

LUIZ HENRIQUE MANSSUR

**APLICAÇÃO DE UM MODELO DE PREVISÃO
DE DEMANDA EM UMA EMPRESA
DE AGROBUSINESS**

Trabalho de Formatura apresentado
à Escola Politécnica da Universidade de
São Paulo para a obtenção do Diploma
de Engenheiro de Produção

São Paulo
2006

LUIZ HENRIQUE MANSSUR

**APLICAÇÃO DE UM MODELO DE PREVISÃO
DE DEMANDA EM UMA EMPRESA
DE AGROBUSINESS**

Trabalho de Formatura apresentado
à Escola Politécnica da Universidade de
São Paulo para a obtenção do Diploma
de Engenheiro de Produção

Orientador: Prof. Luis Fernando Pinto de Abreu

São Paulo

2006

FICHA CATALOGRÁFICA

Manssur, Luiz Henrique

Aplicação de um modelo de previsão de demanda em uma empresa de agrobusiness / L.H. Manssur. -- São Paulo, 2006. p.94

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Produção.

1.Previsão de demanda I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Produção II.t.

Agradecimentos

Aos meus pais pelo apoio, compreensão e colaboração durante esses cinco anos que estudei na Escola Politécnica.

A minha namora por sempre acreditar em mim e não me deixar desistir nunca.

Ao Professor Luis Fernando pela orientação cuidadosa, que me fez seguir o caminho correto neste trabalho.

A todos os amigos que fiz na Escola Politécnica durante esses cinco anos, que foram fundamentais para minha graduação.

Aos colegas da Accenture e da empresa onde este trabalho foi realizado, que contribuíram para a sua realização.

Resumo

O objetivo deste trabalho de formatura é desenvolver um modelo de previsão de demanda para uma empresa do setor de agrobusiness. Primeiramente é feita uma pequena apresentação da empresa e do mercado o qual a mesma está inserida. A seguir um resumo de modelos de previsão é apresentado. Com isso começa o desenvolvimento do trabalho, onde é feita a escolha dos produtos piloto, em seguida os mesmos são analisados para que seja possível definir um modelo a ser aplicado. Com o modelo definido é feito um teste comparativo entre o modelo escolhido e o processo de previsão atual. Após a comparação é feita uma análise econômica da solução para se determinar os ganhos com a sua implementação e por fim são feitas as considerações finais sobre o trabalho.

Abstract

The objective of this essay is to develop a demand forecasting model for an agrobusiness company. First a small presentation of the company and the market is made. Then a brief of the main forecasting methods is presented. After that, starts the development of the essay, the products that will be tested are selected, then they are analyzed, so the best method can be defined and applied. With the method selected, a comparative test will be made comparing the results of the method selected and the current forecasting process. After the comparative test, an economic analyses of the solution is made to determine the financial improvement if the implementation be made . After that the final considerations about the essay are presented.

Sumário

1	Introdução.....	14
1.1	– Descrição da Empresa	14
1.2	– Portifólio de Produtos	14
1.3	– Estrutura da Área de Comercial.....	15
2	Problema	17
3	Objetivo	18
4	Metodologia	19
4.2	– Apresentação do modelo atual de previsão	19
4.3	– Revisão bibliográfica	19
4.4	– Dados Disponíveis/Seleção dos produtos piloto	20
4.5	– Análise dos produtos piloto	20
4.6	– Escolha do modelo a ser utilizado	20
4.7	– Aplicação do modelo	20
4.8	– Análise Econômica da Solução	21
5	Descrição do estágio.....	22
6	Descrição do Mercado.....	23
6.1	– O Mercado	23
6.2	– Safra e Entre-safra	24
6.3	– Distribuição Agrícola no Brasil.....	24
6.5	– Variabilidade Inerente e Eventos	27
7	Descrição do Modelo atual de previsão.....	29
8	Revisão Bibliográfica	32
8.1	– Importância da Previsão	32
8.2	– Maneiras de medir o erro da previsão	33
8.3	– Métodos Qualitativos de Previsão de Demanda	36
8.4	– Métodos Quantitativos	39
8.4.1	– Método da Média Móvel Simples	40
8.4.2	– Método da Suavização Exponencial Simples	41

8.4.3 – Método da Suavização Exponencial Simples com Taxa de Resposta Adaptativa	42
8.4.4 – Método da Suavização Exponencial Linear com um Parâmetro – Método de Brown	43
8.4.5 – Método Linear de Holt.....	44
8.4.6 – Método Linear de Winters	45
8.4.7 – Classificação de Pegels	46
8.4.8 – Método de Box-Jenkins	49
8.4.9 – Regressão Linear Simples.....	51
8.4.10 – Regressão Linear Múltipla	54
9 Dados Disponíveis e Seleção dos produtos piloto.	55
9.1 – Dados Disponíveis	55
9.2 – Metodologia para escolha dos produtos piloto	56
10 Análise dos produtos Piloto.....	63
10.1 – Análise do Pesticida A	64
10.2 – Análise do Pesticida B	67
10.3 – Análise do Herbicida A	69
10.4 – Análise do Herbicida B.....	71
10.5 – Análise do Fungicida A	73
10.6 – Análise do Fungicida B	75
10.7 – Análise Global dos Produtos	77
11 Seleção do Modelo de Previsão	78
12 Aplicação do Modelo.....	82
12.1 – Aplicação do Modelo – Pesticida A	85
12.2 – Aplicação do Modelo – Pesticida B.....	88
12.3 – Aplicação do Modelo – Herbicida A	90
12.4 – Aplicação do Modelo – Herbicida B	92
12.5 – Aplicação do Modelo – Fungicida A	94
12.6 – Aplicação do Modelo – Fungicida B	96
13 Análise Econômica da Solução.....	98

14 Conclusão.....	102
15 Bibliografia	104
16 Anexos.....	105
16.1 – Histórico de Venda dos Produtos Piloto	105
16.2 – Memorial de cálculos das etapas de inicialização e validação	107
16.3 – Cálculo do valor econômico	112

Lista de Tabelas

Tabela 1: Classificação de Pegels.

Tabela 2: Porcentagem de participação dos produtos

Tabela 3: Produtos escolhidos

Tabela 4: Nova nomenclatura para os produtos escolhidos

Tabela 5: Distribuição das Vendas mês a mês – Pesticida A

Tabela 6: Distribuição das Vendas mês a mês – Pesticida B

Tabela 7: Distribuição das Vendas mês a mês – Herbicida A

Tabela 8: Distribuição das Vendas mês a mês – Herbicida B

Tabela 9: Distribuição das Vendas mês a mês – Fungicida A

Tabela 10: Distribuição das Vendas mês a mês – Fungicida B

Tabela 11: Análise do modelo suavização exponencial

Tabela 12: Análise do modelo Holt-Winter

Tabela 13: Análise do modelo Box-Jenkins

Tabela 14: Análise do modelo de regressão Linear

Tabela 15: Inicialização e Validação do modelo (pesticida A)

Tabela 16: Previsões Pesticida A

Tabela 17: Previsões Pesticida B

Tabela 18: Previsões Herbicida A

Tabela 19: Previsões Herbicida B

Tabela 20: Previsões Fungicida A

Tabela 21: Previsões Fungicida B

Tabela 22: Reduções do erro de previsão

Tabela 23: Cálculo do Ganho econômico Pesticida A

Tabela 24: Ganho Anual dos Produtos Piloto

Lista de Figuras

Figura 1: Organograma da Estrutura Comercial

Figura 2: Distribuição e área total das culturas no Brasil

Figura 3: Agrupamento das grandes regiões

Figura 4: Efeito da variabilidade inerente e do eventos

Figura 5: Fluxograma do processo atual de geração da previsão

Lista de Gráficos

Gráfico 1: Proporção de vendas – Pesticidas 2005

Gráfico 2: Proporção de vendas – Herbicidas 2005

Gráfico 3: Proporção de vendas – Fungicidas 2005

Gráfico 4: Volume de Vendas - Pesticida A

Gráfico 5: Correlograma – Pesticida A

Gráfico 6: Volume de Vendas - Pesticida B

Gráfico 7: Correlograma – Pesticida B

Gráfico 8: Volume de Vendas - Herbicida A

Gráfico 9: Correlograma – Herbicida A

Gráfico 10: Volume de Vendas - Herbicida B

Gráfico 11: Correlograma – Herbicida B

Gráfico 12: Volume de Vendas - Fungicida A

Gráfico 13: Correlograma – Fungicida A

Gráfico 14: Volume de Vendas – Fungicida B

Gráfico 15: Correlograma – Fungicida B

Gráfico 16: Previsões X Vendas – Pesticida A

Gráfico 17: Previsões X Vendas – Pesticida B

Gráfico 18: Previsões X Vendas – Herbicida A

Gráfico 19: Previsões X Vendas – Herbicida B

Gráfico 20: Previsões X Vendas – Fungicida A

Gráfico 21: Previsões X Vendas – Fungicida B

Listas de Siglas e Abreviaturas

IA – Ingrediente Ativo

APO - advanced planner and optimizer

PIB – Produto interno bruto

ME – Mean Error - Erro Médio

MAE – Mean Absolute Error - Erro Absoluto Médio

MSE – Mean Squared Error - Erro Quadrático Médio

PE – Percentage Error - Erro Percentual

MPE – Mean Percentage Error - Erro Percentual Médio

MAPE – Mean Absolute Percentage Error - Erro Percentual Absoluto Médio

ARIMA – Auto Regressive Integrated Moving Averages

Kg – Quilogramas

L – Litros

1 Introdução

1.1 – Descrição da Empresa

A empresa onde será desenvolvido este trabalho é a primeira empresa global focada exclusivamente no mercado de agrobusiness, empresa de origem Suíça, só começou suas operações no Brasil em fevereiro de 2001 com a união de duas outras empresas. Com forte presença mundial, apresenta forte atuação na Europa, América do Norte, América do Sul e Ásia, empregando mais de 19 mil pessoas em mais de 90 países. No Brasil a empresa possui mais de 900 funcionários e é líder no mercado de defensivos agrícola e ocupa a terceira posição no mercado de sementes. A empresa possui apenas uma fábrica no Brasil que se localiza em Paulínea (SP). Essa fábrica é responsável pelo suprimento de produtos para todo o Brasil e a maioria da América Latina, que possui apenas uma outra fábrica de menor porte em Cartagena (Colômbia).

1.2 – Portifólio de Produtos

Os produtos vendidos pela empresa no Brasil podem ser divididos em três grandes grupos:

Proteção de Cultivos: Estes produtos são direcionados diretamente para a proteção de cultivos, existindo produtos especializados para um único tipo de cultivo, ou sendo genérico para mais de uma cultura. Dentro desse grupo os produtos são classificados dentro das seguintes classes: Herbicidas, Fungicidas e Pesticidas.

Herbicida: *Composto ativo de agrotóxico usado para eliminar das lavouras espécies não desejadas, especialmente plantas daninhas ou plantas invasoras, e que apresenta certa toxicidade às plantas cultivadas. (Definição retirada do glossário de biotecnologia, edição de 2005)*

Fungicida: *Agente tóxico a fungos. (Definição retirada do glossário de biotecnologia, edição de 2005)*

Pesticida: Substância que mata organismos indesejados de modo seletivo. (Definição retirada do glossário de biotecnologia, edição de 2005)

Sementes: Esse grupo é dirigido diretamente à venda de sementes para serem plantadas. A empresa comercializa sementes para as mais diversas culturas, sendo as principais: Soja, milho, algodão, café, vegetais, frutas, cítricos, cana-de-açúcar, tabaco, trigo, entre outros.

Produtos Profissionais (Saúde Pública): Esse grupo se dedica à produção de produtos para o mercado de saúde pública, sendo os principais deles raticidas, inseticidas, além de produtos veterinários.

1.3 – Estrutura da Área de Comercial

O trabalho será realizado apenas na área de proteção de cultivos, que é a área que representa a maior parte do faturamento da empresa. Logo a descrição da estrutura comercial apresentará apenas os componentes referentes à venda de produtos que integram esse grupo.

A área comercial, que será a maior beneficiada pela realização deste projeto, tem como sua central a área administrativa em São Paulo. Abaixo existem 4 filiais (Uberlândia, Campinas, Cuiabá e Londrina). Cada filial é formada por diversas regionais que compõem um total de 25 regionais no Brasil. Cada regional possui seus vendedores que são os responsáveis diretos pela venda de produtos no Brasil. Atualmente a empresa possui aproximadamente 220 vendedores espalhados pelas regionais brasileiras.

Os canais de distribuição que a empresa usa são: vendas diretas, que ocorrem para grandes agricultores que possuem uma grande área plantada e alto poder de barganha; Cooperativas, que geralmente são formadas por agricultores de médio porte e se unem para aumentar seu poder de barganha; Revendedores, que são responsáveis por distribuir os produtos para os pequenos agricultores.

Um organograma da estrutura comercial no Brasil pode ser visto abaixo:

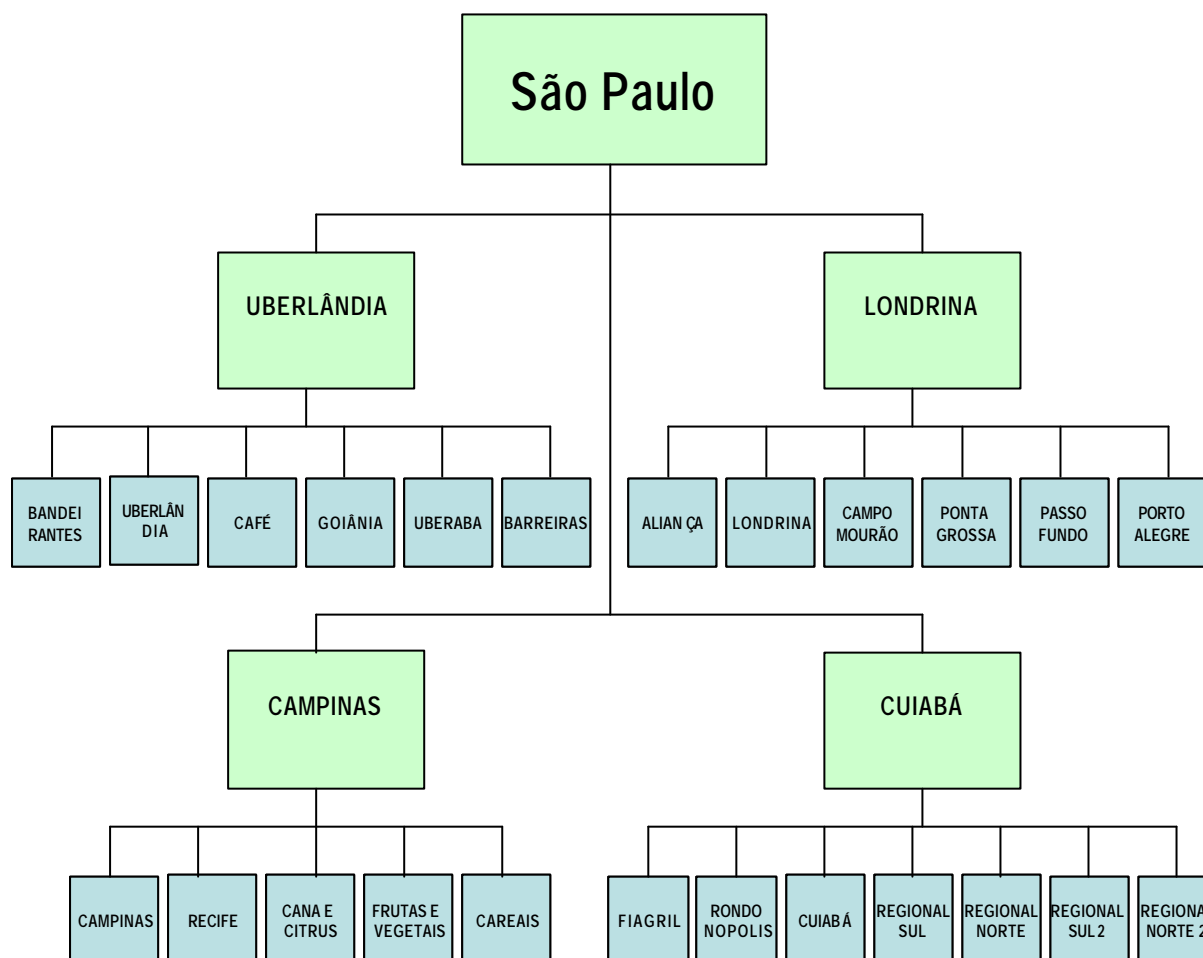


Figura 1: Organograma da Estrutura Comercial
Fonte: Empresa

No organograma acima pode-se observar que as regionais são classificadas de diversas maneiras. A regional pode representar a região em torno de uma determinada cidade, como por exemplo, Goiânia. Outra forma é uma regional representar uma cultura, como por exemplo, a regional “café” na filial de Uberlândia. Uma regional pode ainda representar apenas um produto, como por exemplo, a regional “Fiagril” da filial Cuiabá. E por último uma regional pode representar toda uma parte de uma filial, como por exemplo, a regional sul ou norte da filial de Cuiabá.

2 Problema

O problema identificado na empresa em questão é a não existência de um modelo matemático de previsão de demanda. O modelo atual que será descrito mais a frente é baseado na previsão direta dos vendedores do campo e é ajustada de acordo com o bom senso dos funcionários envolvidos no processo. Atualmente não existe um processo formal que considera o passado de vendas a empresa. O processo atual de previsão de demanda será descrito mais à frente neste trabalho.

Muitos fatores podem influenciar a venda de um produto, e no modelo atual fica muito difícil identificar se esses fatores foram considerados, e se foram, quando foram considerados. Pois é fundamental que o setor comercial que é responsável por fazer os ajustes finais saiba o que foi considerado na formação do número.

Os vendedores da empresa na sua grande maioria não possuem qualificação suficiente para fazerem previsões de demanda, logo usam de sua experiência e conhecimento de seus clientes para gerarem o número, mas muitas vezes isso não basta para gerar um número confiável.

Outro problema a ser considerado é a formação de várias previsões independentes que são somadas pelo departamento comercial em São Paulo antes de começarem os ajustes. Por isso podem existir vários erros de diversos vendedores, que podem gerar previsões baseadas nos próprios interesses, ou realmente cometerem erros de previsão involuntários.

3 Objetivo

O objetivo desse trabalho é desenvolver um modelo de previsão de demanda baseado no histórico de vendas da empresa, e também no estudo de fatores que influenciam a demanda deste mercado. Hoje é fundamental que toda empresa que deseja ser bem sucedida e crescer de forma sustentável, tenha um modelo de previsão de demanda que seja eficiente e adequado ao mercado o qual está inserido.

O modelo será desenvolvido a partir do passado de venda da empresa, levando ainda em consideração fatores fundamentais para a variação da demanda. O estudo será baseado nos principais produtos da empresa, classificados em grupos de acordo com o seu comportamento. Os dados usados neste trabalho serão os reais, porém será usado um coeficiente para respeitar a confidencialidade dos dados, por se tratarem de dados estratégicos para a empresa.

Com um modelo de previsão de demanda matemático, o número gerado será um número mais confiável, porém mesmo com esse modelo o conhecimento de negócio dos funcionários ainda será aproveitado, porém agora baseados em números muito mais confiáveis, além de possuírem total visibilidade do processo de geração da previsão.

Com a implementação do modelo matemático mais adequado é esperado que a empresa consiga aumentar o nível de atendimento, diminuindo o número de pedidos perdidos ou atrasados. Porém esse benefício não virá acompanhado de um aumento de estoques, e sim uma redução dos níveis de produtos estocados, além de reduzir estoques de matéria-prima e de matérias usados em embalagens. Além disso, com esse modelo o vendedor do campo não terá a necessidade de gerar uma previsão, podendo assim dedicar todo seu tempo para vender os produtos da empresa.

4 Metodologia

Será apresentada a metodologia a ser utilizada para o desenvolvimento deste projeto. Até agora a empresa foi apresentada e descrita, assim como o problema e os objetivos deste trabalho. Podemos agora começar a solucionar o problema.

Este projeto pode ser dividido nas seguintes partes:

4.1 – Descrição do mercado

Este capítulo tem como principal objetivo apresentar o mercado no qual a empresa está inserido, para que seja possível determinar os fatores mais importantes que compõem a demanda. Este capítulo apresentará e deixará clara a diferença entre variabilidade inerente ao negócio e eventos que causam flutuações aleatórias, pois ambos são fatores decisivos para se realizar uma previsão de demanda acurada.

4.2 – Apresentação do modelo atual de previsão

Este capítulo tem como principal finalidade a apresentação e detalhamento do modelo usado atualmente na empresa para se realizar a previsão de demanda. Além disso, serão apresentados os pontos fortes e pontos fracos do modelo atual, para que estes sirvam de base para o desenvolvimento do novo modelo.

4.3 – Revisão bibliográfica

Neste capítulo serão estudados diversos modelos de previsões, para que o autor tenha conhecimento e base suficientes para fazer a determinação do modelo a ser adotado para a empresa. Serão estudados modelos quantitativos que se encaixam no objetivo deste trabalho, para que após a análise dos dados seja possível determinar o modelo que mais se identifica com o comportamento da demanda desta empresa.

4.4 – Dados Disponíveis/Seleção dos produtos piloto

Neste capítulo começa a tarefa de se trabalhar com os dados da empresa. Por a empresa possuir muitos tipos de produtos devem-se escolher quais produtos serão estudados. É fundamental que a escolha seja criteriosa, pois estes serão a base para se descobrir a aplicabilidade do modelo na empresa. Uma escolha equivocada nesta etapa pode comprometer todo o trabalho, chegando a um resultado que não represente a realidade da empresa e de todos os produtos. O principal objetivo é encontrar produtos que representem de maneira satisfatória a maioria dos produtos da empresa, além de serem produtos importantes e com base de dados confiáveis.

4.5 – Análise dos produtos piloto

Esta etapa do projeto também é fundamental, pois é aqui que toda a base para a escolha do modelo de previsão será desenvolvida. Através do estudo do comportamento dos produtos piloto. Por se tratar de uma série temporal, todos os componentes desta série devem ser estudados e descobertos, para evitar surpresas nas etapas seguintes, e para garantir a aderência do modelo escolhido aos produtos piloto, e ao resto da empresa.

4.6 – Escolha do modelo a ser utilizado

Nesta etapa o autor já possui conhecimento a respeito dos modelos de previsão existentes, além de saber como os produtos desta empresa se comportam, logo chega o momento onde será determinado qual será o modelo definitivo a ser implementado nesta empresa.

4.7 – Aplicação do modelo

Nesta etapa o modelo selecionado será aplicado aos produtos escolhidos, e os resultados serão comparados com os resultados obtidos pelo modelo atual. Para termos uma real noção sobre a aderência do modelo proposto, e se realmente o modelo proposto é superior ao modelo atual, trazendo benefícios para a empresa no caso de implementação do mesmo.

4.8 – Análise Econômica da Solução

Com os resultados em mãos será a vez de se estimar qual seria o ganho da empresa em termos qualitativos e quantitativos com a adoção do modelo proposto por este trabalho. Podendo nesta etapa serem estimados ganhos com redução de estoque ou aumento de vendas devido a maior disponibilidade de produtos.

5 Descrição do estágio

O aluno ingressou em uma consultoria onde realizou diversos projetos, entre eles foi desenvolvido um projeto com a duração de 6 meses na empresa onde este trabalho está sendo desenvolvido. O objetivo do projeto era a implementação global da ferramenta SAP APO (advanced planner and optimizer), que é uma ferramenta focada na cadeia de suprimentos. Para isso o aluno teve grande visibilidade da cadeia de suprimentos da empresa como um todo, tendo a oportunidade de identificar pontos de melhoria que poderiam ser implementadas. Deve ficar claro que o projeto tinha como objetivo implementar novos processos para a ferramenta APO nos 4 continentes e não em remodelar a previsão de demanda da empresa. As principais atividades desenvolvidas pelo aluno foram suportar toda a equipe, que era composta de consultores e por funcionários da empresa cliente. Com isso o aluno participou do desenho de diversos processos que seriam modificados para a implementação da ferramenta, tanto do processo como era feito e também da solução proposta, após a implementação. O aluno teve a oportunidade de conhecer o modelo de previsão de demanda da empresa, pois os números de previsão que eram colocados em um sistema legado da empresa, passariam a ser colocados e reportados para as diversas áreas envolvidas pela nova ferramenta (APO). Além do modelo de previsão, o aluno conheceu o processo de produção e planejamento da produção da fábrica e também a rede de distribuição dos produtos pela América Latina.

6 Descrição do Mercado

A empresa onde o projeto será desenvolvido atua no mercado de defensivos agrícolas, por isso será apresentado agora uma descrição do mercado agrícola, com a finalidade de entender fatores como tamanho, distribuição no Brasil, taxas de crescimento e também as principais culturas agrícolas cultivadas no Brasil.

Além disso neste capítulo serão apresentados dois conceitos fundamentais para a previsão de demanda nesta empresa, o conceito de variabilidade inerente e o conceito de eventos. Nestes conceitos estão diferenciadas as possíveis causas de flutuação de demanda, ajudando assim a sua possível previsão.

6.1 – O Mercado

Moderno, eficiente e competitivo, o agro-negócio brasileiro é uma atividade próspera, segura e rentável. Com um clima diversificado, chuvas regulares, energia solar abundante e quase 13% de toda a água doce disponível no planeta, o Brasil tem 388 milhões de hectares de terras férteis e de alta produtividade, dos quais 90 milhões ainda não foram explorados. Esses fatores fazem do país um lugar de vocação natural para a agricultura e todos os negócios relacionados à suas cadeias produtivas.

O agro-negócio é responsável por 33% do Produto Interno Bruto (PIB), 42% das exportações totais e 37% dos empregos brasileiros. O PIB do setor chegou a US\$ 180,2 bilhões em 2004, contra US\$ 165,5 bilhões alcançados no ano de 2003. Entre 1998 e 2003, a taxa de crescimento do PIB agropecuário foi de 4,67% ao ano.

O Brasil é um dos líderes mundiais na produção e exportação de vários produtos agropecuários. É o primeiro produtor e exportador de café, açúcar, álcool e sucos de frutas. Além disso, lidera o ranking das vendas externas de soja, tabaco. As projeções indicam que o país também será, em pouco tempo, o principal pólo mundial de produção de algodão e biocombustíveis, feitos a partir de cana-de-açúcar e óleos vegetais. Milho, arroz, frutas frescas, cacau, castanhas, nozes, são

destaques no agro-negócio brasileiro, que emprega atualmente 17,7 milhões de trabalhadores somente no campo.

6.2 – Safra e Entre-safra

O principal ponto a ser destacado neste mercado é a sazonalidade causada pelos períodos de safra e entre-safra, pois todas as culturas agrícolas apresentam seu ciclo produtivo. O período da safra e entre-safra varia de cultura para cultura, e também está fortemente relacionada ao clima da região do plantio. O número de safras por ano também pode variar de cultura para cultura e o período da safra de uma mesma cultura pode variar de ano para ano. Isso é causado principalmente por variações climáticas e pressão de mercado para se adiantar ou se atrasar a safra.

Para o mercado de defensivos agrícolas, sua demanda está fortemente relacionado a essa sazonalidade, porém a sua previsão não é facilitada pois não existem períodos certos para a aplicação de herbicidas, pesticidas e fungicidas. Estes podem ser aplicados em diferentes períodos do ciclo produtivo, dificultando a sua previsão. Além disso como um mesmo defensivo pode ser usado em diferentes culturas agrícolas, a variação da demanda varia de acordo com mais de um período de safra.

6.3 – Distribuição Agrícola no Brasil

O Brasil é um país que apresenta grande diversidade natural, o que causa a existência de muitos tipos de culturas diferentes, e gera grande diferenciação das características dos produtores. Entre as principais culturas existentes no Brasil pode-se destacar a soja, que apresenta a maior quantidade de área plantada do país, com mais de 22 milhões de hectares na safra 2005/2006. Além da soja podemos destacar os cultivos de cana-de-açúcar, milho, café, arroz, feijão, trigo, além de frutas e vegetais em gerais.

A seguir é apresentado um mapa com a distribuição e com a área total plantada das principais culturas no Brasil.

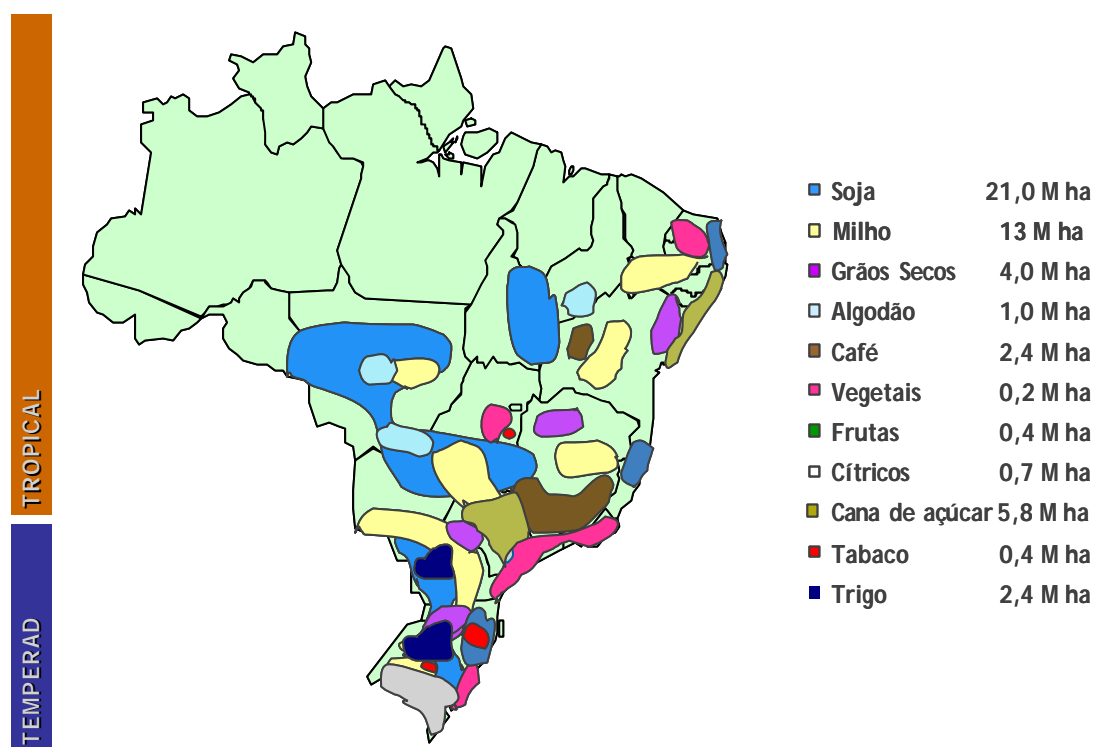


Figura 2: Distribuição e área total das culturas no Brasil
Fonte: Empresa

Podemos assim classificar o país em 3 grandes regiões que apresentam algumas características em comum:




Figura 3: Agrupamento das grandes regiões
Fonte: Empresa

A região 1 apresenta as seguintes características:

- Aproximadamente 25.000 fazendas;
- 70% da área plantada de algodão do Brasil;
- 54% da área plantada de soja do Brasil;
- Grandes produtores;
- 30% dos produtores de soja tem plantações com mais de 5.000 hectares;
- 70 Milhões de hectares cultiváveis disponíveis;
- Investimentos em infra-estrutura ;
- **Mercado = U\$ 1,55 bilhão.**

A região 2 apresenta as seguintes características:

- Aproximadamente 150.000 fazendas;
- 44% da área plantada de milho do Brasil;
- 41% da área plantada de soja do Brasil;
- Produções de multi-culturas;
- Pequenos produtores;
- 95% dos produtores de soja com menos de 200 hectares;
- Produções tradicionais;
- Espaço de terra limitado;
- **Mercado = U\$ 0,9 bilhão.**

A região 3 apresenta as seguintes características:

- Aproximadamente 250.000 fazendas;
 - Safras de alto valor, concentração de safras constantes;
 - Multi-culturas;
 - Pequenos e médios produtores em geral;
 - Combinação de produções convencionais e orientadas para negócio;
-

- Projetos de irrigação (NE);
- Industrias de exportação de frutas;
- **Mercado = U\$ 0,7 bilhão.**

6.5 – Variabilidade Inerente e Eventos

Para o negócio da empresa existem dois tipos de fatores que fazem com que a demanda seja alterada. O primeiro é o conceito de variabilidade inerente, que são efeitos causados por fatores conhecidos e que podem ser previstos. Alguns exemplos de fatores que geram variabilidade inerente ao negócio são o início e o fim das estações, os impactos causados pelos efeitos meteorológicos, ou também períodos de safra e entre-safra. Em todos esses caso é possível saber qual o efeito baseado na história da empresa, por isso são fatores inerentes ao negócio. A variabilidade inerente pode causar tanto aumento quanta diminuição da demanda esperada.

O segundo tipo de fator será chamado de eventos, eventos são fatos aleatórios, que não se repetem periodicamente, por isso são mais difíceis de serem previstos. Geralmente quando se descobre a possibilidade de ocorrência de um evento, não existe grande certeza quanto a sua probabilidade de ocorrência, além de não saber também qual o efeito real desse evento para a demanda. Quando a probabilidade de ocorrência destes eventos entra em níveis aceitáveis, muitas vezes a ocorrência é eminente não sendo possível reagir para o atendimento do mesmo. Um evento pode causar efeitos de alto ou de baixa na demanda, ou seja, ele pode aumentar as vendas da empresa, ou pode diminuir a quantidade de produtos vendidos.

Alguns exemplos de eventos para a empresa podem ser:

- introdução de novos produtos no mercado por concorrentes;
 - Pendência de registros para a introdução de produtos da própria empresa;
 - Iniciativas do marketing não planejadas, ou reativas;
 - Impacto na introdução de genéricos (concorrentes ou da própria empresa);
 - Casos excepcionais de doenças ou resistência à produtos da empresa;
 - Negócio impactado por fatores macro político econômicos.
-

Com isso é fundamental que seja desenvolvido além do modelo de previsão de demanda, um processo para que a ocorrência de eventos seja tratada, para que o efeito desses eventos seja minimizado da melhor e mais eficiente maneira possível. Deve-se criar uma maneira de se prever e medir os efeitos dos eventos, para que a empresa seja capaz de reagir a tempo de não sofrer perdas. Para tratar a variabilidade inerente não será necessário a criação de nenhum processo paralelo, pois por serem efeitos de fatores previsíveis, estes já serão previstos pelo modelo matemático de previsão a ser proposto.

Segue abaixo um gráfico que demonstra os efeitos da variabilidade inerente e dos eventos, tanto de alta quanto de baixa.




Figura 4: Efeito da variabilidade inerente e do eventos
Fonte: Empresa

7 Descrição do Modelo atual de previsão

Para o desenvolvimento de um modelo de previsão de demanda, devemos entender e analisar como este processo vem sendo feito atualmente. Para isso será apresentado o fluxograma do processo atual, junto com uma explicação detalhada de cada atividade desse processo. Com essa análise fica mais fácil identificar quais as mudanças que serão implementadas neste processo. Pois como o objetivo deste trabalho é desenvolver um modelo matemático para a previsão, não será substituído todo o processo de desenvolvimento do número final. Mesmo baseado em estatísticas, para que se obtenha o melhor resultado possível, deve-se também utilizar a experiência dos funcionários da empresa, por isso não iremos substituir todo o processo de previsão, e sim, aprimorá-lo para que se torne mais confiável e eficaz.

Abaixo está o fluxograma do processo atual:




Figura 5: Fluxograma do processo atual de geração da previsão
Fonte: Autor

Como não existe uma ferramenta de previsão de demanda estatística, todos os números durante esse processo são armazenados em um programa em base Access, para que todos tenham maior acesso e agilidade ao trabalharem com esses números.

A primeira etapa desse processo é realizada pelo vendedor, que diretamente com seus clientes, faz o levantamento do inventário final de cada um, para que ele saiba qual foi o consumo no mês. Esse consumo irá ser a base que o vendedor realize a previsão de vendas para o próximo mês.

Com o consumo calculado o vendedor começa a fazer a previsão de consumo para os próximos meses, nesta etapa o vendedor realiza a sua previsão para os próximos quatro meses, levando em consideração o consumo de seu cliente e também a sua meta anual, mesmo que isso implique muitas vezes em aumentar o estoque no canal de distribuição. Assim que esses números estão fechados o vendedor encaminha esses dados para o gerente de sua filial.

A terceira etapa do processo acontece na filial, onde o gerente responsável consolida a previsão de todos os seus vendedores, gerando a previsão de consumo de sua filial. Mas uma vez esse número sofre alterações baseadas no conhecimento do gerente sobre o comportamento dos clientes e das tendências de seus vendedores. Essa previsão também é para os próximos quatro meses. É nesta etapa que o número entra na base Access para que possa ser acessada por São Paulo, onde fica o escritório central.

A quarta etapa do processo é muito parecida com a terceira, a diferença é o nível em que ocorre a consolidação, pois agora o gerente da filial, consolida os números que recebe dos gerentes da regionais. Esse número pode sofrer novamente alterações baseadas no conhecimento dos funcionários responsáveis pela filial. Nesta etapa é gerada uma previsão de três meses. Ao se finalizar esta etapa, o número será apenas tratado pelos funcionários do escritório central de São Paulo.

A quinta etapa ocorre no escritório de São Paulo, os gerentes de produto, que são responsáveis por determinados produtos, consolidam a previsão das filiais, para que pela primeira vez seja criado um número de previsão para o Brasil. Nesta etapa a adequação do número ocorre baseado em mais fatores, entre eles podemos destacar o conhecimento do negócio, a meta de crescimento do produto, planos de marketing, pois é a primeira vez no processo, que a pessoa que faz a previsão tem visibilidade das ações de outras áreas da empresa que podem afetar de alguma maneira a venda.

Com o encerramento da etapa anterior, o número deixa de ser responsabilidade de apenas um área da empresa, passando agora por reuniões onde participam outras áreas. A sexta etapa

envolve uma reunião entre três áreas, a área comercial, marketing e a área de supply. Nesta reunião são discutidos os números e os valores para cada produto, mês a mês para o Brasil. Com isso as três áreas acordam um número final. Esse número leva em consideração fatores relativos ao marketing, que podem ser as iniciativas para aumento de venda, ou entrada de novos produtos no mercado. Fatores de supply, que consideram a disponibilidade de ingrediente ativo, que é o principal componente do produto, esta matéria-prima é importada e por isso possui maior tempo de aquisição. Esta etapa realiza a previsão para o ano todo, gerando doze meses de previsão.

8 Revisão Bibliográfica

8.1 – Importância da Previsão

O processo de previsão de demanda pode ser considerado uma das atividades mais importantes de uma empresa. Assim, constitui a base do processo de planejamento. De acordo com Arnold (1999), o processo em questão configura-se no prelúdio do planejamento.

De acordo com Makridakis; Wheelwright; Hyndman (1998), freqüentemente existe um intervalo (lead-time) entre o momento em que um evento se torna conhecido e a realização do mesmo. Esse lead-time é a principal razão para se planejar e prever. Se esse lead-time for muito pequeno ou zero, não existe a necessidade de se realizar uma previsão. Se o lead-time é longo, o planejamento e a previsão tem um papel muito importante, pois em tais situações a previsão poderá determinar quando o evento irá ocorrer, assim as medidas apropriadas poderão ser tomadas a tempo.

Podemos caracterizar o lead-time citado por Makridakis; Wheelwright; Hyndman (1998), em três grupos principais: Curto prazo, Média prazo e Longo prazo. Previsões de curto prazo podem ser exemplificadas por decisões de produção, para evitar diminuição no nível de serviço, sabendo o que produzir e quando produzir. O médio prazo pode se caracterizar como decisões que envolvam importação ou exportação, por um modal de transporte que tenha um lead-time de entrega elevado, como por exemplo o marítimo. Então compras de produtos importados ou vendas necessárias para suprir um mercado externo podem ser considerados previsões de médio prazo. Já previsões de longo prazo podem ser caracterizadas como investimentos em ampliação ou entrada em novas áreas de negócio.

Deve ficar claro que quanto maior o horizonte de previsão, maior é a sua dificuldade, diminuindo a sua precisão, aumento o erro. A seguir serão explicados alguns modelos de erros de previsão.

Segundo Makridakis; Wheelwright; Hyndman (1998), Existem cinco passos básicos em qualquer processo de previsão onde dados quantitativos estejam disponíveis.

Passo 1: Definição do Problema - Esta muitas vezes pode ser a tarefa mais difícil do processo, pois necessita de entendimentos sobre como a previsão será usada, quem necessita da previsão e como esse processo irá se integrar à organização.

Passo 2: Coleta de Informação – Existem dois tipos de informação disponível; dados estatísticos que são geralmente numéricos e conhecimento e expertise dos funcionários chave para o processo.

Passo 3: Análise Preliminar – Nesta etapa verificamos os dados para interpretá-los de uma maneira correta, encontrando comportamentos e padrões dos dados.

Passo 4: Escolhendo o Modelo Ideal – Com a análise preliminar limitamos as opções de modelos que são viáveis para o nosso problema, assim nesta etapa definimos o modelo que melhor se encaixa ao problema.

Passo 5: Usar e Avaliar o Modelo Escolhido – Com o modelo escolhido as previsões serão feitas e os usuários dessa previsão poderão avaliar os prós e contras do modelo em questão. O modelo só pode ser avaliado apropriadamente após que o dado do período previsto esteja disponível.

8.2 – Maneiras de medir o erro da previsão

Agora começaremos a tratar um conceito fundamental para a previsão, que seria medir a precisão de um modelo de previsão para uma série de dados. A precisão pode ser definida por quão preciso o modelo de previsão pode reproduzir os dados já conhecidos. Baseado nos erros pode-se descobrir e sanar anormalidades no processo, além de ser de grande importância para a escolha do método a ser implementado. Seguindo essa definição podemos considerar o erro da previsão como sendo:

$$e_t = Y_t - F_t \quad (8.1)$$

Onde Y é o dado observado e F o resultado da previsão, ambos dados para um período t. Dessa maneira pode-se calcular o erro para cada período, agora apresentarei modos de calcular o erro médio de mais de um período.

Erro Médio - Mean Error (ME)

O erro médio é calculado pela média aritmética dos erros dos períodos, este erro tende a ser pequeno, uma vez que os erros positivos acabam compensando os erros negativos, o que pode distorcer o resultado. Porém esse método pode mostrar se existe erro de viés no modelo de previsão. A fórmula do erro médio é apresentada abaixo:

$$ME = \frac{1}{n} \sum_{t=1}^n e_t \quad (8.2)$$

Erro Absoluto Médio – Mean Absolute Error (MAE)

Esse erro usa o valor absoluto dos erros para se calcular a média, evitando assim o problema apresentado no erro médio. A fórmula é apresentada abaixo:

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (8.3)$$

Erro Quadrático Médio – Mean Squared Error (MSE)

Neste modelo o problema de cancelamento de valores é superado calculando-se o quadrado de todos os valores dos erros. A fórmula é apresentada abaixo:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (8.4)$$

Erro Percentual – Percentage Error (PE)

Ao calcularmos o erro de maneira absoluta, não podemos fazer muitas comparações, se não soubermos qual o volume total que está sendo previsto. Pois um erro de 10 é relativamente pequeno se estamos tratando um volume de 1000, porém seria elevado para um volume de 50. Por isso calculamos o erro percentual, para evitar problemas de interpretação. Uma dificuldade que pode ocorrer neste modelo seria caso a série de dados contenha valores nulos, pois não é possível realizar o calculo percentual. A fórmula do erro percentual é apresentada abaixo:

$$PE_t = (Y_t - F_t / Y_t) \times 100 \quad (8.5)$$

Erro Percentual Médio – Mean Percentage Error (MPE)

É a média aritmética dos erros percentuais, mais uma vez valores positivos e negativos podem se anular, ditrocendo o resultado. A fórmula é apresentada a seguir:

$$MPE = \frac{1}{n} \sum_{t=1}^n Pe_t \quad (8.6)$$

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

É a média aritmética do módulo dos erros percentuais:

$$MAPE = \frac{1}{n} \sum_{t=1}^n |Pe_t| \quad (8.7)$$

Erro de Viés

Um tipo de erro que pode ocorrer em previsões é o erro de viés, que é caracterizado por ser um erro sistemático ou sempre positivo, ou sempre negativo. Para identificar se existe esse erro, e qual a sua magnitude, pode ser usado a estatística de Durbin-Watson. O teste de Durbin-Watson para de descobrir se existe correlação serial (viés) entre os erros, é baseada no método dos mínimos quadráticos ordinários e é apresentada pela seguinte fórmula:

$$DW = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (8.8)$$

A interpretação dos resultados é feita pelo valor de DW, para valores maiores que 2 o viés é negativo, já para valores menores que 2 o viés no caso é positivo e caso os valores fiquem muito próximo de 2, pode-se considerar que não existe viés.

8.3 – Métodos Qualitativos de Previsão de Demanda

Primeiramente serão apresentados os métodos qualitativos de previsão de demanda, nestes modelos não são usados dados numéricos como referência e sim o conhecimento e experiência das pessoas envolvidas no processo.

Esses métodos são mais utilizados para realizarem previsões de horizonte mais acentuado, como por exemplo, os investimentos que uma empresa irá realizar no futuro. Por isso eles são mais utilizados juntamente com outros métodos, com uma função principalmente de suporte á decisões. Um ponto fraco dos modelos qualitativos é a difícil mensuração de sua eficiência.

Os principais métodos qualitativos são:

- Pesquisa de Mercado
- Método Delphi
- Painel de Especialistas
- Analogia Histórica

Pesquisa de Mercado: O levantamento de dados é feito através de questionários e entrevistas. Os fatores mais relevantes para os clientes são levantados, as pesquisas são individuais, e a análise é feita agrupando-se todas as respostas obtidas. Pode ser mais eficiente para empresas que possuem poucos clientes. Este método apresenta menor confiabilidade, pois está suscetível a erros de interpretação e orientação. Por causa da estrutura necessária para se realizar um pesquisa confiável, esse modelo pode apresentar custo elevado e longo período de execução.

Método Delphi: Esse método é usado para se obter o consenso dentro de um comitê. Por esse método, os executivos respondem anonimamente a uma série de perguntas em turnos sucessivos. Cada resposta é repassada a todos os participantes em cada turno, e o processo é então repetido. Até seis turnos podem ser necessários antes que se atinja o consenso sobre a previsão. Esse método pode resultar em previsões com as quais a maioria dos participantes concordou apesar de ter ocorrido uma discordância inicial. Com este método o resultado é mais preciso, não apresentando viés. Porém mais uma vez o tempo de execução pode ser longo, baseado nos números de iterações necessárias.

Painel de Especialistas: Este método segue a linha do método delphi, onde é formado um comitê, porém desta vez existe interação entre os membros deste comitê. Geralmente esse comitê é formado por executivos de diferentes áreas da corporação, para que existem diferentes visões e percepções do mesmo assunto, e para que todas as consequências sejam consideradas. Esse método é consideravelmente mais rápido que os anteriores, porém o resultado pode sofrer forte influencia das características pessoas dos participantes, como o poder de persuasão, prestígio e liderança.

Analogia Histórica: Esse método une a estimativa de vendas futuras de um produto ao conhecimento das vendas de um produto similar. O conhecimento das vendas de um produto durante várias etapas de seu ciclo de vida é aplicado à estimativa de vendas de um produto similar. Esse método pode ser especialmente útil na previsão de vendas de novos produtos, além de apresentar um custo relativamente baixo.

8.4 – Métodos Quantitativos

Os métodos quantitativos são métodos que se baseiam em dados numéricos para realizarem a previsão.

Podemos classificar os métodos quantitativos em dois grupos: Métodos de séries temporais e Métodos Causais.

Métodos de séries temporais: Nestes métodos o objetivo é ajustar um modelo matemático a uma série temporal. Uma das premissas básicas destes modelos é que o comportamento da demanda no futuro seguirá os mesmos padrões das do passado. São chamados de modelos univariados, pois são levados em consideração para a previsão uma variável, o tempo. Sendo assim esses modelos são adequados para previsões de curto prazo.

Métodos Causais (correlação): Nestes métodos é analisado o efeito de uma ou mais variáveis independentes no comportamento da variável que se deseja prever (dependente). A premissa básica a ser considerada é que a relação entre essas variáveis serão as mesmas no futuro. Estes métodos são mais adequados para previsões de longo prazo.

Séries Temporais

Segundo Makridakis; Wheelwright; Hyndman (1998), podemos decompor a demanda em quatro componentes distintos, que são de importância essencial para a escolha do modelo mais adequado:

Tendência: Consiste em um movimento gradual de longo prazo, direcionando os dados de maneira crescente ou decrescente.

Ciclicidade: Demonstra oscilações ou movimentos para cima e para baixo ao longo da série, porém se período de tempo definido.

Sazonalidade: A sazonalidade refere-se a mudanças ou variações cíclicas de curto prazo, se repetindo de maneira regular. Makridakis (1998), afirma ainda que um padrão sazonal existe quando a série temporal é influenciada por um fator sazonal.

Irregularidade: são alterações na demanda passada resultantes de fatores excepcionais, que não podem ser previstos e, portanto, incluídos no modelo.

8.4.1 – Método da Média Móvel Simples

Esse método consiste em calcular a média das últimas N observações, sendo o valor encontrado considerado a previsão para o próximo período. O método em questão gera previsões médias com menor variabilidade que os dados originais. Isso ocorre devido ao processo de combinação entre as observações com valores altos e com valores baixos.

Segundo Makridakis (1998), o termo móvel vem da possibilidade de a cada nova previsão feita, o dado mais antigo é descartado e o mais novo é considerado. Além disso, Makridakis sugere que deve ser utilizado um maior número de amostras quando a maioria dos dados for aleatório e no caso de existência de tendência ou sazonalidade deve-se descartar os dados mais antigos, se trabalhando apenas com os dados mais recentes. Para casos de sazonalidade ainda existe a opção de se trabalhar com períodos de tempo que equivalem ao período de sazonalidade.

A expressão matemática que representa este modelo é:

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i$$

(8.9)

Nesta fórmula, k seria o número de períodos a serem considerados na média. Esta fórmula confere pesos iguais para todos os períodos. O valor Y é o valor da observação em um dado período, e o valor F é o valor da previsão para o período $t+1$.

Para Makridakis (1998), a acurácia deste modelo geralmente é baixa, além disso o número de dados a serem armazenados pode ser alto, variando de acordo com o número de séries a serem previstas e do número de períodos necessários para se calcular a média por série.

8.4.2 – Método da Suavização Exponencial Simples

A suavização exponencial pode ser considerada uma extensão do método da média móvel. A diferença fundamental, é que a suavização leva em consideração ponderações diferentes para os dados utilizados. Os dados mais recentes recebem maior ponderação, enquanto os mais antigos menores ponderações. Isso deriva da premissa de que os dados mais recentes fornecem informações mais precisas sobre o padrão de comportamento futuro.

Este método pode ser representado pela seguinte equação:

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (8.10)$$

O valor da constante de suavizamento α varia entre 0 e 1.

Segundo Makridakis (1998), a nova previsão pode ser vista como a soma da antiga previsão com um ajuste para o erro que ocorreu na previsão passada. Quando α ficar perto de 1, a nova previsão terá um ajuste substancial para o erro ocorrido na previsão passada, logo se o valor ficar perto de 0, esse ajuste será muito pequeno.

Uma outra maneira de se expressar essa equação é:

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (8.11)$$

Onde Y é o valor real verificado no período t , e a variável F é a previsão para os períodos t e $t+1$.

Este método possui este nome, pois os pesos atribuídos são calculados baseados em uma tendência exponencial. Assim o dado mais recente recebe um peso a , a próxima recebe um peso $a(1-a)$, a seguinte recebe o peso $a(1-a)^2$, seguindo a lógica a próxima seria $a(1-a)^3$ e assim por diante.

Para Makridakis (1998), este método soluciona o problema do armazenamento de dados, uma vez que só é necessário armazenar o valor de algumas previsões passadas, a observação recente e também o valor de a .

8.4.3 – Método da Suavização Exponencial Simples com Taxa de Resposta Adaptativa

Um problema para a suavização exponencial é a definição da constante a , logo um método que não necessite dessa definição teria uma vantagem. No modelo com taxa de resposta adaptativa o valor da constante a varia a cada nova observação, essa mudança ocorre quando existe alguma alteração no comportamento dos dados. Essa característica se mostra atrativa quando é necessária a previsão de centenas de itens.

Este método pode ser representado pela seguinte equação:

$$F_{t+1} = \alpha_t Y_t + (1 - \alpha_t) F_t \quad (8.12)$$

A equação básica deste método é similar ao do método da suavização exponencial, porém:

$$\alpha_{t+1} = \left| \frac{A_t}{M_t} \right| \quad (8.13)$$

sendo,

$$\text{(Erro suavizado)} \quad A_t = \beta E_t + (1 - \beta) A_{t-1} \quad (8.14)$$

$$\text{(Erro suavizado absoluto)} \quad M_t = \beta |E_t| + (1 - \beta)M_{t-1} \quad (8.15)$$

$$\text{(Erro da previsão)} \quad E_t = Y_t - F_t \quad (8.16)$$

Nesta equação β é um parâmetro de valor entre 0 e 1.

Pode-se notar pelas equações que a previsão para o próximo período nada mais é do que uma combinação linear entre a observação e a previsão do período anterior.

8.4.4 – Método da Suavização Exponencial Linear com um Parâmetro – Método de Brown

Quando é evidente a presença de uma tendência linear na série temporal, os métodos de média móvel são menos eficientes. Uma maneira de solucionar este problema seria estender a técnica de suavização exponencial simples para uma suavização exponencial dupla. O método de Brown é utilizado para séries temporais que apresentam tendência linear. O funcionamento lógico do método é o seguinte: Como os resultados obtidos pela suavização linear simples e dupla são diferentes do real quando existe uma tendência, a diferença entre eles poderá ser adicionada ao valor da suavização simples, para que esta seja ajustada de acordo com a tendência.

A série exponencial simples é dada por:

$$S_{t+1} = \alpha Y_{t+1} + (1 - \alpha)S_t \quad (8.17)$$

Já a série exponencial dupla é dada por:

$$S'_{t+1} = \alpha S_{t+1} + (1 - \alpha)S'_t \quad (8.18)$$

E novamente α é a constante de suavização que pode assumir valores entre 0 e 1.

Os valores usados para o ajuste do modelo são calculados por

$$a_t = 2S_t - S'_t \quad (8.19)$$

$$b_t = \frac{\alpha}{1-\alpha}(S_t - S'_t) \quad (8.20)$$

Finalmente:

$$F_{t+m} = a_t + b_t m \quad (8.21)$$

O valor da variável m é referente ao número de períodos a frente a ser previsto.

Com isso na equação final (8.21) podemos observar que o valor previsto é composto de dois componentes, a que é o valor do ajuste e b que representa a tendência presente na série temporal.

8.4.5 – Método Linear de Holt

O método de Holt é o método da suavização exponencial linear com dois parâmetros. Também usado para séries temporais que apresentam tendência. A diferença deste método para o método de Brown é que o método de Holt suaviza os valores da tendência diretamente, sem a necessidade de uma segunda série exponencial. Essa suavização é feita diretamente com o auxílio de duas constantes de suavização e três equações:

$$L_t = \alpha Y_t + (1-\alpha)(L_{t-1} + b_{t-1}) \quad (8.22)$$

Segundo Makridakis (1998), O valor de L_t é a estimativa do nível da série no período t . Então este valor é ajustado somando o ultimo valor suavizado com L_{t-1} com a tendência passada b_{t-1} .

$$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1} \quad (8.23)$$

A segunda equação possui a constante β que elimina uma possível aleatoriedade. Essa equação representa a estimativa da tendência, por meio da diferença entre os dois últimos valores que foram suavizados.

Por fim temos o valor da previsão que é dado por,

$$F_{t+m} = L_t + b_t m \quad (8.24)$$

8.4.6 – Método Linear de Winters

O método de Winters é o método da suavização exponencial linear com três parâmetros. Esse método pode ser usado para séries temporais que apresentam tanto tendência como comportamento sazonal. Assim Winters estendeu o método de Holt acrescentado mais um parâmetro, para que seja possível estimar o componente sazonalidade da série temporal.

Segundo Makridakis (1998), existem dois métodos de diferentes de Winters, dependendo de como a sazonalidade é modelada, podendo ser multiplicativa ou aditiva. Sendo que a única diferença destes modelos é a atuação dos índices sazonais.

As equações do método multiplicativo são apresentadas a seguir:

$$\text{Nível:} \quad L_t = \alpha(Y_t / S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8.25)$$

$$\text{Tendência:} \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8.26)$$

$$\text{Sazonalidade:} \quad S_t = \gamma(Y_t / L_t) + (1 - \gamma)S_{t-s} \quad (8.27)$$

$$\text{Previsão:} \quad F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (8.28)$$

Onde,

s – É o intervalo de sazonalidade;

L_t – Representa o nível da série temporal;

B_t – Estimativa da Tendência ;

S_t – É o componente sazonal;

F_{t+m} – Previsão para m períodos futuros;

α , β e γ – Constantes de suavização, com valor entre 0 e 1.

De acordo com Makridakis (1998), a equação (8.27) pondera o mais recente fator sazonal. A equação (8.26), ao seu tempo, é igual a equação (8.23) do método linear de Holt. Por fim, a equação (8.25) difere-se da equação (8.22) do método linear de Holt pelo fato do primeiro termo ser dividido pelo número sazonal S_{t-s} . Esse procedimento acontece para eliminar flutuações sazonais de Y_t .

Já as Equações do método aditivo são:

$$\text{Nível:} \quad L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8.29)$$

$$\text{Tendência:} \quad b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8.30)$$

$$\text{Sazonalidade} \quad S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (8.31)$$

$$\text{Previsão:} \quad F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (8.32)$$

Podemos perceber que a única diferença entre os dois métodos está relacionada aos índices sazonais, no métodos aditivo, estes são somados e divididos, enquanto que no multiplicativo os mesmos são multiplicados e divididos.

8.4.7 – Classificação de Pegels

Segundo Makridakis (1998), quando se utiliza métodos exponenciais que trabalham com tendência e sazonalidade, torna-se importante determinar se os mesmos devem ser aditivos (lineares) ou multiplicativos (não-lineares). Para tanto, a classificação de Pegels fornece uma estrutura com o intuito de discutir e solucionar esta questão.

Através da classificação de Pegels pode-se apresentar as nove equações referentes aos métodos exponenciais. Para Makridakis (1998), as mesmas podem ser descritas mediante o uso das seguintes equações:

Nível:
$$L_t = \alpha P_t + (1 - \alpha) Q_t \quad (8.33)$$

Tendência:
$$b_t = \beta R_t + (1 - \beta) b_{t-1} \quad (8.34)$$

Sazonalidade
$$S_t = \gamma T_t + (1 - \gamma) S_{t-s} \quad (8.35)$$

Onde,

s – É o intervalo de sazonalidade;

L_t – Representa o nível da série temporal;

B_t – Estimativa da Tendência ;

S_t – É o componente sazonal;

α , β e γ – Constantes de suavização, com valor entre 0 e 1.

Nas equações acima, os valores apropriados de P, Q, R e T, bem como as previsões para m períodos à frente, são demonstrados no tabela abaixo:

		Componente Sazonal		
		Nenhum 1	Aditivo 2	Multiplicativo 3
Componente Tendência	Nenhum A	$L_t = \alpha Y_t + (1 - \alpha)L_{t-1}$ $F_{t+m} = L_t$	$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)L_{t-1}$ $S_t = \gamma(Y_t L_t) + (1 - \gamma)S_{t-s}$ $F_{t+m} = L_t + S_{t+m-s}$	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)L_{t-1}$ $S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$ $F_{t+m} = L_t S_{t+m-s}$
	Aditivo B	$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1})$ $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ $F_{t+m} = L_t + mb_t$	$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$ $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ $S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$ $F_{t+m} = L_t + mb_t + S_{t+m-s}$	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$ $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ $S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$ $F_{t+m} = (L_t + mb_t)S_{t+m-s}$
	Multiplicativo C	$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} b_{t-1})$ $b_t = \beta \frac{L_t}{L_{t-1}} + (1 - \beta)b_{t-1}$ $F_{t+m} = L_t b_t^m$	$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} b_{t-1})$ $b_t = \beta \frac{L_t}{L_{t-1}} + (1 - \beta)b_{t-1}$ $S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$ $F_{t+m} = L_t b_t^m + S_{t+m-s}$	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} b_{t-1})$ $b_t = \beta \frac{L_t}{L_{t-1}} + (1 - \beta)b_{t-1}$ $S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$ $F_{t+m} = L_t b_t^m S_{t+m-s}$

Tabela 1: Classificação de Pegels.

Fonte: MAKRIDAKIS, S.; WHEELWRIGHT, S. C. & HYNDMAN, R.J. Forecasting: methods and applications. 3ª ed. John Wiley & Sons, 1998.

8.4.8 – Método de Box-Jenkins

Os modelos de Box-Jenkins, genericamente conhecidos por ARIMA (*Auto Regressive Integrated Moving Averages*) e na literatura em português por Auto-regressivos Integrados de Médias Móveis, são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões. Os modelos ARIMA resultam da combinação de três componentes denominados “filtros”: o componente auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em vários modelos como:

Modelos estacionários: Modelos estacionários são aqueles que assumem que o processo está em “equilíbrio”. Um processo é considerado fracamente estacionário se sua média e variância se mantêm constantes ao longo do tempo e a função de autocovariância depende apenas da defasagem entre os instantes de tempo. Um processo é fortemente estacionário se todos os momentos conjuntos são invariantes a translações no tempo.

Modelos não-estacionários: Quando uma série temporal apresenta média e variância dependentes do tempo, é porque ela não é estacionária. A não-estacionariedade de uma série implica que: a) há inclinação nos dados e eles não permanecem ao redor de uma linha horizontal ao longo do tempo e/ou b) a variação dos dados não permanece essencialmente constante sobre o tempo, isto é, as flutuações.

Modelos Sazonais: Os modelos ARIMA exploram a autocorrelação entre os valores da série em instantes sucessivos, mas quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidade s . Os modelos que contemplam as séries que apresentam autocorrelação sazonal são conhecidos como SARIMA.

Etapas da Metodologia Box-Jenkins

A construção dos modelos Box-Jenkins é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com base nos próprios dados. São três as etapas para construção do modelo:

Identificação: consiste em descobrir qual dentre as várias versões dos modelos de Box-Jenkins, sejam eles sazonais ou não, descreve o comportamento da série. A identificação do modelo a ser estimado ocorre pelo comportamento das funções de autocorrelações e das funções de autocorrelações parciais. Outros detalhes referentes à obtenção dessas funções e a quais comportamentos representam os modelos anteriormente abordados podem ser pesquisados em Makridakis

Estimação: consiste em estimar os parâmetros do componente auto-regressivo, do componente de médias móveis e da variância.

Verificação: consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados.

Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. Um procedimento muito utilizado é identificar não só um único modelo, mas alguns modelos que serão então estimados e verificados. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de Box-Jenkins, que constitui o objetivo principal da metodologia que é realizar previsões.

Modelos causais

Diferentemente dos modelos de séries temporais, os modelos causais tem como premissa que a variável a ser prevista apresenta uma relação de causa e efeito com uma ou mais variáveis independente.

Com isso podemos esses modelos estabelecem um relacionamento entre as variáveis para que se possa prever o comportamento desejado, além disso deve-se considerar que a relação entre variáveis vai se manter constante ao longo do tempo, para que o modelo seja usado de maneira eficiente.

8.4.9 – Regressão Linear Simples

Como o próprio nome diz esse modelo faz a correlação entre duas variáveis (simples), tentando relacioná-las de forma a expressar uma reta (linear). Ou seja, expressar a variável dependente Y em função de uma variável independente X, a equação pode ser vista abaixo:

$$Y = a + bX \quad (8.36)$$

Os coeficientes a e b que estão contidos na expressão acima, serão definidos pelo método dos mínimos quadrados. O objetivo desse método é expressar a reta que melhor defina a correlação entre as variáveis envolvidas, com isso os valores de a e b serão tais que minimizem a somatória do quadrado da distancia vertical entre os pontos e seu respectivo correspondente na reta formada. Expressão que pode ser vista abaixo:

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (8.37)$$

onde,

Y_t – Valor real de Y para o período t

\hat{Y}_t – Valor estimado pela equação no período t

O método quadrático é usado para que distancias positivas e negativas não se anulem, pois sem esse recurso poderíamos chegar a uma conclusão de que a somatória das distancias é mínima, mas na verdade os pontos só estariam distribuídos de maneira igualitária para cima e para baixo da reta. Assim o resultado não é distorcido.

Para se calcular o valor dos parâmetros de regressão a e b, podemos usar as formulas abaixo.

$$b = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (8.38)$$

A expressão do parâmetro b é mostrado primeiro pois este parâmetro é necessário para o calculo de a.

$$a = \bar{Y} - b\bar{X} \quad (8.39)$$

O modelo de regressão é baseado na correlação entre duas variáveis. Portanto é importante medir o coeficiente de correlação entre as duas variáveis. Esse coeficiente assume valores que variam entre -1 e 1. Valores próximos de 0 indicam pouca ou nenhuma correlação. Já valores próximos de -1 ou 1 indicam forte correlação, para valores positivos dizemos que as variáveis estão positivamente relacionadas, o que significa que com o aumento de uma ocorre o aumento da outra. Portanto valores negativos indicam que existe o relacionamento negativo, que acontece quando ao aumentar uma variável existe diminuição da outra.

Segundo Makridakis (1998), deve-se tomar cuidado, pois para amostras com poucas observações o valor do coeficiente de correlação se torna instável, além disso caso exista na amostra uma observação que esteja muito distante das outras (outlier), seria suficiente para prejudicar a medição do coeficiente.

O coeficiente de correlação pode ser calculado pela seguinte fórmula.

$$r_{xy} = \frac{n \sum XY - (\sum X)(\sum Y)}{\sqrt{n \sum X^2 - (\sum X)^2} * \sqrt{n \sum Y^2 - (\sum Y)^2}} \quad (8.40)$$

Elevando-se r ao quadrado obtemos o coeficiente de determinação, segundo Makridakis (1998), esse coeficiente é o quadrado da correlação entre a variável a ser prevista e o valor previsto, e a razão para ser apresentada elevada ao quadrado é que este coeficiente também pode ser interpretado como sendo a proporção da variação em Y que pode ser explicada por X. Assim esse coeficiente pode ser expresso por:

$$R^2 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \quad (8.41)$$

8.4.10 – Regressão Linear Múltipla

Podemos entender a regressão simples, apresentada anteriormente como uma variação da regressão múltipla, onde existe apenas uma variável independente. Na regressão múltipla podem existir mais de uma variáveis independentes. Sendo assim podemos representar este modelo pela equação:

$$Y_i = b_0 + b_1 X_{1,i} + b_2 X_{2,i} + \dots + b_k X_{k,i} \quad (8.42)$$

Nesta equação os valores de $X_{1,i}$, $X_{2,i}$, ..., $X_{k,i}$ são a i -ésima observação das variáveis independentes.

Os valores dos coeficientes são calculados usando a mesma lógica do modelo simples, onde se busca minimizar a soma dos erros quadráticos. Vale lembrar que este também é um modelo linear, ou seja tenta relacionar as variáveis de forma a expressar uma reta.

Neste modelo o cálculo de índice de correlação é mais extenso pois deve-se calcular este índice para cada par de variáveis possível. Com isso será montada uma matriz de correlação. Nesta matriz serão apresentados todos os índices de correlação tanto para variáveis dependentes e independentes. Analisando esta matriz, fica possível determinar se existe relação da variável Y com as variáveis X e também entre as variáveis X . O modo de se calcular o índice é o mesmo do modelo passado, usando exatamente a mesma equação.

É muito importante analisar a relação das variáveis independentes entre si, pois pode ocorrer a multicolinearidade, que acontece quando estas variáveis estão fortemente relacionadas. A existência de multicolinearidade faz com que os valores encontrados para os coeficientes de regressão não sejam confiáveis, prejudicando o resultado da previsão. Duas soluções são propostas, a primeira seria a exclusão de uma das variáveis do modelo, pois ambas explicam a variável dependente da mesma maneira. A segunda solução seria a criação de uma nova variável independente a partir das duas variáveis independentes.

9 Dados Disponíveis e Seleção dos produtos piloto.

9.1 – Dados Disponíveis

Os dados disponíveis para a realização deste trabalho, são dados confidenciais, fundamentais para a estratégia da empresa em questão. Por essa razão iremos usar alguns artifícios para camuflar os dados, de uma maneira que não distorça o resultado alcançado e ao mesmo tempo mantenha a confidencialidade dos mesmos. Assim um fator multiplicativo será aplicado a todos os dados para que a proporção seja mantida. Esse critério foi adotado, pois o que importa para a análise é a proporção, sendo assim os dados não perderão sua validade. Outro ponto importante para se manter a confidencialidade envolve o nome dos produtos, estes serão chamados por nomes genéricos, não utilizando em momento algum seus nomes comerciais.

Para a realização deste trabalho temos o histórico de vendas de todos os produtos da empresa comercializados no Brasil desde 2002. Os dados mais recentes, para o ano de 2006, não foram cedidos por motivo de confidencialidade. Por isso o intervalo de dados disponíveis vai de janeiro de 2002 até fevereiro de 2006. Sendo sem dúvida uma amostra suficientemente grande para o desenvolvimento de um modelo confiável.

O número de produtos disponíveis para a análise é em torno de 220 aproximadamente, sendo dos mais variados tipos de produtos. Iremos focar o trabalho nos tipos herbicidas, fungicidas e pesticidas. Porém nem todos os produtos apresentam histórico completo, desde 2002, muitos deles são produtos novos, que foram criados em 2003, 2004 e 2005, sendo assim teremos uma amostra menor de produtos que apresentam vendas desde 2002. Este ponto será analisado mais à frente.

Isso faz com que a escolha do modelo a ser aplicado seja baseada em séries temporais, excluindo os modelos causais de previsão de demanda. Pois não temos variáveis suficientes para determinarmos possíveis correlações.

Além do histórico de venda, foram disponibilizados dados confidenciais, como custo, preço e margem dos produtos. Estes dados são médias referentes ao ano passado e serão fundamentais

para a escolha dos produtos pilotos, que serão a base para a escolha e teste do modelo. Pois os produtos modelo devem ser produtos importantes para a empresa, tanto em volume como em faturamento, e ao mesmo tempo devem ser representar bem a maioria dos produtos.

Além destes dados foram cedidas as previsões feitas para os anos de 2004 e 2005 pela empresa, sabemos assim qual foi a margem de erro, sendo possível uma futura comparação entre o modelo desenvolvido e o atual. Pois para o ano de 2005, podemos simular o novo modelo com os dados dos anos passados e comparar com o modelo atual, e como sabemos quais foram as vendas para este ano, saberemos quais as vantagens trazidas pelo modelo a ser desenvolvido. Este fato é muito importante, pois em algum momento do trabalho será fundamental prever valores de venda para 2005 com o modelo desenvolvido, por isso é importante que os produtos escolhidos tenham histórico de venda completo, desde 2002.

9.2 – Metodologia para escolha dos produtos piloto

Começaremos a classificar os 220 produtos disponíveis, para que possamos escolher os produtos que serão a base para os testes do modelo a ser implementado. É importante ressaltar que dentre os 220 produtos, existem produtos com a mesma composição química, mas que são vendidos em embalagens diferentes, com volumes diferentes. Essa é uma estratégia adotada pela empresa, que faz a previsão separadamente de dois produtos iguais, mas que apresentam mais de uma embalagem. Como o objetivo deste trabalho é desenvolver um modelo de previsão que se adapte a realidade da empresa, iremos adotar o mesmo sistema, considerando estes produtos como diferentes.

Como foi dito anteriormente, nem todos os produtos apresentam a mesma quantidade de meses de histórico, pois muitos produtos foram lançados nos últimos anos. Assim a primeira etapa da seleção do produto seria eliminar aqueles que não apresentam histórico de vendas desde 2002, ou seja, foram criados em 2003, 2004 ou 2005. Como usaremos um modelo de série temporal a ser determinado, é fundamental que tenhamos o maior número de informação possível. Com esta eliminação chegamos ao número de 95 produtos. Dentre estes estão os mais importantes produtos

da empresa, pois por serem mais antigos, já estão consolidado no mercado e são reconhecidos como produtos líderes.

Iremos agora classificar estes produtos por seu tipo (herbicida, fungicida e pesticida) para termos a certeza que eles apresentam comportamento semelhante. Classificando os 95 produtos por seus grupos ficamos com 20 tipos de fungicidas, 24 tipos de herbicidas e 16 tipos de pesticidas. O objetivo desta seleção é escolher dentre estes produtos, 2 de cada grupo, para termos uma amostra de 6 produtos totais. Os outros 35 produtos não selecionados pertencem a outras categorias, que não são o foco deste projeto, pois são áreas menos importantes para a empresa.

Antes de estudarmos o comportamento dos produtos iremos selecionar os 10 mais importantes de cada categoria. Para esta seleção usaremos os dados referentes a preço médio praticado no ano de 2005. Assim escolheremos os produtos que são responsáveis por maiores participações no faturamento total da empresa. Para evitarmos uma análise muito longa, não iremos comparar todos os produtos novamente, somente os pré-selecionados até aqui, que são: 20 tipos de fungicidas, 24 tipos de herbicidas e 16 tipos de pesticidas.

Com estes produtos foi gerada a tabela abaixo, já ordenada por ordem de importância:

Produtos	Volume 2005	Preço (R\$/Kg ou L)	Vendas (R\$)	% total
Herbicida 23	5513240	4.4	24122757	8.78%
Herbicida 4	1774775	12.8	22712040	8.27%
Pesticida 9	805633	25.8	20812834	7.58%
Herbicida 6	1314885	12.2	16035430	5.84%
Pesticida 1	296974	37.3	11062618	4.03%
Herbicida 24	2242240	4.6	10351851	3.77%
Herbicida 5	755165	13.1	9900974	3.60%
Pesticida 8	1081815	8.9	9659563	3.52%
Fungicida 13	1060627	8.7	9226628	3.36%
Fungicida 3	393767	21.9	8630929	3.14%
Herbicida 13	2005115	4.2	8409306	3.06%
Pesticida 5	579326	12.3	7127031	2.59%
Herbicida 21	1609870	4.3	7002264	2.55%
Pesticida 7	614199	9.7	5949985	2.17%
Pesticida 4	896535	6.5	5797200	2.11%
Herbicida 11	1149705	4.7	5457858	1.99%
Fungicida 11	300754	16.9	5095244	1.85%
Fungicida 1	267022	16.7	4462799	1.62%
Herbicida 19	1379640	2.9	4038578	1.47%
Pesticida 16	167055	23.2	3881287	1.41%
Herbicida 14	271495	14.2	3867494	1.41%
Fungicida 12	192415	20.0	3845013	1.40%

Herbicida 20	1155765	3.0	3468157	1.26%
Herbicida 7	889500	3.9	3452262	1.26%
Fungicida 16	306172	11.1	3397940	1.24%
Fungicida 9	80430	40.2	3231982	1.18%
Pesticida 14	127312	24.8	3155714	1.15%
Herbicida 16	990250	3.1	3094971	1.13%
Herbicida 17	637120	4.8	3035235	1.10%
Fungicida 6	274787	10.6	2909104	1.06%
Herbicida 15	953000	3.0	2869982	1.04%
Herbicida 8	962500	2.9	2824929	1.03%
Herbicida 1	483220	5.8	2809591	1.02%
Fungicida 20	200257	11.7	2346055	0.85%
Fungicida 15	87276	26.7	2328988	0.85%
Herbicida 18	483560	4.6	2248478	0.82%
Pesticida 11	260484	7.5	1959425	0.71%
Herbicida 22	75780	24.6	1867537	0.68%
Herbicida 12	380290	4.9	1862062	0.68%
Fungicida 2	27833	65.9	1832909	0.67%
Herbicida 9	585800	3.1	1821656	0.66%
Herbicida 3	135654	13.3	1809619	0.66%
Pesticida 2	37165	47.4	1761292	0.64%
Fungicida 19	99600	16.9	1687153	0.61%
Herbicida 2	268560	5.9	1586831	0.58%
Fungicida 17	85350	17.6	1498802	0.55%
Herbicida 10	227660	5.3	1214289	0.44%
Fungicida 7	23315	49.7	1158877	0.42%
Fungicida 5	199415	5.4	1079704	0.39%
Pesticida 15	32030	28.6	915601	0.33%
Pesticida 3	85910	7.2	621988	0.23%
Pesticida 6	49944	11.1	553963	0.20%
Fungicida 8	30615	15.4	470552	0.17%
Fungicida 4	1769	250.2	442533	0.16%
Fungicida 18	18495	21.9	404788	0.15%
Fungicida 14	13704	27.5	376278	0.14%
Pesticida 12	3608	92.8	334839	0.12%
Fungicida 10	74538	4.4	331139	0.12%
Pesticida 13	5334	49.0	261127	0.10%
Pesticida 10	6504	36.6	238127	0.09%
Total	35297498		274714158	100.00%

Tabela 2: Porcentagem de participação dos produtos

A unidade de medida para os pesticidas é o Kg, já para Herbicidas alguns são Kg outros são Litros e Fungicidas é o Litro. Assim a unidade de preço para pesticidas é R\$/Kg, para fungicidas é R\$/L e para herbicidas depende do produto, podendo ser ambos.

Com esta tabela gerada, iremos selecionar os 10 produtos mais importantes de cada categoria. Com estes produtos será gerado um gráfico por categoria para a análise do padrão de comportamento, esta análise é fundamental para assegurarmos que os produtos piloto representem bem a amostra total, pois a escolha de um piloto que não apresente comportamento

semelhante ao dos outros produtos pode comprometer o resultado final do trabalho, fazendo com que o modelo escolhido não seja factível para o resto dos produtos.

Abaixo é apresentado o gráfico com a porcentagem de vendas dos pesticidas mês a mês, referente ao ano de 2005.

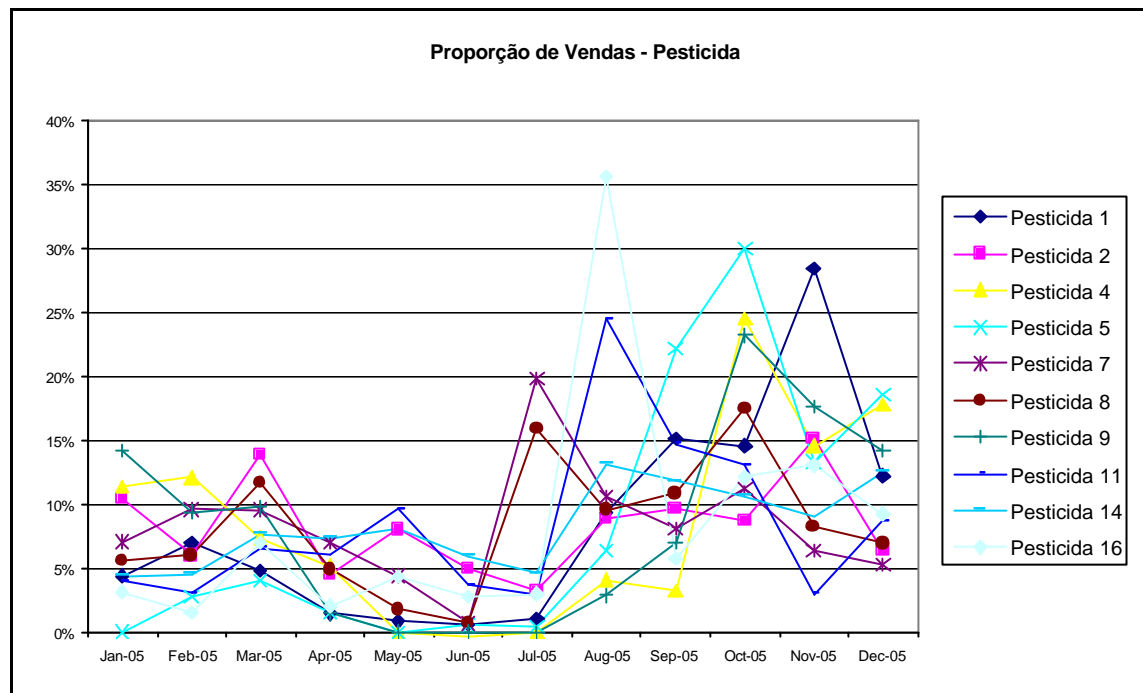


Gráfico 1: Proporção de vendas – Pesticidas 2005

Analisando o gráfico chegamos à conclusão que a grande maioria dos produtos apresentam comportamento semelhante, com vendas menores no começo do ano, e um aumento das vendas no segundo semestre. Podemos também notar um padrão de altos e baixos na grande maioria dos produtos, com pouca presença de crescimento ou decrescimento constante.

Abaixo é apresentado o gráfico com a porcentagem de vendas dos herbicidas mês a mês, referente ao ano de 2005.




Gráfico 2: Proporção de vendas – Herbicidas 2005

A análise deste gráfico nos mostra que o padrão dos pesticidas se repete, onde as vendas são menores no primeiro semestre, com altas vendas no segundo semestre, para a grande maioria dos produtos. Nesta categoria o padrão de altos e baixos é menos acentuado, com a presença de decréscimo constante no primeiro semestre e crescimento constante no segundo para alguns produtos, e a presença de altos e baixos menos acentuados para outros.

Abaixo é apresentado o gráfico com a porcentagem de vendas dos fungicidas mês a mês, referente ao ano de 2005.




Gráfico 3: proporção de vendas – Fungicidas 2005

Analisando este gráfico, observamos uma menor tendência crescimento de vendas no segundo semestre, porém o padrão de altos e baixos observados nos últimos dois grupos aparece novamente para a maioria dos produtos.

Uma análise geral dos 3 gráficos, mostra que o comportamento por tipo de produto é semelhante, sendo que as principais características observadas são o crescimento de vendas no segundo semestre para pesticidas e herbicidas, característica menos predominante para os fungicidas. A característica mais marcante e presente nos 3 grupos foi a existência de altos e baixos nas vendas, característica menos presente nos herbicidas, não apresentando venda constante durante o ano, o que diferencia estes picos são as proporções e períodos de pico, fato que pode ser ligado a períodos de safra e entressafra das culturas nas quais os produtos são aplicados. Geralmente as maiores proporções se concentram no segundo semestre.

Com esta análise feita, podemos escolher dentre os produtos com comportamento semelhante os pilotos, evitando escolher um produto que não represente a amostra como um todo, ou seja, que tenha um comportamento ímpar dentro do grupo de produtos ao qual pertence.

Assim usando novamente a tabela 2 como parâmetro de decisão os produtos escolhidos para serem os pilotos foram:

Produtos	Volume 2005	Preço (R\$/Kg ou L)	Vendas (R\$)	% total
Herbicida 23	5513240 Kg	4.4	24297773	8.78%
Herbicida 4	1774775 L	12.8	22712040	8.27%
Pesticida 9	805633 Kg	25.8	20183075	7.58%
Pesticida 1	296974 Kg	37.3	11062618	4.03%
Fungicida 13	1060627 L	8.7	9226628	3.36%
Fungicida 3	393767 L	21.9	8630929	3.14%

Tabela 3: Produtos escolhidos

Estes produtos foram escolhidos, pois são os dois produtos de cada categoria que apresentaram maior participação no faturamento, ou seja, que geraram maiores vendas para a empresa no ano de 2005.

Para facilitar a nomenclatura utilizada para o nome dos produtos escolhidos, eles serão chamados de:

Produtos	Novo Nome
Herbicida 4	Herbicida A
Herbicida 23	Herbicida B
Pesticida 9	Pesticida A
Pesticida 1	Pesticida B
Fungicida 13	Fungicida A
Fungicida 3	Fungicida B

Tabela 4: Nova nomenclatura para os produtos escolhidos

10 Análise dos produtos Piloto

Com a seleção dos produtos realizada, começa a tarefa de análise dos mesmos. Isto é importante para descobrirmos como a série temporal de cada produto se comporta, encontrando fatores como tendência, ciclicidade, sazonalidade ou irregularidade. Será apresentada de forma gráfica a série temporal de cada um dos 6 produtos escolhidos, além de uma tabela que demonstre a proporção de vendas mês a mês.

Como uma análise visual do gráfico da série temporal não é suficiente para definirmos os padrões de comportamento, vamos usar a função da autocorrelação para uma análise mais aprofundada a fim de descobrir as propriedades estatísticas da série.

O coeficiente de autocorrelação pode ser calculado pela seguinte fórmula, sendo que os valores podem variar entre -1 e 1:

$$r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t-k} - \bar{Y}_{t-k})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (10.1)$$

onde,

k – períodos de defasagem;

n – tamanho da amostra;

Y – Valor medido para o período.

A função autocorrelação mede o grau de correlação entre os dados de uma mesma série temporal. Por exemplo, r_1 indica como valores sucessivos de uma mesma série estão relacionados, já r_2 indica como valores com dois períodos de diferença de uma mesma série estão relacionados, e assim por diante. Os valores do coeficiente tendem a diminuir com o aumento dos períodos de defasagem, entende-se por períodos de defasagem a diferença dos períodos analisados, por

exemplo, r_2 está defasado em dois períodos. O correlograma é o gráfico onde são apresentados os valores para os coeficientes calculados.

Segundo Makridakis (1998) uma série temporal com dados aleatórios deveria produzir coeficientes com valor nulo, pois não existe relação entre as observações, porém isto não acontece na prática, mas podemos reconhecer uma série aleatória quando os valores dos coeficientes se aproximam de zero, ficando dentro de um intervalo de confiança de $-1/\sqrt{n}$ e $1/\sqrt{n}$, onde n é o tamanho da amostra da série analisada. Ainda segundo o autor, se uma série temporal for estacionária, ou seja, não existe crescimento ou decrescimento nos dados, os valores iniciais dos coeficientes serão altos porém irão decair rapidamente em direção a zero com o aumento da defasagem. Já para dados não-estacionários os valores dos primeiros coeficientes também serão altos, diminuindo lentamente com o aumento da defasagem, se aproximando de zero.

Para identificar sazonalidade em uma série temporal é esperado que quando a defasagem seja a mesma que o período de sazonalidade, exista grande autocorrelação entre os dados. Assim para séries sazonais existirá um valor significativamente alto de coeficiente que irá ocorrer a cada k períodos, sendo que k representa o período de sazonalidade. Ainda segundo o autor é mais fácil identificar sazonalidade quando a série for estacionária, com isso para séries não-estacionárias é sugerido transformar está para estacionária usando o método das diferenças, neste método uma nova série é criada baseado nas diferenças de períodos consecutivos da série antiga. Assim analisando-se a série nova a identificação de sazonalidade é mais fácil.

10.1 – Análise do Pesticida A

O gráfico com o volume de vendas deste produto durante o período de 2002 a 2005 é apresentado abaixo:




Gráfico 4: Volume de Vendas - Pesticida A

Além deste gráfico é apresentada a tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	0.6%	2.2%	0.8%	2.4%	0.7%	2.5%	2.8%	5.1%	16.0%	23.7%	26.7%	16.5%	401,671 KG
2003	0.4%	1.8%	4.9%	3.1%	0.9%	0.6%	1.3%	9.1%	12.3%	9.0%	18.1%	38.4%	473,881 KG
2004	11.1%	11.5%	14.7%	2.2%	0.1%	0.3%	0.4%	4.7%	8.3%	12.5%	15.6%	18.7%	878,785 KG
2005	12.2%	9.9%	10.3%	1.6%	0.1%	0.1%	0.2%	3.5%	7.4%	14.5%	17.9%	22.3%	805,633 KG

Tabela 5: Distribuição das Vendas mês a mês – Pesticida A

Analisando visualmente este gráfico e a tabela, torna-se claro a concentração de vendas em período de 4 a 5 meses por ano, que geralmente se inicia no final do ano. Normalmente o período de alta deste produto começa em Outubro, porém em 2003 o período de alta teve início entre Novembro e Dezembro, o que causou um prolongamento de altas vendas até Março de 2004, mês que normalmente apresentava baixas vendas. Isto ocorreu devido ao atraso da safra de culturas que usam este pesticida, por razões meteorológicas, fazendo com que o consumo de pesticida

fosse atrasado também. Assim podemos perceber que o segundo pico no gráfico está um pouco deslocado para a direita em relação aos outros picos. Já de 2004 para 2005, o mesmo comportamento pode ser percebido, onde as altas começaram em Outubro e se estenderam até Março de 2005. Outra análise que podemos observar é o crescimento da demanda ano após ano, conforme a linha de tendência apresentada no gráfico. Em 2004 as vendas foram ligeiramente maiores que 2005, por causa do atraso da safra de 2003, concentrando boa parte das vendas deste ano (2003) no ano seguinte, porém se a safra deste ano tivesse ocorrido no período esperado as vendas de 2004 seriam relativamente menores que as de 2005. Podemos concluir que houve crescimento do mercado (demanda) e não apenas crescimento da participação da empresa, pois neste período o crescimento de vendas foi maior que o crescimento da participação da empresa, ou seja, o mercado se expandiu neste período. O aumento das vendas foi de 18% em 2003, 85% em 2004 e sofreu queda de 8% em 2005.

Como foi dito anteriormente a análise visual não é suficiente para determinar os padrões de comportamento da série, por isso é apresentado o correlograma para o Pesticida A.




Gráfico 5: Correlograma – Pesticida A

Analisando o correlograma chegamos a clara conclusão de que a série apresenta comportamento sazonal, sendo que esta sazonalidade ocorre anualmente. Isto pode ser percebido por causa dos altos valores dos coeficientes defasados de 12, 24 e 36 períodos. Como foi explicado anteriormente, os valores tendem a cair com o aumento da defasagem, o que faz com que os valores se aproximem de zero. Os altos valores para r_1 , r_{11} e r_{13} podem ser explicados pela não concentração das altas vendas em apenas um mês, e sim em períodos de 4 a 5 meses, o que gera alta correlação para estas defasagens.

10.2 – Análise do Pesticida B

O gráfico com o volume de vendas deste produto de 2002 a 2005 é apresentado abaixo:




Gráfico 6: Volume de Vendas - Pesticida B

A tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	1.8%	2.2%	3.5%	2.0%	1.0%	3.7%	2.7%	4.7%	13.9%	25.2%	22.8%	16.6%	68,751 KG
2003	1.4%	4.9%	1.6%	5.0%	2.4%	1.9%	0.5%	2.7%	13.3%	28.5%	18.5%	19.3%	152,060 KG
2004	4.6%	2.5%	7.1%	4.4%	1.8%	0.8%	0.7%	3.9%	7.2%	22.8%	31.8%	12.4%	256,251 KG
2005	4.7%	2.9%	5.2%	1.6%	0.9%	0.7%	1.1%	4.9%	11.9%	22.4%	30.5%	13.1%	296,974 KG

Tabela 6: Distribuição das Vendas mês a mês – Pesticida B

Analisando os dados, pode-se perceber que as vendas também apresentam grandes altas no final do ano. As altas normalmente se iniciam em setembro, durando até dezembro. As vendas deste produto se comportou de maneira constante nesses quatro anos, não sofrendo a ação de atrasos ou adiantamento de safras. Mais uma vez a linha de tendência tem inclinação positiva, indicando tendência de crescimento ao longo da série. Pode-se constatar também que a demanda do mercado está aumentando, pois novamente o aumento das vendas foi maior que o aumento da participação da empresa. O aumento das vendas foi de 121% em 2003, 69% em 2004 e de 16% em 2005.

O correlograma do pesticida B é apresentado a seguir:




Gráfico 7: Correlograma – Pesticida B

As mesmas conclusões podem ser tiradas para os pesticidas A e B a respeito do correlograma. A série apresenta comportamento sazonal, sendo que esta sazonalidade ocorre anualmente. Justificado pelos altos valores dos coeficientes defasados de 12, 24 e 36 períodos. Novamente os valores decaem com o aumento da defasagem e altos valores são encontrados para períodos defasados de 1, 11, 13 por causa de um período de alta de mais de um mês.

10.3 – Análise do Herbicida A

O gráfico com o volume de vendas deste produto de 2002 a 2005 é apresentado abaixo:




Gráfico 8: Volume de Vendas – Herbicida A

A tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	1.5%	0.9%	3.1%	0.2%	0.7%	6.1%	14.3%	10.9%	19.6%	28.3%	7.1%	7.2%	1,191,153 L
2003	1.9%	1.8%	0.3%	0.3%	0.6%	2.0%	14.6%	17.6%	13.5%	13.3%	21.0%	13.0%	1,359,752 L
2004	5.3%	1.8%	0.8%	0.2%	0.4%	6.3%	7.8%	14.9%	15.1%	15.7%	22.4%	9.4%	1,615,905 L
2005	3.3%	1.2%	1.0%	0.2%	0.5%	3.5%	5.0%	18.4%	17.4%	19.4%	21.3%	8.7%	1,774,775 L

Tabela 7: Distribuição das Vendas mês a mês – Herbicida A

Analisando este produto, vemos que a alta das vendas ocorre no segundo semestre. O período de alta deste produto é maior que para os pesticidas, apresentando períodos de até seis meses, se concentrando de julho a dezembro. Porém esse período não se mantém constante, em 2003 o período de alta se estendeu até janeiro de 2004. Em 2004 a alta começou em junho, porém de maneira menos acentuada em junho e julho. Já em 2005 o período de alta começou apenas em agosto. Também é observada uma tendência de crescimento de demanda para este produto, o que pode ser comprovado pelo aumento das vendas, que foi proporcionalmente maior que o aumento na participação. O aumento das vendas foi de 14% em 2003, 19% em 2004 e de 10% em 2005.

O correlograma do Herbicida A é apresentado a seguir:




Gráfico 9: Correlograma – Herbicida A

A partir do correlograma é concluído que existe sazonalidade anual, por causa dos altos valores dos coeficientes com defasagem de 12, 24 e 36. Neste correlograma podemos observar mais coeficientes positivos, isto é justificado por causa do maior período de altas, que para este produto pode chegar a até 6 meses, gerando alta correlação para períodos de defasagem ao redor de 12, 24 e 26, além das defasagens de 1 e 2 períodos.

10.4 – Análise do Herbicida B

O gráfico com o volume de vendas deste produto de 2002 a 2005 é apresentado abaixo:




Gráfico 10: Volume de Vendas – Herbicida B

A tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	4.7%	9.0%	3.1%	1.0%	1.5%	9.8%	13.3%	15.7%	12.9%	5.3%	10.0%	13.7%	1,393,000 KG
2003	2.2%	2.6%	1.6%	2.0%	1.7%	7.4%	7.3%	14.2%	22.4%	16.0%	11.0%	11.4%	2,512,400 KG
2004	2.4%	1.3%	1.7%	2.9%	3.3%	4.0%	2.0%	21.8%	25.7%	15.3%	15.2%	4.3%	3,618,660 KG
2005	1.9%	1.2%	1.8%	2.6%	3.0%	3.7%	3.4%	19.4%	24.6%	16.9%	15.0%	6.6%	5,513,240 KG

Tabela 8: Distribuição das Vendas mês a mês – Herbicida B

Analisando o gráfico é possível observar que o ano de 2002 apresenta uma distribuição única, pois apresenta dois picos de vendas. A partir de 2003 o produto se comporta de maneira similar, com período de alta que se inicia em agosto e dura até novembro, podendo se estender até dezembro, fato ocorrido em 2003. Também é observado um crescimento de demanda para este produto, o que pode ser comprovado pelo aumento das vendas, que foi proporcionalmente maior que o aumento na participação. O aumento de vendas foi de 80% em 2003, 44% em 2004 e 52% em 2005.

O correlograma do Herbicida B é apresentado a seguir:




Gráfico 11: Correlograma – Herbicida B

Este correlograma nos leva as mesmas conclusões referentes ao Herbicida A, o produto apresenta comportamento sazonal, com sazonalidade anual. Isto é comprovado pelo alto valor dos coeficientes com 12, 24 e 36 períodos de defasagem. Além disso, por causa do período de 4 a 5 meses de alta, outros valores positivos são apresentados para defasagens próximas de 12,24 e 36. O coeficiente com defasagem de um período apresenta alto valor pelo mesmo motivo dos produtos anteriores.

10.5 – Análise do Fungicida A

O gráfico com o volume de vendas deste produto de 2002 a 2005 é apresentado abaixo:




Gráfico 12: Volume de Vendas – Fungicida A

A tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	0.0%	0.0%	36.6%	23.2%	21.9%	12.0%	2.8%	1.3%	0.8%	0.7%	0.6%	0.1%	725,324 L
2003	0.0%	5.5%	21.2%	18.6%	33.0%	15.2%	3.5%	1.2%	0.3%	0.6%	0.7%	0.2%	895,104 L
2004	0.2%	0.1%	37.2%	15.6%	23.4%	12.4%	8.2%	1.6%	0.9%	0.1%	0.2%	0.2%	975,275 L
2005	0.3%	0.4%	40.4%	12.1%	22.7%	11.9%	7.8%	2.6%	1.2%	0.2%	0.2%	0.2%	1,060,627 L

Tabela 9: Distribuição das Vendas mês a mês – Fungicida A

Analisando o gráfico e a tabela pode-se concluir que existe uma grande diferença entre este produto e os outros analisados até agora, o período de alta das vendas se concentra no começo do ano, começando normalmente em março, podendo se estender até junho ou julho. A única semelhança é o crescimento das vendas, fator constante desde 2002. Novamente podemos concluir que houve um aumento da demanda, pois o crescimento das vendas foi maior que o aumento da participação da empresa. O aumento das vendas foi de 23% em 2003, 9% em 2004 e de 10% em 2005. Para este produto a linha de tendência é praticamente constante ao longo dos anos.

O correlograma da Fungicida A é apresentado a seguir:




Gráfico 13: Correlograma – Fungicida A

Pela análise do correlograma, é possível concluir que o produto apresenta comportamento sazonal, com sazonalidade anual. Isto é comprovado pelo alto valor dos coeficientes com 12, 24 e 36 períodos de defasagem. Novamente alguns coeficientes de defasagem próxima a 12, 24 e 36 apresentam valores positivos, o que novamente é explicado pelo período de altas que não se restringe a apenas um mês.

10.6 – Análise do Fungicida B

O gráfico com o volume de vendas deste produto de 2002 a 2005 é apresentado abaixo:




Gráfico 14: Volume de Vendas – Fungicida B

A tabela com a distribuição das vendas deste produto de 2002 a 2005, seguido pelo montante total vendido.

Ano	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	Volume Total
2002	0.3%	0.7%	7.4%	26.5%	12.3%	31.5%	10.3%	4.7%	2.4%	0.9%	0.6%	2.3%	156,763 L
2003	1.7%	2.4%	7.9%	23.0%	19.2%	26.7%	3.9%	4.6%	3.9%	0.7%	1.1%	4.9%	123,209 L
2004	2.5%	4.1%	14.7%	18.3%	24.6%	16.8%	7.4%	4.1%	3.5%	0.7%	1.0%	2.2%	283,547 L
2005	4.0%	4.5%	15.6%	17.4%	22.2%	19.0%	7.5%	3.7%	2.4%	0.4%	1.1%	2.2%	393,767 L

Tabela 10: Distribuição das Vendas mês a mês – Fungicida B

Com a análise deste gráfico é possível determinar uma semelhança no comportamento dos fungicidas, que difere dos outros produtos, eles apresentam alta das vendas no começo do ano. O Fungicida B tem o início da sua alta entre Março e Abril, este período pode se estender até julho. O aumento das vendas só ocorreu em 2004, pois em 2003 o produto sofreu diminuição de 21%, porém não houve redução do mercado, e sim perda na participação deste produto com seus concorrentes. Já em 2004 houve aumento de 130% e em 2005 aumento de 39%. Novamente nesses anos o mercado está em expansão.

O correlograma da Fungicida B é apresentado a seguir:




Gráfico 15: Correlograma – Fungicida B

Pela análise do correlograma, é possível concluir que o produto apresenta comportamento sazonal, com sazonalidade anual. Isto é comprovado pelo alto valor dos coeficientes com 12, 24 e 36 períodos de defasagem. Novamente alguns coeficientes de defasagem próxima a 12, 24 e 36

apresentam valores positivos, o que novamente é explicado pelo período de altas que não se restringe a apenas um mês.

10.7 – Análise Global dos Produtos

Após apresentação dos gráficos de vendas e dos correlogramas, foram feitas análises individuais dos produtos, porém o modelo buscado será implementado para todos os produtos. Assim é fundamental tirar conclusões completas, com as semelhanças que estes produtos apresentaram. A primeira conclusão a ser levada em consideração é o comportamento sazonal de todos os produtos, além disso ambos apresentam sazonalidade anual, ou seja, o padrão se repete todo ano. Um comportamento que também se repete para os produtos é um período maior ou igual a quatro meses para a alta das vendas, nunca apresentando apenas um mês de altas venda. Uma diferença apresentada entre os produtos é o período do ano em que ocorre a alta das vendas, para quatro produtos (pesticidas e herbicidas) esta alta ocorre no segundo semestre, enquanto que para os fungicidas ela ocorre no primeiro semestre. Isto ocorre por causa da safra dos produtos que utilizam estes produtos, porém esta diferença não interfere no processo de escolha do modelo e de aplicação do mesmo.

Além da sazonalidade, outro padrão que apareceu para todos os produtos foi a tendência a crescimento das vendas com o passar dos anos, logicamente este crescimento aconteceu de maneira diferenciado para os produtos testados, além disso para o mesmo produto muitas vezes o percentual de crescimento é diferenciado de ano para ano. Além do crescimento das vendas também houve expansão do mercado, conciliado a um crescimento da participação dos produtos em detrimento aos seus concorrentes.

11 Seleção do Modelo de Previsão

Chega uma etapa fundamental do trabalho, a escolha do modelo a ser testado e implementado. Esta etapa também é fundamental para o sucesso deste trabalho, pois uma escolha equivocada pode trazer resultados ruins, a ponto de inviabilizar o sucesso deste projeto. Portanto uma metodologia coesa deve ser desenvolvida nesta etapa, além de contar com a solidez dos dados dos capítulos passados, como a revisão bibliográfica e a análise do comportamento dos produtos piloto. A revisão é fundamental para que seja apresentado cada método, mostrando seus pontos fortes e fracos, evitando a não compreensão dos modelos apresentados. Já a análise dos dados mostra como são os produtos, facilitando a classificação dos modelos apresentados e a escolha final.

Para essa escolha apresentaremos os pontos fortes e fracos de quatro métodos estudados: Suavização exponencial, Método de Winters, Box Jenkins e o Método da Regressão Linear.

As análises serão baseadas em critérios definidos como fundamentais por O'Donovan (1983). Os critérios a serem utilizados na escolha do método serão:

Horizonte de Previsão: É o tempo futuro no qual a previsão é necessária, para este trabalho o horizonte necessário é de três a quatro meses. Este período pode ser considerado elevado, porém a principal matéria-prima dos defensivos agrícolas é o ingrediente ativo, e na maioria dos casos este insumo é importado o que aumenta o lead-time de recebimento. Aumento assim o lead-time de produção.

Comportamento dos Dados: Os principais tipos de comportamento já foram explicados anteriormente. Esses são: a tendência, sazonalidade e ciclicidade. Para nosso trabalho é importante que o modelo esteja apto a trabalhar com dados que apresentem sazonalidade e tendência. Estes dois comportamentos foram detectados no capítulo de análise de dados.

Necessidade de Dados: este critério está relacionado à quantidade de dados que cada método necessita para que seja aplicado. Para o nosso trabalho temos o histórico de vendas de quatro anos. Por isso modelos que necessitem de mais histórico podem ficar comprometidos.

Facilidade de Entendimento: este critério está mais relacionado à utilização modelo, pois é fundamental que todos os funcionários da empresa que tem contato com a previsão de vendas entenda o modelo que está sendo utilizado. Além disso, um modelo de mais fácil compreensão tem maiores chances de ser implementado. Um modelo muito complexo, mas que apresente resultados excelentes, pode muitas vezes não passar confiança aos seus usuários, dados que eles não entendam o que está sendo feito.

Custos: Todos os custos para a implementação do modelo devem ser considerados, como por exemplo, os custos de desenvolvimento, coleta e armazenamento de dados, treinamento e também custos relacionados a aquisição de softwares.

Acurácia: este critério está relacionado ao quão próximo do real serão as previsões realizadas pelo modelo. As notas serão referentes a acurácia geral do modelo e não caso este fosse aplicado aos produtos deste trabalho.

A seguir os modelos serão analisados um a um de acordo com os critérios apresentados.

Sua viziação Exponencial

Critério	Análise
Horizonte de Previsão	Modelo apto a prever no horizonte necessário
Comportamento dos dados	O modelo não apresenta bom desempenho com séries temporais que possuem sazonalidade
Necessidade de dados	O histórico disponível é suficiente para utilizar o modelo
Facilidade de entendimento	O modelo é de fácil entendimento
Custos	Os custos agregados a implementação são baixos
Acurácia	O modelo não apresenta grande acurácia para séries temporais com sazonalidade

Tabela 11 : análise do modelo suavização exponencial

Método Holt-Winter

Critério	Análise
Horizonte de Previsão	Modelo apto a prever no horizonte necessário
Comportamento dos dados	O modelo apresenta um parâmetro específico para sazonalidade, sendo apto a fazer previsões de séries sazonais
Necessidade de dados	O histórico disponível é suficiente para utilizar o modelo
Facilidade de entendimento	O modelo é de fácil entendimento
Custos	Os custos agregados a implementação são baixos
Acurácia	Apresenta grande acurácia, pois é capaz de prever séries temporais com comportamento sazonal

Tabela 12 : análise do modelo Holt-Winter

Método de Box-Jenkins

Critério	Análise
Horizonte de Previsão	Modelo apto a prever no horizonte necessário
Comportamento dos dados	O modelo pode prever séries temporais que apresentam qualquer comportamento
Necessidade de dados	Os dados disponíveis não são suficientes para se garantir bom funcionamento do modelo
Facilidade de entendimento	O modelo é mais complexo do que os outros modelos, dificultando um pouco seu entendimento
Custos	Os custos agregados a implementação são relativamente maiores, porém não inviabilizam o modelo
Acurácia	Apresenta grande acurácia, pois é capaz de prever séries temporais com comportamento sazonal

Tabela 13: análise do modelo Box-Jenkins

Regressão Linear

Critério	Análise
Horizonte de Previsão	Modelo apto a prever no horizonte necessário
Comportamento dos dados	O modelo pode prever séries temporais que apresentam qualquer comportamento
Necessidade de dados	Para a utilização deste modelo é necessário a utilização de mais uma variável, o que inviabiliza sua aplicação neste trabalho por só possuir a variável relativa a histórico de vendas
Facilidade de entendimento	O modelo é de fácil entendimento
Custos	Os custos agregados a implementação são baixos, porém maiores que os dois primeiros modelos
Acurácia	Apresenta grande acurácia, pois é capaz de prever séries temporais com comportamento sazonal

Tabela 14: análise do modelo de regressão Linear

A partir da análise feita acima podemos concluir por eliminação que o modelo que não apresenta nenhuma restrição é o modelo de Holt-Winter. Pois é capaz de prever para séries temporais com comportamento sazonal, não necessita de mais histórico de dados para que o modelo seja iniciado e aplicado, e também não precisa de nenhuma outra variável. Assim por eliminação o modelo a ser utilizado na próxima etapa deste trabalho é o modelo de Holt-Winter.

12 Aplicação do Modelo

Chega a etapa crucial do trabalho, onde o modelo selecionado será aplicado para se testar a real aderência aos produtos da empresa. O método selecionado foi o Holt-Winter. Este modelo usa a suavização exponencial de três parâmetros, será utilizado o modelo multiplicativo, por se adequar melhor ao comportamento sazonal dos produtos analisados, pois o componente sazonal é tratado como multiplicativo neste modelo. Seus algoritmos já foram apresentados no capítulo da revisão bibliográfica, porém para facilitar sua explicação, eles serão apresentados novamente.

Nível:
$$L_t = \alpha(Y_t/S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

Tendência:
$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

Sazonalidade:
$$S_t = \gamma(Y_t/L_t) + (1 - \gamma)S_{t-s}$$

Previsão:
$$F_{t+m} = (L_t + b_t m) S_{t-s+m}$$

Onde,

s – É o intervalo de sazonalidade;

L_t – Representa o nível da série temporal;

b_t – Estimativa da Tendência ;

S_t – É o componente sazonal;

F_{t+m} – Previsão para m períodos futuros;

α , β e γ – Constantes de suavização, com valor entre 0 e 1.

No capítulo de análise do comportamento dos produtos foi percebido que o intervalo de sazonalidade é anual, como temos dados mensais das vendas, o valor de s para a aplicação do modelo será de 12.

A aplicação do modelo será dividida em três etapas: inicialização, validação e testes. A etapa de inicialização usará os dados de 2002 para que sejam gerados os valores iniciais de L_t , b_t e de S_t .

Para se fazer a inicialização deve usar um período completo de sazonalidade, no caso deste trabalho 12 meses. As equações utilizadas na fase de inicialização serão:

$$\text{Nível: } L_s = \frac{1}{S} (Y_1 + Y_2 + \dots + Y_s)$$

$$\text{Tendência: } b_s = \frac{1}{S} \left[\frac{Y_{s+1} - Y_1}{S} + \frac{Y_{s+2} - Y_2}{S} + \dots + \frac{Y_{s+s} - Y_s}{S} \right]$$

$$\text{Sazonalidade: } S_1 = \frac{Y_1}{L_s}; S_2 = \frac{Y_2}{L_s}; \dots; S_s = \frac{Y_s}{L_s}$$

Na etapa de validação que usará o histórico de vendas de 2003 e 2004, serão encontrados os valores para os coeficientes a , β e γ , de modo a minimizar o MAPE (Erro percentual médio absoluto). Esta etapa não será usada para testes, pois a previsão de cada mês tem como input a venda real do mesmo mês, logo este sistema não seria aplicável em uma empresa, pois não faz sentido prever para um mês o qual já sabemos como se comportaram as vendas.

Para se testar o modelo, será gerada a previsão de vendas para todos os meses de 2005 (12 meses à frente) se baseando apenas no histórico até 2004. Como as vendas de 2005 já são conhecidas será testada a aderência do modelo caso o mesmo fosse utilizado em 2004 pela empresa. Além disso, a previsão que a empresa gerou para o ano de 2005 também é conhecida, permitindo comparar as duas previsões, descobrindo qual é a que apresenta menor desvio. Como a previsão da empresa foi gerada no final de 2004, a comparação será entre duas previsões geradas no mesmo período. Baseado nesta comparação será estimado os benefícios quantitativos do modelo implementado.

Anteriormente foi definido que o horizonte de previsão seria de três a quatro meses, porém para efeito de testes usaremos um horizonte de doze meses. Esta escolha foi feita para que sejam comparadas duas previsões geradas no mesmo período, evitando favorecimento de algum dos

dois sistemas. Como a empresa não possui um modelo formal de previsão, é muito difícil definir quando foram feitas revisões do números previstos. Por isso usaremos a previsão feita no começo do ano chamada de “best view”.

Para a geração das previsões foi utilizado o software Microsoft Excel, pois com ele foi possível otimizar os valores dos coeficientes α , β e γ , de modo a minimizar o erro gerado.

Para o primeiro produto testado (pesticida A) todo o memorial de cálculo das fases de inicialização e validação serão apresentados no corpo do trabalho, porém para os 5 outros produtos piloto estes cálculos serão apresentados somente no anexo, mostrando apenas os dados mais importantes para o trabalho.

12.1 – Aplicação do Modelo – Pesticida A

Primeiramente será apresentada o memorial de cálculos das etapas de inicialização e validação.

Pesticida A				Alfa	Beta	Gama	MAPE Validação (%)			
				0.18	0.00	1.00	0.65			
Ano	Mês	Venda Real (Kg)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)
2002	jan	2534	Inicialização	1			0.08			
	fev	8885		2			0.27			
	mar	3121		3			0.09			
	abr	9490		4			0.28			
	mai	2965		5			0.09			
	jun	9910		6			0.30			
	jul	11420		7			0.34			
	ago	20500		8			0.61			
	set	64325		9			1.92			
	out	95005		10			2.84			
	nov	107046		11			3.20			
	dez	66470		12	33473	501	1.99			
2003	jan	1945	Validação	13	32502	501	0.06	1975	30	1.54
	fev	8595		14	32893	501	0.26	8726	131	1.52
	mar	23400		15	72070	501	0.32	23563	163	0.70
	abr	14640		16	68850	501	0.21	14747	107	0.73
	mai	4205		17	65462	501	0.06	4237	32	0.77
	jun	3073		18	56083	501	0.05	3101	27	0.89
	jul	6354		19	49836	501	0.13	6418	64	1.01
	ago	42985		20	53866	501	0.80	43385	400	0.93
	set	58320		21	50098	501	1.16	58904	584	1.00
	out	42830		22	44287	501	0.97	43315	485	1.13
	nov	85694		23	41590	501	2.06	86727	1033	1.21
	dez	181840		24	50887	501	3.57	183632	1792	0.99
2004	jan	97480	Validação	25	331819	501	0.29	97627	147	0.15
	fev	100960		26	341928	501	0.30	101108	148	0.15
	mar	128745		27	352046	501	0.37	128928	183	0.14
	abr	19155		28	305891	501	0.06	19186	31	0.16
	mai	730		29	253947	501	0.00	731	1	0.20
	jun	2770		30	218203	501	0.01	2776	6	0.23
	jul	3305		31	184435	501	0.02	3314	9	0.27
	ago	40985		32	161191	501	0.25	41113	128	0.31
	set	73015		33	144099	501	0.51	73269	254	0.35
	out	110165		34	139145	501	0.79	110562	397	0.36
	nov	137215		35	126661	501	1.08	137758	543	0.40
	dez	164260		36	112729	501	1.46	164991	731	0.44

Tabela 15: Inicialização e Validação do modelo (pesticida A)

Para o pesticida A, os valores dos coeficientes que geraram o menos erro foram:

Alfa	Beta	Gama
0.18	0.00	1.00

Estes coeficientes geraram um MAPE (erro percentual médio absoluto) de 0,65%. Este erro é muito baixo, mostrando que os coeficientes estão otimizados. O que garante mais acuracidade do modelo, para que a etapa de testes seja iniciada.

Analisando os coeficientes é observado que o coeficiente Beta apresenta valor nulo, ou seja, a tendência não apresenta muita importância para a geração da previsão. Enquanto o coeficiente

Gama apresenta valor 1 (máximo), que mostra a importância do fator sazonal na geração desta previsão.

Abaixo serão apresentadas as previsões geradas pelo modelo e pela empresa. Vale ressaltar que como a previsão da empresa foi gerada no final de 2004, só foram usados os dados históricos até 2004 para a geração da previsão do modelo.

					Método Holt-Winter			Previsão da Empresa		
Ano	Mês	Venda Real (Kg)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio Absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio Absoluto (%)
2005	jan	98205	Teste	37	73264	-24941	25.40	120000	21795	22.19
	fev	79810		38	87581	7771	9.74	90000	10190	12.77
	mar	82638		39	102776	20138	24.37	135000	52362	63.36
	abr	12930		40	7185	-5745	44.43	40000	27070	209.36
	mai	905		41	331	-574	63.40	2000	1095	120.99
	jun	1035		42	1469	434	41.96	4000	2965	286.47
	jul	1863		43	2083	220	11.81	5000	3137	168.38
	ago	28510		44	29683	1173	4.11	50000	21490	75.38
	set	59325		45	59406	81	0.14	90000	30675	51.71
	out	116500		46	93220	-23280	19.98	200000	83500	71.67
	nov	143867		47	128098	-15769	10.96	236000	92133	64.04
	dez	180045		48	173028	-7017	3.90	172000	-8045	4.47
						MAPE ANO (%)		21.68	MAPE ANO (%)	
					MAPE ALTA (%)		12.32	MAPE ALTA (%)		45.70

Tabela 16: Previsões Pesticida A

O gráfico comparativo das previsões com as vendas reais para 2005 é apresentado abaixo:

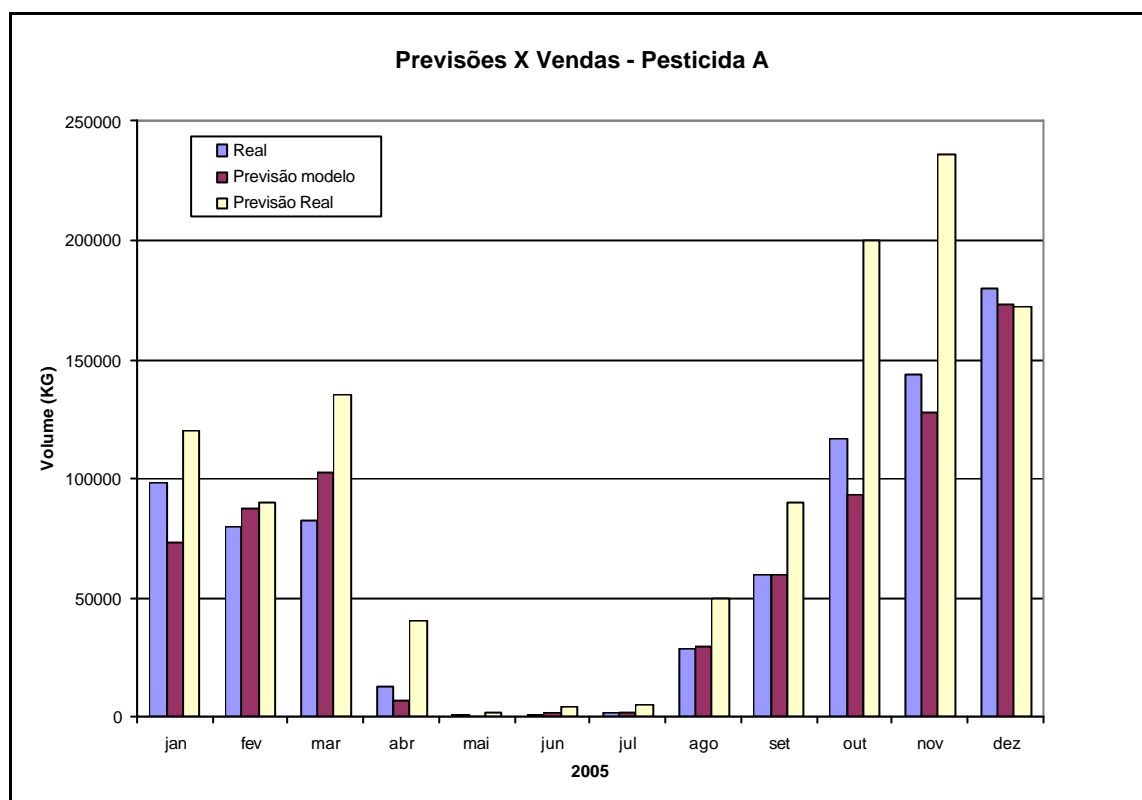


Gráfico 16: Previsões X Vendas – Pesticida A

Primeiramente para a análise do erro foi calculado o MAPE para o ano todo, porém este valor era muito alto. Analisando os desvios percentuais absolutos pode ser percebido que os meses de baixa apresentavam desvios muito elevados, o que acabava distorcendo o valor para o ano todo. Por isso foi adotada outra medição de erro, que considera a média dos desvios absolutos apenas dos meses que apresentam altas vendas. Para este produto foram desconsiderados os meses de Abril até Julho. Os meses escolhidos representam aproximadamente 95% das vendas de 2005.

Pode-se observar que para a maioria dos meses a previsão do modelo foi mais próxima das vendas reais, fato que pode ser provado pelo MAPE adotado. O modelo Holt-Winter gerou uma previsão com MAPE de 12,32% enquanto a previsão da empresa gerou MAPE de 45,70%. Observando o gráfico é percebido que as maiores diferenças foram nos meses de Outubro e Novembro, onde a previsão da empresa ficaram muito acima das vendas reais.

12.2 – Aplicação do Modelo – Pesticida B

O memorial de cálculos para as fases de inicialização e validação do modelo Holt-Winter será apresentado em anexo.

A fase de validação gerou os seguintes valores dos coeficientes:

Alfa	Beta	Gama
0.30	0.00	1.00

Esses foram os valores encontrados que minimizaram o MAPE das previsões geradas nesta fase, que foi de 3,19%. Novamente foi encontrado um valor muito baixo para o MAPE o que mostra a aderência do modelo aos dados tratados.

Os valores dos coeficientes encontrados são muito parecidos aos encontrados para o pesticida A. Novamente o valor de Gama é 1 o que mostra a forte importância do fator sazonalidade do produto.

A tabela que apresenta as previsões do modelo e a da empresa, assim como o gráfico comparativo das previsões são apresentados abaixo.

					Método Holt-Winter			Previsão da Empresa			
Ano	Mês	Venda Real (Kg)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio absoluto (%)	
2005	jan	14020	Teste	37	13327	-693	4.94	30000	15980	113.98	
	fev	8654		38	8443	-211	2.44	15000	6346	73.33	
	mar	15430		39	11724	-3706	24.02	20000	4570	29.62	
	abr	4842		40	8100	3258	67.28	10000	5158	106.53	
	mai	2760		41	3664	904	32.74	5000	2240	81.16	
	jun	2030		42	2030	0	0.00	2000	-30	1.48	
	jul	3395		43	1729	-1666	49.06	15000	11605	341.83	
	ago	14690		44	9256	-5434	36.99	30000	15310	104.22	
	set	35358		45	21300	-14058	39.76	40000	4642	13.13	
	out	66422		46	74670	8248	12.42	69000	2578	3.88	
	nov	90432		47	89419	-1013	1.12	60000	-30432	33.65	
	dez	38941		48	40740	1799	4.62	24000	-14941	38.37	
						MAPE ANO (%)		22.95		MAPE ANO (%)	
					MAPE ALTA (%)		14.48		MAPE ALTA (%)		22.26

Tabela 17: Previsões Pesticida B

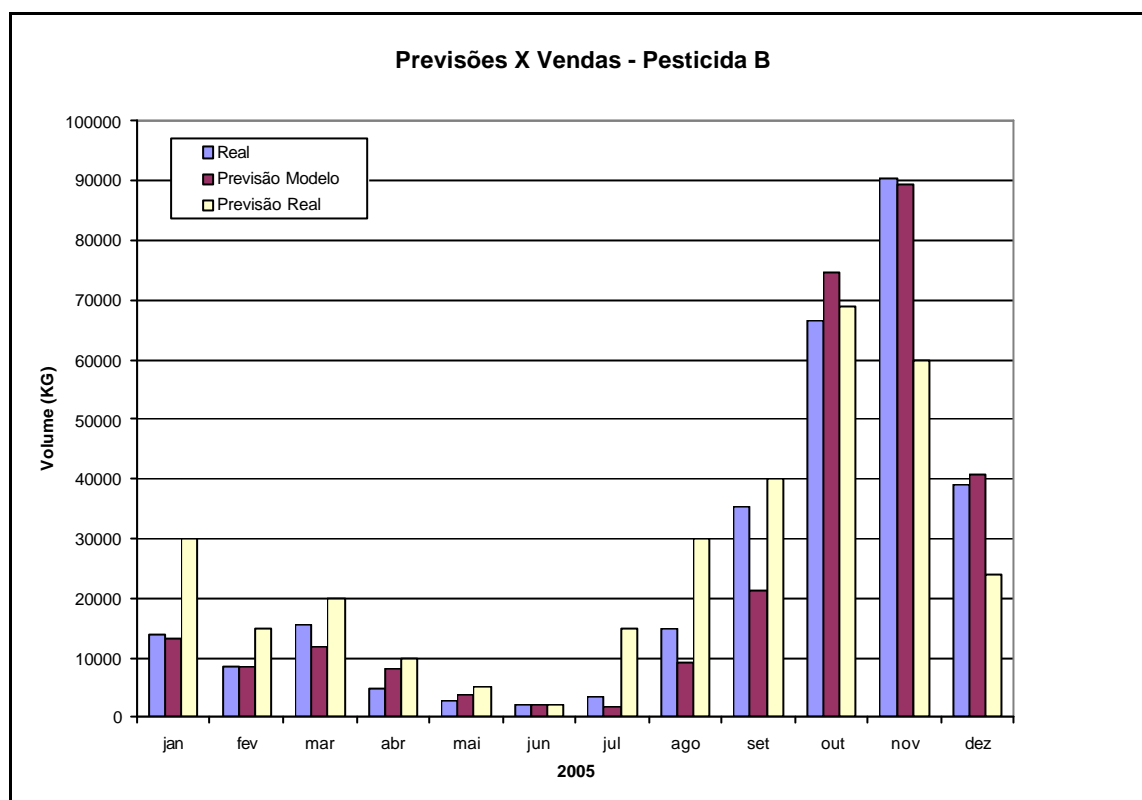


Gráfico 17: Previsões X Vendas – Pesticida B

Analisando a tabela e o gráfico, foi encontrado um valor alto do MAPE baseado no ano todo para a previsão feita pela empresa, novamente os valores que causam distorção eram os meses que apresentavam baixas vendas. Assim foi novamente calculada uma medida de erro somente para os meses de alta. Para este produto foram considerados apenas os meses de Setembro a Dezembro. Consideramos apenas estes 4 meses pois juntos representam aproximadamente 78% das vendas de 2005.

Assim, mais uma vez a previsão gerada pelo modelo Holt-Winter apresentou menor erro do que a previsão gerada pela empresa. O MAPE gerado pela previsão do modelo foi de 14,48% enquanto o MAPE gerado pela previsão da empresa foi de 22,26%. As maiores diferenças encontradas nestas previsões foram, nos meses de Novembro e dezembro onde a previsão da empresa ficou muito abaixo das vendas reais.

12.3 – Aplicação do Modelo – Herbicida A

O memorial de cálculos para as fases de inicialização e validação do modelo Holt-Winter será apresentado em anexo.

A fase de validação gerou os seguintes valores dos coeficientes:

Alfa	Beta	Gama
0.30	0.00	1.00

Esses foram os valores encontrados que minimizaram o MAPE das previsões geradas nesta fase, que foi de 0,80%. Novamente foi encontrado um valor muito baixo para o MAPE o que mostra a aderência do modelo aos dados tratados. Os valores dos coeficientes encontrados são idênticos aos encontrados para o pesticida B. Novamente o valor de Gama é um o que mostra a forte importância do fator sazonalidade do produto. Além disso o valor de Beta é zero que mostra pouca importância do fator tendência.

A tabela que apresenta as previsões do modelo e a da empresa, assim como o gráfico comparativo das previsões são apresentados abaixo.

					Método Holt-Winter			Previsão da Empresa		
Ano	Mês	Venda Real (L)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio Absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio Absoluto (%)
2005	jan	58695	Teste	37	60962	2267	3.86	90000	31305	53.34
	fev	21635		38	22293	658	3.04	60000	38365	177.33
	mar	17470		39	8475	-8995	51.49	40000	22530	128.96
	abr	4425		40	2891	-1534	34.66	8000	3575	80.79
	mai	8980		41	6811	-2169	24.15	15000	6020	67.04
	jun	62940		42	76777	13837	21.98	80000	17060	27.11
	jul	88145		43	122482	34337	38.96	200000	111855	126.90
	ago	327125		44	256798	-70327	21.50	420000	92875	28.39
	set	308180		45	269235	-38945	12.64	370000	61820	20.06
	out	344800		46	295220	-49580	14.38	220000	-124800	36.19
	nov	378860		47	379036	176	0.05	300000	-78860	20.82
	dez	153520		48	164167	10647	6.93	56500	-97020	63.20
						MAPE ANO (%)		19.47	MAPE ANO (%)	
					MAPE ALTA (%)		11.10	MAPE ALTA (%)		33.73

Tabela 18: Previsões Herbicida A




Gráfico 18: Previsões X Vendas – Herbicida A

Analisando a tabela e o gráfico, foi encontrado um valor alto do MAPE baseado no ano todo para a previsão feita pela empresa, novamente os valores que causam distorção eram os meses que apresentavam baixas vendas. Assim foi novamente calculada uma medida de erro somente para os meses de alta. Para este produto foram considerados apenas os meses de Agosto até Dezembro. Consideramos apenas estes cinco meses pois juntos representam aproximadamente 86% das vendas de 2005.

Assim, mais uma vez a previsão gerada pelo modelo Holt-Winter apresentou menor erro do que a previsão gerada pela empresa. O MAPE gerado pela previsão do modelo foi de 11,10% enquanto o MAPE gerado pela previsão da empresa foi de 33,73%. As maiores diferenças encontradas nestas previsões foram, nos meses de Agosto onde a previsão da empresa foi super-estimada e para os meses de Outubro até Dezembro onde a previsão ficou muito abaixo das vendas reais.

12.4 – Aplicação do Modelo – Herbicida B

O memorial de cálculos para as fases de inicialização e validação do modelo Holt-Winter será apresentado em anexo.

A fase de validação gerou os seguintes valores dos coeficientes:

Alfa	Beta	Gama
0.26	0.12	1.00

Esses foram os valores encontrados que minimizaram o MAPE das previsões geradas nesta fase, que foi de 4,11%. Novamente foi encontrado um valor muito baixo para o MAPE o que mostra a aderência do modelo aos dados tratados. Este foi o primeiro produto que não apresentou valor nulo para Beta, o que demonstra uma importância um pouco maior do fator tendência, mas ainda é uma importância relativamente pequena. Novamente o valor de Gama é um o que mostra a forte importância do fator sazonalidade do produto.

A tabela que apresenta as previsões do modelo e a da empresa, assim como o gráfico comparativo das previsões são apresentados abaixo.

					Método Holt-Winter			Previsão da Empresa					
Ano	Mês	Venda Real (Kg)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio Absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio Absoluto (%)			
2005	jan	104300	Teste	37	127928	23628	22.65	150000	45700	43.82			
	fev	65220		38	87181	21961	33.67	100000	34780	53.33			
	mar	96560		39	124100	27540	28.52	100000	3440	3.56			
	abr	141280		40	182716	41436	29.33	185000	43720	30.95			
	mai	164340		41	160014	-4326	2.63	102000	-62340	37.93			
	jun	201900		42	222313	20413	10.11	300000	98100	48.59			
	jul	186910		43	138821	-48089	25.73	400000	213090	114.01			
	ago	1068770		44	1310100	241330	22.58	960000	-108770	10.18			
	set	1355400		45	1434252	78852	5.82	800000	-555400	40.98			
	out	934340		46	770177	-164163	17.57	420000	-514340	55.05			
	nov	828620		47	637678	-190942	23.04	500000	-328620	39.66			
	dez	365600		48	215191	-150409	41.14	150000	-215600	58.97			
						MAPE ANO (%)		21.90			MAPE ANO (%)	44.75	
						MAPE ALTA (%)		22.03			MAPE ALTA (%)	40.97	

Tabela 19: Previsões Herbicida B




Gráfico 19: Previsões X Vendas – Herbicida B

Analisando a tabela e o gráfico, foi encontrado um valor alto do MAPE baseado no ano todo para a previsão feita pela empresa, porém ao se calcular o MAPE baseado nos meses de alta (Agosto até Dezembro), os valores encontrados não são muito diferentes dos encontrados anteriormente. Porém para se manter um padrão neste trabalho estas medidas de erro serão usadas para efeito de comparação. Os meses de alta considerados nesta ponderação representam aproximadamente 83% das vendas de 2005.

Assim, mais uma vez a previsão gerada pelo modelo Holt-Winter apresentou menor erro do que a previsão gerada pela empresa. O MAPE gerado pela previsão do modelo foi de 22,03% enquanto o MAPE gerado pela previsão da empresa foi de 40,97%. Um padrão percebido nas previsões feita pela empresa, é que durante o período de altas a previsão foi sempre menor que as vendas reais. Já a previsão gerada pelo modelo ficou dois meses acima e três abaixo durante as altas, porém em proporções menores que a previsão da empresa.

12.5 – Aplicação do Modelo – Fungicida A

O memorial de cálculos para as fases de inicialização e validação do modelo Holt-Winter será apresentado em anexo.

A fase de validação gerou os seguintes valores dos coeficientes:

Alfa	Beta	Gama
0.15	0	1.00

Esses foram os valores encontrados que minimizaram o MAPE das previsões geradas nesta fase, que foi de 0,15%. Novamente foi encontrado um valor muito baixo para o MAPE o que mostra a aderência do modelo aos dados tratados. O valor de Beta novamente volta a ser nulo, demonstrando pouca importância para o fator tendência. Mais uma vez o valor de Gama é um o que mostra a forte importância do fator sazonalidade do produto.

A tabela que apresenta as previsões do modelo e a da empresa, assim como o gráfico comparativo das previsões são apresentados abaixo.

					Método Holt-Winter			Previsão da Empresa				
Ano	Mês	Venda Real (L)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio Absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio Absoluto (%)		
2005	jan	3216	Teste	37	4320	1104	34.34	1500	-1716	53.36		
	fev	3843		38	3225	-618	16.09	1000	-2843	73.98		
	mar	428436		39	399227	-29209	6.82	500000	71564	16.70		
	abr	128440		40	151340	22900	17.83	200000	71560	55.71		
	mai	240932		41	223972	-16960	7.04	250000	9068	3.76		
	jun	126220		42	117548	-8672	6.87	100000	-26220	20.77		
	jul	83008		43	72961	-10047	12.10	50000	-33008	39.76		
	ago	27484		44	20286	-7198	26.19	20000	-7484	27.23		
	set	13180		45	6215	-6965	52.84	6000	-7180	54.48		
	out	2134		46	985	-1149	53.84	5000	2866	134.30		
	nov	2076		47	1356	-720	34.66	1000	-1076	51.83		
	dez	1658		48	1499	-159	9.61	3000	1342	80.94		
						MAPE ANO (%)		23.19	MAPE ANO (%)		51.07	
						MAPE ALTA (%)		10.13	MAPE ALTA (%)		27.34	

Tabela 20: Previsões Fungicida A




Gráfico 20: Previsões X Vendas – Fungicida A

Analisando a tabela e o gráfico, foi encontrado um valor alto do MAPE baseado no ano todo para a previsão feita pela empresa, novamente os valores que causam distorção eram os meses que apresentavam baixas vendas. Assim foi adotada a medida de erro somente para os meses de alta. Para este produto foram considerados apenas os meses de Março até Julho. Consideramos apenas estes cinco meses pois juntos representam aproximadamente 95% das vendas de 2005.

Assim, mais uma vez a previsão gerada pelo modelo Holt-Winter apresentou menor erro do que a previsão gerada pela empresa. O MAPE gerado pela previsão do modelo foi de 10,13% enquanto o MAPE gerado pela previsão da empresa foi de 27,34%. As maiores diferenças encontradas nestas previsões foram nos meses de Março e Abril onde a previsão da empresa foi relativamente alta as vendas, fato que não ocorre para as previsões do modelo.

12.6 – Aplicação do Modelo – Fungicida B

O memorial de cálculos para as fases de inicialização e validação do modelo Holt-Winter será apresentado em anexo.

A fase de validação gerou os seguintes valores dos coeficientes:

Alfa	Beta	Gama
0.06	0.01	1.00

Esses foram os valores encontrados que minimizaram o MAPE das previsões geradas nesta fase, que foi de 0,98%. Novamente foi encontrado um valor muito baixo para o MAPE o que mostra a aderência do modelo aos dados tratados. Este produto apresenta o menor valor de alfa encontrado até aqui, fazendo com que o fator de nível sofra pouca alteração em relação ao valor encontrado na fase de inicialização. O valor de gama é praticamente nulo, mostrando pouca importância do fator de tendência. Mais uma vez o valor de Gama é um o que mostra a forte importância do fator sazonalidade do produto.

A tabela que apresenta as previsões do modelo e a da empresa, assim como o gráfico comparativo das previsões são apresentados abaixo.

					Método Holt-Winter			Previsão da Empresa		
Ano	Mês	Venda Real (L)	Fase	Período	Previsão (F)	Desvio Relativo	Desvio Absoluto (%)	Previsão Empresa	Desvio Relativo	Desvio Absoluto (%)
2005	jan	15589	Teste	37	10871	-4718	30.27	25000	9411	60.37
	fev	17676		38	15385	-2291	12.96	20000	2324	13.15
	mar	61528		39	47819	-13709	22.28	35500	-26028	42.30
	abr	68426		40	58544	-9882	14.44	37000	-31426	45.93
	mai	87388		41	73811	-13577	15.54	100000	12612	14.43
	jun	74993		42	50606	-24387	32.52	50000	-24993	33.33
	jul	29500		43	20317	-9183	31.13	23000	-6500	22.03
	ago	14544		44	11206	-3338	22.95	30000	15456	106.27
	set	9496		45	9496	0	0.00	15000	5504	57.96
	out	1636		46	1762	126	7.71	5000	3364	205.62
	nov	4235		47	2655	-1580	37.31	7000	2765	65.29
	dez	8756		48	6057	-2699	30.83	12000	3244	37.05
					MAPE ANO (%)		21.49	MAPE ANO (%)		58.64
					MAPE ALTA (%)		23.18	MAPE ALTA (%)		31.60

Tabela 21: Previsões Fungicida B

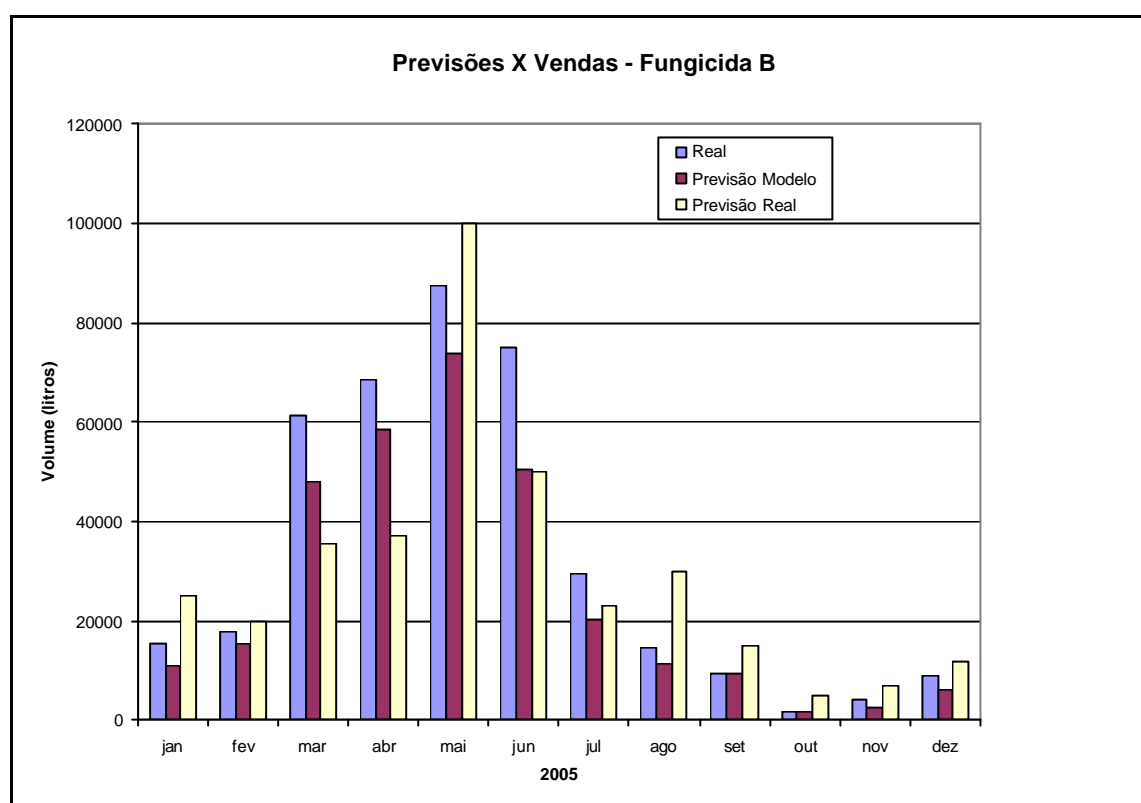


Gráfico 21: Previsões X Vendas – Fungicida B

Analisando a tabela e o gráfico, foi encontrado um valor alto do MAPE baseado no ano todo para a previsão feita pela empresa, porém ao se calcular o MAPE baseado nos meses de alta (Março até Julho), o valor encontrado para a previsão da empresa é muito menor, enquanto que para a previsão do modelo o valor é praticamente o mesmo, piorando aproximadamente 2%. Assim, para se manter um padrão neste trabalho estas medidas de erro serão usadas para efeito de comparação. Os meses de alta considerados nesta ponderação representam aproximadamente 82% das vendas de 2005.

Assim, mais uma vez a previsão gerada pelo modelo Holt-Winter apresentou menor erro do que a previsão gerada pela empresa. O MAPE gerado pela previsão do modelo foi de 23,18% enquanto o MAPE gerado pela previsão da empresa foi de 31,60%. Um padrão percebido no período de altas é que na maioria dos meses ambas previsões ficaram abaixo das vendas, porém em proporções diferentes, sendo que a previsão da empresa apresenta maior desvio.

13 Análise Econômica da Solução

Após aplicar o método de Holt-Winters aos produtos piloto, foi gerada uma redução considerável do erro de previsão em relação à previsão feita pela empresa. Agora será realizada uma mensuração econômica dessa redução para que seja explicitado qual o ganho que esta implementação traria em relação a os produtos piloto. Lembrando que esses produtos foram responsáveis em 2005 por cerca de 30% do faturamento da divisão de proteção de cultivos, que é responsável por 86% do faturamento da empresa no Brasil.

Para estimar o ganho com cada produto piloto será usada a seguinte metodologia de mensuração: Primeiro será calculado a redução do erro que o modelo gera em relação ao erro da previsão da empresa; Segundo, para cada produto os desvios relativos do modelo de previsão da empresa serão valorizados. Esses desvios serão classificados em dois grupos para que sejam valorizados de maneira diferenciada. Os desvios positivos serão classificados como custos de manutenção de estoques, que é formado por dois custos: o custo de capital e o custo de armazenagem. O custo de capital é o custo de se ter o capital preso em forma de produtos, perdendo juros caso estivesse investido, ou seja, é um custo de oportunidade. Já o custo de armazenagem é quanto custa para a empresa manter o estoque parado em seus armazéns, ele inclui custos de transportes, perdas, obsolescências, taxas de seguro e custo da área física. Para o cálculo do custo de capital será usada a taxa média de juros de 2005 multiplicado pelo custo total de produção dos produtos excedentes, esse cálculo sendo realizado mês a mês. Já o cálculo de armazenagem será feito a partir de um número estimado pelo setor de produção da empresa, sendo considerado o mesmo para produtos vendidos em quilos ou em litros.

Os desvios negativos serão valorizados de acordo com o a margem de cada produto. Ou seja, é a perda de lucro por incapacidade de suprir a demanda. Não serão considerados custos como multas e encargos por não cumprimento do prazo de entrega ou perda de clientes por não atender aos pedidos. Este custo será calculado com a multiplicação da margem de cada produto pelo total previsto a menos.

O desvio negativo não representa que a empresa deixou de vender por causa do erro de previsão, pois parte ou toda a demanda foi suprida de alguma maneira, mesmo com a previsão subestimada. Este suprimento pode ter ocorrido através o estoque de segurança, ou através de uma produção emergencial ou até transferência da outra planta da empresa na América Latina. Assim a empresa não teve essa perda de lucro calculada, porém este seria o benefício que o modelo causaria para a empresa, pois não é possível calcular neste momento qual foi o custo despendido para suprir este erro de previsão.

Assim durante o ano teremos um fluxo de caixa, que seriam as reduções mês a mês. Com isso traremos todos os valores para janeiro de 2005, considerando a taxa média de juros de 2005. Estimando assim o valor presente (janeiro de 2005) que a implementação do modelo traria para a empresa, por produto piloto. Com isso feito, basta somarmos esse ganho para todos os produtos piloto. Tendo assim o ganho econômico estimado que este modelo traria para a divisão de proteção de cultivo da empresa pelos produtos piloto.

As reduções no erro alcançadas pelo método foram:

	MAPE Empresa (%)	MAPE Modelo (%)	Redução do Erro
Pesticida A	45.70	12.32	73%
Pesticida B	22.26	14.48	35%
Herbicida A	33.73	11.10	67%
Herbicida B	40.97	22.03	46%
Fungicida A	27.34	10.13	63%
Fungicida B	31.60	23.18	27%

Tabela 22: Reduções do erro de previsão

Com a redução do erro de cada produto calculada, usaremos uma taxa média de juros de 1,46% ao mês. Apenas será apresentado o calculo completo para o pesticida A, o memorial de cálculo dos outros produtos se encontra no anexo. Apresentaremos então o resultado obtido para os produtos piloto.

Pesticida A:

Redução: 73%

Custo de Produção: R\$ 18,07

Preço do Produto: R\$ 25,83

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

Mês	Venda Real (Kg)	Previsão Empresa (Kg)	Desvio Relativo (Kg)	Redução (Kg)	Custo Capital (R\$)	Custo Armazenagem (R\$)	Custo perda de lucro (R\$)	SOMA (R\$)	Valor Presente (R\$)
jan	98,205	120,000	21,795	15,910	4,223	981		5,204	5,204
fev	79,810	90,000	10,190	7,439	1,975	459		2,433	2,398
mar	82,638	135,000	52,362	38,224	10,147	2,356		12,503	12,144
abr	12,930	40,000	27,070	19,761	5,246	1,218		6,464	6,187
mai	905	2,000	1,095	799	212	49		261	247
jun	1,035	4,000	2,965	2,164	575	133		708	658
jul	1,863	5,000	3,137	2,290	608	141		749	686
ago	28,510	50,000	21,490	15,688	4,164	967		5,131	4,633
set	59,325	90,000	30,675	22,393	5,944	1,380		7,325	6,518
out	116,500	200,000	83,500	60,955	16,181	3,758		19,938	17,486
nov	143,867	236,000	92,133	67,257	17,854	4,146		22,000	19,015
dez	180,045	172,000	-8,045	-5,873			45,588	45,588	38,832
Total								R\$ 114,008.17	

Tabela 23: Cálculo do Ganho econômico Pesticida A

Vale ressaltar que o custo de capital e de armazenagem só é calculado par desvios positivos, ou seja, quando a previsão foi superestimada, já o custo de perda de lucro é calculado para desvios negativos, ou seja, quando a previsão é subestimada.

A coluna desvio relativo é o erro da previsão em volume, assim a coluna redução representa o ganho em volume com o modelo sugerido neste trabalho, que é calculado pela multiplicação do desvio relativo pela redução, que neste caso é de 73%. O custo de capital é calculado pelo produto da redução pela taxa de juros. O custo de armazenagem é calculado com pela multiplicação entre o custo mensal em toneladas pelo volume que seria reduzido na coluna redução. Custo da perda de lucro é o produto entre as reduções negativas e a diferença entre preço e custo do produto.

Assim aplicando o mesmo procedimento para os seis produtos piloto, o seguinte resultado é obtido:

Produto	Ganho anual
Pesticida A	R\$ 114,008
Pesticida B	R\$ 213,525
Herbicida A	R\$ 579,543
Herbicida B	R\$ 511,501
Fungicida A	R\$ 168,690
Fungicida B	R\$ 205,935
Total	R\$ 1,793,202

Tabela 24: Ganho Anual dos Produtos Piloto

Vale lembrar que o cálculo detalhado dos outros produtos piloto se encontra em anexo.

Podemos observar que os produtos que geraram maior ganho foram os herbicidas, isto ocorre, pois estes produtos apresentam vendas altíssimas em volume e a previsão para eles apresentaram grandes desvios negativos, ou seja, a previsão foi menor do que as vendas, fazendo com que o custo de perda de lucro fosse elevado.

Assim o ganho estimado que a empresa teria caso implementasse o modelo para estes produtos em 2005 seria de R\$ 1.793.202,00 o que representa cerca de 0,162% do faturamento total da empresa ou aproximadamente 0,19% do faturamento dos defensivos agrícolas.

Estes ganhos foram estimados baseando-se nas previsões feitas no começo do ano, ou seja, no número em que a empresa se baseia para estimar o orçamento. É possível observar que os erros da previsão feita pela empresa são grandes, fazendo com que a redução do erro gerado pelo modelo também fosse grande, o que resultou no elevado ganho estimado acima.

14 Conclusão

Com o desenvolvimento deste trabalho pode-se observar e entender os benefícios que um bom modelo de previsão de demanda pode trazer para a empresa. Com os resultados obtidos pudemos observar que existe um grande espaço para o aprimoramento do processo de previsão atual. Este processo é muito engessado, com muitas reuniões, porém seu ponto mais fraco é o fato de que o número inicial é gerado pelos vendedores. Isto porque os vendedores não estão capacitados para realizarem tal tarefa. Uma vez que o vendedor reporta um número impreciso, por melhor que sejam os executivos responsáveis pelo afinamento, sempre existirá um erro agregado que irá permanecer por toda a cadeia decisória.

Uma solução aplicável a estrutura e a cultura da empresa seria usar o modelo estatístico como input para as reuniões. Assim não existiria a necessidade de ser gerada uma previsão por vendedor, todo o processo de previsão estaria concentrado. Isto traria benefícios tanto para as áreas responsáveis por fechar o número final quanto para os vendedores. Primeiramente os vendedores ficariam responsáveis apenas por vender, voltando inteiramente o seu esforço para o que eles fazem de melhor. Já o processo de previsão ficaria mais flexível e ágil, pois não dependeria de uma consolidação prévia de todas as estimativas de vendedores, diminuindo também o tempo que os executivos perderiam com reuniões para a definição de previsões. Além disso, seria mais precisa, o que pode ser observado nos testes realizados neste trabalho. A sugestão não é acabar com o modelo atual de previsão, e sim aprimorá-lo de forma a aumentar a precisão.

Os resultados obtidos foram extremamente encorajadores. A análise do comportamento dos produtos mostrou que eles apresentam comportamento bem definido, com pouca aleatoriedade, o que facilita o processo de aplicação de modelos de previsão de demanda. Além disso, na etapa de testes pode-se observar que mesmo para uma previsão com um ano de antecedência, o modelo gerou resultados muito melhores do que os atuais. Aliado a estimativa com a ganho na redução do erro de previsão, é possível concluir que existe viabilidade econômica para o desenvolvimento de um projeto para a implementação do modelo de previsão de demanda testado.

Para uma previsão com horizonte de três a quatro meses, é esperado que o modelo gere dados com maior precisão. Porém a conclusão que se chega a respeito do ganho econômico é que este seria menor para as previsões com menor horizonte. Isto porque o modelo atual de previsão gerou erros extremamente altos para a previsão com um ano de horizonte, tendendo a gerar maior redução no erro com a diminuição do horizonte.

Um problema que pode ser observado na empresa foi que por causa do alto aquecimento do mercado agrícola brasileiro, que vem sofrendo grande expansão nos últimos anos, a empresa muitas vezes não percebe quão custosos são os erros de previsão, pois de uma forma ou de outra ela consegue se livrar dos altos níveis de estoque, porém caso o mercado sofra um desaquecimento, estes erros podem se tornar mais evidentes virando assim um problema a ser resolvido com urgência.

Pode-se entender que um modelo de previsão de demanda não precisa ser sempre o mais sofisticado para funcionar, muitos critérios devem ser considerados para que seja escolhido um modelo. É fundamental definir qual o objetivo do modelo, para que esta escolha seja feita visando o maior custo / benefício possível.

Este trabalho agregou muito para o desenvolvimento acadêmico e profissional do aluno. É fundamental se deparar com um problema real, onde foi visto que nem sempre toda a teoria aprendida funciona da melhor maneira possível. É necessário criatividade, para adaptar toda a teoria estudada as limitações do seu problema, encontrando assim soluções que sejam adequadas e se mostrem eficientes. Pelo lado profissional, este trabalho possibilitou ao aluno interagir com diferentes áreas e diferentes processos, ampliando a visão pré-existente a respeito da estrutura da empresa e da cadeia decisória.

Assim, com os resultados obtidos e com o entendimento das necessidades da empresa, pode-se esperar que a implementação de um modelo estatístico de previsão de demanda seja um dos próximos passos a serem dados, para que cada vez mais a empresa melhore sua forma de atuação, buscando sempre a excelência.

15 Bibliografia

- MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven; HYNDMAN, Rob. **Forecasting: Methods and Applications**. 3rd edition. New York, John Wiley & Sons, 1998
 - JARRETT, Jeffrey. **Business Forecasting Methods**. 1st edition. Oxford, Basil Blackwell Ltd, 1987.
 - O'DONOVAN, Thomas M. **Short Term Forecasting – An Introduction to the Box-Jenkins Approach**. 1st edition. New York, John Wiley & Sons, 1983.
 - ALVIM, André Chang. **Previsão de Demanda no Varejo**. Trabalho de Formatura. São Paulo, EPUSP, 2003.
 - KIYUZATO, Leandro. **Aplicação de Modelos de Previsão de Demanda em Empresa com Vendas Sazonais**. Trabalho de Formatura. São Paulo, EPUSP, 2001.
 - FERRARI, Adriana. **Previsão de Vendas para um Bem de Consumo**. Trabalho de Formatura. São Paulo, EPUSP, 1996.
-

16 Anexos

16.1 – Histórico de Venda dos Produtos Piloto

Pesticida A

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	2,534 KG	8,885 KG	3,121 KG	9,490 KG	2,965 KG	9,910 KG	11,420 KG	20,500 KG	64,325 KG	95,005 KG	107,046 KG	66,470 KG
2003	1,945 KG	8,595 KG	23,400 KG	14,640 KG	4,205 KG	3,073 KG	6,354 KG	42,985 KG	58,320 KG	42,830 KG	85,694 KG	181,840 KG
2004	97,480 KG	100,960 KG	128,745 KG	19,155 KG	730 KG	2,770 KG	3,305 KG	40,985 KG	73,015 KG	110,165 KG	137,215 KG	164,260 KG
2005	98,205 KG	79,810 KG	82,638 KG	12,930 KG	905 KG	1,035 KG	1,863 KG	28,510 KG	59,325 KG	116,500 KG	143,867 KG	180,045 KG

Pesticida B

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	1,219 KG	1,490 KG	2,393 KG	1,364 KG	660 KG	2,555 KG	1,853 KG	3,240 KG	9,581 KG	17,325 KG	15,681 KG	11,390 KG
2003	2,140 KG	7,438 KG	2,440 KG	7,630 KG	3,645 KG	2,821 KG	720 KG	4,170 KG	20,182 KG	43,357 KG	28,194 KG	29,322 KG
2004	11,719 KG	6,400 KG	18,220 KG	11,159 KG	4,672 KG	2,095 KG	1,908 KG	9,882 KG	18,331 KG	58,472 KG	81,543 KG	31,850 KG
2005	14,020 KG	8,654 KG	15,430 KG	4,842 KG	2,760 KG	2,030 KG	3,395 KG	14,690 KG	35,358 KG	66,422 KG	90,432 KG	38,941 KG

Herbicida A

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	18,040 L	10,520 L	37,346 L	2,634 L	7,923 L	72,105 L	170,265 L	130,225 L	233,875 L	337,345 L	85,095 L	85,780 L
2003	26,400 L	25,040 L	4,160 L	3,630 L	8,342 L	27,365 L	199,000 L	238,840 L	183,780 L	181,420 L	285,190 L	176,585 L
2004	85,900 L	28,800 L	12,620 L	3,600 L	7,080 L	101,220 L	126,120 L	240,160 L	243,960 L	253,155 L	361,825 L	151,465 L
2005	58,695 L	21,635 L	17,470 L	4,425 L	8,980 L	62,940 L	88,145 L	327,125 L	308,180 L	344,800 L	378,860 L	153,520 L

Herbicida B

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	65,700 KG	125,060 KG	43,640 KG	14,320 KG	20,300 KG	136,000 KG	185,500 KG	218,500 KG	180,200 KG	73,300 KG	139,480 KG	191,000 KG
2003	55,700 KG	64,320 KG	40,460 KG	50,520 KG	43,840 KG	186,660 KG	183,940 KG	357,920 KG	563,620 KG	403,100 KG	275,640 KG	286,680 KG
2004	86,640 KG	47,800 KG	61,300 KG	106,180 KG	120,340 KG	145,000 KG	72,560 KG	790,420 KG	928,680 KG	553,740 KG	548,880 KG	157,120 KG
2005	104,300 KG	65,220 KG	96,560 KG	141,280 KG	164,340 KG	201,900 KG	186,910 KG	1,068,770 KG	1,355,400 KG	934,340 KG	828,620 KG	365,600 KG

Fungicida A

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	250 L	120 L	265,402 L	168,120 L	158,832 L	87,312 L	20,304 L	9,120 L	5,712 L	5,220 L	4,284 L	648 L
2003	300 L	49,008 L	189,756 L	166,692 L	295,164 L	136,212 L	31,776 L	10,428 L	2,784 L	4,944 L	6,576 L	1,464 L
2004	1,928 L	1,248 L	362,520 L	151,788 L	228,039 L	120,744 L	80,016 L	15,728 L	9,068 L	1,240 L	1,470 L	1,486 L
2005	3,216 L	3,843 L	428,436 L	128,440 L	240,932 L	126,220 L	83,008 L	27,484 L	13,180 L	2,134 L	2,076 L	1,658 L

Fungicida B

Ano	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	dezembro
2002	420 L	1,140 L	11,544 L	41,614 L	19,208 L	49,448 L	16,090 L	7,350 L	3,835 L	1,465 L	974 L	3,675 L
2003	2,040 L	3,012 L	9,788 L	28,372 L	23,654 L	32,928 L	4,788 L	5,628 L	4,758 L	856 L	1,385 L	6,000 L
2004	7,008 L	11,616 L	41,700 L	52,013 L	69,736 L	47,650 L	21,037 L	11,712 L	10,021 L	1,877 L	2,844 L	6,333 L
2005	15,589 L	17,676 L	61,528 L	68,426 L	87,388 L	74,993 L	29,500 L	14,544 L	9,496 L	1,636 L	4,235 L	8,756 L

16.2 – Memorial de cálculos das etapas de inicialização e validação

Pesticida B

Pesticida B				Alfa	Beta	Gama	MAPE Validação (%)			
				0.30	0.00	1.00	3.19			
Ano	Mês	Venda Real (Kg)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)
2002	jan	1219	Inicialização	1			0.21			
	fev	1490		2			0.26			
	mar	2393		3			0.42			
	abr	1364		4			0.24			
	mai	660		5			0.12			
	jun	2555		6			0.45			
	jul	1853		7			0.32			
	ago	3240		8			0.57			
	set	9581		9			1.67			
	out	17325		10			3.02			
	nov	15681		11			2.74			
	dez	11390		12	5729.25	578.53	1.99			
2003	jan	2140	Validação	13	7435	579	0.29	2307	167	7.78
	fev	7438		14	14202	579	0.52	7741	303	4.07
	mar	2440		15	12093	579	0.20	2557	117	4.78
	abr	7630		16	18496	579	0.41	7869	239	3.13
	mai	3645		17	22852	579	0.16	3737	92	2.53
	jun	2821		18	18289	579	0.15	2910	89	3.16
	jul	720		19	13865	579	0.05	750	30	4.17
	ago	4170		20	12319	579	0.34	4366	196	4.70
	set	20182		21	12648	579	1.60	21105	923	4.57
	out	43357		22	13561	579	3.20	45207	1850	4.27
	nov	28194		23	12986	579	2.17	29450	1256	4.46
	dez	29322		24	13920	579	2.11	30541	1219	4.16
2004	jan	11719	Validação	25	22379	579	0.52	12022	303	2.59
	fev	6400		26	19730	579	0.32	6588	188	2.93
	mar	18220		27	41349	579	0.44	18475	255	1.40
	abr	11159		28	37456	579	0.30	11332	172	1.54
	mai	4672		29	35406	579	0.13	4748	76	1.63
	jun	2095		30	29251	579	0.07	2136	41	1.98
	jul	1908		31	31908	579	0.06	1943	35	1.81
	ago	9882		32	31495	579	0.31	10064	182	1.84
	set	18331		33	25886	579	0.71	18741	410	2.23
	out	58472		34	24007	579	2.44	59881	1409	2.41
	nov	81543		35	28484	579	2.86	83199	1656	2.03
	dez	31850		36	24872	579	1.28	32591	741	2.33

Herbicida A

Herbicida A					Alfa	Beta	Gama	MAPE Validação (%)		
					0.30	0.00	1.00	0.80		
Ano	Mês	Venda Real (L)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)
2002	jan	18040	Inicialização	1			0.18			
	fev	10520		2			0.11			
	mar	37346		3			0.38			
	abr	2634		4			0.03			
	mai	7923		5			0.08			
	jun	72105		6			0.73			
	jul	170265		7			1.72			
	ago	130225		8			1.31			
	set	233875		9			2.36			
	out	337345		10			3.40			
	nov	85095		11			0.86			
	dez	85780		12	99262.75	1170.83	0.86			
2003	jan	26400	Validação	13	113909	1171	0.23	26671	271	1.03
	fev	25040		14	151508	1171	0.17	25234	194	0.77
	mar	4160		15	110108	1171	0.04	4204	44	1.06
	abr	3630		16	118950	1171	0.03	3666	36	0.98
	mai	8342		17	115429	1171	0.07	8427	85	1.01
	jun	27365		18	92875	1171	0.29	27710	345	1.26
	jul	199000		19	100649	1171	1.98	201315	2315	1.16
	ago	238840		20	125938	1171	1.90	241060	2220	0.93
	set	183780		21	112347	1171	1.64	185695	1915	1.04
	out	181420		22	95442	1171	1.90	183646	2226	1.23
	nov	285190		23	167570	1171	1.70	287183	1993	0.70
	dez	176585		24	179442	1171	0.98	177737	1152	0.65
2004	jan	85900	Validação	25	237731	1171	0.36	86323	423	0.49
	fev	28800		26	219471	1171	0.13	28954	154	0.53
	mar	12620		27	254725	1171	0.05	12678	58	0.46
	abr	3600		28	214436	1171	0.02	3620	20	0.55
	mai	7080		29	180245	1171	0.04	7126	46	0.65
	jun	101220		30	230147	1171	0.44	101735	515	0.51
	jul	126120		31	180960	1171	0.70	126936	816	0.65
	ago	240160		32	165449	1171	1.45	241860	1700	0.71
	set	243960		33	161364	1171	1.51	245730	1770	0.73
	out	253155		34	153711	1171	1.65	255083	1928	0.76
	nov	361825		35	172231	1171	2.10	364285	2460	0.68
	dez	151465		36	167544	1171	0.90	152523	1058	0.70

Herbicida B

Herbicida B				Alfa		Beta		Gama		MAPE Validação (%)		
				0.26		0.12		1.00		4.11		
Ano	Mês	Venda Real (Kg)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)		
2002	jan	65700	Inicialização	1			0.57					
	fev	125060		2			1.08					
	mar	43640		3			0.38					
	abr	14320		4			0.12					
	mai	20300		5			0.17					
	jun	136000		6			1.17					
	jul	185500		7			1.60					
	ago	218500		8			1.88					
	set	180200		9			1.55					
	out	73300		10			0.63					
	nov	139480		11			1.20					
	dez	191000		12	116083.33	7773.61	1.65					
2003	jan	55700	Validação	13	117181	6972	0.48	59014	3314	5.95		
	fev	64320		14	107242	4943	0.60	67285	2965	4.61		
	mar	40460		15	110988	4800	0.36	42210	1750	4.32		
	abr	50520		16	192866	14049	0.26	54200	3680	7.28		
	mai	43840		17	218402	15427	0.20	46937	3097	7.06		
	jun	186660		18	214280	13081	0.87	198055	11395	6.10		
	jul	183940		19	197906	9547	0.93	192813	8873	4.82		
	ago	357920		20	202914	9002	1.76	373799	15879	4.44		
	set	563620		21	251580	13762	2.24	594451	30831	5.47		
	out	403100		22	363225	25508	1.11	431408	28308	7.02		
	nov	275640		23	346926	20491	0.79	291921	16280	5.91		
	dez	286680		24	316727	14408	0.91	299721	13041	4.55		
2004	jan	86640		25	292074	9721	0.30	89524	2884	3.33		
	fev	47800		26	243517	2728	0.20	48335	535	1.12		
	mar	61300		27	225755	269	0.27	61373	73	0.12		
	abr	106180		28	273079	5915	0.39	108480	2300	2.17		
	mai	120340		29	363096	16008	0.33	125645	5305	4.41		
	jun	145000		30	323306	9312	0.45	149176	4176	2.88		
	jul	72560		31	265825	1297	0.27	72914	354	0.49		
	ago	790420		32	314612	6996	2.51	807995	17575	2.22		
	set	928680		33	345990	9921	2.68	955310	26630	2.87		
	out	553740		34	393448	14426	1.41	574043	20303	3.67		
	nov	548880		35	482120	23335	1.14	575447	26567	4.84		
	dez	157120		36	418375	12886	0.38	161959	4839	3.08		

Fungicida A

Fungicida A				Alfa	Beta	Gama	MAPE Validação (%)			
				0.15	0.00	1.00	0.15			
Ano	Mês	Venda Real (L)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)
2002	jan	250	Inicialização	1			0.00			
	fev	120		2			0.00			
	mar	265402		3			4.39			
	abr	168120		4			2.78			
	mai	158832		5			2.63			
	jun	87312		6			1.44			
	jul	20304		7			0.34			
	ago	9120		8			0.15			
	set	5712		9			0.09			
	out	5220		10			0.09			
	nov	4284		11			0.07			
	dez	648		12	60443.67	1179.03	0.01			
2003	jan	300	Validação	13	63303	1179	0.005	306	6	1.86
	fev	49008		14	3855986	1179	0.01	49023	15	0.03
	mar	189756		15	3269830	1179	0.06	189824	68	0.04
	abr	166692		16	2776514	1179	0.06	166763	71	0.04
	mai	295164		17	2367236	1179	0.12	295311	147	0.05
	jun	136212		18	2018208	1179	0.07	136292	80	0.06
	jul	31776		19	1722976	1179	0.02	31798	22	0.07
	ago	10428		20	1469284	1179	0.01	10436	8	0.08
	set	2784		21	1248554	1179	0.002	2787	3	0.09
	out	4944		22	1066094	1179	0.005	4949	5	0.11
	nov	6576		23	917205	1179	0.01	6584	8	0.13
	dez	1464		24	797985	1179	0.002	1466	2	0.15
2004	jan	1928		25	738746	1179	0.003	1931	3	0.16
	fev	1248		26	641100	1179	0.002	1250	2	0.18
	mar	362520		27	1505365	1179	0.24	362804	284	0.08
	abr	151788		28	1663886	1179	0.09	151896	108	0.07
	mai	228039		29	1690293	1179	0.13	228198	159	0.07
	jun	120744		30	1706495	1179	0.07	120827	83	0.07
	jul	80016		31	2112838	1179	0.04	80061	45	0.06
	ago	15728		32	2129729	1179	0.01	15737	9	0.06
	set	9068		33	2429024	1179	0.004	9072	4	0.05
	out	1240		34	2097137	1179	0.001	1241	1	0.06
	nov	1470		35	1806757	1179	0.001	1471	1	0.07
	dez	1486		36	1654253	1179	0.001	1487	1	0.07

Fungicida B

Fungicida B				Alfa		Beta		Gama		MAPE Validação (%)	
				0.06		0.01		1.00		0.98	
Ano	Mês	Venda Real (L)	Fase	Período	Nível (L)	Tendência (b)	Sazonalidade (S)	Previsão (F)	Desvio Absoluto	Desvio Absoluto (%)	
2002	jan	420	Inicialização	1			0.03				
	fev	1140		2			0.09				
	mar	11544		3			0.88				
	abr	41614		4			3.19				
	mai	19208		5			1.47				
	jun	49448		6			3.79				
	jul	16090		7			1.23				
	ago	7350		8			0.56				
	set	3835		9			0.29				
	out	1465		10			0.11				
	nov	974		11			0.07				
	dez	3675		12	13063.58	-233.01	0.28				
2003	jan	2040	Validação	13	15704	-205	0.13	2013	-27	1.31	
	fev	3012		14	16578	-194	0.18	2977	-35	1.17	
	mar	9788		15	16083	-197	0.61	9668	-120	1.23	
	abr	28372		16	15489	-201	1.83	28003	-369	1.30	
	mai	23654		17	15333	-201	1.54	23344	-310	1.31	
	jun	32928		18	14767	-204	2.23	32472	-456	1.38	
	jul	4788		19	13957	-210	0.34	4716	-72	1.51	
	ago	5628		20	13534	-212	0.42	5540	-88	1.57	
	set	4758		21	13485	-211	0.35	4684	-74	1.56	
	out	856		22	12954	-214	0.07	842	-14	1.65	
	nov	1385		23	13072	-211	0.11	1363	-22	1.61	
	dez	6000		24	13342	-206	0.45	5907	-93	1.54	
2004	jan	7008	Validação	25	15452	-183	0.45	6925	-83	1.19	
	fev	11616		26	18031	-156	0.64	11515	-101	0.87	
	mar	41700		27	20749	-128	2.01	41442	-258	0.62	
	abr	52013		28	21062	-124	2.47	51706	-307	0.59	
	mai	69736		29	22315	-111	3.13	69390	-346	0.50	
	jun	47650		30	22157	-111	2.15	47411	-239	0.50	
	jul	21037		31	24275	-89	0.87	20959	-78	0.37	
	ago	11712		32	24412	-87	0.48	11670	-42	0.36	
	set	10021		33	24556	-85	0.41	9986	-35	0.35	
	out	1877		34	24694	-83	0.08	1871	-6	0.34	
	nov	2844		35	24738	-82	0.11	2835	-9	0.33	
	dez	6333		36	24056	-87	0.26	6310	-23	0.36	

16.3 – Cálculo do valor econômico

Pesticida B

Redução: 35%

Custo de Produção: R\$ 22,25

Preço do Produto: R\$ 37,25

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

Mês	Venda Real (Kg)	Previsão Empresa (Kg)	Desvio Relativo (Kg)	Redução (Kg)	Custo Capital (R\$)	Custo Armazenagem (R\$)	Custo perda de lucro (R\$)	SOMA (R\$)	Valor Presente (R\$)
jan	14020	30000	15,980	5,593	1,828	252		2,079	2,079
fev	8654	15000	6,346	2,221	726	100		826	814
mar	15430	20000	4,570	1,599	523	72		595	578
abr	4842	10000	5,158	1,805	590	81		671	642
mai	2760	5000	2,240	784	256	35		291	275
jun	2030	2000	-30	-11			158	158	146
jul	3395	15000	11,605	4,062	1,327	183		1,510	1,384
ago	14690	30000	15,310	5,359	1,751	241		1,992	1,799
set	35358	40000	4,642	1,625	531	73		604	538
out	66422	69000	2,578	902	295	41		335	294
nov	90432	60000	-30,432	-10,651			159,824	159,824	138,137
dez	38941	24000	-14,941	-5,229			78,467	78,467	66,839
Total								R\$ 213,524,51	

Herbicida A

Redução: 67%

Custo de Produção: R\$ 9,73

Preço do Produto: R\$ 12,80

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

Mês	Venda Real (L)	Previsão Empresa (L)	Desvio Relativo (L)	Redução (L)	Custo Capital (R\$)	Custo Armazenagem (R\$)	Custo perda de lucro (R\$)	SOMA (R\$)	Valor Presente (R\$)
jan	58695	90000	31,305	20,974	2,998	944		3,942	3,942
fev	21635	60000	38,365	25,705	3,674	1,157		4,831	4,761
mar	17470	40000	22,530	15,095	2,158	679		2,837	2,756
abr	4425	8000	3,575	2,395	342	108		450	431
mai	8980	15000	6,020	4,033	577	182		758	715
jun	62940	80000	17,060	11,430	1,634	514		2,148	1,997
jul	88145	200000	111,855	74,943	10,713	3,372		14,085	12,905
ago	327125	420000	92,875	62,226	8,895	2,800		11,695	10,560
set	308180	370000	61,820	41,419	5,921	1,864		7,785	6,927
out	344800	220000	-124,800	-83,616			256,335	256,335	224,807
nov	378860	300000	-78,860	-52,836			161,976	161,976	139,997
dez	153520	56500	-97,020	-65,003			199,276	199,276	169,743
Total	R\$ 579,542.72								

Herbicida B

Redução: 46%

Custo de Produção: R\$ 3,69

Preço do Produto: R\$ 4,38

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

Mês	Venda Real (Kg)	Previsão Empresa (Kg)	Desvio Relativo (Kg)	Redução (Kg)	Custo Capital (R\$)	Custo Armazenagem (R\$)	Custo perda de lucro (R\$)	SOMA (R\$)	Valor Presente (R\$)
jan	104300	150000	45,700	21,022	1,140	946		2,086	2,086
fev	65220	100000	34,780	15,999	868	720		1,588	1,565
mar	96560	100000	3,440	1,582	86	71		157	153
abr	141280	185000	43,720	20,111	1,091	905		1,996	1,911
mai	164340	102000	-62,340	-28,676			19,564	19,564	18,455
jun	201900	300000	98,100	45,126	2,448	2,031		4,479	4,164
jul	186910	400000	213,090	98,021	5,318	4,411		9,729	8,914
ago	1068770	960000	-108,770	-50,034			34,134	34,134	30,822
set	1355400	800000	-555,400	-255,484			174,297	174,297	155,105
out	934340	420000	-514,340	-236,596			161,411	161,411	141,559
nov	828620	500000	-328,620	-151,165			103,128	103,128	89,135
dez	365600	150000	-215,600	-99,176			67,660	67,660	57,633
Total	R\$ 511,501.41								

Fungicida A

Redução: 63%

Custo de Produção: R\$ 5,29

Preço do Produto: R\$ 8,70

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

Mês	Venda Real (L)	Previsão Empresa (L)	Desvio Relativo (L)	Redução (L)	Custo Capital (R\$)	Custo Armazenagem (R\$)	Custo perda de lucro (R\$)	SOMA (R\$)	Valor Presente (R\$)
jan	3216	1500	-1.716	-1.081			3.681	3.681	3.681
fev	3843	1000	-2.843	-1.791			6.099	6.099	6.011
mar	428436	500000	71.564	45.085	3.506	2.029		5.535	5.376
abr	128440	200000	71.560	45.083	3.506	2.029		5.534	5.298
mai	240932	250000	9.068	5.713	444	257		701	662
jun	126220	100000	-26.220	-16.519			56.252	56.252	52.297
jul	83008	50000	-33.008	-20.795			70.815	70.815	64.883
ago	27484	20000	-7.484	-4.715			16.056	16.056	14.498
set	13180	6000	-7.180	-4.523			15.404	15.404	13.708
out	2134	5000	2.866	1.806	140	81		222	194
nov	2076	1000	-1.076	-678			2.308	2.308	1.995
dez	1658	3000	1.342	845	66	38		104	88
Total									R\$ 168.690.30

Fungicida B

Redução: 27%

Custo de Produção: R\$ 13,04

Preço do Produto: R\$ 21,92

Taxa de Juros (mensal): 1,4689%

Custo de armazenagem mensal (tonelada): R\$ 45,00

