do que desejam fazer; previsões superestimadas ou subestimadas, entre outras. Tais métodos são utilizados pelas empresas devido à ausência de uma sistemática de determinação de previsões, além disso, adotam-se essas técnicas por falta de tempo para coletar e analisar demandas passadas (TUBINO, 2000).

Percebe-se que o papel da previsão pura e simplesmente intuitiva, praticamente a única ferramenta disponível para os tomadores de decisão antes da difusão dos microcomputadores, está diminuindo. A mente humana, apesar de possuir características únicas com relação à complexidade e o poder para armazenamento e associação de informações está sujeita a vieses e emoções, sendo geralmente otimista e subestimando a incerteza futura, especialmente no que se refere à previsão de vendas (WANKE e JULIANELLI, 2006).

2.4.2 Métodos matemáticos ou quantitativos

Entre os métodos quantitativos podem-se citar (ARMSTRONG e GREEN, 2005): (i) métodos de extrapolação, (ii) analogias quantitativas, (iii) redes neurais, e (iv) modelos causais.

Os *métodos de extrapolação* utilizam dados históricos para previsão de valores futuros. Extrapolações estatísticas são muito utilizadas em casos onde os responsáveis pela previsão estão sugestionados ou não possuem grande conhecimento sobre as situações dos dados de análise. No caso de inexistência de série temporal e de relações de causa-efeito nos fatores que influenciam a demanda e de existência, apenas, de um corte temporal, é possível utilizar analogias quantitativas.

Caso a empresa preveja mudanças de mercado ou de atitudes frente às mudanças, a previsão de demanda não deve ser uma extrapolação do

comportamento passado do produto. Nestes casos, os métodos quantitativos não são muito eficazes isoladamente e necessitam incorporar opiniões de especialistas. Os métodos quantitativos que contemplam situações em que mudanças são previstas são: modelos causais, segmentação e redes neurais.

Para utilização de *modelos causais*, é necessário que a tendência do relacionamento seja conhecida ou possa ser estimada, sendo que mudanças nas variáveis causais devem ser previsíveis e controláveis. A *segmentação* envolve a ruptura de um problema em partes independentes e a utilização dos dados para fazer a previsão de cada parte. Após, são combinadas as previsões para cada segmento e as previsões por segmentos são somadas (população e comportamento).

Métodos quantitativos utilizam dados históricos para prever a demanda em períodos futuros (PELLEGRINI e FOGLIATTO, 2000). Modelos de previsão de séries temporais, como a *decomposição clássica*, por exemplo, baseiam-se na suposição de que o histórico da antiga demanda é um bom indicador da demanda, sendo modelos simples a serem implementados.

As *redes neurais*, por sua vez, apresentam algumas vantagens sobre os métodos estatísticos tradicionais. A literatura aponta como vantagem teórica, por exemplo, o processo de aprendizado, que estabelece as relações entre as variáveis, não tendo assim que ser previamente especificadas como acontece com a regressão linear, em que são conhecidas as relações entre o fator a ser previsto e outros fatores (RITZMAN e KRAJEWSKI, 2004).

2.5 DECOMPOSIÇÃO CLÁSSICA

A decomposição clássica mantém-se entre os modelos de previsão mais utilizados devido principalmente a sua simplicidade matemática e grande aceitação, e também porque nenhum método mais sofisticado conseguiu oferecer previsão superior à dela (BALLOU, 2006).

A previsão por decomposição clássica fundamenta-se na filosofia de que um padrão histórico de vendas pode ser decomposto em quatro categorias: tendência, variação sazonal, variação cíclica e variação residual (ou aleatória). A tendência representa o movimento de longo prazo causado nas vendas devido a mudanças na

população, no desempenho mercadológico da empresa e em questões relacionadas à aceitação dos produtos e serviços da empresa pelo mercado. A variação sazonal refere-se aos altos e baixos normais na série de tempo que se repetem a cada 12 meses, causados por mudanças climáticas, padrões de compra determinados por datas especiais, e a disponibilidade das mercadorias. A variação cíclica é resultante das ondulações de longo prazo (superiores a um ano) na demanda padrão. A variação residual (ou aleatória) representa a parte das vendas totais não explicada pelos componentes de tendência, sazonais ou cíclicos (BALLOU, 2006).

A combinação de cada uma das variações de vendas no modelo de decomposição clássica resulta na seguinte equação:

$$F = T \times S \times C \times R \quad (1)$$

onde:

F representa a demanda prevista (unidades ou \$);

T representa o nível da tendência (unidades ou \$);

S representa o índice sazonal;

C representa o índice cíclico;

R representa o índice residual.

2.5.1 Componentes de uma série temporal

Segundo Becker (1999), para estudar o comportamento dos dados de uma série temporal é conveniente pensar que a série temporal é constituída por diversos componentes. A hipótese usual é a separação em quatro componentes: a tendência, o ciclo, a sazonalidade e irregular (residual). Mais detalhes são expostos a seguir.

2.5.1.1 Componente de tendência

As análises de uma série temporal podem utilizar qualquer intervalo regular de tempo, desde horas a anos. Enquanto os dados de série normalmente

demonstram flutuações aleatórias, a série também pode apresentar mudanças ou movimentos “para cima” ou “para baixo” ao longo do tempo. Esta mudança gradual da série, normalmente associada a fatores de longo prazo (população, economia, preferência de consumo, clima, tecnologia, etc.) é chamada de série temporal. Para Becker (1999), a componente de tendência de uma série temporal representa movimentos graduais ascendentes ou descendentes ao longo do tempo, conforme se pode verificar nos gráficos abaixo:




Figura 2 – Exemplos de tendências temporais

Fonte: Becker (1999)

Na Figura 2, o gráfico (a) ilustra a existência de uma tendência não linear em uma série temporal com breve crescimento inicial, seguido de um período de estagnação. O gráfico (b) demonstra uma tendência linear decrescente, representando uma série temporal com declínio constante ao longo do tempo. O gráfico (c) representa uma linha horizontal onde não há crescimento nem declínio, ou seja, há uma ausência de tendência.

Para determinar a curva de tendência, recomenda-se:

- Uso de tendência linear;
- Cálculo da regressão linear simples da série de médias móveis com o tempo.

A regressão linear simples consiste em encontrar a linha reta que melhor se ajusta a uma nuvem de pontos ou massa de dados. Seu cálculo é feito através da seguinte fórmula:

$$Y = a + b X \quad (2)$$

Isso significa dizer que os valores de a e b minimizam a média dos erros (Real – Previsto) ao quadrado (MSQ, do inglês *Mean Square*).

A função, que serve como ponto de partida, é a equação da reta, onde:

Y representa a variável dependente (vendas, por exemplo);

a representa o coeficiente linear (valor de Y quando $X = 0$);

b representa o coeficiente angular $(Y_2 - Y_1) / (X_2 - X_1)$;

X representa a variável independente (tempo).

Para medir o poder de explicação da regressão deve-se encontrar o coeficiente R^2 , através do cálculo:

$$R^2 = \frac{\text{Variação nas Vendas Explicada pela Reta}}{\text{Variação Total das Vendas em Relação à Média}} \quad (3)$$

onde a variação entre 0 e 1 significa:

$R^2 = 0$, nenhum poder de explicação ($b = 0$);

$R^2 = 1$, pontos alinhados sobre a reta.

2.5.1.2 Componente cíclica

Considerando que uma série temporal pode exibir mudanças graduais ao longo do período, não se pode dizer que todos os valores futuros da série permanecerão exatamente em cima da linha de tendência, pois as séries temporais muitas vezes apresentam sequências alternadas (pontos abaixo ou acima da linha de tendência). Qualquer comportamento regular de sequências de pontos acima e abaixo da linha de tendência é atribuído à componente cíclica. Sendo assim, pode-se considerar que a componente cíclica de uma série temporal representa variações regulares de longo prazo acima e abaixo da linha de tendência. É comum acreditar que os componentes das séries temporais representam movimentos plurianuais da economia, por exemplo, períodos de alta inflação seguidos de períodos de baixa

inflação podem levar as séries temporais a alternarem indicadores abaixo e acima de uma tendência geral de crescimento.

Para determinar a série de movimento cíclico, as seguintes etapas devem ser seguidas:

- Dividir a série de médias móveis pela série de tendência (Ciclo = Média móvel/ Tendência);
- Os valores de ciclo devem variar em torno de 1, com dispersão máxima de 20%, ou seja, entre 0,8 e 1,2.

2.5.1.3 Componente sazonal

Enquanto as componentes de tendência e cíclica de uma série temporal são identificadas observando-se movimentos de vários anos nos dados históricos, muitas séries temporais apresentam ainda um comportamento regular de variabilidade dentro de períodos anuais.

A componente sazonalidade (S) se refere a um padrão consistente de movimentação de vendas durante o ano. O termo sazonalidade descreve amplamente qualquer padrão de vendas: horário, diário, semanal, mensal ou trimestral. O componente sazonal pode estar relacionado a fatores climáticos, feriados e hábitos de comércio (KOTLER, 2000).

Para determinar a componente sazonal, segue-se os seguintes passos:

- Calcular a média móvel do período desejado (3 meses, 6 meses, etc.);
- Dividir a série de dados pela série móvel;
- Resultado será a série de fatores sazonais;
- Os índices sazonais são a média dos fatores sazonais de cada mês.

2.5.1.4 Componente irregular ou residual

Conforme descreve Becker (1999), a componente irregular das séries temporais é o fator residual que representa desvios entre os valores efetivamente observados da série e o que se esperaria se as componentes de tendência, cíclica e

sazonal explicassem completamente a série temporal. O que causa a componente residual são fatores de curto prazo não previstos e não repetitivos (aleatórios), que afetam as séries temporais. Desta forma ela não é previsível. Em resumo:

- Intervalo de Previsão = Dispersão de erro aleatório

Serve para analisar resíduos do modelo de previsão, onde:

- Resíduo = Real/Previsto (o resultado deve ser ~ 1);
- Após esta etapa, calcula-se o desvio padrão.

2.5.1.5 Médias móveis

Os modelos de média móvel utilizam como previsão para um determinado período no futuro a média das observações passadas. O analista deve usar seu julgamento para determinar em quantas semanas, meses ou trimestres deve se basear a média móvel. Quanto menor o número, mais peso é dado aos períodos recentes. Contrariamente, quanto maior o número, menos peso é dado aos períodos mais recentes. Um número pequeno põe muito peso na história recente, permitindo que as previsões alcancem mais rapidamente o nível atual. Um número grande é desejável quando há flutuações de caráter mais amplo e esporádico nas séries.

As médias móveis podem ser simples, centradas ou ponderadas. Para os modelos de média móvel centrada, os quais foram adotados neste trabalho, podemos definir sua equação como:

$$x_t = \frac{x_{t-1} + x_{t-2} + \dots + x_{t-n}}{n} \quad (4)$$

Na Equação (4), n representa o número de observações incluídas na média x_t , ou seja, n (também pode ser chamado de janela de observações) pode ser considerado como um parâmetro a ser ajustado. Neste caso quanto maior for a janela de observações maior o efeito de alisamento na previsão. Sendo assim, se a série em estudo apresentar muita aleatoriedade ou pequenas mudanças em seus padrões um número maior de observações pode ser utilizado no cálculo da média

móvel, ou seja, podemos dizer que a média móvel neste caso fica mais imune a ruídos e movimentos curtos. Já para o caso de séries que apresentam pouca flutuação aleatória nos dados ou mudança significativa, um número menor deve ser usado para o tamanho da janela de observações, pois caso contrário a série prevista poderá reagir de maneira muito lenta a essas mudanças significativas.

O termo média móvel é utilizado porque à medida que a próxima observação está disponível, a média das observações é recalculada, incluindo esta observação no conjunto de observações e desprezando a observação mais antiga.

2.6 REDES NEURAIS ARTIFICIAIS

Embora a busca pelo conhecimento do cérebro humano tenha iniciado há milhares de anos, a pesquisa moderna no campo das redes neurais teve seu início em um trabalho publicado pelo psiquiatra McCulloch e pelo matemático Pitts, em 1943. Esse estudo foi baseado nas descrições da estrutura cerebral publicada por Ramón e Cajál (1911 *apud* HAYKIN, 2001) que introduziu a ideia dos neurônios como constituintes do cérebro.

As Redes Neurais Artificiais (RNAs) funcionam conceitualmente de forma similar ao cérebro humano, tentando reconhecer regularidades e padrões de dados. Esse interesse foi principalmente motivado pela observação da facilidade e eficácia com que o cérebro realiza tarefas difíceis e complexas. As redes neurais resolvem problemas onde é difícil criar modelos adequados à realidade ou, então, situações que mudam muito (problemas não lineares), sem a necessidade de se definir regras ou modelos explícitos. As RNAs são capazes de aprender com a experiência e fazer generalizações baseadas no seu conhecimento previamente acumulado. Embora biologicamente inspiradas, as RNAs encontraram aplicações em diferentes áreas científicas.

Devido à similaridade de uma rede neural com a estrutura de um cérebro, as RNAs também acabam por exibir características semelhantes, tais como:

- Aprendizado: aprende-se por experiência;
- Associação: faz associações entre padrões diferentes;

- Generalização: são capazes de generalizar o conhecimento adquirido a partir de experiências passadas;
- Abstração: extrai a essência de um conjunto de informações, retirando os ruídos.

2.6.1 O modelo de neurônio biológico

O sistema nervoso humano pode ser dividido através de três fases de tratamento da informação, conforme demonstrado na Figura 3, na qual se identificam, através de um diagrama de blocos, as entradas (estímulos), as saídas (respostas), assim como a interface responsável pela interpretação da informação de entrada, resultando em um sinal de saída para os atuadores. Esta interface, identificada pela rede neural, é o cérebro humano (HAYKIN, 2001).



Figura 3 – Esquema básico do sistema nervoso

Fonte: Adaptado de Haykin (2001)

Embora, atualmente, haja uma vasta documentação do mapeamento cerebral e sua forma de funcionamento, o tratamento computacional utiliza os modelos básicos do neurônio, conforme verificado na Figura 4. Aí, tem-se a identificação das sinapses, do axônio, dos dendritos e do corpo celular em uma representação conhecida como célula piramidal, que é um dos tipos mais comuns de neurônios corticais (HAYKIN, 2001).

Os dendritos compõem a camada de entrada de um neurônio e são responsáveis por receber os sinais oriundos de outros neurônios e/ou de outras células sensoriais através de uma membrana conhecida como membrana pós sináptica. A soma é o corpo celular que abriga o núcleo do neurônio e onde, efetivamente, é realizado o processamento como uma etapa decisória. Essa decisão será processada com base nos sinais de entrada das células sensoriais. Sua

propagação, conhecida como impulsos nervosos ou potenciais de ação, é realizada pelos axônios que são saídas ramificadas com terminações sinápticas. Alguns desses axônios podem se estender ao longo do corpo humano atingindo vários metros (HAYKIN, 2001).

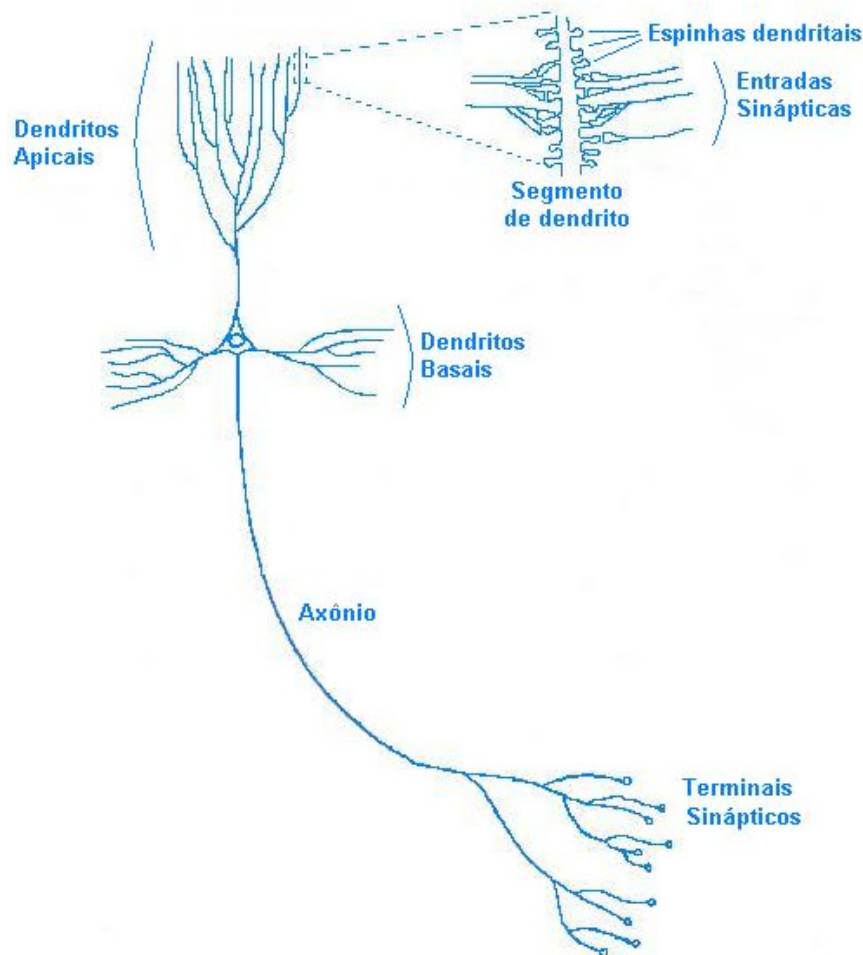


Figura 4 – A célula piramidal

Fonte: Adaptado de Haykin (2001)

As sinapses são as unidades de conexão elementares para a mediação entre os neurônios, e o tipo mais comum é a sinapse química em que ocorre um processo entre duas membranas para a transmissão do sinal. Na região intersináptica, o estímulo nervoso que chega através da membrana pré-sináptica, oriunda de outra célula, é transferido à membrana pós-sináptica (dendritos) através de substâncias conhecidas como neurotransmissores. O resultado é a alteração do potencial elétrico da membrana dendrital que pode ocorrer em dois modos: excitação ou inibição (KOVÁCS, 1996). Quando esta região intersináptica atinge seu equilíbrio químico entre íons de sódio, potássio, cálcio e íons orgânicos negativamente

carregados, a membrana atinge um estado conhecido como potencial de repouso, mantido por um processo conhecido como bomba de sódio e caracterizado por apresentar um potencial elétrico de aproximadamente -70 mV entre a região interna da membrana e a região externa (FREEMAN e SKAPURA, 1992).

A condição de disparo ocorre quando um impulso nervoso excitatório transmite uma despolarização suficientemente acentuada para cruzar o limiar de disparo. A integralização das várias entradas do neurônio possui uma propriedade conhecida por integração espacial-temporal dos estímulos. Na Figura 5 é possível visualizar, na parte superior, o efeito das várias entradas em um neurônio típico e na parte inferior da figura é demonstrado o efeito das várias entradas até o cruzamento no limiar de disparo (KOVÁCS, 1996).

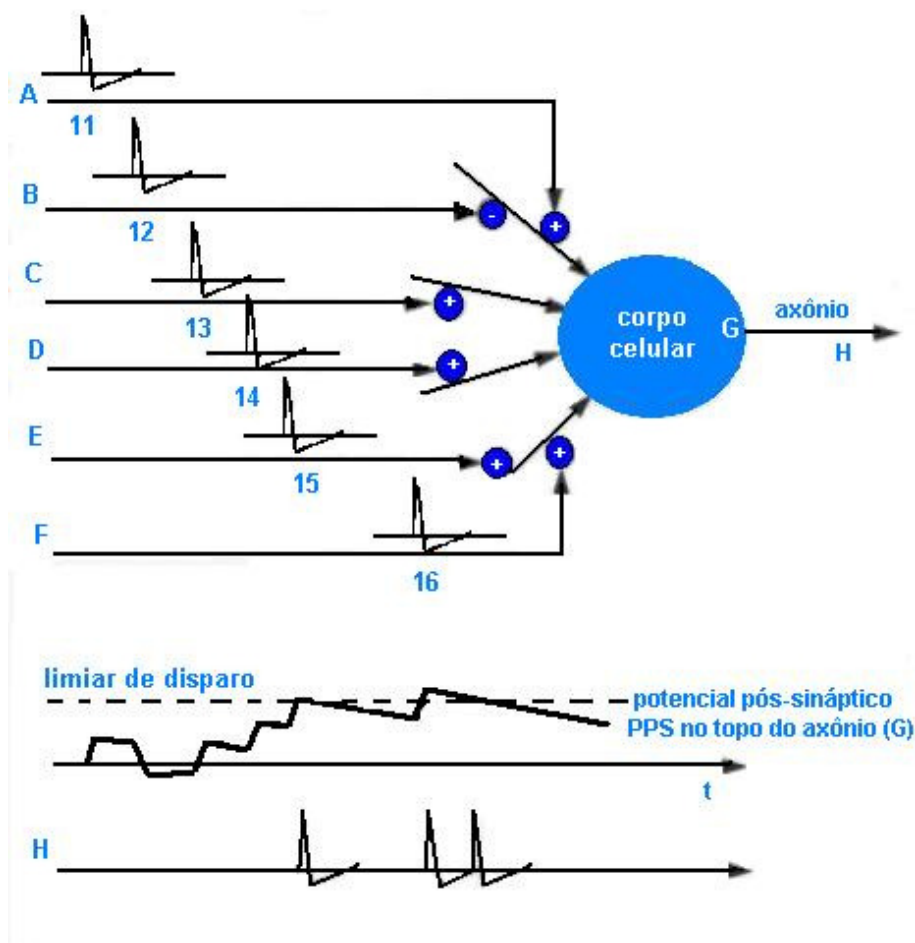


Figura 5 – O limiar de disparo de um neurônio

Fonte: Adaptado de Kóvacs (1996)

2.6.2 O modelo de neurônio artificial

O modelo de neurônio artificial proposto por McCulloch-Pitts (modelo MCP) é mostrado na Figura 6 e seu processamento pode ser descrito como uma equação generalizada por (HAYKIN, 2001):

$$y_k = \varphi \left(\left(\sum_{j=1}^m w_{kj} x_j \right) + b_k \right) \quad (5)$$

onde:

y_k representa o sinal de saída do neurônio;

φ representa a função de ativação;

w_{kj} são os pesos que representam as sinapses;

x_j representa as entradas que formam um vetor;

b_k representa o bias com a função de aumentar ou reduzir a entrada da função de ativação.




Figura 6 – Modelo de neurônio artificial

Fonte: Adaptado de Haykin (2001)

Rosenblatt demonstrou, através de seu teorema de convergência do Perceptron, que a rede neural sugerida por McCulloch-Pitts (MCP) alcançava a

convergência para a classificação quando os padrões de entrada eram linearmente separáveis, reproduzindo assim as funções lógicas computacionais básicas. No modelo utilizado por Rosenblatt a função de ativação apresentava um limiar de decisão abrupto e descontínuo, representado na Figura 7, onde se detecta o limiar de decisão formado para o caso de duas variáveis x_1 e x_2 e é possível identificar que as classes apresentadas são linearmente separáveis (HAYKIN, 2001).

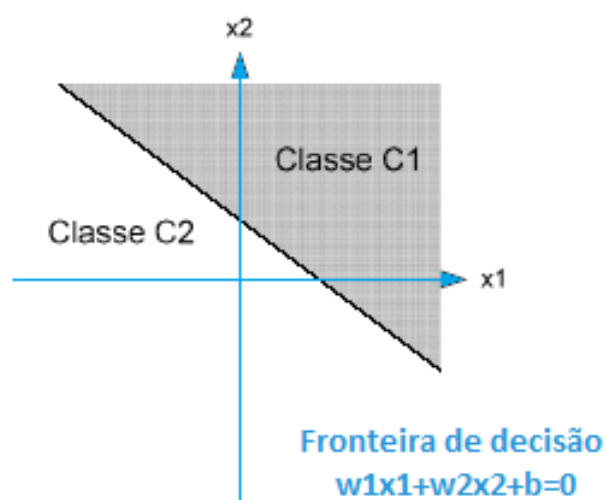


Figura 7 – Hiperplano demonstrando o limiar de decisão

Fonte: Adaptado de Haykin (2001)

2.6.3 Principais arquiteturas de RNAs

A definição da estrutura de uma rede neural artificial é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Redes com uma camada única de nodos MCP (por McCulloch e Pitts), por exemplo, só conseguem resolver problemas linearmente separáveis. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal. Fazem parte da definição da arquitetura os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede. Alguns exemplos são apresentados na Figura 8.

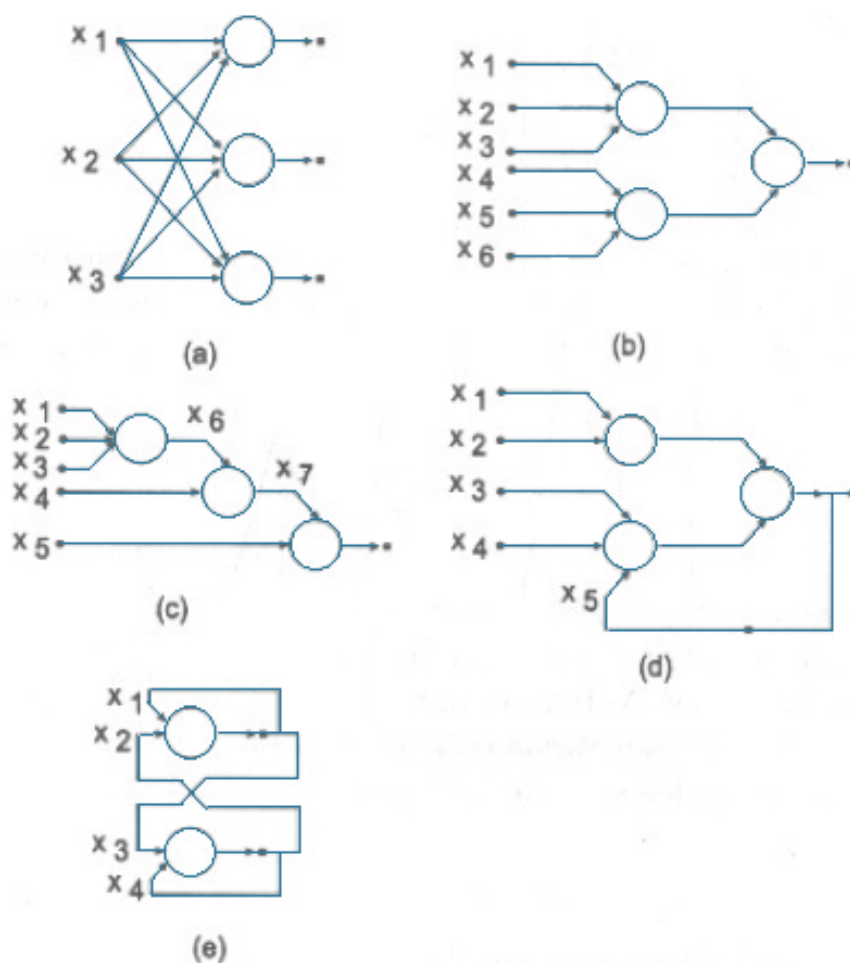


Figura 8 – Arquiteturas de redes neurais artificiais

Fonte: Braga, Carvalho e Ludermir (2000)

Quanto ao número de camadas, pode-se ter:

- redes de camada única: só existe um nó entre qualquer entrada e qualquer saída da rede (Figura 8 a, e);
- redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 8 b, c, d).

Os nodos podem ter conexões do tipo:

- *feedforward*, ou acíclica: a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a i (Figura 8 a, b, c);

- *feedback*, ou cíclica: a saída de algum neurônio na i -ésima camada da rede é usada como entrada de nodos em camadas de índice menor ou igual a i (Figura 8 d, e).

É importante também atentar aos seguintes pontos:

- Redes cuja saída final (única) é ligada às entradas comportam-se como autômatos reconhecedores de cadeias, onde a saída que é realimentada fornece o estado do autômato (Figura 8 d);
- Se todas as ligações são cíclicas, a rede é denominada *autoassociativa*. Estas redes associam um padrão de entrada com ele mesmo, e são particularmente úteis para recuperação ou “regeneração” de um padrão de entrada (Figura 8 e).

Finalmente, as RNAs podem também ser classificadas quanto à sua conectividade:

- rede fracamente (ou parcialmente) conectada (Figura 8 b, c, d);
- rede completamente conectada (Figura 8 a, e).

2.6.4 Aprendizado supervisionado

O aprendizado é o processo pelo qual a RNA aprende por meio dos padrões a ela apresentados. Os procedimentos de aprendizado (ou treinamento) que levam as RNAs a aprender determinadas tarefas podem ser classificados em duas classes: *treinamento supervisionado*, onde a rede é alimentada por dados de entrada e seus respectivos valores de saída (alvo), e *treinamento não supervisionado*, que não requer valores de saída, onde a rede agrupa os valores de maior semelhança (*clusters*).

O método de *aprendizado supervisionado* é o mais comumente utilizado para o treinamento das RNAs. Nele o supervisor (professor) fornece a entrada e saída desejadas para a rede (BRAGA, CARVALHO e LUDERMIR, 2000).

Segundo Haykin (2001), um algoritmo de aprendizado é definido como um conjunto preestabelecido de regras bem definidas para a solução de um problema

de aprendizagem. Durante o desenvolvimento das redes neurais artificiais surgiram diversas ferramentas com diferentes métodos para implementar o ajuste dos pesos sinápticos e, assim, causar o processo de aprendizagem da rede neural. Dentre os conjuntos de algoritmos, citam-se (HAYKIN, 2001):

- a aprendizagem por correção de erro;
- a aprendizagem por retropropagação do erro;
- a aprendizagem baseada em memória;
- a aprendizagem Hebbiana;
- a aprendizagem competitiva;
- a aprendizagem de Boltzmann.

A aprendizagem por correção de erro, adotada neste trabalho, procura minimizar a diferença entre a soma ponderada das entradas pelos pesos (saída calculada pela rede) e a saída desejada, ou seja, o erro da resposta atual da rede. Para Haykin (2001), os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro. O *sinal de erro* é a diferença entre a resposta desejada e a resposta real da rede que será ajustado passo a passo com o objetivo de fazer a rede neural *emular*, da maneira ótima no sentido estatístico, o professor. Assim, o conhecimento do ambiente disponível ao professor é transferido para a rede neural através de treinamento, da forma mais completa possível. Quando esta condição é alcançada, pode-se dispensar o professor e deixar a rede neural lidar com o ambiente inteiramente por si mesma.

O termo $e(t)$ do erro deve ser escrito como:

$$e(t) = d(t) - y(t) \quad (6)$$

onde:

$d(t)$ é a saída desejada;

$y(t)$ é a resposta atual (calculada) no instante de tempo t .

A forma genérica para alteração dos pesos (w) por correção de erros é apresentada na Equação (7) (BRAGA, CARVALHO e LUDERMIR, 2000):

$$w_i(t + 1) = w_i(t) + \eta e(t)x_i(t) \quad (7)$$

onde:

η é a taxa de aprendizado;

$e(t)$ é o termo do erro;

$x_i(t)$ é a entrada para o neurônio i no tempo t .

2.6.5 Rede neural de função radial

O princípio básico da rede neural de base radial é que esta rede consiste de duas camadas cujas saídas formam uma combinação linear das funções de base calculadas pelos nós da camada escondida. As funções de base não lineares produzem uma resposta não nula aos estímulos de entrada somente quando as entradas se encontram dentro de uma pequena região do espaço de entrada.

A principal diferença entre uma rede de base radial e uma rede perceptron multicamadas é a forma de processamento das entradas. Na rede de base radial a ativação de cada neurônio se dá pela norma ponderada da diferença entre o vetor de entradas e o vetor de pesos, e na rede perceptron multicamadas ocorre o produto escalar de ambos os vetores.

Em particular, as redes neurais de função de base radial formam uma classe de redes neurais que possuem algumas vantagens em relação a outros tipos de redes neurais, incluindo melhor capacidade de aproximação, estruturas simples e algoritmos de aprendizado rápido (SARIMVEIS *et al.*, 2002).

A rede neural desenvolvida neste trabalho é uma variação da rede de base radial, não recorrente, isto é, sem laços de realimentação, e com aprendizado (ou treinamento) supervisionado, adaptado por correção de erros.

2.6.6 Rede neural de regressão generalizada

Uma rede neural de regressão generalizada, do inglês *Generalized Regression Neural Network* (GRNN), é uma variação da rede neural de base radial

frequentemente usada para aproximação de funções, previsão de séries temporais e controle. Segundo Tsoukalas e Uhrig (1997), a GRNN é uma extensão especial do tipo de rede *Radial Basis Function Network* (RBFN).

A principal função de uma rede GRNN é a de estimar uma superfície de regressão linear ou não-linear das variáveis dependentes sobre as variáveis independentes de uma função ou de um sistema.

A rede GRNN é uma rede do tipo *feedforward* baseada na teoria da regressão não linear que possui quatro camadas: a camada de entrada, a camada padrão ou oculta, a camada de soma e a camada de saída. A rede GRNN pode aproximar qualquer mapeamento arbitrário entre o vetor de entrada e o de saída. Além disso, não requer um procedimento iterativo para o treinamento, e apresenta um alto grau de paralelismo em sua estrutura. A rede GRNN pode ser usada para predição, modelagem, mapeamento, e interpolação ou como um controlador.

2.6.7 Redes neurais aplicadas à previsão

Para Davis, Aquilano e Chase (2001):

As redes neurais representam uma área relativamente nova e crescente de previsão. Diferentemente das técnicas de previsão estatística mais comuns, como a análise de séries temporais e a análise de regressão, as redes neurais simulam o aprendizado humano, desenvolvendo relacionamentos complexos entre entradas e saídas de um modelo de previsão.

A modelagem por meio de redes neurais artificiais é umas das técnicas de mineração de dados mais utilizada, sendo bastante empregada em tarefas de previsão (BERRY e LINOFF, 1997). O desempenho dos computadores permite, atualmente, que processem grandes bases de dados por meio de redes neurais (DETIENNE, DETIENNE e JOSHI, 2003).

Uma vantagem das RNAs em relação às técnicas clássicas para predição diz respeito à construção dos modelos, que pode depender de um entendimento mais profundo do problema, além de poder ter alta complexidade, dependendo do número de variáveis consideradas. Assim, se torna atraente a alternativa de modelagem através das RNAs, já que estas se caracterizam por uma modelagem não-

paramétrico, em que não há grande necessidade de se entender o processo propriamente dito. A modelagem pode ser feita utilizando-se somente amostragens de valores de entrada e saída do sistema em intervalos de tempos regulares. Outro fator favorável às RNAs está relacionado ao fato de não haver para estas grande limitação no número variáveis de entrada. Para o caso específico de predição, este é um fator importante, pois está relacionado com o número de atrasos de tempo que podem ser considerados na predição (BRAGA, CARVALHO e LUDERMIR, 2000).

Outro atrativo das RNAs surge a partir das limitações de técnicas convencionais de regressão múltipla, tais como incapacidade de lidar com não-linearidade, exigência de estabelecimento de um modelo subjacente preestabelecido, sensibilidade à multicolinearidade, exigências quanto à distribuição dos dados, entre outras limitações (DETIENNE, DETIENNE e JOSHI, 2003).

2.7 MEDIDAS DE PERFORMANCE PREDITIVA

Parte da decisão para usar uma técnica de previsão em particular envolve a determinação se a técnica produzirá os erros de previsão que são julgados ser suficientemente pequenos. É certamente realístico esperar que uma técnica produza erros relativamente pequenos de previsão em uma base consistente (HANKE, 2001).

A palavra erro é utilizada quando estamos nos referindo à diferença entre o valor da demanda prevista e o que realmente aconteceu (DAVIS, AQUILANO e CHASE, 2001). Para se ter uma ideia do quanto uma previsão é precisa, é necessário haver uma forma de estimar o quanto se está errando, em média.

Existem na literatura diversas medidas de erro disponíveis que podem ser utilizadas para se encontrar o método que melhor atenda os resultados esperados. Neste presente trabalho, o erro é calculado através da Média do Erro Percentual Absoluto (MAPE), que consiste na seguinte expressão:

$$MAPE = \left(\frac{1}{n}\right) \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (8)$$

onde:

n é o número de períodos de previsão;

A_t é o valor real de venda;

F_t é o valor previsto de venda.

3. PROCEDIMENTOS METODOLÓGICOS

3.1 TIPO DE ESTUDO

Este trabalho caracteriza-se como um projeto técnico-experimental que visa buscar o aperfeiçoamento dos processos de uma organização, de forma a torná-la mais competitiva, através da proposição de uma ferramenta de previsão de demanda, capaz de gerar informações adequadas para a sua tomada de decisões.

3.2 PROCEDIMENTOS

A partir de quatro passos distintos, demonstrados de forma esquematizada na Figura 9, o método de previsão mais adequado, entre as metodologias analisadas, será determinado:

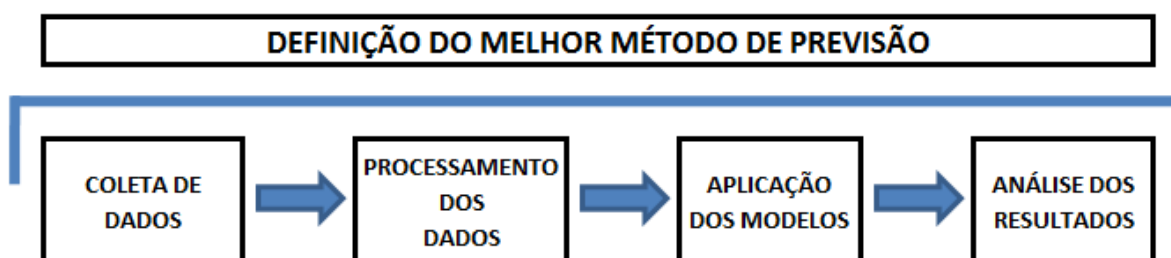


Figura 9 – Esquema de seleção de método de previsão

Fonte: Elaborada pela autora

3.2.1 Coleta de dados

Bases de dados históricos serviram como recurso para a elaboração das previsões. O horizonte de estudo é composto pelas informações mensais de venda dos últimos seis anos completos, de janeiro de 2004 a dezembro de 2009, realizadas para o mercado nacional e internacional.

3.2.2 Processamento dos dados

Os dados foram organizados mensalmente e todos os valores foram convertidos para Reais, com paridade cambial respectiva à época em que foram registrados, ou seja, ao mês e ano correspondentes. Os impostos, quando aplicáveis, foram desconsiderados, mantendo assim uma base de valores líquidos. Além disso, a fim de tornar os dados o mais homogêneos possível, optou-se por ajustar os montantes de exportação para a modalidade de entrega FOB⁵ – Porto de embarque (Rio Grande ou Porto Alegre), reduzindo assim o impacto, na maioria das vezes significativamente elevado, que o custo de transporte internacional gera nos preços.

3.2.3 Aplicação dos modelos

Para a execução do método de decomposição clássica optou-se pelo uso do Microsoft® Excel, que tem como vantagem sua ampla disponibilidade e uso. As simulações com as redes neurais artificiais, por sua vez, foram realizadas no software NeuralTools® – Palisade⁶, cuja viabilidade reside na utilização da mesma interface da planilha eletrônica Microsoft® Excel.

3.2.4 Análise dos resultados

Os métodos de previsão foram avaliados de acordo com critérios de desempenho baseado em medidas de erro, isto é, desvios entre valores previstos e efetivamente observados. O método utilizado foi o MAPE (Média do Erro Percentual

⁵ *Free On Board* (FOB) designa uma modalidade de repartição de responsabilidades, direitos e custos entre comprador e vendedor, no comércio de mercadorias. O termo é incluído na listagem dos *Incoterms* (*International Commercial Terms*), estabelecidos pela Câmara de Comércio Internacional.

⁶ A Palisade Corporation é fabricante dos softwares de análise de risco e tomada de decisão @RISK e DecisionTools® Suite. Praticamente todos os produtos da Palisade são integrados na interface do Microsoft® Excel, o que garante flexibilidade, facilidade de uso e ampla aceitação em uma variedade de setores.

Absoluto), do inglês *Mean Absolute Percentual Error*, que mede os erros de previsão, numa escala relativa, em erros de porcentagem.

A partir do comparativo de resultados pôde-se eleger o método de previsão mais adequado.

4. ELABORANDO AS PREVISÕES

4.1 COLETA E PROCESSAMENTOS DOS DADOS

Para a formação da série histórica realizou-se a extração de informações sobre vendas do banco de dados da AREVA T&D Brasil referentes ao período de janeiro de 2004 a dezembro de 2009, totalizando uma amostra composta por 72 itens. Conforme mencionado anteriormente, esses dados foram compilados de maneira cronológica, sendo identificados por sua data efetiva de registro. Adicionalmente, converteu-se as diversas moedas contratuais (USD, EUR, GBP, CAN) para BRL (Reais) com paridade cambial respectiva ao período de venda e extraiu-se todos e quaisquer impostos (PIS, COFINS, ICMS, IPI e II), quando aplicáveis.

Os dados referentes às vendas para o mercado externo foram ajustados para uma mesma modalidade de entrega, FOB – Porto de embarque (Rio Grande ou Porto Alegre) com vistas a minimizar os efeitos do custo de transportes nos preços, já que estes tendem a distorcê-los.

O Anexo I (coluna 1) contém todos os dados de vendas mensalmente distribuídos em kBRL (símbolo k; de kilo, conforme Sistema Internacional de Unidades), ou seja, divididos por mil. Aos valores apresentados, aplicou-se, também, um fator escolhido aleatoriamente, de forma a mascarar os dados reais, uma vez que se trata de informação confidencial. O conjunto de informações referentes ao histórico de vendas constitui a amostra utilizada no modelo de decomposição clássica.

No caso das redes neurais artificiais, a viabilidade da construção do modelo depende ainda da disponibilidade de outros dados relevantes e confiáveis, que possam ser facilmente utilizados em conjunto com os dados históricos de vendas coletados. Além das variáveis dependentes, que são aquelas que desejamos prever com o modelo, é necessário encontrar outras variáveis que mantenham uma forte relação com as vendas e que possam contribuir para o aprendizado da rede e reconhecimento dos parâmetros comportamentais da demanda. Após investigação conduzida, por meio de um conjunto de testes e simulações com possíveis variáveis,

no software NeuralTools® – Palisade, encontrou-se duas variáveis independentes para utilização no modelo: a soma da potência em MVA (Mega Volt Ampère) dos equipamentos vendidos no mês, extraída também da base de dados da AREVA T&D Brasil, e o preço médio de geradores e transformadores elétricos em US\$/ton, este último disponibilizado mensalmente pela Secretaria de Comércio Exterior (SECEX) através da página do Ministério do Desenvolvimento, Indústria e Comércio Exterior (MDIC). Convém salientar que a informação sobre a potência total dos equipamentos mensalmente vendidos também sofreu modificação por meio da aplicação de um coeficiente qualquer, visando manter a confidencialidade dos dados originais.

Não são detalhados neste trabalho os exercícios realizados para a seleção das variáveis independentes, a fim de não desviar do seu objetivo principal. Não obstante, é importante citar quais foram as demais informações cogitadas e testadas em inúmeras combinações, com e sem defasagem de tempo, para a aplicação do método, as quais, todavia, não foram consideradas em virtude de seus resultados insatisfatórios:

- média mensal ponderada das cotações para venda do dólar americano fornecida diariamente pelo BACEN;
- índice de preço médio mensal do cobre eletrolítico, cotação LME em US\$/ton fornecido mensalmente pela ABINEE;
- índice de preço médio mensal da chapa siliciosa de grãos orientados M-5 da lista da ACESITA em R\$/ton, FOT – Usina com embalagem tipo II, com ICMS 12%, pagamentos a 30 dias, fornecido mensalmente pela ABINEE;
- índice de produtos industriais – ferro, aço e derivados, coluna 32 da Revista Conjuntura Econômica, publicada pela Fundação Getúlio Vargas;
- média mensal ponderada de preço do óleo isolante tipo AV-58, em R\$/litro, para fabricantes e firmas de manutenção de equipamentos elétricos na Região Sul/Sudeste, fornecido diariamente pela Petrobras;
- salário ABDIB/FIPE – índice de salário médio na produção de bens de capital sob encomenda, coluna “Setor ABDIB Global com encargos sociais”;

- taxa-hora praticada pela AREVA T&D Brasil para fabricação, gestão de contratos, projeto de engenharia, gestão de contratos e ensaios nos anos de 2004 a 2009.

Desta forma, a amostra a ser utilizada para a modelagem das RNAs, constituída a partir das variáveis dependentes e independentes, totaliza 216 observações, conforme pode ser visto no Anexo I (colunas 1 a 3).

Como se pode notar neste mesmo anexo, o ano de 2009 apresentou uma forte retração nas vendas, com resultados nulos em 50% de seus meses, em virtude da crise econômica mundial de 2008-2009 e seu impacto desestabilizador no mercado financeiro, que provocou falências e perdas colossais para empresas mundo afora e, conseqüentemente, levou clientes a reações desesperadas, como o cancelamento de muitos compromissos de venda previamente estabelecidos, em sua maioria para o mercado externo.

No que diz respeito aos componentes da amostra anteriores a 2009 que igualmente apresentaram resultados nulos, esses também se devem ao cancelamento de pedidos em carteira, porém devido a outras razões particulares.

Conforme sondagens conjunturais, quanto à área de Geração, Transmissão e Distribuição de Energia Elétrica (GTD), as encomendas de equipamentos para infraestrutura de distribuição de energia foram muito baixas no ano de 2009 devido também à queda dos investimentos neste segmento, especialmente do Programa Luz para Todos⁷.

A venda de um pacote significativo de equipamentos para um projeto de longo prazo no mercado doméstico, com fornecimento de máquinas até o ano de 2012, conforme pode ser observado no montante registrado no mês de dezembro, contribuiu e muito para o resultado do ano de 2009. O montante vendido recuperou o desempenho dos meses anteriores e, graças a ele, a unidade TCT atingiu a meta de vendas do ano.

Antes de prosseguir para a execução dos modelos, faz-se necessário abordar a questão da ordem de importância das vendas da empresa e de sua distribuição ao longo do tempo. É importante esclarecer que o foco da área comercial da AREVA

⁷ Programa lançado pelo Governo Federal em novembro de 2003 que tem a meta de levar energia elétrica para pessoas do meio rural. O Programa Luz para Todos é coordenado pelo Ministério de Minas e Energia, operacionalizado pela Eletrobrás e executado pelas concessionárias de energia elétrica e cooperativas de eletrificação rural.

T&D Brasil é o atingimento de um montante predeterminado de vendas, que serve para nortear a rede de vendas em suas atividades ao longo de um ano de trabalho. O *budget*⁸, como é chamado, é uma meta anual que deve ser alcançada pela equipe de vendas. Desta forma, a distribuição das vendas ao longo dos meses do ano ou em parcelas menores a um ano não faz diferença para a empresa, pois o objetivo, como já mencionado, é conquistar o montante anual desejado. O Quadro 1 demonstra a evolução do total de vendas nos anos verificados:

ANO	2004	2005	2006	2007	2008	2009
REALIZADO (kBRL)	119.449	128.826	155.306	281.872	305.951	385.286
AUMENTO (%)	-	7,8%	20,6%	81,5%	8,5%	25,9%

Quadro 1 – Evolução anual das vendas

Fonte: Elaborado pela autora

4.2 EXECUTANDOS OS MODELOS

Para obtenção das previsões com base na série histórica determinada, descreve-se aqui todas as etapas dos dois métodos aplicados, complementadas com informações particularmente pertinentes.

4.2.1 Decomposição clássica

O processo de determinação do volume de vendas, segundo o método de decomposição clássica, é composto por cinco etapas distintas:

- *Primeira etapa:* cálculo da média móvel centrada da série histórica, com $n = 12$;

⁸ Do francês antigo *bougette*, o *budget* é, geralmente, uma lista de todas as despesas e receitas planejadas. O *budget* de uma empresa é frequentemente compilado anualmente, mas pode não ser. Se os números realizados ao longo do ano são muito próximos ao *budget*, pode-se supor que os gerentes entendem bem o negócio e têm dirigido com sucesso a empresa na direção pretendida. Por outro lado, se os números divergem drasticamente do *budget*, entende-se que o negócio está aparentemente “fora de controle”.

- *Segunda etapa:* cálculo do índice sazonal resultante da média móvel;
- *Terceira etapa:* cálculo da média de sazonalidade através da divisão do montante de vendas pela média móvel de vendas;
- *Quarta etapa:* cálculo do índice sazonal normalizado através da divisão da média dos índices sazonais pela soma destes índices multiplicada por doze (meses de um ano);
- *Quinta etapa:* cálculo do coeficiente R^2 através de regressão linear, utilizando a linha de tendência para identificar o poder de explicação dos pontos na reta.

Em previsões mensais, geralmente o padrão sazonal se repete de 12 em 12 meses. Por esta razão calculou-se a média móvel centrada em $n = 12$, onde 12 representa a duração do padrão sazonal, ou seja, um ano. Como o número de períodos do padrão sazonal é par, definiu-se centrar a média móvel dos valores entre janeiro e dezembro de cada ano no mês de julho.

As Tabelas 1 e 2 mostram o resultado das etapas realizadas na planilha eletrônica Microsoft® Excel:

Tabela 1 – Média móvel e índice sazonal da série histórica de vendas no período de 2007 a 2009

PERÍODO	REAL	MÉDIA-MÓVEL	SAZONALIDADE
jan/07	9.969	11265	0,88
fev/07	-	10782	0,00
mar/07	590	20119	0,03
abr/07	9.586	19247	0,50
mai/07	15.827	17322	0,91
jun/07	31.617	18622	1,70
jul/07	7.884	23489	0,34
ago/07	85.481	23514	3,64
set/07	12.264	25731	0,48
out/07	-	30885	0,00
nov/07	31.622	33078	0,96
dez/07	77.031	32093	2,40
jan/08	10.268	29459	0,35
fev/08	26.596	29128	0,91
mar/08	62.443	22271	2,80
abr/08	35.907	22233	1,62
mai/08	4.007	25080	0,16
jun/08	-	29018	0,00
jul/08	3.918	25496	0,15
ago/08	3.195	25119	0,13
set/08	11.806	22903	0,52
out/08	34.162	19555	1,75

PERÍODO	REAL	MÉDIA-MÓVEL	SAZONALIDADE
nov/08	78.885	16563	4,76
dez/08	34.764	16652	2,09
jan/09	5.750	16652	0,35
fev/09	-	16849	0,00
mar/09	22.264	17207	1,29
abr/09	-	16223	0,00
mai/09	5.077	13376	0,38
jun/09	-	6803	0,00
jul/09	6.289	32107	0,20
ago/09	7.488		
set/09	-		
out/09	-		
nov/09	-		
dez/09	338.417		

Tabela 2 – Índices sazonais normalizados

Mês	Índice Sazonal Normalizado
Jan	0,29
Fev	0,96
Mar	1,18
Abr	0,82
Mai	0,31
Jun	1,13
Jul	0,41
Ago	0,90
Set	0,65
Out	1,32
Nov	1,72
Dez	2,30

Ressalta-se que a elaboração das previsões para efeitos comparativos restringiu-se aos três últimos anos fiscais, ou seja, ao período de janeiro de 2007 a dezembro de 2009, de forma a não estender demasiadamente o tempo de desenvolvimento prático do trabalho.

Prosseguindo com a execução da previsão, calcula-se então a regressão linear por meio da função ($Y = a + bX$) a partir da equação da reta. Em seguida, procede-se ao cálculo da tendência e do ciclo através da execução dos passos abaixo na ferramenta Microsoft® Excel:

- Cálculo do coeficiente angular (b) da série histórica através da função “inclinação”, na qual x representa o tempo e y a média móvel;

- Cálculo do coeficiente linear (a) através da função “intercepção”, na qual X representa o tempo e Y a média móvel;
- Cálculo da tendência através da fórmula:

$$\text{Coeficiente angular } (a) + \text{Coeficiente linear } (b) \times \text{tempo } (X) \quad (9)$$

- Cálculo do ciclo através da divisão da média móvel pela tendência.

Os coeficientes angular (b) e linear (a) encontrados são apresentados no Quadro 2:

Coeficiente Angular	258
Coeficiente Linear	6938

Quadro 2 – Coeficientes angular e linear

Fonte: Elaborado pela autora

A Tabela 3 apresenta o resultado destes cálculos. Como se pode perceber, as projeções de tendência são facilmente calculadas a partir da equação da curva que melhor se ajusta à série de médias móveis. No entanto, a projeção do movimento cíclico não é realizada internamente pelo método, tendo que ser avaliada pelo analista que executa o modelo. Deve-se sempre estar ciente de que esta componente representa as variações cíclicas de médio ou longo prazo, causadas principalmente pelos fatores econômicos. Assim, para previsões de curto prazo (por exemplo, alguns meses para frente), geralmente utiliza-se o último valor calculado para o ciclo. Em contrapartida, para previsões de longo prazo, o ciclo deve ser avaliado à parte, conforme sugerem Wanke e Julianelli (2006). Verifica-se a inexistência de tendências próprias para os meses 68 a 72 na Tabela 3 devido à média móvel centrada no mês de julho de 2009. Por esta razão, e para fins de estimativa de valor do ciclo, repete-se o último valor calculado (1,33) para os meses de agosto a dezembro de 2009.

Tabela 3 – Cálculo dos coeficientes angular e linear

PERÍODO	TEMPO	TENDÊNCIA	CICLO
jan/07	37	16.484	0,81
fev/07	38	16.742	0,80
mar/07	39	17.000	1,19
abr/07	40	17.258	1,12
mai/07	41	17.516	0,94
jun/07	42	17.774	1,03
jul/07	43	18.032	1,30
ago/07	44	18.290	1,29
set/07	45	18.548	1,39
out/07	46	18.806	1,64
nov/07	47	19.064	1,74
dez/07	48	19.322	1,66
jan/08	49	19.580	1,50
fev/08	50	19.838	1,47
mar/08	51	20.096	1,11
abr/08	52	20.354	1,09
mai/08	53	20.612	1,22
jun/08	54	20.870	1,39
jul/08	55	21.128	1,21
ago/08	56	21.386	1,17
set/08	57	21.644	1,06
out/08	58	21.902	0,89
nov/08	59	22.160	0,75
dez/08	60	22.418	0,74
jan/09	61	22.676	0,73
fev/09	62	22.934	0,73
mar/09	63	23.192	0,74
abr/09	64	23.450	0,69
mai/09	65	23.708	0,56
jun/09	66	23.966	0,28
jul/09	67	24.224	1,33
ago/09	68		1,33
set/09	69		1,33
out/09	70		1,33
nov/09	71		1,33
dez/09	72		1,33

O resultado das etapas e cálculos da decomposição clássica, realizados até aqui, para todos os anos da amostra, podem ser verificados no Anexo II.

Após realizar os cálculos descritos, recompõem-se os números por meio da fórmula $T \times S \times C$ para gerar a previsão probabilística, utilizando um intervalo de previsão de 95% de confiabilidade na verificação da dispersão do erro, máximo e mínimo. A Tabela 4 apresenta a recomposição realizada do período analisado:

Tabela 4 – Recomposição para o período de 2007 a 2009

TEMPO	SAZONALIDADE	PERÍODO	PREVISTO	DESVIO	MÁXIMO	MÍNIMO
37	0,24	jan/07	3.278,36	131,13	3.409,49	3.147,22
38	0,80	fev/07	10.712,86	428,51	11.141,38	10.284,35
39	0,99	mar/07	20.003,12	800,12	20.803,25	19.203,00
40	0,69	abr/07	13.259,03	530,36	13.789,39	12.728,67
41	0,26	mai/07	4.230,44	169,22	4.399,66	4.061,22
42	0,95	jun/07	17.384,24	695,37	18.079,61	16.688,87
43	0,35	jul/07	8.139,41	325,58	8.464,99	7.813,83
44	0,75	ago/07	17.750,16	710,01	18.460,16	17.040,15
45	0,54	set/07	13.937,33	557,49	14.494,83	13.379,84
46	1,11	out/07	34.131,76	1.365,27	35.497,03	32.766,49
47	1,44	nov/07	47.582,24	1.903,29	49.485,53	45.678,95
48	1,92	dez/07	61.653,70	2.466,15	64.119,85	59.187,55
49	0,24	jan/08	7.210,32	288,41	7.498,73	6.921,91
50	0,80	fev/08	23.260,96	930,44	24.191,39	22.330,52
51	0,99	mar/08	22.061,90	882,48	22.944,38	21.179,42
52	0,69	abr/08	15.276,85	611,07	15.887,93	14.665,78
53	0,26	mai/08	6.462,09	258,48	6.720,58	6.203,61
54	0,95	jun/08	27.477,14	1.099,09	28.576,22	26.378,05
55	0,35	jul/08	8.834,73	353,39	9.188,12	8.481,34
56	0,75	ago/08	18.961,84	758,47	19.720,32	18.203,37
57	0,54	set/08	12.405,77	496,23	12.902,00	11.909,54
58	1,11	out/08	21.610,53	864,42	22.474,96	20.746,11
59	1,44	nov/08	23.824,72	952,99	24.777,71	22.871,73
60	1,92	dez/08	31.989,11	1.279,56	33.268,68	30.709,55
61	0,24	jan/09	4.075,68	163,03	4.238,71	3.912,66
62	0,80	fev/09	13.455,43	538,22	13.993,65	12.917,22
63	0,99	mar/09	17.045,56	681,82	17.727,38	16.363,73
64	0,69	abr/09	11.147,55	445,90	11.593,45	10.701,65
65	0,26	mai/09	3.446,62	137,86	3.584,49	3.308,76
66	0,95	jun/09	6.441,44	257,66	6.699,10	6.183,78
67	0,35	jul/09	11.125,62	445,02	11.570,65	10.680,60
68	0,75	ago/09	24.579,21	983,17	25.562,37	23.596,04
69	0,54	set/09	17.822,94	712,92	18.535,86	17.110,03
70	1,11	out/09	36.742,33	1.469,69	38.212,02	35.272,63
71	1,44	nov/09	48.318,66	1.932,75	50.251,40	46.385,91
72	1,92	dez/09	65.188,64	2.607,55	67.796,19	62.581,10

4.2.2 Redes neurais artificiais

Para a aplicação do método de redes neurais artificiais na base de dados histórica, adotou-se o software NeuralTools® - Palisade. A arquitetura utilizada foi a do tipo *Generalized Regression Neural Network* (GRNN), que apresenta características mais atraentes tendo em vista o objetivo de uso como ferramenta preditiva que o tipo *Multi-Layer Feedforward* (MLF).

A principal vantagem das redes GRNN é que, ao contrário das redes MLF, elas não precisam de nenhuma configuração. Ao mesmo tempo, o grau de exatidão das previsões, de modo geral, é comparável aos dados das redes MLF

(NeuralTools, 2010). Outra vantagem encontrada, além do fato de não requererem especificação da topologia (número de camadas ocultas e nós), é o seu treinamento rápido, o que tende a facilitar e agilizar o processo de obtenção das previsões.

Para o treinamento da rede, foi adotado o método mais comumente utilizado no treinamento das RNAs, o de aprendizado supervisionado (BRAGA, CARVALHO e LUDERMIR, 2000), em que o conjunto de exemplos de entrada-saída são fornecidos pelo “professor” que disponibiliza seu conhecimento do ambiente para a rede neural através do treinamento, da forma mais completa possível (HAYKIN, 2001).

A investigação conduzida para a seleção das variáveis independentes a serem incorporadas no treinamento resultou na identificação de duas variáveis: a soma da potência dos equipamentos vendidos no mês na unidade MVA e o preço médio de geradores e transformadores elétricos em US\$/ton. Em conformidade ao exposto no início deste capítulo, essas variáveis apresentaram os resultados mais satisfatórios em relação aos padrões esperados.

Para a segunda variável independente - preço médio de geradores e transformadores elétricos em US\$/ton - uma defasagem de oito períodos ($n - 8$) foi considerada, visto que se trata do preço médio em condição de entrega FOB, e a média de prazo de entrega FOB da base histórica analisada, a partir da colocação da ordem de compra, é de respectivamente oito meses.

Variáveis independentes
Soma da potência dos equipamentos vendidos no mês na unidade MVA
Preço médio de geradores e transformadores elétricos em US\$/ton

Quadro 3 – Variáveis independentes para a rede neural

Fonte: Elaborado pela autora

O Gráfico 1 mostra a correlação entre as variáveis dependentes e independentes:

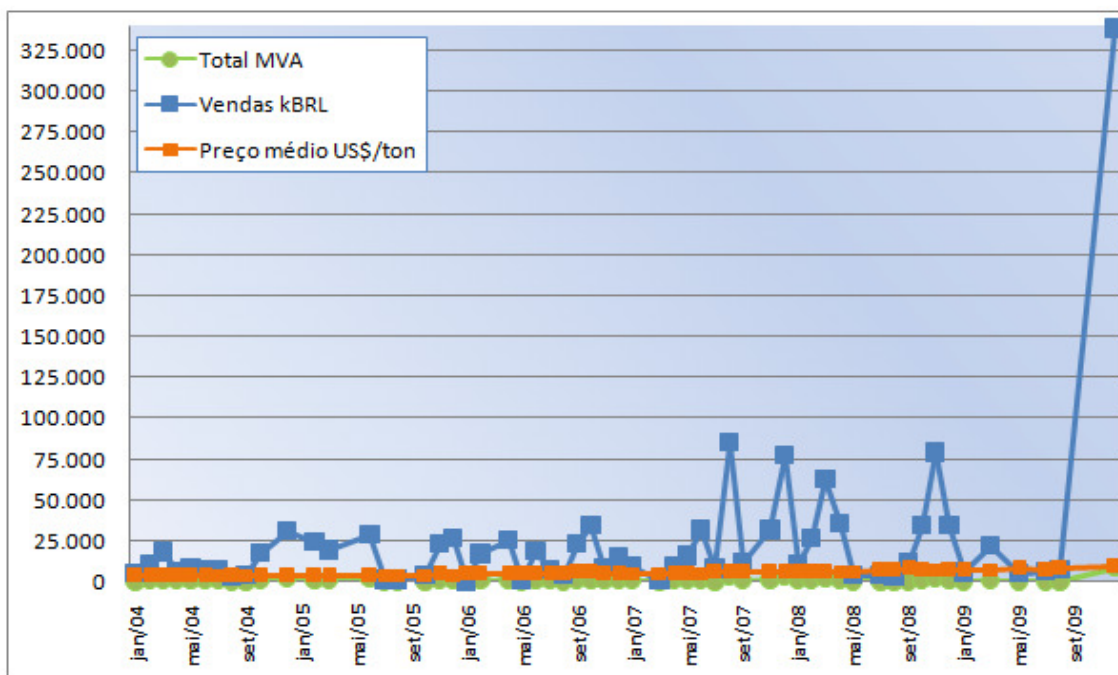


Gráfico 1 – Correlação entre variáveis dependentes e independentes

Fonte: Elaborado pela autora

Devido à diferença de valores em relação à variável dependente, fica difícil visualizar as linhas correspondentes às variáveis independentes. Com o intuito de permitir uma adequada compreensão da correlação entre as variáveis, elaborou-se a Figura 10 que ilustra parte do gráfico em foco, permitindo assim uma melhor visualização destas linhas.




Figura 10 – Correlação entre variáveis - linhas em foco

Fonte: Elaborada pela autora

A rede foi construída com duas variáveis de entrada e uma de saída. A base de dados, como já mencionado, foi constituída a partir de 72 observações mensais de cada variável, ou seja, um total de 216 observações. Os dados coletados foram separados em duas categorias: *dados de treinamento*, utilizados para o treinamento da rede, e *dados de teste*, que foram utilizados para verificar sua performance sob condições reais de utilização. O treinamento, como já mencionado, é uma etapa essencial do processo, visto que a propriedade mais importante das redes neurais é a sua habilidade de aprender.

Para a escolha da melhor proporção de dados a ser usada no treinamento, foram realizados inúmeros exercícios no software NeuralTools® considerando porcentagens de 10% a 90% e, entre esses, destacaram-se as redes treinadas com 90% das informações. A partir da média do erro, na realidade a média de todas as médias MAPE, calculada através de um total de 20 previsões geradas para cada configuração de treinamento, pôde-se encontrar aquela que gerou melhores resultados preditivos, conforme demonstrado no Quadro 4. Maiores detalhes das previsões que deram origem às médias encontradas podem ser verificados no Anexo III.

Treinamento %	2007	2008	2009
10	9,81%	15,07%	28,13%
20	8,29%	14,00%	20,65%
30	7,91%	12,32%	18,76%
40	5,72%	8,79%	15,05%
50	4,07%	9,14%	7,78%
60	4,75%	8,08%	6,99%
70	4,78%	7,84%	7,44%
80	1,77%	4,73%	3,55%
90	2,12%	3,67%	2,04%

Quadro 4 – Média MAPE das previsões - treinamento

Fonte: Elaborado pela autora

Como o objetivo deste trabalho é verificar a eficácia da previsibilidade do método, e o comparativo final não é feito com base nos dados remanescentes do treinamento, ou seja, no desempenho dos dados testados, não há problemas em considerar somente uma pequena parcela (10%) das informações no teste.

Percebeu-se que o uso de uma quantidade significativa de dados no treinamento contribuiu positivamente para o reconhecimento dos padrões de venda

pelas redes neurais. Quanto ao tempo de execução do treinamento, estabeleceu-se o limite de 1.000.000 tentativas como ponto de corte.

Dando continuidade à elaboração do modelo, cabe destacar as três etapas que configuram a análise de uma rede neural: treinamento dos dados para busca de padrões em um conjunto de dados conhecido, teste da rede neural para verificação de sua precisão diante de dados conhecidos e a execução de previsões com base nas redes treinadas. A seguir, descreve-se em detalhes o passo a passo realizado para a construção do modelo de redes neurais artificiais utilizando o software NeuralTools®:

- Primeiramente, deve-se definir os dados para o modelo através da função “*Data Set Manager*”, conforme demonstra a Figura 11:

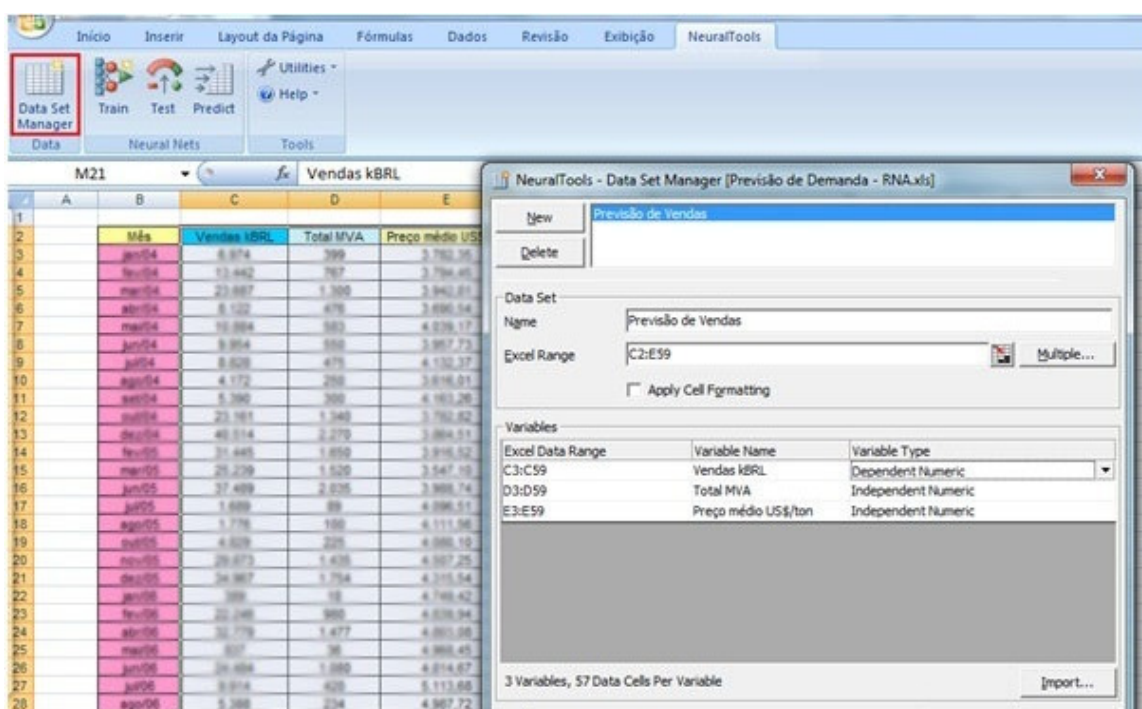


Figura 11 – Definição dos dados para o modelo RNA

Fonte: Elaborada pela autora

- Em seguida a rede deve ser testada para aprender os padrões através da base de dados por meio da função “*Train*”. Para isso deve-se definir o modo de treinamento desejado, programando a configuração da rede e o tempo de duração desejado (Figura 12):

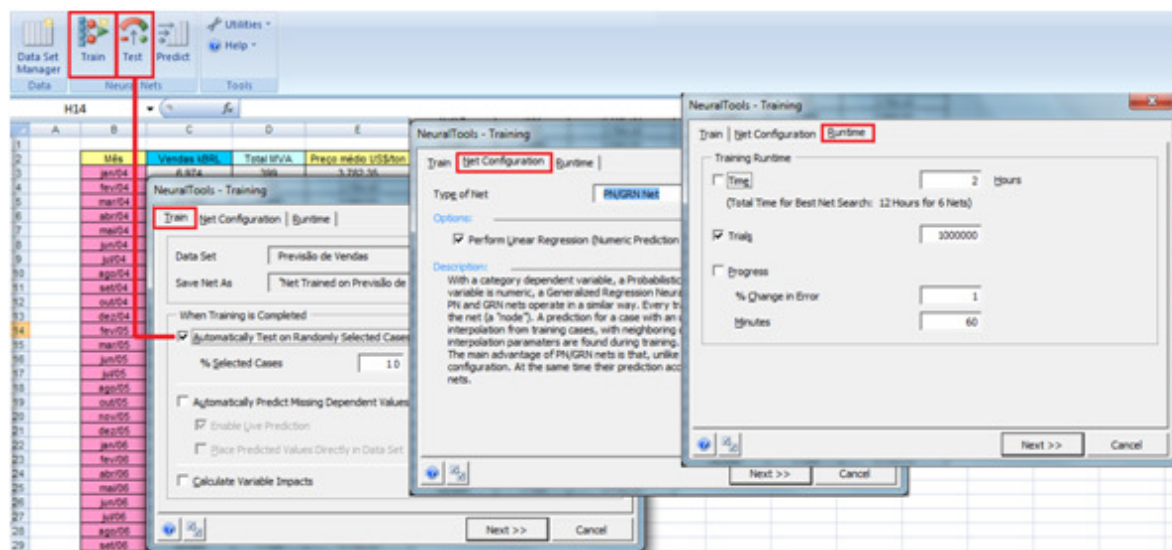


Figura 12 – Definição da configuração para treinamento da RNA

Fonte: Elaborada pela autora

Ao selecionar a opção “*Automatically Test on Randomly Selected Cases*”, o software automaticamente realiza, após a conclusão do treinamento, o teste em casos aleatoriamente selecionados na proporção de dados determinada, que neste caso foi de 90-10, ou seja, 90% para treinamento e 10% para testes.

- Por último, utiliza-se a função “*Predict*” para obter as previsões (Figura 13):

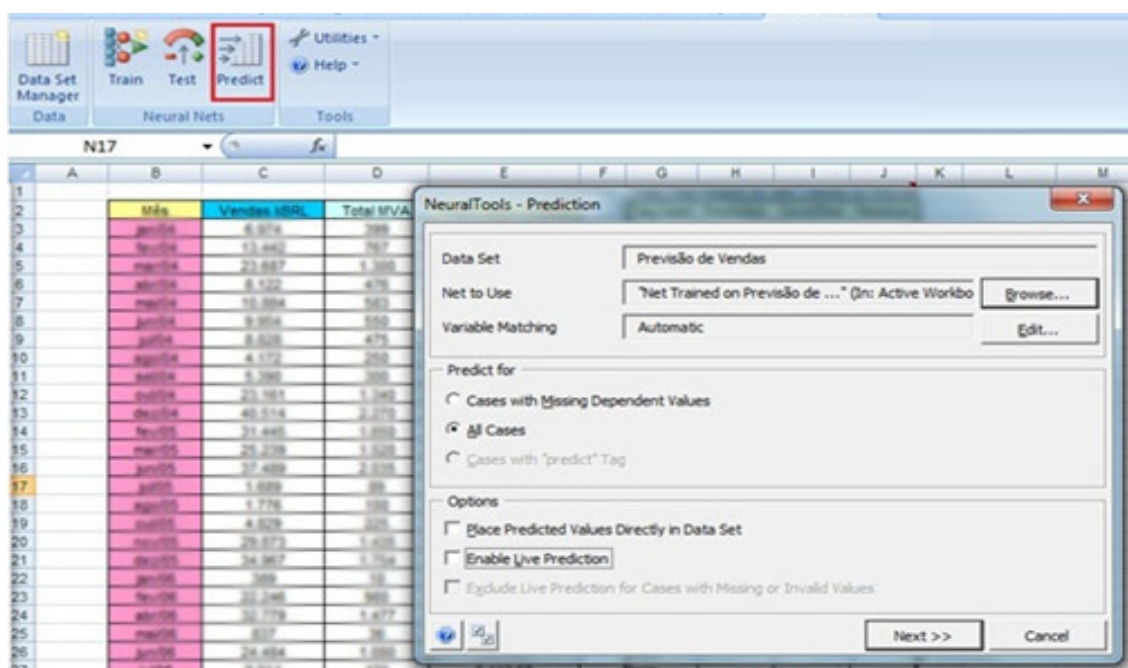


Figura 13 – Obtendo as previsões por meio da RNA

Fonte: Elaborada pela autora

Como a finalidade é obter os valores de vendas para os anos já conhecidos, de formar a se efetuar uma análise comparativa entre o realizado e o previsto, optou-se por selecionar a caixa “All cases”, assim o software gera automaticamente estimativas para todos os períodos de tempo.

4.3 ANÁLISE DOS MODELOS

Dentre os resultados encontrados a partir da decomposição clássica, calculados com média móvel $n = 12$, observa-se que o ano de 2009 apresentou a maior margem de erro, com 33%. Este fato deve-se ao montante elevado registrado no mês de dezembro, que colaborou significativamente para o desvio da previsão. Enquanto o valor registrado para o mês foi de kBRL 338.417,31, o método apontou uma previsão de kBRL 65.188,64, uma diferença de cerca de 419%. O Gráfico 2 mostra o comparativo entre os dados projetados e aqueles de fato verificados:




Gráfico 2 – Comparativo previsto e realizado - decomposição clássica

Fonte: Elaborado pela autora

No gráfico acima ilustrado, é possível verificar visualmente a presença desse ponto que muda drasticamente a estimação dos parâmetros. A observação do mês de dezembro de 2009 é tida como um *outlier*⁹, um ponto cujos resíduos têm valores muito maiores em módulo que os dos outros pontos.

⁹ Em estatística, um *outlier* é uma observação numericamente distante do restante dos dados.

Constatou-se que o ano de 2007, por sua vez, apresentou o melhor resultado entre as previsões do período analisado, tendo em vista a média do erro percentual absoluto (MAPE) encontrada, de apenas 11%, com um valor realizado de kBRL 281.871,84 *versus* o estimado de kBRL 252.062,65. Mesmo tendo apresentado um resultado bastante favorável, verifica-se que algumas previsões deste mesmo ano ficaram significativamente distantes dos valores realizados, como foi o caso do mês de agosto, em que o montante de vendas foi de kBRL 85.480,80 e a previsão calculada de kBRL 17.750,16, uma diferença de kBRL 67.730,65, aproximadamente 382%. Verifica-se que nos demais anos o mês de agosto apresentou valores registrados muito inferiores ao de 2007, configurando, portanto, uma disparidade causada por um comportamento não usual de demanda.

A respeito do ano de 2008, notou-se que, apesar do MAPE de 28%, as diferenças mensais do comparativo de valores realizados e previstos foram razoavelmente baixas, quando comparadas aos outros dois anos verificados. A diferença mais significativa foi de 231% para o mês de novembro, o qual apresentou um resultado de vendas atípico, o que justifica tal discrepância.

No Quadro 5 são expostos os resultados das médias de erros encontrados nas previsões do método de decomposição clássica.

Decomposição clássica	2007	2008	2009
MAPE ($n = 12$)	11,0%	28,0%	33,0%

Quadro 5 – MAPE das previsões - Decomposição clássica

Fonte: Elaborado pela autora

No que concerne às previsões obtidas através das redes neurais artificiais, conforme exposto anteriormente, foram geradas algumas previsões na ferramenta NeuralTools®, de forma a se obter uma gama de cenários para análise. Uma vez que cada previsão gerada reflete as escolhas aleatórias realizadas pelo software, o mais adequado não é considerar somente um conjunto de estimativas obtidas, ou aquela que gerou o melhor resultado aparentemente, pois desta forma a capacidade preditiva da ferramenta não é apropriadamente refletida. Portanto, optou-se por compor o resultado a ser utilizado para a finalidade comparativa a partir de uma média das médias dos erros (MAPE) encontrados em 20 previsões geradas para

cada um dos três anos, utilizando 90% dos dados para treinamento e 10% para testes, proporção previamente percebida como a mais satisfatória. A Tabela 5 apresenta o resultado das previsões geradas:

Tabela 5 – MAPE das previsões geradas com treinamento de 90% dos dados - RNA

Treinamento 90%	MAPE		
	2007	2008	2009
Previsão 1	0,81%	3,02%	0,04%
Previsão 2	1,37%	11,00%	23,15%
Previsão 3	14,61%	6,45%	4,50%
Previsão 4	0,10%	3,45%	1,84%
Previsão 5	1,46%	3,36%	0,69%
Previsão 6	0,58%	3,45%	0,59%
Previsão 7	13,40%	5,82%	4,59%
Previsão 8	0,86%	2,11%	0,69%
Previsão 9	0,60%	2,67%	0,55%
Previsão 10	0,10%	2,51%	0,04%
Previsão 11	2,38%	8,31%	0,01%
Previsão 12	0,66%	1,74%	0,06%
Previsão 13	0,69%	2,82%	0,11%
Previsão 14	0,95%	2,48%	0,31%
Previsão 15	1,88%	3,39%	0,44%
Previsão 16	0,15%	2,21%	0,47%
Previsão 17	0,60%	1,46%	1,45%
Previsão 18	0,44%	3,04%	0,72%
Previsão 19	0,07%	1,73%	0,59%
Previsão 20	0,71%	2,42%	0,04%

O resultado da medição dos erros por meio do método MAPE aplicada ao conjunto das 20 previsões acima pode ser visto no Quadro 6:

Redes neurais	2007	2008	2009
MAPE	2,12%	3,67%	2,04%

Quadro 6 – MAPE das previsões - RNA

Fonte: Elaborado pela autora

É admirável a capacidade de previsão obtida por meio das redes neurais. O resultado de 2009 apresentou o menor erro de previsão, somente 2,04%, percentual nada semelhante ao encontrado no método de decomposição clássica. O poder de

reconhecer os padrões e de prover resultados muito próximos aos reais é, sem dúvida, um ponto forte desse método.

Na análise dos demais anos, identificou-se que o maior erro de previsão encontrado no período, 3,67%, estava vinculado ao ano de 2008. Tal resultado reflete o conjunto das previsões geradas, em que se pode constatar os maiores percentuais de MAPE ao longo dos 20 cenários, estando 65% dos erros concentrados na faixa de 2% a 4%.

Entre os valores da Tabela 5, mesmo ao se considerar os percentuais mais altos encontrados nas previsões de cada ano, pode-se perceber que as redes neurais mostram-se eficazes na estimação de valores. No ano de 2008 e 2009, por exemplo, os maiores valores encontrados foram de 11% e 23,15%, respectivamente. Para o ano de 2007, todavia, o erro médio mais alto foi de 14,61%, seguido de um segundo percentual, também razoavelmente elevado, de 13,4%, ambos superiores ao MAPE encontrado através da decomposição clássica, que foi de 11%. Contudo, as demais previsões para 2007 mostraram-se efetivamente satisfatórias, com cerca de 70% dos erros médios absolutos situados abaixo de 1%.

De forma a criar um contraponto ao Gráfico 2, utilizou-se os dados resultantes da Previsão 10 da Tabela 5 para ilustrar o bom desempenho preditivo das RNAs através do Gráfico 3:




Gráfico 3 – Comparativo previsto e realizado - RNA

Fonte: Elaborado pela autora

A previsão completa mensal resultante de ambas as técnicas para o período analisado pode ser verificada nos anexos IV e V.

O desempenho de cada método é colocado à prova a partir do comparativo dos valores realizados e projetados. Conforme mostra o Quadro 7, percebe-se uma melhor performance com o uso da técnica de redes neurais artificiais. Os resultados estatísticos mostram que a ferramenta é, de fato, nesse caso, a mais apropriada para a previsão.

MAPE	2007	2008	2009
Decomposição clássica	11,0%	28,0%	33,0%
Redes neurais	2,12%	3,67%	2,04%

Quadro 7 – Comparativo dos erros das previsões

Fonte: Elaborado pela autora

Convém ressaltar que o sucesso das aplicações por meio de redes neurais se deve, principalmente, aos dados complementares utilizados na previsão, ou seja, às variáveis de entrada associadas à rede neural de base radial, com os quais as vendas se inter-relacionam e que, de certa forma, balizam os preços e o volume de vendas no mercado de transmissão e distribuição de energia.

A relação MVA/preço é um fator muito utilizado no mercado de produtos para transmissão e distribuição de energia como indicativo de competitividade. O preço médio de venda por tonelada, por sua vez, serve para entender e alinhar o comportamento das vendas ao do mercado. Ambas as variáveis certamente contribuíram para agregar valor à capacidade preditiva das redes neurais artificiais.

5. CONSIDERAÇÕES FINAIS

Este trabalho foi desenvolvido com o propósito de selecionar um modelo quantitativo de previsão de demanda como alternativa ao atual método qualitativo adotado pela empresa em questão, ao mesmo tempo em que contribui com uma análise comparativa entre os métodos de decomposição clássica e redes neurais artificiais. O método quantitativo tende a trazer benefícios à organização, como maior assertividade na sua tomada de decisões e melhorias ao seu planejamento estratégico.

O método de previsão apontado como o mais adequado a partir dos resultados alcançados – as redes neurais artificiais – foi favorável na previsão de demanda de produtos de transmissão e distribuição de energia, superando a modelagem de decomposição clássica. Ao considerar a medição dos erros entre os valores previstos e realizados, a previsão gerada mostrou-se confiável, tendo em vista os baixos percentuais de MAPE apresentados.

A utilização da inteligência artificial para a formação de estimativas de demanda é uma alternativa viável aos métodos tradicionais. Uma de suas vantagens é a versatilidade quanto a mudanças nos dados, bastando treinar a rede novamente para que seus pesos sinápticos sejam realocados. No caso do software NeuralTools®, a vantagem é ainda maior, uma vez que a atualização das previsões é automaticamente realizada à medida que mudanças nos dados são efetuadas. Sendo assim, o usuário não necessita gerar novas previsões quando informações são adicionadas ou alteradas.

Adicionalmente, entre as características que melhor explicam o potencial das redes neurais sobressaem-se a adaptabilidade, paralelismo, possibilidade de manipulação eficiente de grandes quantidades de dados, sua capacidade de generalização, sua tolerância a dados ruidosos e incompletos e a rapidez de resposta, as quais proporcionam uma ferramenta matemática promissora para aplicações práticas.

Entre as limitações práticas encontradas na execução do trabalho, destaca-se a dificuldade em encontrar variáveis numéricas que retratem de forma abrangente as influências sobre a demanda de produtos de transmissão e distribuição de energia. A soma total da potência em MVA dos equipamentos vendidos mensalmente e o

preço médio de geradores e transformadores elétricos em US\$/ton foram, entre as variáveis analisadas, aquelas que demonstraram melhor correlação com as vendas. A pesquisa e seleção de outras ou de melhores variáveis torna-se, então, uma possibilidade e um desafio para a realização de trabalhos futuros ou mesmo aperfeiçoamento deste.

Optou-se, ainda, por analisar comparativamente somente o histórico de vendas, não estendendo a aplicação para períodos futuros. Da mesma forma que, objetivando uma simplificação, não foram contemplados todos os anos da amostra no comparativo, somente uma parcela. Sugere-se, portanto, a incorporação dessas informações e projeções em outros trabalhos ou pesquisas que possam vir a ser realizados acerca deste tema.

Outras arquiteturas e configurações de redes neurais podem ainda ser testadas futuramente, a fim de se verificar a consistência dos resultados das redes neurais como um todo ou mesmo a existência de melhores sistemas configuracionais para o processamento das previsões.

É importante salientar que este trabalho não tem a pretensão de estabelecer que as redes neurais artificiais apresentam-se como o melhor método de realização de previsão de valores futuros de demanda, até porque o presente estudo contempla apenas um comparativo entre dois métodos, não podendo, assim, seu resultado ser generalizado. Entretanto, pelo observado, pode-se dizer com certa confiança, que elas são uma ferramenta poderosa capaz de realizar previsões com um excelente nível de precisão.

A busca por uma ferramenta quantitativa para o processo estimativo de vendas futuras da AREVA T&D Brasil não somente resultou na seleção de um modelo bastante satisfatório para esse fim, como também propiciou uma ferramenta alternativa de apoio na tomada de decisões da empresa.

REFERÊNCIAS BIBLIOGRÁFICAS

ABINEE - Associação Brasileira da Indústria Elétrica e Eletrônica. **Desempenho setorial - 1º trimestre 2010**. Disponível em: <<http://www.abinee.org.br/abinee/decon/decon11.htm>>. Acesso em 15 abr. 2010.

ARMSTRONG, J. S.; GREEN, K. C. **Demand forecasting: evidence-based methods**. In: MOUTINHO, L. & SOUTHERN, G. Strategic marketing management: a business process approach, 2005.

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. São Paulo: Bookman, 2006.

BECKER, João. L. **Técnicas de previsão**. Porto Alegre: PPGA/UFRGS, 1999 (Notas de aula).

BERRY, Michael J.A.; LINOFF, Gordon. **Data mining techniques for marketing, sales and customer support**. John Wiley & Sons, 1997.

BRAGA, Antônio de P.; CARVALHO, André P. L. F.; LUDERMIR, Teresa B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.

CLANCY, Kevin J.; KRIEG, Peter C. **Marketing contra-intuitivo**. Rio de Janeiro: Campus, 2007.

DAVIS, Mark M.; AQUILANO, Nicholas J.; CHASE, Richard B. **Fundamentos da administração da produção**. Porto Alegre: Bookman, 2001.

DETIENNE, Kristen B.; DETIENNE, David H.; JOSHI, Shirish A. Neural networks as statistical tools for business researchers. **Organizational Research Methods**, Thousand Oaks, v.6, n.2, p.236-265, 2003.

DIAS, M. A. P. **Administração de materiais: uma abordagem logística**. São Paulo: Atlas, 1993.

DIEBOLD, Francis X. **Elements of forecasting**. Manson, Ohio: Thomson/South-Western, 2004.

FREEMAN, James A.; SKAPURA, David M. **Neural networks: algorithms, applications and programming techniques**. Addison-Wesley, 1992.

GAITHER, Norman; FRAZIER, Greg. **Administração da produção e operações**. São Paulo: Thomson Learning, 2002.

GOMES, Luiz F.A.M. **Teoria da decisão**. São Paulo: Thompson Learning, 2007.

HANKE, J; REITSCH, C. **Business forecasting**. Prentice Hall, 1992.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

KOTLER, P. **Administração de marketing**. São Paulo: Prentice Hall, 2000.

KOVÁCS, Zsolt L. **Redes neurais artificiais, fundamentos e aplicações: um texto básico**. São Paulo: Collegium Cognitio, 1996.

MDIC - Ministério do Desenvolvimento, Indústria e Comércio. **Balança Comercial Brasileira Mensal. IV - Exportação. Principais produtos por Fator Agregado – mensal (US\$ e kg). Motores, geradores e transformadores elétricos e suas partes**. Disponível em: <<http://www.desenvolvimento.gov.br/sitio/interna/interna.php?area=5&menu=2039&ref=1161>>. Acesso em 12 maio 2010.

MOREIRA, Daniel Augusto. **Administração da produção e operações**. São Paulo: Cengage Learning, 2008.

NeuralTools® - Palisade. **O Novo NeuralTools**. Disponível em: <<http://www.palisade-br.com/neuraltools/>>. Acesso em 22 abr. 2010.

PELLEGRINI, F.R.; FOGLIATTO, F. Estudo comparativo entre modelos de Winters e de Box-Jenkins para a previsão de demanda sazonal. **Revista Produto & Produção**, v. 4, número especial, abril de 2000. p.72-85.

REUTERS. **Demanda deve crescer 5% em 2010, prevê ONS**. Disponível em: <<http://www1.folha.uol.com.br/folha/dinheiro/ult91u639125.shtml>>. Acesso em 24 out. 2009.

RITZMAN, Larry P.; KRAJEWSKI, Lee J. **Administração da produção e operações**. São Paulo: Prentice Hall, 2004.

SARIMVEIS, H. et al. Fast and efficient algorithm for training radial basis function neural networks based on a fuzzy partition of the input space. **Industrial Engineering Chemical Research**, v. 41, n. 4, p. 751-759, 2002.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da produção**. São Paulo: Atlas, 2002.

SRZD - Portal Sydney Rezende. **Desempenho do BNDES atinge recorde no primeiro semestre de 2009**. Disponível em: <<http://www.sidneyrezende.com/noticia/46186+desempenho+do+bndes+atinge+recorde+no+primeiro+semestre+de+2009>>. Acesso em 25 out. 2009.

STEVENSON, William J. **Administração das operações de produção**. Rio de Janeiro: LTC, 2001.

TSOUKALAS, L. H.; UHRIG, R. E. **Fuzzy and neural approaches in engineering**. New York: John Wiley & Sons, Inc., 1996, p. 326-327.

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

WANKE, Peter; JULIANELLI, Leonardo. **Previsão de vendas**. São Paulo: Atlas, 2006.

WEO – World Energy Outlook. **Resumen Ejecutivo 2009**. Disponível em: <http://www.worldenergyoutlook.org/docs/weo2009/WEO2009_es_spanish.pdf>. Acesso em 19 jun. 2010.

Anexo I – Amostra: variáveis dependentes e independentes

Mês	Vendas kBRL (1)	Total MVA (2)	Preço médio US\$/ton (3)
jan/04	5.370	307	3.782,35
fev/04	10.350	591	3.794,45
mar/04	18.239	1.001	3.942,81
abr/04	6.254	367	3.690,54
mai/04	8.381	449	4.039,17
jun/04	7.664	424	3.957,73
jul/04	6.798	366	4.132,37
ago/04	3.212	193	3.616,01
set/04	4.151	231	4.163,26
out/04	17.834	1.032	3.782,82
dez/04	31.196	1.748	3.864,51
fev/05	24.213	1.271	3.916,52
mar/05	19.434	1.170	3.547,10
jun/05	28.866	1.567	3.988,74
jul/05	1.300	69	4.096,51
ago/05	1.367	77	4.111,56
out/05	3.718	173	4.080,10
nov/05	23.002	1.105	4.507,25
dez/05	26.925	1.351	4.315,54
jan/06	300	14	4.749,42
fev/06	17.129	755	4.839,94
abr/06	25.240	1.137	4.803,08
mai/06	645	28	4.968,45
jun/06	18.853	832	4.814,67
jul/06	7.634	323	5.113,68
ago/06	4.149	180	4.987,72
set/06	23.022	870	5.732,33
out/06	34.532	1.281	5.832,39
nov/06	8.332	354	5.095,62
dez/06	15.470	661	5.067,10
jan/07	9.969	408	5.267,71
mar/07	590	25	5.282,05
abr/07	9.586	402	5.163,41
mai/07	15.827	693	4.968,90
jun/07	31.617	1.251	5.471,25
jul/07	7.884	273	6.245,02
ago/07	85.481	3.272	5.655,99
set/07	12.264	470	5.733,99
nov/07	31.622	1.226	5.585,36
dez/07	77.031	2.874	5.802,43
jan/08	10.268	380	5.847,02
fev/08	26.596	971	5.930,21
mar/08	62.443	2.233	6.053,97
abr/08	35.907	1.203	6.462,93
mai/08	4.007	133	6.506,90
jul/08	3.918	116	6.975,18
ago/08	3.195	94	7.353,37
set/08	11.806	308	8.385,64
out/08	34.162	1.005	7.360,18
nov/08	78.885	2.191	7.795,54
dez/08	34.764	1.029	7.313,07
jan/09	5.750	179	6.908,88
mar/09	22.264	620	7.774,97
mai/09	5.077	139	7.852,08
jul/09	6.289	186	7.296,00
ago/09	7.488	193	8.385,50
dez/09	338.417	8.239	9.325,33

Anexo II – Etapas da elaboração do modelo de decomposição clássica

PERÍODO	REAL	MÉDIA-MÓVEL	SAZONALIDADE	TEMPO	TENDÊNCIA	CICLO
jan/04	5.370			1		
fev/04	10.350			2		
mar/04	18.239			3		
abr/04	6.254			4		
mai/04	8.381			5		
jun/04	7.664			6		
jul/04	6.798	9954	0,68	7	8744	1,14
ago/04	3.212	9507	0,34	8	9002	1,06
set/04	4.151	10662	0,39	9	9260	1,15
out/04	17.834	10761	1,66	10	9518	1,13
nov/04	-	10240	0,00	11	9776	1,05
dez/04	31.196	9542	3,27	12	10034	0,95
jan/05	-	11309	0,00	13	10292	1,10
fev/05	24.213	10851	2,23	14	10550	1,03
mar/05	19.434	10697	1,82	15	10808	0,99
abr/05	-	10351	0,00	16	11066	0,94
mai/05	-	9175	0,00	17	11324	0,81
jun/05	28.866	11091	2,60	18	11582	0,96
jul/05	1.300	10735	0,12	19	11840	0,91
ago/05	1.367	10760	0,13	20	12098	0,89
set/05	-	10170	0,00	21	12356	0,82
out/05	3.718	8551	0,43	22	12614	0,68
nov/05	23.002	10654	2,16	23	12872	0,83
dez/05	26.925	10708	2,51	24	13130	0,82
jan/06	300	9873	0,03	25	13388	0,74
fev/06	17.129	10401	1,65	26	13646	0,76
mar/06	-	10633	0,00	27	13904	0,76
abr/06	25.240	12551	2,01	28	14162	0,89
mai/06	645	15119	0,04	29	14420	1,05
jun/06	18.853	13897	1,36	30	14678	0,95
jul/06	7.634	12942	0,59	31	14936	0,87
ago/06	4.149	13748	0,30	32	15194	0,90
set/06	23.022	12320	1,87	33	15452	0,80
out/06	34.532	12370	2,79	34	15710	0,79
nov/06	8.332	11065	0,75	35	15968	0,69
dez/06	15.470	12330	1,25	36	16226	0,76
jan/07	9.969	13394	0,74	37	16484	0,81
fev/07	-	13415	0,00	38	16742	0,80
mar/07	590	20193	0,03	39	17000	1,19
abr/07	9.586	19296	0,50	40	17258	1,12
mai/07	15.827	16418	0,96	41	17516	0,94
jun/07	31.617	18359	1,72	42	17774	1,03
jul/07	7.884	23489	0,34	43	18032	1,30
ago/07	85.481	23514	3,64	44	18290	1,29
set/07	12.264	25731	0,48	45	18548	1,39
out/07	-	30885	0,00	46	18806	1,64
nov/07	31.622	33078	0,96	47	19064	1,74
dez/07	77.031	32093	2,40	48	19322	1,66
jan/08	10.268	29459	0,35	49	19580	1,50
fev/08	26.596	29128	0,91	50	19838	1,47
mar/08	62.443	22271	2,80	51	20096	1,11
abr/08	35.907	22233	1,62	52	20354	1,09
mai/08	4.007	25080	0,16	53	20612	1,22
jun/08	-	29018	0,00	54	20870	1,39
jul/08	3.918	25496	0,15	55	21128	1,21
ago/08	3.195	25119	0,13	56	21386	1,17
set/08	11.806	22903	0,52	57	21644	1,06
out/08	34.162	19555	1,75	58	21902	0,89
nov/08	78.885	16563	4,76	59	22160	0,75
dez/08	34.764	16652	2,09	60	22418	0,74
jan/09	5.750	16652	0,35	61	22676	0,73
fev/09	-	16849	0,00	62	22934	0,73
mar/09	22.264	17207	1,29	63	23192	0,74
abr/09	-	16223	0,00	64	23450	0,69
mai/09	5.077	13376	0,38	65	23708	0,56
jun/09	-	6803	0,00	66	23966	0,28
jul/09	6.289	32107	0,20	67	24224	1,33
ago/09	7.488			68		1,33
set/09	-			69		1,33
out/09	-			70		1,33
nov/09	-			71		1,33
dez/09	338.417			72		1,33

Anexo III – Exercícios para definição da configuração de treinamento

Treinamento 90%	MAPE		
	2007	2008	2009
Previsão 1	0,81%	3,02%	0,04%
Previsão 2	1,37%	11,00%	23,15%
Previsão 3	14,61%	6,45%	4,50%
Previsão 4	0,10%	3,45%	1,84%
Previsão 5	1,46%	3,36%	0,69%
Previsão 6	0,58%	3,45%	0,59%
Previsão 7	13,40%	5,82%	4,59%
Previsão 8	0,86%	2,11%	0,69%
Previsão 9	0,60%	2,67%	0,55%
Previsão 10	0,10%	2,51%	0,04%
Previsão 11	2,38%	8,31%	0,01%
Previsão 12	0,66%	1,74%	0,06%
Previsão 13	0,69%	2,82%	0,11%
Previsão 14	0,95%	2,48%	0,31%
Previsão 15	1,88%	3,39%	0,44%
Previsão 16	0,15%	2,21%	0,47%
Previsão 17	0,60%	1,46%	1,45%
Previsão 18	0,44%	3,04%	0,72%
Previsão 19	0,07%	1,73%	0,59%
Previsão 20	0,71%	2,42%	0,04%
Média	2,12%	3,67%	2,04%

Treinamento 80%	MAPE		
	2007	2008	2009
Previsão 1	1,42%	2,56%	0,35%
Previsão 2	0,84%	5,34%	3,78%
Previsão 3	0,65%	3,64%	0,69%
Previsão 4	1,50%	1,58%	2,48%
Previsão 5	0,74%	10,28%	22,37%
Previsão 6	1,04%	2,80%	1,02%
Previsão 7	0,67%	2,65%	1,87%
Previsão 8	0,99%	10,12%	2,49%
Previsão 9	0,83%	9,77%	21,69%
Previsão 10	0,30%	2,19%	0,19%
Previsão 11	1,03%	1,27%	2,69%
Previsão 12	15,97%	7,08%	4,35%
Previsão 13	3,23%	2,83%	1,01%
Previsão 14	0,21%	4,36%	0,74%
Previsão 15	0,39%	2,88%	0,91%
Previsão 16	0,02%	0,38%	2,99%
Previsão 17	2,12%	12,27%	0,18%
Previsão 18	1,65%	3,78%	0,64%
Previsão 19	0,28%	0,49%	0,53%
Previsão 20	1,52%	8,25%	0,07%
Média	1,77%	4,73%	3,55%

Treinamento 70%	MAPE		
	2007	2008	2009
Previsão 1	14,71%	9,28%	0,22%
Previsão 2	8,97%	7,90%	1,97%
Previsão 3	1,75%	3,86%	1,00%
Previsão 4	1,15%	9,24%	20,50%
Previsão 5	5,36%	4,03%	0,46%
Previsão 6	1,62%	2,29%	0,48%
Previsão 7	17,40%	8,21%	3,40%
Previsão 8	1,29%	1,36%	1,81%
Previsão 9	4,04%	3,52%	0,30%
Previsão 10	0,47%	9,40%	21,25%
Previsão 11	4,31%	17,15%	1,10%
Previsão 12	0,46%	8,59%	19,96%
Previsão 13	19,46%	9,91%	2,20%
Previsão 14	4,19%	13,60%	25,57%
Previsão 15	1,35%	8,40%	1,88%
Previsão 16	2,16%	7,29%	0,75%
Previsão 17	4,87%	4,81%	2,13%
Previsão 18	0,45%	9,04%	21,26%
Previsão 19	0,20%	9,25%	21,17%
Previsão 20	1,39%	9,63%	1,40%
Média	4,78%	7,84%	7,44%

Treinamento 60%	MAPE		
	2007	2008	2009
Previsão 1	2,00%	7,79%	20,37%
Previsão 2	1,45%	1,00%	1,70%
Previsão 3	0,79%	10,11%	0,81%
Previsão 4	2,98%	8,86%	22,58%
Previsão 5	2,98%	9,07%	0,80%
Previsão 6	3,91%	13,06%	24,95%
Previsão 7	18,52%	7,20%	3,68%
Previsão 8	0,86%	0,10%	3,52%
Previsão 9	1,86%	1,26%	4,42%
Previsão 10	2,53%	7,60%	0,98%
Previsão 11	2,56%	3,73%	0,98%
Previsão 12	1,68%	9,29%	22,46%
Previsão 13	0,06%	2,07%	2,20%
Previsão 14	4,02%	10,00%	0,22%
Previsão 15	13,47%	16,07%	2,52%
Previsão 16	12,20%	16,41%	2,50%
Previsão 17	17,39%	9,68%	0,96%
Previsão 18	2,04%	11,30%	23,37%
Previsão 19	1,03%	7,41%	0,40%
Previsão 20	2,68%	9,61%	0,43%
Média	4,75%	8,08%	6,99%

Treinamento 50%	MAPE		
	2007	2008	2009
Previsão 1	3,04%	12,04%	2,97%
Previsão 2	3,20%	5,55%	0,13%
Previsão 3	12,12%	2,16%	1,47%
Previsão 4	3,76%	4,31%	1,94%
Previsão 5	1,47%	9,08%	19,93%
Previsão 6	3,60%	19,09%	2,98%
Previsão 7	25,19%	13,07%	0,76%
Previsão 8	4,34%	15,25%	28,08%
Previsão 9	1,76%	11,68%	1,38%
Previsão 10	0,59%	8,44%	19,68%
Previsão 11	4,64%	0,43%	3,09%
Previsão 12	2,65%	16,37%	1,21%
Previsão 13	3,97%	13,33%	2,22%
Previsão 14	1,30%	1,29%	0,84%
Previsão 15	2,57%	3,41%	1,36%
Previsão 16	0,08%	9,20%	20,80%
Previsão 17	2,77%	1,93%	3,58%
Previsão 18	0,08%	9,44%	21,34%
Previsão 19	2,37%	7,01%	19,19%
Previsão 20	1,86%	19,69%	2,69%
Média	4,07%	9,14%	7,78%

Treinamento 40%	MAPE		
	2007	2008	2009
Previsão 1	17,85%	4,73%	3,10%
Previsão 2	1,54%	12,00%	24,77%
Previsão 3	8,05%	10,62%	1,88%
Previsão 4	2,11%	9,54%	20,68%
Previsão 5	0,20%	4,05%	1,73%
Previsão 6	19,63%	15,03%	5,79%
Previsão 7	1,90%	7,23%	3,78%
Previsão 8	1,15%	8,89%	21,29%
Previsão 9	3,36%	15,07%	28,42%
Previsão 10	4,90%	3,52%	15,54%
Previsão 11	8,18%	6,23%	21,98%
Previsão 12	22,55%	12,25%	0,15%
Previsão 13	0,07%	6,48%	16,98%
Previsão 14	1,52%	10,20%	22,08%
Previsão 15	4,17%	6,99%	20,25%
Previsão 16	8,47%	3,66%	17,94%
Previsão 17	3,45%	17,03%	31,31%
Previsão 18	0,42%	8,00%	6,51%
Previsão 19	3,13%	5,18%	16,80%
Previsão 20	1,82%	9,19%	20,04%
Média	5,72%	8,79%	15,05%

Treinamento 30%	MAPE		
	2007	2008	2009
Previsão 1	11,13%	20,28%	31,61%
Previsão 2	3,14%	12,93%	25,11%
Previsão 3	5,90%	7,46%	22,30%
Previsão 4	7,01%	18,23%	31,26%
Previsão 5	6,74%	6,63%	21,41%
Previsão 6	27,96%	18,07%	5,12%
Previsão 7	5,61%	16,58%	29,27%
Previsão 8	5,49%	0,62%	11,62%
Previsão 9	5,66%	17,04%	29,93%
Previsão 10	1,02%	11,22%	25,02%
Previsão 11	3,94%	3,60%	14,78%
Previsão 12	0,92%	9,17%	2,01%
Previsão 13	3,95%	1,42%	0,07%
Previsão 14	17,83%	23,86%	5,36%
Previsão 15	11,90%	21,61%	33,56%
Previsão 16	23,42%	14,17%	2,35%
Previsão 17	9,27%	1,82%	0,26%
Previsão 18	0,54%	15,32%	30,64%
Previsão 19	4,52%	14,65%	27,16%
Previsão 20	2,27%	11,62%	26,43%
Média	7,91%	12,32%	18,76%

Treinamento 20%	MAPE		
	2007	2008	2009
Previsão 1	2,51%	14,84%	28,09%
Previsão 2	1,17%	6,60%	17,05%
Previsão 3	7,95%	7,03%	22,98%
Previsão 4	5,69%	16,11%	28,27%
Previsão 5	18,22%	13,37%	1,54%
Previsão 6	3,85%	16,70%	30,34%
Previsão 7	0,23%	10,41%	23,17%
Previsão 8	15,21%	23,44%	34,37%
Previsão 9	15,59%	27,49%	40,49%
Previsão 10	33,74%	24,47%	1,16%
Previsão 11	1,78%	12,97%	25,64%
Previsão 12	33,30%	18,09%	1,73%
Previsão 13	9,50%	18,59%	29,99%
Previsão 14	0,46%	12,67%	5,74%
Previsão 15	4,91%	8,83%	18,37%
Previsão 16	0,30%	14,91%	30,36%
Previsão 17	2,25%	3,77%	9,86%
Previsão 18	5,55%	12,53%	23,31%
Previsão 19	1,76%	8,43%	19,11%
Previsão 20	1,80%	8,79%	21,40%
Média	8,29%	14,00%	20,65%

Treinamento 10%	MAPE		
	2007	2008	2009
Previsão 1	5,42%	12,89%	30,68%
Previsão 2	23,67%	35,52%	47,81%
Previsão 3	28,17%	19,38%	7,39%
Previsão 4	1,56%	2,08%	4,28%
Previsão 5	5,72%	15,11%	25,60%
Previsão 6	4,18%	5,68%	14,13%
Previsão 7	10,29%	7,55%	2,66%
Previsão 8	20,93%	7,71%	29,55%
Previsão 9	9,26%	14,71%	24,00%
Previsão 10	7,43%	21,19%	35,29%
Previsão 11	0,99%	18,02%	34,57%
Previsão 12	3,60%	11,45%	27,41%
Previsão 13	19,59%	29,93%	41,94%
Previsão 14	1,36%	15,13%	29,50%
Previsão 15	0,15%	14,83%	88,35%
Previsão 16	2,13%	8,30%	18,92%
Previsão 17	25,66%	9,35%	8,04%
Previsão 18	19,92%	28,28%	39,12%
Previsão 19	2,26%	12,47%	25,66%
Previsão 20	3,88%	11,75%	27,66%
Média	9,81%	15,07%	28,13%

Anexo IV – Previsão para 2007 a 2009 – decomposição clássica

PERÍODO	PREVISTO	REALIZADO	DIFERENÇA
jan/07	3.278,36	9.969,17	6.690,81
fev/07	10.712,86	0,00	-10.712,86
mar/07	20.003,12	590,29	-19.412,83
abr/07	13.259,03	9.586,27	-3.672,76
mai/07	4.230,44	15.827,40	11.596,96
jun/07	17.384,24	31.617,18	14.232,94
jul/07	8.139,41	7.884,18	-255,23
ago/07	17.750,16	85.480,80	67.730,65
set/07	13.937,33	12.264,04	-1.673,30
out/07	34.131,76	0,00	-34.131,76
nov/07	47.582,24	31.621,58	-15.960,65
dez/07	61.653,70	77.030,95	15.377,24
jan/08	7.210,32	10.268,40	3.058,09
fev/08	23.260,96	26.596,08	3.335,13
mar/08	22.061,90	62.442,81	40.380,91
abr/08	15.276,85	35.907,29	20.630,44
mai/08	6.462,09	4.007,33	-2.454,77
jun/08	27.477,14	0,00	-27.477,14
jul/08	8.834,73	3.917,81	-4.916,92
ago/08	18.961,84	3.195,06	-15.766,78
set/08	12.405,77	11.805,54	-600,23
out/08	21.610,53	34.161,94	12.551,41
nov/08	23.824,72	78.884,88	55.060,16
dez/08	31.989,11	34.763,88	2.774,77
jan/09	4.075,68	5.750,44	1.674,75
fev/09	13.455,43	0,00	-13.455,43
mar/09	17.045,56	22.263,78	5.218,22
abr/09	11.147,55	0,00	-11.147,55
mai/09	3.446,62	5.077,06	1.630,43
jun/09	6.441,44	0,00	-6.441,44
jul/09	11.125,62	6.289,14	-4.836,48
ago/09	24.579,21	7.488,17	-17.091,03
set/09	17.822,94	0,00	-17.822,94
out/09	36.742,33	0,00	-36.742,33
nov/09	48.318,66	0,00	-48.318,66
dez/09	65.188,64	338.417,31	273.228,67

ANO	PREVISTO	REALIZADO	DIFERENÇA
2007	252.062,65	281.871,84	29.809,19
2008	219.375,96	305.951,03	86.575,07
2009	259.389,69	385.285,90	125.896,21

Anexo V – Previsão para 2007 a 2009 – previsão 10 RNA

PERÍODO	REALIZADO	PREVISTO	DIFERENÇA
jan/07	9.969	9.402	567
fev/07	0	2.097	-2.097
mar/07	590	1.988	-1.398
abr/07	9.586	9.039	547
mai/07	15.827	15.395	432
jun/07	31.617	30.740	877
jul/07	7.884	6.604	1.280
ago/07	85.481	84.763	718
set/07	12.264	10.798	1.466
out/07	0	2.648	-2.648
nov/07	31.622	30.951	671
dez/07	77.031	77.720	-689
jan/08	10.268	9.267	1.002
fev/08	26.596	27.169	-573
mar/08	62.443	62.531	-88
abr/08	35.907	33.287	2.621
mai/08	4.007	4.103	-96
jun/08	0	2.893	-2.893
jul/08	3.918	3.190	728
ago/08	3.195	2.703	492
set/08	11.806	7.338	4.468
out/08	34.162	33.359	803
nov/08	78.885	78.827	58
dez/08	34.764	33.617	1.147
jan/09	5.750	3.738	2.013
fev/09	0	2.036	-2.036
mar/09	22.264	20.078	2.185
abr/09	0	2.052	-2.052
mai/09	5.077	3.347	1.730
jun/09	0	2.117	-2.117
jul/09	6.289	3.422	2.867
ago/09	7.488	5.130	2.358
set/09	0	2.424	-2.424
out/09	0	1.533	-1.533
nov/09	0	832	-832
dez/09	338.417	338.417	0

PERÍODO	REALIZADO	PREVISTO	DIFERENÇA
2007	281.872	282.144	-272
2008	305.951	298.284	7.667
2009	385.286	385.125	161