



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Ciências Aplicadas

RAISA CAROLINA DORNELAS

**PREVISÃO DE VENDAS E GESTÃO DA DEMANDA DE MÁQUINAS AGRÍCOLAS:
PROPOSTA DE UMA ABORDAGEM BASEADA EM REDES NEURAIAS
ARTIFICIAIS**

**SALES FORECASTING AND DEMAND MANAGEMENT FOR AGRICULTURAL
MACHINERY: AN ARTIFICIAL NEURAL NETWORK APPROACH PROPOSAL**

LIMEIRA
2017



RAISA CAROLINA DORNELAS

**PREVISÃO DE VENDAS E GESTÃO DA DEMANDA DE MÁQUINAS AGRÍCOLAS:
PROPOSTA DE UMA ABORDAGEM BASEADA EM REDES NEURAIAS
ARTIFICIAIS**

Dissertação apresentada à Faculdade de Ciências Aplicadas da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestra em Pesquisa Operacional, na área de concentração Pesquisa Operacional.

Orientador: Prof. Dr. Luis Antonio de Santa-Eulália

Co-orientador: Prof. Dr. Aníbal Azevedo

ESTE EXEMPLAR CORRESPONDE À VERSÃO
FINAL DISSERTAÇÃO DEFENDIDA PELA ALUNA
RAISA CAROLINA DORNELAS, E ORIENTADA
PELO PROF. DR. LUIS ANTÔNIO DE SANTA-
EULÁLIA.

**LIMEIRA
2017**

Agência(s) de fomento e nº(s) de processo(s): Não se aplica.

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Faculdade de Ciências Aplicadas
Renata Eleuterio da Silva - CRB 8/9281

D735p Dornelas, Raisa Carolina, 1990-
Previsão de vendas e gestão da demanda de máquinas agrícolas :
proposta de uma abordagem baseada em Redes Neurais Artificiais / Raisa
Carolina Dornelas. – Limeira, SP : [s.n.], 2017.

Orientador: Luis Antônio de Santa-Eulália.
Coorientador: Aníbal Tavares de Azevedo.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade
de Ciências Aplicadas.

1. Planejamento da produção. 2. Redes Neurais (Computação). 3.
Suavização (Análise numérica). I. Santa-Eulália, Luis Antônio, 1974-. II.
Azevedo, Aníbal Tavares de, 1977-. III. Universidade Estadual de Campinas.
Faculdade de Ciências Aplicadas. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Sales forecasting and demand management for agricultural
machinery : an Artificial Neural Network approach proposal

Palavras-chave em inglês:

Production planning

Neural networks (Computer science)

Smoothing (Numerical analysis)

Área de concentração: Pesquisa Operacional

Titulação: Mestra em Pesquisa Operacional

Banca examinadora:

Luis Antônio de Santa-Eulália [Orientador]

Claudio Rogerio Negri

Cleber Damiano Rocco

Data de defesa: 18-01-2017

Programa de Pós-Graduação: Pesquisa Operacional

UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Ciências Aplicadas

**PREVISÃO DE VENDAS E GESTÃO DA DEMANDA DE MÁQUINAS AGRÍCOLAS:
PROPOSTA DE UMA ABORDAGEM BASEADA EM REDES NEURAIAS
ARTIFICIAIS**

Autora: Raisa Carolina Dornelas

Orientador: Luis Antônio de Santa-Eulália

Co-orientador: Aníbal Azevedo

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

Prof. Dr. Luis Antônio de Santa-Eulália, Presidente

École de gestion, Université de Sherbrooke

Prof. Dr. Claudio Rogerio Negri da Silva

Universidade Federal de São Carlos / Embraer

Prof. Dr. Cleber Damiano Rocco

Faculdade de Ciências Aplicadas, Unicamp

A Ata de Defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do aluno.

Limeira, 14 de março de 2017

Resumo

O presente estudo propõe um modelo baseado em Redes Neurais Artificiais (RNA) para Previsão de Vendas adequado a um processo de Gestão da Demanda. Para tanto, realizamos a avaliação e aperfeiçoamento geral do processo de negócio da Gestão da Demanda (GD), tendo como foco principal os métodos de Previsão de Vendas (PV) e servindo-nos do processo e dos dados históricos de uma grande empresa de máquinas agrícolas. Após uma revisão sobre o processo de GD, uma avaliação dos métodos de PV atuais da empresa foi realizada. A partir da revisão bibliográfica sobre ambos os temas, um modelo matemático de RNA foi desenvolvido em sintonia com um processo de GD, ambos aplicados à empresa. O modelo de previsão é considerado aqui como parte de um processo de GD, sendo função de variáveis distintas de mercado, levando em considerações diversas características, incluindo horizonte de planejamento, padrões da demanda, acurácia e a aplicabilidade dos métodos. Os resultados dos modelos testados de RNA foram comparados aos métodos de Regressão Múltipla e Suavização Exponencial. O modelo de Suavização, o qual faz uso apenas da série histórica de vendas para realizar a previsão, foi o que apresentou performance menos satisfatória. Os métodos causais de Regressão Múltipla e Redes Neurais Artificiais, por sua vez, exibiram uma boa performance, semelhantes entre si. A Regressão Múltipla, cuja aplicação é mais usual na literatura, exibiu desvios menores que a RNA em algumas das medições de acurácia utilizadas. A pesquisa apresenta tanto contribuição de natureza teórica, uma vez que a literatura não abrange métodos previsão de vendas para produtos similares, como de natureza prática, pois colabora de forma concreta para o meio empresarial, em particular para uma empresa de grande porte. Contribui ainda com o uso empírico da técnica de Inteligência Artificial que, apesar de ser conhecida há mais de meio século, ainda é tida como um método de difícil implantação .

Palavras-chave: ANN; Regressão Múltipla; Suavização Exponencial; Planejamento de Produção.

Abstract

The presented study proposes a model based in Artificial Neural Networks (ANNs) for sales forecasting, suitable for the Demand Management process. We performed the valuation and improvement of the business process for demand management, focusing on sales forecasting methods and using the data series from a large company of agricultural machinery. After the review of the current process we we evaluated the current forecasting method. An algorithm model of ANNs has been developed in parallel to the process. The forecasting models were considered as part of the demand management and have distinct market variables in its main function. Some of the characteristics considered include planning horizon, demand patterns, accuracy and applicability of methods. The results of the ANNs models were compared with the exponential smoothing and multiple regression methods. The first, which uses only the sales history series to perform the forecast, was the one with worst results. The multiple regression and the artificial neural networks, which are known as causal methods, presented good performance, similar to each other. The multiple regression even showed less errors than the ANNs in some of the error measures we have used. This research presents contribution for the theory of forecasting methods, once there is not much of research for similar products. The contribution of this study is also practical, since it collaborates with a company's reality, in particular a large enterprise.

Key-words: multiple regression, production planning, ann.

Lista de Ilustrações

Figura 2.1 A Gestão da Demanda como parte da Gestão da Cadeia de Suprimentos

Figura 2.2 Série histórica com padrão horizontal

Figura 2.3 Série histórica com padrão sazonal

Figura 2.4 Série histórica com padrão cíclico

Figura 2.5 Série histórica com tendência de crescimento

Figura 2.6 Classificação de métodos de previsão segundo Fernandes e Godinho (2010), Makridakis e Wheelwright (1989) e Mentzer e Moon (2005)

Figura 2.7 Rede Neural Artificial do tipo MLP

Figura 5.1 Árvore da Realidade Atual

Figura 5.2 Processo de Gestão da Demanda - Caso da empresa de máquinas agrícolas Parte 1

Figura 5.3 Processo de Gestão da Demanda - Caso da empresa de máquinas agrícolas Parte 2

Figura 5.4 Histórico de vendas de máquinas agrícolas de 2009 a 2013

Figura 5.5 Comportamento sazonal anual da venda de máquinas agrícolas

Figura 5.6 Previsão de Vendas por Regressão Múltipla de 2009 a 2013

Figura 5.7 Potencial de ativação de uma Rede Neural Artificial

Figura 5.8 Cálculo da Margem do Produtor de Soja no MT

Figura 5.9 Valores previstos comparados com valores reais – Previsão por Redes Neurais com 7 neurônios na camada intermediária

Figura 5.10 Valores previstos comparados com valores reais – Previsão por Regressão Múltipla com as mesmas variáveis da Rede Neural

Figura 5.11 Fragmentação da série histórica sazonal para PV com melhor performance na etapa de validação

Figura 5.12 Fragmentação da série histórica sazonal para PV com pior performance na etapa de validação

Figura 5.13 Processo Proposto de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 1

Figura 5.14 Processo Proposto de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 2

Lista de Tabelas

Tabela 2.1 Processo de Previsão

Tabela 5.1 Desagregação dos padrões da série histórica de vendas

Tabela 5.2 Padrão de sazonalidade da série histórica por trimestre

Tabela 5.3 Índice de Sazonalidade médio

Tabela 5.4 Estatísticas da Previsão por Regressão Múltipla

Tabela 5.5 Acurácia da Previsão de Vendas por Suavização Exponencial

Tabela 5.6 Neurônios de entrada da RNA – Variáveis independentes correlacionadas às Vendas anuais

Tabela 5.7 Modelos de previsão de vendas testados para máquinas agrícolas

Tabela 5.8 Acurácia dos métodos de previsão selecionados

Tabela 5.9 Erro Absoluto das Previsões NN A10 e NN A13 por trimestre – Desagregação pelo Índice de Sazonalidade

Tabela 7.1 Comparação da acurácia – Rede Neural Artificial e Regressão Múltipla

Lista de Abreviaturas e Siglas

APICS: *American Production and Inventory Control Society*

ARA: Árvore da Realidade Atual

ARIMA: *Autoregressive Integrated Moving Average* - Médias Móveis Integradas Auto-Regressivas

BNDES: Banco Nacional de Desenvolvimento Econômico e

FMTS: *Fixed-model Time Series* - Modelos Fixos de Séries Temporais

GD: Gestão da Demanda

IC-Br: Índice *Commodities* Brasil

MAD: *Mean Absolute Deviation* - Erro Médio Absoluto

MAPE: *Mean Absolute Percentage Error* - Erro Médio Absoluto Percentual;

MLP: *Multi-layer Perceptron* - Perceptron de Múltiplas Camadas

MSE: *Mean Squared Error* - Erro Quadrático Médio

OGM: Organismos Geneticamente Modificados

OMTS: *Open-model Time Series* - Modelos Abertos de Séries Temporais

P&D: Pesquisa & Desenvolvimento

PIB: Produto Interno Bruto

PPCP: Planejamento, Programação e Controle de Produção

PV: Previsão de Vendas

RMSE: *Root Mean Square Error* - Raiz Quadrada do Erro Quadrático Médio.

RNA: Redes Neurais Artificiais

SCM: *Supply Chain Management* - Gestão da Cadeia de Suprimentos

Sumário

1. Introdução	12
a. Motivação e Problematização	12
b. Objetivos	15
c. Organização da dissertação	15
2. Fundamentação Teórica	17
a. Gestão da Demanda	17
b. Previsão de Vendas	20
c. Modelos de Previsão de Séries Temporais	30
d. Medidas de Acurácia na Previsão	36
3. Revisão da Literatura	38
a. A PV no setor de máquinas agrícolas	38
b. Previsão de Vendas com Redes Neurais Artificiais	39
c. Particularidades das RNAs em PV	42
4. Metodologia	45
5. Previsão de Vendas no mercado de máquinas agrícolas: propostas, resultados e discussões	49
a. O processo de negócio da Previsão de Vendas na empresa estudada	49
b. Análise da série histórica	54
c. PV baseado em Regressão Múltipla – Modelo <i>Status Quo</i>	59
d. Novos Modelos	61
d1. Suavização Exponencial	62
d2. Rede Neural Artificial	63
Seleção das variáveis	65
Estabelecimento dos parâmetros	69
d.3 Regressão Múltipla	72
e. O processo de Gestão da Demanda e Previsão de Vendas proposto	74
6. Conclusões	82
Referências	85
ANEXO 1: Questionário Fase 1	94
ANEXO 2: Questionário Fase 2	95

1. Introdução

a. Motivação e Problematização

Constantes mudanças de ordem econômica, impulsionadas pelo crescimento populacional e avanço tecnológico, vem conduzindo grandes empresas a desenvolverem ferramentas direcionadas à melhoria de flexibilidade em seus processos produtivos. Tal cenário cria desafios no que concerne a Gestão da Demanda, em que o objetivo é balancear e alinhar de forma estratégica as necessidades originadas no mercado com a capacidade operacional da cadeia de suprimentos (MELO e ALCÂNTARA, 2011). Esses esforços, no entanto, não devem visar exclusivamente os fornecedores, mas ter em vista a redução do desperdício de recursos e a minimização das perdas decorrentes de oscilações no âmbito econômico, político e do próprio mercado.

Esta realidade é especialmente presente no agronegócio, ou em setores correlacionados, como o de máquinas agrícolas. A agropecuária, por exemplo, utiliza 72% da água do país e quase metade desse montante (45%) é desperdiçado, conforme levantamento da FAO¹. A mesma instituição indica que cerca de um bilhão de toneladas de alimentos produzidos no mundo são desperdiçados por ano. Ademais, o Brasil é apontado como o maior mercado consumidor de agroquímicos do mundo, e segundo estudo do Instituto Emater, 46% das aplicações de defensivos agrícolas utilizadas no campo são desperdiçadas (CASALI *et al.*, 2014).

Parte do desafio de gerir a demanda está em prever e planejar o atendimento ao mercado. O principal elemento da gestão ao iniciar um processo de previsão de vendas é descobrir uma boa correspondência entre a situação em que o negócio encontra-se e o método a ser empregado na previsão, antes mesmo de adentrar na coleta de dados e aplicação do método. Quando se trata de um mercado altamente dependente de outros setores específicos, uma opção é buscar indicadores econômicos correlacionados ao desempenho das vendas. Este é o caso do modelo de previsão de vendas a ser descrito neste estudo, o qual para prever as vendas de máquinas agrícolas apoia-se em indicadores relacionados ao agronegócio, entre eles a Produtividade e Produção agrícolas, o preço do grão e a margem calculada ao produtor de soja. Inclui ainda área de colheita nacional e o IC-Br, índice calculado pelo Banco Central

¹ A FAO (*Food and Agriculture Organization of the United Nations* - Organização das Nações Unidas para Alimentação e Agricultura) é uma organização da ONU cujo objetivo é aumentar a capacidade mundial na produção de alimentos de forma eficaz e coordenada, promovendo suporte sustentável para segurança alimentar e nutrição global.

vinculado à participação das principais *commodities* no mercado financeiro, todas variáveis com altos índices de correlação com as vendas anuais da empresa.

A produção agrícola mundial, a partir da década de 1960, apoiada pela Revolução Verde, sustentou-se em novo modelo tecnológico, implicando na expansão do uso de insumos (químicos, biológicos e mecânicos) em suas atividades. A partir de 1980, no entanto, esse modelo passou a apresentar limitações decorrentes da diminuição da inovação, apesar do aumento dos gastos com P&D e identificação dos impactos ambientais causados pelo uso intensivo de agrotóxicos (ALBERGONI e PELAEZ, 2007). Essa crise de paradigma reduziu a produtividade marginal das empresas, anteriormente favorecidas pela revolução, cujas vendas vêm perdendo espaço para a biotecnologia e para o desenvolvimento dos organismos geneticamente modificados (OGM), mais resistentes a pragas.

A problemática da previsão de vendas é um excelente exemplo de tomada de decisão crítica no gerenciamento de ambientes complexos, incertos e irregularmente estruturados. De modo geral, o modelo de tomada de decisão em cenários como esse passa por três fases principais: identificação do problema, desenvolvimento de alternativas e seleção da melhor alternativa baseando-se no peso dos critérios de decisão (LUXHOJ *et al.*, 1996). Atualmente, as maiores dificuldades enfrentadas por fabricantes e vendedores ao realizar projeções são o aumento crescente da competição global, o desenvolvimento acelerado de produtos, o aumento da flexibilidade produtiva e a expansão da variedade de produtos.

O setor de maquinários agrícolas depende em grande parte do desempenho do agronegócio e da produtividade do setor. Quanto maior for a produção agrícola, maior será a necessidade de máquinas e equipamentos que auxiliem no processo produtivo. No caso do Brasil, o agronegócio tem forte participação na economia. A sua representatividade no PIB total em 2015 foi de 21% (CEPEA, 2015) e a produtividade do setor aumentou cerca de 40% nos últimos dez anos (CONAB, 2015). Apesar das dificuldades enfrentadas em 2014 e 2015, as exportações do agronegócio neste último ano atingiram volume recorde, com crescimento de 16% em comparação ao ano anterior, apesar da queda de 3% em 2014, em comparação à 2013 (CEPEA, 2015).

Realizar previsões nesse setor, no entanto, apresenta dificuldades. Devido a grande participação do mercado externo na produção nacional, oscilações na economia mundial influenciam nos resultados à curto e médio prazo em seu desempenho, uma vez que os

principais importadores são União Européia, China e Estados Unidos (MAPA, 2010). Tendo em vista a carência de métodos consistentes na literatura que auxiliem na realização de previsões para maquinários agrícolas, tal como discutido em detalhes no Capítulo 3, o presente estudo propõe um processo de Gestão da Demanda integrado a um modelo de Previsão de Vendas (PV) para maquinários agrícolas, com o auxílio de dados reais de uma empresa especializada em produtos deste tipo.

A fim de compreender como empregar modelos preditivos em cenários oscilantes, a pesquisa foi realizada por meio da vivência no ambiente cotidiano da organização, havendo participação da pesquisadora na atividade em análise e impulsionando os participantes do processo de gestão da demanda a tornarem-se também investigadores do objeto em estudo. A pesquisa apresentada a seguir mostra-se, portanto, com contribuição prática no campo de estudo de métodos preditivos, os quais apesar de amplamente estudados muitas vezes não são aplicados assertivamente no ambiente corporativo, seja por falta de conhecimento ou pelas dificuldades de aplicação e compreensão dos modelos matemáticos.

Para tanto, as técnicas tradicionais de previsão foram estudadas, para que uma série de modelos matemáticos preliminares de Redes Neurais Artificiais fosse desenvolvida. Posteriormente, a avaliação e o aperfeiçoamento geral do processo de negócio da Gestão da Demanda (GD), tendo como foco principal os métodos de Previsão de Vendas (PV) foram realizados, utilizando o processo e os dados históricos da empresa em estudo. A partir da fundamentação teórica e revisão bibliográfica dos temas, desenvolveu-se um modelo matemático em sintonia com o processo de Gestão da Demanda da organização. O modelo de previsão é considerado aqui como parte de um processo de GD, sendo função de variáveis distintas de mercado, levando em consideração os padrões de demanda, acurácia e a aplicabilidade do método. Para fins comparativos, a análise utilizou-se também de três outros modelos lineares de previsão, sendo dois deles de Regressão Múltipla e Suavização Exponencial. Foram avaliadas as vantagens e desvantagens de cada modelo de previsão testado para a série histórica, para que o tomador de decisão pudesse escolher o método que mais se adequasse ao cenário.

Com isto em mente, a seção seguinte formaliza os objetivos do presente trabalho.

b. Objetivos

O objetivo deste trabalho é propor e comparar métodos de Previsão de Vendas aderentes ao processo de Gestão da Demanda para o setor de máquinas agrícolas. Atenção maior será dada aos métodos de Redes Neurais Artificiais, pois a literatura aponta este como sendo de grande potencial na área, tal como será discutido mais adiante.

c. Organização da dissertação

O estudo a seguir foi iniciado pela fundamentação teórica dos principais assuntos tratados pelo tema apresentado, realizada na Seção 2. O processo de Gestão da Demanda, conforme tratado na literatura nacional e internacional, é apresentado incluindo o processo de Previsão de Vendas como parte do planejamento estratégico da firma. Uma caracterização dos modelos de Previsão de Vendas aplicados no estudo é realizada nesta etapa. Tendo sido escolhido o método de Redes Neurais Artificiais como principal técnica de previsão de vendas, pois a literatura destaca-o como sendo de grande valor, tal como será discutido mais a frente, o assunto é tratado também na fundamentação teórica.

A revisão da literatura de redes neurais artificiais é elaborada na Seção 3, apresentando-se primeiramente as principais aplicações da técnica no setor de maquinários agrícolas e aeroespacial. Em seguida, um apanhado geral das publicações recentes é disposto, apontando os pontos principais de atenção dos pesquisadores da área, assim como a performance dos modelos de Redes Neurais Artificiais (RNA) nos estudos em âmbito nacional e internacional.

Na Seção 4 a metodologia do estudo é descrita. Tendo em vista a importância da pesquisadora em envolver-se com o campo investigado e dispor-se a pensar com os participantes do processo em estudo, este trabalho assume a forma de uma Pesquisa-Ação. Reconhece-se, assim, a capacidade da ação em grupo de reinventar ações, pensamentos e saberes-fazer, a fim de superar situações que pareçam intransponíveis (JESUS *et al.*, 2014).

Em seguida, apresenta-se na Seção 5 a investigação dos processos da empresa de máquinas agrícolas, descrevendo o modelo de negócios de Gestão da Demanda e Previsão de Vendas praticado pela organização. O mapeamento dos processos foi elaborado nessa etapa para que posteriormente o modelo *status quo* de Regressão Múltipla, atualmente empregado pela empresa fosse explicado. Em seguida, apresenta-se os modelos alternativos, Suavização, RNA e novamente a Regressão Múltipla, agora utilizando-se das variáveis do modelo de

RNA. A seleção de variáveis da RNA por meio da análise de correlação e o estabelecimento dos parâmetros de teste são expostos seguidamente. Os Resultados são apresentados ao final do capítulo por meio da análise comparativa entre RNAs e métodos lineares de previsão (Regressões Múltiplas e Suavização Exponencial). As próximas etapas do estudo são pontuadas na Seção 6, assim como as limitações da pesquisa. Por fim, delinea-se as Conclusões iniciais, seguido das Referências.

2. Fundamentação Teórica

a. Gestão da Demanda

A Gestão da Demanda é definida pela APICS² como a função de reconhecimento de toda a demanda por produtos e serviços para dar suporte ao mercado. Esse processo facilita o planejamento e utilização dos recursos a fim de atingir resultados lucrativos para o negócio. Em marketing, é o processo de planejamento, execução, controle e monitoramento do *design*, precificação, promoção e distribuição dos produtos e serviços resultando em transações e atingindo as necessidades organizacionais (APICS, 2016).

O processo de Gestão da Demanda consiste na criação, ao longo da cadeia de suprimentos e de seus respectivos mercados, de um fluxo de demanda coordenado. Tradicionalmente o marketing cria demandas para vários produtos, no entanto não costuma compartilhar essa demanda com outras funções da empresa - e com outras empresas da cadeia - para a criação de previsões e planos para supri-la (MENTZER e MOON, 2005).

A necessidade de estudos aprofundados sobre a Gestão da Demanda foi observada por uma pluralidade de autores, como exposto na revisão de Melo e Alcântara (2011). A falta de alinhamento entre oferta e demanda gera conseqüências observadas facilmente nas grandes organizações, como a falta ou excesso de estoque, ou nas perdas devido ao desperdício. Segundo as autoras o objetivo da gestão da demanda é buscar a integração ágil e adequada das necessidades que são originadas no mercado, a fim de alinhar estrategicamente a demanda com a capacidade operacional ao longo da cadeia de suprimentos.

Para Mentzer e Moon (2005) algumas vezes a Gestão da Demanda deve ocupar-se em reduzir a procura por seus produtos. Segundo os autores, as demandas geralmente existem na companhia em certo nível que a gerência não consegue atender completamente de modo lucrativo. A administração dessas necessidades de mercado implica na avaliação da lucratividade de seus produtos e clientes, selecionando aqueles mais alinhados com os objetivos da empresa. Outro aspecto levantado pelos autores é a gestão do relacionamento entre as empresas da cadeia de suprimentos, a fim de atingir a otimalidade na performance dos parceiros da cadeia, gerando vantagens a todos os envolvidos no processo.

² A APICS (*American Production and Inventory Control Society*) é uma associação com o objetivo de unir os profissionais práticos e acadêmicos das áreas de *Supply Chain Management* e Gestão de Operações. Busca desenvolver excelência por meio da padronização de termos, oferecendo treinamentos com certificação de reconhecimento internacional e promovendo eventos relacionados ao tema. Mais informações em www.apics.org

O primeiro passo dessa abordagem conceitual é compreender o mercado por meio de análises de capacidade, restrições e oportunidades internas e externas à empresa. Essas análises devem ser realizadas por um time multifuncional (com a colaboração das áreas de marketing e de SCM - *Supply Chain Management*), responsável pelo desenvolvimento conjunto das previsões de vendas, e da elaboração, execução e acompanhamento do plano de negócios (MELO e ALCÂNTARA, 2011).

A gestão da demanda engloba as funções tradicionalmente atreladas ao marketing, assim como a coordenação dessas atividades com outras funções da empresa e da cadeia de suprimentos. No entanto, a criação de demanda independente (gerada pelo consumidor final) influencia diretamente o fluxo de demanda da cadeia de suprimentos. O processo de gestão de demanda é responsável pela coordenação ao longo da cadeia das demandas derivadas e dependentes. A previsão da demanda, como parte desse processo, é a responsável pela projeção da demanda independente nessa cadeia (MENTZER e MOON, 2005).

Na gestão da cadeia de suprimentos o foco encontra-se na eficiência dos processos relacionados ao atendimento da demanda, orientando-se para custos. A gestão de marketing, por sua vez, preocupa-se com a criação de demanda e conseqüente geração de receita. Ou seja, desta forma os processos de criação e atendimento de demanda não são integrados e a gestão da cadeia de suprimentos agrega a função de desenvolvedor de capacidades para atendimento a estratégia de marketing (MELO e ALCÂNTARA, 2011).

Apesar de ser de conhecimento de analistas e executivos que a integração é favorável para o negócio, poucas empresas potencializam essa vantagem. Cerca de metade das organizações pesquisadas por Fawcett e Magnan (2002) trabalham com a integração dentro da empresa, e um terço amplia esse esforço com os fornecedores de primeiro nível da cadeia. Há pouco esforço para a ampliação em outros níveis.

A criação de um time multifuncional, composto por integrantes de diversos níveis e setores da organização, é um dos melhores meios para se criar uma visão ampla do processo de gestão da demanda. Por ter caráter estratégico, este time deve contar com a gerência das distintas funções, incluindo marketing, finanças, produção, compras e logística. Eventualmente, outras áreas, representantes de fornecedores e clientes estratégicos devem participar do time, uma vez que deve-se compreender bem a estratégia da organização, os consumidores e suas necessidades, as capacidades da manufatura e da rede de suprimentos. É

de responsabilidade deste time a definição dos procedimentos para elaboração da previsão, como determinar o nível de detalhamento, abrangência da previsão e identificação das fontes de informação (CROXTON *et al.*, 2008).

Mentzer e Moon (2005) indicam a gestão da demanda como componente da gestão da cadeia de suprimentos. O processo engloba as funções tradicionais do marketing e abrange o planejamento da demanda e, conseqüentemente, o fluxo coordenado da demanda derivada e dependente pelas empresas na cadeia de suprimentos. O planejamento da demanda incorpora a gestão de previsão de demanda, direcionada à demanda independente que ocorre na cadeia de suprimentos.

Orientar-se para a cadeia de suprimentos significa desenvolver esforços colaborativos intra e interempresas, ou seja, compartilhamento de informações; planejamento e execução de ações conjuntas; compartilhamento de riscos, custos e ganhos; desenvolvimento de relacionamento interno e externo à organização; investimentos financeiros e não financeiros; definição e acompanhamento de indicadores de desempenho (MELO e ALCÂNTARA, 2011).

Uma das conseqüências da colaboração na cadeia de suprimentos é o desenvolvimento de um plano de negócios conjunto à medida que a interação entre os elos é fundamentada. No contexto da gestão da demanda, o "plano" é o conjunto de ações gerenciais a fim de alcançar ou exceder as previsões de vendas. Frente às condições econômicas, da concorrência, dos planos de Marketing, Vendas, Produção e Logística, é efetuada a projeção de demanda futura. A partir dela é então formalizado o plano de negócios, de forma iterativa (ou seja, se o plano não estiver alinhado com as necessidades da empresa, deve-se retornar à previsão de vendas e examinar os esforços que podem ser realizados para alcançar o plano). Desta forma, garante-se um plano baseado na realidade financeira e de mercado da empresa, nas capacidades e necessidades logísticas e de produção. O processo de gestão da demanda deve ser formalizado detalhando as métricas de desempenho que envolvem direcionamentos específicos em custos, produtividade e metas de ganho (MIN *et al.*, 2005).

Para realizar a gestão da demanda de modo eficiente uma série de elementos requerem atenção. O principal deles é o desenvolvimento da habilidade de prever as vendas. Para tanto, é preciso manter a série histórica e informações que expliquem o comportamento das vendas no passado, utilizando esses dados em modelos matemáticos adequados que ajudem a explicar

a demanda. O processo de GD requer ainda que haja um canal de comunicação com o mercado, trazendo continuamente para dentro da empresa as informações dos clientes e do mercado por meio dos vendedores e representantes. Além disso, é fundamental que a empresa busque aumentar seu poder de influência sobre a demanda, cumpra os prazos que promete e tenha bons sistemas para priorização e alocação de seus recursos (CORRÊA *et al*, 2007).

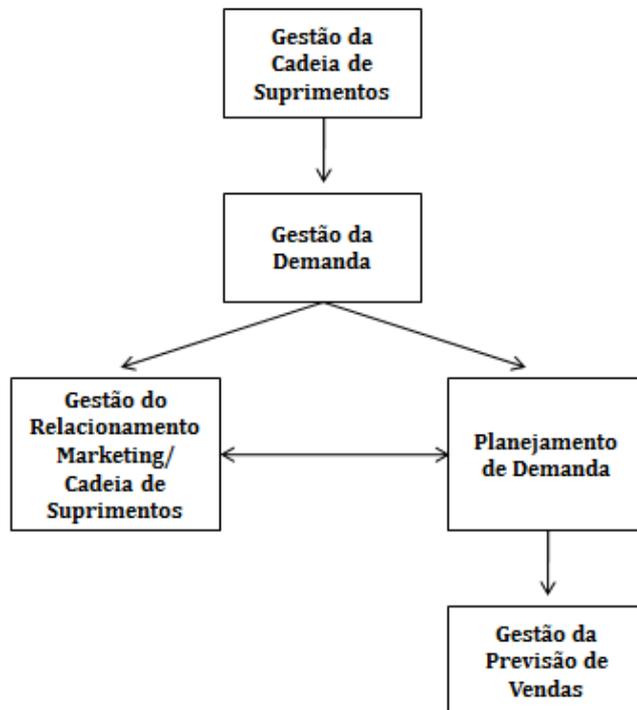


Figura 2.1 A Gestão da Demanda como parte da Gestão da Cadeia de Suprimentos

Fonte: Mentzer e Moon (2005)

b. Previsão de Vendas

Segundo Mentzer *et al.* (2007), a previsão de vendas é a projeção futura de uma demanda presumida, tendo em vista as condições ambientais atreladas ao cenário em que a organização se encontra. O plano de vendas, por sua vez, é o conjunto de ações gerenciais necessárias para que as vendas alcancem ou excedam a previsão, sendo assim nela fundamentado. O propósito de uma previsão de vendas é ser preciso, enquanto o do plano é atingir a previsão de modo eficiente e eficaz.

A previsão está intimamente relacionada à capacidade conjunta dos métodos e do conhecimento dos especialistas que se dedicam a estruturação da previsão. Pode-se dizer que

a previsão de longo prazo dedica-se à geração de resultados no sentido de planejar novas instalações, estudar o mercado para novos produtos, ou ações que gerem altos gastos de capital. Quando se trata do médio prazo, as previsões são a base para o planejamento agregado da produção, servindo como base para análises do tipo carga-capacidade. No curto prazo, por sua vez, a previsão oferece suporte para a programação da força de trabalho e da aquisição de matéria-prima, além de auxiliar nas análises de capacidade de curto prazo (FERNANDES e GODINHO, 2010).

O sistema de previsão de vendas empregado em uma entidade deve considerar informações como: o históricos de vendas, dados explicativos do comportamento das vendas passadas, histórico de variáveis explicativas correlacionadas às vendas e valores futuros projetados para tais variáveis. Além disso, são fatores de atenção a conjuntura econômica atual e futura, informações relacionadas a clientes indicando seu comportamento futuro, informações relevantes de concorrentes que influenciem as vendas, assim como informações da área comercial que possam afetar a demanda pelo produto (CORRÊA *et al.*, 2007).

Apesar da função de previsão estar atrelada na maioria das vezes às vendas, o que de fato deseja-se prever é a demanda, isto é, o que e quanto os compradores pretendem consumir. A partir disso, o fabricante tem a possibilidade de planejar-se para atender as necessidades de seus clientes. É neste momento que a previsão diferencia-se do planejamento operacional, o qual consiste em um conjunto específico de ações gerenciais para atingir ou superar a projeção de vendas (MENTZER e MOON, 2005).

Para selecionar um método apropriado na previsão de vendas é importante observar o padrão dos dados históricos disponíveis e encontrar a técnica mais adequada para tais padrões. São cinco tipos de padrão que podem ser observados nas séries (MAKRIDAKIS e WHEELWRIGHT, 1989; FERNANDES e GODINHO, 2010; CORRÊA *et al.*, 2007):

1. **Padrão horizontal:** os valores dos dados flutuam ao redor de um valor médio, isto é, as vendas do produto não aumentam nem diminuem significativamente no tempo. Isso significa que a série não tende a crescer ou decrescer no tempo de maneira sistemática, sendo tão provável que o próximo valor esteja acima da média quanto abaixo dela. Produtos com vendas estáveis ou o número de peças defeituosas produzidas em uma linha produtiva estável são exemplos em que esse tipo de tendência pode ocorrer.

Abaixo segue um exemplo de uma série histórica com padrão horizontal, cuja média dos resultados oscila próximo a um valor médio:

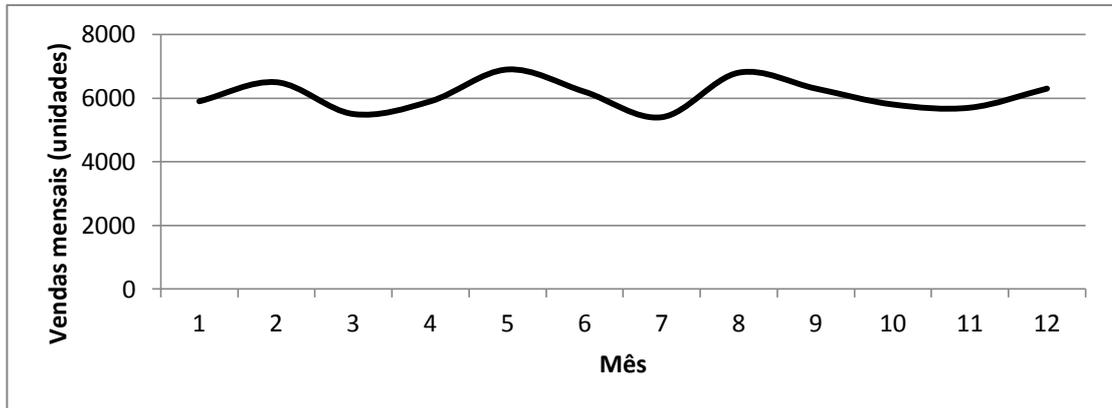


Figura 2.2 Série histórica com padrão horizontal

2. **Sazonalidade:** é observado quando uma série temporal flutua conforme um fator sazonal, seja ele mensal, trimestral, ou mesmo durante as horas de um mesmo dia ou dias específicos da semana. Esse padrão de repetição ao longo do tempo pode ocorrer por diversas razões, desde a estratégia da empresa, até o clima ou o mesmo a cultura do mercado em questão. No caso da série histórica de máquinas agrícolas apresentada abaixo nota-se maior sazonalidade nos dois últimos trimestres do ano:

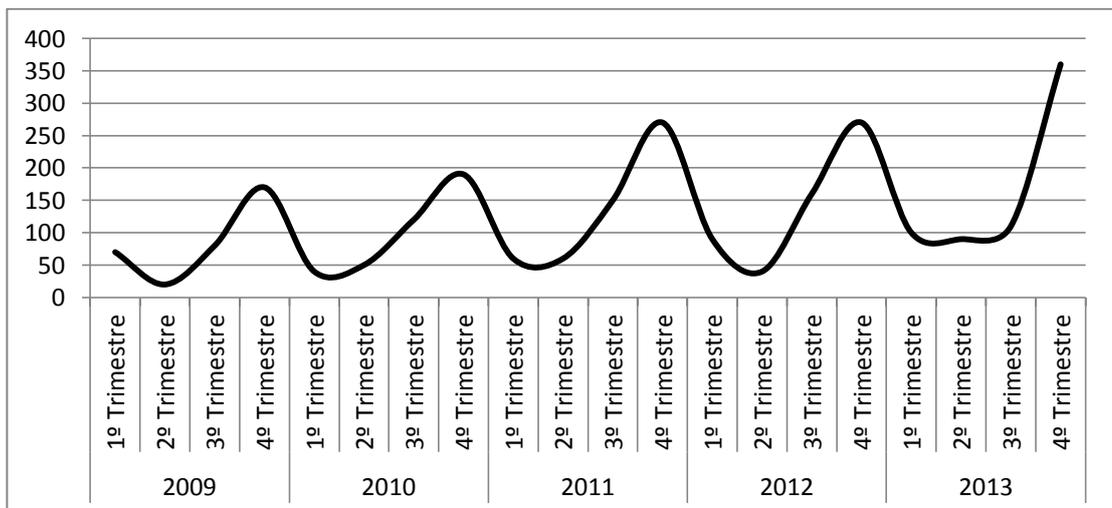


Figura 2.3 Série histórica com padrão sazonal

3. **Cíclico:** dados são influenciados por variações econômicas de longo prazo como aquelas associadas ao ciclo de negócios. O padrão cíclico segue o mesmo raciocínio do sazonal, porém ocorre entre períodos mais longos, maiores que um ano. Este é um

padrão difícil de prever, pois não se repete em intervalos conhecidos e constantes e sua duração não é uniforme. É possível notar este tipo de padrão em ciclos econômicos, como exemplificado no gráfico abaixo.

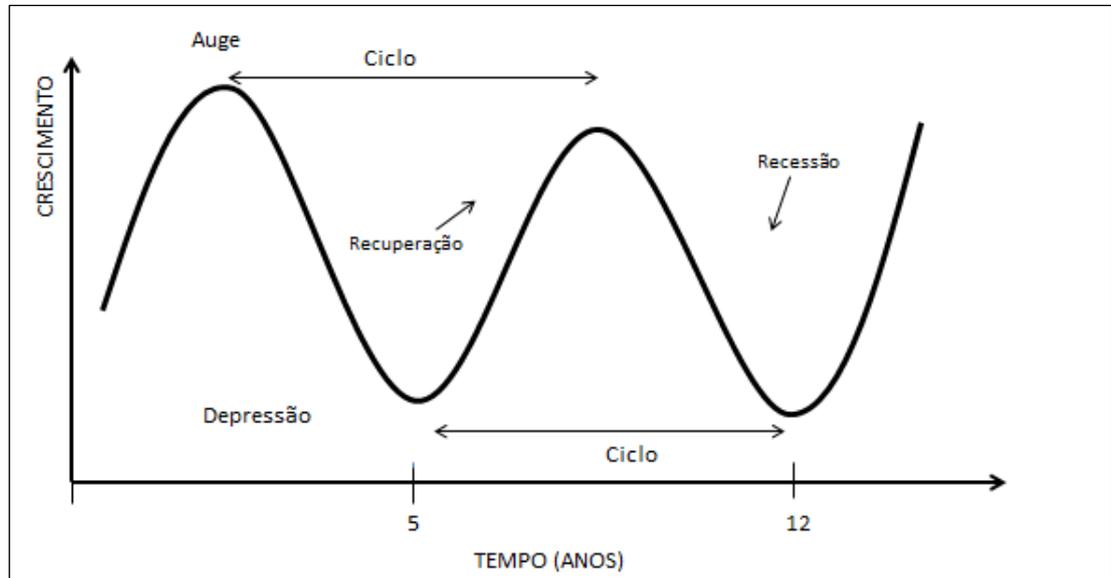


Figura 2.4 Série histórica com padrão cíclico

4. **Tendência:** há aumento ou diminuição dos valores dos dados por um largo período de tempo. O padrão de tendência ocorre quando a série não é estacionária, ou seja, não é horizontal. No caso abaixo nota-se uma série com tendência de crescimento, uma vez que a quantidade de vendas apresenta aumento anualmente.

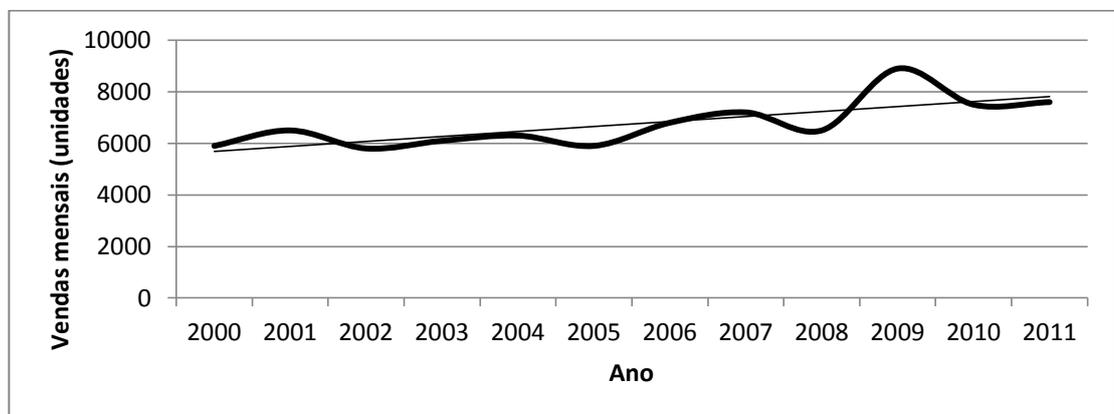


Figura 2.5 Série histórica com tendência de crescimento

5. **Varição aleatória:** corresponde à porção de incerteza da demanda. A maioria das séries temporais são resultantes de uma combinação de padrões.

Há uma variedade de técnicas que podem ser empregadas na previsão de vendas, exigindo que o tomador de decisão tome conhecimento dos distintos métodos e das particularidades que caracterizam tais técnicas a fim de selecionar a mais adequada para o cenário que pretende projetar (MENTZER e MOON, 2005). Os modelos de previsão podem ser de abordagem **quantitativa**, utilizando modelos matemáticos para análise dos dados, ou **qualitativos**, em que a percepção de mercado dos especialistas é o que direciona os estabelecimento da previsão de vendas. Essa segunda abordagem tem característica subjetiva e baseia-se no julgamento e experiência dos departamentos de marketing, operações e finanças, principalmente. São alguns exemplos: método Delphi, pesquisa de mercado e consenso do comitê executivo (FERNANDES e GODINHO, 2010). As classificações dadas por Fernandes e Godinho (2010), Makridakis e Wheelwright (1989) e Mentzer e Moon (2005) foram compiladas na Figura 2.6.

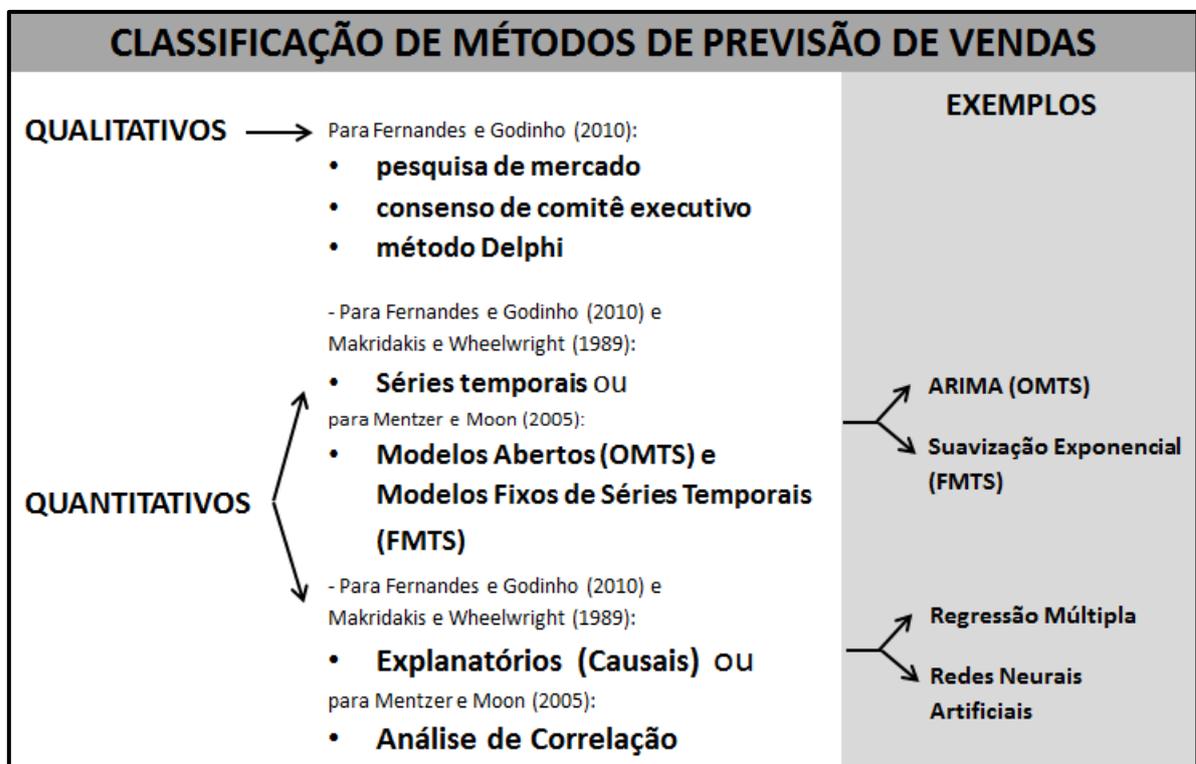


Figura 2.6 Classificação de métodos de previsão segundo Fernandes e Godinho (2010), Makridakis e Wheelwright (1989) e Mentzer e Moon (2005)

Dentre os modelos qualitativos, o método Delphi é amplamente utilizado desde a década de 1950 por auxiliar na tomada de decisão quando as previsões são realizadas com base em julgamentos de especialistas (ROWE e WRIGHT, XXXX). Essa técnica baseia-se na suposição de que uma previsão realizada por um grupo é mais precisas do que se realizada por

um único indivíduo. O objetivo é encontrar o consenso entre o grupo de especialistas por meio de encontros estruturados, normalmente liderados por um facilitador que implementa e administra o processo. Geralmente o método Delphi segue as seguintes etapas (HYNDMAN e ATHANASOPOULOS, 2014):

1. Estabelecimento de um painel de especialistas;
2. Os membros do painel são designados a realizar previsões e determinar os desafios e oportunidades;
3. Os especialistas retornam então com suas previsões e justificativas, que são compiladas e discutidas;
4. São realizadas seções de comentários entre os especialistas quantas vezes necessário até que se atinja um consenso;
5. Previsão final é definida com base nas discussões e comentários.

O modo como a técnica é realizada procura permitir que os aspectos positivos da interação do grupo de especialistas, tais como o conhecimento de uma variedade de fontes, sejam valorizadas, enquanto aspectos negativos como conflitos políticos, sociais e pessoais sejam minimizados. Esse método não deve ser utilizado com a pretensão de desafiar métodos estatísticos de previsão, mas em casos em que essas técnicas não são apropriadas por motivos históricos, econômicos, por falta de dados ou quando o julgamento humano torna-se necessário (ROWE e WRIGHT, 1999).

Tradicional autores no campo de estudo das previsões, como Makridakis e Wheelwright (1989), Fernandes e Godinho (2010), diferenciam os modelos quantitativos em dois tipos. Os **modelos de séries temporais** consideram como fator principal a própria série histórica dos dados a serem previstos e o período de tempo a ser utilizado. Um modelo de séries temporais assume que há um padrão ou um conjunto de padrões no decorrer do tempo e busca identificá-los, a fim de projetá-los para o futuro (FERNANDES e GODINHO, 2010; MAKRIDAKIS e WHEELWRIGHT, 1989).

Segundo Makridakis e Wheelwright (1989), modelos de séries temporais encaram o sistema como uma "caixa preta" e não visam identificar os fatores que afetam seu comportamento. Isso ocorre pois o sistema pode não ser bem compreendido, ou se for, provavelmente será extremamente difícil de mensurar as relações as quais entende-se que o governam. Além disso, seu propósito será provavelmente prever o que irá acontecer, não

necessariamente entender o porquê acontece. Por fim, compreender os motivos dos acontecimentos demanda mais custo e esforço do que efetivamente prever o que virá a ocorrer.

O segundo tipo de modelo quantitativo é o **explanatório** ou **causal**, no qual qualquer modificação nas entradas do modelo acarretará na variação das saídas de modo previsível, assumindo-se que a relação é constante. Basicamente, esse tipo de modelo entende que o valor de uma certa variável y (dita variável dependente) é função de uma ou mais outras variáveis x (ditas independentes). O objetivo é obter uma equação em que os dados sejam representados, minimizando a soma dos quadrados dos desvios entre os pontos de dados reais e os da curva ou reta equacionada (método dos mínimos quadrados) (FERNANDES e GODINHO, 2010; MAKRIDAKIS e WHEELWRIGHT, 1989).

O diferencial de um modelo explanatório como método de previsão é a possibilidade de desenvolver previsões correspondentes a um conjunto de valores para as distintas variáveis de entrada. Uma dificuldade, no entanto, é a exigência desse modelo por uma série de informações das variáveis de entrada, além daquela que está sendo prevista. Assim, este tipo de modelo requer certa quantidade de dados significativamente maior que modelos simples de séries temporais. Ademais, estes modelos demandam mais tempo para elaboração e são sensíveis a mudanças nas relações entre as variáveis, as quais podem mudar de tempos em tempos (MAKRIDAKIS e WHEELWRIGHT; 1989).

Para Mentzer e Moon (2005) a classificação segue uma regra similar. As categorias baseiam-se no uso de análises estatísticas a partir de dados endógenos (histórico de vendas apenas) ou exógenos (dados externos que expliquem o comportamento das vendas), dividindo-se assim os métodos em três tipos principais:

- **Modelos Abertos de Séries Temporais (OMTS – *Open-Model Time Series*):** a construção do modelo de previsão baseia-se somente na análise da série histórica de vendas, sem interferência de informações externas, sendo portanto considerado um método endógeno. Essa técnica fundamenta-se nas inter-relações dos quatro padrões conhecidos nos dados: nivelamento (histórico de vendas horizontal), tendência (crescimento ou decrescimento das vendas), sazonalidade (repetição de tempos em tempos de um aumento nas vendas) ou ciclo (períodos de oscilação econômica mais extensos que um ano), e a aleatoriedade (flutuações de mercado que não podem ser

previstas). A partir do reconhecimento desses padrões, o modelo é capaz de construir uma equação apropriada para previsão. Um exemplo desta técnica é Box-Jenkins (ARIMA – *autoregressive integrated moving average*), método que aplica a média móvel autoregressiva para encontrar modelo de série temporal mais adequado, como pelo uso do método dos mínimos quadrados.

- **Modelos Fixos de Séries Temporais (FMTS – *Fixed-Model Time Series*):** em previsões de curto prazo podem ocorrer mudanças bruscas e havendo uma grande variedade de produtos faz-se necessário a utilização de técnicas simples e flexíveis. Baseiam-se também nos quatro padrões conhecidos da série, no entanto assumem que um ou mais desses padrões estão fixados na série e os projeta para o futuro. A Suavização Exponencial é um exemplo deste tipo de modelo.
- **Análises de Correlação e Regressão:** modelo estabelece a relação entre as vendas e as variáveis externas que a influenciam, por meio da análise de correlação entre os dados do passado. Havendo encontrado forte relação entre as variáveis independentes e a variável dependente (no caso, as vendas), os fatores podem ser utilizados para prever dados futuros. A análise de correlação é um dos meios mais precisos de previsão, no entanto requer uma grande quantidade de dados. Exemplos desse tipo são as Regressões Simples e Múltipla, assim como os modelos de Redes Neurais Artificiais.

No livro "Planejamento e Controle da Produção" de Fernandes e Godinho (2010) os autores descrevem os fundamentos da Previsão de Vendas. Segundo eles, o avanço tecnológico e desenvolvimento dos pacotes computacionais facilitou em grande medida a estruturação de modelos matemáticos de previsão, tornando esse processo mais fácil e mais barato. No entanto, o simples uso de métodos e pacotes não é suficiente para atingir resultados satisfatórios. É de suma importância compreender claramente os princípios, utilizar a experiência e conhecimento detalhado de mercado como fundamento básico, principalmente no que diz respeito ao comportamento do cliente e entendimentos do planejador. Os fundamentos por eles citados são apontados também por Corrêa *et al.* (2007), e são resumidos a seguir:

- Geralmente os métodos de previsão pressupõem que o futuro será a repetição do comportamento causal do passado. Conseqüentemente, o gerente de produção deve

estar atento às mudanças de mercado que podem vir a influenciar suposições do modelo, alterando-o caso estas suposições deixem de ser aplicáveis;

- Os potenciais erros das previsões não devem desencorajar sua utilização e evolução. Há duas naturezas de erros que podem afetar a previsão: o ruído, relacionado à aleatoriedade de mercado, a qual todas as empresas estão sujeitas, e os erros pertinentes ao método de previsão ou mesmo aos parâmetros do método.
- Previsões agregadas são mais precisas que aquelas que visam um produto individualmente, quando aplicável. Dessa forma ocorre o equilíbrio dos erros para mais e para menos.
- A precisão da previsão tende a ser reduzida conforme alonga-se o horizonte de planejamento. Ou seja, previsões de longo prazo são mais incertas do que aquelas de curto prazo, uma vez que as mudanças políticas, econômicas e de mercado são mais perceptíveis quando a proximidade temporal é menor. Dessa forma, aquelas organizações mais flexíveis, as quais possuem a capacidade de responder rapidamente às oscilações do ambiente de negócios, contam com a vantagem de previsões mais exatas.
- As melhores previsões são aquelas que reagem as variações verdadeiras e ignoram os ruídos, ou variações aleatórias. O sistema adotado pela organização deve ser capaz de perceber quais alterações são factíveis, diferenciando-as das instabilidades imprevisíveis.
- A previsão deve estar estreitamente conectada com as decisões as quais pretende colaborar, em relação ao horizonte de tempo ponderado. Isso significa que o horizonte de planejamento desta previsão deve ser no mínimo equivalente ao tempo para implantação das modificações que ela propõe.
- É essencial que o processo de previsão implementado gere confiabilidade, ocasionando aos usuários segurança no sistema e nos resultados por ele gerados.
- A previsão deve ser expressa em unidades significativas, conforme as necessidades dos usuários.
- O método de previsão implementado deve ser, na medida do possível, de fácil utilização e compreensão pelos usuários. Em casos em que métodos mais sofisticados são usados, a sua lógica e as razões para sua utilização devem ser bem esclarecidas.

As etapas do processo de Previsão

Passo 1: Identificar o objetivo da previsão.	<ul style="list-style-type: none"> ❖ Qual decisão será afetada pelo processo de previsão? ❖ O que será previsto? ❖ Qual é a quantidade de itens que farão parte da previsão? ❖ Qual é o valor agregado dos itens? ❖ Qual é o nível de agregação? ❖ Qual é o horizonte de planejamento da decisão (longo, médio e curto prazo)? ❖ Qual é o grau de detalhe exigido pela previsão? ❖ Qual é o volume dos recursos a serem utilizados (mão de obra, tempo computacional, dinheiro etc.)? ❖ Qual é o nível de exatidão necessário?
Passo 2: Selecionar uma abordagem de previsão.	<p>Observar:</p> <ul style="list-style-type: none"> ❖ A existência ou não de dados; ❖ A possibilidade de coleta desses dados; ❖ A natureza dos dados; ❖ A existência ou não de fatores causais.
Passo 3: Selecionar os métodos de previsão e estimar os parâmetros.	<ul style="list-style-type: none"> ❖ Os parâmetros do método foram estimados? Exemplos: constante de suavização, taxa de tendência, índice sazonal. ❖ A previsão foi simulada para diferentes valores dos parâmetros? ❖ A previsão foi simulada para períodos passados e comparada com os dados reais desses períodos?
Passo 4: Elaborar a previsão.	<ul style="list-style-type: none"> ❖ Estimar os valores para n períodos à frente.
Passo 5: Monitorar, interpretar e atualizar a previsão.	<ul style="list-style-type: none"> ❖ A previsão está sob controle? ❖ Os erros são baixos? ❖ Há algum viés? ❖ Houve análise gerencial do resultado?

Tabela 2.1 Processo de Previsão

Fonte: Adaptado de Fernandes e Godinho (2010)

c. Modelos de Previsão de Séries Temporais

Suavização Exponencial de Holt-Winters

O método mais simples de suavização é chamado de suavização exponencial simples, técnica apropriada para previsões sem tendência ou padrão sazonal. Holt expandiu esse método a fim de permitir a previsão agregada da tendência. Seguidamente, Holt e Winters expandiram para um método cuja sazonalidade também era agregada à equação geral da suavização, denominado Suavização Exponencial de Holt-Winters (MAKRIDAKIS e WHEELWRIGHT, 1989).

O objetivo dos métodos de suavização é distinguir entre flutuações aleatórias e os padrões básicos presentes nos dados por meio da amortização dos valores históricos. São duas classes principais de suavização, aqueles baseados na média (como a Média Móvel), com peso igualitário para todos os valores, e aqueles chamados de suavização exponencial, em que pesos desiguais são aplicados aos dados, aplicando pesos maiores para dados mais recentes (MAKRIDAKIS e WHEELWRIGHT, 1989; CORRÊA *et al.*, 2007).

O método de Suavização Exponencial diferencia-se da Média Móvel pois utiliza todos os valores históricos, com coeficientes de ponderação que decrescem exponencialmente. A Suavização de Holt-Winters realiza a previsão considerando na amortização parâmetros de sazonalidade e tendência. O modelo básico pode ser explicado pela equação a seguir (CORRÊA *et al.*, 2007):

Em que:

P_t = Previsão de vendas para o período t

P_{t+n} = Previsão de vendas para o período t+n

S_t = Valor da base dessazonalizada calculado no instante t

F_t = Valor do coeficiente de sazonalidade para o período t

R_t = Valor da taxa de tendência calculado no período t

α = Constante de suavização da base

β = Constante de suavização de tendência (entre 0 e 1)

V_t = Valor das vendas reais no período t

$$P_t = (S_{t-1} + R_{t-1}) \times F_t \quad (1)$$

$$P_{t+n} = (S_{t-1} + R_{t-1} \times (n + 1)) \times F_{t+n} \quad (2)$$

$$S_t = \alpha \times \left(\frac{V_t}{F_t}\right) + (1 - \alpha) \times (S_{t-1} + R_{t-1}) \quad (3)$$

$$R_t = \beta \times (S_t - S_{t-1}) + (1 - \beta) \times R_{t-1} \quad (4)$$

Regressão Múltipla

Dentro da abordagem causal, os métodos mais utilizados são os de regressão. A técnica consiste basicamente em obter uma equação em que os dados considerados sejam representados de modo a minimizar a soma dos quadrados dos desvios entre os pontos de dados e a curva considerada (FERNANDES e GODINHO, 2010). De modo geral os métodos de regressão seguem a seguinte forma:

$$d_t = f(x_{t-k}) + \varepsilon_t \quad (5)$$

Em que:

d_t = demanda no período t (variável dependente)

$f(x_{t-k})$ = função do comportamento da variável independente x no período t-k

ε_t = ruído (erro aleatório)

O valor de k indica a defasagem da relação entre a variável dependente e as variáveis independentes.

A regressão múltipla é utilizada quando duas ou mais variáveis independentes afetam a variável dependente, não exigindo necessariamente que a relação entre as variáveis seja

linear. O modelo geral da regressão múltipla para n observações e m variáveis independentes segue a forma a seguir (FERNANDES e GODINHO, 2010):

$$d_t = b_0 + b_1x_{1t} + b_2x_{2t} + \dots + b_mx_{mt} + \varepsilon_t \quad (6)$$

$$t = 1, 2, \dots, n$$

Em que:

$b_0, b_1, b_2, \dots, b_m$ = parâmetros (intersecção e inclinações) a serem estimados

Redes Neurais Artificiais

Uma série de fatores influenciam o comportamento da demanda e modelos lineares muitas vezes não conseguem estimar as funções presentes nos dados. Isso ocorre por conta da complexidade que as relações externas (p.e. políticas, econômicas, setoriais) adicionam ao comportamento do consumidor. Neste contexto, as Redes Neurais Artificiais (RNAs) são aproximadores funcionais, ou seja, podem aproximar qualquer função contínua para qualquer acurácia desejada (IRIE e MIYAKE, 1988; HORNIK *et al.*, 1989; CYBENKO, 1989; FUNAHASHI, 1989; HORNIK, 1991, 1993).

Os métodos tradicionais para previsão de séries temporais, como o Box-Jenkins/ARIMA ou a suavização exponencial de Holt-Winters, supõem que a série temporal em estudo é gerada a partir de um processo linear. Apesar da facilidade de implementação dos métodos lineares, eles podem ser inapropriados se a base de dados for fundamentalmente não-linear, o que acontece na maioria dos problemas reais (ZHANG *et al.*, 1997; BASHEER e HAJMEER, 2000).

A formulação de um modelo não-linear para um conjunto de dados em particular não é uma operação simples, uma vez que há um grande leque de possibilidades de padrões não lineares e um modelo não-linear específico pode não ser generalista o suficiente para notar todas as características relevantes do problema. A vantagem das Redes Neurais é que elas são capazes de desempenhar modelos não-lineares sem o conhecimento *a priori* a respeito das relações entre as variáveis de entrada e de saída (ZHANG *et al.*, 1998).

De modo geral, as RNAs são compostas por uma quantidade pré-definida de elementos interconectados, os neurônios. Cada um deles recebe um sinal de entrada, ou seja, o total de “informação” dos outros nós ou ainda de estímulos externos. Em seguida, a rede

processa localmente o conteúdo recebido por meio de uma função de ativação ou transferência e produz um sinal de saída alterado para os outros nós ou para as saídas externas. Esse processamento de informações faz com que a Rede Neural seja uma ferramenta computacional eficiente, capaz de aprender e generalizar o que foi assimilado para dados não vistos anteriormente (ZHANG *et al.*, 1998).

Esforços atuais em pesquisa sobre Redes Neurais Artificiais vêm demonstrando nas últimas décadas que esta técnica conta com uma intensa capacidade de reconhecimento de padrões. Tratada também como ANN (*Artificial Neural Network*), este método auto-adaptativo é impulsionado por dados de entrada e por certas suposições que devem ser estabelecidas *a priori* para que o cenário de estudo seja adequadamente representado no modelo. A rede aprende por meio de exemplos e captura relações sutis nos dados, ainda que tais relações sejam desconhecidas ou difíceis de descrever (ZHANG *et al.*, 1998).

Segundo Fyfe (2000), a história das redes neurais iniciou-se em 1943, quando MCCulloch e Pitts mostraram que uma simples construção baseada nos neurônios do cérebro humano era capaz de executar todas as operações lógicas. Na mesma época, Von Neumann e Turing discutiam aspectos da natureza estatística e robusta do processamento de informações do cérebro. No entanto, foi apenas em 1950 que implementações na tecnologia da informação de fato ocorreram para que as redes neurais começassem a ser produzidas. Ainda assim, alguns problemas não podiam ser resolvidos pelas novas máquinas inteligentes, e em 1969 Minsky e Papert publicaram uma pesquisa, demonstrando claramente que as redes daquele tempo possuíam limitações que não poderiam ser superadas. O entusiasmo pelas redes neurais diminuiu significativamente até que na década de 1980, o físico John Hopfield analisou uma classe específica de redes neurais e provou que elas possuem uma capacidade poderosa de percepção de padrões. Em 1986 o assunto ganhou notoriedade quando Rumalhart, McClelland e o PDP Group redescobriram as regras de aprendizado poderosas as quais transcenderam as limitações antes discutidas por Minsky e Papert (FYFE, 2000).

Diversos tipos de modelos de redes neurais foram propostos desde a década de 1980, sendo o mais importante deles conhecido como *Multi-layer Perceptron* (MLP), ou Perceptron de Múltiplas Camadas (CASTRO e ZUBEN, 1998; HAMZAÇEBI, 2008). Por conta da sua capacidade de mapeamento arbitrário de entradas e saídas, esse tipo de modelo pode ser utilizado em uma variedade de problemas, especialmente em previsões (ZHANG *et al.*, 1998; HAMZAÇEBI, 2008).

A atividade na rede é propagada à frente por meio dos pesos advindos da camada de entrada para a camada intermediária, na qual uma função de ativação da rede é calculada. Em seguida, a atividade é propagada através de mais pesos para os neurônios de saída. Assim, dois conjuntos de pesos devem ser atualizados: entre as camadas intermediária e de saída, e entre a camada de entrada e a intermediária. O erro ocorrido no primeiro conjunto de pesos (entre a camada intermediária e a de saída) é calculado utilizando a regra da menor média quadrática. Em seguida é preciso que essa parte do erro seja propagado à montante devido aos desvios que existem no segundo conjunto de pesos, determinando-se assim o erro proporcional aos pesos os quais o causaram. Observa-se então um problema de determinação de crédito, no qual é preciso decidir que efeito cada peso no primeiro conjunto irá proporcionar nas saídas finais da rede. Esse é o principal resultado do método conhecido como *backpropagation* (FYFE, 2000).

O erro resultante de *backpropagation* é comprovadamente útil no treinamento supervisionado de redes neurais de múltiplas camadas quando aplicado a problemas de classificação e no mapeamento de funções estatísticas não-lineares. Há casos em que a rapidez do aprendizado é um fator limitante às implementações práticas deste tipo de ferramenta computacional no processo de resolução de problemas que requerem otimalidade e rapidez de convergência no ajuste de parâmetros (CASTRO e ZUBEN, 1998).

O treinamento supervisionado, em que o resultado esperado é conhecido para o conjunto de treinamento e teste, de redes neurais artificiais de múltiplas camadas é equivalente a problemas de otimização não-linear sem restrições, em que a função global do erro é minimizada pelo ajuste de parâmetros (pesos e vieses) da rede (CASTRO e ZUBEN, 1998).

Considera-se que as entradas de uma rede neural são aqui denotadas por p , um vetor de valores reais de dimensão ou comprimento arbitrários. Tipicamente, este vetor p é referenciado como o *input* e seu comprimento é o número de entradas da rede. Considera-se ainda que as saídas da rede são denotadas y' , uma aproximação da saída desejada y , também sendo um vetor de valores reais contendo um ou mais componentes, sendo o número de *outputs* da rede. Normalmente o conjunto de dados contém uma quantidade de pares *input-output*, ou seja p e y denotam matrizes com um vetor de *input* e um de *output* em cada linha (LIVINGSTONE, 2008).

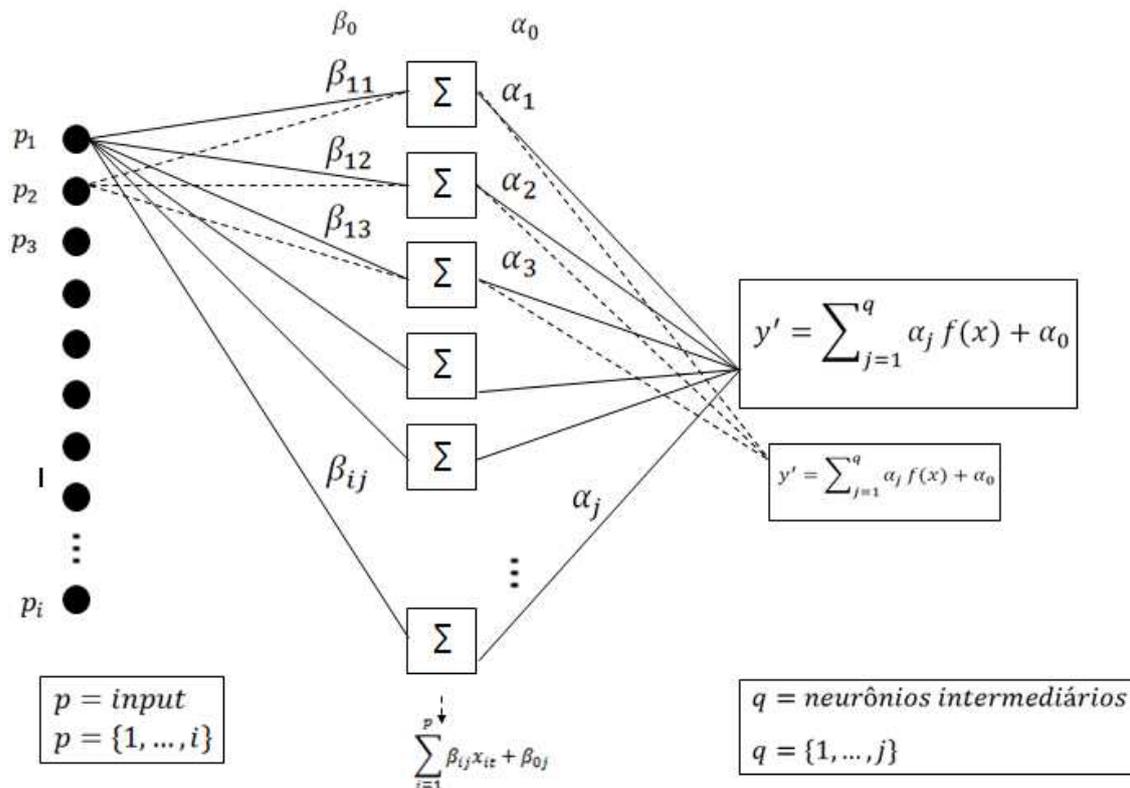


Figura 2.7 Rede Neural Artificial do tipo MLP (Multi Layer Perceptron – Perceptron de m\u00faltiplas camadas)

Geralmente, a estrutura de uma rede neural envolve pesos interconectados entre os neur\u00f4nios, os quais s\u00e3o muitas vezes transforma\u00e7\u00f5es n\u00e3o-lineares escalares, mas as quais tamb\u00e9m podem ser lineares. A Figura 2.7 apresenta um exemplo de uma rede neural com uma camada intermedi\u00e1ria com i inputs $p = \{p_1, p_2, p_3, \dots, p_i\}$, os quais alimentam cada um dos q neur\u00f4nios que compreendem a camada intermedi\u00e1ria. Os *outputs* desta camada e o vi\u00e9s unit\u00e1rio alimentam, em seguida, o neur\u00f4nio \u00fanico da camada de sa\u00edda, ocasionando o *output* escalar $y' = \sum_{j=1}^q \alpha_j f(x) + \alpha_0$ (ZHANG *et al.*, 1998).

Cada linha da Figura 2.7 corresponde a um par\u00e2metro de valor real ou um peso da rede. Os valores desses par\u00e2metros s\u00e3o direcionados durante o treinamento da rede. O neur\u00f4nio \u00e9 estruturado para processar m\u00faltiplos *inputs*, incluindo o input de vi\u00e9s, de forma n\u00e3o-linear, produzindo um \u00fanico *output*, y' . Especificamente, todos os *inputs* de um neur\u00f4nio s\u00e3o primeiramente aumentados por pesos multiplicativos. Esses *inputs* com pesos s\u00e3o somados e em seguida transformados por meio de uma fun\u00e7\u00e3o de ativa\u00e7\u00e3o n\u00e3o-linear $f(x)$. O *output* de sa\u00edda \u00fanico \u00e9 linear uma vez que a fun\u00e7\u00e3o de ativa\u00e7\u00e3o \u00e9 utilizada (LIVINGSTONE, 2008).

Assim, o *output* da rede neural da Figura 2.6 é dado por:

$$y' = \sum_{j=1}^q \alpha_j f \left(\sum_{i=1}^p \beta_{ij} x_{it} + \beta_{0j} \right) + \alpha_0 \quad (7)$$

Em que:

y' = saída da RNA (previsão e valores aproximados de y)

q = neurônios intermediários $\{1, \dots, j\}$

p = entrada da RNA (variáveis independentes) $\{1, \dots, i\}$

α = pesos da camada de saída

β = pesos da camada de intermediária

Antes que a rede treinada seja aceita, é necessário validá-la. A grosso modo, isso significa que é preciso efetuar uma série de testes a fim de determinar se o modelo da rede reconhece certos requisitos. Provavelmente o melhor modo é testar a rede em um conjunto de dados que não tenha sido usado no treinamento, mas o qual foi gerado em condições similares. É comum que a rede treinada falhe na validação, obrigando o usuário a escolher um modelo melhor. No entanto, é possível que simplesmente repetir o treinamento, iniciando com pesos diferentes, seja suficiente para gerar melhores resultados (LIVINGSTONE, 2008).

d. Medidas de Acurácia na Previsão

Na literatura há uma série de medidas de acurácia, havendo para cada uma delas vantagens e desvantagens. Um modo considerado ótimo para uma amostra não necessariamente será o melhor em outras. Por conta das limitações associadas a cada medida indica-se utilizar uma combinação delas (ZHANG *et al.*, 1998). Os métodos usuais aplicados aos dados neste estudo são: MAD (*Mean Absolute Deviation* - erro médio absoluto); MAPE (*Mean Absolute Percentage Error* - erro médio absoluto percentual); MSE (*Mean Squared Error* - erro quadrático médio) e RMSE (*Root Mean Square Error* - raiz quadrada do erro quadrático médio).

O erro médio é um modo simples de calcular a acurácia do método de previsão. Se os valores dos erros forem simplesmente somados para em seguida tirar a média, haverá certo

desaproveitamento, pois valores positivos serão neutralizados pelos negativos. Dessa forma, utiliza-se o valor absoluto, sem os sinais. Essa medida de acurácia é chamada de *Mean Absolute Deviation* (MAD) ou Erro Médio Absoluto (MAKRIDAKIS e WHEELWRIGHT, 1989). Quanto mais próximo de zero for a média dos erros, mais precisa é a previsão. Essa medida, no entanto, pode ser mal interpretada devido a proporção com relação ao volume total da série a ser prevista. Ou seja, havendo um volume grande de vendas e erro médio absoluto diferente de zero, proporcionalmente o desvio pode não ser significativamente grande.

Assim, um outro modo de medição é o Erro Médio Absoluto Percentual, ou *Mean Absolute Percentage Error* (MAPE). Para calculá-lo basta utilizar a relação entre o erro absoluto de cada período e o valor real observado, multiplicando o resultado por 100%. Somando-se todos os valores observados e dividindo pela quantidade de períodos, obtém-se o valor médio, ou seja, o MAPE (MAKRIDAKIS e WHEELWRIGHT, 1989). Neste caso, a proporção com relação ao volume total de vendas é respeitado. Essa medida é provavelmente a mais utilizada para comparação entre séries históricas (GOODWIN e LAWTON, 1999), entretanto penaliza desvios extremos da mesma maneira que pequenos desvios.

Neste sentido, o Erro Médio Quadrático, ou *Mean Squared Error* (MSE), é obtido ao calcular o quadrado de cada erro, dividindo-se o total pela quantidade de períodos. Esta medição penaliza mais os maiores desvios, ou seja, este critério implica que é preferível obter vários erros pequenos na previsão do que um único grande desvio (MAKRIDAKIS e WHEELWRIGHT, 1989). O RMSE, por sua vez, nada mais é do que a raiz quadrada desse desvio.

3. Revisão da Literatura

a. A PV no setor de máquinas agrícolas

Os estudos na área de previsão de vendas mostram-se majoritariamente direcionados ao varejo (REYNOLDS *et al.*, 2013; XIA e WONG, 2014; ARUNRAJ e AHRENS, 2015; AYE *et al.*, 2015; ALI e PINAR, 2016; MERINO e RAMIREZ-NAFARRATE, 2016). No entanto, é possível encontrar um escasso número de pesquisas recentes na área aplicadas à maquinários agrícolas. Como apontado por Klochkov (2006), atualmente métodos econométricos de previsão de demanda estão se tornando ineficientes em analisar mercados deste tipo. Segundo o autor, projeções baseadas na análise direta do processo de escolha do comprador estão se tornando mais apropriados e, desta forma, modelagens econométricas de prospecção do comportamento do mercado devem ser acompanhadas pela análise da interação deles com os procedimentos de marketing. Assim, o paradigma tradicional de previsão de demanda passiva é substituído por uma abordagem baseada no controle ativo de demanda. Vale ressaltar aqui a importância da Gestão da Demanda neste processo.

Estudos sobre métodos de previsão de vendas relacionados ao mercado de equipamentos abrangem a gestão de peças de reposição e manutenção. A fim de planejar a manutenção de motores, Kozik e Sep (2012) comprovaram a superioridade das redes neurais na previsão de peças de reposição para helicópteros, utilizando como fator de decisão o ciclo de revisão do produto. Wang *et al.* (2013) propuseram uma combinação métodos para previsão de confiabilidade no armazenamento de interruptores eletromecânicos. O modelo foi nomeado Rede Neural Artificial Grey e utiliza a técnica de inteligência artificial de RNAs atrelada à teoria Grey, sistema que inclui a continuação discreta de dados, com alta precisão na modelagem e capaz de fornecer previsões simplificadas (WANG *et al.*, 2013).

Paralelamente, Gerdes (2013) propôs um modelo de algoritmo genético para prever a condição de sistemas de ar condicionado de meios de transporte, a fim de facilitar o planejamento de manutenções. O método utiliza árvores de decisão para encontrar e aprender os padrões na série histórica e utiliza os padrões para selecionar o método de previsão a ser utilizado. O algoritmo genético é utilizado para encontrar o melhor conjunto de características que melhora a performance do método de previsão.

No âmbito nacional, Flores e Werner (2007) realizaram a modelagem de RNAs para prever as vendas de máquinas agrícolas. Dentre os modelos testados, o que demonstrou

melhor performance não utilizou variáveis externas, apenas a própria série histórica de venda de tratores. Por meio do modelo de redes neurais com três neurônios na camada intermediária, atingiu-se erro médio percentual de 35%. Apesar do desvio alcançado ter sido menor do que aquele praticado pela previsão que o fabricante costumava obter, a performance mostrou-se ainda insatisfatória quando comparada aos resultados que uma RNA é capaz de obter.

Outros estudos envolvem a previsão de demanda de rotas. É o caso do artigo de Srinidhi e Manrai (2014), em que os autores desenvolveram um modelo de previsão de demanda de tráfego, baseando-se no rendimento de zonas de operação. Em seguida, estruturaram uma matriz de posicionamento de serviço para auxiliar na especificação geográfica das previsões de rotas que desejavam realizar. No caso de Tasmbekov *et al.* (2014), um modelo de previsão da trajetória foi desenvolvido para auxiliar a tomada de decisão de curto e médio prazo. Como ferramentas de suporte à decisão, o algoritmo mostrou-se útil no controle de tráfego e na detecção de conflitos.

Oliveira e Ferraz (2008) desenvolveram um modelo econométrico de previsão de demanda para o processo de chegadas no Sistema de Reservas de companhias aéreas, visando otimizar o faturamento das firmas. O resultado do modelo de séries temporais proposto pelos autores indica a existência de um processo auto-regressivo de chegadas em que as variáveis de nível defasadas, de variação e aceleração, tem poder preditivo dos níveis correntes de chegada.

Em termos de análise estratégica da demanda, Lewis e Loebbaka (2008) investigaram o decaimento estratégico na indústria aeronáutica comercial. O processo de gestão estratégica foi analisado nos termos de uma companhia de alumínio na cadeia de suprimentos que pôde planejar suas ações futuras por meio da adequação resiliente de seus processos. Observa-se por meio da revisão da literatura de previsões no setor aeroespacial e de maquinários agrícolas que o aumento na performance dos métodos aplicados à esses setores vem sendo ampliada por meio da Inteligência Artificial (IA), em âmbito nacional e internacional.

b. Previsão de Vendas com Redes Neurais Artificiais

As abordagens quantitativas de previsão de vendas existentes incluem métodos heurísticos, como decomposição de séries temporais e suavização exponencial, assim como modelos de regressão e de médias móveis integradas auto-regressivas (ARIMA). CHU & ZHANG (2003) defendem que a linearidade dos modelos é a maior limitação dos métodos

tradicionais, uma vez que previsões baseadas nessas técnicas não são capazes de considerar as complexas relações presentes nos dados. Foi neste cenário que os modelos não lineares de redes neurais ganharam força. No entanto, o método não é o mais indicado quando se trata de indústrias com ciclo de vida curto ou com ampla variedade de produtos (TANAKA, 2010).

As recentes pesquisas com Redes Neurais Artificiais vem demonstrando a alta capacidade desse método no reconhecimento e classificação de padrões. Inspirado no sistema biológico do cérebro humano, as RNAs quando bem elaboradas são eficazes no aprendizado e generalização de experiências passadas (LIVINGSTONE, 2008). Os modelos de previsão vem se tornando cada vez mais precisos com as aplicações de RNAs, especialmente por meio de incrementos e ajustes cada vez mais complexos.

As aplicações das Redes Neurais em previsão vendas foram extensivamente investigadas nos últimos anos, principalmente em projeções para o varejo (ALON *et al.*, 2001; CALÔBA *et al.*, 2002; ALMEIDA e PASSARI, 2006; ALVES *et al.*, 2013). O fenômeno se dá provavelmente devido à dinâmica do mercado e à necessidade de agilidade e flexibilidade das empresas em reagir à demanda.

Outros setores também tem investido em aplicações de RNA, como a moda e a indústria cinematográfica. Du *et al.* (2015) formulou um modelo de redes neurais com otimização multiobjetivo para solucionar as dificuldade do replanejamento de curto prazo no setor de moda. Tanto Yu *et al.* (2011) como Xia *et al.* (2012), no entanto, propuseram modelos de aprendizado de máquinas como alternativa às RNAs. Na indústria de filmes, o método de RNAs dinâmicas foi aplicado por Ghiassi *et al.* (2015) para prever os rendimentos no lançamento de novos filmes, atingindo um aumento de 32,8% na acurácia das previsões.

A combinação de técnicas é comumente encontrada na literatura, especialmente envolvendo RNAs. Kuo (2001), por exemplo, criou um modelo para previsão de vendas por meio de uma complexa combinação de métodos, considerando as variações geradas por campanhas de marketing. O autor modelou uma rede neural tradicional e combinou-a com uma rede neural a partir de algoritmo genético especificamente para as vendas em tempos de promoção.

Um outro aperfeiçoamento de método foi aplicado por Wang *et al.* (2011). No estudo as Redes Neurais Artificiais foram combinadas à lógica fuzzy, técnica em que experiências ou conhecimentos anteriores são utilizadas em um conjunto de restrições a fim de atingir a

solução ótima. A combinação das técnicas possibilitou capturar os padrões mais finos, adaptando os parâmetros da função central rapidamente e otimizando-os conforme os dados de entrada. O modelo apresentou performance superior ao método ARIMA e às RNAs tradicionais, apesar deste último também ter exibido desvio percentual médio satisfatório, menor do que 5%.

Baseando-se no argumento de que a combinação de métodos costuma melhorar a acurácia das previsões, Zhang (2003) desenvolveu um modelo híbrido utilizando o método linear ARIMA em conjunto com a técnica não-linear de Redes Neurais para captar os distintos padrões em uma determinada série temporal. Primeiramente, o autor separou o componente linear do não-linear e utilizou o método ARIMA para realizar a análise linear. Em seguida, o modelo de RNA é aplicado para a fração não-linear dos dados. No entanto, apesar de ter demonstrado em seus resultados que a combinação dos métodos gerou melhora na acuracidade na previsão em três diferentes amostras, o aperfeiçoamento não é impressionante. A diferença entre o método híbrido e o uso da RNA por si só é pequena.

De modo geral, as Redes Neurais Artificiais estão presentes nas previsões com melhores performances da literatura. Alon *et al.* (2001) compararam métodos tradicionais e redes neurais para previsão de vendas no varejo. Na análise de dois distintos períodos de estabilidade econômica foram avaliados e as previsões foram testadas para um mês e para doze meses à frente. Os resultados demonstraram que RNAs tem a melhor performance de modo geral, seguida do método ARIMA e da Suavização Exponencial de Winters, especialmente quando se trata de condições macroeconômicas voláteis. Além disso, a previsão 12 meses à frente apresentou melhores resultados nessas condições. Ademais, foi comprovado que RNAs são capazes de capturar os padrões dinâmicos de tendência e sazonalidade, assim como suas interações.

Chu e Zhang (2003) testaram a rede neural para previsão de vendas no varejo com dados brutos e desazonalizados. Os resultados foram comparados com outros métodos de previsão, como modelo regressão com variáveis *dummy* e ARIMA, indicando a superioridade das redes com dados ajustados. Zhang e Qi (2005) realizaram uma análise comparativa entre modelos de RNAs para previsão de séries temporais e comprovaram que o método é capaz de gerar resultados melhores que os gerados pela técnica ARIMA. Os autores realizaram previsões para uma variedade de setores, atingindo erro médio percentual menor que 1% para bens de consumo. No caso de bens duráveis, o desvio percentual médio foi de cerca de 3%.

Dentro da literatura nacional também são encontrados estudos com redes neurais em previsões. Oliveira *et al.* (2010) obtiveram sucesso na aplicação das redes neurais para previsão da produção de álcool no Brasil em 2006. A arquitetura da rede contou com 48 neurônios intermediários e atingiu um erro médio percentual de 24,7%, contra aproximadamente 26% de desvio médio com o método SARIMA. Resultados similares foram alcançados por Almeida e Passari (2006), em que a técnica de redes neurais foi utilizada para prever vendas no varejo e comparada com um modelo de regressão. A RNA obteve desvio médio de cerca de 30% enquanto a regressão apresentou cerca de 50% de erro médio percentual.

Calôba *et al.* (2002), no entanto, atingiu resultados mais precisos na previsão da série histórica de vendas de cerveja na Austrália. Primeiramente os autores estimaram a reta de tendência para os pontos da série a fim de reduzir a dispersão das observações, em seguida foram subtraídos os padrões sazonais. A análise comparativa foi realizada entre os métodos tradicionais lineares de decomposição e suavização exponencial de Holt-Winters, com performance superior da rede que atingiu erro médio percentual de 4,5% contra 7% na decomposição clássica e 5% na suavização.

Ainda no âmbito nacional, a técnica de RNAs também foi empregada para previsão de faturamento em lojas do varejo por Alves *et al.* (2013). O modelo desenvolvido pelos autores realiza a previsão por meio da entrada de um conjunto de dados que caracterizam um novo ponto de venda. Os resultados indicaram desvio médio de no máximo 4% na fase de testes, no entanto não foi possível observar a performance da rede após a validação.

Geralmente a literatura ocupa-se em testar diferentes modelos e selecionar aquele com resultados mais precisos. No entanto, é praticamente universalmente aceito na literatura de previsões que um único modelo seja o melhor em qualquer situação. O modelo final selecionado não será necessariamente o melhor para aplicações futuras por conta de fatores potenciais de influência como a variação da amostra, as incertezas do modelo e as mudanças de estrutura do sistema de previsão (ZHANG, 2003).

c. Particularidades das RNAs em PV

No final da década de 1990 e início dos anos 2000 uma variedade de estudos discutiram a necessidade de pré-processamento dos dados, questionando se RNAs são capazes

de modelar diretamente diferentes componentes de sazonalidade e tendência na série (ZHANG *et al.*, 1998).

Apesar da comprovação de Alon *et al.* (2001), as conclusões quanto à pré-modelagem dos dados de entrada da rede neural são mistas. Hanzaçebi (2008) também demonstrou em seu modelo de redes neurais com sazonalidade que essa técnica é capaz de realizar previsões diretamente, sem a necessidade de remover o efeito sazonal dos dados. No entanto, Zhang e Qi (2005) demonstraram que previsões mais precisas podem ser obtidas se a sazonalidade e a tendência forem retiradas dos dados antes de utilizá-los na rede neural. Em ambos os casos a performance das redes neurais provou ser superior ao método ARIMA.

Ghysels *et al.* (1996) concluíram em seu trabalho que o ajuste dos dados pode resultar em propriedades não lineares indesejadas, distorções severas nos dados e performance inferior nas previsões. De Gooijer e Franses (1997) apontaram que apesar dos ajustes de sazonalidade serem úteis em alguns casos, é recomendado utilizar dados sem o ajuste sazonal. Goor (1994) apontou em seu estudo que o ajuste é desnecessário uma vez que as redes neurais, por definição, contém a habilidade de aproximadores universais, enquanto Franses e Draisma (1997) comprovaram em seus estudos que redes neurais são capazes de detectar possíveis mudanças nos padrões sazonais. Resultados similares foram publicados por Tang e Fishwick (1993), Nam e Schaefer (1995) e Alon *et al.* (2001). Por outro lado, Nelson *et al.* (1999), Zhang e Qi (2002), assim como Chu e Zhang (2003) indicaram que as redes neurais não são capazes de capturar as dinâmicas não-lineares dos padrões de tendência e sazonalidade, assim como as interações entre eles.

O método de Redes Neurais Artificiais oferece a pesquisadores e profissionais do mercado uma ferramenta atrativa por conta de uma série de notáveis características. Inicialmente, as RNAs são auto-adaptativas, orientadas por dados e suposições associados à amostra em estudo. Elas aprendem por meio de exemplos e captam relações intrínsecas entre os dados e funções atrelados ao modelo, ainda que tais relações sejam difíceis de serem captadas (ZHANG e QI, 2005; HANZAÇEBI, 2008). Desse modo as RNAs são eficazes na solução de problemas em que é difícil reconhecer as regras que influenciam o sistema em que os dados são gerados, ainda que haja dados suficientes (TANAKA, 2010).

As RNAs contam também com a capacidade de generalização. Ou seja, após aprender por meio da amostra, podem realizar inferências para uma parcela não vista da população,

ainda que essa parte contenha ruídos. É dessa forma que a previsão ocorre por este método (LIVINGSTONE, 2008). Outra característica das RNAs favorável para o campo das previsões é a sua capacidade de aproximação funcional - são ditas aproximadoras funcionais universais (HANZAÇEBI, 2008). Foi demonstrado que uma rede neural pode aproximar qualquer função contínua para qualquer acuracidade desejada, contando com funções mais generalistas e flexíveis do que os métodos estatísticos tradicionais. Qualquer que seja o método de previsão, assume-se que há uma relação subjacente entre os dados de entrada (série histórica das variáveis relevantes) e os de saída (valores futuros). Os métodos tradicionais são limitados no reconhecimento dessas funções, ao contrário das RNAs (BASHEER e HAJMEER, 2000).

RNAs são não-lineares, ao contrário dos métodos mais tradicionais de previsão. Métodos lineares tem a vantagem de serem mais fáceis de implementar e utilizar, no entanto é arriscado afirmar que a ocorrência de uma série histórica em particular é gerada por um processo linear. Pelo contrário, sistemas reais, na maioria das vezes, são não lineares em razão da complexidade (CHU e ZHANG, 2003). As RNAs são capazes de representar modelagens não lineares sem que haja *a priori* o conhecimento das relações entre os dados de entrada e saída.

As aplicações de RNAs em previsão de séries históricas são variadas. Elkateb *et al.* (1998) realizaram um estudo comparativo entre o método ARIMA e RNAs para previsão de carga elétrica, comprovando a superioridade da técnica não-linear para esse caso. A concentração diária máxima de ozônio também foi estudada por Prybutok *et al.* (2000), em que modelos lineares de regressão e ARIMA apresentaram performance inferior ao modelo de RNA. No entanto, nem todos os autores concluíram a superioridade das RNAs em previsão de séries históricas. Tanto Church e Curram (1996) como Ntungo e Boyd (1998) mostraram que as redes neurais apresentam desempenho muito próximo, mas não superior, a métodos econométricos. Descobertas negativas à respeito da técnica foram reportadas em previsão de lucros contábeis trimestrais por Callen *et al.* (1996). Na ocasião os autores mostraram que as RNAs não eram mais eficientes que modelos de séries temporais lineares, ainda que os dados fossem não-lineares. Conclusões similares foram relatadas por Kirby *et al.* (1997) e Darbellay e Slama (2000).

4. Metodologia

De caráter investigativo, o estudo vinculado neste trabalho assumiu a forma de uma Pesquisa-Ação, método que, como salientado por Tripp (2005), aplica-se a projetos em que o objetivo é realizar transformações das práticas pelos próprios práticos. Desta forma, os participantes deixam-se envolver pela vida cotidiana e pela compreensão das tensões do coletivo, percebendo e repensando as possíveis rupturas nos processos práticos (JESUS *et al.*, 2014). Trata-se aqui de um estudo aplicado de caráter quantitativo, atrelado à pesquisa bibliográfica sobre os temas de Gestão da Demanda, Previsão de Vendas e, especialmente, Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas (MLP).

A fim de direcionar os envolvidos com o processo de Gestão da Demanda da empresa a discutir os temas inerentes à pesquisa, uma série de questões foram preparadas de antemão. No entanto, permitiu-se que os assuntos fossem extrapolados para que assim o conteúdo das discussões fosse além dos temas previstos pelos pesquisadores e questões pertinentes ao mercado fossem apontadas e analisadas. Seguidamente, de modo a agregar a realidade prática da instituição às percepções do estudo, o processo de gestão do negócio foi amplamente analisado por meio da vivência no ambiente empresarial.

Segundo Jesus *et al.*, (2014), a pesquisa-ação faz uso de distintas lógicas para interpretar, dialogar e instituir mudanças em processos, especialmente por meio de perspectivas multirreferenciais. Os questionamentos tiveram enfoque, primeiramente, nos processos de Gestão da Demanda e Previsão de Vendas praticados pela empresa, realizado por meio de uma ferramenta de planejamento integrado. A elaboração do questionário foi realizada com o intuito de conduzir os entrevistados à expressarem suas percepções quanto às razões pelas quais as ferramentas são utilizadas. As etapas para realização do processo de Gestão da Demanda, fase a fase, foram observadas. Os resultados esperados pelos envolvidos com a utilização da ferramenta foi então questionada, assim como a frequência de execução. Foram levantados e analisados ainda os *stakeholders* do processo, as interfaces com outras áreas e os sistemas de informações atrelados.

A pesquisa teve como objetivo elaborar um modelo de Previsão de Vendas aderente a um processo de Gestão da Demanda, praticado por uma empresa de máquinas agrícola, cuja série histórica de dados de vendas foi cedida para teste de modelos preditivos. A empresa escolhida para realizar o estudo apresenta requisitos substanciais para execução do estudo, tais como

sólida presença no mercado de máquinas agrícolas, com cerca de 60% de participação no mercado do produto cuja série histórica foi utilizada, gerando assim segurança na série de dados e nas informações cedidas para a análise. Além disso, trata-se de um produto inovador, único no mercado mundial no tipo de tecnologia, o qual ainda não apresenta participação significativa na literatura de previsões. A empresa, a qual não exibiu ainda um processo formal de gestão da demanda cedeu não apenas os dados, como o ambiente de trabalho e acesso aos processos de modo integrante ao negócio.

As informações decorrentes do processo de Gestão da Demanda e Previsão de Vendas foram mapeadas por meio de entrevistas direcionadas por questionário aberto (ANEXO 1) com os responsáveis pelas áreas Comercial e de Planejamento de Produção, assim como pela observação sistemática dos processos de negócio. Seis profissionais da empresa de diferentes níveis hierárquicos foram entrevistados, abrangendo Vendas e Inteligência de Mercado, Planejamento de Produção e Gerência. Os colaboradores entrevistados foram aqueles cujo contato era maior com o processo de previsão de vendas. Dois profissionais de vendas e um de inteligência de mercado, com experiência maior que três anos em suas funções, puderam agregar informações de mercado, assim como as dificuldades em projetar as vendas futuras. Os entrevistados, com base no contato com os representantes externos à empresa, apontaram a oscilação do mercado e as dificuldades no contato com os bancos para obtenção do financiamento aos compradores como restrição no processo de gestão da demanda.

Os dois profissionais de planejamento entrevistados, sendo um gestor e ambos responsáveis pelas etapas de planejamento, programação e controle de produção, com experiência maior que cinco anos na função, puderam agregar ao estudo noções de tempo e capacidade dos recursos da companhia. A área é responsável pelo abastecimento da linha e, portanto, pelo contato direto com as áreas de Suprimentos. A gestão da capacidade produtiva, tanto na produção como no escritório, foi apontada como uma dificuldade no processo de gestão da demanda.

Em uma segunda etapa, questões mais específicas foram abordadas (ANEXO 2), como parâmetros de entrada e horizonte de previsão. Com o lançamento planejado de um novo modelo do equipamento, o leque de produtos finais foi apontado como sendo quatro: duas versões do modelo antigo e duas do novo modelo. Os dados utilizados na realização do estudo correspondem às séries temporais das vendas anuais e trimestrais de máquinas agrícolas num período de 8 anos. Foram selecionadas sete variáveis independentes, a serem apresentadas na

Seção 5d., que apresentaram alto índice de correlação com a venda do equipamento para realizar a modelagem matemática de uma Rede Neural Artificial do tipo MLP, ou Perceptron de Múltiplas Camadas, para previsão de vendas.

As interações frequentes entre os especialistas, tanto no início do mapeamento do processo quanto durante a fase de testes e implementação seguiram uma lógica similar aquela proposta pelo método Delphi, apresentado na Seção 2. As discussões e comentários dos profissionais foram compiladas a cada encontro até que o processo de Gestão da Demanda estivesse mapeado conforme o consenso, e as variáveis do modelo de previsão estabelecidas.

Barbier (2004) aponta a pesquisa-ação como um modo não de produzir mais saber, mas de reconhecer e melhorar a realidade do ambiente tal como é percebido nas interações sociais. Sendo assim, foi utilizado como ferramenta de análise o Processo de Pensamento da Teoria das Restrições de Goldratt, o qual pode ser considerado um método de identificação, análise e solução de problemas que procura facilitar a liberação, focalização e crítica da intuição (GOLDRATT e WEISS, 2005). A lógica baseia-se em relações de efeito-causa-efeito e na visão crítica da realidade, procurando compreender por que as coisas acontecem (ANTUNES *et al.*, 2004). Parte do processo que busca identificar o que mudar é chamada Árvore da Realidade Atual (ARA), em que são definidos os problemas centrais encontrados no sistema em análise. A representação da ARA para a situação observada para a previsão de equipamentos agrícolas será apresentada no Capítulo 5.

As dinâmicas de mercado visando competitividade e agilidade na hora de lidar com mudanças bruscas de mercado vem direcionando as empresas a buscar soluções de integração em seus processos. Tendo em vista que a gestão orienta-se a agregar valor ao longo das diversas funções nas organizações, o eficiente mapeamento de processos pode auxiliar gestores a obter melhor desempenho das operações (JACOSKI e GRZEBIELUCHAS). Desse modo, o processo de Gestão da Demanda praticado pela empresa foi mapeado conforme informações cedidas e entrevistas compiladas. Posteriormente ao estudo e à definição do processo de Previsão de Vendas, foi também proposto um novo processo de GD, ambos a serem apresentados no Capítulo 5.

Os processos foram mapeamento utilizando-se a Notação de Modelagem de Processos de Negócio, ou BPMN³ (OMG, 2011), cuja gramática de símbolos teve grande aceitação

³ *Business Process Model and Notation*

devido a sua simbologia intuitiva. Nele o processo de negócios é representado através do encadeamento de eventos e atividades, ligados por conectores indicando a sequência do fluxo. O software gratuito Bizagi foi utilizado para realizar o mapeamento.

Além do modelo de redes neurais, também foram utilizados neste trabalho os modelos de Regressão Múltipla e de Suavização Exponencial a título de comparação. Foram testadas onze configurações diferentes de redes neurais a fim de determinar aquela que forneceria o resultado mais preciso. A performance dos resultados foi avaliada por um conjunto de medições de erro, sendo elas: Erro Médio Absoluto, Erro Médio Percentual e Erro Médio Quadrático.

Os modelos de Regressão e Suavização foram aplicados com o software MS Excel, enquanto a Rede Neural foi modelada por meio do MATLAB. O procedimento para determinação dos parâmetros da rede foi o de tentativa e erro, como praticado majoritariamente na literatura (ZHANG *et al.*, 1998). Os parâmetros testados foram a quantidade de neurônios na camada intermediária, a taxa de treinamento e a quantidade máxima de iterações para encontrar o peso ótimo.

O departamento de Planejamento e Controle da Produção da indústria, responsável pelo processo de Gestão da Demanda em conjunto com a área de Inteligência de Mercado, vinha realizando a previsão de vendas de máquinas agrícolas por meio de um modelo de regressão múltipla já obsoleto, como apresentado no Capítulo 5. Havendo a necessidade de revisão do modelo a fim de adequá-lo à realidade do mercado atual foi promovido um estudo abrangente de seu processo de Gestão da Demanda e para que fosse delineado um novo processo de Previsão de Vendas, explorando técnicas mais robustas. Neste cenário, o modelo de previsão com Redes Neurais Artificiais foi colocado em prática.

A pesquisa-ação, assim como qualquer investigação-ação, segue um ciclo no qual aprimora-se a prática por meio da alternância entre o agir, no campo da prática, e investigar sobre ela. O ciclo consiste no Planejamento, Implementação, Descrição e Avaliação de uma mudança visando melhorar as atividades práticas. Desse modo aprende-se mais no decorrer dos processos tanto sobre a prática quanto sobre a investigação, como em um ciclo de melhoria contínua de PDCA⁴ (TRIPP, 2005).

⁴ PDCA: *Plan, Do, Check, Act*. Método iterativo de gestão de melhoria contínua e controle de processos, popularizado por W. Edwards Deming.

A validação do processo de Gestão da Demanda foi realizada nessa investigação por meio de dois ciclos de Pesquisa-Ação. No primeiro ciclo as ferramentas de análise de dados e previsão de vendas foram implementadas e avaliadas, procedendo-se com ajustes e adaptações para que um segundo ciclo fosse implementado e o processo de Gestão da Demanda estabelecido. Na segunda avaliação da mudança, os ajustes necessários identificados foram corrigidos e o processo de melhoria contínua foi inserido no processo de Gestão da Demanda para que a organização pudesse a partir de então manter ciclos internos de investigação.

5. Previsão de Vendas no mercado de máquinas agrícolas: propostas, resultados e discussões

a. O processo de negócio da Previsão de Vendas na empresa estudada

Tendo em vista a complexidade na aplicação e manutenção de modelos de previsão, foi desenvolvido para a empresa de máquinas agrícolas um mapeamento do processo de negócio do planejamento, previsão e gestão da demanda. Trata-se de uma empresa e de um produto nacionais, cuja série histórica de vendas tem início na década de 70. As vendas são exclusivamente para o mercado interno, com forte presença e um produto cuja tecnologia é única no mercado mundial de produtos similares. O tempo de produção varia de 56 a 68 dias.

Uma das questões centrais na previsão de vendas consiste na percepção da empresa quanto às características essenciais no processo de decisão do comprador. No caso estudado, a venda de maquinário agrícola é realizada por representantes comerciais, que comunicam periodicamente a quantidade de clientes interessados em realizar a compra das máquinas. A informação é destinada à área Comercial, a qual realiza a previsão de vendas com base na percepção de mercado destes representantes. Antes do mapeamento e revisão do processo de Gestão da Demanda, notou-se que esse meio de realizar a previsão seguia algumas das premissas do método Delphi. Isto é, os especialistas de mercado e os da empresa fabricante realizavam a previsão por meio de interações recorrentes até que um consenso fosse estabelecido.

Esse modelo de negócios dificultava a assimilação da área de Marketing dos fatores mais importantes na tomada de decisão do cliente em potencial. A realidade do processo de previsão e gestão de demanda da empresa antes do estudo, bem como o mapeamento dos processos são apresentados nas Figuras 5.1, 5.2 e 5.3.

A previsão de vendas de uma determinada empresa gera impactos diretos em todo o planejamento e controle da produção, uma vez que a partir dessa expectativa futuros necessidades ou investimentos podem ser planejados. Isto é, o planejamento é a formalização do que pretende-se que aconteça no futuro, com base na previsão. Quanto maior for a incerteza quanto à demanda, mais difícil será realizar o planejamento de recursos e da capacidade produtiva (SLACK *et al.*, 2009). Assim, a previsão de vendas assume um papel de suma importância para a manutenção do negócio, seja ela realizada para o curto, o médio ou o longo prazo.

O processo de previsão de vendas reflete no plano de vendas da organização, em que a expectativa de demanda é transmitida em ações gerenciais para atingir a previsão. É de responsabilidade dos gestores a formalização de um plano operacional, em que a realidade da empresa e de mercado, as capacidades e necessidades da organização, são incorporados. Isso significa que o plano de vendas pode resultar em uma quantidade maior ou até mesmo menor do que a resultante da previsão.

Sendo assim, o papel da previsão de vendas extrapola sua função na Gestão da Demanda. Os impactos resultantes da projeção irão gerar ações que vão além das funções de marketing e suprimentos, atingindo diretamente a produção e os recursos produtivos, assim como a gestão da capacidade. Uma previsão otimista poderá levar ao aumento dos estoques, gerando perda de liquidez no capital da empresa. Mais do que isso, a produção excedente gera o desperdício dos recursos produtivos, sejam eles materiais ou intangíveis – como o tempo gasto pelos colaboradores, seja na produção ou no planejamento, o qual poderia ser investido de modo a agregar mais valor ao negócio.

Por outro lado, uma previsão pessimista pode resultar em perda na participação de mercado, principalmente quando trata-se de produtos cujo tempo de produção é longo. Isto é, tendo sido planejada a produção de uma quantidade menor que aquela demandada, haverá clientes insatisfeitos. Essa insatisfação pode refletir-se em vantagem competitiva para os concorrentes.

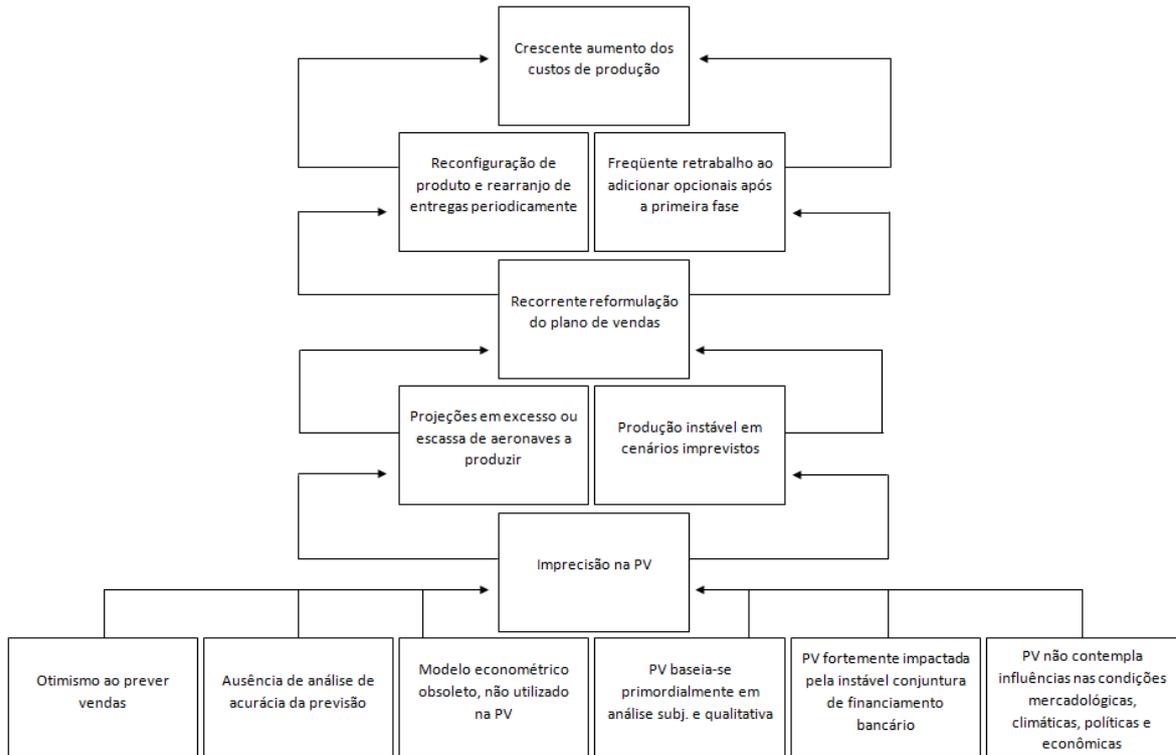


Figura 5.1 Árvore da Realidade Atual: principais disfunções levantadas

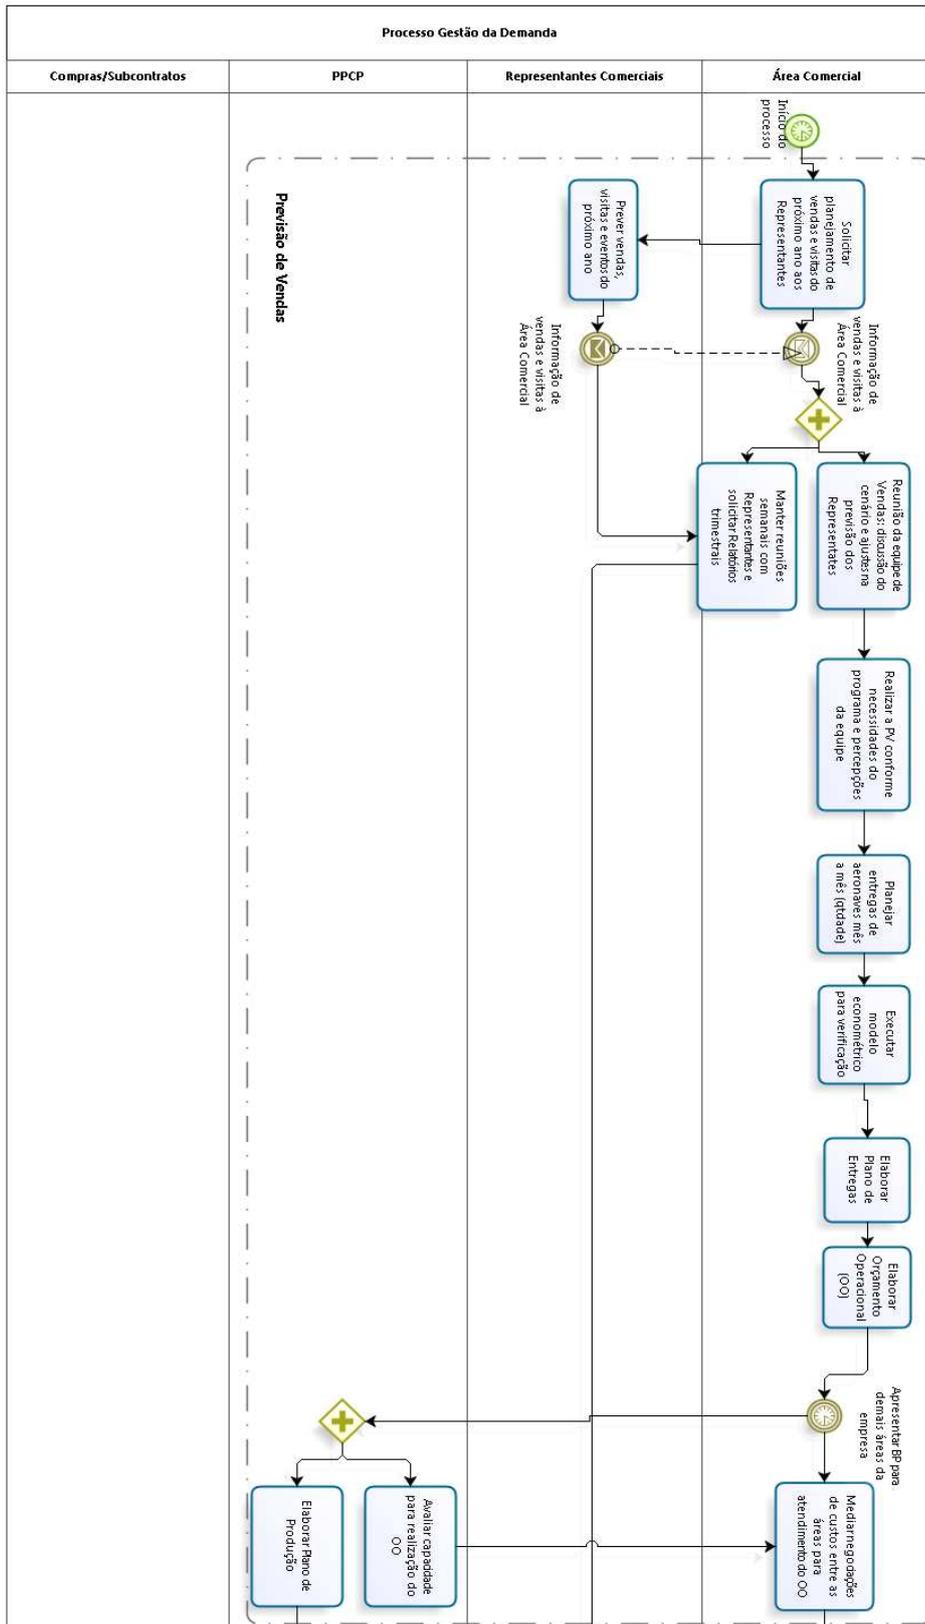


Figura 5.2 Processo de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 1

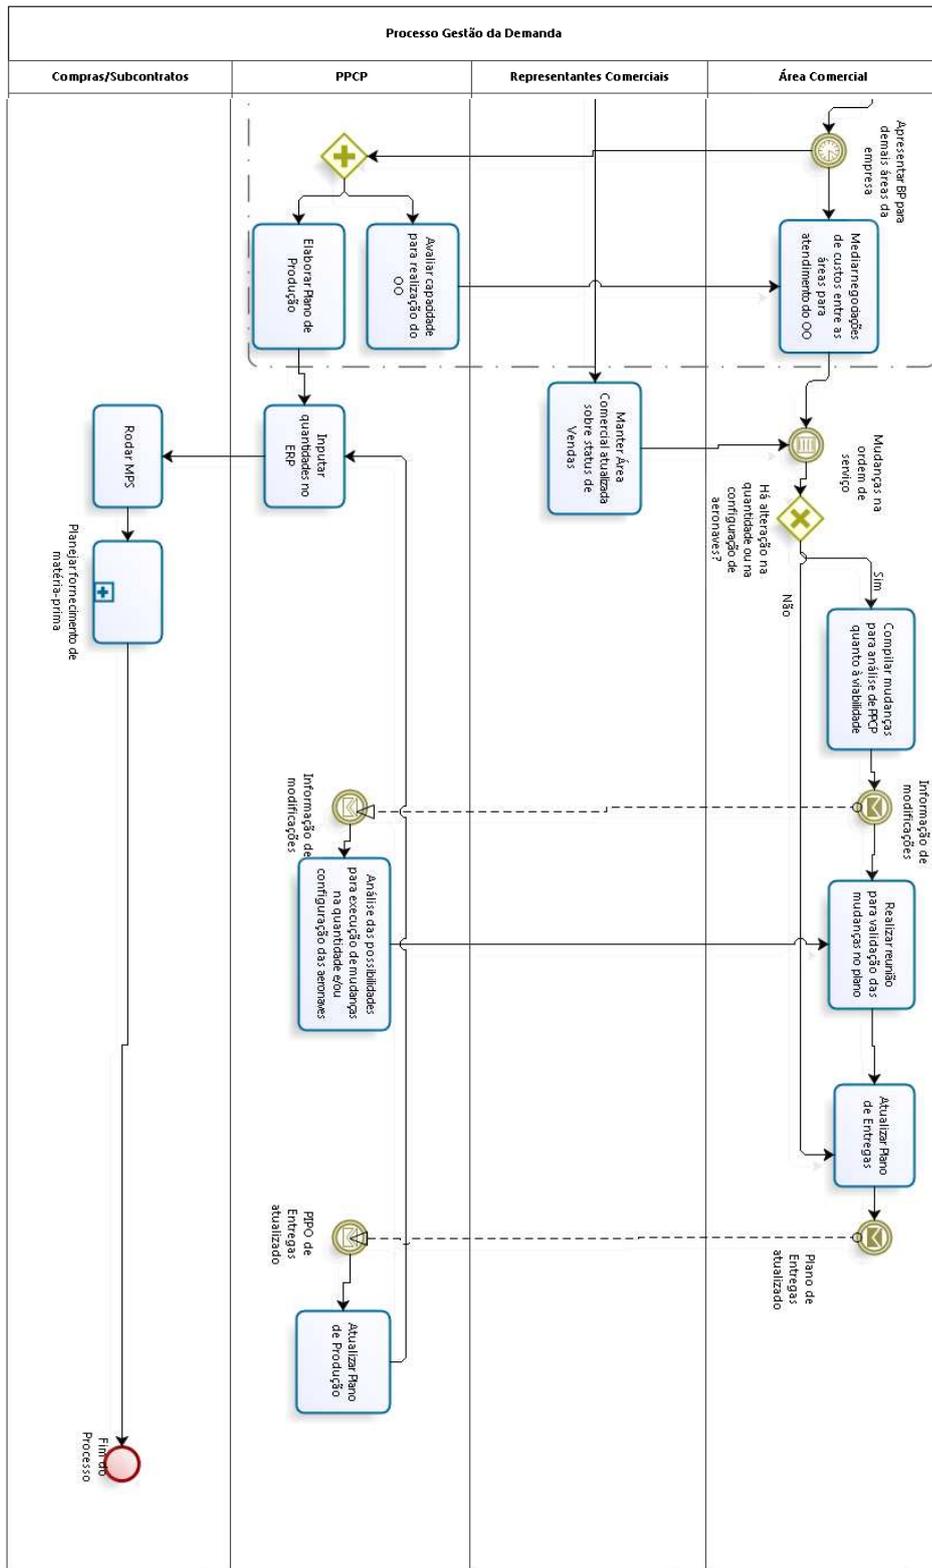


Figura 5.3 Processo de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 2

O processo de negócio praticado pela empresa de máquinas agrícolas para Gestão da Demanda inicia-se na Área Comercial, que solicita aos vendedores externos uma previsão de base qualitativa, conforme suas perspectivas. Após receber as expectativas dos representantes para o próximo ano de vendas, a área Comercial discute o cenário da empresa e realiza a PV de acordo com as necessidades da unidade de negócios e por meio das percepções de mercado de especialistas internos. Um modelo econométrico de regressão linear para previsão de vendas é executado nesta etapa.

Em seguida o Plano de Operações (PO) é formulado. Esse planejamento consiste no estabelecimento das entregas projetadas mês a mês. Esse plano é posteriormente utilizado para definir o Orçamento Operacional (OO), em que o plano orçamentário para o ano seguinte é realizado pela alta direção.

Periodicamente, os Representantes Comerciais enviam um relatório de vendas e visitas à Área Comercial. Essas informações são utilizadas para revisão do Plano, adicionando ou retirando máquinas sempre que necessário, após uma reunião de validação com a equipe de Planejamento e Controle de Produção.

b. Análise da série histórica

A procura pelas máquinas é sazonal e cíclica, como pode ser observado no gráfico do histórico de vendas apresentado na Figura 5.4. A linha de tendência também é evidenciada por meio da equação linear que a representa. Como indicado por MAKRIDAKIS e WHEELWRIGHT (1989), FERNANDES e GODINHO (2010) e CORRÊA *et al.* (2007), observar o padrão dos dados históricos disponível é determinante para encontrar a técnica adequada de previsão.

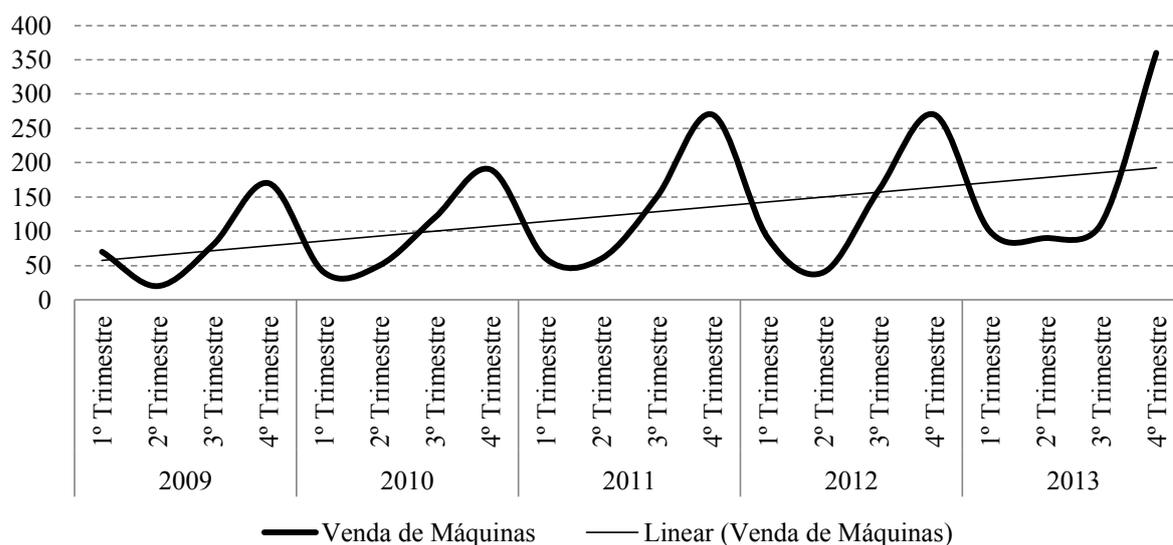


Figura 5.4 Histórico de vendas de máquinas agrícolas de 2009 a 2013

É possível observar na série histórica a presença do padrão de sazonalidade, havendo aumento das vendas no segundo semestre do ano, com pico no último trimestre. Especialistas da empresa afirmam que o comportamento sazonal ocorre devido a dois fatores principais: forte dependência dos compradores do financiamento bancário para compra das máquinas e expectativa de rendimento da safra anterior à compra, cujo resultado é obtido no início do segundo semestre. No início do ano o BNDES⁵ abre o credenciamento pelo FINAME e FINAME Agrícola⁶, destinados à aquisição de máquinas e equipamentos, implementos agrícolas e bens de informática e automação, novos, de fabricação nacional. A partir do início do segundo semestre, o crédito começa a ser liberado e as máquinas são entregues aos compradores.

Entende-se, portanto, que a série histórica de vendas do maquinário contempla os seguintes padrões em sua formação: sazonalidade (S), tendência (T) - representada no gráfico em conjunto com sua equação linear, ciclo (C) - presente em dados influenciados por variações econômicas de longo prazo, além da aleatoriedade (A). A análise dos componentes da série histórica foi realizada por meio da técnica de decomposição, apresentada na Tabela 5.1.

O cálculo dos valores correspondentes a cada padrão foi realizado conforme indicado na literatura (MAKRIDAKIS e WHEELWRIGHT, 1989; FERNANDES e GODINHO, 2010;

⁵ Banco Nacional de Desenvolvimento Econômico e Social

⁶ Agência Especial de Financiamento Industrial

CORRÊA *et al.*, 2007). Primeiramente, a Média Móvel de três períodos foi calculada a partir do quarto período conforme indicações de Makridakis & Wheelwright (1989). Segundo os autores, dessa forma, a sazonalidade e aleatoriedade serão anuladas da série, restando tendência e ciclo. Por meio da equação linear de tendência, os valores correspondentes a esse padrão foram encontrados. Sabendo-se que a Média Móvel consiste na multiplicação dos padrões de tendência e ciclo, basta fazer a relação entre Média Móvel e Tendência para se obter o valor correspondente do Ciclo.

Ano	Trimestre	Máquinas Vendas (TxCxSxA)	Média Móvel (TxC)	Tendência (T)	Ciclo (C)	Sazonalidade (S)	Aleatoriedade (A)
2009	1	70	-	57	-	-	-
	2	20	-	65	-	-	-
	3	80	-	72	-	-	-
	4	170	57	79	72	3,00	2
2010	1	40	90	86	105	0,44	1
	2	50	97	93	104	0,52	1
	3	120	87	100	87	1,38	1
	4	190	70	107	65	2,71	2
2011	1	60	120	114	105	0,50	1
	2	60	123	121	102	0,49	1
	3	150	103	129	80	1,45	1
	4	270	90	136	66	3,00	2
2012	1	90	160	143	112	0,56	1
	2	40	170	150	113	0,24	1
	3	160	133	157	85	1,20	1
	4	270	97	164	59	2,79	2
2013	1	100	157	171	91	0,64	1
	2	90	177	178	99	0,51	1
	3	110	153	185	83	0,72	1
	4	360	100	193	52	3,60	2

Tabela 5.1 Desagregação dos padrões da série histórica de vendas

O Índice de Sazonalidade é calculado com base no valor obtido de Médias Móveis. Sabendo-se que a Média Móvel é equivalente aos padrões de tendência e ciclo agrupados (MAKRIDAKIS e WHEELWRIGHT, 1989), a razão entre o valor da série histórica real

dividido pela média móvel irá retornar o valor equivalente aos padrões contidos na série real diferentes daqueles contidos na Média Móvel, ou seja, sazonalidade e aleatoriedade.

$$\text{Série histórica de vendas} = T \times C \times S \times A \quad (8)$$

$$\text{Média Móvel} = T \times C \quad (9)$$

$$\text{Padrão Sazonal} = \frac{\text{Série histórica de vendas}}{\text{Média Móvel}} = \frac{T \times C \times S \times A}{T \times C} = S \times A \quad (10)$$

Os padrões sazonais obtidos foram compilados na Tabela 5.2 a seguir. Nota-se que para o ano de 2013 houve uma diminuição da sazonalidade no terceiro trimestre, acarretando em um aumento do índice no quarto trimestre do mesmo ano. As vendas concentram-se no segundo semestre do ano, podendo portanto ocorrer em maior volume no terceiro e quarto trimestres.

	Trimestre			
	1º	2º	3º	4º
2009				3,000
2010	0,444	0,517	1,385	2,714
2011	0,500	0,486	1,452	3,000
2012	0,563	0,235	1,200	2,793
2013	0,638	0,509	0,717	3,600

Tabela 5.2 Padrão de sazonalidade da série histórica por trimestre

Essa relação entre o histórico de vendas e a média móvel de cada período permite que se faça as seguintes inferências sobre o padrão sazonal: (a) trimestres com valores acima de 1 apresentam vendas acima da média do ano, enquanto aqueles com valores abaixo de 1 exibiram vendas abaixo da média do ano; (b) a soma dos índices obtidos nos trimestres do ano deve ser, portanto, equivalente a 4; (c) a média dos valores obtidos para cada trimestre resulta em um índice médio para cada "estação", compilados na Tabela 5.3 a seguir (MAKRIDAKIS e WHEELWRIGHT, 1989).

Trimestre					
	1°	2°	3°	4°	Total
S	0,536	0,437	1,188	3,021	5,183
				Ajuste	0,772
S (ajustado)	0,414	0,337	0,917	2,332	4

Tabela 5.3 Índice de Sazonalidade médio

Os índices médios obtidos para cada trimestre podem ser ajustados para que a soma de seus valores seja equivalente a 4. Para tanto, deve-se primeiramente calcular o índice de ajuste dividindo-se 4 pelo valor total, no caso 5,301. Em seguida o valor do índice de sazonalidade de cada trimestre é multiplicado pelo índice de ajuste. Assim, obtém-se os índices de sazonalidade ajustados, cuja a soma é equivalente a 4. A representação gráfica do comportamento sazonal ao longo de um ano é dado pela Figura 5.3. Nota-se que tendência sazonal das vendas sofre uma queda abrupta do último trimestre de um ano para o primeiro do próximo, ocasionado pelas vendas programadas para o último semestre do ano devido a liberação de crédito ao comprador a partir do meio do ano e ao fechamento das metas ao final.

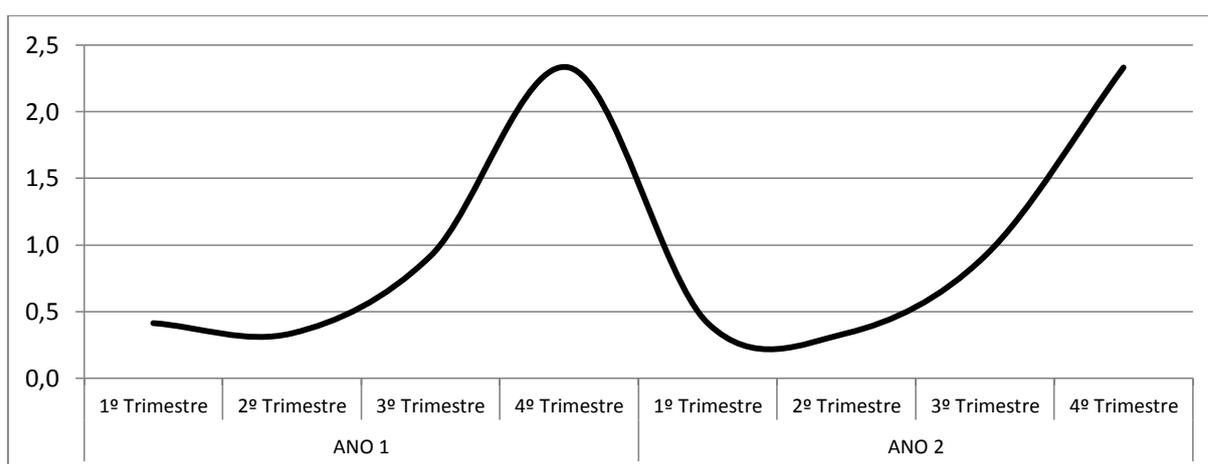


Figura 5.5 Comportamento sazonal anual da venda de máquinas agrícolas

Tendo analisado em detalhes a série histórica dos dados de vendas, os modelos testados para previsão de vendas são apresentados a seguir. O modelo *status quo* de Regressão Múltipla, utilizado pela empresa, é primeiramente apresentado. Em seguida são descritos os novos modelos, de suavização exponencial, redes neurais artificiais e um novo modelo de regressão múltipla, utilizando as mesmas variáveis do modelo de RNA.

c. PV baseado em Regressão Múltipla – Modelo *Status Quo*

As análises de mercado e previsão de vendas anuais de máquinas agrícolas no modelo de negócios da empresa vem sendo realizadas por meio de um modelo estatístico econométrico. A técnica utilizada de Regressão Múltipla segue a Equação 6 (página 28), apresentada anteriormente, a qual prevê valores de uma ou mais variáveis de resposta (ditas dependentes) através de um conjunto de variáveis explicativas (variáveis independentes).

A empresa realizou simulações da regressão até que obtivesse um modelo considerado estatisticamente válido, estabelecendo quatro variáveis independentes que impactam diretamente na venda das máquinas. As variáveis determinadas são apresentadas a seguir.

x_1 = média do preço pago ao produtor brasileiro para quatro culturas (algodão, arroz, milho e soja), dado em reais;

x_2 = série histórica da parcela do PIB relacionada ao setor agropecuário brasileiro;

x_3 = produção agrícola total brasileira das culturas anteriormente citadas, também como uma série histórica, em milhares de toneladas.

x_4 = produção agrícola total observada no ano anterior ao de referência.

Os coeficientes atrelados às variáveis independentes foram determinados a partir de uma equação da regressão realizada pelo MS Excel. Para definição desses coeficientes, foi adotada a série histórica desde 1990 dos números de vendas de máquinas, PIB agropecuário, preço das culturas e produção agrícola. Como as unidades adotadas para as variáveis independentes possuem escalas diferentes (enquanto para produção agrícola a variação ocorre em escala de milhões, para o preço pago ao produtor a variação se dá em uma escala de dezenas) foi necessário padronizá-las através do cálculo de suas variações percentuais ao longo do tempo. A seguinte equação foi então empregada:

$$\Delta A = f(\Delta x_1, \Delta x_2, \Delta x_3, \Delta x_4) \quad (11)$$

Em que:

ΔA = variação percentual de vendas

Δx_1 = variação percentual da média de preço para as quatro culturas selecionadas

Δx_2 = variação percentual da parcela do PIB relacionada ao setor agropecuário brasileiro

Δx_3 = variação percentual da produção agrícola total brasileira das culturas selecionadas

Δx_4 = variação percentual da produção agrícola total observada no ano anterior

A variação percentual do número de máquinas vendidas (ΔA) é função da variação percentual do preço pago ao produtor (Δx_1), do PIB Agropecuário (Δx_2), da produção agropecuária do ano atual (Δx_3) e da produção agropecuária do ano anterior (Δx_4). Conforme o cálculo dos coeficientes realizado pelo software, a equação da regressão para o modelo proposto é como segue:

$$f(x) = -0,68 + 2,26(\Delta x_1) + 2,48(\Delta x_2) - 2,52(\Delta x_3) + 1,07(\Delta x_4) \quad (12)$$

Nos modelos causais, a previsão é expressa como função de um conjunto de variáveis ou fatores, os quais influenciam os resultados. O desenvolvimento de modelos causais de previsão permite compreender melhor o cenário em que a previsão está inserida, permitindo que combinações de entradas sejam experimentadas e seus efeitos nos resultados estudados.

A aderência do modelo de regressão é realizada pela avaliação do coeficiente de correlação, r , uma medida relativa do grau de identificação que existe entre duas variáveis. Esse coeficiente pode variar de 0 (indicando que não há correlação) a +/-1 (indicando correlação perfeita direta ou indiretamente). Quando o coeficiente de correlação é maior que 0, significa que as variáveis são correlacionadas positivamente, ao passo que o coeficiente de correlação menor que 0 representa uma correlação negativa. Outra medida estatística amplamente utilizada neste campo de estudo é o r^2 , o qual representa a porcentagem da variação total que pode ser explicada pela linha de regressão. Essa medida estatística varia entre 0 e 1, em que 0 significa que não há correlação e 1 que há correlação perfeita.

As estatísticas da equação de regressão do modelo de previsão de vendas de máquinas agrícolas são apresentadas na Tabela 5.4. Como pode ser observado, o r^2 é igual a 0,61 o que corresponde a um baixo índice de correlação, não sendo capaz de explicar satisfatoriamente as mudanças na série histórica de vendas (variável dependente) com as variáveis independentes utilizadas no modelo.

R	0,781
R²	0,610
R² (ajustado)	0,524
Erro padrão	0,339
Observações	23

Tabela 5.4 Estatísticas da Previsão por Regressão Múltipla

O processo de previsão de vendas na empresa estudada leva em consideração o modelo econométrico de regressão múltipla descrito em conjunto com as projeções dos representantes de vendas. Nos anos em que o modelo foi utilizado, a performance da previsão atingiu erro médio percentual de 15% entre 2009 e 2013. Em 2011 o erro foi ainda maior, equivalente a 33%, demonstrando a baixa aderência do modelo.

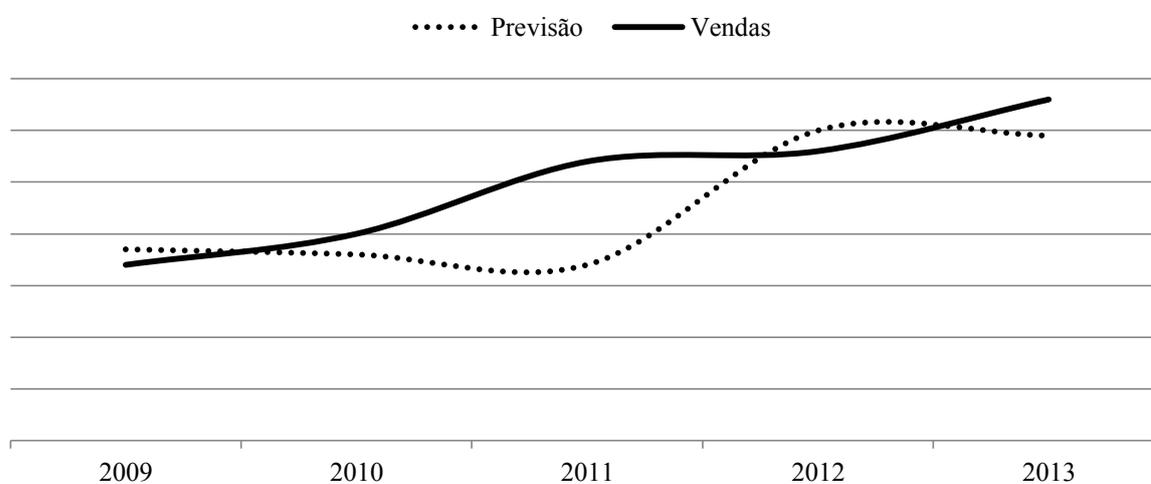


Figura 5.6 Acurácia Previsão de Vendas por Regressão Múltipla de 2009 a 2013

d. Novos Modelos

Os modelos de regressão múltipla são capazes de gerar benefícios em acurácia na previsão, no entanto existem algumas dificuldades relatadas em sua utilização. Um dos fatores críticos refere-se à geração dos dados para as variáveis independentes no período de previsão, as quais também devem ser previstas por conta do atraso de alguns meses na divulgação de certos dados econômicos. Ademais, método econométricos como a regressão demandam certo tempo e recursos específicos, e requerem constante coleta de dados. A interrelação entre vendas e as variáveis econômicas geralmente mudam através do tempo, complicando o processo de construção do modelo e exigindo que novos modelos sejam desenvolvidos

(GEURTS e KELLY, 1986). Dessa forma, outro tipo de modelo linear de previsão, Suavização Exponencial, foi colocado em teste neste estudo, a título de comparação.

Além do método de suavização também foram testadas onze arquiteturas de Redes Neurais Artificiais a fim de encontrar a combinação de parâmetros que retornasse previsões mais precisas. Adicionalmente, um modelo de Regressão Múltipla utilizando as mesmas variáveis da RNA também foi testado. Vale ressaltar que um método não será necessariamente o melhor para todas as previsões realizadas no decorrer da vida do produto. Isso significa que os modelos de previsão requerem avaliação e revisão periodicamente. Os novos modelos apresentados a seguir são opções de utilização ao tomador de decisão, que deve ponderar as vantagens e desvantagens em utilizar um ou outro método.

d1. Suavização Exponencial

O método de suavização exponencial é amplamente utilizado na previsão de séries temporais. Tal relevância foi conquistada por essa técnica devido a agilidade em associar e gerar dados, resultando, de modo geral, em resultados com acurácia satisfatória (POLONI e SBRANA, 2015). O método não requer nada além da série histórica de vendas, simplificando o processo de modelagem. Neste estudo foi utilizada a Suavização Exponencial com Tendência, por meio dos dois parâmetros apresentados na Seção 2, α (constante de suavização) e β (constante de suavização e tendência).

O método utiliza dados de vendas passadas suavizados, ou seja, são atribuídos pesos a dados mais antigos, reduzindo o fator de suavização conforme os dados se tornam mais velhos. O método foi empregado para prever as vendas anuais de máquinas agrícolas para 13 anos, 2000 a 2013. Os resultados são apresentados na Tabela 5.5 a seguir. O método apresentou boa performance, com erro médio percentual menor que 20% para seis anos e chegando a 0% em 2007. No entanto, a técnica de suavização não prevê mudanças imediatas da série histórica, tendo obtido um desvio de 302% em 2006.

		Suavização Simples		Suavização Exponencial com Tendência			
Ano	Vendas	$\alpha = 0,5$	MAPE	$\alpha = 0,5$ $\beta = 0,1$	MAPE	$\alpha = 0,5$ $\beta = 0,5$	MAPE
2000	140	148	6%	174	24%	136	3%
2001	160	144	10%	167	5%	136	15%
2002	220	152	31%	174	21%	152	31%
2003	470	186	60%	209	56%	203	57%
2004	640	328	49%	363	43%	408	36%
2005	350	484	38%	531	52%	602	72%
2006	110	417	279%	453	311%	442	302%
2007	200	263	32%	280	40%	199	0%
2008	290	232	20%	244	16%	184	37%
2009	280	261	7%	274	2%	251	10%
2010	400	270	32%	284	29%	271	32%
2011	550	335	39%	354	36%	368	33%
2012	570	443	22%	470	18%	513	10%
2013	660	506	23%	537	19%	573	13%

Tabela 5.5 Acurácia da Previsão de Vendas por Suavização Exponencial

É possível notar que a Suavização representa a série histórica com certo atraso, não sendo possível prever mudanças repentinas. Além disso, por tratar-se de um baixo volume de vendas anuais, pequenas variações representam proporcionalmente grandes erros. Trantando-se de um produto de alto valor agregado, os desvios podem representar alto valor em recursos empregados na produção. Para os anos de 2012 e 2013, no entanto, o erro médio percentual foi de 12%.

d2. Rede Neural Artificial

Nos modelos de séries temporais o comportamento passado de um processo é modelado com o objetivo de realizar inferências sobre o comportamento futuro. Tais modelos são especialmente úteis quando há pouco conhecimento do processo subjacente de geração de dados. Foram selecionados os seguintes métodos tradicionais: Suavização Exponencial com Tendência e Regressão Múltipla, ambos extensivamente investigados na literatura e capazes de gerar previsões com performance satisfatória em grande parte dos casos.

Modelos estruturais, como o de Regressão Múltipla e o de RNA, buscam descrever as relações causais entre a variável de saída e as variáveis de entrada. A Regressão permite ao tomador de decisão explorar como as mudanças nas variáveis de entrada impactam a de saída.

A RNA, similarmente, representa uma tecnologia de suporte à decisão que permite diferenciar os padrões contidos em dados não lineares e projetar a performance futura de uma certa variável de interesse.

De modo geral, as redes são compostas por elementos simples, chamados de neurônios ou nós. Os sinais passam por esses neurônios por meio de links de conexão. Cada link possui um peso associado, que em uma rede típica multiplica o sinal transmitido. Isso significa que cada entrada é multiplicada por um peso.

A soma dos produtos das entradas com os pesos é chamada de potencial de ativação do neurônio. O objetivo de uma rede cujo aprendizado é supervisionado (ou seja, em que o valor alvo é conhecido) é atingir o valor do potencial de ativação. Se a soma resultar em um valor positivo, a saída gerada será igual a 1, caso contrário a saída será -1. A Figura 5.7 a seguir exemplifica esse raciocínio.

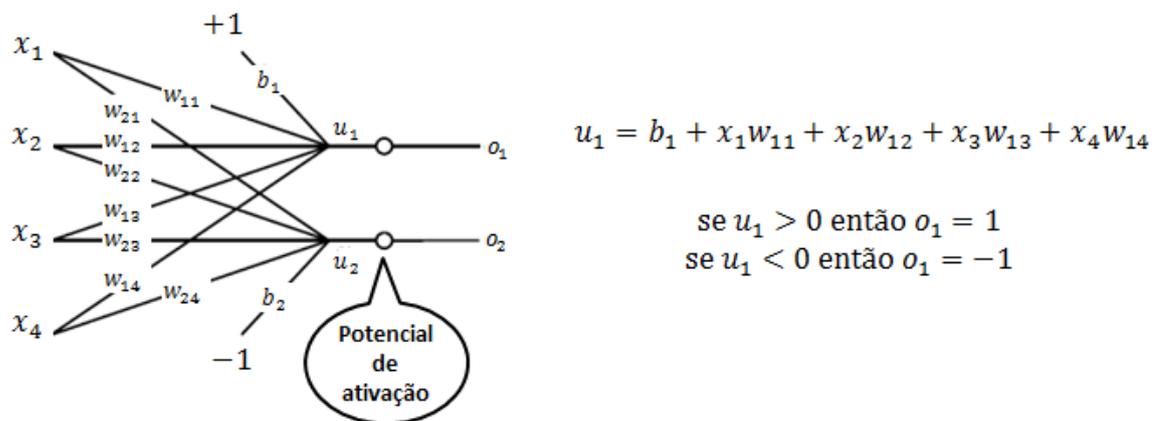


Figura 5.7 Potencial de ativação de uma Rede Neural Artificial

Tendo em vista que a equação acima apresenta quebra na origem e derivadas iguais a 0 em vários pontos, a função de ativação é trocada por uma função contínua. A tangente hiperbólica é a função mais comumente utilizada. Portanto, a saída o_1 é igual a tangente hiperbólica de u_1 , e a saída o_2 é igual a tangente hiperbólica de u_2 .

Dessa forma a RNA opera por meio da minimização do erro entre o resultado obtido e o alvo. Para minimizar o erro utiliza-se então uma função objetivo. Para cada conjunto de dados de entrada, no caso para cada ano observado, haverá um erro. A função objetivo tem o papel de minimizar o erro médio dos dados de entrada conforme o valor alvo estipulado (ou

observado) para cada conjunto. Ou seja, deve haver um conjunto de pesos cujo erro médio é mínimo.

Para encontrar esse conjunto de pesos, utiliza-se o cálculo das derivadas parciais da função objetivo em relação a matriz de entrada, primeiramente com valores aleatórios de pesos. Os números resultantes indicam a direção em que a função objetivo aumenta no espaço euclidiano. Como o objetivo é minimizar o erro, utiliza-se o valor oposto, dando um passo na direção contrária do gradiente. Por meio do método iterativo, a cada rodada a função objetivo será mais baixa e o valor obtido mais próximo do alvo.

O tipo mais amplamente utilizado de RNA em problemas de previsão é o *perceptron* de múltiplas camadas (na sigla em inglês, MLP⁷) (ZHANG *et al.*, 1998). Na modelagem de uma RNA há uma série de questões importantes que devem ser analisadas com cautela. Uma das decisões críticas nesse processo é a arquitetura da rede, ou seja, o número de camadas, o número de neurônios em cada camada e o número de arcos que conectam os neurônios. Além disso, é necessário atentar-se para as funções de ativação selecionadas, tanto para os neurônios intermediários, como para os neurônios de saída. Outras importantes decisões são: a escolha do algoritmo de treinamento, a transformação dos dados e os métodos de normalização, os conjuntos de treinamento e teste, além das medições de performance (ZHANG *et al.*, 1998; HAMZAÇEBI, 2008). Tais elementos serão discutidos a seguir para o caso sendo estudado.

Seleção das variáveis

O número de neurônios de entrada da rede é determinante para a eficiência no reconhecimento de padrões e relações entre as observações (HAMZAÇEBI, 2008). Sete fatores foram utilizados neste estudo como variáveis de entrada da rede, além dos valores da série histórica de vendas dos três anos anteriores ao de referência para que observações mais recentes tivessem maior influência sobre a previsão. A seleção foi realizada por meio de análises de correlação, tendo sido escolhidas apenas variáveis que apresentassem correlação igual ou superior a 80%.

As variáveis que apresentaram maior correlação com as vendas de máquinas agrícolas, como adiantado no Capítulo 1, são indicadores econômicos do agronegócio brasileiro. Os valores da produtividade e produção agrícolas foram obtidos por meio da base da CONAB

⁷ *Multi Layer Perceptron*

(Companhia Nacional de Abastecimento). Similarmente o PIB do agronegócio foi auferido da base do CEPEA (Centro de Estudos Avançados em Economia Aplicada), assim como a média anual do preço da soja, dado em Reais por saca. Curiosamente, a área de colheita do território nacional, disponibilizada pelo Departamento de Agricultura dos Estados Unidos (USDA), apresentou correlação significativamente maior que o indicador de Área Plantada publicado pela CONAB.

Outra variável acrescentada ao modelo foi o Índice Commodities (IC-Br), calculado pelo Banco Central. Segundo a BMF&Bovespa (2015), o indicador é ponderado com base na participação das commodities integrantes (café arábica, etanol, boi gordo, milho e soja) no total das *commodities* negociadas na bolsa. Por fim, a margem do produtor foi calculada com base nas informações fornecidas pelo Instituto Matogrossense de Economia Agropecuária de custo e volume de produção, agregando o preço da soja para cálculo da receita. Os indicadores para o cálculo empregado na obtenção dessa última variável foram utilizados conforme Figura 5.8 a seguir.

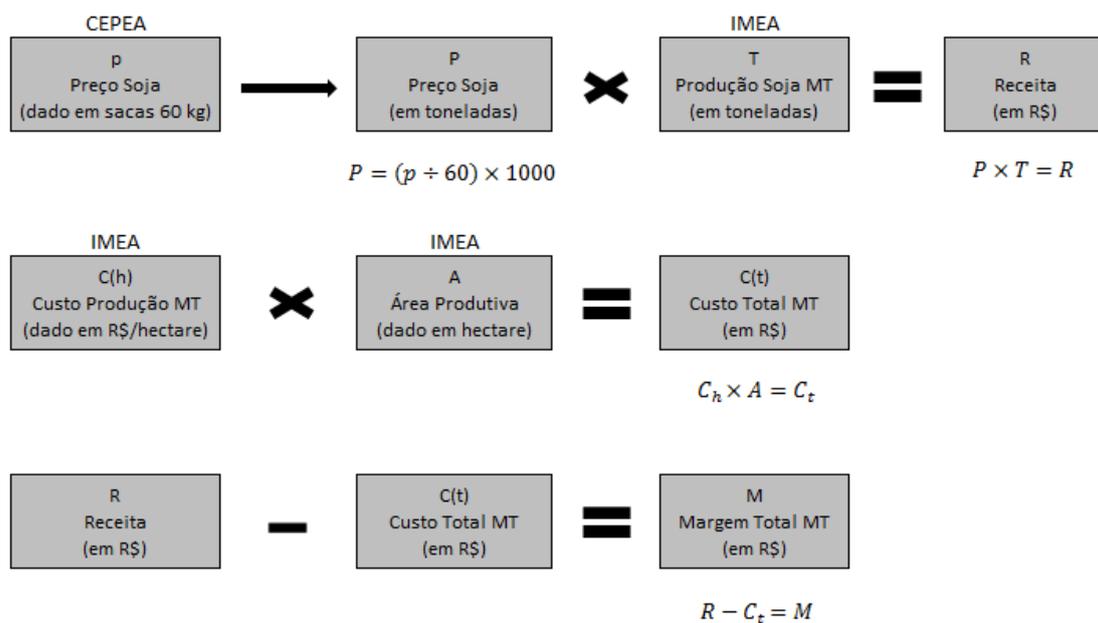


Figura 5.8 Cálculo da Margem do Produtor de Soja no MT

Além dessas variáveis, a correlação da série histórica de vendas com diversos outros indicadores e medições relacionados ao agronegócio e à economia nacional e internacional foi testada. Dentre fatores testados estão inclusos dados de produtividade agrícola internacional

do Departamento de Agricultura dos Estados Unidos (USDA⁸); séries históricas de preço de outras culturas com forte participação no agronegócio (milho, arroz, algodão, entre outros) e índices de exportação compilados pelo CEPEA; série histórica de área plantada nacional fornecida pela CONAB, indicadores financeiros do Banco Central, inclusive taxa de câmbio. Nenhum desses fatores apresentou correlação satisfatória, ou seja, com índice de correlação maior ou igual a 80%.

Devido a dependência do financiamento bancário para muitos dos compradores de máquinas agrícolas de alto valor agregado, foi testada a correlação também com desembolsos do BNDES para a linha de crédito Finame e Finame Agrícola, geralmente utilizados na compra dos equipamentos. No entanto não houve sucesso na obtenção de índices de correlação satisfatórios. Além desses fatores, também foi realizado o teste de correlação para índices de confiança do agronegócio da FIESP, porém essa última contava com uma série reduzida de medições.

⁸ *United States Department of Agriculture*

Descrição	Fonte	Escala	R²	F Sig
Produtividade Agrícola	CONAB	Kg/ha	0,8050	0,0010
Produção Agrícola*	CONAB	mil ton	0,8801	0,0006
PIB Agronegócio	CEPEA	R\$ milhões	0,8663	0,0008
Preço da Soja**	CEPEA	R\$/saca	0,8740	0,0007
Índice Commodities IC-Br**	BCB	-	0,8557	0,0010
Margem do Produtor (Soja)***	IMEA	R\$	0,8074	0,0009
Área de Colheita	USDA	mil ha	0,9149	0,0028

OBS.: Além das variáveis selecionadas, foram utilizados os valores da série histórica para três períodos anteriores, a fim de capacitar a rede no reconhecimento padrões recentes.

* Vendas são influenciadas pela Safra do ano anterior

** Vendas são influenciadas pela expectativa de preço do produtor para o ano seguinte

*** Vendas são influenciadas pela expectativa de rendimento do produtor para a Safra seguinte

Tabela 5.6 Neurônios de entrada da RNA – Variáveis independentes correlacionadas às Vendas anuais

Uma das medidas para se levar em consideração é o teste o qual indica o nível geral de significância na equação de regressão, ou F de Significância. Essa medida representa a relação entre a variância explicada e a não explicada. O ideal é que o valor seja abaixo de 0,05, o que representa 95% de confiança nos resultados (MAKRIDAKIS & WHEELWRIGHT, 1989). No caso das variáveis da tabela acima, os valores de F Sig estão adequados e satisfazem a condição de correlação.

Apesar da extensão da série histórica para os modelos anteriores terem considerado um horizonte maior para previsão, neste caso foi necessário reduzir a abrangência devido a série histórica disponível das variáveis independentes correlacionadas. Dessa forma, a previsão por RNA e a Regressão Múltipla correspondente contém oito pontos de dados (anos), de 2006 a 2013. Chu e Zhang (2003) afirmaram em seus estudos que amostras grandes da série de dados não são necessariamente úteis na performance das previsões de modo geral.

Estabelecimento dos parâmetros

É a camada intermediária e seus neurônios que capacitam a rede neural a reconhecer as características e padrões dos dados, permitindo que o mapeamento não-linear entre as variáveis seja executado. Estudos científicos anteriores sugerem que uma única camada intermediária é suficiente para a rede neural efetuar a aproximação em qualquer função não-linear complexa, sendo suficiente para a maioria dos problemas de previsão (ZHANG *et al.*, 1998; HAMZAÇEBI, 2008).

Determinar a quantidade ótima de neurônios intermediários é uma decisão essencial ao efetuar a modelagem de uma rede. RNAs com um número menor de nós intermediários normalmente possuem melhor habilidade de generalização e menor possibilidade de causar *overfitting*⁹. No entanto, se o número de neurônios intermediários for pequeno demais, a rede pode ser incapaz de modelar e aprender com os dados. Assim, o modo mais comum de determinar a quantidade de nós intermediários é por meio de experimentos, ou pela tentativa e erro. Há uma indicação na literatura para que o número de neurônios intermediários seja igual ao número de neurônios de entrada (DE GROOT e WURTZ, 1991; CHAKRABORTY *et al.*, 1992; SHARDA e PATIL, 1992; TANG e FISHWICK, 1993). Partindo-se deste princípio, foram testados de 7 a 14 neurônios na camada intermediária neste estudo.

Antes que uma rede neural possa ser utilizada para uma determinada tarefa, ela precisa ser treinada. Isso significa que é necessário determinar os pesos de arcos, elemento essencial para o desempenho da RNA. O conhecimento gerado pelo processo de treinamento é armazenado nos arcos e nos neurônios na forma de pesos de arcos e neurônios de vieses. É por meio das conexões entre os arcos que a rede irá transportar os complexos mapeamentos não-lineares dos neurônios de entrada para os de saída. O treinamento de um MLP é dito supervisionado quando a resposta esperada para cada padrão de entrada é conhecida.

Os dados de entrada do treinamento são dados em forma de vetores, compostos pelas variáveis de entrada, ou “padrões de treinamento”. Cada elemento deste vetor conta com um neurônio de entrada correspondente na primeira camada, ou seja, o número de nós de entrada é equivalente à dimensão do vetor inicial. Os dados disponíveis são divididos em conjunto de treinamento (*in-sample data*) e conjunto de teste (*out-of-sample data*). O conjunto de

⁹ *Overfitting* ocorre quando um modelo estatístico representa um erro ou ruído quando deveria apresentar uma relação entre os dados. Ocorre quando o modelo é complexo demais, como quando contempla um número muito grande de parâmetros. Um modelo com *overfitting* tem capacidade limitada de predição e reage exageradamente pequenas flutuações nos dados.

treinamento é utilizado para estimar os pesos, enquanto o conjunto de teste deve avaliar a capacidade de generalização da rede.

O treinamento da rede é a fase determinante para o estabelecimento dos pesos em cada arco. A dinâmica de treinamento da RNA neste estudo ocorreu em ciclos. Isto é, a rede neural passa por uma simulação em modo sequencial, uma vez que trata-se de dados históricos, no entanto os pesos são atualizados em cargas. Desse modo os pesos testados no treinamento são atualizados apenas uma vez em cada “*epoch*”, ou seja, em cada iteração (BEALE *et al.*, p. 1-33, 2015).

A taxa de treinamento é um valor atribuído à rede com função de dar um objetivo ao treinamento, a qual nada mais é do que o erro quadrático médio. Ou seja, é determinado pela diferença entre os valores dos vetores de saída da rede treinada e os vetores alvos, fornecidos no aprendizado supervisionado da rede. A taxa de treinamento da rede foi testada para os valores 0,05 e 0,01. Quando se usa um gradiente de descida mais íngreme para estabelecimento dos pesos, tipicamente utiliza-se taxas de aprendizado menores no modo de treinamento em ciclo. Isso porque todos os gradientes individuais são somados antes de determinar a mudança de pesos (BEALE *et al.*, p. 1-33, 2015).

Assim, um conjunto de treinamento é primeiramente incluído nos neurônios de entrada e valores de ativação para esses nós são estabelecidos em pesos e acumulados em cada neurônio da camada intermediária. O total é transformado por meio de uma função de ativação no valor de ativação do neurônio, considerada nesse estudo como sendo a função logística apresentada logo abaixo. Assim, torna-se um valor de entrada para os neurônios da próxima camada, até que eventualmente os valores de ativação das saídas sejam atingidos. O algoritmo de treinamento é utilizado para encontrar os pesos que minimizem o erro entre a saída e o valor-alvo. O treinamento é, portanto, um problema de minimização não-linear sem restrições.

A magnitude do gradiente e o número de validações são critérios utilizados para encerrar o treinamento. O gradiente se torna menor conforme o treinamento atinge melhor performance. Se a magnitude do gradiente tornar-se menor que 0,00001. O número de validações, por sua vez, representa o número de iterações sucessivas em que a validação falhou em melhorar a performance. Se esse número chegar a 6, o treinamento é encerrado (BEALE *et al.*, p. 2-20, 2015). A função de ativação ou de transferência é o que

determina a relação entre as entradas e as saídas de um neurônio e da rede. De modo geral, a função de ativação introduz certo grau de não-linearidade, essencial para a maioria das aplicações em RNAs. Para a rede de tipo *feedforward* utilizada neste estudo a função de processamento tanto para os inputs como para os outputs normalizam os valores-alvo para que estejam compreendidos entre -1 e 1. Ademais, a função remove quaisquer inputs ou valores-alvo que sejam constantes (BEALE *et al.*, p. 2-11, 2015).

Não se sabe ao certo qual das funções gera melhores resultados para a rede neural. Enquanto a maioria dos pesquisadores utilizam funções logísticas para os nós intermediários, não há consenso sobre qual função utilizar para os nós de saída. Para problemas de previsão que envolvem valores contínuos de alvo, é indicado utilizar a função linear como ativação para os neurônios de saída, dada abaixo (RUMELHART *et al.*, 1995).

O treinamento de uma rede neural consiste na modificação iterativa dos pesos representados nos arcos, a fim de minimizar o erro médio total entre o valor de saída desejado e o resultante da rede, para todos os nós de saída sobre todos os padrões de entrada. Algoritmos de otimização contam com o problema de ótimo local e é necessário utilizar métodos que retornem o melhor ótimo local, caso a solução global não estiver disponível.

O método mais utilizado para o treinamento de redes é o algoritmo de *backpropagation*. Basicamente, é um método de gradiente de descida mais íngreme. A taxa de aprendizado deste algoritmo é essencial para determinar a magnitude das mudanças de pesos durante o treinamento. Uma maneira de aprimorar este método é incluindo um parâmetro adicional de *momentum* a fim de permitir que taxas de aprendizado maiores resultem em convergências mais rápidas, enquanto minimiza-se a tendência de oscilação. A ideia de adicionar o termo *momentum* é fazer com que a próxima mudança de peso seja mais ou menos na mesma direção que a anterior, e então reduzir a efeito de oscilação de maiores taxas de aprendizado.

A técnica padrão de *backpropagation* com *momentum* é utilizada pela maioria dos pesquisadores (ZHANG *et al.*, 1998). Os melhores valores costumam ser escolhidos por meio da experimentação. Uma vez que a taxa de aprendizado e o *momentum* podem assumir valores entre 0 e 1, é inviável efetuar uma busca exaustiva para encontrar o melhor valor. Assim, alguns valores pré-selecionados costumam ser considerados.

Uma amostra de treinamento é utilizada em uma rede neural para desenvolvimento do modelo e a amostra de teste é adotada para avaliar a habilidade de previsão do modelo. É comum adotar uma terceira amostra, chamada de validação, a fim de evitar o problema de *overfitting* ou para determinar o ponto de interrupção do processo de treinamento (BASHEER & HAJMEER, 2000).

A divisão dos dados entre conjunto de treinamento e de teste não conta com uma única possibilidade, sendo que uma série de fatores devem ser avaliados antes de estabelecer as amostras (características do problema, tipo de dados, tamanho do conjunto de dados disponível). A maioria dos autores selecionam a proporção de 90% para treinamento e 10% para teste, ou 80%-20%, ou ainda 70%-30%. O conjunto de treinamento, teste e validação foi definido neste estudo como sendo 70% treinamento, 15% teste e 15% validação.

d.3 Regressão Múltipla

A título de comparação, as mesmas variáveis utilizadas na Rede Neural Artificial foram utilizadas em um modelo de Regressão Múltipla. O cálculo da equação da regressão foi realizada pelo MS-Excel, o qual emprega o método de mínimos quadrados nos cálculos. O mesmo software foi utilizado para o modelo Status Quo de regressão.

A equação da regressão deu-se como segue:

$$\Delta B = f(\Delta x_1, \Delta x_2, \Delta x_3, \Delta x_4, \Delta x_5, \Delta x_6, \Delta x_7) \quad (13)$$

$$f(x) = -2939,5 - 0,03(\Delta x_1) + 0,003(\Delta x_2) - 0,0009(\Delta x_3) + 0(\Delta x_4) + 0(\Delta x_5) + 0,000004(\Delta x_6) + 0,023(\Delta x_7) \quad (14)$$

Em que:

ΔB = vendas anuais de máquinas agrícolas

Δx_1 = produtividade agrícola anual

Δx_2 = produção agrícola anual

Δx_3 = PIBAgro anual

Δx_4 = média do preço da saca de soja no ano

Δx_5 = índice commodities anual

Δx_6 = margem do produtor de soja MT anual

Δx_7 = área de colheita anual nacional

A Tabela 5.7 apresenta as nomenclaturas utilizadas para cada modelo de previsão testado. A título de comparação, realizou-se também a previsão de vendas das máquinas agrícolas por Suavização Exponencial.

Sigla	Método e Parâmetros da Previsão
NN A07	Rede Neural: 7 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A08	Rede Neural: 8 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A09	Rede Neural: 9 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A10	Rede Neural: 10 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A11	Rede Neural: 11 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A12	Rede Neural: 12 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A13	Rede Neural: 13 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN A14	Rede Neural: 14 neurônios intermediários; 10 iterações; taxa de treinamento 0,01
NN B07	Rede Neural: 7 neurônios intermediários; 7 iterações; taxa de treinamento 0,01
NN C05 - 7HN	Rede Neural: 7 neurônios intermediários; 7 iterações; taxa de treinamento 0,05
NN C05 - 10HN	Rede Neural: 10 neurônios intermediários; 7 iterações; taxa de treinamento 0,05
REGR A	Regressão Múltipla: $\Delta A = f(\Delta x_1, \Delta x_2, \Delta x_3, \Delta x_4)$
SMOT	Suavização Exponencial: $\alpha = 0,5$ e $\beta = 0,5$
REGR B	Regressão Múltipla: $\Delta B = f(\Delta x_1, \Delta x_2, \Delta x_3, \Delta x_4, \Delta x_5, \Delta x_6, \Delta x_7)$

Tabela 5.7 Modelos de previsão de vendas testados para máquinas agrícolas

e. O processo de Gestão da Demanda e Previsão de Vendas proposto

A fim de desenhar um processo de Gestão da Demanda aderente às práticas da empresa, métodos distintos de Previsão de Vendas foram testados para verificar qual deles melhor incorpora as características de mercado estudadas. Dois métodos lineares tradicionais foram comparados com a técnica não-linear de Redes Neurais Artificiais, sendo que essa última foi examinada para 11 arquiteturas diferentes.

As arquiteturas consideraram basicamente três aspectos da configuração da rede. Primeiramente, a quantidade de neurônios intermediários foi testada para os valores entre 7 e 14 neurônios. A escolha se deu devido a indicação da literatura (CHU e ZHANG, 2003), de valores próximos a quantidade de neurônios de entrada. A quantidade de iterações de pesos a fim de encontrar o mínimo quadrado foi testada seguidamente, para 10 e 7 iterações. Por fim, a taxa de treinamento foi testada para as quantidades de neurônios que obtiveram melhores resultados, para 0,05 e 0,01.

Apesar das medidas das acurácias estarem presentes nas fases de modelagem e treinamento da RNA, a medida mais importante para estabelecer a performance da previsão é aplicada após o treinamento dos dados. No entanto, não há uma medida universalmente aceita pelos analistas de previsão, seja na Academia ou no mercado. Uma medida da acurácia é comumente definida nos termos do erro da previsão, ou seja, a diferença entre o valor real e o valor previsto. Quatro modos de mensurar a performance dos modelos de previsão foram utilizadas neste estudo, conforme Tabela 5.8

Observou-se que, de acordo com os métodos de medida de acurácia adotados, as melhores configurações da rede neural são aquelas com menor número de neurônios na camada intermediária, de 7 a 10 nós. Ademais, conforme resultados apresentados, a configuração com 10 iterações e taxa de treinamento equivalente a 0,01 é tida neste caso como melhor configuração. Zhang, Patuwo e Hu (1997) no artigo de revisão da literatura de RNAs, apontam que uma série de autores suspeitavam na década de 1990 que a melhor configuração de uma rede neural tende a apresentar a mesma quantidade de neurônios intermediários e de entrada. Ou seja, a quantidade de variáveis de entrada na matriz inicial da RNA pode ser a quantidade ótima de neurônios intermediários.

É possível observar, no entanto, que no conjunto de medidas de acurácia, a Regressão Múltipla apresentou melhores resultados que a Rede Neural, com Erro Absoluto e Erros

Quadráticos apresentando desvios mais satisfatórios. O Erro Percentual, por sua vez, foi o mesmo para ambas as técnicas.

SIGLA	MAD*	MAPE*	MSE*	RMSE*
NN A07	45	7%	3250	57,0
NN A08	45	7%	3250	57,0
NN A09	45	7%	3250	57,0
NN A10	60	10%	4000	63,2
NN A11	70	11%	5800	76,2
NN A12	90	15%	8200	90,6
NN A13	120	20%	14800	121,7
NN A14	95	15%	10250	101,2
NN B07	45	7%	3250	57,0
NN C05 (7 HN)	60	10%	4000	63,2
NN C05 (10 HN)	45	7%	3250	57,0
REGR A	55	9%	4250	65,2
SMOT01	75	12%	5850	76,5
REGR B	40	7%	1615	40,2

* Legenda:

MAD: Mean Absolute Deviation - erro médio absoluto

MAPE: Mean Absolute Percentage Error - erro médio absoluto percentual

MSE: Mean Squared Error - erro quadrático médio

RMSE: Root Mean Square Error - raiz quadrada do erro quadrático médio

Tabela 5.8 Acurácia dos métodos de previsão selecionados

O objetivo da realização de testes de modelos matemáticos de previsão foi direcionar os esforços dos reponsáveis pelo planejamento de vendas e pela realização das diretrizes e

orçamentos operacionais, a escolher o método que melhor atenda as necessidades da organização no período, por meio da avaliação das vantagens e desvantagens de cada técnica.

Dois gráficos foram elaborado com os resultados obtidos na configuração da rede neural com 7 neurônios e na Regressão Múltipla, em que os erros médios percentuais foram equivalentes. Nota-se que, enquanto o primeiro modelo realizou previsões mais pessimistas, o segundo foi mais otimista do que os valores reais observados. Dessa forma, fica a critério do tomador de decisão que tipo de técnica é mais aderente à estratégia da empresa.

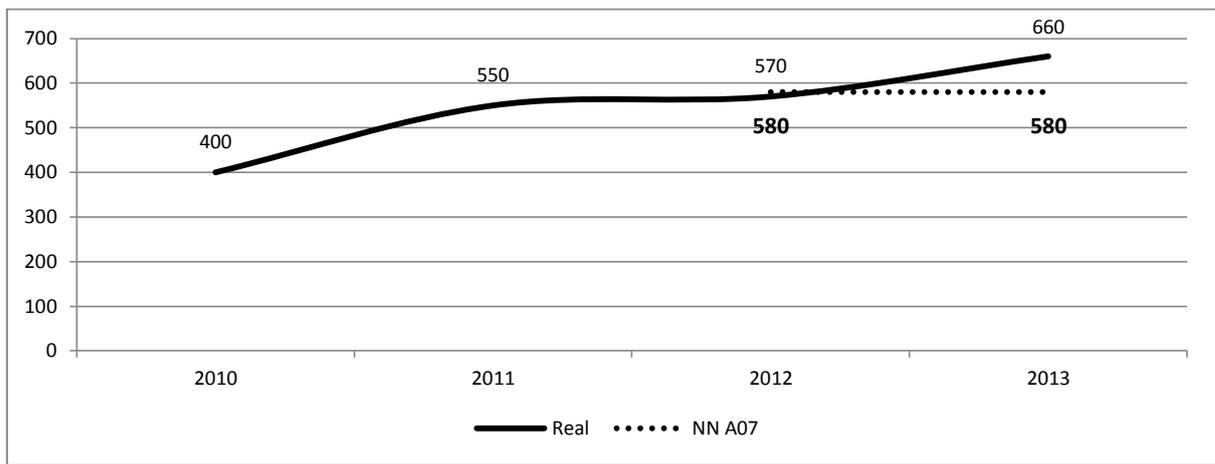


Figura 5.9 Valores previstos comparados com valores reais – Previsão por Redes Neurais com 7 neurônios na camada intermediária

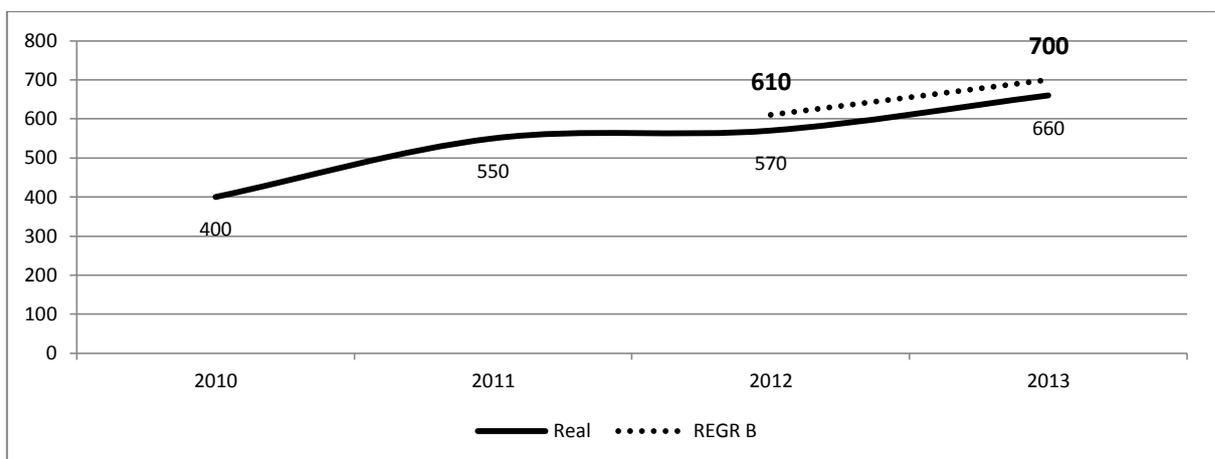


Figura 5.10 Valores previstos comparados com valores reais – Previsão por Regressão Múltipla com as mesmas variáveis da Rede Neural

Para fins de teste, o comportamento sazonal observado trimestralmente na série histórica, cujo cálculo do índice de sazonalidade está apresentado na Seção 5 (página 56), foi

refletido na previsão de vendas anual. Ou seja, multiplicou-se o valor obtido de previsão do ano pelo índice de cada trimestre e dividiu-se cada valor por 4. Os resultados são apresentados a seguir, na Figura 5.11 para a previsão por regressão múltipla e na Figura 5.12 para a previsão por RNA com 13 neurônios, sendo que a primeira apresentou a melhor performance, enquanto a segunda teve o resultado menos satisfatório.

O comportamento da previsão de vendas trimestral para ambas as configurações acompanharam o padrão geral da série para os dois anos. Na Tabela 5.10 o erro médio absoluto (MAD) para ambas as configurações indica que houve três trimestres em que a RNA com pior performance superou a previsão com melhor performance geral.

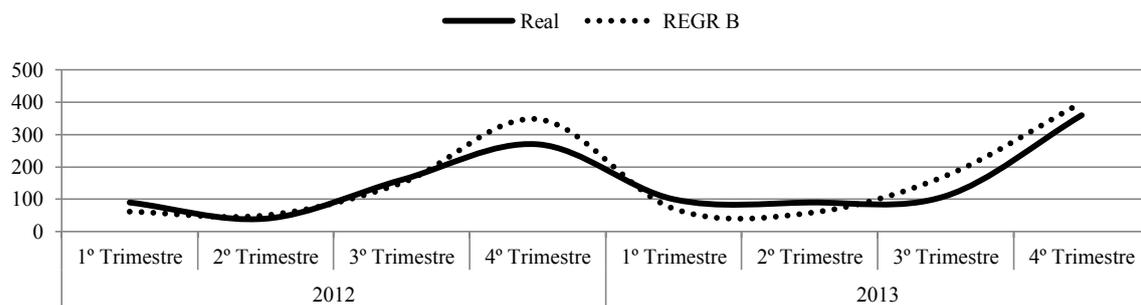


Figura 5.11 Fragmentação da série histórica sazonal para PV com melhor performance na etapa de validação

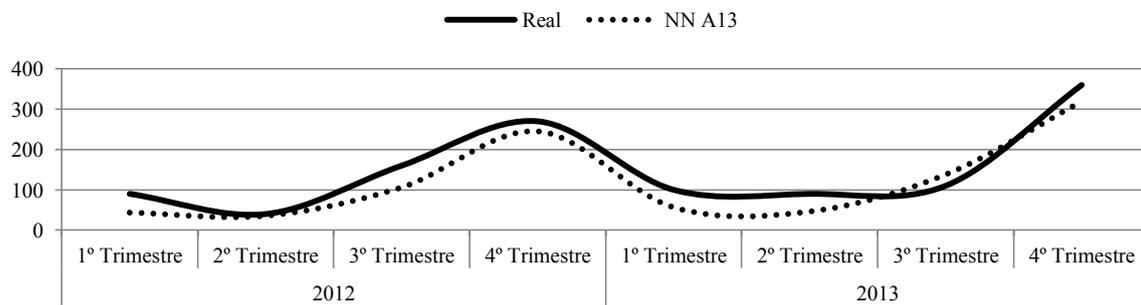


Figura 5.12 Fragmentação da série histórica sazonal para PV com pior performance na etapa de validação

		Real	REGR B	Erro Absoluto	NN A13	Erro Absoluto
2012	1º Trimestre	90	62	28	44	46
	2º Trimestre	40	50	10	35	5
	3º Trimestre	160	150	10	106	54
	4º Trimestre	270	348	78	245	25
2013	1º Trimestre	100	71	29	57	43
	2º Trimestre	90	58	32	46	44
	3º Trimestre	110	172	62	138	28
	4º Trimestre	360	399	39	319	41

Tabela 5.14 Erro Absoluto das Previsões NN A10 e NN A13 por trimestre – Desagregação pelo Índice de Sazonalidade

Processo de Negócio

Para que o modelo de previsão de vendas tenha sustentação e faça parte do processo de tomada de decisão e planejamento estratégico da organização é fundamental que esteja aderente aos seus processos e capacidades. Tendo em vista essa necessidade foi elaborado um processo de Gestão da Demanda atrelado aos modelos de previsão de vendas desenvolvidos para auxiliar o planejamento de vendas e planejamento operacional da fabricante de máquinas agrícolas.

Essencialmente, o processo de Gestão da Demanda mostrado nas Figuras 5.13 e 5.14 propõe uma abordagem baseada nas conclusões da análise dos processos da empresa e na revisão da literatura. Isto é, empregando a previsão de vendas como uma ferramenta de auxílio na elaboração do Plano de Vendas e do Plano Orçamentário Operacional – esses últimos sendo realizados pela área comercial porém conforme necessidades e capacidades das demais áreas da empresa, principalmente Planejamento de Produção e Suprimentos.

A proposta consiste primeiramente na verificação do modelo de previsão utilizado no período previsto anterior. Caso o modelo já não seja aderente ao cenário, será necessário avaliar a troca de técnica e atualizar variáveis e parâmetros. Isso significa que, caso no último período o modelo de regressão tenha sido utilizado, porém perdeu a correlação com as variáveis, novas variáveis deverão ser encontradas ou um outro tipo de modelo empregado. Além da verificação da correlação entre as variáveis, um outro ponto importante para avaliação da aderência de um modelo de previsão é a avaliação do erro, ou desvio, entre os valores previstos e o observado.

Sugere-se que as previsões realizadas pelos representantes de vendas sejam posteriormente confrontadas com a previsão obtida pelos modelos matemáticos. Essa avaliação, em conjunto com a análise do cenário competitivo da organização fará parte do estabelecimento do Plano de Vendas. Por sua vez, este plano é a base para a realização conjunta do Plano Orçamentário Operacional entre as áreas comercial, de planejamento de produção e de suprimentos, principalmente.

As mudanças sugeridas no novo processo de Gestão de Demanda estão evidenciadas em vermelho nas Figuras 5.13 e 5.14. Consistem essencialmente nos pontos apresentados a seguir:

1. Verificação de acurácia do modelo de previsão: por meio da observação dos desvios entre os valores previstos e observados nos três últimos anos, a qual propõe-se que deve ser matida inferior a 10%. Similarmente, as correlações entre as variáveis independentes selecionadas devem manter-se com r^2 acima de 0,8.
2. Execução da Previsão de Vendas: caso o modelo esteja aderente, executa-se a previsão conforme ano anterior e realiza-se a avaliação do cenário em que a empresa encontra-se para que o Plano de Vendas seja formalizado. Por outro lado, se o modelo não estiver aderente, será necessário avaliar as vantagens e desvantagens de um novo método / modelo de previsão e estabelecer novos parâmetros e variáveis para que apenas depois disso o Plano de Vendas seja formalizado.
3. Elaboração do Plano Orçamentário Operacional: após a formalização do Plano de Vendas as áreas de Planejamento de Produção e Suprimentos deverão avaliar a capacidade produtiva da empresa e de seus fornecedores para realização do plano. Posteriormente, o Plano Orçamentário Operacional é estabelecido e os gestores transmitirão as ações necessárias para cumprimento do plano.

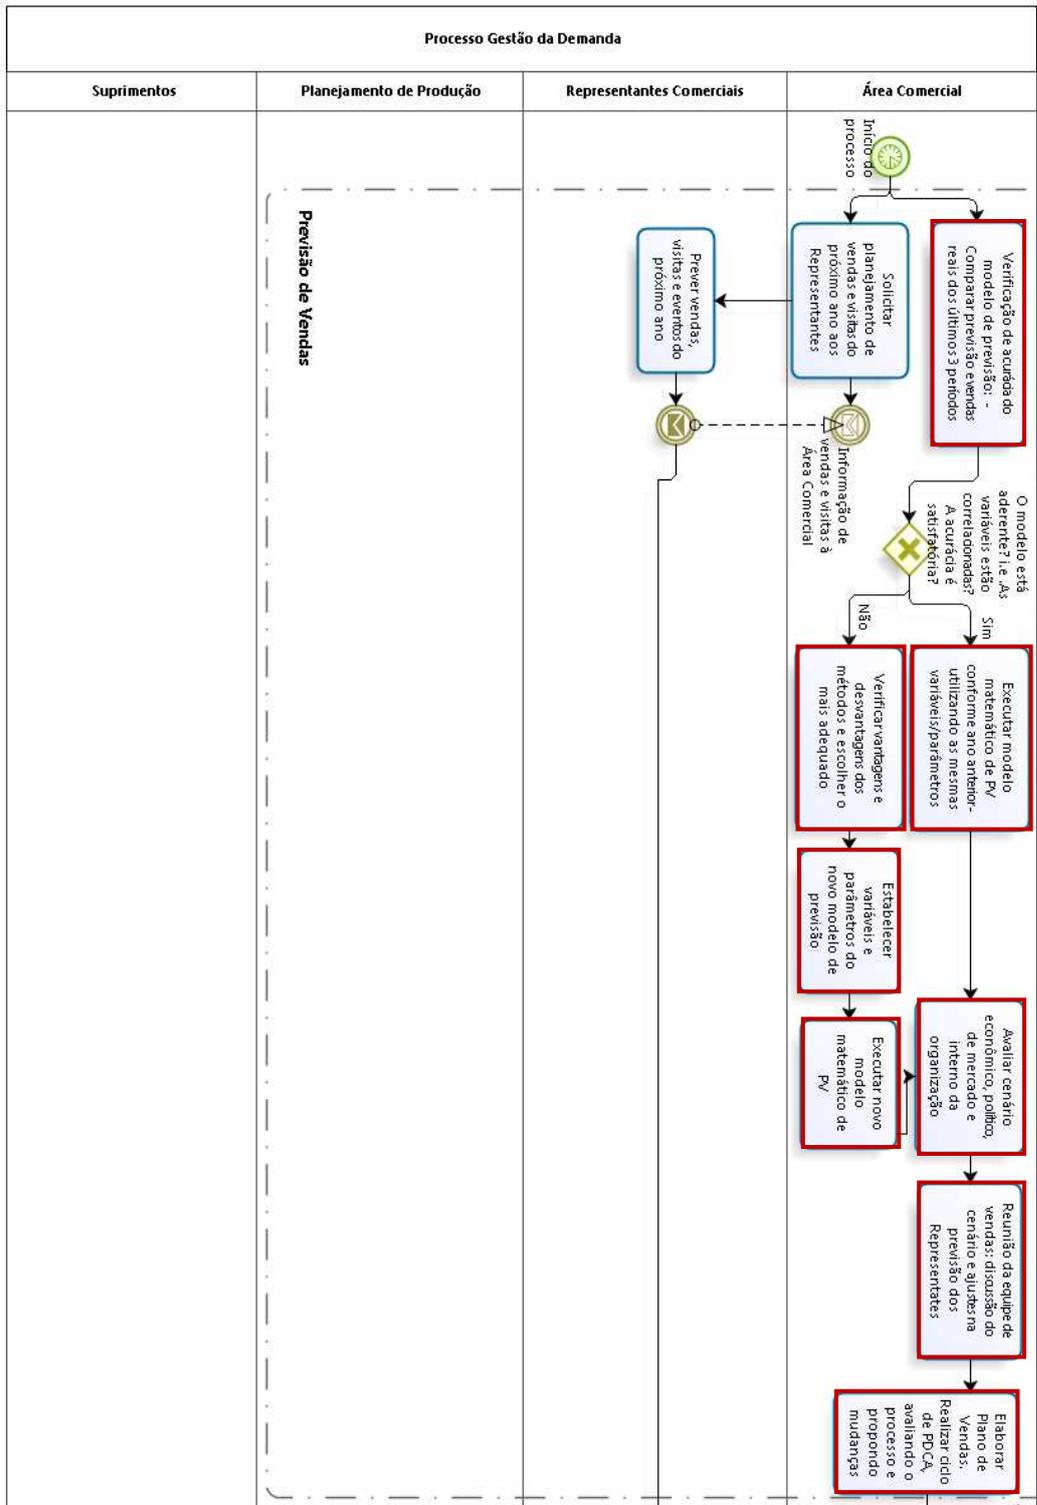


Figura 5.13 Processo Proposto de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 1

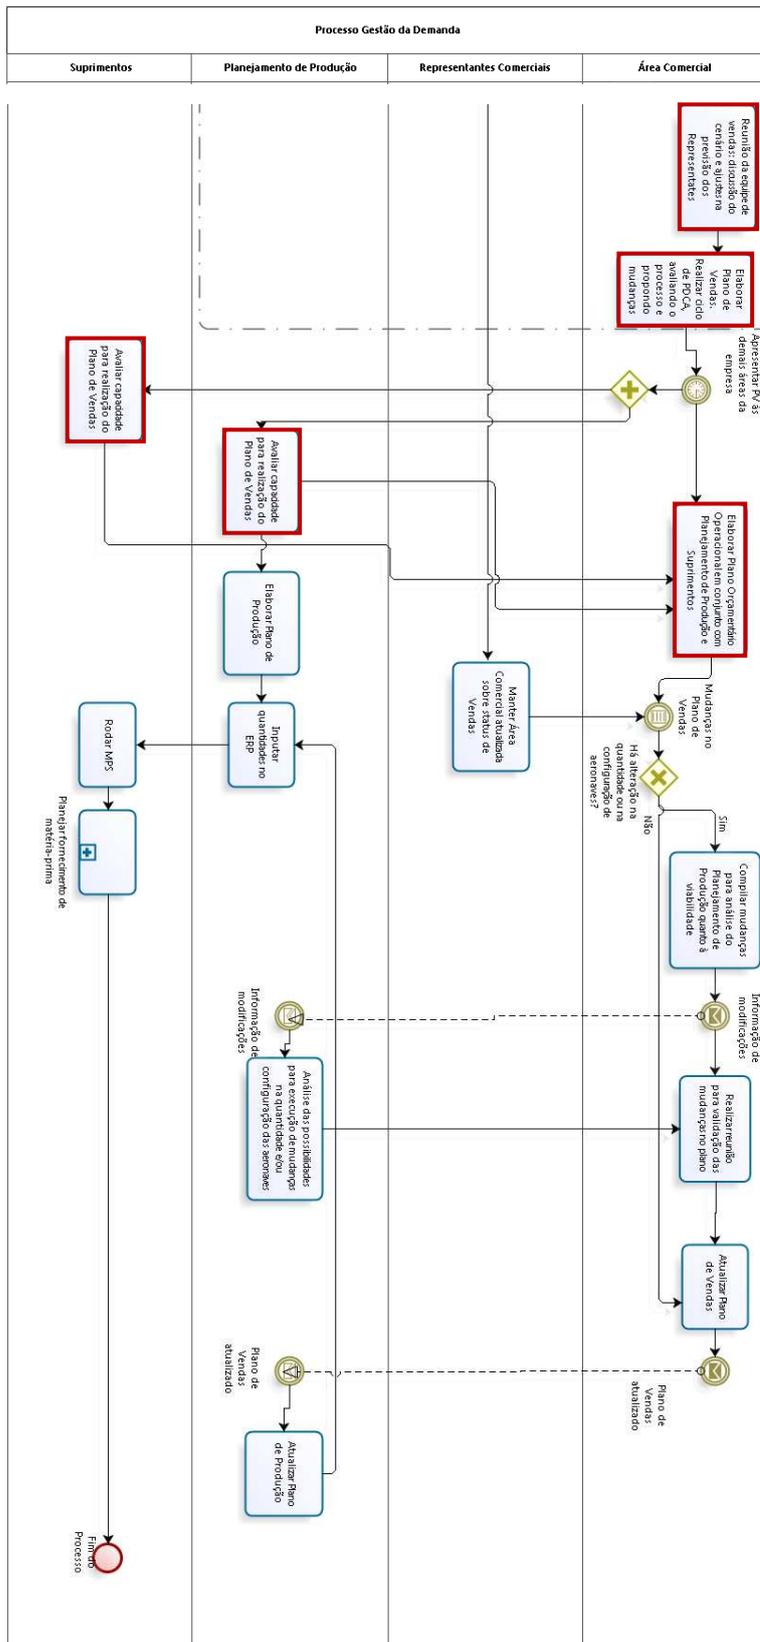


Figura 5.14 Processo Proposto de Previsão de Vendas e de Gestão da Demanda - Caso da empresa de máquinas agrícolas – Parte 2

6. Conclusões

Os resultados comparativos obtidos indicam que os métodos causais de previsão de vendas podem apresentar resultados satisfatórios na previsão e planejamento da demanda. Em particular, modelos causais como a regressão múltipla e redes neurais artificiais são capazes de gerar previsões com índices maiores de acurácia, uma vez que agregam variáveis externas à série histórica. A avaliação de acurácia realizada não indicou superioridade da rede neural sobre a regressão múltipla, tendo ambos os métodos apresentado resultados satisfatórios para a previsão de máquinas agrícolas.

Apesar dos muitos resultados satisfatórios em previsão de vendas apresentados na literatura de Redes Neurais Artificiais, alguns autores relataram resultados semelhantes em suas pesquisas. Darbellay e Slama (2000) demonstraram que Redes Neurais não são tão eficientes quanto modelos de séries temporais lineares, ainda que os dados sejam não lineares. As mesmas conclusões foram obtidas por Kirby *et al.* (1997) e Callen *et al.* (1996). Outros artigos demonstraram que Redes Neurais operam tão bem quanto, mas não melhores que modelos lineares (CHURCH e CURRAM, 1996; NTUNGO e BOYD, 1998).

A decisão de qual dos métodos utilizar é de escolha do tomador de decisão, responsável pela execução da previsão de vendas. A diferença essencial entre ambos nesse caso foi a tendência da previsão, isto é, o primeiro realizou predição pessimista, enquanto o segundo previu quantidades ligeiramente maiores de vendas do que as observadas. No entanto, com o passar do tempo essa característica poderá mudar, uma vez que métodos de previsão não são permanentes. Por isso a importância de manter análises de acurácia e avaliação das correlações no processo de previsão.

O modelo de regressão tido como status quo na empresa avaliada apresentava baixa aderência, com r^2 igual a 0,61. Com os novos modelos, tanto de regressão quanto de redes neurais, foi possível não apenas melhorar a aderência do modelo de previsão, como avaliar o processo de previsão, planejamento e gestão da demanda. O ganho na acurácia do modelo foi de 9% do modelo anterior para 7% nos novos modelos. Trantando-se de um produto de alto valor agregado, a melhoria na acurácia traz resultados expressivos no uso dos recursos produtivos e no planejamento da produção da organização. A escolha pelo método a ser empregado, no entanto, deve ser realizada pelo tomador de decisão.

A previsão por regressão múltipla apresenta ao responsável pela sua execução uma abordagem mais acessível, podendo ser realizada pelo MS Excel. Exige conhecimentos específicos da ferramenta de análise que o programa oferece, porém é passível de ser compreendida de modo prático com mais facilidade que uma rede neural. No entanto, a equação da regressão não é capaz de perceber variações mais finas e padrões não lineares nos dados.

Por sua vez, a previsão por rede neural, além de perceber tais padrões não lineares, possibilita a extrapolação desses padrões para os valores futuros. No caso do modelo desenvolvido, os dados mais recentes tem maior peso no cálculo da previsão – uma vez que os valores da série para três anos anteriores são contemplados nos neurônios de entrada da rede em conjunto com sete variáveis correlacionadas.

Apesar do modelo desenvolvido exigir o conhecimentos em programação por meio do software MATLAB, é possível encontrar programas com plataformas mais amigáveis que não exigem o conhecimento aprofundado da técnica de programação. O RapidMiner é um exemplo de software em cuja a utilização de métodos complexos como RNAs é facilitada. As variáveis correlacionadas podem ser utilizadas no modelo deste programa, assim como os parâmetros sugeridos.

O estudo em desenvolvimento neste trabalho visou agregar à literatura de previsões uma análise crítica aos métodos de previsão, apresentando uma aplicações no cenário nacional ao tratar-se de um produto de alto valor agregado e demanda flutuante e sazonal. Contribui ainda para a avaliação da aplicação empírica das redes neurais artificiais, que apesar de estarem presentes no campo científico há mais de 70 anos, são de difícil popularização devido a sua complexidade e caráter ‘caixa-preta’.

Apesar de ter ampliado sua participação em estudos científicos e softwares de análise e mineração de dados, as Redes Neurais Artificiais apresentam vantagens limitadas para gestores e tomadores de decisão em ambientes dinâmicos. Isso se dá provavelmente à demanda dessa técnica por investimentos em tempo e recursos. Apesar de ter sido demonstrado que RNAs são capazes de gerar boas previsões comparativamente aos métodos lineares, no caso da empresa de máquinas agrícolas a técnica não apresentou performance significativamente maior que a Regressão Múltipla, cuja aplicação demanda menos tempo e

recurso. A Regressão Múltipla, inclusive teve valores melhores em algumas medições de acurácia.

Modelos não-lineares mistos como os apresentados na revisão da literatura (ANFIS; RNAs com ARIMA ou com algoritmos genéticos) não foram incluídos neste estudo devido ao seu caráter aplicado, uma vez que modelos mais complexos são de difícil implantação no cenário organizacional. Além disso, a abrangência das previsões não pôde expandir para os anos seguintes a 2013 devido a substituição do produto por um novo modelo, inviabilizando a utilização da série histórica.

As limitações encontram-se também nas generalizações do modelo de previsão aqui utilizado. Como apontado na literatura, não há um modelo de previsão aplicável para todos os casos. Os resultados dessa pesquisa, portanto, restringem-se à entidades cujo objeto de previsão tenha características semelhantes ao produto investigado, caracterizado pelo alto valor agregado, baixo volume de vendas anuais e forte dependência de um setor específico da Economia, no caso o agronegócio. Pesquisas futuras poderão explorar tais limitações, assim como investigar a utilização de mais camadas na rede, mudanças nos parâmetros da rede ou ainda na quantidade de variáveis na matriz de entrada.

Como salientado por PIDD (2003), a tomada de decisão estratégica caracteriza-se pela ambigüidade sobre os objetivos, incerteza sobre os resultados e grandes riscos. Por meio da exploração de uma abordagem direcionada à compreensão da situação, é possível aplicar uma sistemática em que os envolvidos possam compreender a complexidade do problema. A partir da compreensão sobre o papel da gestão da demanda como um amplo processo de colaboração entre as diversas áreas e métodos de previsão aderentes ao negócio, a sistemática sugerida para o planejamento anual de vendas da empresa de equipamentos agrícolas reflete na obtenção ganhos em produtividade e na diminuição do desperdício de recursos. Havendo um plano de operações aderente às necessidades de mercado e às capacidades da empresa, o risco de perdas deve reduzir significativamente.

Referências

- ALBERGONI, L.; PELAEZ, V. Da Revolução Verde à agrobiotecnologia: ruptura ou continuidade de paradigmas? *Revista de Economia*. v. 33, n. 1, p. 31-53. Paraná, 2007.
- ALI, O. G.; PINAR, E. Multi-period-ahead forecasting with residual extrapolation and information sharing — Utilizing a multitude of retail series. *International Journal of Forecasting*. v. 32, i. 2, p. 502-517. Turquia, 2016.
- ALMEIDA, F. C.; PASSARI, A. F. L. Previsão de vendas no varejo por meio de redes neurais. *R. Adm.*, v. 41, n. 3, p. 257-272. São Paulo, 2006.
- ALON, I.; QI, M.; SADOWSKI, R. J. Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional methods. *Journal of Retailing and Consumer Services*, v. 8, p. 147-156. USA, 2001.
- ALVES, L. A.; CHICRALLA, R. C.; LEITE, V. P.; MELLO, J. C. C. B. S.; NETO, L. B. Previsão de faturamento para lojas do setor de varejo com redes neurais. *Revista Eletrônica Pesquisa Operacional para o Desenvolvimento*. v. 5, n. 1, p. 1-13. Rio de Janeiro, 2013.
- ANTUNES, J. A. V. et al. Critical Issues about the Theory of Constraints Thinking Process— A Theoretical and Practical Approach. 15th POMS – Production and Operation Management Society. Cancun, 2004.
- AYE, G. C.; BALCILAR, M.; GUPTA, R.; MAJUMDAR, A. Forecasting aggregate retail sales: The case of South Africa. *International Journal of Production Economics*, v. 160, p. 66-79. África do Sul/Turquia/China, 2015.
- ARUNRAJ, N. S.; AHRENS, D. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. *International Journal of Production Economics*, v. 170, part A, p. 321-335. Alemanha, 2015.
- BARBIER, René. *A Pesquisa-Ação*. Tradução de Lucie Didio. Brasília: Líber Livro Editora, 2004, p. 37-57.
- BASHEER, I. A.; HAJMEER, M. Artificial Neural Networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, v. 43, p. 3-31. Estados Unidos, 2000.

BM&F BOVESPA. Índice de Commodities Brasil – ICB. Disponível em http://www.bmf.com.br/bmfbovespa/pages/boletim1/bd_manual/PDF/ICB-Metodologia.pdf. Acesso em 10/07/16. 2015.

CALLEN, J. L.; KWAN, C. Y.; YIP, C. Y.; YUAN, Y. Neural network forecasting of quarterly accounting earnings. *International Journal of Forecasting*, v. 12, p. 475–482. Estados Unidos, 1996.

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

CASALI, A. L.; SCHLOSSER, J. F.; GANDOLFO, M. A.; UHRY, D.; RODRIGUES, F. A. Nível de capacitação e informação dos operadores de máquinas para a aplicação de agrotóxicos. *Ciência Rural*, ISSN 0103-8478. Santa Maria, PR, 2014.

CASTRO, L. N.; ZUBEN, F. J. V. Optimized training techniques for feedforward neural networks. Technical Report. Department of Computer Engeneering and Industrial Automation, FEEC-UNICAMP. Campinas, 1998.

CHAKRABORTY, K.; MEHROTRA, K.; MOHAN, C. K.; RANKA, S. Forecasting the behavior of multivariate time series using neural networks. *Neural Networks* v. 5, p. 961–970. Estados Unidos, 1992.

CHU, C.; ZHANG, G. P. A comparative study of linear and nonlinear models for aggregate retail sales forecasting. *International Journal of Production Economics*, v. 86, p. 217-231. Taiwan/Estados Unidos, 2003.

CHURCH, K. B.; CURRAM, S. P. Forecasting consumers' expenditure: A comparison between econometric and neural network models. *International Journal of Forecasting*, v. 12, p. 255–267. Reino Unido, 1996.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. Planejamento, Programação e Controle da Produção. 5a ed. Ed. Atlas. 2007. Capítulos 5 a 7.

CROXTON, K. L. et al. The Demand Management Process. LAMBERT, D. M. Supply Chain Management: Processes, Partnerships, Performance. Florida: Supply Chain Management Institute, 2008. p. 87-104.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematical Control Signals Systems*, v. 2, p. 303–314. Estados Unidos, 1989.

DARBELLAY, G. A.; SLAMA, M. Forecasting the short-term demand for electricity: Do neural networks stand a better chance? *International Journal of Forecasting*, v. 16, p. 71–83. República Tcheca, 2000.

DE GOOIJER, J. G.; FRANSES, P. H. Forecasting and seasonality. *International Journal of Forecasting*, v. 13, p. 303–305. Holanda, 1997.

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

DU, W.; LEUNG, S. Y. S.; KWONG, C. K. A multiobjective optimization-based neural network model for short-term replenishment forecasting in fashion industry. *Neurocomputing*, v. 151, p. 342–353. China, 2015.

ELKATEB, M. M.; SOLAIMAN, K.; AL-TURKI, Y. A comparative study of medium-weather-dependent load forecasting using enhanced artificial/fuzzy neural network and statistical techniques. *Neurocomputing* v. 23, p. 3–13. Reino Unido/Arábia Saudita, 1998.

FAWCETT, S. E.; MAGNAN, G. M. The rhetoric and reality of supply chain management. *International Journal of Physical Distribution & Logistics Management*, v. 32, n. 5. EUA, 2002.

FERNANDES, F. C. F.; GODINHO FILHO, M. Planejamento e Controle da Produção: Dos Fundamentos ao Essencial. São Paulo, Editora Atlas, 2010. Capítulos 2 e 3.

FLORES, J. H. F.; WERNER, L. Aplicação de Redes Neurais Artificiais à previsão de vendas de máquinas agrícolas. XXVII Encontro Nacional de Engenharia de Produção. Foz do Iguaçu, PR, 2007.

FRANSES, P.H.; DRAISMA, G. Recognizing changing seasonal patterns using artificial neural networks. *Journal of Econometrics*, v. 81, p. 273–280. Holanda, 1998.

FUNAHASHI, K. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, v. 2, p. 183–192. Japão, 1989.

FYFE, C. Artificial Neural Networks and Information Theory. Department of Computing and Information Systems. The University of Paisley. Edition 1.2, 2000.

GAO, L. Collaborative forecasting, inventory hedging and contract coordination in dynamic supply chain risk management. *European Journal of Operational Research*, v. 245, p. 133-145. Estados Unidos, 2015.

GRANGER, C. W. J.; TERASVIRTA, T. *Modelling Nonlinear Economic Relationships*. Oxford University Press, Oxford. 1993.

GERDES, M. Decision trees and genetic algorithms for condition monitoring forecasting of aircraft air conditioning. *Expert Systems with Applications*, v. 40, p. 5021-5026. Alemanha, 2013.

GEURTS, M. D.; KELLY, J. P. Forecasting retail sales using alternative models. *International Journal of Forecasting*, v. 2, p. 261-272. 1986.

GHIASSI, M.; LIO, D.; MOON, B. Pre-production forecasting of movie revenues with a dynamic artificial neural network. *Expert Systems with Applications*, v. 42, p. 3176-3193. Estados Unidos, 2015.

GHYSELS, E.; GRANGER, C. W. J.; SIKLOS, P. L. Is seasonal adjustment a linear or nonlinear data filtering process? *Journal of Business and Economics Statistics* v. 14, p. 374-386. Estados Unidos, 1996.

GOLDRATT, R.; WEISS, N. Significant Enhancement of Academic Achievement through Application of the Theory of Constraints. *Human Systems Management*, v. 24, p. 13-19, 2005.

GOODWIN, P.; LAWTON, R. On the asymmetry of the symmetric MAPE. *International journal of forecasting*, v. 15, p. 405-408. Inglaterra, 1999.

HAMZAÇEBI, C. Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*, v. 178, p. 4550-4559. Turquia, 2008.

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

- HORNIK, K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*, v.4, p. 251-257. Austria, 1991.
- HORNIK, K. Some new results on neural network approximation. *Neural Networks*, n. 6, p. 1069-1072. Austria, 1993.
- HYNDMAN, R.; ATHANASOPOLOS, G. *Forecasting. Principals and Practice*. Print edition. Otext.com, 2014. p. 70-71.
- IRIE, B. MIYAKE, S. Capabilities of three-layered perceptrons. *IEEE International Conference on Neural Networks*, p. 641-648. Estados Unidos, 1988.
- JACOSKI, C. A.; GRZEBIELUCHAS, T. Modelagem na contratação de projetos utilizando os conceitos de BPM – gerenciamento de processos de negócio. *Produto & Produção*, vol. 2, n. 3, p. 29-37. Chapecó, 2011.
- JESUS, D. M.; VIEIRA, A. B.; EFFGEN, A. P. S. Pesquisa-ação colaborativo-crítica: em busca de uma epistemologia. *Educação & Realidade*, vol. 39, n.3. Porto Alegre, 2014.
- KIRBY, H. R.; WATSON, S. M.; DOUGHERTY, M. S. Should we use neural networks or statistical models for short-term motorway traffic forecasting? *International Journal of Forecasting*, v. 13, p. 43–50. Reino Unido, 1997.
- KLOCHKOV, V. V. Forecasting de demand for aircraft industry products today. *Studies on Russian Economic Development*, v. 17, n. 1, p. 48-57. Rússia, 2006.
- KOZIK, P.; SEP, J. Aircraft engine overhaul demand forecasting using ANN. *Management and Production Engineering Review*, v. 3, n. 2, p. 21-36. Polônia, 2012.
- KUO, R. J. A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm. *European Journal of Operational Research*, v. 129, p. 496-517. Taiwan, 2001.
- LACERDA, D. P.; RODRIGUES, L. H.; CORCINI NETO, S. L. H. Processo de Pensamento da Teoria das Restrições: uma abordagem para compreensão, aprendizagem e ação sobre problemas complexos. *Perspectivas em Gestão & Conhecimento*. v. 1, n. 2, p. 52-76. João Pessoa, 2011.

LOEBBAKA, A. L. J. Managing future and emergent strategy decay in the commercial aerospace industry. *Business Strategy Series*, v. 9, p. 147-156. Estados Unidos, 2008.

LIVINGSTONE, D. J. *Artificial Neural Networks. Methods and Applications*. Humana Press, Springer. v. 458. 2009. p. 14-42; 226-243.

LUXHOJ, J. T.; RIIS, J. O.; STENSBALLE, B. A hybrid econometric-neural network modeling approach for sales forecasting. *International Journal of Production Economics*, v. 43, p. 175-192. Dinamarca, 1995.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C. *Forecasting Methods for Management*. 5a ed. New York, NY: John Wiley, c. 1989.

MELO, Daniela de Castro; ALCÂNTARA, Rosane Lúcia Chicarelli. Gestão da demanda em cadeias de suprimentos: uma abordagem além da previsão de vendas. *Gest. Prod.*, São Carlos, v. 18, n. 4, p. 809-824, 2011.

MENTZER, J. T.; MOON, M. A. *Sales Forecasting Management: A Demand Management Approach*. 2a ed. Sage Publications. 2005, p. 1-32.

MENTZER, J. T.; MYERS, M. B.; STANK, T. P. *Handbook of Global Supply Chain Management*. Sage Publications. EUA, 2007.

MERINO, M.; RAMIREZ-NAFARRATE, A. Estimation of retail sales under competitive location in Mexico. *Journal of Business Research*, v. 69, p. 445-451. Mexico, 2016.

MIN, S; ROATH, A. S.; DAUGHERTY P. J.; GENCHEV, S. E.; CHEN, H.; AMDT, A. D.; RICHEY, R. G. Supply chain collaboration: what's happening?. *The International Journal of Logistics Management*, v. 16, i. 2, p. 237-256. EUA, 2005.

NAM, K.; SCHAEFER, T. Forecasting international airline passenger traffic using neural networks. *Logistics and Transportation Review*, v. 31 (3), p. 239–251. Canada, 1995.

NELSON, M.; HILL, T.; REMUS, T.; O'CONNOR, M. Time series forecasting using neural networks: Should the data be deseasonalized first? *Journal of Forecasting*, v. 18, p. 359–367. Austrália, 1999.

NTUNGO, C.; BOYD, M. Commodity futures trading performance using neural network models versus ARIMA models. *The Journal of Futures Markets*, v. 18 (8), p. 965–983. Canada, 1998.

OLIVEIRA, A. V. M. O.; FERRAZ, R. B. Overbooking, gerenciamento de receitas e previsão de demanda: estudo empírico das posições em sistemas de reservas de companhias aéreas. *Rev. adm. comtemp.*, v. 12, n. 2. Curitiba, 2008.

OLIVEIRA, A. C. S.; SOUZA, A. A.; LACERDA, W. S. GONÇALVES, L. R. Aplicação de Redes Neurais Artificiais na previsão da produção de álcool. *Ciênc. agrotec*, v. 34, n. 2, p. 279-284. Lavras, MG, 2010.

OMG. Business Process Model and Notation. Janeiro, 2011. Standart document URL: <http://www.omg.org/spec/BPMN/2.0>. Acesso em 02/02/17.

PIDD, Michael. *Tools for thinking: Modelling in Management Science*. 2 ed., England: John Wiley & Sons, 2003. p. 61.

POLONI, F.; SBRANA, G. A note on forecasting demand using the multivariate exponential smoothing framework. *International Journal of Production Economics*, v. 162, p. 143-150. Itália/ França, 2015.

PRYBUTOK, V. R.; YI, J.; MITCHELL, D. Comparison of neural network models with ARIMA and regression models for prediction of Houston's daily maximum ozone concentrations. *European Journal of Operational Research*, n. 122, p. 31–40. EUA/Coréia do Sul, 2000.

REYNOLDS, D.; RAHMAN, I.; BALINBIN, W. Econometric modeling of the U.S. restaurant industry. *International Journal of Hospitality Management*, v. 34, p. 314-323. EUA, 2013.

ROWE, G. WRIGHT, G. The Delphi technique as a forecasting tool: issues and analysis. *International Journal of Forecasting*, v. 15, i. 4, p. 353-375. Reino Unido, 1999.

ROWE, G.; WRIGHT, G. Expert Opinions in Forecasting: the role of the Delphi technique. *Principles of Forecasting. A handbook for researchers and practitioners*. Edited by J. Scott Armstrong. Springer Science Business Media, 2001. p. 127-128.

RUMELHART, D. E.; DURBIN, R.; GOLDEN, R.; CHAUVIN, Y. Backpropagation: the basic theory. Backpropagation: Theory, Architectures, and Applications. Lawrence Erlbaum Associates. p. 1-34. EUA, 1995.

SHARDA, R.; PATIL, R. B. Connectionist approach to time series prediction: An empirical test. *Journal of Intelligent Manufacturing*, v. 3, p. 317–323. EUA, 1992.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. Administração da Produção. 3 ed. Editora Atlas, 2009. p. 283.

SRINIDHI, S.; MANRAI, A. K. International air transport demand: drivers and forecasts in the Indian context. *Journal of Modelling in Management*, v. 9, p. 245-260. Índia/EUA, 2014.

TANAKA, K. A sales forecasting model for new-released and nonlinear sales trend products. *Expert System with Applications*, v. 37, p. 7387-7393. Japão, 2010.

TANG, Z. FISHWICK, P. A. Feedforward neural nets as models for time series forecasting. *ORSA Journal on Computing* 5, v. 4, p. 374-385. EUA, 1993.

TRIPP, D. Pesquisa-ação: uma introdução metodológica. *Revista Brasileira de Educação*, v. 31, n. 3, p. 443-466. São Paulo, 2005.

TASTAMBEKOV, K.; PUECHMOREL, S.; DELAHAYE, D.; RABUT, C. Aircraft trajectory forecasting using local functional regression in Sobolev space. *Transportation Research Part C*, v. 39, p. 1-22. França, 2014.

WANG, F.; CHANG, K.; TZENG, C. Using adaptive network-based fuzzy inference system to forecast automobile sales. *Expert Systems with Applications*, v. 38, p. 10587-10593. Taiwan, 2011.

WANG, Z.; ZHAI, G.; HUANG, X.; YI, D. Combination forecasting method for storage reliability parameters of aerospace relays based on grey-artificial neural networks. *International Journal of Innovative Computing, Information and Control*, v. 9, n. 9, p. 3807-3816. China, 2013.

XIA, M.; ZHANG, Y. WENG, L.; YE, X. Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs. *Knowledge-Based Systems*, v. 36, p. 253-259. China, 2012.

XIA, M.; WONG, W. K. A seasonal discrete grey forecasting model for fashion retailing. *Knowledge-Based Systems*, v. 57, p. 119-126. China, 2014.

YU, Y.; CHOI, T.; HUI, C. An intelligent fast sales forecasting model for fashion products. *Expert Systems with Applications*, v. 38, p. 7373-7379. Hong Kong, 2011.

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

ZHANG, G. P.; QI, M. Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, v. 160, i. 2, p. 501-514. EUA, 2005.

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

ZHANG, G. P.; QI, M. Predicting consumer retail sales using neural networks. *Neural Networks in Business: Techniques and Applications*. Idea Group Publishing, Hershey, PA, pp. 26-40. 2002.

ANEXO 1: Questionário Fase 1

1. Por que a Gestão da Demanda existe?
2. Como se inicia o processo de S&OP?
3. Quando e como ele acaba?
4. Quais são as fases do processo?
5. Quais são os resultados esperados?
6. Quais são as funções de negócios (áreas ou departamentos) que estão envolvidas com o S&OP?
7. A quem interessa o processo?
8. Quem é responsável pelo gerenciamento do S&OP?
9. Como a Gestão da Demanda se relaciona com o processo de S&OP?
10. Qual o horizonte de planejamento o S&OP contempla?
11. Quais são os indicadores de desempenho associados ao processo?
12. Quais são os resultados passados do processo?
13. Quais são os recursos necessários para execução do processo?
14. Quais são os documentos associados ao processo?
15. Quais são as principais atividades que englobam o S&OP?
16. Quem executa essas atividades?
17. Quais são as principais interfaces com outros processos?
18. Quais são os sistemas informatizados ou aplicações que dão suporte ao processo?
19. Quais são as regras de negócio?
20. Qual a frequência de execução do processo?
21. Quais são as restrições?
22. Quais são os riscos?
23. Quais são as informações mais importantes/criticas tratadas ao longo do processo e em que fase elas são processadas?
24. Como o processo de PV se relaciona com a Gestão da Demanda?

ANEXO 2: Questionário Fase 2

25. Qual é o parâmetro para considerar o total produzido no histórico?
26. Qual é a melhor métrica anual para utilizar no nosso estudo?
27. Com quanto tempo de antecedência uma modificação no plano de Entregas poderia ocorrer idealmente?
28. Quantos são os produtos finais?
29. Por que ocorre retrabalho quando opcionais são adicionados no decorrer do processo?
30. Como ocorre a comunicação entre a Área Comercial e PPCP?
31. Como a ferramenta de Previsão de Vendas auxilia no processo?
32. Quem efetua a Previsão de Vendas? Quem a produz? Quantas pessoas?
33. Quem utiliza a Previsão de Vendas?
34. Qual é a métrica para o histórico de produção? De que mês a que mês?
35. Prestadores de serviço: é possível entrar em contato?
36. Qual é a lógica para utilização dos Número de Série?
37. Representantes de Vendas são funcionários da empresa?