



Universidade de Aveiro
Ano 2021

**Diana
Cardoso
Neves**

**Previsão de Vendas e Planeamento de
Inventário: O Caso da DigiPneus**



**Diana
Cardoso
Neves**

Previsão de Vendas e Planeamento de Inventário: O Caso da DigiPneus

Relatório de projeto apresentado à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Gestão Comercial, realizado sob a orientação científica da Doutora Magda Sofia Valério Monteiro, Professora Adjunta da Escola Superior de Tecnologia e Gestão de Águeda da Universidade de Aveiro e coorientação da Doutora Maria José Rodrigues Felício de Moura e Castro, Professora Adjunta da Escola Superior de Tecnologia e Gestão de Águeda da Universidade de Aveiro.

o júri

presidente

Prof. Doutor Daniel Margaça Magueta
Professor Adjunto da Universidade de Aveiro

Prof. Doutor Rui Jorge Ferreira Soares Borges Lopes
Professor Auxiliar da Universidade de Aveiro

Prof. Doutora Magda Sofia Valério Monteiro
Professora Adjunta da Universidade de Aveiro

palavras-chave

Inventário, planeamento de inventário, métodos de previsão, previsão de vendas, procura intermitente

resumo

O planeamento do inventário pode acarretar um impacto crítico para o retalhista, pois exerce influência não só ao nível financeiro, como também ao nível da satisfação do consumidor.

Tal evidencia a necessidade de melhorar os níveis de inventário detidos pelo retalhista, o que pode ser alcançado através da previsão das vendas dos artigos que comercializa ou necessita para prestar o serviço.

O presente projeto visou desenvolver modelos de previsão de vendas para os artigos pneus e combustíveis, comercializados por um retalhista português, com o intuito de melhorar o sistema de planeamento e a política de inventário em vigor.

São aplicados diferentes métodos de previsão quantitativos, nomeadamente métodos de alisamento exponencial, de regressão linear, ARMA e atendendo à procura intermitente, o método de Croston e a Aproximação de Syntetos-Boylan. Posteriormente, retiram-se ilações quanto às políticas de inventário que melhor se adequam a cada artigo, determinando-se a política (R,s,S) como a mais adequada para o artigo pneus, e a política (s,S) para o artigo combustíveis.

keywords

Inventory, inventory planning, forecasting methods, sales forecasting, intermittent demand

abstract

Inventory planning can have a critical impact on a retailer's business as it influences not only the financial side, but also the level of consumer satisfaction. This highlights the need to improve the levels of inventory held by the retailer, which can be achieved by forecasting the sales of items that are sold or needed to provide the service.

The present project aims to develop sales forecast models for tires and fuels sold by a Portuguese retailer, with the aim of improving the current inventory planning system and policy.

Different quantitative forecasting methods are applied, namely exponential smoothing, linear regression and ARMA methods and given the intermittent demand, the Croston method and the Syntetos-Boylan approximation.

Subsequently, conclusions are drawn regarding the inventory policies that best suit each item, specifically the (R,s,S) policy as the most appropriate for the item tire, and the (s,S) policy for the item fuel.

Índice

Índice de Figuras	iii
Índice de Tabelas.....	iv
Lista de Abreviaturas e Siglas	vii
Introdução	1
1. Questão de Investigação e Objetivos	3
2. Revisão de Literatura	3
2.1. Serviços.....	4
2.2. Gestão de Inventário	5
2.3. Previsão da Procura.....	7
2.3.1. Métodos de Previsão.....	8
2.3.1.1. Métodos de Previsão por Julgamento	8
2.3.1.2. Métodos de Previsão Quantitativos.....	9
2.3.2. Procura Intermitente	14
2.3.3. Considerações sobre a Previsão da Procura.....	17
2.4. Política de Inventário.....	20
3. Mercado de Pneus e de Combustíveis	23
3.1. Pneus	23
3.2. Combustíveis.....	24
4. A Empresa DiguiPneus	26
4.1. Descrição da Empresa	26
4.2. Evolução do Volume de Negócios	27
4.3. Análise Nacional do Retalho de Pneus e Combustíveis.....	30
4.4. Planeamento de Compras e de Inventário.....	31
5. Estudo de Caso.....	33
5.1. Pneus	33
5.1.1. Seleção das Medidas a Analisar	33
5.1.2. Metodologia	34
5.1.3. Resultados.....	38
5.1.3.1. Vendas Agrupadas por Mês	38
5.1.3.1.1. O Caso da Medida 205/55R16.....	38
5.1.3.1.1. Análise Global das Restantes Medidas de Pneus	41
5.1.3.2. Vendas Agrupadas por Trimestre.....	44
5.1.3.3. Vendas Agrupadas por Semestre	46
5.1.4. Discussão de Resultados	48
5.2. Combustíveis.....	48
5.2.1. Apresentação dos Dados	49
5.2.2. Metodologia	53
5.2.3. Resultados.....	57

5.2.3.1. O Caso do Gasóleo Simples	57
5.2.3.1. Análise Global dos Combustíveis.....	60
5.2.4. Discussão de Resultados	63
Conclusão	65
Referências Bibliográficas	68
Anexo I – Pneus: Análise dos pressupostos dos modelos.....	75
Anexo II – Pneus: Resultados obtidos para o modelo de previsão.....	77
Anexo III – Pneus: Resultados obtidos para as previsões futuras	85
Anexo IV – Combustíveis: Cronogramas, Funções de Autocorrelação e Testes não paramétricos	91
Anexo V – Combustíveis: Modelos determinados.....	93
Anexo VI – Combustíveis - Eliminação de variáveis não estatisticamente significativas: MLG	98
Anexo VII – Combustíveis - Eliminação de variáveis não estatisticamente significativas: modelos SARMA e ARMA	100

Índice de Figuras

Figura 1 - Política de Inventário (R,S), onde R corresponde ao período de revisão, S ao nível de inventário determinado e L ao lead time da entrega da encomenda.....	21
Figura 2 - Política de Inventário (s,S), onde s corresponde à quantidade mínima de inventário e S ao nível de inventário determinado.....	21
Figura 3 - Política de Inventário (R,s,S), onde R corresponde ao período de revisão, s à quantidade mínima de inventário e S ao nível de inventário determinado.....	22
Figura 4 - Volume de negócios total anual da empresa DiguiPneus Lda.....	27
Figura 5 - Volume de negócios total mensal da empresa DiguiPneus Lda.....	28
Figura 6 - Vendas de produtos totais mensais da empresa DiguiPneus Lda.....	28
Figura 7 - Serviços prestados totais mensais da empresa DiguiPneus Lda.....	28
Figura 8 - Lucro Bruto anual da empresa DiguiPneus Lda.....	30
Figura 9 - Cronograma de vendas da medida de pneus ligeiros 205/55R16, entre maio de 2011 e fevereiro de 2020.....	34
Figura 10 - Modelo de AES para a medida 205/55R16.....	39
Figura 11 - Modelo de Holt para a medida 205/55R16.....	39
Figura 12 - Modelo de RLM para a medida 205/55R16.....	39
Figura 13 - Modelo de Croston para a medida 205/55R16.....	39
Figura 14 - Modelo de ASB para a medida 205/55R16.....	39
Figura 15 - Modelo ponderado para a medida 205/55R16.....	39
Figura 16 - Vendas diárias de gasóleo simples.....	50
Figura 17 - Vendas semanais de gasóleo simples.....	50
Figura 18 - Vendas mensais de gasóleo simples.....	51
Figura 19 – Vendas médias, agrupadas por dia do mês, para os combustíveis gasóleo simples, gasóleo agrícola e gasóleo para aquecimento.....	51
Figura 20 - Vendas médias, agrupadas por dia do mês, para os combustíveis gasóleo aditivado, gasolina 95 e gasolina 98.....	51
Figura 21 – Vendas médias, agrupadas por dia da semana, para os combustíveis gasóleo simples, gasóleo agrícola e gasóleo para aquecimento.....	52
Figura 22 – Vendas médias, agrupadas por dia da semana, para os combustíveis gasóleo aditivado, gasolina 95 e gasolina 98.....	52
Figura 23 – Função de autocorrelação das vendas diárias de gasóleo simples.....	91
Figura 24 – Função de autocorrelação das vendas diárias de gasóleo aditivado.....	91
Figura 25 – Cronograma das vendas diárias de gasóleo aditivado.....	91
Figura 26 - Função de autocorrelação das vendas diárias de gasolina 95.....	91
Figura 27 - Função de autocorrelação das vendas diárias de gasolina 98.....	91
Figura 28 - Cronograma das vendas diárias de gasolina 95.....	92
Figura 29 - Cronograma das vendas diárias de gasolina 98.....	92
Figura 30 - Função de autocorrelação das vendas diárias de gasóleo agrícola.....	92
Figura 31 - Função de autocorrelação das vendas diárias de gasóleo para aquecimento.....	92
Figura 32 - Cronograma das vendas diárias de gasóleo agrícola.....	92
Figura 33 - Cronograma das vendas diárias de gasóleo para aquecimento.....	93

Índice de Tabelas

Tabela 1 - Distribuição das categorias Combustíveis, Pneus e Outros sobre o volume de vendas e sobre o lucro bruto.....	29
Tabela 2 - Evolução do Volume de Negócios dos diferentes CAEs e da DiguiPneus.....	31
Tabela 3 - Número de observações existentes em cada medida de pneus.....	33
Tabela 4 - Agrupamento das observações das medidas de pneus.....	34
Tabela 5 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para a medida 205/55R16.....	38
Tabela 6 - Valores de REQM obtidos para o horizonte de previsão de março de 2020 a fevereiro de 2021, para a medida de pneus 205/55R16.....	40
Tabela 7 – Determinação da quantidade a encomendar (S), em cada mês, para a medida 205/55R16.....	41
Tabela 8 – Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus agrupadas por mês.....	41
Tabela 9 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus agrupadas por mês.....	42
Tabela 10 – Cruzamento dos modelos com menor REQM, considerando as medidas de pneus agrupadas por mês.....	42
Tabela 11 – Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo.....	43
Tabela 12 – Parâmetros da política de inventário (R,2,S) para as medidas de pneus 175/65R14, 195/65R15 e 385/65R22,5.....	43
Tabela 13 - Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus agrupadas por trimestre.....	44
Tabela 14 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus agrupadas por trimestre.....	44
Tabela 15 - Cruzamento dos modelos com menor REQM, considerando as medidas de pneus agrupadas por trimestre.....	45
Tabela 16 - Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo.....	45
Tabela 17 - Parâmetros da política de inventário (R,2,S) para as medidas de pneus 205/65R15, 225/50R17 e 700R16.....	46
Tabela 18 - Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus agrupadas por semestre.....	46
Tabela 19 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus agrupadas por semestre.....	47
Tabela 20 - Cruzamento dos modelos com menor REQM, considerando as medidas de pneus agrupadas por semestre.....	47
Tabela 21 - Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo.....	47
Tabela 22 - Parâmetros da política de inventário (R,2,S) para as medidas de pneus 185/70R14, 215/55R17, 285/70R19,5.....	48
Tabela 23 – Valores de vendas e de compras, em número e em litros, para os combustíveis.....	49

Tabela 24 - Venda média de combustíveis, em número.....	53
Tabela 25 - Venda média de combustíveis, em litros.....	53
Tabela 26 - Compra média de combustíveis, em número.....	53
Tabela 27 - Compra média de combustíveis, em litros.....	53
Tabela 28 - Lista de variáveis explicativas testadas numa primeira fase.....	54
Tabela 29 - Lista de variáveis explicativas testadas numa segunda fase.....	55
Tabela 30 - Lista de variáveis explicativas agregadas anualmente testadas numa segunda fase.....	56
Tabela 31 - Resumo dos métodos aplicados aos dados diários de gasóleo simples.....	58
Tabela 32 - Resumo dos modelos semanal e mensal dos dados de gasóleo simples.....	59
Tabela 33 - Quantidade prevista de litros vendidos para o combustível gasóleo simples, para um horizonte temporal de três meses.....	60
Tabela 34 - REQM dos diferentes métodos de previsão aplicados a todos os combustíveis.....	61
Tabela 35 - Previsões semanais para um horizonte de três meses para todos os combustíveis.....	62
Tabela 36 - Análise dos pressupostos dos modelos de RLM para as medidas de pneus agrupadas por mês.....	75
Tabela 37 - Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus agrupadas por mês.....	75
Tabela 38 - Análise dos pressupostos dos modelos de RLM para as medidas de pneus agrupadas por trimestre.....	76
Tabela 39 - Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus agrupadas por trimestre.....	76
Tabela 40 - Análise dos pressupostos dos modelos de RLM para as medidas de pneus agrupadas por semestre.....	77
Tabela 41 - Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus agrupadas por semestre.....	77
Tabela 42 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus agrupadas por mês.....	77
Tabela 43 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus agrupadas por trimestre.....	80
Tabela 44 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus agrupadas por semestre.....	82
Tabela 45 - Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por mês, sem revisão dos dados e com revisão a cada 1, 2, 4 e 6 meses.....	85
Tabela 46 - Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por trimestre, sem revisão dos dados e com revisão a cada 1 e 2 trimestres.....	88
Tabela 47 - Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por semestre, sem revisão dos dados e com revisão a cada 6 meses.....	89
Tabela 48 - Resultado dos testes não paramétricos aos dados diários e semanais dos diferentes combustíveis.....	93
Tabela 49 - Modelos obtidos para os dados diários do combustível gasóleo simples.....	94
Tabela 50 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo simples.....	94

Tabela 51 - Modelos obtidos para os dados diários do combustível gasóleo agrícola.....	94
Tabela 52 – Modelos obtidos para os dados semanais e mensais do combustível gasóleo agrícola.	95
Tabela 53 - Modelos obtidos para os dados diários do combustível gasóleo para aquecimento.....	95
Tabela 54 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo para aquecimento.....	95
Tabela 55 - Modelos obtidos para os dados diários do combustível gasóleo aditivado.....	96
Tabela 56 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo aditivado.....	96
Tabela 57 - Modelos obtidos para os dados diários do combustível gasolina 95.....	96
Tabela 58 - Modelos obtidos para os dados semanais do combustível gasolina 95.....	97
Tabela 59 - Modelos obtidos para os dados mensais e trimestrais do combustível gasolina 95.....	97
Tabela 60 - Modelos obtidos para os dados diários do combustível gasolina 98.....	97
Tabela 61 - Modelos obtidos para os dados semanais e mensais do combustível gasolina 98.....	98
Tabela 62 – Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo simples.....	98
Tabela 63 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo aditivado.....	98
Tabela 64 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasolina 95.....	99
Tabela 65 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados semanais de gasolina 95.....	99
Tabela 66 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasolina 98.....	99
Tabela 67 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados semanais de gasolina 98.....	99
Tabela 68 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo agrícola.....	100
Tabela 69 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo para aquecimento.....	100
Tabela 70 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gasóleo simples e de gasóleo aditivado.....	100
Tabela 71 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gasolina 95 e 98.....	101
Tabela 72 - Processo de eliminação das variáveis não estatisticamente significativas no modelo ARMA dos dados semanais de gasolina 95 e 98.....	101
Tabela 73 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gasóleo agrícola e de gasóleo para aquecimento.....	101

Lista de Abreviaturas e Siglas

ADIDA – abordagem de agregação-desagregação da procura intermitente

AES – alisamento exponencial simples

AR – autorregressivo

ARIMA – autorregressivo integrado de médias móveis

ARMA – autorregressivo de médias móveis

ASB – aproximação de Syntetos-Boylan

CAE – classificação portuguesa de atividades económicas

COVID-19 – Doença por coronavírus 2019

DAM - desvio absoluto médio

EM – erro médio

EN113 – estrada nacional número 113

EPA – erro de previsão acumulado

EPAM – erro percentual absoluto médio

EQM – erro quadrático médio

HW – método de Holt-Winters

LASSO – operador de menor redução absoluta e de seleção

MA – média móvel

MLG – modelos lineares generalizados

PAM – percentagem de arrependimento média

PEI – períodos em inventário

PIB – produto interno bruto

PM – percentagem melhor

REQM – raiz quadrada do erro quadrático médio

RGREQM – raiz quadrada geométrica relativa do erro quadrático médio

RL – regressão linear

RLM – regressão linear múltipla

RLS – regressão linear simples

RNA – rede neuronal artificial

SARIMA – autorregressivo integrado de médias móveis sazonal

SARMA – autorregressivo de médias móveis sazonal

SEPAM – erro percentual absoluto médio simétrico

UE – União Europeia

Introdução

O planeamento do inventário pode acarretar um impacto crítico para o retalhista, pois exerce influência não só ao nível financeiro, como também ao nível da satisfação do consumidor. Neste sentido, deve procurar-se implementar uma política de inventário adequada, que permita ao retalhista minimizar os custos inerentes ao inventário, sem prejudicar o serviço oferecido ao consumidor.

Para tal, é necessário melhorar os níveis de inventário detidos pelo retalhista, o que pode ser alcançado através da previsão das vendas dos artigos que comercializa ou necessita para prestar o serviço.

Existem diversos métodos de previsão na literatura, uns qualitativos, outros quantitativos, que permitem reduzir a incerteza associada à procura. Contudo, diferentes fatores pertencentes ao ambiente externo do retalhista, desde a presença de concorrentes, a alterações económicas, a variações no comportamento do consumidor, afetam as suas vendas e podem dificultar a determinação de um modelo de previsão adequado.

O presente projeto visa desenvolver modelos de previsão de vendas para os artigos pneus e combustíveis comercializados pela empresa Diguipneus, com o intuito de melhorar o sistema de planeamento e a política de inventário em vigor, por forma a otimizar o compromisso entre os custos inerentes ao inventário e a satisfação dos seus consumidores.

Em Portugal, tanto o retalho de pneus, como o de combustíveis, é bastante fragmentado e ocorre principalmente em pequenas empresas, o que significa que existe um elevado nível de concorrência e que os consumidores podem adiar as suas compras até encontrarem um local que lhes pareça adequado, sem que tal represente um custo de oportunidade.

Neste sentido, para que as empresas subsistam e prosperem, os retalhistas necessitam de ser competitivos, atender aos custos e garantir que respondem às necessidades dos consumidores.

O trabalho inicia com uma breve revisão da literatura que descreve temas e processos essenciais para compreender a metodologia aplicada no projeto, desde métodos de previsão da procura a políticas de gestão de inventário. Segue-se uma apresentação do mercado de pneus e do de combustíveis, desde o nível global ao nacional.

Posteriormente é apresentado o estudo de caso, a empresa Diguipneus, e efetuada uma análise do seu volume de negócios, comparando-o com o mercado nacional, e descritos os processos em vigor relativos ao planeamento de compras e de inventário.

De seguida é exposto o trabalho prático realizado, nomeadamente a apresentação e seleção dos dados utilizados, tanto referente ao artigo pneus, como aos combustíveis, a metodologia seguida, os resultados obtidos e as principais ilações retiradas.

Por fim, exibem-se as conclusões gerais do projeto, identificam-se as políticas de inventário recomendadas e sugerem-se aspetos que podem ser alvo de investigação futura, complementando o presente trabalho.

1. Questão de Investigação e Objetivos

De entre as várias formas de pesquisa, optou-se pelo estudo de caso. Um estudo de caso visa compreender uma realidade específica, procurando alcançar um conhecimento detalhado da mesma. Esta é a estratégia de investigação preferencial quando a questão central de pesquisa é “como” e /ou “porquê”, quando o investigador não tem controlo sobre os eventos ou quando o foco consiste num contexto contemporâneo específico da vida real ou na compreensão de um evento ao longo do tempo (Yin, 2003).

O caso em estudo foi uma empresa sediada no concelho de Leiria, a DigiPneus Lda, em concreto os seus níveis de inventário de pneus e de combustíveis.

De acordo com o contextualizado teoricamente, e utilizando métodos estatísticos, que apresentam um grau de precisão razoável ao tornar possível determinar, em termos numéricos, a probabilidade de certa conclusão ser verdadeira e qual a sua margem de erro (Gil, 2008), o foco do estudo vai no sentido da aplicação de métodos previsionais às vendas de pneus e de combustíveis desta empresa.

Atendendo a que o planeamento de inventário na empresa em estudo se realiza através de julgamento humano e sem recurso a qualquer modelo previsional, colocou-se a seguinte questão que norteou o presente trabalho:

Como poderá ser melhorado o sistema de planeamento de inventário em vigor na empresa, quer de pneus quer de combustíveis, de forma a minimizar os custos de inventário associados?

Em termos concretos, pretendem-se alcançar os seguintes objetivos:

- Desenvolver modelos que permitam prever o volume de vendas de cada medida de pneus;
- Desenvolver modelos que permitam prever o volume de vendas de cada tipo de combustíveis;
- Melhorar os níveis de inventário de pneus na empresa;
- Melhorar os níveis de inventário de combustíveis na empresa.

2. Revisão de Literatura

Neste capítulo é apresentada uma breve revisão de literatura que abrange tópicos, processos e expressões próprias da metodologia aplicada no projeto. São definidos serviços, metodologias de gestão de inventário, métodos de previsão da procura e políticas de inventário.

2.1. Serviços

Os principais setores económicos em Portugal incluem o setor agrícola, o setor industrial e o setor de serviços, correspondendo a cerca de 2,1%, 19,2% e 65,3% do PIB, respetivamente. Ao nível do emprego, 5,7% da população ativa encontra-se no setor agrícola, 24,6% no setor industrial e 69,8% no setor de serviços (Export Entreprises SA, 2021; PORDATA, 2020).

Os serviços têm alcançado um papel cada vez mais relevante na economia portuguesa, de entre os quais o comércio a grosso e a retalho representam 18,6% do emprego, pelo que o seu desenho e operação eficientes são cruciais para o bem-estar da economia (Export Entreprises, 2021; PORDATA, 2020; Russell e Taylor, 2014).

O *output* de um serviço é variável, devido à grande variedade de fornecedores e de consumidores que serve. Assim, é crucial garantir que a entrega do serviço ocorre no tempo, local e da forma desejada.

Atualmente, estratégias competitivas para servir os consumidores com maior qualidade e menor desperdício e custo tornaram-se num fator chave para garantir o sucesso dos retalhistas. Neste sentido, é crítica a utilização de processos eficientes de gestão da cadeia de abastecimento, para que se atinjam vantagens competitivas no setor dos serviços.

Uma cadeia de abastecimento envolve todas as atividades relacionadas com o fluxo e transformação de materiais e serviços desde a etapa de aquisição de matérias-primas até à entrega ao consumidor final, tal como os fluxos de informação que lhe estão associados e são essenciais para unificar todo o processo. Assim, consiste num grupo integrado de processos de negócio e de atividades com o objetivo comum de garantir a satisfação do consumidor (Russell e Taylor, 2014).

O desenvolvimento de cadeias de abastecimento de serviços requer um nível de recursos superior ao necessário em cadeias de abastecimento da indústria, pois o serviço é menos tangível, dependente do contexto, difícil de imitar e perecível, pelo que não se pode armazenar para utilização futura.

Ao serem baseadas na dualidade consumidor-fornecedor, as cadeias de serviços são heterogéneas, o que se reflete na difícil padronização dos serviços e na trabalhosa previsão do padrão da procura para um período ou artigo específico. Em consequência, não são tão facilmente definidas como as cadeias de abastecimento da indústria, nem tão extensas, focando-se principalmente nos recursos humanos e nos serviços de suporte necessários para fornecer o serviço.

2.2. Gestão de Inventário

O inventário de uma empresa engloba as reservas de produtos e de materiais que esta detém armazenados até que sejam procurados por consumidores, internos ou externos. O inventário cíclico constitui o inventário normal, utilizado durante as operações de uma organização, enquanto o inventário de segurança engloba a reserva de artigos detida para responder a emergências (como atrasos nas entregas ou procura superior à esperada), sendo o seu tamanho dependente do grau de incerteza associado à procura.

A gestão de inventário é a função responsável por todas as decisões acerca do inventário numa organização, abrangendo políticas gerais, atividades e procedimentos para garantir que a quantidade certa de cada artigo existe em inventário, a todo o momento, e de forma custo-eficiente (Waters, 2003). Para tal, recorre ao controlo de inventário, determinando que artigos armazenar e em que quantidade, o investimento necessário, o nível de serviço ao consumidor pretendido, o tamanho e *timing* das encomendas, entre outros aspetos (Russell e Taylor, 2014; Waters, 2003).

Uma gestão cuidadosa do inventário aumenta a disponibilidade de produtos e diminui os custos operacionais ao reduzir o *lead time* (intervalo de tempo entre a criação da ordem de encomenda e a sua entrega) e permitir o tamanho e frequência de entregas corretos. Igualmente, operações mais eficientes resultam em maiores margens de lucro ou permitem reduzir os preços praticados para potenciar as vendas, libertam recursos financeiros para propósitos mais produtivos e diminuem a necessidade de empréstimos.

Os custos operacionais associados à gestão de inventário dividem-se em custos de inventário, custos de armazenamento, custos de encomenda e custos de rotura (Waters, 2003).

Os custos de inventário (despesas com seguros, administrativas, deterioração, perda, etc.) correspondem, por norma, a 20% a 25% do valor anual do inventário, e, exceto se rigorosamente controlados, existe uma tendência para aumentar os níveis de inventário detidos, em especial se existirem poucas restrições de capital ou de espaço para armazenamento (Harris, 1913; Syntetos *et al.*, 2010; Waters, 2003).

Os custos de armazenamento englobam as despesas de manutenção do inventário até que os artigos sejam requisitados, garantindo que têm o tratamento e embalamento corretos para se manterem nas condições adequadas (armazéns, equipamento para manuseamento de materiais, sistemas de informação, etc.). Assim, variam de acordo com nível de inventário detido, e ocasionalmente com o período de armazenamento, geralmente numa tendência linear positiva entre o custo e as unidades detidas. Por norma, estes custos representam 10% a 40% do valor do artigo detido (Russell e Taylor, 2014; Waters, 2003).

Os custos de encomenda abrangem a criação de ordens de encomenda para artigos e podem incluir despesas administrativas, de transporte, de supervisão, de utilização de equipamento, entre outras. Estes custos tendem a ser independentes da quantidade a encomendar, pois o fornecedor pode oferecer descontos de quantidade, e podem variar de acordo com os processos necessários (p.e., controlo de qualidade, inspeções, distância a percorrer). Contudo, apresentam uma relação linear positiva com o número de encomendas realizadas, pelo que possuem uma relação inversa com os custos de armazenamento (Russell e Taylor, 2014; Waters, 2003).

Quando a procura pelos consumidores não encontra resposta no retalhista, ocorre uma rotura de inventário, com um custo de rotura associado. Estas roturas podem ser planeadas e benéficas, nomeadamente nas situações em que o custo de deter o artigo em inventário é superior ao lucro da venda, sendo que os consumidores aguardam a chegada do artigo através de uma *backorder* (pedido atrasado). No entanto, existe o risco de os consumidores retirarem a encomenda e se dirigem a outro retalhista, ocorrendo vendas perdidas, e, eventualmente, perda de vendas futuras ou de reputação. Salienta-se que quando se permitem roturas, o objetivo de minimizar o custo não é sinónimo do objetivo de maximização da receita (Russell e Taylor, 2014; Waters, 2003).

Uma vez que os custos de rotura são difíceis de calcular, podem ser determinados através do julgamento dos retalhistas ao especificarem a probabilidade máxima de insatisfação da procura, isto é, o nível de serviço ao consumidor mínimo aceitável. Por norma, especifica-se um nível de serviço de 95%, ou seja, 5% da procura não será satisfeita, sendo que estas probabilidades podem variar consoante a importância dos artigos para as vendas da empresa. Estes custos apresentam uma relação inversa com os custos de armazenamento (Vizinger e Žerovnik, 2019; Waters, 2003).

Assim, o objetivo da gestão de inventário consiste em implementar um sistema de controlo de inventário que indique a quantidade a encomendar e o momento de realizar encomendas para que a soma dos custos de armazenamento, de encomenda e de rotura seja minimizada.

Contudo, não pode existir foco apenas na eficiência das operações, pois deve ser mantido um nível de serviço que satisfaça os consumidores e seja competitivo. Tal significa definir o nível de serviço a atingir com o mínimo custo, aumentando o valor percebido, o que se traduz em maior satisfação do consumidor e pode originar vendas maiores, mais frequentes e repetidas, e novos consumidores.

Desta forma, a extrapolação do comportamento futuro da procura (previsão), utilizando dados históricos do passado e admitindo que as condições atuais, mesmo as

desconhecidas, se manterão inalteradas, possibilita ajustes adequados na gestão do inventário do retalhista e na sua cadeia de abastecimento (Caiado, 2011).

2.3. Previsão da Procura

A previsão da procura é um dos aspetos chave da gestão de operações, em particular da previsão de vendas, pois desempenha um papel determinante na alocação de recursos (financeiros, de *marketing* e humanos) do retalhista e impacta a satisfação do consumidor.

Os retalhistas têm expandido consistentemente os sortidos oferecidos para responderem à facilidade com que os consumidores recorrem a concorrentes e também às suas expectativas crescentes quanto a maior variedade de produtos. Segundo Hoch *et al.* (1999), os consumidores valorizam a variedade do sortido oferecido por existir maior probabilidade de encontrarem o que desejam, em especial quando as preferências não estão bem definidas, ou são dinâmicas. Contudo, este aumento de inventário não se traduz necessariamente em melhor nível do serviço ao consumidor (Mahajan e van Ryzin, 1999).

Neste sentido, torna-se crucial fazer corresponder a procura e a oferta com a maior precisão possível, o que requer a avaliação dos processos de inventário e de controlo dos retalhistas para diminuir, em simultâneo, eventuais custos de rotura e/ou de investimento em inventário excessivo e melhorar o nível de serviço oferecido.

Ton e Raman (2010) mostraram que, à medida que a variedade de produtos de uma empresa aumenta, também aumentam os erros na previsão da procura e nos sistemas de informação, o que resulta em maiores custos operacionais, nomeadamente custos de armazenamento de inventário. Em concordância, Ghobbar e Friend (2003) observaram que as empresas detêm mais inventário que o necessário devido a expectativas imprecisas da procura e frequentemente não atingem os níveis de serviço desejados.

Também Prak e Teunter (2019) concluem que os níveis de inventário de segurança aumentam com o grau de incerteza no modelo de previsão, sendo que a incerteza aumenta se mais parâmetros tiverem de ser determinados, se as estimativas se basearem num pequeno número de observações, se o *lead time* for elevado ou se a variância da procura for grande em relação à média.

Assim, embora sejam necessárias previsões precisas, existirá sempre um grau de incerteza, pelo que todos os processos da cadeia de abastecimento devem apresentar alguma flexibilidade. De facto, a previsão da procura requer não só o conhecimento do passado, mas também da situação atual, sujeita ao ambiente externo do retalhista que, por variar com frequência, inclui fatores difíceis de descrever numa simples fórmula

quantitativa, como a relevância dos dados históricos no futuro, a variabilidade da procura, o custo associado aos erros ou os benefícios esperados da previsão.

Beutel e Minner (2012) consideram que a previsão da procura apenas baseada na procura histórica não fornece resultados satisfatórios para o planeamento de inventário devido à elevada dependência da procura de outros fatores (como alterações de preço e o tempo), tendo concluído que a regressão linear apresenta o melhor desempenho, desde que os pressupostos assumidos sejam válidos.

Contudo, a procura pode ser prevista de formas distintas, pelo que se apresenta na subsecção seguinte um resumo dos principais métodos de previsão.

2.3.1. Métodos de Previsão

Os métodos desenvolvidos para efetuar previsões podem ser divididos em dois grandes grupos: qualitativos (por julgamento) e quantitativos.

2.3.1.1. Métodos de Previsão por Julgamento

Os métodos de previsão por julgamento mais comuns incluem a opinião do gestor (de apenas uma pessoa, com ou sem dados históricos), o painel de opinião executiva (pequeno grupo de gestores de topo), a opinião da força de vendas, o inquérito de mercado aos consumidores (atuais e potenciais), a analogia histórica (usa a procura por um artigo similar introduzido no passado para julgar a procura por um novo produto) e o método de Delphi (painel de especialistas de diferentes origens que respondem independentemente a questionários sucessivos) (Hillier e Lieberman, 2001; Waters, 2003).

Estes métodos são especialmente valiosos quando existem poucos ou nenhuns dados históricos ou quando grandes mudanças no mercado tornam os dados existentes inadequados para propósitos de previsão.

Vários estudos sugerem que nas décadas de 70 e 80 do século XX a previsão por julgamento era amplamente utilizada no retalho e na indústria (Dalrymple, 1975; Mentzer e Cox, 1984). Porém, Einhorn e Hogarth (1981) concluíram que este comportamento de decisão é sensível até a ligeiras mudanças na tarefa e no contexto.

Estratégias para melhorar a previsão por julgamento envolvem combiná-la com outras previsões, por julgamento ou quantitativas. Ferrel (1985) defende que o julgamento obtido por um grupo de especialistas será de qualidade superior ao obtido por apenas um. Já Blattberg e Hoch (2010) argumentam que existem forças complementares nas previsões por julgamento e nas quantitativas, como a consistência e rigidez dos modelos estatísticos e a inconsistência e maior adaptabilidade a fatores em mudança do julgamento humano.

2.3.1.2. Métodos de Previsão Quantitativos

Os métodos de previsão estatísticos tradicionais recorrem a dados históricos de séries temporais para prever a procura futura, assumindo que as tendências históricas irão continuar. Uma série temporal consiste num conjunto de observações, obtidas ao longo do tempo, de alguma variável de interesse, ao qual será ajustado um modelo matemático que as represente, sendo este utilizado para gerar previsões.

A escolha do modelo, frequentemente, decorre da análise gráfica da série temporal (cronograma) para detetar os padrões subjacentes à série, sendo os mais comuns o padrão constante, com a procura a ter um nível aproximadamente igual ao longo do tempo; a tendência, com a procura a crescer ou diminuir continuamente; e a sazonalidade, onde a procura apresenta uma variação periódica regular em torno da tendência, sendo que cada ciclo contém várias fases que permitem medir a variação da procura através de índices sazonais (Hillier e Lieberman, 2001; Russell e Taylor, 2014; Waters, 2003).

Contudo, existem sempre diferenças entre a procura real e o padrão subjacente, que formam o ruído aleatório. Este ruído é resultado de fatores como procura variável, erros nos dados disponíveis, oscilações económicas ou comunicação imperfeita (Waters, 2003).

Os métodos de previsão causais procuram aplicar uma relação entre a procura e outras variáveis para prever a primeira. Como exemplo pode-se referir a regressão linear (RL), que assume que a variável dependente está linearmente relacionada com uma ou mais variáveis independentes (regressão linear simples – RLS - e múltipla – RLM -, respetivamente), procurando a melhor equação que se ajusta aos dados. Na prática, a melhor equação é a que minimiza o erro quadrático médio (EQM), com o coeficiente de determinação (R^2) a informar acerca da adequação aos dados, isto é, indica quanta da variabilidade da variável dependente é explicada pelas variáveis independentes (Russell e Taylor, 2014; Waters, 2003).

A RLM apresenta algumas limitações na previsão com um grande conjunto de indicadores, nomeadamente a causalidade, pois tenta criar o melhor ajuste utilizando todas as variáveis independentes, sem avaliar a influência real entre estas variáveis e a dependente; a multicolinearidade, que decorre da introdução de variáveis colineares no método com a consequente estimativa incorreta dos coeficientes; e o sobreajuste, pois o método vai selecionar tantas variáveis quanto possível para minimizar o erro na amostra, o que pode facilmente originar problemas de sobreajustamento (Verstraete *et al.*, 2020).

Para mitigar estas questões, pode ser aplicado o procedimento *stepwise*, que consiste num processo de seleção automática de variáveis independentes aplicado à RLM, que adiciona ou remove repetidamente a variável que melhora a métrica de seleção. Este

processo é útil quando existe um grande número de variáveis no modelo e se pretende avaliar a significância das mais importantes, contudo, é criticado por não garantir a melhor seleção de variáveis (Verstraete *et al.*, 2020).

Os modelos lineares generalizados (MLG) correspondem a uma generalização do modelo de RL e pressupõem que a variável resposta segue uma distribuição pertencente à família exponencial, que engloba, entre outras, as distribuições normal, binomial, gama, Poisson e gaussiana inversa. Utilizam ainda uma função de ligação (*link*) que permite estabelecer uma relação linear entre as variáveis independentes e uma transformação da média da variável dependente.

A principal vantagem dos MLG sobre o modelo linear geral decorre da sua capacidade de especificação de uma distribuição diferente da normal e de uma função *link* diferente da identidade $f(\mu) = \mu$. De facto, a distribuição normal com função de ligação identidade (modelo linear clássico) pressupõe que a variância das respostas é constante e que os valores observados apresentam uma distribuição simétrica sobre um valor central (média), o que nem sempre se verifica (IBM, 2021; lærd statistics, 2018; Turkman e Silva, 2000).

Nos MLG, tal como nos modelos de RLM, a análise de resíduos é útil para avaliar a qualidade de ajustamento do modelo no que diz respeito à escolha da distribuição e da função de ligação, tal como para auxiliar na identificação de observações influentes (*outliers* - observações drasticamente diferentes das restantes). Esta avaliação pode decorrer da análise gráfica (p.e., resíduos vs valores preditos), sendo que, caso não existam anomalias, os resíduos se devem encontrar distribuídos em torno de zero, com uma amplitude constante para diferentes valores de μ (IBM, 2021; lærd statistics, 2018; Turkman e Silva, 2000).

Os métodos de previsão projetivos utilizam valores históricos da procura para prever a procura futura. Entre estes encontram-se os métodos de decomposição, o alisamento exponencial e os modelos ARIMA (autorregressivos integrados de médias móveis).

No que se refere aos métodos de decomposição, o método estatístico mais simples é o método de previsão do último valor (ou método ingénuo) que utiliza apenas o valor da última observação como previsão futura, pelo que é impreciso e apresenta elevada variância, mas é recomendado quando as condições do mercado estão em rápida mudança (Hillier e Lieberman, 2001).

O método de média simples utiliza todas as observações da amostra para efetuar previsões simples, adequando-se se o processo for completamente estável. Já o método de média móvel efetua a média dos últimos n períodos para realizar a previsão, contudo aplica exatamente o mesmo peso a todas as observações. O número de observações a

incluir na média móvel determina o grau de alisamento da série, devendo escolher-se uma ordem elevada se se pretende eliminar a aleatoriedade da série ou uma ordem reduzida caso o objetivo seja captar alterações mais recentes (Caiado, 2011).

Já o alisamento exponencial, e em concreto o método de alisamento exponencial simples (AES) desenvolvido por Brown (1959), ao aplicar uma constante de alisamento α e assumir que a procura segue uma distribuição normal, coloca maior peso na observação mais recente e pesos decrescentes nas observações anteriores, sendo indicado para séries temporais com tendência nula e sem sazonalidade (Hillier e Lieberman, 2001; Waters, 2003; Willemain *et al.*, 2004).

Se a constante de alisamento apresentar valor baixo, enfatiza o passado e é favorável à procura estável, mas é morosa a reagir a mudanças sistemáticas. Se o seu valor é elevado, enfatiza as observações mais recentes e adequa-se quando se pretende uma reação rápida à procura em mudança, contudo é sensível a alterações aleatórias. Silver *et al.* (1998) discutem que a constante de alisamento do AES mais adequada se encontra entre 0,1 e 0,3, quando as previsões se realizam mensalmente.

Holt (2004) propôs que o método das médias móveis exponencialmente ponderadas, amplamente utilizado então, poderia ser aplicado à previsão de múltiplos componentes (como a tendência e a sazonalidade), tendo desenvolvido um método adequado a séries temporais com tendência linear e sem sazonalidade. Winters (1960) testou o método de Holt e desenvolveu-se o sistema de previsão denominado método de Holt-Winters, indicado para artigos que apresentam procura com tendência e sazonalidade.

Fildes *et al.* (1998) indicam que o desempenho dos métodos de alisamento depende de como os parâmetros de alisamento são estimados e de como se definem os métodos de inicialização, pelo que ao invés de se utilizarem valores fixos, deve ser retirada informação da própria série temporal. Neste sentido, Gilchrist (1976) sugere a utilização da regressão dos mínimos quadrados nos primeiros dados como forma de obter as condições iniciais do nível e declive do método de Holt, contudo pode também ser aplicado o método das médias, como refere Caiado (2011).

As vantagens dos métodos de alisamento exponencial são a sua simplicidade, baixo custo e facilidade de implementação na realidade, onde é necessário prever as vendas de milhares de artigos. No entanto, a escolha do número de observações a incluir em cada estimativa inicial e dos métodos de inicialização são algo subjetivas e dependem da experiência de quem os aplica (Caiado, 2011).

Atualmente, é aceite que o AES de Brown é tão preciso como o método de Holt-Winters, embora o último tenha sido mais preciso em estudos empíricos e apresente maior eficiência computacional e maior flexibilidade para mais parâmetros (Gardner, 1985, 2006).

Box e Jenkins (1970) introduziram os modelos lineares de séries estacionárias não sazonais, os modelos ARMA (autorregressivos de médias móveis), onde a série Y_t é função dos seus próprios valores passados (autorregressiva) e de resíduos anteriores (média móvel) (Caiado, 2011; Hyndman e Athanasopoulos, 2018).

Já os modelos SARIMA (autorregressivos integrados de médias móveis sazonais) são bastante flexíveis e procuram descrever as autocorrelações nos dados, possibilitando modelar uma grande variedade de dados sazonais. O princípio base assumido pelo método é o de que o processo subjacente à série temporal, condicional ao passado, segue uma distribuição estatística conhecida, como a distribuição normal (Hyndman e Athanasopoulos, 2018).

Estes métodos envolvem um processo iterativo de três etapas para a seleção do modelo, estimação dos parâmetros e verificação do modelo, sendo aplicados a séries temporais estacionárias e sem observações em falta (Caiado, 2011; Hyndman e Athanasopoulos, 2018).

Uma série temporal estacionária possui características como média, variância e estrutura de autocorrelação constantes ao longo do tempo, o que implica que séries não estacionárias, isto é, que apresentam tendência ou heterocedasticidade, necessitem de ser transformadas (p.e., através de diferenciação ou da transformação de Box-Cox) para estabilizar a média e/ou a variância antes de ser possível ajustar um modelo SARIMA (Hyndman e Athanasopoulos, 2018).

Contudo, os métodos de previsão estatística tradicionais apenas extrapolam tendências históricas e influências sazonais para prever a procura futura, pelo que não permitem antecipar mudanças macroeconómicas, as quais impactam significativamente, e com frequência, a procura. Para acomodar estas alterações, os retalhistas podem ajustar por julgamento a previsão inicial ou recorrer a previsões de especialistas para efetuar a previsão final. No entanto, ambas as abordagens podem ser enviesadas, sujeitas a erro humano e morosas (Sagaert *et al.*, 2018b; Verstraete *et al.*, 2020; Waters, 2003).

Pesquisas de Lim e O'Connor (1995) e de Mathews e Diamantopoulos (1992) indicam que estes ajustes podem melhorar a previsão quando os especialistas dispõem de informação importante, que não está disponível no modelo estatístico. Já, estudos de Diamantopoulos e Mathews (1989) e de Fildes *et al.* (2009) concluíram que ajustes inferiores a 10% da previsão estatística podem ser irrelevantes devido ao ruído normal.

Os resultados da análise de Syntetos *et al.* (2009) mostram que as previsões ajustadas são mais precisas que as obtidas por via estatística, mas não melhoram com o tempo, diminuindo até, contrariamente ao esperado, com a maior disponibilidade de informação. Os autores concluem ainda que os ajustes negativos têm melhor desempenho que os positivos, e, no geral, a maior precisão das previsões ajustadas também se traduz em melhor desempenho no controlo de inventário, nomeadamente em melhores níveis de serviço ao consumidor, apenas à custa de alterações modestas nos níveis de inventário.

Alternativas que atentam a indicadores macroeconómicos disponíveis são sugeridas por Sagaert *et al.* (2018a), nomeadamente os modelos de regressão LASSO.

A regressão LASSO (operador de menor redução absoluta e de seleção), criada por Tibshirani (1996), consegue lidar eficientemente com um grande número de variáveis utilizando uma função de otimização de custo, alterada face à regressão dos mínimos quadrados, para estimar os coeficientes do modelo. Esta nova função balanceia dois objetivos concorrentes: o EQM e a soma dos valores absolutos dos coeficientes multiplicada por um termo de regularização. Por um lado, visa obter o melhor ajuste aos dados, minimizando o erro. Por outro lado, ao aumentar o custo para coeficientes com grande valor, reduz esse valor a zero, pelo que apenas as variáveis mais informativas apresentam um coeficiente diferente de zero e são incluídas no modelo. Assim, a LASSO evita o sobreajustamento e a multicolinearidade e permite conhecer a contribuição individual de cada variável para a previsão final.

Sagaert *et al.* (2018b) observam que, na maioria das situações, a LASSO apresenta melhor desempenho que outros métodos de previsão (p.e., Holt-Winters), com a diferença a aumentar para horizontes temporais maiores, o que demonstra os benefícios de utilizar variáveis chave no cálculo das previsões. Contudo, a LASSO é apenas indicada para situações nas quais existe um número elevado de variáveis explicativas.

Os métodos tradicionais de séries temporais podem julgar incorretamente a forma funcional entre as variáveis dependente e independentes, falhar na realização dos ajustes necessários aos dados ou a presença de *outliers* pode originar estimativas enviesadas dos parâmetros do modelo. Para ultrapassar estas limitações, surgem os métodos de previsão que recorrem à inteligência artificial e permitem a análise de estruturas de dados mais complexas ao se basearem em algoritmos sofisticados que são capazes de aprender por tentativa e erro, nomeadamente as redes neuronais artificiais (RNA) (White, 1992).

As RNA consistem em redes, com um grande número de neurónios interconectados (unidades), que simulam o mecanismo do cérebro humano para processar informação. Cada ligação tem um peso numérico e o processo geral de treino da rede segue

sumariamente os seguintes passos: avançar com os sinais de entrada, propagar o erro de volta e ajustar a matriz de pesos (Kourentzes, 2013; Mitrea *et al.*, 2009; Qin e Li, 2011).

A precisão da previsão obtida com a RNA está intimamente ligada à escolha da amostra, pois apenas observações suficientes podem refletir a tendência geral dos dados, fazer uso pleno da capacidade de mapeamento não linear da rede e obter uma previsão sólida, sendo que o desenho da rede deve ser adequado a cada caso (Gutierrez *et al.*, 2008; Mitrea *et al.*, 2009; Qin e Li, 2011).

Os artigos de Arslankaya e Öz (2018) e de Hill *et al.* (1996) mostram que as RNA apresentam melhor ajuste aos dados que o obtido com métodos de previsão tradicionais.

No entanto, enquanto um modelo de RL pode recorrer a apenas três variáveis, uma RNA simples requer mais parâmetros (nove pesos de conexão) para estimar o mesmo resultado, pelo que é difícil compreender a natureza exata da relação entre as variáveis independentes e o resultado previsto com a RNA (Tu, 1996; Young e Weckman, 2010).

Mais, as RNA podem ser mais difíceis de aplicar na prática pois requerem o conhecimento das matrizes de peso já criadas para serem aplicadas por vários utilizadores, necessitam de mais recursos computacionais e de mais tempo para obter o resultado com menor erro (horas, dias ou semanas) e são propícias ao sobreajuste dos dados, necessitando de mecanismos de controlo (p.e., validação cruzada) (Tu, 1996).

2.3.2. Procura Intermitente

Existem várias situações, tanto na indústria como nos serviços, onde os artigos existentes em inventário são requisitados com pouca frequência, o que resulta em procura esporádica ou intermitente, sendo que estes artigos apresentam risco elevado de obsolescência, o que pode impactar significativamente as operações do retalhista e empatar recursos. As séries temporais de procura intermitente diferem das séries convencionais por apresentarem múltiplos períodos com procura igual a zero.

Estes artigos tendem também a apresentar grande variabilidade nos valores da procura, podendo corresponder a até 60% do valor total do inventário de uma empresa, pelo que o controlo de inventário se torna decisivo, tal como obter previsões precisas da procura, embora a sua natureza intermitente dificulte a previsão (Johnston *et al.*, 2003).

Em séries temporais que não apresentam tendência, contêm observações iguais a zero, mudanças de tendência súbitas e *outliers*, Gardner (1990) afirma que um modelo de alisamento exponencial é o método mais razoável para efetuar previsões e sugere utilizar o modelo ingénuo como referência. De facto, o AES tem provado ser um método robusto

de previsão e é provavelmente o mais utilizado, de entre as abordagens estatísticas, para prever a procura intermitente (Syntetos e Boylan, 2005; Willemain *et al.*, 2004).

No entanto, Croston (1972) observou que quando uma série temporal apresenta procura intermitente, o AES obtém previsões enviesadas negativamente imediatamente antes de ocorrer procura e positivamente logo de seguida, o que resulta em níveis de inventário excessivos. Desta forma, surgiu o método padrão para estes artigos, criado por Croston (1972) (e corrigido por Rao (1973)) e que consiste em alisar duas componentes da série temporal em separado, o valor observado da procura diferente de zero e o tempo entre chegadas de procura (intervalo inter-procura), utilizando para ambas o AES com o mesmo parâmetro de alisamento α . Assim, a previsão para o próximo período resulta do rácio entre o tamanho da procura alisado e o tempo alisado entre procuras.

Se não ocorrer procura no período, a previsão anterior não é alterada, e se ocorrer procura em todos os períodos, a previsão é idêntica ao AES. Estas previsões não são enviesadas se a probabilidade de ocorrência de procura seguir um processo de Bernoulli (isto é, constituir uma família enumerável de variáveis aleatórias que adota valores binários dados por 0 e 1), assumindo que os intervalos inter-procura são distribuídos geometricamente e que a procura diferente de zero segue uma distribuição normal (Gardner, 1985, 2006; Kourentzes, 2014; Syntetos e Boylan, 2005).

A eficácia do método de Croston foi comprovada pelas pesquisas de Willemain *et al.* (2004), Syntetos e Boylan (2006) e de Johnston e Boylan (1996), tendo os últimos concluído que este método é superior ao AES quando o tempo médio entre chegadas é superior a 1,25 vezes o intervalo entre atualizações do AES.

No entanto, o método de Croston apresentou apenas ganhos modestos em desempenho quando comparado com técnicas de previsão mais simples, aparentando ter um desempenho mais preciso quando se utilizam pressupostos claros e dados teóricos, segundo Eaves e Kingsman (2004) e Syntetos e Boylan (2001). Quando aplicado em dados reais, existe alguma evidência de que métodos mais simples apresentam resultados mais precisos e permitem um controlo de inventário mais eficaz (Sani e Kingsman, 1997).

Syntetos e Boylan (2001) reviram o método de Croston quanto às imprecisões na previsão, decorrentes do pressuposto de que as estimativas da procura e do intervalo inter-procura são independentes e de se utilizar a mesma constante de alisamento, tendo desenvolvido um método modificado (Aproximação de Syntetos-Boylan - ASB) que, teoricamente, elimina o enviesamento positivo da previsão, aumentando a sua precisão.

Eaves e Kingsman (2004) compararam modelos de previsão adequados à procura intermitente (ASB, AES, método de Croston, média móvel de 12 meses e média simples)

através de medidas tradicionais de avaliação, tendo observado que os resultados variam e que nenhum método de previsão emerge como o melhor no geral.

O método de Croston, para além de ser positivamente enviesado, não realiza atualizações após períodos com procura igual a zero, o que torna as previsões desatualizadas após (muitos) períodos destes, tornando o método inadequado para estimar o risco de obsolescência. Consequentemente, Teunter *et al.* (2011) propõem um método de previsão que atualiza a probabilidade da procura, ao contrário do método de Croston, onde é o intervalo da procura que é atualizado (que corresponde ao inverso da probabilidade de ocorrer procura). Desta forma, o método reage rapidamente a situações de obsolescência súbita ou com risco aumentado, ao gerar estimativas com valor zero, apresentando ainda elevada flexibilidade ao utilizar diferentes constantes de alisamento para o tamanho e probabilidade da procura.

No estudo de Nikolopoulos *et al.* (2011), é aplicado o método ADIDA (abordagem de agregação-desagregação da procura intermitente) que visa reduzir (ou eliminar) a intermitência, ao partir do pressuposto de que as previsões com maiores níveis de agregação são geralmente mais precisas e menos variáveis.

Se, ao realizar a agregação deixar de existir procura igual a zero, pode ser utilizado qualquer método de previsão aplicado aos artigos com saída rápida, como o AES ou o método ingénuo, e deixa de existir limitação ao método de Croston ou à ASB. Depois, as estimativas poderão ser desagregadas para uma análise mais detalhada, por exemplo, passando de agregação trimestral a desagregação mensal, com igual peso na divisão.

As RNA estão também normalmente envolvidas na previsão de artigos com procura intermitente pois podem ser aplicadas à modelação de séries temporais sem assumirem modelos de funções *a priori* (Mitrea *et al.*, 2009).

Gutierrez *et al.* (2008) avaliaram a adequação, e eventual superioridade, das RNA para modelar e prever a procura intermitente face aos métodos tradicionais. Este estudo aplica quatro métodos alternativos (AES, método de Croston, ASB e RNA), de entre os quais a ASB obteve melhor desempenho que o AES e o método de Croston, mas, no geral, as RNA foram superiores a todos os métodos.

Kourentzes (2013) propõe um método de RNA para prever séries temporais de procura intermitente que permite a interação entre o tamanho da procura e os intervalos inter-procura, retendo os conceitos básicos do método de Croston, mas expandindo-os para permitir dinâmicas de modelação no volume da procura e nos intervalos inter-procura, e interações entre estes. Conclui que, embora não se observe superioridade das RNA face aos métodos de referência (método de Croston e suas modificações, médias móveis e

AES) no que se refere à precisão identificada, existe uma clara vantagem das RNA quanto às métricas de controlo de inventário, com o nível de serviço a melhorar significativamente, sem aumentar substancialmente o nível de inventário armazenado.

2.3.3. Considerações sobre a Previsão da Procura

Um dos principais problemas do controlo de inventário consiste em encontrar a distribuição que representa adequadamente a procura para cada artigo. Se a procura agregada por um artigo resulta de um grande número de pequenas procuras de consumidores individuais, é seguro assumir que esta é contínua e segue uma distribuição normal. De facto, na maioria da literatura, a procura é representada por uma distribuição normal (Johnston *et al.*, 2003; Levén e Segerstedt, 2004; Waters, 2003).

Contudo, as desvantagens da distribuição normal, no que respeita às características desejáveis para a procura, incluem o facto de ser definida no conjunto dos números reais, o que é irrealístico, e, como é simétrica, apenas se adequa à representação da procura de artigos com saída muito rápida (Burgin, 1975).

Em múltiplos outros estudos, a procura segue uma distribuição similar à de Poisson (p.e., Hill *et al.* (2007), Levén e Segerstedt (2004)), e noutros várias distribuições contínuas (gama, uniforme, lognormal, exponencial negativa, etc.) foram utilizadas para modelar a procura (p.e., Burgin (1975), Klosterhalfen *et al.* (2013)).

Já o tipo de método de previsão a utilizar depende de diversos fatores, desde a janela temporal da previsão, ao comportamento da procura e às suas causas, até à possível existência de padrões.

Se se suspeita que a procura é altamente não estacionária, é preferível aplicar um método de previsão que se adapte rapidamente, o que pode ser alcançado com a utilização de constantes de alisamento suficientemente grandes. Se tal não for o caso, preferem-se constantes de alisamento pequenas (Prak e Teunter, 2019; Syntetos e Boylan, 2008; Teunter *et al.*, 2011).

Uma forma de definir as constantes de alisamento sem conhecer o processo subjacente da procura é através da otimização empírica baseada nos dados históricos da procura, o que pode ser difícil para a procura intermitente devido à típica falta de dados. Outra opção consiste em utilizar os valores fixos recomendados por Syntetos e Boylan (2005).

É altamente improvável que um único modelo seja dominante uniformemente ao longo do tempo e é plausível que o melhor ajuste se altere com o passar do tempo. Assim, é aceitável considerar que as previsões resultantes de um dado método de previsão podem

fornecer alguma informação útil que não está presente nas previsões decorrentes de outros métodos (Aiolfi e Timmermann, 2006; S. Makridakis et al., 1982).

Desta forma, em vez de selecionar apenas um método de previsão, combinar previsões resultantes de vários métodos pode ser vantajoso. Nestes casos, pode ser atribuído igual peso às previsões ou pesos diferenciados, inversamente proporcionais ao EQM do método individual de previsão (Aiolfi e Timmermann, 2006; Spyros Makridakis e Winkler, 1983).

Petropoulos *et al.* (2014) combinaram diversos métodos de previsão, tendo determinado que a precisão da conjugação de métodos frequentemente excede a precisão dos métodos individuais, reduzindo também a variância dos erros de previsão e, conseqüentemente, a incerteza nas previsões, tal como já demonstrado por Hibon e Evgeniou (2005) e por Makridakis e Winkler (1983), embora exista uma tendência para a estabilização da precisão a partir da adição de um certo número de métodos.

O objetivo dos métodos de previsão é gerar estimativas de previsão que sejam tão precisas quanto possível, pelo que é comum avaliar o desempenho destes métodos através de medidas dos erros de previsão (ou resíduos). Estes erros, para qualquer período t , correspondem ao valor do desvio da previsão face ao valor real observado nesse período (Hillier e Lieberman, 2001).

As medidas dos erros de previsão estão sujeitas a validação e existem diferentes conclusões a retirar dependendo da medida utilizada. As mais comuns incluem o desvio absoluto médio (DAM), que deve rondar zero se os erros não estiverem enviesados, e o EQM, que penaliza mais os erros maiores de previsão e ignora praticamente os erros pequenos (Gardner, 1985; Hillier e Lieberman, 2001; Wallström e Segerstedt, 2010).

Bretschneider (1986) comparou as medidas DAM e EQM para estimar a variação das previsões para o AES, tendo mostrado que o EQM é mais eficiente.

Os métodos de previsão são ainda otimizados, por norma, quanto à raiz do erro quadrático médio (REQM) (Gneiting, 2011) e ao erro percentual absoluto médio (EPAM), mais robusto contra *outliers* (Gardner, 2006). Um estudo de Armstrong e Collopy (1992) concluiu que a medida de erro mais adequada para efetuar comparações quando existe um grande conjunto de dados na série temporal é o EPAM. Contudo, aplicá-lo à procura intermitente é difícil devido ao grande número de períodos com procura igual a zero.

As medidas apresentadas são úteis para determinar o método de previsão que melhor se ajusta a uma série temporal, auxiliando também na escolha e otimização de parâmetros, como as constantes de alisamento. Independentemente da medida aplicada, menores valores de erro significam melhores previsões (Hillier e Lieberman, 2001; Waters, 2003).

Syntetos e Boylan (2005) argumentam que, para medir a precisão das previsões na procura intermitente, é necessário considerar a presença de zeros na procura, o que torna difícil, ou impossível, calcular as medidas de erro tradicionais que subavaliam as previsões. Neste sentido, uma avaliação mais apropriada consiste em analisar o efeito das previsões nos parâmetros de desempenho e controlo de inventário, nomeadamente nos níveis de inventário e de serviço resultantes (Strijbosch *et al.*, 2011; Teunter e Duncan, 2009).

Wallström e Segerstedt (2010) compararam o AES, o método de Croston, a ASB e a versão modificada do método de Croston de Levén e Segerstedt (2004), com o objetivo de mostrar que uma única medida de erro, por norma, não representa as diferentes dimensões dos erros. Para tal, determinam o DAM, o EQM, o SEPAM (EPAM simétrico, que pode ser aplicado na procura intermitente, de acordo com Makridakis e Hibon (2000)) e o erro de previsão acumulado (EPA, uma medida do enviesamento do erro).

Adicionalmente, os mesmos autores avaliam o número de roturas e introduzem a medida do número de períodos em inventário (PEI) que considera o aspeto temporal do erro de previsão, ou seja, o número total de períodos em que as unidades previstas do artigo permanecerão em inventário. Esta medida avalia não só o erro, mas também o tempo que demora a corrigir a previsão, sendo que um sinal positivo indica que o método de previsão sobrestima a procura, enquanto um sinal negativo aponta para uma subestimação ou períodos em rotura.

Syntetos e Boylan (2005) confrontam a precisão dos métodos AES, de Croston e ASB. Os resultados foram comparados utilizando o erro médio (EM), o EQM, a raiz geométrica relativa do erro médio (RGREQM) e a percentagem melhor (PM, de Makridakis e Hibon (2000)) e indicam que a ASB apresenta a estimativa mais precisa para os dados de procura intermitente. Quando se considera todo o período temporal, a AES apresenta precisão superior ao método de Croston.

Syntetos e Boylan (2006) confrontaram o método de médias móveis exponencialmente ponderadas, o método de Croston, o método de média móvel 13 e a ASB, quanto ao desempenho no controlo de inventário, tendo aplicado como medidas de avaliação a fração da procura que é satisfeita diretamente pelo inventário (a medida de serviço mais amplamente utilizada no contexto de procura intermitente, de acordo com Strijbosch *et al.* (2000)), e ainda os custos de rotura e de entrega de emergência por unidade em rotura.

Foram também aplicadas a PM e a percentagem de arrependimento média (PAM), uma medida que indica o arrependimento relativo associado a utilizar um dado método, considerando o melhor desempenho possível de atingir. Os resultados demonstram, em geral, o desempenho superior da ASB (Syntetos e Boylan, 2006).

Como referido por Eaves e Kingsman (2004) e Syntetos e Boylan (2006, 2008), a melhor precisão de um método de previsão sobre outros não se traduz numa melhor eficiência na gestão e controlo de inventário, pois o crucial não é a previsão em si, mas sim utilizá-la para alcançar o nível de serviço ao consumidor alvo ou minimizar a função custo. De facto, os métodos de previsão fornecem estimativas baseadas em dados históricos, mas não garantem o ajuste a novos dados e não atentam à posição de inventário atual, nem à política de encomenda em vigor, pelo que tendem a falhar nestes aspetos.

Quanto ao nível de agregação dos dados, a estimativa da procura que se obtém utilizando dados desagregados será mais elástica pois consegue capturar a resposta inicial dos consumidores a uma alteração e comportamentos individuais com maior precisão, enquanto as estimativas que utilizam dados agregados captam respostas de longo prazo (Espey, 1998; Levin *et al.*, 2017; Nicol, 2003).

Independentemente do método e nível de agregação utilizados, ocorre eventualmente enviesamento, como apontam Wallström e Segerstedt (2010), pelo que existe a necessidade de aplicar medidas que o detetem, meçam e sugiram correções apropriadas.

Em concreto, uma subprevisão substancial da procura pode originar vendas perdidas, consumidores insatisfeitos e, possivelmente, direcioná-los para concorrentes. Por outro lado, uma sobreprevisão pode ser dispendiosa devido a custos excessivos de inventário, reduções de preço forçadas, capacidade de armazenagem desnecessária, depreciação dos artigos (por norma, cerca de 10% do valor do inventário) ou perda de oportunidade de venda de artigos mais lucrativos (Hillier e Lieberman, 2001).

Desta forma, é crucial aplicar uma política de inventário que seja simultaneamente adequada à previsão da procura, mas que também permita flexibilidade para ajustes sempre que estes se mostrarem necessários.

2.4. Política de Inventário

A política de inventário engloba o conjunto de ações que visa alinhar o inventário detido por um retalhista com a procura por ele esperada. Neste sentido, uma política adequada necessita de considerar as características dos artigos, em especial quando estes apresentam variabilidade tanto no tamanho como na ocorrência de procura (Babiloni *et al.*, 2012; Syntetos *et al.*, 2005).

Os retalhistas dividem os artigos que oferecem em várias categorias, iniciando o processo de planeamento do sortido pela previsão das vendas para cada categoria, para um período futuro. De seguida, o espaço disponível e o orçamento são alocados a cada categoria, com base na procura prevista, nas preferências do consumidor, nas margens de

lucro, na disponibilidade de fornecedores e no enquadramento competitivo, determinando-se o número de artigos a integrar em cada uma (Akçay *et al.*, 2020; Kök *et al.*, 2015).

O momento de efetuar uma encomenda pode seguir uma de três abordagens: realizar uma revisão periódica (R) e colocar encomendas de tamanho variável em intervalos de tempo regulares, elevando o inventário para um nível determinado (S) (política (R,S) presente na Figura 1); realizar uma revisão contínua e efetuar uma encomenda de quantidade fixa (S) assim que os níveis de inventário descem abaixo do limite (s) definido (política (s,S) ilustrada na Figura 2); ou relacionar a oferta com a procura ao encomendar inventário suficiente para responder à procura esperada num período de tempo específico (política (R,s,S) exibida na Figura 3) (Babiloni *et al.*, 2012; Waters, 2003).

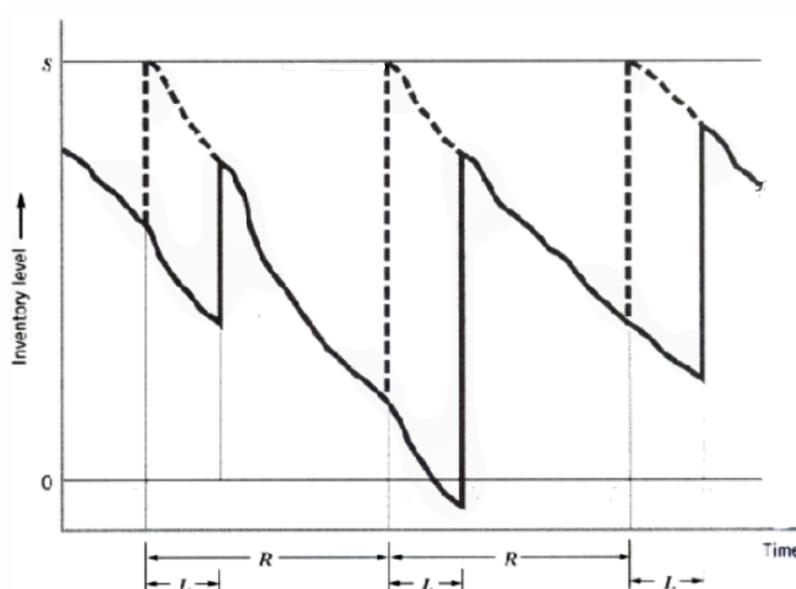


Figura 1 - Política de Inventário (R,S) , onde R corresponde ao período de revisão, S ao nível de inventário determinado e L ao lead time da entrega da encomenda (Silver *et al.*, 1998).

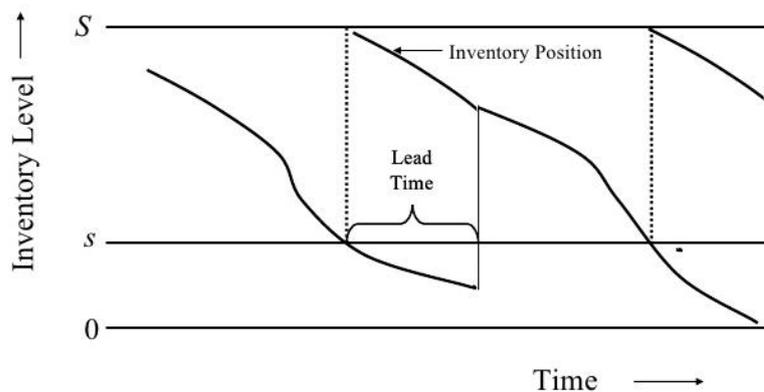


Figura 2 - Política de Inventário (s,S) , onde s corresponde à quantidade mínima de inventário e S ao nível de inventário determinado (Waters, 2003).

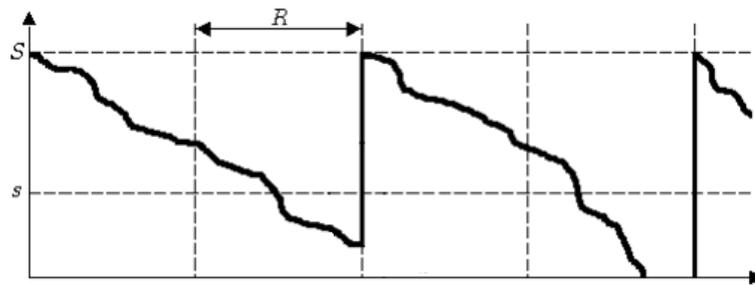


Figura 3 - Política de Inventário (R,s,S) , onde R corresponde ao período de revisão, s à quantidade mínima de inventário e S ao nível de inventário determinado (Babiloni et al., 2012).

Uma vez tomada a decisão acerca da frequência e tamanho das encomendas, são estabelecidos automaticamente aspetos como o nível de inventário médio, o inventário de segurança, os custos, o nível de serviço ao consumidor e a probabilidade de rotura.

Sani e Kingsman (1997) sugerem a revisão periódica de forma a minimizar os custos totais de inventário, enquanto Yeh *et al.* (1997) propõem a revisão contínua para garantir o nível de serviço ao consumidor desejado. Já o sistema (R, s, S) foi aclamado por Babiloni *et al.* (2012) e Silver *et al.* (1998), como eficiente para a gestão tanto de artigos com saída rápida como lenta.

É de ressaltar que a quantidade a encomendar pode ser variável ou fixa, neste caso justificada pela teoria clássica do lote económico (Harris, 1913), que determina a quantidade ótima de encomenda que minimiza os custos totais. Consequentemente, uma encomenda pode ter a capacidade de responder à procura de vários períodos de revisão.

Syntetos *et al.* (2009) propõem uma modificação do modelo de previsão clássico e da abordagem (s,S) para a procura intermitente quando o *lead time* é inferior ao intervalo inter-procura. Se não ocorre procura durante o intervalo definido, o valor inicial da procura é definido em um e assume-se que a procura unitária por período segue uma distribuição binomial negativa. Ao avaliarem o desempenho em termos de custo total de inventário, os resultados indicam uma redução considerável nos custos de inventário (entre 14% e 22%) com a nova abordagem, sem penalizar o serviço ao consumidor.

Já o artigo de Levén e Segerstedt (2004) conclui que quando a procura é intermitente, um sistema de controlo de inventário baseado no procedimento de Croston modificado e na distribuição de Erlang tem melhor desempenho que um sistema que recorra ao AES e à distribuição normal, para a redução de roturas de inventário, mostrando os resultados que a redução de roturas não se deve a maiores níveis de inventário.

3. Mercado de Pneus e de Combustíveis

O presente capítulo descreve o mercado de pneus e de combustíveis a nível mundial, europeu e nacional, e refere investigações anteriores realizadas no âmbito da previsão das vendas de pneus e de combustíveis.

3.1. Pneus

A indústria de pneus divide-se em dois segmentos principais de mercado final: pneus de substituição (mercado pós-venda) e pneus para novos veículos (fabricantes originais de equipamento). O consumo do mercado global, em volume, aumentou 5,3% entre 2014 e 2018, atingindo 4.415,7 milhões de pneus em 2018. Espera-se que este valor aumente para 5.667,4 milhões até ao final de 2023 (MarketLine, 2019).

A European Tyre and Rubber Manufacturers' Association (2019) reportou que foram vendidos 310 milhões de pneus na UE (ligeiros e comerciais), o que representa 20% do mercado global de pneus.

O segmento do mercado pós-venda mundial mais lucrativo em 2018 foi o comercial e pesado, com receitas equivalentes a 36,8%, decorrentes principalmente das economias de países em desenvolvimento (MarketLine, 2019).

Em Portugal, segundo dados da Europool, o mercado total de pneus ascendeu a 2,72 milhões de pneus vendidos em 2020, destes 2,16 milhões são pneus ligeiros (79,6%), 0,18 milhões pneus 4x4 (6,6%), 0,21 milhões pneus comerciais (7,8%) e 0,17 milhões pneus pesados (6,1%). Em termos percentuais, verifica-se um decréscimo nas vendas em todas as categorias face a 2019 (de -14,42%, -0,79%, -12,86% e -11,91%, respetivamente).

Ao nível de fabricantes originais de equipamento, existem claros líderes, destacando-se a Bridgestone, a Continental AG e a Michelin. Já o mercado pós-venda é nitidamente mais fragmentado (MarketLine, 2019).

O mercado de pneus é altamente sensível a efeitos externos, nomeadamente ao avanço da indústria automóvel, a melhorias na economia que impulsionam a compra de veículos e ao aumento do transporte rodoviário (de pessoas e carga). Consequentemente, ocorrerá maior e mais rápido desgaste dos pneus, potenciando o consumo de substituição.

A literatura acerca da previsão de vendas de pneus é escassa e pouco extensa. Neste âmbito, Mahama-Musah *et al.* (2020) observaram que o mercado pós-venda independente (oficinas particulares) é o mais popular para a compra de pneus e que a internet é bastante consultada para a pesquisa de informação geral relativa a locais para substituição de pneus e de informação específica acerca de marcas, preços e de quando substituir pneus.

Quanto aos fatores que influenciam a escolha da marca ou modelo de pneu, o preço e qualidade são os mais comuns, sendo a escolha do artigo a adquirir altamente influenciada pela opinião do mecânico, mas sobretudo pelo preço (Mahama-Musah *et al.*, 2020).

Existem diversas variáveis que afetam o consumo de pneus, desde fatores económicos que afetam a procura, como o preço do petróleo e do gás, o PIB, as taxas de juro e a taxa de desemprego, a outros fatores, como a quilometragem média percorrida, condições das estradas, vida útil dos pneus, carga transportada e a procura e custos de anos anteriores.

Contudo, efetuar previsões tem-se provado difícil uma vez que a psicologia humana desempenha um papel crucial na decisão de como e onde comprar pneus, pelo que os modelos de previsão tradicionais tendem a não considerar os fatores supramencionados, dependendo predominantemente dos dados históricos de vendas e do conhecimento de especialistas (Miller e Liem, 2004; Natarajan *et al.*, 2013).

3.2. Combustíveis

As bombas de combustíveis integram uma indústria de serviços onde a qualidade do combustível, a velocidade do serviço e o preço constituem os principais componentes da vantagem competitiva. De facto, Wu e Wolak (2018) concluíram no seu estudo que, em média, um condutor observa os preços de 3,57 retalhistas no seu itinerário diário e compara o custo de abastecer em cada um face à alternativa de esperar para adquirir combustível numa viagem futura.

Nos países europeus, o volume de veículos a gasóleo representa cerca de metade do parque automóvel, não correspondendo apenas aos veículos de transporte como nos demais países (Dahl, 2012; Labandeira *et al.*, 2017; Liddle e Huntington, 2020).

Em 2019, em Portugal, as vendas de gasolinas 95 e 98 alcançaram 1.080.137 toneladas e as de gasóleo rodoviário 4.328.684 toneladas, representando, já desde 2015, uma distribuição de cerca de 81% do consumo para veículos movidos a gasóleo e de 19% para os movidos a gasolina (INE, 2021).

No mesmo ano, as vendas de gasóleo agrícola alcançaram 265.734 toneladas e as de gasóleo para aquecimento 91.965 toneladas, o que corresponde a 4,61% e a 1,59%, respetivamente, das vendas totais de combustíveis (INE, 2021).

No concelho de Leiria, as vendas de combustíveis distribuem-se em 12.497 toneladas de gasolinas, 97.322 toneladas de gasóleo rodoviário, 8.559 toneladas de gasóleo agrícola e 6.306 toneladas de gasóleo para aquecimento, o que equivale a 1,16%, 2,25%, 3,22% e 6,86%, respetivamente, do total de vendas nacional (INE, 2021).

A grande maioria da literatura (p.e., Baranzini e Weber (2013), Dahl (2012), Havranek e Kokes (2015), Mikayilov *et al.* (2020) ou Pock (2010)), utiliza como variáveis da determinação da procura por combustíveis o preço destes e o rendimento *per capita* (ou PIB *per capita*, como *proxy*). Alguns autores acrescentam outras variáveis, como a quantidade de veículos detida por condutor, o preço do combustível em países vizinhos, o preço do barril de petróleo, os impostos sobre os combustíveis, a eficiência de combustível do veículo ou variáveis que se considere que afetam o consumo de um agregado familiar (p.e., tamanho e composição do agregado, número de assalariados e nível de educação).

Os consumidores apresentam uma elevada elasticidade do preço da procura ao serem bastante responsivos a mudanças temporárias e previsíveis nos preços de combustíveis (p.e., mudam os dias de compra para os dias com promoções conhecidas), com uma resposta mais forte a aumentos de preço do que a descidas (Levin *et al.*, 2017; Liu, 2020; Noel, 2019). Mais, verifica-se um padrão consistente com os consumidores a encherem os depósitos antes de subidas de preços conhecidas, por exemplo, provocadas pelo aumento de impostos (Coglianese *et al.*, 2017; Filippini e Heimsch, 2016; Scott, 2012).

No entanto, é de ressaltar que os veículos de transporte de bens apresentam menor sensibilidade ao preço que os veículos privados (Goodwin *et al.*, 2004).

Em valor absoluto, a elasticidade do rendimento é superior à do preço, o que significa que o preço necessita de aumentar mais rapidamente que o rendimento para que o consumo de combustível permaneça nos níveis atuais (Aklilu, 2020; Basso e Oum, 2007; Scott, 2012).

O efeito da variação do preço do combustível, no curto prazo, é solucionado através do ajuste da utilização do veículo (p.e., quilómetros percorridos, número de viagens, estilo de condução), enquanto no longo prazo os consumidores adaptam o custo de utilização do veículo, nomeadamente optando por um veículo mais eficiente ou mudando de local de residência ou de emprego (Baranzini e Weber, 2013; Levin *et al.*, 2017; Scott, 2012).

Kayser (2000), Schmalensee e Stoker (1999) e Wadud *et al.* (2010) concluem que a elasticidade de preço e de rendimento de um agregado familiar depende do número de veículos detido, do número de assalariados e da localização da residência. Os mesmos autores determinaram ainda que agregados que residem em áreas urbanas consomem menos combustível que os que vivem nos subúrbios, e estes menos que habitantes de zonas rurais, e que a elasticidade do rendimento diminui com o aumento deste, indicando possivelmente a saciação da procura com rendimentos superiores.

Para prever a procura por combustíveis, o modelo mais simples utilizado é o estático, onde a procura é função do preço e rendimento reais. Na utilização deste modelo, é crucial

garantir que as séries temporais são estacionárias, como refere Havranek e Kokes (2015), caso contrário a regressão requer que exista uma relação estável de longo prazo entre as variáveis para ser confiável (as variáveis dizem-se cointegradas).

No entanto, vários autores (p.e., Dahl (2012), Espey (1998)) salientam que estes modelos assumem que a procura observada está em equilíbrio com o preço observado e apenas captam elasticidades de preço no prazo intermédio, pois ao manterem as características das variáveis fixas não captam o processo de resposta comportamental a alterações que ocorrem ao longo do tempo, muito provavelmente num período superior ao dos dados utilizados. Neste sentido, Dahl e Sterner (1991), Goodwin *et al.* (2004) e Kanjilal e Ghosh (2018) argumentam que é necessário utilizar modelos dinâmicos para capturar respostas de longo prazo e para separar de forma adequada o curto do longo prazo.

Já Souza *et al.* (2018) aplicaram um modelo de RNA para prever as vendas de combustível que, mesmo com estrutura relativamente simples, apresentou precisão e desempenho satisfatórios durante o período observado.

4. A Empresa DiguiPneus

Este capítulo apresenta o caso de estudo do projeto, em concreto a empresa DiguiPneus, Lda, realizando-se uma breve exposição da mesma e da evolução do seu volume de negócios, uma análise do retalho nacional de pneus e combustíveis e a descrição dos processos atuais de planeamento de compras e de inventário.

4.1. Descrição da Empresa

A DiguiPneus, Lda. consiste numa empresa familiar, com sede no lugar de Cardosos, concelho de Leiria, tendo sido formada em 2011 como derivação de uma outra empresa familiar estabelecida em 1988. Posiciona-se no setor do pós-venda do mercado automóvel ao deter como CAE principal o 46711, comércio por grosso de produtos petrolíferos, e como CAEs secundários o 45200, manutenção e reparação de veículos automóveis, e o 47300, comércio a retalho de combustível para veículos a motor, em estabelecimentos especializados.

Neste sentido, a DiguiPneus é uma oficina automóvel que presta serviços a veículos ligeiros, comerciais, pesados e agrícolas, nomeadamente, serviços rápidos e mecânica, mudança de pneus, alinhamento de direção, equilibragem de rodas e carregamento de ar condicionado. Adicionalmente, é revendedora de lubrificantes (p.e., óleo de motor, valvulina) e de combustíveis, nomeadamente, gasóleo simples e aditivado, gasolinas 95 e 98, petróleo, gasóleo agrícola e gasóleo para aquecimento.

A empresa pretende oferecer aos seus clientes, empresariais e particulares, uma experiência de consumo de confiança, com produtos adequados e serviço de qualidade superior, pautada por variedade e disponibilidade. Para tal, visa a criação e fortalecimento de relações de valor com todos os seus *stakeholders*, em especial colaboradores, clientes, fornecedores e a comunidade onde se insere.

Presentemente, conta com 11 colaboradores e alcançou um volume de negócios de cerca de 2,595 milhões de euros em 2020, o que a classifica como uma pequena empresa, de acordo com a recomendação efetuada pela Comissão Europeia.

4.2. Evolução do Volume de Negócios

Uma análise da Figura 4 permite observar que o volume de negócios da empresa aumentou constantemente entre 2011 e 2017, atingindo o máximo de 2,978 milhões de euros. Em 2018 verifica-se um decréscimo de cerca de 6% neste valor, sendo que o volume de negócios alcançado em 2019 também apresenta uma redução, neste caso de 3%, face aos 2,799 milhões de euros alcançados no ano prévio.

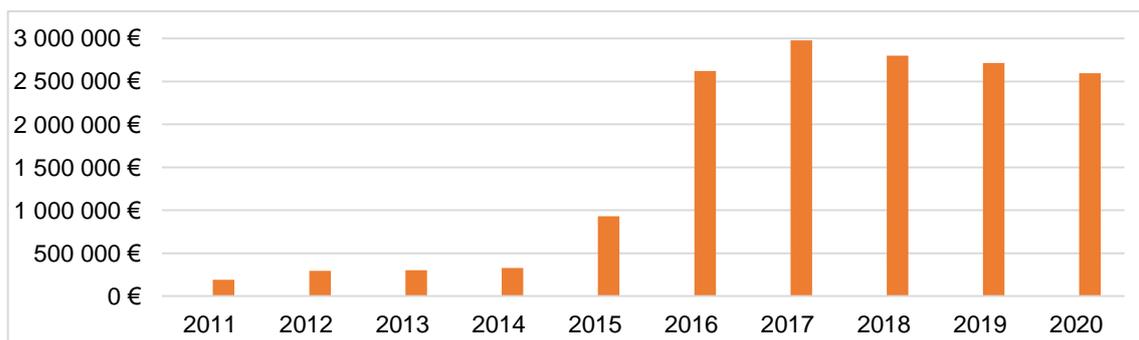


Figura 4 - Volume de negócios total anual da empresa DiguiPneus Lda (Fonte: elaboração própria).

No ano de 2020 a empresa continuou a laborar dentro da nova “normalidade” associada à pandemia COVID-19, uma vez que foi sempre permitida a sua atividade. O volume de negócios verificou, contudo, um decréscimo de cerca de 4% relativamente aos 2,714 milhões de euros alcançados em 2019.

Analisando a Figura 5, referente ao volume de negócios mensal atingido em cada ano, não é possível determinar um padrão evidente. No entanto, os meses de abril a setembro aparentam ser aqueles com menor volume de negócios.

Quando se reparte o volume de negócios em vendas de produtos e em serviços prestados (consultar Figuras 6 e 7), verifica-se que entre 97% a 99% deste provém da venda de produtos, pelo que os serviços prestados apresentam um peso muito reduzido sobre o volume de negócios, apenas alcançando aproximadamente 2,65% em 2019.

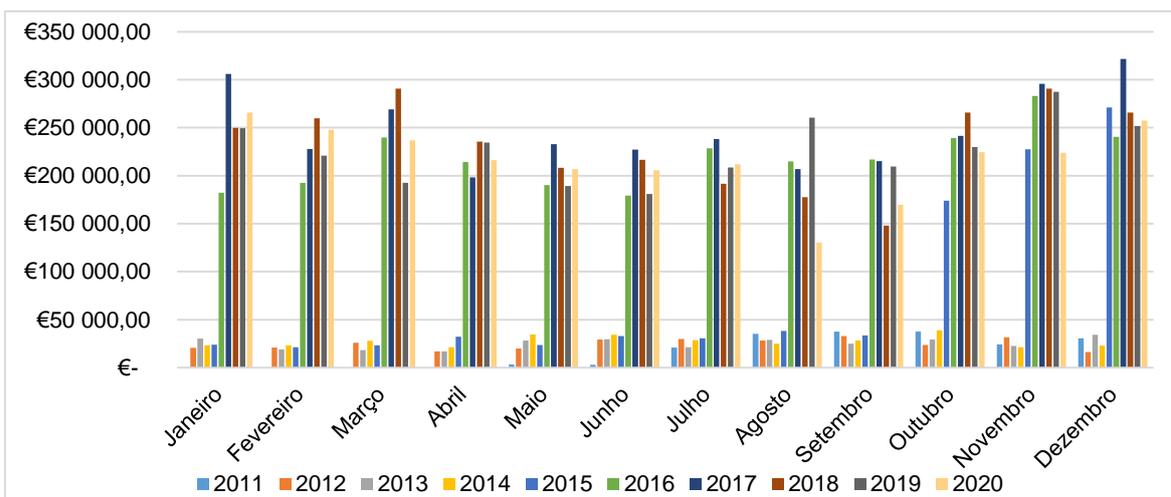


Figura 5 - Volume de negócios total mensal da empresa DiguiPneus Lda (Fonte: elaboração própria).

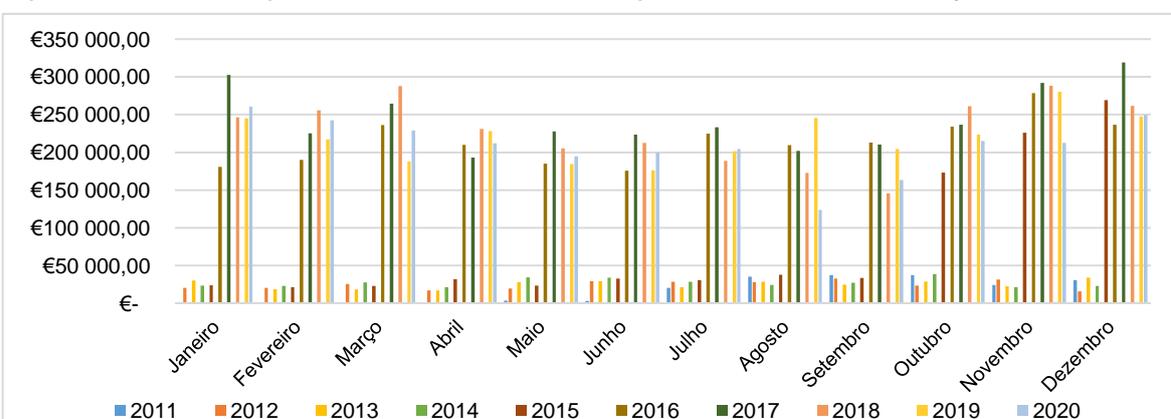


Figura 6 - Vendas de produtos totais mensais da empresa DiguiPneus Lda (Fonte: elaboração própria).

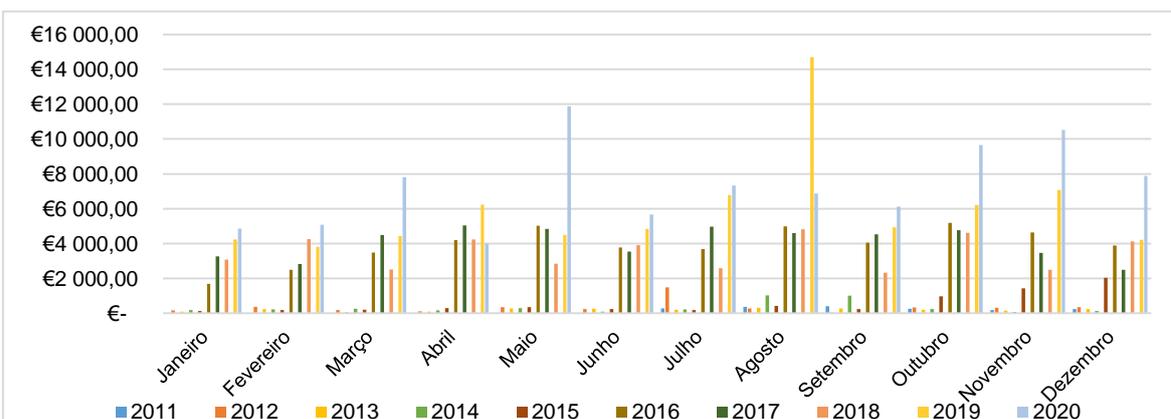


Figura 7 - Serviços prestados totais mensais da empresa DiguiPneus Lda (Fonte: elaboração própria).

Na Tabela 1 encontra-se agregado o volume de vendas nas categorias Combustíveis, Pneus e Outros. A denominação “Combustíveis” engloba as vendas de gasóleo simples, gasóleo aditivado, gasóleo agrícola, gasóleo para aquecimento, gasolina 95, gasolina 98, mistura e petróleo. Já a designação “Pneus” inclui as vendas de pneus ligeiros, comerciais, 4x4, pesados e outros (p.e., agrícolas, industriais). Por fim, a categoria “Outros” engloba

as vendas de peças e produtos para automóveis, serviços prestados, lubrificantes, câmaras de ar e AdBlue.

Tabela 1 - Distribuição das categorias Combustíveis, Pneus e Outros sobre o volume de vendas e sobre o lucro bruto.

Ano	Percentagem do Volume de Vendas			Percentagem do Lucro		
	Combustíveis	Pneus	Outros	Combustíveis	Pneus	Outros
2011		92,97%	7,03%		83,97%	16,03%
2012		96,77%	3,23%		87,14%	12,86%
2013		97,45%	2,55%		89,65%	10,35%
2014		96,45%	3,55%		88,21%	11,79%
2015	53,93%	42,79%	3,28%	34,64%	52,80%	12,56%
2016	80,32%	14,37%	5,31%	57,12%	21,18%	21,71%
2017	81,61%	13,50%	4,89%	56,06%	20,57%	23,37%
2018	78,54%	16,10%	5,37%	53,19%	24,37%	22,44%
2019	78,67%	15,21%	6,12%	55,38%	20,40%	24,22%
2020	74,75%	18,14%	7,11%	60,91%	19,39%	19,70%

É de notar que entre 2011 e 2014 não existiu comercialização de combustíveis. Neste sentido, desde 2015 que se verifica que é a venda de combustíveis que representa a maioria da faturação (cerca de 80%), seguida do comércio de pneus (cerca de 15%) e dos restantes produtos e serviços (cerca de 5%). Em termos de evolução, verifica-se um ligeiro aumento nas transações de Outros nos últimos anos (2017 a 2019), em detrimento das restantes categorias.

Atendendo ao que estas vendas representam para o lucro bruto, observa-se que, a partir de 2015, o peso da categoria Pneus é aproximadamente seis pontos percentuais maior, em média, sobre o lucro que sobre as vendas, enquanto o peso de Outros é 3,5 vezes superior sobre o lucro que sobre as vendas. Por outro lado, é notório o menor impacto que o comércio de combustíveis apresenta sobre o lucro quando comparado com o impacto sobre a faturação, quantificando-se em 1,4 vezes inferior.

Para o ano de 2019 em específico, verifica-se que 78,67% das vendas correspondem ao retalho dos diversos combustíveis (de onde se destacam o gasóleo para aquecimento e o gasóleo simples), 15,21% ao comércio de pneus (com peso decrescente para pneus pesados, ligeiros e comerciais) e 6,12% aos restantes produtos e serviços. Contudo, os Combustíveis representam 55,38% do lucro bruto, enquanto os Pneus constituem 20,40% deste e os Outros 24,22%.

Já em 2020, e salientando que em grande parte do ano se viveu uma situação de pandemia e de quarentena, observa-se que 74,75% das vendas correspondem ao retalho dos diversos combustíveis (voltando-se a destacar o gasóleo para aquecimento e o gasóleo simples), 18,14% ao comércio de pneus (com peso decrescente para pneus ligeiros, pesados e comerciais) e 7,11% aos restantes produtos e serviços. Os

Combustíveis compõem 60,91% do lucro bruto, já os Pneus constituem 19,39% deste e os Outros 19,70%.

Deve ainda ser realçado que, embora o volume de negócios anual tenha regredido em 2020 (conforme observado na Figura 4), o mesmo não sucedeu com o lucro bruto realizado, como demonstra a Figura 8. De facto, em 2018 foi verificado um decréscimo de 3,42% face a 2017, contudo em 2019 ocorreu um aumento de 13% no lucro bruto e em 2020 esse aumento foi de 22,09%.

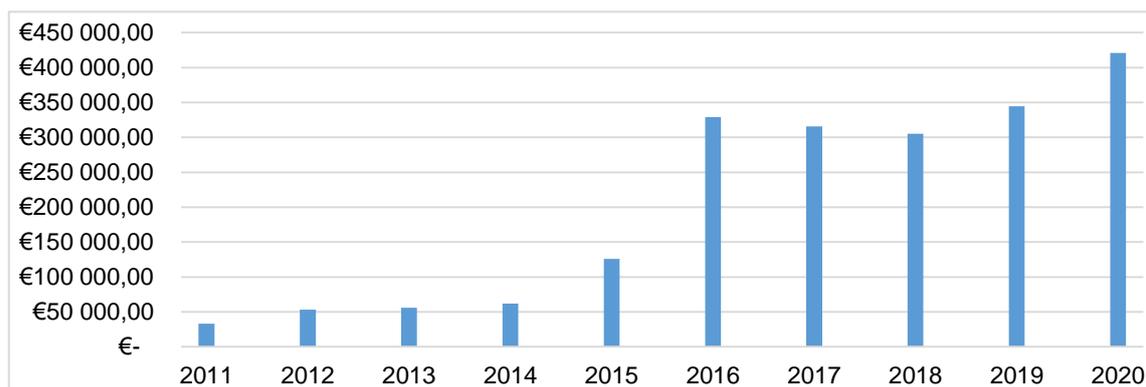


Figura 8 - Lucro Bruto anual da empresa Diguipneus Lda (Fonte: elaboração própria).

4.3. Análise Nacional do Retalho de Pneus e Combustíveis

O Banco de Portugal disponibiliza quadros do setor que possibilitam comparar o desempenho da empresa Diguipneus com pequenas empresas do mesmo setor. Neste sentido, verifica-se que quanto ao CAE 46711 (comércio por grosso de produtos petrolíferos) em 2019 (último ano disponível) existiam 75 empresas no panorama português sendo que entrou uma empresa e ocorreram duas saídas, tendo o volume de negócios médio sido de cerca de 724 mil euros, correspondente a 43,54% do volume de negócios de todas as empresas com este CAE.

Em relação ao CAE 45200 (manutenção e reparação de veículos automóveis), os dados de 2019 mostram que existiam 524 empresas em Portugal, resultado de mais uma entrada e de cinco saídas, com um volume de negócios médio de 503 mil euros, uma subida de 4% comparando com 2018. Este volume de negócios corresponde a 30,60% do volume de negócios de todas as empresas com o CAE 45200.

Considerando o CAE 47300 (comércio a retalho de combustíveis), existiam, em 2019, 361 empresas, tendo ocorrido duas entradas e cinco saídas, com um volume de negócios médio de 2,730 milhões de euros, menos 0,2% que em 2018. Este volume de negócios refere-se a 40,61% do produzido por todas as empresas com o CAE 47300.

Na Tabela 2 estão presentes as evoluções do volume de negócios dos diferentes CAEs e da Diguipneus, podendo-se verificar que enquanto a empresa apurou um aumento do

volume de negócios de 2012 a 2017, existiu um decréscimo nas vendas associadas aos CAES 46711 e 47300 em 2012 e ao CAE 45200 em 2012 e 2013. Em 2016 o comércio a retalho de combustíveis também sofreu uma diminuição nas vendas.

*Tabela 2 - Evolução do Volume de Negócios dos diferentes CAEs e da DigiuiPneus. (*não existem dados disponíveis para o CAE 46711 entre 2013 e 2018).*

	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
DigiuiPneus	-	↗	↗	↗	↗	↗	↗	↘	↘	↘
CAE 46711	↗	↘	*	*	*	*	*	*	↗	-
CAE 45200	↘	↘	↘	↗	↗	↗	↗	↗	↗	-
CAE 47300	↗	↘	↗	↗	↗	↘	↗	↗	↘	-

Já em 2018, a DigiuiPneus obteve uma quebra no volume de negócios, contrariamente ao verificado no setor da manutenção e reparação de veículos automóveis e no de comércio a retalho de combustíveis. Em 2019, a diminuição do volume de negócios está apenas alinhada com a do CAE 47300.

As diferenças observadas podem ser explicadas, nos primeiros anos (2012 e 2013), pelo crescimento do volume de negócios normal associado à criação de uma empresa. Quanto a 2016, as disparidades provavelmente resultam do facto da diminuição nas vendas associadas ao CAE 47300 ser compensada pelo aumento das vendas associadas aos restantes CAEs, verificando-se o inverso em 2018 e 2019.

Contudo, e como demonstra a Figura 8, a diminuição do volume de vendas não se traduz na diminuição do lucro obtido, mas antes na alteração da distribuição das vendas, tendo-se passado a executar atividades com menor valor de venda nas quais a margem de lucro para a empresa é superior.

4.4. Planeamento de Compras e de Inventário

As compras de produtos na DigiuiPneus são apenas da responsabilidade do chefe de oficina, sendo este também o responsável pela determinação das quantidades a encomendar e da altura indicada. Atualmente, a execução das compras resulta apenas do julgamento humano, isto é, não recorre a modelos (matemáticos ou outros) para determinar a previsão de vendas futuras, apoiado pela faturação diária da empresa, respeitando a regra de que apenas se voltam a comprar os artigos que forem vendidos (saídas efetivas de inventário) e em quantidade idêntica.

A área de armazenamento disponível na empresa é extensa, pelo que nunca surgiram questões de falta de espaço, nem se verificou a necessidade de planear melhor o inventário.

Quanto a fatores macroeconómicos, aquando da criação da empresa, existia alguma atenção à variação de preços para escolher o momento indicado da compra de pneus de

forma a tirar vantagem de descidas de preços. Contudo, as variações atuais são diminutas e surgiram vários novos fornecedores, cada um com o seu *marketplace* digital, o que permite a comparação *online* de preços, quantidade disponível e prazos de entrega. Mais, os atuais custos de encomenda não são significativos, pois o valor mínimo de encomenda a partir do qual o fornecedor assume os custos de envio ronda, em geral, os €100, um montante facilmente atingido (p.e., com a aquisição de apenas dois ou quatro pneus).

Pelo facto da DigiuiPneus se encontrar localizada próximo de duas outras bombas de combustíveis, uma da marca Repsol (a 350m) e outra da marca GUI (a 2,1km), a sua política de preços de combustíveis passa por não adotar dias de promoção, tal como a bomba marca GUI, mas de apresentar sempre o preço igual ao praticado nos dias de promoção nas bombas marca Repsol. Por norma, os preços são atualizados todas as terças-feiras, em todos os postos de abastecimento.

A empresa dispõe ainda da sua própria frota de camiões-cisterna, responsável não só pelo abastecimento de combustíveis a clientes (de gasóleo simples, gasóleo agrícola e gasóleo para aquecimento), como também pelo autoabastecimento do posto de combustível, pelo que não se encontra dependente de terceiros para efetuar compras destes artigos. É de referir que não existem custos de encomenda destes produtos e que os custos de transporte são otimizados uma vez que é a própria DigiuiPneus que efetua o carregamento e transporte do combustível que adquire.

Assim, uma vez que os preços de combustíveis são mais voláteis e oscilam quase semanalmente, tanto os de compra a fornecedores como os de venda ao público, a empresa dá uma atenção superior a estas variações, em especial quando o seu inventário se encontra mais reduzido e já existe espaço para uma nova encomenda.

Atualmente, a decisão acerca do momento e da quantidade de combustível a encomendar é variável e não segue nenhum padrão. Tal é justificado pelo facto da empresa se autoabastecer, o que lhe permite tirar proveito das já mencionadas descidas ou subidas de preços conhecidas, e, conseqüentemente, adiantar ou atrasar compras, e também pelos transportes que realiza por conta de outrem, o que lhe possibilita utilizar a capacidade total dos camiões-cisterna ao realizar compras próprias.

No que respeita a acordos com fornecedores, estes não se verificam no comércio de combustíveis. Já relativamente ao artigo pneus, a DigiuiPneus dispõe de um acordo com a Bridgestone Portugal que lhe proporciona um desconto fixo face aos preços tabelados e ainda descontos de quantidade. Neste momento, os descontos de quantidade apenas se têm verificado nas medidas de pneus ligeiros mais vendidas pela empresa, nomeadamente

as medidas 205/55R16, 195/65R15 e 225/45R17, das quais se adquirem 100 pneus Bridgestone, 50 pneus Firestone e 20 pneus Bridgestone por encomenda, respetivamente.

Com o propósito de melhorar o sistema de planeamento de inventário em vigor na empresa e de minimizar os custos de inventário, quer de pneus quer de combustíveis, foi realizado o trabalho prático descrito no capítulo 4.

5. Estudo de Caso

Neste capítulo são expostos os dados disponíveis para a execução do trabalho prático e explicada a metodologia aplicada, tanto para os pneus como para os combustíveis, com o objetivo de melhorar os níveis de inventário detidos, pela empresa, de cada artigo, através da previsão do seu volume de vendas.

5.1. Pneus

5.1.1. Seleção das Medidas a Analisar

Os dados analisados para a escolha das medidas de pneus a estudar abarcam o período de maio de 2011 (início de venda de pneus pela empresa) a outubro de 2020.

A pesquisa começou por averiguar todas as medidas alguma vez comercializadas pela DiguiPneus relativamente a pneus ligeiros, comerciais, 4x4 e pesados, o que totalizou 225 medidas diferentes. Destas, verificaram-se quais as que existem em inventário atualmente na empresa, o que contabiliza 181 medidas das 225 iniciais. Foram também descartadas as medidas que correspondem a encomendas únicas de clientes específicos.

Depois de agrupar os dados de venda de cada medida por observações mensais (e não por vendas diárias, como se encontravam), obteve-se a Tabela 3 relativamente ao número de observações diferentes de zero existentes em cada medida, face a um total de 114 meses.

Tabela 3 - Número de observações existentes em cada medida de pneus.

Nº observações (x)	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	≥20
Nº de medidas com x observações	8	11	11	10	7	8	2	7	5	9	0	3	3	3	3	5	3	1	0	82

Depois de analisada a Tabela 3, verifica-se que existem 99 medidas com menos de 20 observações, sendo as observações existentes bastante espaçadas no tempo, pelo que estas foram excluídas de análise futura, restando as 82 medidas com mais observações.

De seguida, foi determinada a percentagem de meses que possuíam observações (do total de 114), de entre as 82 medidas restantes, tendo-se obtido a Tabela 4 e decidido

agrupar os dados semestralmente para medidas com menos de 30% dos meses com observações, trimestralmente para medidas com observações em 30% a 50% dos meses e mensalmente para medidas com mais de 50% dos meses com observações.

Tabela 4 - Agrupamento das observações das medidas de pneus.

	% Observações	Nº Medidas
Semestral	<30%	28
Trimestral	30%-50%	23

A vantagem de agrupar os dados prende-se com a diminuição, ou eliminação, do número de observações iguais a zero, alargando o espectro dos métodos de previsão que se podem aplicar aos dados, tal como defendido por Nikolopoulos *et al.* (2011).

5.1.2. Metodologia

A partir da análise visual do cronograma das vendas (ver exemplo da Figura 9), no qual não se detetaram nem sazonalidade, nem tendência claras (embora na Figura 9 se observe uma ligeira tendência de crescimento), aplicaram-se métodos de previsão, tendo-se iniciado pelos mais simples, o AES e o método de Holt.

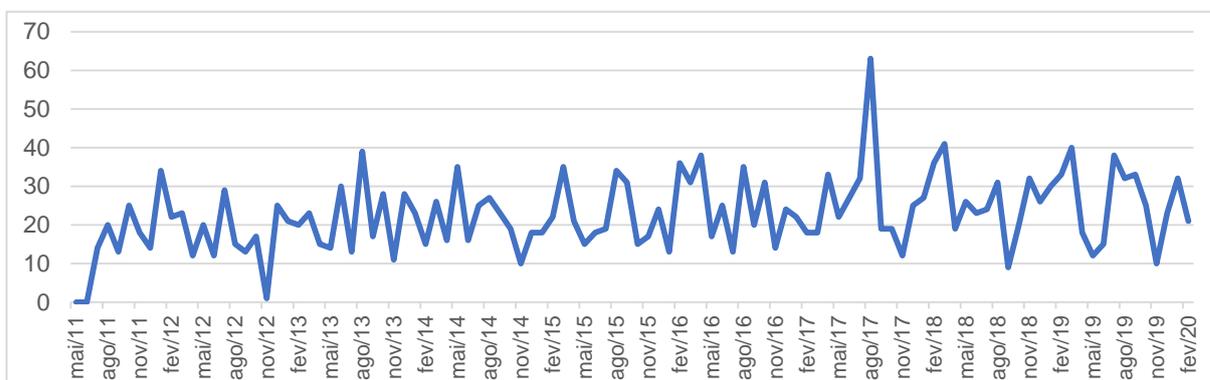


Figura 9 - Cronograma de vendas da medida de pneus ligeiros 205/55R16, entre maio de 2011 e fevereiro de 2020 (Fonte: elaboração própria).

Para o cálculo do AES, de acordo com Brown (1959), foi utilizada a fórmula

$$P_{t+1} = \alpha Y_t + (1 - \alpha)P_t$$

onde Y_t corresponde às vendas reais no momento t , P_t é a previsão obtida para o momento t e α constitui a constante de alisamento e está compreendida entre 0 e 1. O parâmetro inicial P_1 foi definido como igual a Y_1 , de acordo com Caiado (2011).

Uma questão importante prende-se com os parâmetros de otimização do modelo, tendo Silver *et al.* (1998) sugerido que estes se devem encontrar entre 0,1 e 0,3, enquanto Syntetos e Boylan (2005) aconselham 0,05 a 0,2, pelo que foi utilizado o suplemento Solver do Excel para obter o valor da constante de alisamento α que minimiza a REQM.

As fórmulas de aplicação do Método de Holt são, segundo Holt (2004b):

- $\hat{a}_t = \alpha Y_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1})$, onde a corresponde ao nível de tendência estimado e b ao declive da tendência;
- $\hat{b}_t = \beta(\hat{a}_t + \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}$;
- $P_{t+1} = \hat{a}_t + \hat{b}_t \times 1$, onde P corresponde à previsão.

Os parâmetros α e β estão compreendidos entre 0 e 1 e correspondem às constantes de alisamento.

O início do processo de previsão foi obtido através do método das médias, para determinar \hat{a}_1 e \hat{b}_1 , segundo as fórmulas $\hat{b}_1 = \frac{\bar{Y}_2 - \bar{Y}_1}{k}$ e $\hat{a}_1 = \bar{Y}_1 - \hat{b}_1 \frac{k+1}{2}$, onde \bar{Y}_1 corresponde à média das k primeiras observações e \bar{Y}_2 à média das k observações seguintes.

No caso das medidas onde se efetuaram previsões mensais k foi definido como igual a 6 (um semestre), para as previsões trimestrais k foi definiu-se como igual a 4 (um ano) e para as previsões semestrais k foi considerado como igual a 4 (dois anos), de acordo com o defendido por Fildes *et al.* (1998) quanto a utilizar dados históricos da própria série para inicializar os modelos de previsão.

Já o número de observações k a incluir em cada estimativa é subjetivo, como apontado por Caiado (2011), pelo que se procuraram não utilizar demasiadas observações para não tornar os dados dependentes entre si.

No método de Holt foi igualmente utilizado o suplemento Solver do Excel para obter o valor das constantes de alisamento α e β , que minimizam a REQM.

De seguida foi implementado o Método de Croston (Croston (1972)), indicado extensivamente na literatura como o adequado para as situações de procura intermitente. Assim, quando a procura real d registada é superior a zero ($d_t > 0$):

- $a_{t+1} = \alpha d_t + (1 - \alpha)a_t$, onde a corresponde ao nível de procura estimado e α está compreendido entre 0 e 1 e é a constante de alisamento;
- $p_{t+1} = \alpha q + (1 - \alpha)p$, onde p corresponde ao tempo entre a ocorrência de duas procuras (periodicidade) e q ao número de períodos sucedidos desde a última ocorrência de procura. Assim, p é apenas atualizado nos períodos em que ocorre procura.

Caso a procura verificada seja zero ($d_t = 0$), então $a_{t+1} = a_t$ e $p_{t+1} = p_t$. O cálculo da previsão, em ambas as situações, é dado por $f_{t+1} = \frac{a_t}{p_t}$.

Relativamente aos parâmetros de inicialização, a_1 corresponde à primeira ocorrência de procura d e p_1 é igual a $d + 1$.

Foi utilizado também o suplemento Solver do Excel para obter o valor da constante de alisamento α , que minimiza a REQM.

Uma vez que vários autores detetaram enviesamento nas previsões resultantes do método de Croston, a correção designada ASB, criada por Syntetos e Boylan (2001), que multiplica a previsão resultante do método anterior (f_{t+1}) por $1 - \frac{\alpha}{2}$, foi também aplicada.

Posteriormente, procurou-se detetar algum padrão nos dados, tendo-se verificado um aparente aumento nas compras de pneus nos meses que antecedem e em que ocorre precipitação (setembro, outubro, novembro e dezembro) e nos que antecedem as viagens de verão (junho, julho e agosto). Assim, foi desenvolvido um modelo de RLS que apenas atendeu à variável tempo (t) ($\hat{Y}_t = \beta_0 + \beta_1 t$), e depois um outro de RLM que considerou diversas variáveis *dummy* ($\hat{Y}_t = \beta_0 + \beta_1 t + \beta_2 c + \beta_3 v$), umas que atendem às compras nos meses de chuva (c , onde 1 identifica os meses de setembro e outubro, outubro e novembro ou novembro e dezembro e 0 os restantes meses) e outras que atendem às compras antes das viagens de verão (v , onde 1 identifica junho e julho ou julho e agosto e 0 os restantes meses), seguindo Waters (2003).

Os modelos de regressão foram calculados através do *software SPSS statistics versão 27*. Conclui-se que adicionar as variáveis *dummy* ao modelo aumenta o valor de R^2 , isto é, a percentagem de variabilidade das vendas explicada pelo conjunto das variáveis independentes, contudo os meses considerados relevantes diferem entre medidas.

Quando se executa o modelo de RL, para todas as medidas, apenas com as variáveis *dummy* com melhor resultado no passo anterior, e sem atender à variável tempo (t), verifica-se que nas medidas que não apresentam qualquer tendência (a grande maioria), o valor de R^2 e da REQM é muito similar ao obtido anteriormente.

Uma vez determinados os modelos, procedeu-se à validação dos seus pressupostos, nomeadamente a homocedasticidade, isto é, se os erros apresentam variância constante ($\sigma_{\varepsilon_i}^2 = \sigma^2$), a normalidade ($\varepsilon_i \sim N(0, \sigma^2)$) e a independência dos mesmos ($\delta_i \sim N(0, \sigma^2)$).

No mesmo sentido, foi realizada a análise estatística global do modelo e da significância estatística individual das variáveis independentes (t , v e c).

Tendo-se verificado que na grande maioria das medidas o modelo obtido não cumpria pelo menos um dos pressupostos, ou, mesmo cumprindo, o próprio modelo não era globalmente válido ou nenhuma variável independente era estatisticamente significativa, foram implementados MLG.

Para o caso dos pneus, e uma vez que a procura é de natureza discreta, inteira e não negativa, as distribuições que se adequam são a de Poisson e a binomial negativa. A primeira pode ser interpretada como o número de ocorrências de um evento de interesse num período fixo de tempo, enquanto a última pode ser lida como o número de tentativas necessárias para observar k sucessos. Com as distribuições referidas, a função *link*

geralmente utilizada é a logarítmica $f(\mu) = \log(\mu)$ (IBM, 2021; lærd statistics, 2018; Turkman e Silva, 2000).

Desta forma, obtém-se um modelo log-linear, que apenas permite valores positivos, com a formulação $\log(\mu) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$, de onde decorre que o aumento de uma unidade no valor da variável explicativa x_i , mantendo as restantes variáveis constantes, multiplica o valor esperado de y por \exp^{β_i} .

É de salientar que, para que o modelo seja considerado válido com a distribuição de Poisson, devem ser cumpridos os seguintes pressupostos: a variável dependente consistir em dados inteiros e positivos, existirem uma ou mais variáveis independentes, as observações serem independentes, a distribuição das observações seguir uma distribuição de Poisson e a média e variância do modelo serem idênticas (lærd statistics, 2018).

Para a comparação da precisão e da eficiência dos modelos de previsão aplicados, foram determinadas diversas medidas de avaliação, de acordo com a conclusão de Wallström e Segerstedt (2010) de que uma única medida de erro não revela as diferentes extensões dos erros. A primeira, já mencionada, foi a REQM, que mede o afastamento das previsões (erro) face ao valor real, defendida como adequada por Bretschneider (1986).

Calculou-se ainda o nível de inventário final médio, a percentagem de roturas (que se considera que ocorre sempre que o inventário final do período é igual ou inferior a zero, pois pretende-se que exista sempre um nível de inventário positivo) e o número de períodos em inventário (PEI).

As fórmulas aplicadas foram:

- $REQM = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$
- $Inventário\ final_t = Inventário\ final_{t-1} + \hat{Y}_t - Y_t$
- $Percentagem\ de\ inventário\ em\ rotura = \frac{n^\circ\ de\ previsões\ com\ valor\ \leq 0}{n^\circ\ total\ de\ previsões} \times 100$
- $PEI_t = PEI_{t-1} + \sum_{t=1}^n (\hat{Y}_t - Y_t)$

Por fim, conjugaram-se as previsões dos dois métodos de previsão com menor REQM, através de média simples, de acordo com Makridakis e Winkler (1983), e, seguindo Aiolfi e Timmermann (2006) e Caiado (2011), foi realizada uma combinação ponderada dos dois métodos de previsão com menor REQM para cada medida, de acordo com a fórmula:

$$Previsão\ ponderada_t = \frac{REQM_2}{REQM_1 + REQM_2} Previsão_1 + \frac{REQM_1}{REQM_1 + REQM_2} Previsão_2.$$

De seguida são apresentados os principais resultados obtidos.

5.1.3. Resultados

Nesta secção apresentam-se os resultados obtidos para o artigo pneus, divididos nos diferentes níveis de agregação. Todos os valores expostos encontram-se nas Tabelas 42 a 47 presentes nos Anexos II e III.

Numa primeira fase são revelados os valores determinados para uma medida concreta de pneus (a medida com maior número de unidades vendidas), e de seguida é efetuada uma análise global das restantes medidas.

5.1.3.1. Vendas Agrupadas por Mês

Quanto aos pneus com vendas agrupadas mensalmente, o número de observações encontra-se entre 93 e 106, enquanto a percentagem de procura diferente de zero varia de 57,303% a 100%.

5.1.3.1.1. O Caso da Medida 205/55R16

A medida de pneus 205/55R16 é a mais vendida em termos de pneus para veículos ligeiros, com um total de 2391 unidades vendidas, apresentado vendas em todos os meses.

Na Tabela 5 são exibidos os resultados obtidos com cada um dos métodos aplicados e em relação a cada medida de avaliação, para esta medida de pneus. Apresentam-se ainda os valores das combinações dos dois métodos com menor valor de REQM.

Tabela 5 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para a medida 205/55R16.

	AES	Holt	RLM	Croston	ASB	Previsão Combinada	
						Média simples	Média ponderada
REQM	9,140	9,145	8,130	10,780	11,221	8,453	8,423
Inventário Médio	8,981	52,087	19,788	17,699	4,786	10,961	11,049
Percentagem de Rotura	25,243%	5,825%	5,769%	23,301%	51,456%	19,417%	19,417%
PEI Médio	-4161	1329	-244	-8225	-13348	-2202	-56

Para a medida em questão, verifica-se que o método com menor valor de REQM é a RLM, seguida do AES e do método de Holt. Neste caso, o modelo de RLM é válido,

$$\hat{Y} = 18,246 + 0,089t - 4,929c + 5,283v$$

com todas as variáveis independentes (tempo (t), meses de outubro e novembro (c) e meses de julho e agosto (v)) a serem estatisticamente significativas (para $\alpha = 0,05$).

Os pressupostos associados à RLM são considerados todos válidos, pois os resíduos são homocedásticos, independentes (estatística de Durbin-Watson de 2,240) e seguem uma distribuição normal (valor-p do teste de Kolmogorov-Smirnov de 0,200).

As figuras 10 a 15 permitem visualizar o ajuste dos modelos determinados às observações reais, observando-se algumas diferenças entre estes, que conseqüentemente

se traduzem em diferentes valores nas medidas de avaliação, como exibido na Tabela 5. Efetivamente, as previsões obtidas pelos métodos de Croston e ASB encontram-se bastante desalinhadas com os valores reais, sendo esse desalinhamento mais acentuado no início do período de análise.

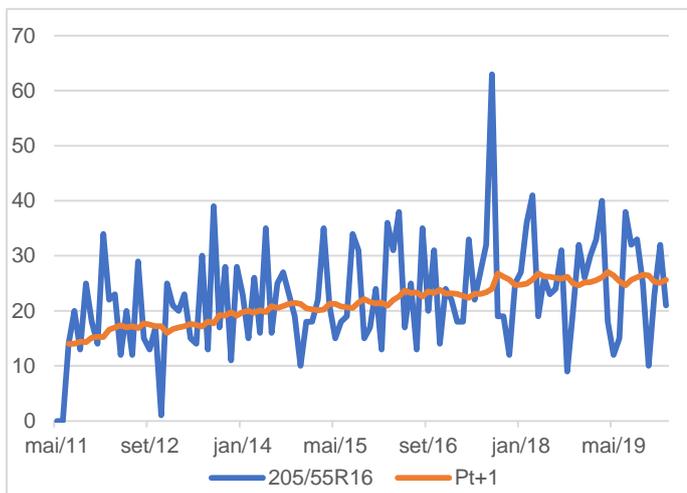


Figura 10 - Modelo de AES para a medida 205/55R16 (Fonte: elaboração própria).

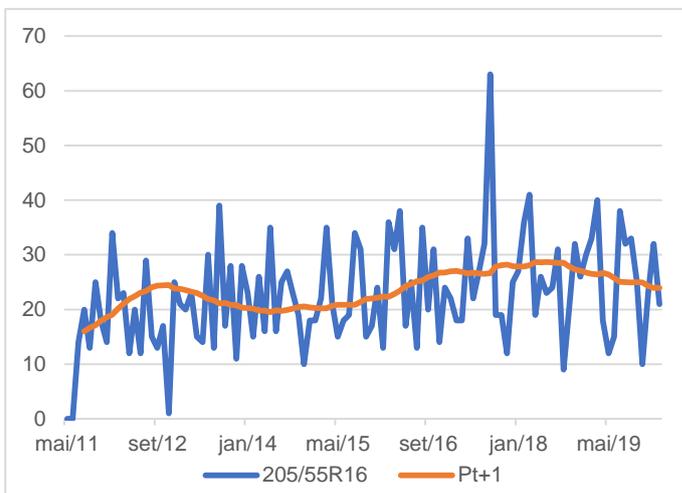


Figura 11 - Modelo de Holt para a medida 205/55R16 (Fonte: elaboração própria).

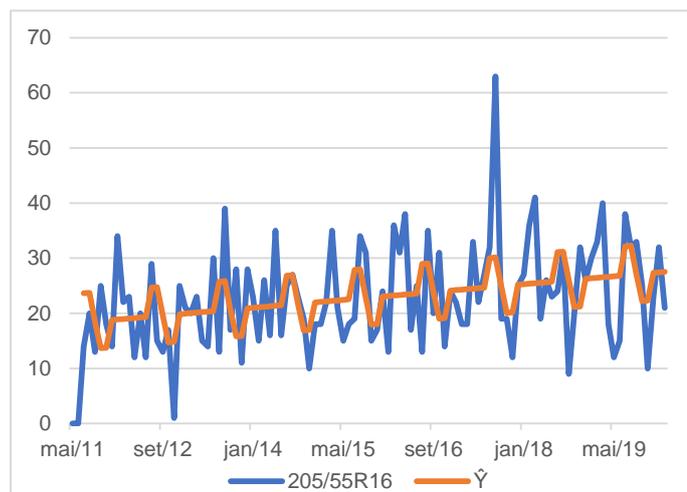


Figura 12 - Modelo de RLM para a medida 205/55R16 (Fonte: elaboração própria).

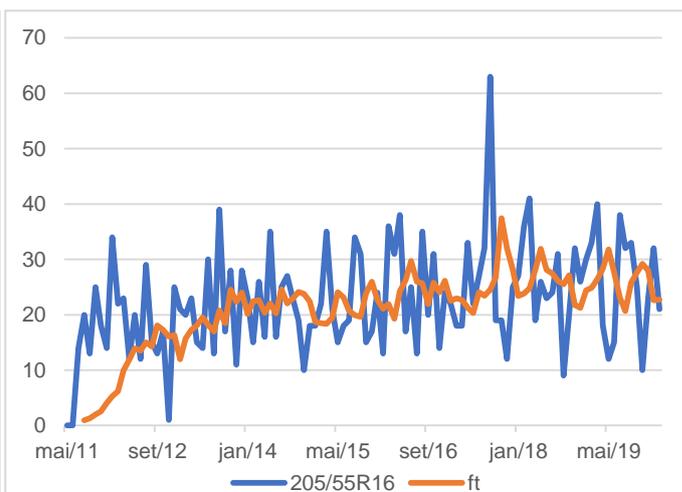


Figura 13 - Modelo de Croston para a medida 205/55R16 (Fonte: elaboração própria).

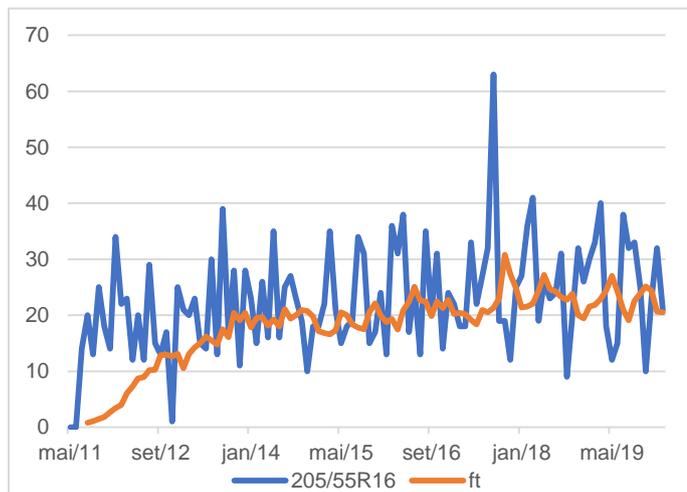


Figura 14 - Modelo de ASB para a medida 205/55R16 (Fonte: elaboração própria).

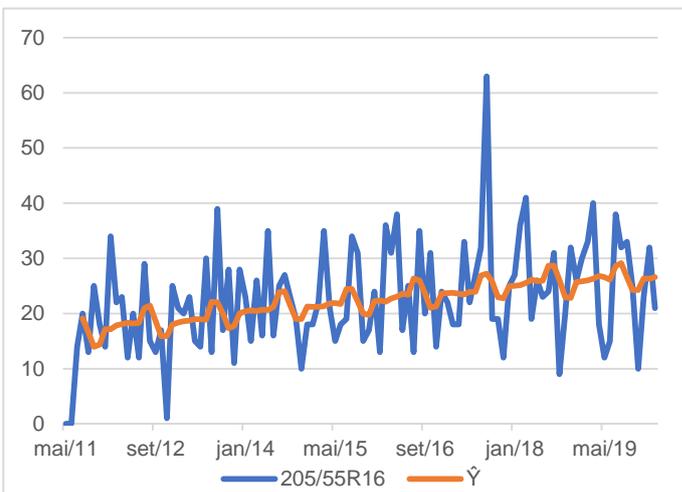


Figura 15 - Modelo ponderado para a medida 205/55R16 (Fonte: elaboração própria).

Relativamente às restantes medidas de avaliação, o menor valor de inventário médio é obtido com a ASB, contudo este método apresenta a maior percentagem de roturas, conforme se observa na Tabela 5. Já a RLM exhibe a menor percentagem de roturas. O menor valor de PEI é alcançado também com a RLM.

Assim, com base na Tabela 5, o modelo com ajuste indicado para a medida 205/55R16 resulta da combinação ponderada dos dois métodos com menor valor de REQM, o AES e a RLM, de acordo com o indicado por Petropoulos *et al.* (2014). De facto, o modelo ponderado apresenta os segundos menores valores de REQM e de inventário médio, o terceiro menor valor de percentagem de rotura e o menor valor de PEI, considerando-se assim ajustado para efetuar previsões.

O mesmo também se verifica através da análise da Tabela 6, onde se observa que o AES e a RLM continuam a ser os métodos com menor valor de REQM quando se efetuam previsões. Mais, a mesma tabela permite constatar que o período ótimo de revisão dos dados é o mensal, o que é esperado uma vez que as vendas deste artigo são elevadas e mostram alguma variabilidade, exigindo uma revisão constante dos dados.

Tabela 6 - Valores de REQM obtidos para o horizonte de previsão de março de 2020 a fevereiro de 2021, para a medida de pneus 205/55R16, sem realizar revisão do modelo previamente obtido e com atualização do modelo a cada 1, 2, 4 e 6 meses com as observações reais.

	AES	Holt	RLM	Croston	ASB
Modelo Determinado	9,140	9,145	8,130	10,780	11,221
Sem revisão	14,045	15,910		13,952	15,523
Revisão	Mensal	13,619	14,517	12,382	15,104
	2 Meses	13,907	14,753		16,120
	4 Meses	13,910	15,310		16,546
	6 Meses	13,596	14,837		13,435

Face a tudo o mencionado, a política de inventário adequada para a medida de pneus 205/55R16 é a política (R,s,S), onde o período de revisão (R) deve ser o mensal, a quantidade a encomendar (S) terá como objetivo satisfazer a procura prevista, que ronda as 27 unidades (S médio), como se observa na Tabela 7, devendo ter em consideração o inventário final do mês anterior e o inventário de segurança (s). Este último deve ser estabelecido em duas unidades, de forma a satisfazer procura imprevista, tal é a variabilidade verificada nas vendas, garantindo que é possível satisfazer as necessidades de um cliente (por norma, são montados sempre dois pneus de cada vez).

Tabela 7 - Determinação da quantidade a encomendar (S), em cada mês, para a medida 205/55R16.

	Vendas Reais	Previsão		
		AES	RLM	Ponderada
mar/20	15	25	28	26
abr/20	13	25	28	27
mai/20	22	25	28	27
jun/20	42	25	28	27
jul/20	40	25	33	29
ago/20	59	25	33	29
set/20	35	25	28	27
out/20	29	25	23	24
nov/20	43	25	23	24
dez/20	31	25	28	27
jan/21	25	25	28	27
fev/21	22	25	29	27

5.1.3.1.1. Análise Global das Restantes Medidas de Pneus

Os dados resultantes da aplicação dos métodos de previsão permitem concluir que o AES é o método com menor REQM em 48% das medidas, seguido do método de Holt em 26% das medidas, conforme se observa na Tabela 8.

Tabela 8 - Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por mês.

	AES	Holt	RLM / MLG	Croston	ASB
Menor REQM	15 (48%)	8 (26%)	2 (6%)	2 (6%)	4 (13%)
2ª menor REQM	8 (26%)	9 (29%)	0 (0%)	9 (29%)	5 (16%)
Menor Inventário Médio	6 (19%)	7 (23%)	0 (0%)	6 (19%)	12 (39%)
Maior Inventário Médio	7 (23%)	13 (42%)	0 (0%)	11 (35%)	0 (0%)
Menor Percentagem de Rotura	17 (55%)	11 (35%)	1 (3%)	1 (3%)	1 (3%)
Maior Percentagem de Rotura	2 (6%)	4 (13%)	0 (0%)	11 (35%)	14 (45%)

A reduzida presença dos métodos de RLM e de MLG na análise geral dos resultados das vendas agrupadas por mês decorre do facto de, uma vez analisada a validade dos pressupostos dos diferentes modelos e a significância estatística das variáveis independentes (ver tabelas 36 e 37 do Anexo I), se ter concluído que em apenas duas medidas, uma com distribuição normal e outra com distribuição de Poisson, estes modelos são considerados válidos, pelo que para as restantes medidas os mesmos foram abandonados.

Os métodos de Croston e ASB apenas se revelam melhores em seis medidas, que apresentam procura em menos de 70% dos meses, sendo que nas restantes quatro

medidas com a mesma percentagem de procura, os métodos de AES e de Holt apresentam menor REQM.

Relativamente às medidas de avaliação remanescentes, e de acordo com a Tabela 8, em relação ao inventário médio, os métodos ASB e de Holt são os que apresentam menor nível de inventário, em 39% e 23% das medidas, respetivamente. Contudo, o método de Holt e o método de Croston apresentam, com 42% e 35%, respetivamente, o maior inventário. Em contrapartida, a maior percentagem de roturas é verificada nos métodos de Croston e ASB (35% e 45%, respetivamente), sendo o AES o método com valores mais intermédios, tanto de nível de inventário como de percentagem de roturas.

Observando os valores da medida de avaliação PEI conclui-se que, em valor absoluto, os valores menores se encontram com o método de Holt, em 52% das medidas. A maior subestimação do inventário ocorre com os métodos de Croston e ASB, em 97% das medidas, sendo que os métodos AES e de Holt apresentam uma percentagem similar de sub e sobrestimação das previsões, conforme se verifica na Tabela 9.

Tabela 9 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por mês.

	AES	Holt	RLM / MLG	Croston	ASB
Menor PEI (Valor Absoluto)	7 (23%)	16 (52%)	2 (6%)	2 (6%)	4 (13%)
PEI Inferior a 0	14 (45%)	17 (55%)	12 (39%)	30 (97%)	30 (97%)

Quando se conjugam os modelos validados com as duas menores REQM, verifica-se que a combinação do AES e método de Holt é a vencedora em 45% das medidas, seguida dos métodos de Croston e ASB em 16% das medidas, de acordo com a Tabela 10.

Tabela 10 - Cruzamento dos modelos com menor REQM, considerando as medidas de pneus com vendas agrupadas por mês.

	Holt	MLG	RLM	Croston	ASB
AES	14 (45%)	1 (3%)	1 (3%)	3 (10%)	4 (13%)
Holt		0 (0%)	0 (0%)	3 (10%)	0 (0%)
Croston		0 (0%)	0 (0%)		5 (16%)

Depois de obtidas as previsões ponderando os dois métodos com menor REQM, observa-se que o modelo resultante passa a obter os menores valores de REQM, inventário médio, percentagem de rotura e PEI em 97%, 39%, 65% e 100% das medidas, respetivamente.

Uma vez determinadas as previsões para o período de março de 2020 a fevereiro de 2021, foi analisada a precisão dos métodos de previsão aplicados quanto à REQM, exibida na Tabela 11.

Observa-se que não alterando a previsão obtida para março de 2020 durante o ano, o método com menor erro passa a ser o método de Holt, com o AES a ser a segunda melhor opção. Se se efetuar uma revisão das previsões com periodicidade mensal, o método de Holt continua a ser o que apresenta menor EQM, tal como quando a revisão é realizada a cada 2, 4 ou 6 meses. O segundo método com menor REQM em todas as revisões, seja mensal ou a 2, 4 ou 6 meses, permanece o AES.

Tabela 11 – Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo, considerando as medidas de pneus com vendas agrupadas por mês.

Previsão	AES	Holt	RLM / MLG	Croston	ASB
Igual a março de 2020	10 (32%)	13 (42%)	0 (0%)	3 (10%)	5 (16%)
Revisão mensal	6 (19%)	22 (71%)	1 (3%)	0 (0%)	2 (6%)
Revisão a 2 meses	8 (26%)	20 (65%)	0 (0%)	0 (0%)	3 (10%)
Revisão a 4 meses	13 (42%)	14 (45%)	0 (0%)	1 (3%)	3 (10%)
Revisão a 6 meses	10 (32%)	16 (52%)	0 (0%)	3 (10%)	2 (6%)

Quanto ao período de revisão, o menor valor de REQM é obtido quando a revisão dos dados é mensal (em 77% das medidas), seguindo-se a previsão constante e igual a março de 2020 ou a 6 meses (em 10% das medidas) e a revisão a 4 meses (em 3% das medidas).

Assim, para as medidas com vendas agrupadas por mês, conclui-se que se obtém o menor erro combinando as previsões ponderadas resultantes dos métodos AES e Holt, com um período de revisão dos dados mensal.

Na Tabela 12 são apresentados os parâmetros da política de inventário (R,2,S) específicos para três medidas de pneus, podendo-se verificar a variabilidade das unidades de venda previstas para cada mês e entre medidas.

Tabela 12 – Parâmetros da política de inventário (R,2,S) para as medidas de pneus 175/65R14, 195/65R15 e 385/65R22,5.

R - mensal	175/65R14	195/65R15	385/65R22,5
S médio	13	17	15
mar/20	14	17	12
abr/20	13	16	12
mai/20	13	16	13
jun/20	13	16	13
jul/20	13	17	14
ago/20	14	17	14
set/20	14	18	14
out/20	13	18	15
nov/20	13	19	16
dez/20	13	17	16
jan/21	14	17	18
fev/21	13	17	18

5.1.3.2. Vendas Agrupadas por Trimestre

Atendendo às medidas de pneus com vendas agrupadas trimestralmente, o número de observações encontra-se entre 31 e 35, enquanto a percentagem de procura diferente de zero varia de 53,571% a 89,474%.

Os valores resultantes da aplicação dos métodos de previsão permitem concluir que o AES é o método com menor REQM em 30% das medidas, seguido do método de Croston em 26% das medidas, como se observa na Tabela 13.

Tabela 13 - Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por trimestre.

	AES	Holt	RLM / MLG	Croston	ASB
Menor REQM	7 (30%)	5 (22%)	1 (4%)	6 (26%)	4 (17%)
2ª menor REQM	4 (17%)	8 (35%)	0 (0%)	5 (22%)	6 (26%)
Menor Inventário Médio	5 (22%)	5 (22%)	0 (0%)	3 (13%)	10 (43%)
Maior Inventário Médio	11 (48%)	3 (13%)	1 (4%)	8 (35%)	0 (0%)
Menor Percentagem de Rotura	15 (65%)	7 (30%)	1 (4%)	8 (35%)	0 (0%)
Maior Percentagem de Rotura	3 (13%)	2 (9%)	0 (0%)	9 (39%)	9 (39%)

Uma vez analisados os pressupostos e a validade dos modelos de RLM e MLG, com as distribuições normal, de Poisson e binominal negativa, presentes nas Tabelas 38 e 39 do Anexo I, verificou-se que em apenas uma medida, com distribuição de Poisson, o MLG é considerado válido, pelo que nas restantes medidas estes modelos foram abandonados.

Os métodos de Croston e ASB apresentaram a menor REQM em 10 das 23 medidas analisadas, com percentagens da procura a variar entre 68% e 89,474%.

Em relação ao inventário médio, de acordo com a Tabela 13, a ASB apresenta menor nível de inventário em 43% das medidas, contrariamente ao AES e ao método de Croston, com 48% e 35%, respetivamente, do maior inventário. A maior percentagem de roturas é verificada nos métodos de Croston e ASB (em 39% das medidas).

Observando os valores da medida de avaliação PEI, conforme a Tabela 14, conclui-se que, em valor absoluto, os menores valores se obtêm com o método de Holt, em 65% das medidas. Já a maior subestimação do inventário ocorre com os métodos de Croston e ASB, em 96% e 100% das medidas, respetivamente, sendo que os métodos AES e RLM / MLG apresentam uma percentagem similar de sub e sobrestimação da previsão.

Tabela 14 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por trimestre.

	AES	Holt	RLM / MLG	Croston	ASB
Menor PEI (Valor Absoluto)	2 (9%)	15 (65%)	1 (4%)	5 (22%)	0 (0%)
PEI Inferior a 0	10 (43%)	19 (83%)	11 (48%)	22 (96%)	23 (100%)

Quando se conjugam os modelos validados com as duas menores REQM, verifica-se que a combinação do AES e método de Holt é a escolhida em 43% das medidas, seguida dos métodos de Croston e ASB em 39% das medidas (ver Tabela 15).

Tabela 15 - Cruzamento dos modelos com menor REQM, considerando as medidas de pneus com vendas agrupadas por trimestre.

	Holt	MLG	RLM	Croston	ASB
AES	10 (43%)	0 (0%)	0 (0%)	0 (0%)	1 (4%)
Holt		1 (4%)	0 (0%)	2 (9%)	0 (0%)
Croston		0 (0%)	0 (0%)		9 (39%)

Posteriormente à obtenção das previsões ponderando os dois métodos com menor REQM, observa-se que o modelo resultante passa a obter os menores valores de REQM, inventário médio, percentagem de rotura e PEI em 96%, 35%, 52% e 100% das medidas, respetivamente.

Uma vez determinadas as previsões desde o 2º trimestre de 2020 até ao 1º trimestre de 2021, foi analisada a precisão dos métodos de previsão aplicados quanto à REQM, como demonstrado na Tabela 16.

Observa-se que mantendo a previsão para o 2º trimestre de 2020 constante durante o período, o método com menor EQM continua a ser o AES, em 35% das medidas, seguido do método de Croston em 30%. Se se efetuar uma revisão das previsões com periodicidade trimestral, o AES permanece o método com menor erro e o segundo lugar é dividido pelos métodos de Croston e ASB. Contudo, quando a revisão é realizada a cada 2 trimestres, em 30% das medidas o AES obtém a menor REQM, tal como a ASB.

Tabela 16 - Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo, considerando as medidas de pneus com vendas agrupadas por trimestre.

Previsão	AES	Holt	RLM / MLG	Croston	ASB
Igual ao 2º Trimestre de 2020	8 (35%)	5 (22%)	0 (0%)	7 (30%)	3 (13%)
Revisão Trimestral	8 (35%)	3 (13%)	0 (0%)	6 (26%)	6 (26%)
Revisão a 2 Trimestres	7 (30%)	4 (17%)	0 (0%)	5 (22%)	7 (30%)

Quanto ao período de revisão, o menor valor de REQM é obtido quando não se efetua a revisão dos dados (em 48% das medidas), seguindo-se a revisão a cada dois trimestres (em 30% das medidas) e, por fim, a revisão trimestral (em 22% das medidas).

Conclui-se que para os dados agrupados por trimestre, é a combinação ponderada dos métodos de previsão AES e método de Croston que aparenta ser a mais adequada, mantendo-se a previsão constante para um ano.

Na Tabela 17 estão expostos os parâmetros da política de inventário (R,2,S) específicos para três medidas de pneus.

Tabela 17 - Parâmetros da política de inventário (R,2,S) para as medidas de pneus 205/65R15, 225/50R17 e 700R16.

R – um ano		205/65R15	225/50R17	700R16
S médio		2	6	2
	Abr/20	2	6	2
Previsão	jul/20	2	6	2
Ponderada	out/20	2	6	2
	jan/21	2	6	2

5.1.3.3. Vendas Agrupadas por Semestre

Para os pneus com vendas agrupadas semestralmente, o número de observações encontra-se entre 11 e 19, enquanto a percentagem de procura diferente de zero varia de 57,143% a 100%.

Os resultados da aplicação dos métodos de previsão permitem concluir que o método de Holt é o que apresenta menor REQM em 46% das medidas, seguido do AES em 29% das medidas, de acordo com o exibido na Tabela 18.

Nas tabelas 40 e 41 do Anexo I encontra-se a análise geral dos resultados das vendas agrupadas por semestre quanto aos métodos de RLM e MLG. Observou-se que em apenas três medidas, uma com distribuição normal e duas com distribuição de Poisson, os modelos são considerados válidos, pelo que foram abandonados para as restantes medidas.

Tabela 18 - Resumo das medidas de avaliação aplicadas a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por semestre.

	AES	Holt	RLM / MLG	Croston	ASB
Menor REQM	8 (29%)	13 (46%)	3 (11%)	3 (11%)	1 (4%)
2ª menor REQM	11 (39%)	4 (14%)	0 (0%)	7 (25%)	6 (21%)
Menor Inventário Médio	3 (11%)	1 (4%)	0 (0%)	4 (14%)	20 (71%)
Maior Inventário Médio	11 (39%)	13 (46%)	0 (0%)	4 (14%)	0 (0%)
Menor Percentagem de Rotura	14 (50%)	10 (36%)	2 (7%)	2 (7%)	0 (0%)
Maior Percentagem de Rotura	4 (14%)	2 (7%)	0 (0%)	3 (11%)	19 (68%)

Os métodos de Croston e ASB apresentaram a menor REQM em 4 das 28 medidas analisadas, com percentagens da procura a variar entre 89,474% e 70,833%. No que se refere ao inventário médio, a ASB também apresenta menor nível de inventário em 71% das medidas, contrariamente ao AES e ao método de Holt, com 39% e 46%, respetivamente, do maior inventário. Contudo, maior percentagem de roturas é verificada com a ASB (em 68% das medidas), como se observa na Tabela 18.

Analisando os valores da medida de avaliação PEI, conclui-se que, em valor absoluto, os menores valores se alcançam com o método de Holt, em 79% das medidas, seguido do AES e RLM / MLG, em 11% das medidas. A maior subestimação do inventário, em concordância com a Tabela 19, ocorre com os métodos de Croston e AES, em 96% e 64%

das medidas, respetivamente, sendo que o método de Holt apresenta uma percentagem similar de sub e sobrestimação das previsões.

Tabela 19 - Resumo da medida de avaliação PEI aplicada a cada método de previsão, considerando as medidas de pneus com vendas agrupadas por semestre.

	AES	Holt	RLM / MLG	Croston	ASB
Menor PEI (Valor Absoluto)	3 (11%)	22 (79%)	3 (11%)	0 (0%)	0 (0%)
PEI Inferior a 0	18 (64%)	16 (57%)	6 (21%)	27 (96%)	23 (82%)

Quando se conjugam os modelos de previsão com as duas menores REQM, verifica-se que a combinação do AES e método de Holt é a preferida em 46% das medidas, seguida da AES e método de Croston em 14% das medidas, tal como observado na Tabela 20.

Tabela 20 - Cruzamento dos modelos com menor REQM, considerando as medidas de pneus com vendas agrupadas por semestre.

	Holt	MLG	RLM	Croston	ASB
AES	13 (46%)	0 (0%)	0 (0%)	4 (14%)	2 (7%)
Holt		1 (4%)	0 (0%)	1 (4%)	2 (7%)
Croston		1 (4%)	1 (4%)		3 (11%)

Determinando as previsões ponderadas com os dois métodos com menor REQM, observa-se que o modelo resultante passa a obter os menores valores de REQM, inventário médio, percentagem de rotura e PEI em 96%, 25%, 21% e 100% das medidas, respetivamente.

Depois de obtidas as previsões desde o 2º semestre de 2020 ao 1º semestre de 2021, foi avaliada a precisão dos métodos de previsão aplicados quanto à REQM. Os resultados encontram-se na Tabela 21.

Observa-se que mantendo a previsão para o 2º semestre de 2020 constante durante o ano, o método com menor erro passa a ser o AES, em 36% das medidas, seguido do método de Holt em 29%. Se se efetuar uma revisão das previsões com periodicidade semestral, o AES continua a ser o método com menor erro (em 36% das medidas), com o método de Holt a ocupar o segundo lugar (menor erro em 32% das medidas).

Tabela 21 - Avaliação do valor de REQM obtido para cada modelo de previsão de acordo com diferentes períodos de revisão do mesmo, considerando as medidas de pneus com vendas agrupadas por semestre.

Previsão	AES	Holt	RLM / MLG	Croston	ASB
Igual ao 2º Semestre de 2020	10 (36%)	8 (29%)	0 (0%)	4 (14%)	6 (21%)
Revisão Semestral	10 (36%)	9 (32%)	0 (0%)	4 (14%)	5 (18%)

Quanto ao período de revisão, deve-se atentar a que existem apenas duas previsões em análise. Assim, o menor valor de REQM é obtido quando não se realiza a revisão dos dados, face à revisão semestral (em 54% e 46% das medidas, respetivamente).

Determina-se então que, em relação às medidas com vendas agrupados por semestre, o menor erro é alcançado combinando as previsões ponderadas resultantes dos métodos AES e Holt. Já manter a previsão constante para um ano ou revê-la a cada semestre origina um valor de erro semelhante.

Na Tabela 22 são apresentados os parâmetros da política de inventário (R,2,S) específicos para três medidas de pneus.

Tabela 22 - Parâmetros da política de inventário (R,2,S) para as medidas de pneus 185/70R14, 215/55R17, 285/70R19,5.

R - semestral		185/70R14	215/55R17	285/70R19,5
S médio		7	7	4
Previsão	abr/20	7	7	4
Ponderada	jul/20	7	7	4

5.1.4. Discussão de Resultados

Depois de aplicados os cinco métodos de previsão em estudo a cada uma das 82 medidas de pneus, verificam-se algumas diferenças de acordo com o nível de agregação das vendas.

Em concreto, observa-se que para as medidas com vendas agrupadas por mês, o método considerado mais adequado aquando da determinação do modelo era o AES (menor REQM em 48% das medidas), tendo sido superado pelo método de Holt na determinação das previsões, o que está de acordo com as conclusões de Aiolfi e Timmermann (2006) acerca de ser irrealista que um único modelo seja predominante ao longo do tempo.

Da mesma forma, verifica-se que enquanto o segundo método com menor REQM nos modelos determinados para as medidas com vendas agrupadas por trimestre era o método de Holt, uma vez calculadas as previsões, este foi ultrapassado pelo método de Croston.

Conclui-se ainda que os períodos de revisão (R) são díspares e que as quantidades a encomendar (S) são bastante variadas entre medidas e, em múltiplas situações, entre meses/ trimestres/ semestres para a mesma medida. Desta forma, é evidente a necessidade de avaliação constante dos modelos e da análise das medidas de erro de forma a detetar enviesamentos o mais cedo possível e proceder aos devidos ajustes.

5.2. Combustíveis

Os dados de vendas e de compras de combustíveis foram analisados para os artigos gasóleo simples, gasóleo aditivado, gasolina 95, gasolina 98, gasóleo agrícola e gasóleo para aquecimento, desde o início da sua venda até ao final de fevereiro de 2020.

5.2.1. Apresentação dos Dados

As vendas de combustíveis iniciaram em outubro de 2015, com exceção da venda de gásóleo aditivado que teve início em setembro de 2019. A análise da Tabela 23 permite observar que os combustíveis com mais dias com vendas são o gásóleo simples e o aditivado (em 97% e 87% dos dias, respetivamente), contrastando com a gasolina 98 que apresenta vendas em apenas 32% dos dias.

Relativamente à quantidade vendida, verifica-se que o combustível mais procurado é o gásóleo simples (4.508.433 litros), seguido do gásóleo para aquecimento (3.148.635 litros) e do gásóleo agrícola (1.707.938 litros).

Observa-se ainda que, embora a sua venda tenha iniciado cerca de quatro anos mais tarde, a quantidade de gásóleo aditivado vendida é elevada e já se aproxima da quantidade vendida de gasolina 98.

Com respeito às compras, tiveram início concordante com as vendas, tendo ocorrido mais vezes para os combustíveis gásóleo simples, gásóleo agrícola e gásóleo para aquecimento (em 83%, 74% e 50% das semanas, respetivamente).

Tabela 23 - Valores de vendas e de compras, em número e em litros, para os combustíveis gásóleo simples, gásóleo aditivado, gasolina 95, gasolina 98, gásóleo agrícola e gásóleo para aquecimento.

	Gasóleo simples	Gasóleo aditivado	Gasolina 95	Gasolina 98	Gasóleo agrícola	Gasóleo p/ aquecimento	
Vendas	Início	08/10/2015	21/09/2019	20/10/2015	21/10/2015	07/10/2015	08/10/2015
	Nº de dias	1340 (97%)	122 (87%)	907 (66%)	443 (32%)	1081 (78%)	1092 (79%)
	Nº de semanas	230 (100%)	24 (100%)	228 (100%)	209 (92%)	230 (100%)	230 (100%)
	Nº de meses	53 (100%)	6 (100%)	53 (100%)	53 (100%)	53 (100%)	53 (100%)
	Totais (lit)	4508433	16190	83276	23902	1707392	3148635
	Máximo (lit)	19336	1157	1375	687	10800	16423
	Mínimo (lit)	23	15	2	1	14	7
Compras	Início	07/10/2015	19/09/2019	20/10/2015	20/10/2015	07/10/2015	08/10/2015
	Nº de dias	339 (25%)	4 (3%)	31 (2%)	12 (1%)	221 (16%)	138 (10%)
	Nº de semanas	191 (83%)	4 (17%)	31 (14%)	12 (5%)	171 (74%)	116 (50%)
	Nº de meses	53 (100%)	4 (67%)	29 (55%)	12 (23%)	53 (100%)	52 (98%)
	Nº de trimestres	18 (100%)	3 (100%)	18 (100%)	10 (56%)	18 (100%)	18 (100%)
	Totais (lit)	4512400	22187	85628	25092	1716562	3175437
	Mínimo (lit)	1950	3601	1503	995	742	4000

A quantidade comprada varia consideravelmente para todos os combustíveis, contudo encontra-se de acordo com a quantidade vendida, pois verifica-se que as compras ocorrem em quantidade superior.

A capacidade dos tanques para armazenamento de combustíveis da empresa distribui-se em 30.000 litros para gásóleo simples, 15.000 litros para gásóleo aditivado, gasolina 95

e gasolina 98, 20.000 litros para gásóleo agrícola e 100.000 litros para gásóleo para aquecimento, encontrando-se em concordância com a quantidade vendida de cada um dos combustíveis. É de referir que, diversas vezes, nem todo o combustível comprado é descarregado para os tanques, pois é entregue diretamente ao cliente final.

Em relação aos combustíveis gásóleo aditivado e gasolinas 95 e 98, nunca se verificou uma situação de rutura, com 75%, 100% e 92% das compras, respetivamente, a ocorrerem quando o nível de inventário era inferior a 2.000 litros.

Já o gásóleo simples encontrou-se numa situação de inventário próximo de zero em duas ocasiões, o gásóleo agrícola em 46 e o gásóleo para aquecimento em nove. As compras de gásóleo simples ocorreram 23% das vezes quando o nível de inventário era inferior a 10.000 litros, as de gásóleo agrícola aconteceram 76% das vezes com inventário inferior a 5.000 litros, e as de gásóleo para aquecimento sucederam 20% das vezes com um nível de inventário inferior a 10.000 litros.

Uma análise visual dos cronogramas (ver exemplos do gásóleo simples, Figuras 16 a 18) não permite detetar de forma evidente a existência de sazonalidade nas vendas, com exceção do gásóleo para aquecimento (Figura 33 do Anexo IV), onde é possível detetar alguma sazonalidade, identificando-se uma clara redução dos litros vendidos nos meses tradicionalmente de maior calor, nomeadamente entre abril e setembro.

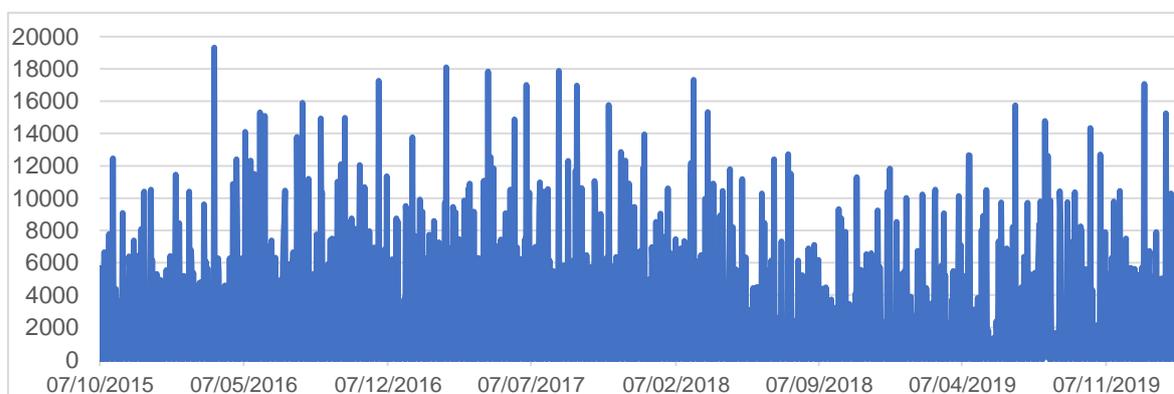


Figura 16 - Vendas diárias de gásóleo simples (Fonte: elaboração própria).

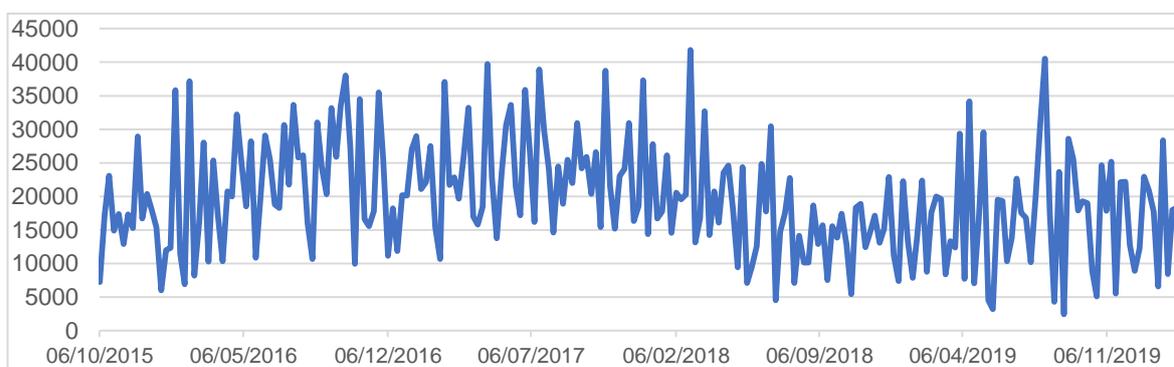


Figura 17 - Vendas semanais de gásóleo simples (Fonte: elaboração própria).

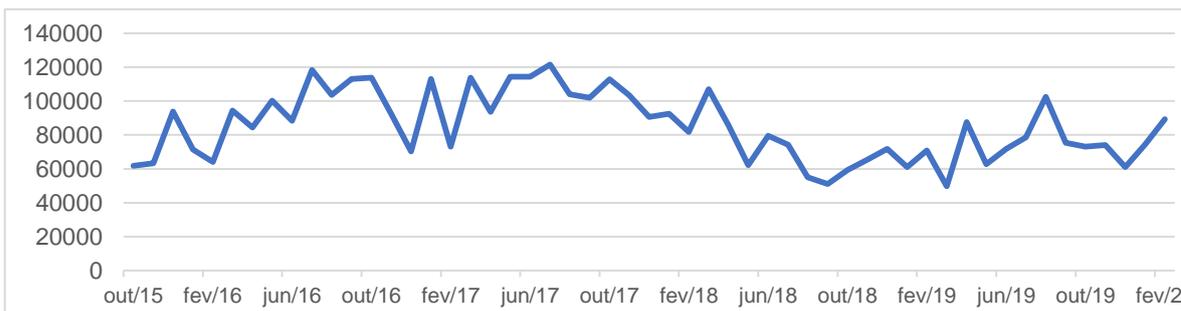


Figura 18 - Vendas mensais de gásóleo simples (Fonte: elaboração própria).

Quando se agrupam as vendas por dia do mês (Figuras 19 e 20), identifica-se que o dia com mais vendas de gásóleo simples é o primeiro (venda média de 5.119 litros), para o gásóleo aditivado e gasolina 98 é o dia 31 (venda média de 440 litros e 45 litros, respetivamente), para a gasolina 95 é o dia 30 (venda média de 171 litros), para o gásóleo agrícola é o dia 3 (venda média de 1.693 litros) e para o gásóleo para aquecimento é o dia 21 (venda média de 2.628 litros).

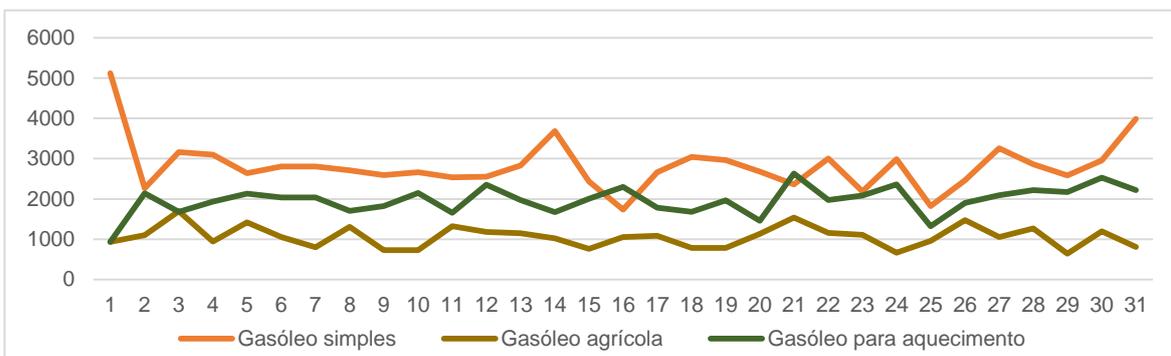


Figura 19 - Vendas médias, agrupadas por dia do mês, para os combustíveis gásóleo simples, gásóleo agrícola e gásóleo para aquecimento (Fonte: elaboração própria).

Já o dia com menor quantidade vendida de gásóleo simples é o dia 16 (venda média de 1.734 litros), para o gásóleo aditivado e gásóleo para aquecimento é o dia 1 (venda média de 15 litros e 934 litros, respetivamente), para a gasolina 95 é o dia 20 (venda média de 22 litros), para a gasolina 98 é o dia 7 (venda média de 3 litros) e para o gásóleo agrícola é o dia 29 (venda média de 641 litros).

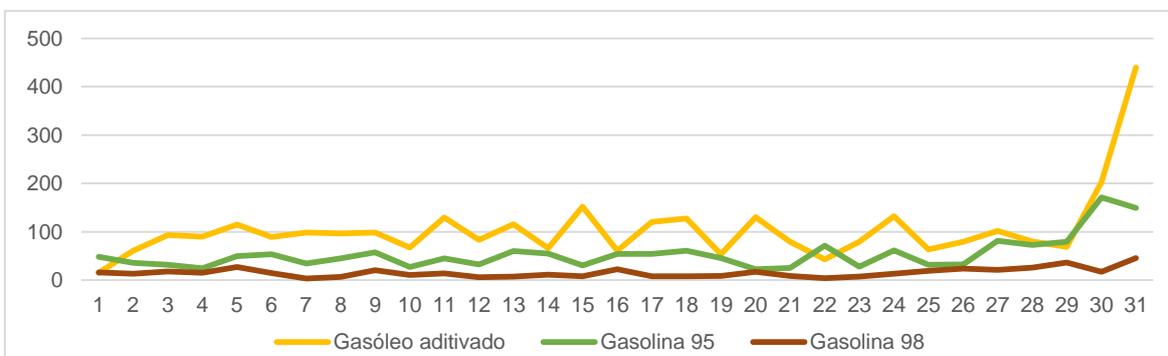


Figura 20 - Vendas médias, agrupadas por dia do mês, para os combustíveis gásóleo aditivado, gasolina 95 e gasolina 98 (Fonte: elaboração própria).

Quanto às vendas agrupadas por dias da semana (Figuras 21 e 22), o máximo de vendas de gásóleo simples, de gásóleo agrícola e de gásóleo para aquecimento ocorre à segunda-feira (venda média de 4.201 litros, 1.592 litros e 2.643 litros, respetivamente), enquanto o sábado é o dia com menores vendas (venda média de 1.454 litros, 774 litros e 953 litros, respetivamente), provavelmente explicado por não se verificarem entregas de combustíveis ao domicílio com a mesma frequência ao sábado que durante a semana.

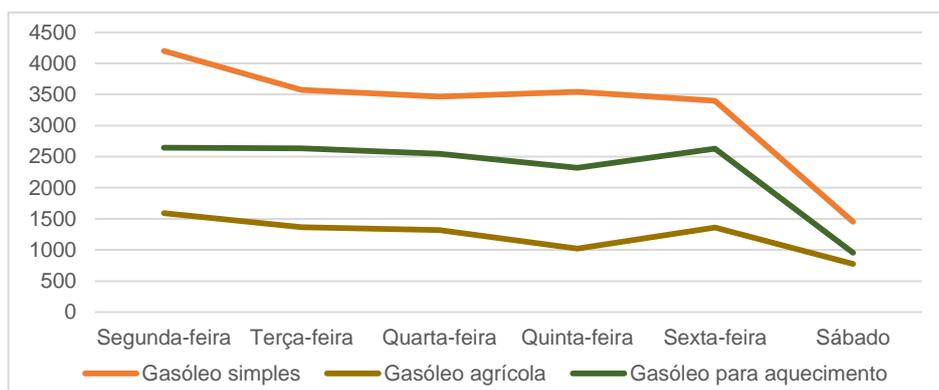


Figura 21 - Vendas médias, agrupadas por dia da semana, para os combustíveis gásóleo simples, gásóleo agrícola e gásóleo para aquecimento (Fonte: elaboração própria).

Para o gásóleo aditivado, o máximo de vendas ocorre à sexta-feira (venda média de 182 litros), enquanto o sábado é o dia com menores vendas (venda média de 69 litros). Para a gasolina 95, o máximo de vendas ocorre ao sábado (venda média de 70 litros), tal como para a gasolina 98 (venda média de 26 litros), enquanto a terça-feira é o dia com menores vendas para a primeira (venda média de 51 litros) e a sexta-feira para a segunda (venda média de 12 litros).

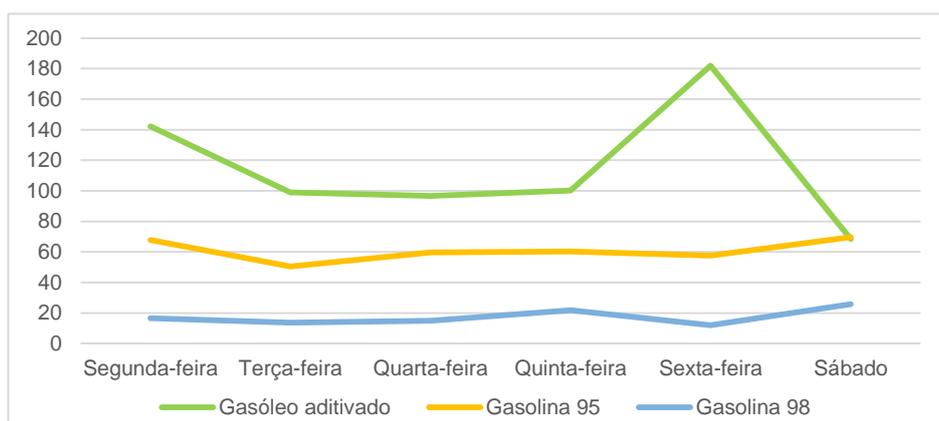


Figura 22 - Vendas médias, agrupadas por dia da semana, para os combustíveis gásóleo aditivado, gasolina 95 e gasolina 98 (Fonte: elaboração própria).

Os valores de venda e de compra médios de todos os combustíveis, em número e em litros, encontram-se nas Tabelas 24 a 27. Como esperado, verifica-se que existem mais

vendas do que compras, em número, e que a quantidade comprada se encontra de acordo com a quantidade vendida, mesmo ao nível diário, sendo apenas levemente superior.

Da mesma forma, e como supramencionado, os combustíveis com mais vendas e compras são os gasóleos, destacando-se as vendas em número por dia para os que são utilizados em veículos ligeiros.

Tabela 24 - Venda média de combustíveis, em número.

Venda média (nº)	Gasóleo Simples	Gasóleo Aditivado	Gasolina 95	Gasolina 98	Gasóleo Agrícola	Gasóleo para aquecimento
Dia	0,972	0,865	0,663	0,324	0,784	0,793
Semana	5,826	1,000	3,978	1,943	4,700	4,748
Mês	25,283	20,333	17,113	8,358	20,396	20,604
Trimestre	75,833	47,333	51,444	25,056	61,333	61,944
Ano	257,800	77,000	174,000	85,400	208,200	209,000

Tabela 25 - Venda média de combustíveis, em litros.

Venda média (lit)	Gasóleo Simples	Gasóleo Aditivado	Gasolina 95	Gasolina 98	Gasóleo Agrícola	Gasóleo para aquecimento
Dia	3271,722	114,825	60,919	17,485	1239,036	2286,590
Semana	19601,881	681,493	365,246	104,831	7423,445	13689,717
Mês	85064,766	2698,387	1571,246	450,973	32214,948	59408,207
Trimestre	255424,349	6416,693	4658,373	1338,434	96847,903	178734,194
Ano	868963,271	8473,710	16166,364	4639,972	341478,451	600751,252

Tabela 26 - Compra média de combustíveis, em número.

Compra média (nº)	Gasóleo Simples	Gasóleo Aditivado	Gasolina 95	Gasolina 98	Gasóleo Agrícola	Gasóleo para aquecimento
Dia	0,246	0,028	0,023	0,009	0,160	0,100
Semana	1,474	0,167	0,136	0,053	0,961	0,600
Mês	6,396	0,667	0,585	0,226	4,170	2,604
Trimestre	19,111	1,667	1,722	0,667	12,500	7,833
Ano	66,000	2,000	6,000	2,400	43,000	26,600

Tabela 27 - Compra média de combustíveis, em litros.

Compra média (lit)	Gasóleo Simples	Gasóleo Aditivado	Gasolina 95	Gasolina 98	Gasóleo Agrícola	Gasóleo para aquecimento
Dia	3274,601	157,355	62,639	18,356	1245,691	2306,054
Semana	19619,130	924,458	375,561	110,053	7463,313	13806,248
Mês	85139,621	3697,833	1615,623	473,434	32387,962	59913,906
Trimestre	255697,107	7397,000	4757,111	1394,000	95364,556	179761,722
Ano	875300,586	13192,000	16406,600	5018,400	343312,400	608420,400

5.2.2. Metodologia

A recolha de dados abarca todas as vendas realizadas desde outubro de 2015, tendo sido agregadas diariamente quanto às quantidades vendidas (em litros). De seguida, procuraram-se identificar variáveis independentes que pudessem explicar a variação das vendas, tendo-se identificado o preço dos combustíveis, o rendimento privado e os veículos em circulação, de acordo com Baranzini e Weber (2013), Dahl (2012), Havranek e Kokes (2015), Mikayilov *et al.* (2020) e Pock (2010).

Uma vez que os dados de algumas variáveis só se encontram disponíveis num nível de agregação superior ao diário, as vendas foram ainda agrupadas em semanas (de terça-feira a terça-feira, de acordo com a atualização de preços dos combustíveis), meses, trimestres e anos.

É de salientar que para os dados diários se consideraram semanas de seis dias, uma vez que a empresa se encontra encerrada ao domingo.

A análise dos dados iniciou pela observação dos cronogramas das vendas (ver Figuras 25, 28, 29, 32 e 33 do Anexo IV), onde não se observam nem padrões, nem tendências evidentes (com exceção das vendas de gasóleo para aquecimento). Desta forma, aplicou-se um modelo de RLS para a quantidade vendida diária, semanal, mensal, trimestral e anualmente, com a variável independente tempo (t).

Avaliaram-se ainda as funções de autocorrelação aplicadas aos dados diários, para medir o grau de correlação de cada conjunto de dados, num determinado instante, com ele próprio, num instante posterior, e efetuaram-se testes não paramétricos para avaliar a independência dos dados em relação à sua média.

Tabela 28 - Lista de variáveis explicativas testadas numa primeira fase.

Variáveis Independentes	
Diárias	Variáveis <i>dummy</i> de cada dia da semana (segunda a sábado)
	Variáveis <i>dummy</i> dos dias do mês em que ocorre maior e menor quantidade vendida
	Variáveis <i>dummy</i> dos dias da semana em que ocorre maior e menor quantidade vendida
	Preço diário dos combustíveis
Semanais	Preço semanal dos combustíveis
Mensais	Desemprego no concelho de Leiria ¹
	Desemprego no concelho de Ourém

De seguida, determinaram-se diversos modelos de RLM, tendo sido acrescentadas variáveis independentes sucessivamente, de acordo com a Tabela 28, e seguindo as conclusões de Beutel e Minner (2012).

Uma vez que praticamente a totalidade dos modelos obtidos continha variáveis estatisticamente não significativas, foi aplicado o procedimento *stepwise* para cada um dos níveis de agregação de dados, conjugado com as variáveis independentes apresentadas nas Tabelas 29 e 30. O objetivo, tal como indicado por Verstraete *et al.* (2020), foi selecionar apenas as variáveis estatisticamente significativas.

Para além de se terem utilizado as quantidades reais totais de litros vendidas, determinaram-se os modelos também com a raiz quadrada da quantidade real vendida. Isto é, procedeu-se à transformação da variável dependente com vista a ultrapassar a falha dos pressupostos de independência e de normalidade dos resíduos.

¹ De 2015 a 2020. IEFP. (2020). *Informação Mensal do Mercado de Emprego*. Acedido a 3 de fevereiro de 2021 em <https://www.iefp.pt/estatisticas>.

Tabela 29 - Lista de variáveis explicativas testadas numa segunda fase.

Variáveis Independentes	
Diárias	Variáveis <i>dummy</i> de cada dia da semana (segunda a sábado)
	Variáveis <i>dummy</i> dos dias do mês em que ocorre maior e menor quantidade vendida, em média
	Variáveis <i>dummy</i> dos dias da semana em que ocorre maior e menor quantidade vendida
	Variáveis <i>dummy</i> dos meses (janeiro a dezembro)
	Variáveis <i>dummy</i> dos dias em que ocorre grande quantidade vendida ²
	Quantidade vendida no dia anterior
Semanais	Preço diário dos combustíveis
	Variáveis <i>dummy</i> dos meses (janeiro a dezembro)
Mensais	Preço semanal dos combustíveis
	Variáveis <i>dummy</i> dos meses (janeiro a novembro)
	Desemprego no concelho de Leiria
	Desemprego no concelho de Ourém
	Índice de preços do consumidor ³
	Remunerações declaradas à segurança social ⁴
	Veículos matriculados ⁵ – total
	Veículos matriculados – ligeiros de passageiros
Veículos matriculados – ligeiros de mercadorias	
Trimestrais	Veículos matriculados – pesados
	PIB a preços de mercado – taxa de variação homóloga ⁶
	PIB a preços de mercado (área euro) – taxa de variação homóloga

Os resultados obtidos mostraram que, para os dados agrupados por dia e por semana, continuavam a não ser obtidos modelos que respeitassem todos os pressupostos da RL com distribuição normal, na grande maioria dos combustíveis. Assim, estimaram-se os MLG já referidos.

De facto, no contexto real existem diversas situações nas quais as variáveis resposta de natureza contínua não apresentam variância constante. Nestas condições, uma transformação frequente para estabilizar a variância, caso a variável resposta seja positiva, é a transformação logarítmica (distribuição normal com *link* logaritmo).

Por outro lado, caso a variável apresente observações enviesadas para grandes valores positivos (distribuição assimétrica), a distribuição gama adequa-se. Neste caso, a função de ligação aplicada é a função recíproca $f(\mu) = \frac{1}{\mu}$, mas apenas para observações com valores positivos (IBM, 2021; lærd statistics, 2018; Turkman e Silva, 2000).

A aplicação dos MLG iniciou com a introdução de todas as variáveis referidas na Tabela 29, tendo sido eliminada, uma a uma, a variável estatisticamente menos significativa, até se alcançar um modelo onde todas as variáveis eram estatisticamente significativas.

² Mais de 1000 litros para todos os combustíveis comercializados, com exceção do gasóleo simples e do gasóleo para aquecimento, onde se consideram mais de 5000 litros.

³ Banco de Portugal. (2021). *Índice de preços no consumidor*. Acedido a 22 de janeiro de 2021 em <https://bpstat.bportugal.pt/conteudos/quadros/141>.

⁴ Banco de Portugal. (2021). *Variação das remunerações declaradas à Segurança Social*. Acedido a 22 de janeiro de 2021 em <https://bpstat.bportugal.pt/conteudos/quadros/299>.

⁵ Pordata. (2021). *Veículos automóveis matriculados*. Acedido a 22 de janeiro de 2021 em <https://www.pordata.pt/NumerosDaCrise/Indicador/Ve%c3%adculos+autom%c3%b3veis+matriculados-13-54>.

⁶ Banco de Portugal. (2021). *PIB a preços de mercado*. Acedido a 22 de janeiro de 2021 em <https://bpstat.bportugal.pt/serie/12518283>.

Tabela 30 - Lista de variáveis explicativas agregadas anualmente testadas numa segunda fase.

Variáveis Independentes	
Anuais	Taxa de poupança dos particulares (em percentagem do rendimento disponível) ⁷
	Rendimento disponível dos particulares (em milhões de euros)
	Consumo privado (em milhões de euros)
	PIB <i>per capita</i> ⁸
	Veículos matriculados ⁹ – total
	Veículos matriculados – automóveis ligeiros
	Veículos matriculados – automóveis pesados
	Veículos matriculados – motociclos
	Veículos matriculados – tratores
	Veículos matriculados – reboques e semirreboques
	Veículos rodoviários motorizados em circulação ¹⁰ – total de ligeiros
	Veículos rodoviários motorizados em circulação – ligeiros de passageiros
	Veículos rodoviários motorizados em circulação – ligeiros de mercadorias
	Veículos rodoviários motorizados em circulação – outros ligeiros
	Veículos rodoviários motorizados em circulação – total de pesados
	Veículos rodoviários motorizados em circulação – pesados de passageiros
	Veículos rodoviários motorizados em circulação – pesados de mercadorias: total
	Veículos rodoviários motorizados em circulação – pesados de mercadorias: camiões
	Veículos rodoviários motorizados em circulação – pesados de mercadorias: tratores
	Veículos rodoviários motorizados em circulação – outros pesados
Veículos rodoviários motorizados em circulação ¹¹ – a gasóleo	
Veículos rodoviários motorizados em circulação – a gasolina	
Veículos rodoviários motorizados em circulação – a GPL	
Veículos rodoviários motorizados em circulação – a outro combustível	

A qualidade do ajustamento dos modelos obtidos foi depois avaliada com recurso ao gráfico de dispersão entre os resíduos e os valores preditos.

Uma vez que se verificou que os modelos obtidos continuavam a não ser válidos para todos os combustíveis, testou-se a aplicação dos modelos ARIMA, tendo o tipo de modelo a implementar resultado da aplicação da opção *expert modeler* do SPSS com deteção automática de *outliers*.

O modelo pode ser escrito por $Y'_t = c + \varphi_1 Y'_{t-1} + \dots + \varphi_p Y'_{t-p} + \sigma_1 \varepsilon_{t-1} + \dots + \sigma_q \varepsilon_{t-q} + \varepsilon_t$ e resulta num modelo *ARIMA*(p, d, q), onde p é a ordem da parte autorregressiva e determina quantos valores passados são utilizados para a regressão, d o grau de

⁷ Banco de Portugal. (2021). *Taxa de poupança dos particulares, Rendimento disponível dos particulares e Consumo privado*. Acedido a 22 de janeiro de 2021 em https://bpstat.bportugal.pt/dados/series?mode=graphicesvid=5AOAAAAAA.oQO_AAAAAA.!!!B!C!10!!!False!12!:1hqdSs:S95q8WESrxFZGI5e3Et_x188utseries=12518372,12518305.

⁸ Pordata. (2021). *PIB per capita (base=2016)*. Acedido a 22 de janeiro de 2021 em [https://www.pordata.pt/Portugal/PIB+per+capita+\(base+2016\)-2297](https://www.pordata.pt/Portugal/PIB+per+capita+(base+2016)-2297).

⁹ Pordata. (2021). *Veículos matriculados: total e por tipo de veículo*. Acedido a 22 de janeiro de 2021 em <https://www.pordata.pt/Portugal/Ve%3%adculos+matriculados+total+e+por+tipo+de+ve%3%adculo-3103>.

¹⁰ Pordata. (2021). *Veículos rodoviários motorizados em circulação: total e por tipo de veículos*. Acedido a 22 de janeiro de 2021 em <https://www.pordata.pt/Portugal/Ve%3%adculos+rodovi%3%a1rios+motorizados+em+circula%3%a7%3%a3o+total+e+por+tipo+de+ve%3%adculos-3100>.

¹¹ Pordata. (2021). *Veículos rodoviários motorizados em circulação: total e por tipo de combustível*. Acedido a 22 de janeiro de 2021 em <https://www.pordata.pt/Portugal/Ve%3%adculos+rodovi%3%a1rios+motorizados+em+circula%3%a7%3%a3o+total+e+por+tipo+de+combust%3%advel-3101>.

diferenciação, utilizado quando o pressuposto de estacionaridade não é cumprido, e q a ordem da parte de média móvel, que determina quantos termos de erro do processo anterior devem ser considerados. Neste sentido, o modelo combina coeficientes autorregressivos (AR), que são multiplicados por valores passados da série temporal, e coeficientes de média móvel (MA), que são multiplicados por erros passados.

Os parâmetros do modelo são estimados de forma a minimizar uma medida de erro (p.e., REQM). Se $c = 0$ e $d = 0$, as previsões de longo-prazo aproximam-se de zero. Já se $c \neq 0$ e $d = 0$, as previsões de longo-prazo aproximam-se da média dos dados. O valor de p é relevante se se detetam ciclos nas observações, contudo para obter previsões cíclicas é necessário que $p \geq 2$ (Hyndman e Athanasopoulos, 2018).

Um modelo SARIMA adiciona os termos sazonais (P, D, Q) ao modelo acima, resultado de retrocessos do período sazonal (Hyndman e Athanasopoulos, 2018).

Foi ainda aplicado o modelo de previsão de Holt-Winters (Winters, 1960), no método aditivo aos dados diários (pois existem observações com valor zero nos dados iniciais, o que impossibilita aplicar o método multiplicativo), seguindo o pressuposto de que existiria uma sazonalidade semanal nas observações (comprimento de sazonalidade $s = 6$). Assim, iniciou-se o modelo com $a_6 = \frac{1}{6} \sum_{t=1}^6 Y_t$ e $b_6 = \frac{\bar{Y}_2 - \bar{Y}_1}{6}$, onde \bar{Y}_1 corresponde à média das seis primeiras observações e \bar{Y}_2 à média das seis observações seguintes.

As previsões são obtidas através de $P_{n+h} = a_n + b_n \times h + S_{n+h-6}$, onde:

- $a_t = \alpha(Y_t - S_{t-6}) + (1 - \alpha)(a_{t-1} + b_{t-1})$, com $0 \leq \alpha \leq 1$;
- $b_t = \beta(a_t - a_{t-1}) + (1 - \beta)b_{t-1}$, com $0 \leq \beta \leq 1$;
- $S_t = \gamma(Y_t - a_t) + (1 - \gamma)s_{t-6}$, com $0 \leq \gamma \leq 1$.

Por fim, para os dados semanais foi implementado o método de Holt, já descrito na metodologia aplicada aos pneus, tendo-se definido k como igual a 4 (mês com 4 semanas) e como igual a 5 (mês com 5 semanas) e comparado os valores obtidos.

5.2.3. Resultados

5.2.3.1. O Caso do Gasóleo Simples

Para os dados diários, o modelo de regressão obtido com o procedimento *stepwise* foi

$$\hat{Y} = 1836,760 - 0,326t - 586,522s + 6566,179g$$

e considera como variáveis estatisticamente significativas o tempo (t) e as variáveis *dummy* sábado (s) e dia com grande quantidade de vendas (g), obtendo-se um R^2 de 0,713 e uma REQM de 1885,159. Efetivamente o modelo é coerente com a Figura 21 das vendas médias acumuladas por dia da semana, no qual o sábado apresenta um valor mais baixo

de vendas e os restantes dias valores de vendas próximos. Contudo, falha o pressuposto de normalidade dos resíduos neste modelo.

Neste sentido, aplicou-se o MLG com distribuição normal e *link* logaritmo, que apresentou como variáveis estatisticamente significativas as variáveis *dummy* segunda-feira (*m*), terça-feira (*t*), quarta-feira (*w*), quinta-feira (*q*), sexta-feira (*f*) e dia com grande quantidade vendida (*g*), obtendo-se o modelo

$$\log(\mu) = 7,154 + 0,246m + 0,202t + 0,154w + 0,178q + 0,178f + 1,666g$$

O procedimento seguido para a eliminação das variáveis estatisticamente não significativas neste MLG encontra-se descrito na Tabela 62 do Anexo VI.

Como supramencionado, no modelo verifica-se que os dias da semana, com exceção do sábado, apresentam valores de vendas próximos. Este modelo possui um valor de REQM aproximadamente igual à do modelo de RLM, 1888,211 apresentando também problemas relativos aos resíduos, que não se encontram distribuídos uniformemente em torno de zero. Assim, não surge como uma alternativa à RLM, que é mais simples de aplicar e de interpretação mais fácil.

Quanto aos modelos SARIMA, o que melhor se ajusta aos dados é SARMA (0,0,0)(1,0,1) com identificação manual de *outliers* (variável dia com grande quantidade de vendas), e escreve-se

$$\hat{Y} = 1456,488 + 0,990x_{t-6} + 0,959\varepsilon_{t-6} - 285,914m + 327,819j + 388,235u + 239,541n$$

com R² de 0,902 e REQM de 1102,952, e inclui as variáveis *dummy* meses de maio (*m*), junho (*j*), julho (*u*) e novembro (*n*). Demonstra assim, que as vendas no mês de maio serão tendencialmente inferiores e que as de junho, julho e novembro tendem a ser superiores às dos restantes meses, o que não é evidente através da observação do cronograma da Figura 16.

Deve-se referir que o modelo SARMA apresentado não se aplica aos *outliers* identificados e que a normalidade dos resíduos continua a não ser cumprida, pelo que a utilização deste modelo também não é preferível à aplicação do modelo de RLM.

O procedimento seguido para a eliminação das variáveis estatisticamente não significativas no modelo SARMA encontra-se descrito na Tabela 70 do Anexo VII.

Tabela 31 - Resumo dos métodos aplicados aos dados diários de gasóleo simples.

Método	R ²	REQM	Variáveis Estatisticamente Significativas
RLM	0,713	1885,159	tempo, sábado e dia com grande quantidade de vendas
MLG	0,712	1888,211	segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira e dia com grande quantidade de vendas
SARMA	0,902	1102,952	Meses de maio, junho, julho e novembro
HW	0,058	3464,665	-

Com o modelo de Holt-Winters aplicado às vendas diárias obtém-se uma REQM de 3464,665, como se observa na Tabela 31 onde se apresenta um resumo dos métodos aplicados aos dados diários de gasóleo simples.

Conclui-se que, para os dados diários, o modelo com melhores valores de REQM e R^2 é o SARMA, contudo a falha do pressuposto de normalidade dos resíduos indica que a sua utilização deve ser prudente. Neste sentido, o modelo de RLM apresenta-se como a opção de mais fácil compreensão.

Para as vendas semanais de gasóleo simples, o modelo obtido foi o de RLS,

$$\hat{Y} = 22660,903 - 26,472t$$

com a variável tempo (t), R^2 igual a 0,045 e REQM de 8128,982, não sendo considerada qualquer variável independente como estatisticamente significativa. Tal é consistente com o observado na Figura 17, onde não se deteta sazonalidade nem tendência.

No entanto, com o modelo de Holt, utilizando 4 semanas para inicializar o processo através do método das médias, é possível alcançar uma REQM de 7950,124.

Já para as vendas mensais, o modelo determinado foi

$$\hat{Y}_t = 58283,317 - 335,482t + 0,429Y_{t-1}$$

e inclui o mês (t) e a quantidade vendida no mês anterior (Y_{t-1}), com um R^2 de 0,340 e uma REQM de 15985,647, como se observa na Tabela 32. Mostra assim uma dependência das vendas atuais face às vendas passadas.

Tabela 32 - Resumo dos modelos semanal e mensal dos dados de gasóleo simples.

Modelo	Método	R^2	REQM	Variáveis Estatisticamente Significativas
Semanal	Holt	0,117	7950,124	-
Mensal	RLM	0,340	15985,647	Tempo e quantidade vendida no mês anterior

No que concerne às vendas trimestrais e às anuais, não foi possível ajustar um modelo de regressão válido, pois nenhuma variável foi considerada estatisticamente significativa.

Atendendo a que não foi possível obter um modelo inteiramente válido para os dados diários, provavelmente devido à grande variabilidade apresentada pelas vendas, e que não se determinam modelos para as vendas trimestrais e anuais, os modelos semanais e mensais apresentam-se como os mais adequados para prever as vendas do combustível gasóleo simples.

Contudo, e uma vez que o objetivo do projeto é planear o inventário, utilizar modelos mensais não parece ser a melhor opção pois o nível de agregação dos dados é já bastante afastado das vendas diárias e encobrirá em demasia a variabilidade que se observa. Em

contrapartida, verifica-se na Tabela 23 que existem compras de gásóleo simples em 83% das semanas e vendas em todas elas.

Neste sentido, a política de inventário mais ajustada será a (s,S), realizando-se uma revisão contínua do inventário com a encomenda de uma quantidade fixa (S) assim que os níveis de inventário descerem abaixo do nível de inventário de segurança (s) definido.

Em concreto, para o combustível gásóleo simples, significa garantir que, em cada semana, existem em inventário as quantidades apresentadas na Tabela 33, definindo-se como inventário de segurança (s) os 8.500 litros e, conseqüentemente, a quantidade a encomendar (S) será de cerca de 10.000 litros.

Tabela 33 - Quantidade prevista de litros vendidos para o combustível gásóleo simples, com o método de Holt, para um horizonte temporal de três meses.

Semana (3ª a 3ª)	Venda Prevista	Semana (3ª a 3ª)	Venda Prevista
03/03/2020	18260,15	21/04/2020	18619,98
10/03/2020	18311,56	28/04/2020	18671,38
17/03/2020	18362,96	05/05/2020	18722,79
24/03/2020	18414,36	12/05/2020	18774,19
31/03/2020	18465,77	19/05/2020	18825,59
07/04/2020	18517,17	26/05/2020	18877,00
14/04/2020	18568,57		

5.2.3.1. Análise Global dos Combustíveis

Uma vez executados os modelos para os dados diários, semanais, mensais, trimestrais e anuais, apresentados nas Tabelas 49 a 61 do Anexo V, observa-se que a elevada variabilidade das vendas, em todos os combustíveis, inviabiliza a aplicação de modelos diários. O mesmo é evidente através da análise da Tabela 34, onde se verifica que a REQM obtida através dos diferentes métodos aplicados aos dados diários varia pouco entre modelos.

Quanto aos modelos trimestrais e anuais, não foi possível obter sequer modelos através do SPSS (com exceção do modelo trimestral para a gasolina 95). Já a agregação de vendas a nível mensal permite obter modelos válidos, contudo afasta-se em demasia do contexto real de vendas.

Conclui-se que os modelos ajustados aos dados semanais aparentam ser os mais adequados para executar a previsão de vendas de combustíveis e, conseqüentemente, o planeamento de inventário, pelo que serão os apresentados de seguida.

Para as vendas semanais de gásóleo aditivado, o modelo com melhor ajuste utiliza a raiz quadrada da quantidade vendida

$$\widehat{\sqrt{Y}} = 14,083 + 1,012t - 9,013f$$

e contempla a variável tempo (t) e variável *dummy* mês de fevereiro (f), com um R^2 de 0,677 e uma REQM de 223,370.

Tabela 34 - REQM dos diferentes métodos de previsão aplicados a todos os combustíveis. (GAD – gasóleo aditivado; GA – gasóleo agrícola; GPA – gasóleo para aquecimento; G – gasóleo simples; 95 – gasolina 95; 98 – gasolina 98).

Dados		Diários					Semanais			Mensais	
Método	HW	RLM	MLG	SARMA		RLM	MLG	Holt	ARMA	RLM	
				Outliers automáticos	Outliers Manuais						
Modelo	GAD	131,58	83,50	79,32	83,85	89,25	223,37	-	280,31	-	313,44
	GA	1813,01	1179,59	1155,31	1345,34	225,78	4140,42	-	4503,56	-	5413,55
	GPA	2136,69	1386,19	1417,31	1924,63	1209,40	5427,89	-	6284,27	-	12002,17
	G	3464,67	1885,16	1888,21	3271,43	1102,95	8128,98	-	7950,12	-	15985,65
	95	154,08	131,36	131,32	26,11	131,97	346,06	342,18	366,15	276,92	661,88
	98	71,77	67,19	63,94	12,95	-	-	162,01	181,51	31,56	243,10
Previsões	GAD	1071,39	713,99	65149,92	848,78	848,92	3730,46	-	1965,23	-	22330,16
	GA	3160,44	1404,10	1392,42	2039,83	2344,12	4902,79	-	5120,53	-	9704,26
	GPA	2948,44	1687,00	1717,08	2485,58	2606,89	7195,94	-	10039,07	-	18065,85
	G	3859,61	2153,91	2135,31	3746,31	4004,19	8269,57	-	8639,93	-	12910,57
	95	158,75	98,82	98,24	100,40	103,81	221,88	218,80	227,28	239,56	1731,82
	98	113,60	93,58	213,89	95,63	-	-	216,48	234,49	233,44	334,16

Em relação à gasolina 95, no modelo de RLM referente às vendas semanais é

$$\hat{Y} = 476,556 - 1,242t + 175,387j + 217,685a$$

e inclui o tempo (t) e as variáveis *dummy* mês de julho (j) e mês de agosto (a), obtendo R^2 de 0,088 e REQM de 346,061. No entanto, o pressuposto de normalidade dos resíduos não é respeitado.

Neste sentido, estimou-se o MLG com distribuição gama e *link* potência, que engloba o tempo (t , em semanas) e as variáveis *dummy* meses de julho (j), agosto (a) e novembro (n). Neste caso, a REQM calculou-se em 342,180 e o modelo válido escreve-se

$$\log(\mu) = 0,002 + 9,673E - 6t - 0,001j - 0,001a + 0,001n$$

Relativamente à gasolina 98, o SPSS não conseguiu estimar um modelo de RLM para as vendas semanais. Assim, apenas depois de aplicado o MLG com distribuição normal e *link* logaritmo se obteve o modelo

$$\log(\mu) = 4,867 - 0,977j - 0,696f - 0,928m - 0,585o$$

que inclui as variáveis *dummy* meses de janeiro (j), fevereiro (f), março (m) e outubro (o). A REQM calcula-se em 162,007. Porém, a normalidade dos resíduos não é cumprida.

Já o modelo ARMA com melhor ajuste aos dados semanais de gasolina 98 é (1,0,1), com deteção automática de *outliers* e a equação

$$\hat{Y} = 45,956 + 0,909x_{t-6} + 0,788\varepsilon_{t-6} - 16,427d$$

onde a R^2 é 0,964 e a REQM é 31,562, e inclui a variável *dummy* mês de dezembro (d). Contudo, a normalidade dos resíduos não é cumprida e o modelo apresentado não se aplica aos *outliers* identificados.

Assim, com o modelo de Holt, inicializando o processo com 5 semanas através do método das médias, é possível alcançar uma REQM de 181,509.

No que respeita ao gasóleo agrícola, o modelo de RLM com melhor ajuste aos dados utiliza a raiz quadrada da quantidade vendida

$$\widehat{\sqrt{Y}} = 79,587 + 12,764n + 16,393d$$

e inclui as variáveis *dummy* meses de novembro (n) e dezembro (d), onde R^2 é 0,051 e a REQM é 4140,419.

Quanto ao gasóleo para aquecimento, o modelo de RLM com melhor ajuste também utiliza a raiz quadrada da quantidade vendida

$$\widehat{\sqrt{Y}} = 112,293 + 74,044j + 57,213f + 50,349m + 26,621a + 36,234o + 79,255n + 78,073d - 36,209p$$

sendo as variáveis contempladas no modelo as variáveis *dummy* dos meses de janeiro (j), fevereiro (f), março (m), abril (a), outubro (o), novembro (n) e dezembro (d) e a variável independente preço (p), com R^2 de 0,665 e REQM de 5427,963.

Determina-se então que, para o gasóleo aditivado, o modelo mais adequado é o de RLM, tal como para o gasóleo para aquecimento. Já para a gasolina 95 será o MLG com distribuição gama. Por outro lado, nenhum dos modelos de regressão aplicados à gasolina 98 respeita os pressupostos, pelo que a opção mais sensata será utilizar o modelo de Holt, o mesmo modelo selecionado para o gasóleo simples.

Tabela 35 - Previsões semanais para um horizonte de três meses para todos os combustíveis. (GAD – gasóleo aditivado; GA – gasóleo agrícola; GPA – gasóleo para aquecimento; G – gasóleo simples; G.95 – gasolina 95; G.98 – gasolina 98).

Semana (3ª a 3ª)	G	GAD	G.95	G.98	GA	GPA
	Holt	RLM	MLG	Holt	RLM	RLM
03/03/2020	18260,15	1552,42	241,90	81,95	6334,04	15261,05
10/03/2020	18311,56	1633,23	241,33	80,50	6334,04	15440,63
17/03/2020	18362,96	1716,09	240,77	79,05	6334,04	15985,69
24/03/2020	18414,36	1801,00	240,21	77,60	6334,04	16261,76
31/03/2020	18465,77	1887,96	239,65	76,16	6334,04	16447,12
07/04/2020	18517,17	1976,96	239,10	74,71	6334,04	11076,13
14/04/2020	18568,57	2068,02	238,55	73,26	6334,04	11076,13
21/04/2020	18619,98	2161,14	238,00	71,81	6334,04	11306,13
28/04/2020	18671,38	2256,30	237,45	70,37	6334,04	11538,50
05/05/2020	18722,79	2353,51	236,91	68,92	6334,04	6528,32
12/05/2020	18774,19	2452,77	236,36	67,47	6334,04	6411,74
19/05/2020	18825,59	2554,08	235,83	66,02	6334,04	6353,84
26/05/2020	18877,00	2657,44	235,29	64,58	6334,04	6124,86

Da mesma forma que o descrito para o gasóleo simples, a política de inventário mais ajustada será a (s,S), sendo que tanto a quantidade a encomendar (S) como o nível de inventário de segurança (s) variam entre combustíveis.

Para o gasóleo agrícola e gasóleo para aquecimento, o valor de (s) será de cerca de 6.000 litros, determinando-se a quantidade (S) consoante as vendas realizadas e a quantidade prevista para cada semana. Já para o gasóleo aditivado, (s) determina-se em 1.000 litros, para a gasolina 95 em 100 litros e para a gasolina 98 em 50 litros.

5.2.4. Discussão de Resultados

Uma vez aplicados os diferentes métodos de previsão enunciados, é possível concluir que existe uma grande variabilidade nas vendas diárias e semanais, o que dificulta a obtenção de modelos válidos, verificando-se ainda que os erros resultantes dos métodos de previsão exibem uma grande amplitude, por vezes da ordem da própria observação.

Quando se efetuam as previsões de vendas diárias para o período de março de 2020 a fevereiro de 2021 com os modelos resultantes dos métodos de previsão, verifica-se que o modelo que tinha obtido anteriormente a menor REQM não continua a ser o mesmo para o período de previsão. Mais, os valores de REQM são, no geral, muito superiores nas previsões para todos os combustíveis, conforme se observa na Tabela 34.

Tal evidencia a constante necessidade de atualização de qualquer modelo que se implemente, devendo a análise das previsões ser sempre cuidadosa e atenta.

É de referir que a falta de obtenção de um modelo para as vendas agrupadas por ano se deve principalmente à escassez de observações, sendo estas apenas cinco, tal como referem Prak e Teunter (2019).

Seguindo as conclusões dos mesmos autores, e uma vez que o que se pretende é melhorar os níveis de inventário da empresa, a opção mais sensata aparenta ser adotar modelos de previsão semanais ou mensais, pois o agrupamento de vendas por trimestre ou por ano é demasiado alargado, aumentando o grau de incerteza dos modelos.

A aleatoriedade de vendas verificada pode ser explicada por fatores externos que têm o potencial de afetar a venda de combustíveis da empresa. Em específico, a proximidade de concorrentes, uma vez que a Diguipneus se localiza numa estrada secundária, perpendicular à EN113, e próxima de dois outros postos de abastecimento. Mais, a realização de dias de promoção fixos pelo posto de abastecimento marca Repsol (o que se localiza mais próximo), faz com que os condutores deliberadamente aguardem por esses dias para abastecer os depósitos.

Da mesma forma, o comportamento do consumidor, naturalmente imprevisível, apresenta influência na variabilidade de vendas, pois este tende a aguardar descidas de preços para abastecer quantidades superiores de combustível, pode apresentar um rendimento disponível variável, tem a possibilidade de partilhar viagens e custos e, embora seja pouco provável a substituição do veículo próprio pelo transporte público devido à falta de oferta, dispõe da opção de utilizar veículos mais eficientes no consumo de combustível.

Adicionalmente, a empresa não representa nenhuma marca específica de combustíveis, o que a torna num posto de combustível de marca branca e acaba por afetar a decisão de compra de consumidores que valorizam a presença de marcas conhecidas.

Conclusão

A importância de existir uma política de inventário claramente definida numa empresa é exposta pelo presente trabalho. De facto, determinar quando se devem realizar encomendas e qual a quantidade ótima a encomendar de cada artigo permite melhorar não só a utilização dos recursos financeiros do retalhista, mas também reduzir custos de inventário excessivos.

Mais, a satisfação do consumidor, aspeto crucial para o sucesso de qualquer retalhista nos dias que correm, é mais facilmente garantida, pois é possível dar resposta às suas necessidades de forma mais célere e diversificada.

Contudo, como supramencionado, nem sempre é claro qual o método de previsão de vendas mais adequado, que permite reduzir a incerteza da procura pelos artigos, e pode até ser difícil encontrar algum que possa ser aplicado.

No caso do artigo pneus, quanto à política de inventário a aplicar, verifica-se que se devem utilizar períodos de revisão (R) distintos de acordo com a medida de pneus em causa. Em concreto, para as medidas mais vendidas (as agrupadas por mês), o período de revisão deve ser o mensal. Para as medidas reunidas por trimestre, o período de revisão deve ser anual. Já para as medidas agrupadas por semestre, e atendendo a que a REQM alcançada é muito semelhante com o período de revisão semestral e com o anual, parece ser mais prudente rever as vendas a cada semestre.

Relativamente à quantidade a encomendar, considerando que foi possível ajustar modelos de previsão da procura às diferentes medidas de pneus, conclui-se que se deve relacionar a oferta com a procura, isto é, encomendar uma quantidade suficiente (S) para responder à procura esperada durante o período de revisão, e garantir que existe sempre um inventário de segurança (s) que permita responder à procura inesperada (no mínimo, um par de pneus de cada medida vendida com frequência).

Tal define-se como uma política de inventário (R,s,S), considerada adequada para artigos com saída mais rápida, mas também mais lenta por Babiloni *et al.* (2012) e Silver *et al.* (1998), sendo que o modelo a utilizar resulta da combinação ponderada das previsões dos dois métodos que apresentaram menor REQM para cada nível de agregação de dados.

Resumindo, para os dados agrupados por mês e para os dados agrupados por semestre, combinam-se as previsões obtidas pelos métodos AES e Holt, enquanto para os dados agrupados por trimestre, se ponderam as previsões resultantes dos métodos AES e de Croston.

De acordo com o defendido por Syntetos e Boylan (2006) e Sani e Kingsman (1997), verifica-se que o método AES se adequa à previsão de artigos com procura intermitente.

No entanto, é de referir a importância de analisar os modelos a cada período de revisão (R) e de se realizarem ajustes de acordo com informação nova que se vá adquirindo e não esteja a ser considerada nos modelos atuais.

Já para o artigo combustíveis, não foi possível obter modelos de previsão para as vendas diárias (quanto a todos os combustíveis) e semanais (para o combustível gasolina 98) que cumprissem todos os pressupostos e que, conseqüentemente, fossem considerados válidos. Isto significa que, embora estes modelos possam ser aplicados para realizar a previsão de vendas, os valores obtidos devem ser utilizados cautelosamente e sujeitos a julgamento face a informação complementar. Tal pode decorrer do facto do procedimento *stepwise* não ter seleccionado as variáveis mais indicadas, como apontado por Verstraete *et al.* (2020), o que evidencia a necessidade de se realizarem investigações mais aprofundadas.

Para as vendas mensais conseguiram-se determinar modelos de RLM válidos, contudo o nível de agregação das vendas é já algo grande e pode induzir em erro algumas compras de inventário, até porque a magnitude dos erros resultantes é elevada.

Neste sentido, a política de inventário mais adequada aparenta ser realizar uma revisão contínua do nível de inventário, com foco particular ao nível semanal, e efetuar uma encomenda de quantidade fixa (S) assim que os níveis de inventário descerem abaixo do nível de inventário de segurança (s) definido, designando-se política (s,S). Tal é o defendido por Yeh *et al.* (1997), de forma a garantir o nível de serviço ao consumidor desejado.

A quantidade a encomendar será diferente para cada combustível, como se espera, e poderá variar (e certamente irá) ao longo do tempo. Em relação aos dados atuais, concluiu-se que a previsão de vendas semanais pode recorrer ao modelo de RLM para os combustíveis gasóleo simples, gasóleo aditivado, gasóleo agrícola e gasóleo para aquecimento, ao MLG para a gasolina 95 e ao método de Holt para a gasolina 98.

Atendendo a que a questão do espaço disponível para armazenagem de combustíveis é praticamente nula, uma vez que cada combustível é armazenado num tanque próprio e o espaço não utilizado nunca pode ser ocupado por outro artigo, o propósito da previsão de vendas de combustíveis prende-se essencialmente com a otimização dos recursos financeiros do retalhista ao nível do planeamento de inventário.

Desta forma, a política de inventário sugerida poderá ser difícil de cumprir, essencialmente devido ao facto da empresa se autoabastecer, pois poderá ser vantajoso não esperar que os níveis de inventário sejam inferiores ao definido (s) para ocorrer uma

compra, mas antes tirar partido de descidas de preços conhecidas ou estabelecer sinergias com os transportes efetuados por conta de clientes.

No que respeita ao cumprimento dos objetivos a que o presente trabalho se propôs a responder, foi possível desenvolver diversos modelos com ajuste adequado às vendas de pneus e sugerir políticas de inventário que permitirão à empresa reduzir os custos associados à gestão de inventário e melhor satisfazer as necessidades dos seus clientes.

Já relativamente aos objetivos relacionados com os combustíveis, os modelos alcançados requerem uma interpretação cautelosa, pelo que indiciam a necessidade de pesquisas mais aprofundadas para que se obtenham modelos com ajuste mais próximo às vendas reais. Consequentemente, as sugestões de melhoria de inventário apresentadas serão meramente indicativas de práticas que permitirão reduzir os custos de inventário.

As principais limitações do presente trabalho prendem-se essencialmente com a inexistência de informação disponível acerca do ambiente externo da empresa com um nível de agregação diário, semanal ou mensal. Neste âmbito, poderia ter sido útil realizar um inquérito de forma a avaliar o comportamento de compra e de decisão do consumidor relativo a pneus e a combustíveis, em concordância com o defendido por Beutel e Minner (2012), sugerindo-se a sua realização numa investigação futura.

Quanto aos métodos aplicados ao artigo pneus, apenas se utilizaram dados passados de vendas. Contudo, a aplicação de informação complementar, seja respeitante a aspetos económicos ou à proximidade de concorrentes, poderá acrescentar informação útil e tornar os modelos mais precisos.

Tendo em conta o sucesso da aplicação das RNA para prever a procura de artigos com procura intermitente, tentou-se aplicar este método aos dados disponíveis. Contudo, a falta de variáveis explicativas tornou impossível executar a sua aplicação.

Já no que concerne aos combustíveis, onde não foi possível obter modelos válidos para o nível de agregação diário de dados, é evidente a necessidade de realizar investigações mais profundas e de procurar reunir dados adicionais que possam explicar a variabilidade de vendas verificada. Complementarmente, a aplicação de métodos de previsão mais sofisticados, que ultrapassam o âmbito deste projeto, poderá ser útil.

Referências Bibliográficas

- Aiolfi, M., & Timmermann, A. (2006). Persistence in forecasting performance and conditional combination strategies. *Journal of Econometrics*, 135(1–2), 31–53. <https://doi.org/10.1016/j.jeconom.2005.07.015>
- Akçay, Y., Li, Y., & Natarajan, H. (2020). Category Inventory Planning With Service Level Requirements and Dynamic Substitutions. *Production and Operations Management*, 0(0), 1–26. <https://doi.org/10.1111/poms.13240>
- Aklilu, A. (2020). Gasoline and diesel demand in the EU: Implications for the 2030 emission goal. *Renewable and Sustainable Energy Reviews*, 118(October 2019), 109530. <https://doi.org/10.1016/j.rser.2019.109530>
- Archibald, R., & Gillingham, R. (1980). An Analysis of the Short-Run Consumer Demand for Gasoline Using Household Survey Data. *The Review of Economics and Statistics*, 62(4), 622. <https://doi.org/10.2307/1924790>
- Armstrong, J., & Collopy, F. (1992). Error Measures For Generalizing About Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, 8(1), 69–80. http://papers.ssrn.com/sol3/papers.cfm?abstract_id=662701
- Arslankaya, S., & Öz, V. (2018). Time Series Analysis of Sales Quantity in an Automotive Company and Estimation by Artificial Neural Networks. *Sakarya University Journal of Science*, 22(5), 1–1. <https://doi.org/10.16984/saufenbilder.456518>
- Babiloni, E., Cardós, M., Albarracín, J., & Palmer, M. (2012). Demand Categorisation, Forecasting, and Inventory Control for Intermittent Demand Items. *The South African Journal of Industrial Engineering*, 21(2), 78–81. <https://doi.org/10.7166/21-2-54>
- Baranzini, A., & Weber, S. (2013). Elasticities of gasoline demand in Switzerland. *Energy Policy*, 63, 674–680. <https://doi.org/10.1016/j.enpol.2013.08.084>
- Basso, L. J., & Oum, T. H. (2007). Automobile fuel demand: A critical assessment of empirical methodologies. *Transport Reviews*, 27(4), 449–484. <https://doi.org/10.1080/01441640601119710>
- Beutel, A., & Minner, S. (2012). Safety stock planning under causal demand forecasting. *International Journal of Production Economics*, 140(2), 637–645. <https://doi.org/10.1016/j.ijpe.2011.04.017>
- Blattberg, R., & Hoch, S. (2010). Database models and managerial intuition: 50% model + 50% manager. *Perspectives on Promotion and Database Marketing: The Collected Works of Robert C Blattberg*, 36(8), 228–240. https://doi.org/10.1142/9789814287067_0014
- Bretschneider, S. (1986). Estimating forecast variance with exponential smoothing Some new results. *International Journal of Forecasting*, 2(3), 349–355. [https://doi.org/10.1016/0169-2070\(86\)90053-1](https://doi.org/10.1016/0169-2070(86)90053-1)
- Brons, M., Nijkamp, P., Pels, E., & Rietveld, P. (2008). A meta-analysis of the price elasticity of gasoline demand. A SUR approach. *Energy Economics*, 30(5), 2105–2122. <https://doi.org/10.1016/j.eneco.2007.08.004>
- Brown, R. G. (1959). *Statistical Forecasting for Inventory Control*. McGraw-Hill. <https://books.google.pt/books?id=oKl8AAAAIAAJ>
- Burgin, T. (1975). Gamma Distribution and Inventory Control. *Operational Research Quarterly*, 26(3 i), 507–525. <https://doi.org/10.1057/jors.1975.110>
- Caiado, J. (2011). *Métodos de previsão em gestão – com aplicações em Excel*. Edições Sílabo.
- Coglianesse, J., Davis, L., Kilian, L., & Stock, J. (2017). Anticipation, Tax Avoidance, and the Price Elasticity of Gasoline Demand. *Journal of Applied Econometrics*, 32(1), 1–15. <https://doi.org/10.1002/jae.2500>
- Croston, J. (1972). Forecasting and Stock Control for Intermittent Demands. *Operational Research Quarterly (1970-1977)*, 23(3), 289. <https://doi.org/10.2307/3007885>
- Dahl, C. (2012). Measuring global gasoline and diesel price and income elasticities. *Energy Policy*, 41, 2–13. <https://doi.org/10.1016/j.enpol.2010.11.055>
- Dahl, C., & Sterner, T. (1991). Analysing gasoline demand elasticities: a survey. *Energy Economics*, 13(3), 203–210. [https://doi.org/10.1016/0140-9883\(91\)90021-Q](https://doi.org/10.1016/0140-9883(91)90021-Q)
- Dalrymple, D. (1975). Sales forecasting methods and accuracy. Em *Business Horizons* (Vol. 18,

- Número 6, pp. 69–73). [https://doi.org/10.1016/0007-6813\(75\)90043-9](https://doi.org/10.1016/0007-6813(75)90043-9)
- Davis, L., & Kilian, L. (2011). Estimating the effect of a gasoline tax on carbon emissions. *Journal of Applied Econometrics*, 26(7), 1187–1214. <https://doi.org/10.1002/jae.1156>
- Diamantopoulos, A., & Mathews, B. (1989). Factors affecting the nature and effectiveness of subjective revision in sales forecasting: An empirical study. *Managerial and Decision Economics*, 10(1), 51–59. <https://doi.org/10.1002/mde.4090100106>
- Eaves, A., & Kingsman, B. (2004). Forecasting for the ordering and stock-holding of spare parts. *Journal of the Operational Research Society*, 55(4), 431–437. <https://doi.org/10.1057/palgrave.jors.2601697>
- Einhorn, H., & Hogarth, R. (1981). Behavioral Decision Theory: Processes of Judgement and Choice. *Annual Review of Psychology*, 32(1), 53–88. <https://doi.org/10.1146/annurev.ps.32.020181.000413>
- Espey, M. (1998). Gasoline demand revisited: An international meta-analysis of elasticities. *Energy Economics*, 20(3), 273–295. [https://doi.org/10.1016/S0140-9883\(97\)00013-3](https://doi.org/10.1016/S0140-9883(97)00013-3)
- European Tyre and Rubber Manufacturers' Association. (2019). *The ETRMA Statistics Report*.
- Export Entreprises, S. (2021). *Portugal: Economic and Political Outline*. Santander Trade. <https://santandertrade.com/en/portal/analyse-markets/portugal/economic-political-outline>
- Export Entreprises SA. (2021). *Portugal: Economic and Political Outline*. Santander Trade. <https://santandertrade.com/en/portal/analyse-markets/portugal/economic-political-outline>
- Ferrell, W. (1985). Combining Individual Judgments. Em *Behavioral Decision Making* (pp. 111–145). Springer US. https://doi.org/10.1007/978-1-4613-2391-4_6
- Fildes, R., Goodwin, P., Lawrence, M., & Nikolopoulos, K. (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, 25(1), 3–23. <https://doi.org/10.1016/j.ijforecast.2008.11.010>
- Fildes, R., Hibon, M., Makridakis, S., & Meade, N. (1998). Generalising about univariate forecasting methods: Further empirical evidence. *International Journal of Forecasting*, 14(3), 339–358. [https://doi.org/10.1016/S0169-2070\(98\)00009-0](https://doi.org/10.1016/S0169-2070(98)00009-0)
- Filippini, M., & Heimsch, F. (2016). The regional impact of a CO2 tax on gasoline demand: A spatial econometric approach. *Resource and Energy Economics*, 46, 85–100. <https://doi.org/10.1016/j.reseneeco.2016.07.002>
- G. Box, & Jenkins, G. (1970). *Time Series Analysis: Forecasting and Control* (Holden-Day (ed.)).
- Gardner, E. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting*, 4(1), 1–28. <https://doi.org/10.1002/for.3980040103>
- Gardner, E. (1990). Evaluating forecast performance in an inventory control system. *Management Science*, 36(4), 490–499. <https://doi.org/10.1287/mnsc.36.4.490>
- Gardner, E. (2006). Exponential smoothing: The state of the art-Part II. *International Journal of Forecasting*, 22(4), 637–666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Ghobbar, A., & Friend, C. (2003). Evaluation of forecasting methods for intermittent parts demand in the field of aviation: A predictive model. *Computers and Operations Research*, 30(14), 2097–2114. [https://doi.org/10.1016/S0305-0548\(02\)00125-9](https://doi.org/10.1016/S0305-0548(02)00125-9)
- Gil, A. C. (2008). *Métodos e técnicas de pesquisa social*. ATLAS EDITORA. <https://books.google.pt/books?id=rhB4wwEACAAJ>
- Gilchrist, W. G. (1976). *Statistical Forecasting*. Wiley.
- Gneiting, T. (2011). Making and evaluating point forecasts. *Journal of the American Statistical Association*, 106(494), 746–762. <https://doi.org/10.1198/jasa.2011.r10138>
- Goodwin, P., Dargay, J., & Hanly, M. (2004). Elasticities of road traffic and fuel consumption with respect to price and income: A review. *Transport Reviews*, 24(3), 275–292. <https://doi.org/10.1080/0144164042000181725>
- Graham, D., & Glaister, S. (2002). The demand for automobile fuel: A survey of elasticities. *Journal of Transport Economics and Policy*, 36(1), 1–26.
- Graham, D., & Glaister, S. (2004). Road traffic demand elasticity estimates: A review. *Transport Reviews*, 24(3), 261–274. <https://doi.org/10.1080/0144164032000101193>
- Gutierrez, R., Solis, A., & Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural

- networks. *International Journal of Production Economics*, 111(2), 409–420. <https://doi.org/10.1016/j.ijpe.2007.01.007>
- Harris, F. W. (1913). How many parts to make at once. *Factory, The Magazine of Management*, 10(2), 135–136. <https://doi.org/000341466000002>
- Havranek, T., Irsova, Z., & Janda, K. (2012). Demand for gasoline is more price-inelastic than commonly thought. *Energy Economics*, 34(1), 201–207. <https://doi.org/10.1016/j.eneco.2011.09.003>
- Havranek, T., & Kokes, O. (2015). Income elasticity of gasoline demand: A meta-analysis. *Energy Economics*, 47, 77–86. <https://doi.org/10.1016/j.eneco.2014.11.004>
- Hibon, M., & Evgeniou, T. (2005). To combine or not to combine: Selecting among forecasts and their combinations. *International Journal of Forecasting*, 21(1), 15–24. <https://doi.org/10.1016/j.ijforecast.2004.05.002>
- Hill, R., Seifbarghy, M., & Smith, D. (2007). A two-echelon inventory model with lost sales. *European Journal of Operational Research*, 181(2), 753–766. <https://doi.org/10.1016/j.ejor.2006.08.017>
- Hill, T., O'Connor, M., & Remus, W. (1996). Neural network models for time series forecasts. *Management Science*, 42(7), 1082–1092. <https://doi.org/10.1287/mnsc.42.7.1082>
- Hillier, F., & Lieberman, G. (2001). *Introduction to Operations Research* (7.^a ed.). McGraw-Hill. <https://doi.org/0-07-232169-5>
- Hoch, S., Bradlow, E., & Wansink, B. (1999). The variety of an assortment. *Marketing Science*, 18(4), 527–546. <https://doi.org/10.1287/mksc.18.4.527>
- Holt, C. (2004a). Author's retrospective on «Forecasting seasonals and trends by exponentially weighted moving averages». *International Journal of Forecasting*, 20(1), 11–13. <https://doi.org/10.1016/j.ijforecast.2003.09.017>
- Holt, C. (2004b). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5–10. <https://doi.org/10.1016/j.ijforecast.2003.09.015>
- Hyndman, R., & Athanasopoulos, G. (2018). Forecasting: Principles and Practice. Em *OTexts* (2.^a ed.). <https://otexts.com/fpp2/arima.html>
- IBM. (2021). *Generalized Estimating Equations*. IBM Knowledge Center. https://www.ibm.com/support/knowledgecenter/SSLVMB_sub/statistics_mainhelp_ddita/spss/advanced/idh_idd_gee_repeated.html
- INE. (2021). *Vendas de combustíveis líquidos e gasosos (t) das empresas por Localização geográfica (NUTS - 2013) e Tipo de combustível*. https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_indicadores&indOcorrCod=0008233
- Johnston, F., & Boylan, J. (1996). Forecasting for Items with Intermittent Demand. *The Journal of the Operational Research Society*, 47(1), 113. <https://doi.org/10.2307/2584256>
- Johnston, F., Boylan, J., & Shale, E. (2003). An examination of the size of orders from customers, their characterisation and the implications for inventory control of slow moving items. *Journal of the Operational Research Society*, 54(8), 833–837. <https://doi.org/10.1057/palgrave.jors.2601586>
- Jong, G., & Gunn, H. (2001). Recent evidence on car cost and time elasticities of travel demand in Europe. *Journal of Transport Economics and Policy*, 35(2), 137–160.
- Kanjilal, K., & Ghosh, S. (2018). Revisiting income and price elasticity of gasoline demand in India: new evidence from cointegration tests. *Empirical Economics*, 55(4), 1869–1888. <https://doi.org/10.1007/s00181-017-1334-2>
- Kayser, H. (2000). Gasoline demand and car choice: Estimating gasoline demand using household information. *Energy Economics*, 22(3), 331–348. [https://doi.org/10.1016/S0140-9883\(99\)00043-2](https://doi.org/10.1016/S0140-9883(99)00043-2)
- Klosterhalfen, S., Dittmar, D., & Minner, S. (2013). An integrated guaranteed- and stochastic-service approach to inventory optimization in supply chains. *European Journal of Operational Research*, 231(1), 109–119. <https://doi.org/10.1016/j.ejor.2013.05.032>
- Kök, A., Fisher, M., & Vaidyanathan, R. (2015). Assortment Planning: Review of Literature and Industry Practice. Em *Retail Supply Chain Management* (pp. 175–236). Springer New York LLC. https://doi.org/10.1007/978-1-4899-7562-1_8

- Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143(1), 198–206. <https://doi.org/10.1016/j.ijpe.2013.01.009>
- Kourentzes, N. (2014). On intermittent demand model optimisation and selection. *International Journal of Production Economics*, 156, 180–190. <https://doi.org/10.1016/j.ijpe.2014.06.007>
- Labandeira, X., Labeaga, J. M., & López-Otero, X. (2017). A meta-analysis on the price elasticity of energy demand. *Energy Policy*, 102(January), 549–568. <https://doi.org/10.1016/j.enpol.2017.01.002>
- laerd statistics. (2018). *Poisson Regression Analysis using SPSS Statistics*. <https://statistics.laerd.com/spss-tutorials/poisson-regression-using-spss-statistics.php>
- Levén, E., & Segerstedt, A. (2004). Inventory control with a modified Croston procedure and Erlang distribution. *International Journal of Production Economics*, 90(3), 361–367. [https://doi.org/10.1016/S0925-5273\(03\)00053-7](https://doi.org/10.1016/S0925-5273(03)00053-7)
- Levin, L., Lewis, M., & Wolak, F. (2017). High Frequency Evidence on the Demand for Gasoline. *American Economic Journal: Economic Policy*, 9(3), 314–347. <https://doi.org/10.1257/pol.20140093>
- Liddle, B., & Huntington, H. (2020). 'On the Road Again': A 118 country panel analysis of gasoline and diesel demand. *Transportation Research Part A: Policy and Practice*, 142(January), 151–167. <https://doi.org/10.1016/j.tra.2020.10.015>
- Lim, J., & O'Connor, M. (1995). Judgemental adjustment of initial forecasts: Its effectiveness and biases. *Journal of Behavioral Decision Making*, 8(3), 149–168. <https://doi.org/10.1002/bdm.3960080302>
- Liu, W. (2020). Asymmetric price effects on gasoline consumption: evidence and Implications. *Applied Economics Letters*, 27(2), 136–139. <https://doi.org/10.1080/13504851.2019.1610700>
- Mahajan, S., & van Ryzin, G. (1999). Retail Inventories and Consumer Choice. Em Springer (Ed.), *Tayur, S., R. Ganeshan, M. Magazine eds. Quantitative Models for Supply Chain Management* (17.^a ed., pp. 491–551). International Series in Operations Research & Management Science. https://doi.org/10.1007/978-1-4615-4949-9_17
- Mahama-Musah, F., Vanhaverbeke, L., & Gillet, A. (2020). The impact of personal, market- and product-relevant factors on patronage behaviour in the automobile tyre replacement market. *Journal of Retailing and Consumer Services*, 57(July), 102206. <https://doi.org/10.1016/j.jretconser.2020.102206>
- Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., Newton, J., Parzen, E., & Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting*, 1(2), 111–153. <https://doi.org/10.1002/for.3980010202>
- Makridakis, Spyros, & Hibon, M. (2000). The M3-competition: Results, conclusions and implications. *International Journal of Forecasting*, 16(4), 451–476. [https://doi.org/10.1016/S0169-2070\(00\)00057-1](https://doi.org/10.1016/S0169-2070(00)00057-1)
- Makridakis, Spyros, & Winkler, R. (1983). Averages of Forecasts: Some Empirical Results. *Management Science*, 29(7), 987–996. <https://doi.org/10.1287/mnsc.29.9.987>
- MarketLine. (2019). *Global Tires & Rubber* (Número March).
- Mathews, B., & Diamantopoulos, A. (1992). Judgemental revision of sales forecasts: The relative performance of judgementally revised versus non-revised forecasts. *Journal of Forecasting*, 11(6), 569–576. <https://doi.org/10.1002/for.3980110606>
- Mentzer, J., & Cox, J. (1984). Familiarity, application, and performance of sales forecasting techniques. *Journal of Forecasting*, 3(1), 27–36. <https://doi.org/10.1002/for.3980030104>
- Mikayilov, J., Mukhtarov, S., Dinçer, H., Yüksel, S., & Aydın, R. (2020). Elasticity analysis of fossil energy sources for sustainable economies: A case of gasoline consumption in Turkey. *Energies*, 13(3). <https://doi.org/10.3390/en13030731>
- Miller, S., & Liem, K. (2004). Collaborative Forecasting Goodyear Tire & Rubber Company's Journey. *Journal of Business Forecasting Methods & Systems*, 23(3), 23–27. <http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=15372585&site=eds-live>
- Mitreá, C., Lee, C., & Wu, Z. (2009). A comparison between neural networks and traditional forecasting methods: A case study. *International Journal of Engineering Business Management*, 1(2), 19–24. <https://doi.org/10.5772/6777>

- Natarajan, K., Soundararajan, K., & Jayakrishnan, J. (2013). Buyer Behaviour Patterns and Satisfaction Trends of Commercial Vehicles Owners in Replacement of Tyres. *Annamalai International Journal of Business Studies & Research*, 5(1), 79–86. <https://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=93994278&site=ehost-live>
- Nicol, C. (2003). Elasticities of demand for gasoline in Canada and the United States. *Energy Economics*, 25(2), 201–214. [https://doi.org/10.1016/S0140-9883\(03\)00002-1](https://doi.org/10.1016/S0140-9883(03)00002-1)
- Nikolopoulos, K., Syntetos, A., Boylan, J., Petropoulos, F., & Assimakopoulos, V. (2011). An aggregate-disaggregate intermittent demand approach (ADIDA) to forecasting: An empirical proposition and analysis. *Journal of the Operational Research Society*, 62(3), 544–554. <https://doi.org/10.1057/jors.2010.32>
- Noel, M. (2019). Calendar synchronization of gasoline price increases. *Journal of Economics and Management Strategy*, 28(2), 355–370. <https://doi.org/10.1111/jems.12267>
- Petropoulos, F., Makridakis, S., Assimakopoulos, V., & Nikolopoulos, K. (2014). «Horses for Courses» in demand forecasting. *European Journal of Operational Research*, 237(1), 152–163. <https://doi.org/10.1016/j.ejor.2014.02.036>
- Pock, M. (2010). Gasoline demand in Europe: New insights. *Energy Economics*, 32(1), 54–62. <https://doi.org/10.1016/j.eneco.2009.04.002>
- PORDATA. (2020). *População empregada: total e por sector de actividade económica*. <https://www.pordata.pt/Portugal/População+empregada+total+e+por+sector+de+actividade+e+conómica-3384>
- Prak, D., & Teunter, R. (2019). A general method for addressing forecasting uncertainty in inventory models. *International Journal of Forecasting*, 35(1), 224–238. <https://doi.org/10.1016/j.ijforecast.2017.11.004>
- Qin, Y., & Li, H. (2011). Sales forecast based on BP neural network. *2011 IEEE 3rd International Conference on Communication Software and Networks*, 186–189. <https://doi.org/10.1109/ICCSN.2011.6014419>
- Rao, A. (1973). A Comment on: Forecasting and Stock Control for Intermittent Demands. *Operational Research Quarterly (1970-1977)*, 24(4), 639. <https://doi.org/10.2307/3008348>
- Russell, R., & Taylor, B. (2014). *Operations Management: Creating Value Along the Supply Chain*. Wiley.
- Sagaert, Y., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018a). Tactical sales forecasting using a very large set of macroeconomic indicators. *European Journal of Operational Research*, 264(2), 558–569. <https://doi.org/10.1016/j.ejor.2017.06.054>
- Sagaert, Y., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018b). Temporal big data for tactical sales forecasting in the tire industry. *Interfaces*, 48(2), 121–129. <https://doi.org/10.1287/inte.2017.0901>
- Sani, B., & Kingsman, B. (1997). Selecting the best periodic inventory control demand forecasting methods for low demand items. *Journal of the Operational Research Society*, 48(7), 700–713. <https://doi.org/10.1057/palgrave.jors.2600418>
- Schmalensee, R., & Stoker, T. (1999). Household gasoline demand in the United States. *Econometrica*, 67(3), 645–662. <https://doi.org/10.1111/1468-0262.00041>
- Scott, K. (2012). Rational habits in gasoline demand. *Energy Economics*, 34(5), 1713–1723. <https://doi.org/10.1016/j.eneco.2012.02.007>
- Sentenac-Chemin, E. (2012). Is the price effect on fuel consumption symmetric? Some evidence from an empirical study. *Energy Policy*, 41, 59–65. <https://doi.org/10.1016/j.enpol.2010.07.016>
- Silver, E., Pyke, D., & Peterson, R. (1998). *Inventory management and production planning and scheduling* (3rd ed.). Hoboken (N.J.): Wiley. <http://lib.ugent.be/catalog/rug01:000762007>
- Souza, L., Silva, S., & Santos, V. (2018). Forecast of the volume of sales index in the Brazilian petroleum sector using artificial neural networks. *ITEGAM- Journal of Engineering and Technology for Industrial Applications (ITEGAM-JETIA)*, 4(14). <https://doi.org/10.5935/2447-0228.20180029>
- Strijbosch, L., Heuts, R., & Schoot, E. (2000). A combined forecast-inventory control procedure for spare parts. *Journal of the Operational Research Society*, 51(10), 1184–1192. <https://doi.org/10.1057/palgrave.jors.2601013>

- Strijbosch, Leo, Syntetos, A., Boylan, J., & Janssen, E. (2011). On the interaction between forecasting and stock control: The case of non-stationary demand. *International Journal of Production Economics*, 133(1), 470–480. <https://doi.org/10.1016/j.ijpe.2009.10.032>
- Syntetos, A., Babai, M., Dallery, Y., & Teunter, R. (2009). Periodic control of intermittent demand items: Theory and empirical analysis. *Journal of the Operational Research Society*, 60(5), 611–618. <https://doi.org/10.1057/palgrave.jors.2602593>
- Syntetos, A., & Boylan, J. (2001). On the bias of intermittent demand estimates. *International Journal of Production Economics*, 71(1–3), 457–466. [https://doi.org/10.1016/S0925-5273\(00\)00143-2](https://doi.org/10.1016/S0925-5273(00)00143-2)
- Syntetos, A., Boylan, J., & Croston, J. (2005). On the categorization of demand patterns. *Journal of the Operational Research Society*, 56(5), 495–503. <https://doi.org/10.1057/palgrave.jors.2601841>
- Syntetos, Aris, & Boylan, J. (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), 303–314. <https://doi.org/10.1016/j.ijforecast.2004.10.001>
- Syntetos, Aris, & Boylan, J. (2006). On the stock control performance of intermittent demand estimators. *International Journal of Production Economics*, 103(1), 36–47. <https://doi.org/10.1016/j.ijpe.2005.04.004>
- Syntetos, Aris, & Boylan, J. (2008). Demand forecasting adjustments for service-level achievement. *IMA Journal of Management Mathematics*, 19(2), 175–192. <https://doi.org/10.1093/imaman/dpm034>
- Syntetos, Aris, Nikolopoulos, K., & Boylan, J. (2010). Judging the judges through accuracy-implication metrics: The case of inventory forecasting. *International Journal of Forecasting*, 26(1), 134–143. <https://doi.org/10.1016/j.ijforecast.2009.05.016>
- Syntetos, Aris, Nikolopoulos, K., Boylan, J., Fildes, R., & Goodwin, P. (2009). The effects of integrating management judgement into intermittent demand forecasts. *International Journal of Production Economics*, 118(1), 72–81. <https://doi.org/10.1016/j.ijpe.2008.08.011>
- Teunter, R., & Duncan, L. (2009). Forecasting intermittent demand: A comparative study. *Journal of the Operational Research Society*, 60(3), 321–329. <https://doi.org/10.1057/palgrave.jors.2602569>
- Teunter, Ruud, Syntetos, A., & Babai, M. (2011). Intermittent demand: Linking forecasting to inventory obsolescence. *European Journal of Operational Research*, 214(3), 606–615. <https://doi.org/10.1016/j.ejor.2011.05.018>
- Tibshirani, R. (1996). Regression Shrinkage and Selection Via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Ton, Z., & Raman, A. (2010). The effect of product variety and inventory levels on retail store sales: A longitudinal study. *Production and Operations Management*, 19(5), 546–560. <https://doi.org/10.1111/j.1937-5956.2010.01120.x>
- Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 49(11), 1225–1231. [https://doi.org/10.1016/S0895-4356\(96\)00002-9](https://doi.org/10.1016/S0895-4356(96)00002-9)
- Turkman, M. A. A., & Silva, G. L. (2000). Modelos Lineares Generalizados: da teoria à prática. Em *VIII Congresso Anual da Sociedade Portuguesa de Estatística*. Edições SPE. <http://docentes.deio.fc.ul.pt/maturkman/mlg.pdf>
- Verstraete, G., Aghezzaf, E. H., & Desmet, B. (2020). A leading macroeconomic indicators' based framework to automatically generate tactical sales forecasts. *Computers and Industrial Engineering*, 139(August 2019), 106169. <https://doi.org/10.1016/j.cie.2019.106169>
- Vizinger, T., & Žerovnik, J. (2019). A stochastic model for better planning of product flow in retail supply chains. *Journal of the Operational Research Society*, 70(11), 1900–1914. <https://doi.org/10.1080/01605682.2018.1501460>
- Wadud, Z., Graham, D., & Noland, R. (2010). Gasoline demand with heterogeneity in household responses. *Energy Journal*, 31(1), 47–74. <https://doi.org/10.5547/ISSN0195-6574-EJ-Vol31-No1-3>
- Wallström, P., & Segerstedt, A. (2010). Evaluation of forecasting error measurements and techniques for intermittent demand. *International Journal of Production Economics*, 128(2), 625–636. <https://doi.org/10.1016/j.ijpe.2010.07.013>

- Waters, D. (2003). Inventory Control and Management. Em *The Journal of the Operational Research Society* (Vol. 44, Número 3). <https://doi.org/10.2307/2584204>
- White, H. (1992). *Artificial Neural Networks: Approximation and Learning Theory*. Blackwell, Oxford, UK.
- Willemain, T., Smart, C., & Schwarz, H. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of Forecasting*, 20(3), 375–387. [https://doi.org/10.1016/S0169-2070\(03\)00013-X](https://doi.org/10.1016/S0169-2070(03)00013-X)
- Winters, P. R. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. *Management Science*, 6(3), 324–342. <https://doi.org/10.1287/mnsc.6.3.324>
- Wu, X., & Wolak, F. (2018). *Consumer Search with Learning : A Structural Estimation of Gasoline Demand*.
- Yeh, Q., Chang, T., & Chang, H. (1997). An inventory control model with gamma distribution. *Microelectronics Reliability*, 37(8), 1197–1201. [https://doi.org/https://doi.org/10.1016/S0026-2714\(96\)00295-8](https://doi.org/https://doi.org/10.1016/S0026-2714(96)00295-8)
- Yin, R. K. (2003). *Case study research: Design and methods* (4.^a ed.). Sage Publications.
- Young, W., & Weckman, G. (2010). Using a heuristic approach to derive a grey-box model through an artificial neural network knowledge extraction technique. *Neural Computing and Applications*, 19(3), 353–366. <https://doi.org/10.1007/s00521-009-0270-2>

Anexo I – Pneus: Análise dos pressupostos dos modelos

1. Medidas de pneus com vendas agrupadas por mês

Para as medidas de pneus com vendas agrupadas por mês, uma análise dos pressupostos assumidos na RLM com distribuição normal demonstra que a homocedasticidade e a independência dos resíduos são sempre cumpridas, enquanto a normalidade falha em 77% das medidas (para $\alpha = 0,05$). Relativamente aos coeficientes das variáveis independentes, o tempo (t) tem impacto estatisticamente significativo em 29% das medidas, a influência dos meses de outono e inverno (c) é estatisticamente significativa em 26% das medidas e o efeito dos meses de verão (v) é estatisticamente significativo em apenas 10% das medidas. Assim, o modelo faz sentido globalmente somente em 35% das medidas, como se verifica na Tabela 36.

Tabela 36 – Análise dos pressupostos dos modelos de RLM para as medidas de pneus com vendas agrupadas por mês.

Erros			Coeficientes			Modelo
Homocedasticidade	Normalidade	Independência	t	c	v	
Cumpre			Estatisticamente significativo			
31 (100%)	7 (23%)	31 (100%)	9 (29%)	8 (26%)	3 (10%)	11 (35%)
Não Cumpre			Estatisticamente não significativo			
0 (0%)	24 (77%)	0 (0%)	22 (71%)	23 (74%)	28 (90%)	20 (65%)

No caso dos MLG com distribuição de Poisson (que são válidos em 87% das medidas), o modelo faz sentido globalmente em 93% destas medidas, o tempo (t) tem impacto estatisticamente significativo em 70% destas medidas, a influência dos meses de outono e inverno (c) é estatisticamente significativa em 74% destas medidas e o efeito dos meses de verão (v) é estatisticamente significativo em 41%, de acordo com a Tabela 37.

Atendendo à RLM (que é válida em 10% das medidas), o modelo faz sentido globalmente em 67% das medidas, o tempo (t) tem impacto estatisticamente significativo em apenas 33% das medidas e o efeito dos meses de outono e inverno (c) e dos meses de verão (v) é estatisticamente significativo em 67% das medidas.

O MLG com distribuição binomial negativa adequa-se a apenas uma medida, sendo que o modelo faz sentido globalmente, mas somente a influência do tempo (t) é estatisticamente significativa.

Tabela 37 – Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus com vendas agrupadas por mês.

Distribuição	Modelos Válidos	Estatisticamente Significativo			
		t	c	v	Modelo
Normal	3 (10%)	1 (33%)	2 (67%)	2 (67%)	2 (67%)
Poisson	27 (87%)	19 (70%)	20 (74%)	11 (41%)	25 (93%)
Binomial Negativa	1 (3%)	1 (100%)	0 (0%)	0 (0%)	1 (100%)

2. Medidas de pneus com vendas agrupadas por trimestre

Quanto às medidas de pneus com vendas agrupadas por trimestre, uma análise dos pressupostos assumidos na RLM com distribuição normal mostra que a homocedasticidade dos resíduos é cumprida em todas as medidas, a normalidade em 78% e a independência em 91% (para $\alpha = 0,05$). Relativamente aos coeficientes das variáveis independentes, o tempo (t) tem impacto estatisticamente significativo em 43% das medidas, a influência do 3º trimestre (c) é estatisticamente significativa em 5% das medidas e o efeito do 4º trimestre (v) é estatisticamente significativo somente em 5% das medidas. No entanto, o modelo faz sentido globalmente em 30% das medidas, de acordo com a Tabela 38.

Tabela 38 - Análise dos pressupostos dos modelos de RLM para as medidas de pneus com vendas agrupadas por trimestre.

Erros			Coeficientes			Modelo
Homocedasticidade	Normalidade	Independência	t	c	v	
Cumpre			Estatisticamente significativo			
23 (100%)	18 (78%)	21 (91%)	10 (43%)	1 (5%)	1 (5%)	7 (30%)
Não Cumpre			Estatisticamente não significativo			
0 (0%)	5 (22%)	2 (9%)	13 (57%)	22 (95%)	19 (95%)	16 (70%)

No caso dos MLG com distribuição de Poisson (que são válidos em 70% das medidas), o modelo faz sentido globalmente em 88% destas medidas, o tempo (t) tem impacto estatisticamente significativo em 81% destas medidas e o efeito dos 3º e 4º trimestres (c e v) é estatisticamente significativo em 38% destas medidas, como verificado na Tabela 39.

Atendendo à distribuição normal (que corresponde ao modelo válido em 30% das medidas), o modelo faz sentido globalmente em 57% das medidas, o tempo (t) tem impacto estatisticamente significativo em 57% das medidas e a influência do 3º trimestre (c) é estatisticamente significativa em apenas 14% das medidas, sendo que o efeito do 4º trimestre (v) nunca é estatisticamente significativo.

Tabela 39 - Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus com vendas agrupadas por trimestre.

Distribuição	Modelos Válidos	Estatisticamente Significativo			
		t	c	v	Modelo
Normal	7 (30%)	4 (57%)	1 (14%)	0 (0%)	4 (57%)
Poisson	16 (70%)	13 (81%)	6 (38%)	6 (38%)	14 (88%)

3. Medidas de pneus com vendas agrupadas por semestre

Relativamente às medidas de pneus com vendas agrupadas por semestre, uma análise dos pressupostos assumidos na RLM com distribuição normal permite observar que a homocedasticidade dos resíduos é cumprida em todas as medidas, a normalidade em 93% e a independência em 89% (para $\alpha = 0,05$). Relativamente à significância estatística dos coeficientes das variáveis independentes, o tempo (t) tem impacto estatisticamente significativo em somente 11% das medidas e o efeito do 2º semestre (β_2) é estatisticamente

significativo em apenas 7% das medidas. De facto, o modelo faz sentido globalmente só para 7% das medidas, como decorre da análise da Tabela 40.

Tabela 40 - Análise dos pressupostos dos modelos de RLM para as medidas de pneus com vendas agrupadas por semestre.

Erros			Coeficientes		Modelo
Homocedasticidade	Normalidade	Independência	t	s	
Cumprido			Estatisticamente significativo		
28 (100%)	26 (93%)	25 (89%)	3 (11%)	2 (7%)	2 (7%)
Não Cumprido			Estatisticamente não significativo		
0 (0%)	2 (7%)	3 (11%)	25 (89%)	25 (89%)	26 (93%)

No caso dos MLG com distribuição de Poisson (que são válidos em 54% das medidas), o modelo faz sentido globalmente em 73% destas medidas e o impacto do tempo (t) e do 2º semestre (s) é estatisticamente significativo em 47% destas medidas, de acordo com a Tabela 41.

Atendendo à distribuição normal (que é válida em 46% das medidas), o modelo faz sentido globalmente em apenas 23% destas medidas, o impacto do tempo (t) é estatisticamente significativo em 23% destas medidas e a influência do 2º semestre (s) é estatisticamente significativa somente em 8% destas medidas.

Tabela 41 - Análise da significância dos modelos de RLM e MLG e dos seus coeficientes, para as medidas de pneus com vendas agrupadas por semestre.

Distribuição	Modelos Válidos	Estatisticamente Significativo		
		t	s	Modelo
Normal	13 (46%)	3 (23%)	1 (8%)	3 (23%)
Poisson	15 (54%)	7 (47%)	7 (47%)	11 (73%)

Anexo II – Pneus: Resultados obtidos para o modelo de previsão

1. Medidas de pneus com vendas agrupadas por mês

Tabela 42 – Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus com vendas agrupadas por mês. Apresentam-se as medidas, o número de unidades vendidas e o número de meses com observações.

Medida de Pneus	Medida de Avaliação	AES	Holt	RLM / MLG	Croston	ASB	Previsões Combinadas	
							Média simples	Média ponderada
155/70R13 320 Un. 99 Obs	REQM	2,537	2,567	2,335	2,612	2,538	2,396	2,392
	Inv.Médio	22,990	5,735	7,566	27,867	7,337	16,684	15,633
	%Rotura	1,020%	20,408%	10,101%	15,306%	16,327%	1,020%	1,020%
155/80R13 171 Un. 94 Obs	PEI médio	952	-778	131	-296	-1171	542	12
	REQM	2,197	2,392	2,114	2,318	2,319	2,230	2,229
	Inv.Médio	6,634	8,419	6,883	4,516	4,516	5,624	5,624
165/65R14 430 Un. 103 Obs	%Rotura	10,753%	19,355%	10,638%	31,183%	31,183%	18,280%	18,280%
	PEI médio	35	-616	93	-1358	-1364	-661	-16
	REQM	3,223	3,186	3,072	3,358	3,273	3,046	3,212
165/65R14 430 Un. 103 Obs	Inv.Médio	6,559	27,059	8,262	25,451	14,333	10,432	12,153
	%Rotura	22,549%	12,745%	16,505%	18,627%	23,529%	3,922%	17,347%
	PEI médio	-1428	499	117	-897	-1067	296	-7

	REQM	4,079	3,961	3,667	4,417	4,397	3,964	3,963
165/70R13 545 Un. 105 Obs	Inv.Médio	10,529	11,952	11,857	16,135	12,529	10,529	10,529
	%Rotura	19,231%	20,192%	5,714%	18,269%	24,038%	20,192%	21,429%
	PEI médio	-1898	-1074	-156	-3036	-3255	-1486	-30
	REQM	2,800	2,720	2,622	2,796	2,800	2,718	2,718
165/70R14 316 Un. 102 Obs	Inv.Médio	25,594	6,673	18,167	10,406	15,891	5,624	5,644
	%Rotura	0,000%	16,832%	9,804%	20,792%	20,792%	22,772%	22,772%
	PEI médio	1275	-713	-49	-1874	-1848	-1293	-29
	REQM	6,526	6,542	6,063	7,964	8,237	6,455	6,455
175/65R14 1539 Un. 104 Obs	Inv.Médio	17,136	52,350	17,788	17,845	6,010	20,845	20,845
	%Rotura	24,272%	1,942%	4,854%	18,447%	42,718%	7,767%	7,767%
	PEI médio	-2690	1841	76	-4792	-9252	-425	-8
	REQM	2,610	2,611	2,475	2,663	2,630	2,580	2,580
175/70R13 314 Un. 104 Obs	Inv.Médio	23,680	17,447	8,942	23,854	11,427	19,369	19,369
	%Rotura	0,971%	1,942%	8,738%	10,680%	13,592%	0,971%	0,971%
	PEI médio	1032	627	12	-483	-664	829	18
	REQM	1,917	1,942	1,835	1,877	1,876	1,876	1,876
175/70R14 171 Un. 101 Obs	Inv.Médio	7,520	16,870	4,020	3,150	3,150	3,150	3,150
	%Rotura	18,000%	2,000%	18,812%	28,000%	28,000%	28,000%	28,000%
	PEI médio	506	644	136	-336	-332	-334	-10
	REQM	3,039	3,170	2,952	3,252	3,156	3,019	3,018
185/55R15 391 Un. 104 Obs	Inv.Médio	16,248	10,406	13,168	34,347	12,822	14,545	14,554
	%Rotura	7,767%	17,476%	8,654%	14,563%	15,534%	13,592%	12,621%
	PEI médio	187	-1127	255	-708	-821	-317	-6
	REQM	5,028	5,171	4,625	5,163	5,183	5,070	5,069
185/60R14 860 Un. 106 Obs	Inv.Médio	20,790	59,619	11,726	26,505	8,914	23,248	23,248
	%Rotura	9,524%	4,762%	11,321%	9,524%	20,000%	9,524%	9,524%
	PEI médio	-2230	1812	-238	-2266	-3910	-2248	-40
	REQM	2,702	2,577	2,435	2,521	2,525	2,523	2,523
185/60R15 256 Un. 100 Obs	Inv.Médio	15,556	5,525	12,190	6,990	6,990	6,990	6,990
	%Rotura	7,071%	14,141%	11,000%	13,131%	13,131%	12,000%	13,000%
	PEI médio	880	111	6	-404	-425	-414	-9
	REQM	2,631	2,759	2,439	2,782	2,957	2,649	2,648
185/65R14 224 Un. 103 Obs	Inv.Médio	25,696	6,765	8,350	7,127	18,559	9,961	9,961
	%Rotura	2,941%	15,686%	8,738%	37,255%	11,765%	7,843%	7,843%
	PEI médio	916	-764	-10	-2561	-560	76	4
	REQM	4,582	4,457	4,174	4,577	4,685	4,448	4,447
185/65R15 804 Un. 104 Obs	Inv.Médio	5,194	43,049	17,654	6,738	4,359	18,922	20,573
	%Rotura	33,010%	3,883%	9,615%	31,068%	43,689%	7,767%	7,767%
	PEI médio	-1857	1499	-259	-1869	-2756	-185	-3
	REQM	2,782	2,769	2,665	2,951	2,814	2,767	2,767
185R14 348 Un. 105 Obs	Inv.Médio	13,466	22,184	14,592	50,282	24,398	16,029	15,875
	%Rotura	13,725%	6,863%	9,709%	8,824%	14,706%	9,804%	12,245%
	PEI médio	-663	317	-164	139	-886	-173	0
	REQM	2,988	2,901	2,774	3,073	3,036	2,900	2,899
195/50R15 374 Un. 103 Obs	Inv.Médio	36,882	10,098	16,631	19,402	10,637	20,873	19,892
	%Rotura	0,980%	7,843%	1,942%	16,667%	17,647%	0,980%	0,980%
	PEI médio	1526	-592	83	-1278	-1252	467	11

	REQM	2,687	2,792	2,569	2,903	2,782	2,665	2,664
195/55R15 270 Un. 104 Obs	Inv.Médio	21,184	25,670	4,981	9,408	5,155	8,534	8,786
	%Rotura	0,000%	1,942%	8,654%	35,922%	21,359%	6,796%	6,796%
	PEI médio	815	941	167	-2468	-829	-7	0
	REQM	2,694	2,838	2,624	2,976	2,883	2,733	2,731
195/60R15 376 Un. 104 Obs	Inv.Médio	19,039	25,214	8,250	39,194	20,068	21,563	22,126
	%Rotura	3,883%	7,767%	3,846%	16,505%	13,592%	3,883%	3,883%
	PEI médio	167	816	59	-803	-878	492	14
	REQM	6,343	6,753	5,958	6,852	6,987	6,411	6,404
195/65R15 1255 Un. 104 Obs	Inv.Médio	10,583	19,214	16,865	6,942	4,194	8,806	8,718
	%Rotura	21,359%	12,621%	6,731%	30,097%	45,631%	17,476%	17,476%
	PEI médio	-953	-1988	12	-5008	-6152	-1471	-41
	REQM	3,227	3,330	3,005	3,500	3,498	3,228	3,227
195/70R15 347 Un. 106 Obs	Inv.Médio	9,114	32,067	9,533	12,248	12,248	12,686	11,829
	%Rotura	22,857%	2,857%	12,264%	32,381%	32,381%	5,714%	5,714%
	PEI médio	-1263	983	-46	-3334	-3235	-140	-1
	REQM	4,339	4,487	4,210	4,565	4,537	4,402	4,401
195/75R16 496 Un. 104 Obs	Inv.Médio	6,466	9,874	8,835	16,524	12,689	8,466	8,466
	%Rotura	26,214%	17,476%	9,615%	21,359%	19,417%	17,476%	17,476%
	PEI médio	-1422	-1395	166	-2311	-2126	-1409	-34
	REQM	2,810	2,900	2,705	2,801	2,803	2,802	2,802
205/50R17 257 Un. 103 Obs	Inv.Médio	17,725	6,882	11,291	4,167	4,098	4,167	4,167
	%Rotura	4,902%	22,549%	5,825%	21,569%	21,569%	21,569%	21,569%
	PEI médio	852	-755	-86	-1143	-1134	-1139	-24
	REQM	9,140	9,145	8,130	10,780	11,221	8,453	8,423
205/55R16 2391 Un. 104 Obs	Inv.Médio	8,981	52,087	19,788	17,699	4,786	10,961	11,049
	%Rotura	25,243%	5,825%	5,769%	23,301%	51,456%	19,417%	19,417%
	PEI médio	-4161	1329	-244	-8225	-13348	-2202	-56
	REQM	4,144	4,427	4,011	4,463	4,410	4,185	4,190
205/60R15 565 Un. 103 Obs	Inv.Médio	21,549	13,216	12,175	28,745	14,637	16,735	13,853
	%Rotura	5,882%	16,667%	11,650%	16,667%	20,588%	15,686%	21,569%
	PEI médio	433	-1369	112	-1749	-2451	-1009	-31
	REQM	2,337	2,361	2,197	2,295	2,290	2,292	2,292
215/55R16 266 Un. 104 Obs	Inv.Médio	10,641	7,350	10,240	6,107	7,893	7,922	7,922
	%Rotura	6,796%	12,621%	7,692%	21,359%	15,534%	19,417%	19,417%
	PEI médio	768	-545	146	-940	-887	-914	-19
	REQM	1,775	1,899	1,710	1,847	1,849	1,780	1,779
215/75R16 168 Un. 93 Obs	Inv.Médio	13,000	19,272	8,419	6,163	6,163	7,109	7,109
	%Rotura	0,000%	7,609%	8,602%	30,435%	30,435%	13,043%	13,043%
	PEI médio	480	557	47	-804	-809	-162	-4
	REQM	4,893	5,060	4,545	5,114	5,144	4,952	4,950
225/45R17 772 Un. 104 Obs	Inv.Médio	12,757	13,146	17,587	21,835	12,301	13,951	13,951
	%Rotura	28,155%	22,330%	10,577%	23,301%	30,097%	23,301%	23,301%
	PEI médio	-1671	-1653	-127	-2326	-3287	-1662	-40
	REQM	2,765	2,919	2,697	2,810	2,700	2,686	2,686
225/55R16 278 Un. 103 Obs	Inv.Médio	6,069	10,520	8,563	18,902	6,049	6,873	6,873
	%Rotura	22,549%	18,627%	13,592%	12,745%	7,843%	10,784%	10,784%
	PEI médio	-570	-800	186	-261	-131	-351	-9

235/45R17 210 Un. 104 Obs	REQM	2,310	2,112	2,090	2,136	2,136	2,105	2,105
	Inv.Médio	15,214	15,864	9,442	5,078	6,641	8,874	8,874
	%Rotura	0,000%	5,825%	5,769%	29,126%	29,126%	25,243%	25,243%
	PEI médio	890	353	38	-671	-672	-159	-5
315/70R22,5 273 Un. 106 Obs	REQM	3,128	2,975	2,820	2,900	2,882	2,846	2,846
	Inv.Médio	24,143	13,324	11,594	8,238	21,752	11,867	11,867
	%Rotura	0,000%	8,571%	8,491%	24,762%	9,524%	15,230%	15,238%
	PEI médio	1227	-520	424	-1052	215	-418	-7
315/80R22,5 2216 Un. 106 Obs	REQM	12,102	12,093	10,397	13,281	13,388	11,926	11,926
	Inv.Médio	34,467	40,371	30,972	37,743	16,552	36,019	36,019
	%Rotura	13,333%	20,000%	11,321%	19,048%	31,429%	14,286%	14,286%
	PEI médio	-5075	-4118	-76	-9058	-12623	-4596	-99
385/65R22,5 1208 Un. 104 Obs	REQM	6,978	7,064	6,414	7,550	7,689	6,916	6,916
	Inv.Médio	13,738	16,728	27,519	17,495	6,699	14,650	14,816
	%Rotura	17,476%	16,505%	7,692%	18,447%	38,835%	20,388%	20,388%
	PEI médio	-3287	-2352	-628	-4061	-6791	-2819	-65

2. Medidas de pneus com vendas agrupadas por trimestre

Tabela 43 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus com vendas agrupadas por trimestre. Apresentam-se as medidas, o número de unidades vendidas e o número de trimestres com observações.

Medida De Pneus	Medida De Avaliação	AES	Holt	RLM / MLG	Croston	ASB	Previsões Combinadas	
							Média simples	Média ponderada
9,5R17,5 110 Un. 35 Obs	REQM	3,113	3,103	2,695	3,154	3,168	3,056	3,056
	Inv.Médio	14,294	11,794	5,257	3,206	2,618	13,676	13,676
	%Rotura	0,000%	11,765%	14,286%	41,176%	41,176%	8,824%	8,824%
	PEI médio	219	63	-32	-264	-271	141	11
13,5R22,5 137 Un. 35 Obs	REQM	4,178	4,366	3,712	3,976	3,968	3,958	4,593
	Inv.Médio	2,559	3,294	4,829	3,559	2,559	2,735	0,706
	%Rotura	29,412%	32,353%	22,857%	32,353%	38,235%	38,235%	70,588%
	PEI médio	-132	-156	42	-93	-117	-105	-31
145/80R13 94 Un. 33 Obs	REQM	2,464	2,595	2,478	2,849	2,600	2,462	2,461
	Inv.Médio	7,313	13,156	5,031	17,344	3,906	9,344	9,344
	%Rotura	15,625%	12,500%	12,121%	15,625%	31,250%	15,625%	15,625%
	PEI médio	-48	80	-17	-15	-283	16	3
165/65R13 165 Un. 35 Obs	REQM	3,853	3,953	3,615	4,055	3,920	3,785	3,784
	Inv.Médio	3,235	11,824	4,800	17,029	4,118	3,000	3,000
	%Rotura	38,235%	14,706%	25,714%	32,353%	35,294%	38,235%	38,235%
	PEI médio	-283	63	-27	-147	-400	-341	-23
175/75R16 160 Un. 34 Obs	REQM	3,566	3,815	3,156	4,210	4,161	3,424	3,420
	Inv.Médio	2,970	6,000	8,824	7,848	6,091	3,818	3,818
	%Rotura	33,333%	27,273%	8,824%	33,333%	27,273%	27,273%	27,273%
	PEI médio	-300	-110	-18	-465	-469	-205	-16
185/75R16 124 Un. 32 Obs	REQM	4,104	4,301	3,864	4,055	3,933	3,970	3,969
	Inv.Médio	9,387	3,226	9,000	11,032	5,613	7,742	7,742
	%Rotura	9,677%	25,806%	12,500%	12,903%	25,806%	22,581%	22,581%
	PEI médio	113	-91	74	-95	-148	-121	-8

195/55R16 133 Un. 35 Obs	REQM	3,110	3,159	2,454	3,002	3,081	3,030	3,030
	Inv.Médio	4,147	2,206	4,429	3,324	2,176	2,529	2,529
	%Rotura	20,588%	41,176%	22,857%	38,235%	50,000%	41,176%	41,176%
	PEI médio	22	-65	4	-97	-149	-123	-12
205/60R16 115 Un. 35 Obs	REQM	2,798	2,730	2,337	2,388	2,556	2,443	2,440
	Inv.Médio	7,059	4,382	5,343	5,412	1,588	2,265	2,265
	%Rotura	5,882%	23,529%	17,143%	8,824%	41,176%	35,294%	35,294%
	PEI médio	107	-77	42	46	-48	-1	-2
205/65R15 126 Un. 35 Obs	REQM	3,286	2,642	2,605	2,639	2,663	2,581	2,581
	Inv.Médio	17,676	3,353	6,286	4,912	1,735	3,441	3,441
	%Rotura	0,000%	26,471%	5,714%	29,412%	38,235%	26,471%	26,471%
	PEI médio	276	-60	135	-147	-241	-103	-9
205/75R17,5 83 Un. 34 Obs	REQM	2,386	2,290	1,584	2,317	2,350	1,814	1,752
	Inv.Médio	2,697	1,455	3,118	1,727	1,515	1,424	1,455
	%Rotura	27,273%	39,394%	11,765%	33,333%	33,333%	36,364%	36,364%
	PEI médio	18	-40	-17	-90	-109	-29	-2
205/80R16 139 Un. 35 Obs	REQM	3,254	3,295	2,935	3,548	3,533	3,233	3,233
	Inv.Médio	2,294	3,647	3,857	2,735	2,912	2,824	2,824
	%Rotura	32,353%	35,294%	17,143%	41,176%	41,176%	32,353%	32,353%
	PEI médio	-253	-85	-16	-417	-376	-169	-14
215/70R15 114 Un. 35 Obs	REQM	2,697	2,766	2,523	2,822	2,838	2,690	2,690
	Inv.Médio	5,529	12,029	8,914	4,029	3,941	7,882	7,882
	%Rotura	26,471%	14,706%	20,000%	29,412%	29,412%	17,647%	17,647%
	PEI médio	-74	104	-17	-240	-247	15	1
215/75R17,5 89 Un. 34 Obs	REQM	2,794	2,742	2,425	2,776	2,787	2,713	2,713
	Inv.Médio	3,364	9,636	4,853	2,455	2,455	6,848	6,848
	%Rotura	27,273%	24,242%	11,765%	36,364%	36,364%	30,303%	30,303%
	PEI médio	-25	-4	-10	-178	-184	-91	-5
225/40R18 94 Un. 31 Obs	REQM	3,585	3,341	2,696	3,590	3,703	3,430	3,426
	Inv.Médio	3,200	2,100	3,774	4,333	2,433	2,667	2,667
	%Rotura	16,667%	40,000%	25,806%	16,667%	26,667%	23,333%	23,333%
	PEI médio	21	-31	10	0	-28	-5	-3
225/50R17 143 Un. 34 Obs	REQM	3,517	3,383	3,047	3,518	3,580	3,431	3,430
	Inv.Médio	3,182	4,394	8,824	5,152	3,485	3,364	3,364
	%Rotura	45,455%	30,303%	26,471%	33,333%	51,515%	45,455%	45,455%
	PEI médio	-172	-25	-27	-240	-269	-99	-9
225/65R16 75 Un. 35 Obs	REQM	2,199	2,225	1,848	1,978	1,973	1,973	1,973
	Inv.Médio	7,824	3,765	4,771	3,059	2,118	2,294	2,294
	%Rotura	2,941%	20,588%	11,429%	17,647%	20,588%	17,647%	17,647%
	PEI médio	135	-47	27	-35	-42	-38	-3
235/75R17,5 134 Un. 35 Obs	REQM	3,865	3,928	3,636	4,122	4,132	3,857	3,857
	Inv.Médio	13,206	5,529	6,543	5,412	4,824	5,971	5,971
	%Rotura	2,941%	29,412%	20,000%	41,176%	41,176%	11,765%	11,765%
	PEI médio	235	-34	53	-267	-271	101	3
245/40R18 109 Un. 34 Obs	REQM	2,820	2,690	2,336	2,667	2,618	2,619	2,619
	Inv.Médio	19,606	2,727	4,971	2,182	3,455	2,758	2,758
	%Rotura	0,000%	30,303%	8,824%	51,515%	24,242%	36,364%	36,364%
	PEI médio	280	-59	51	-321	-210	-266	-17

245/45R17 99 Un. 35 Obs	REQM	2,964	3,110	2,761	2,938	2,949	2,942	2,942
	Inv.Médio	2,706	3,206	5,657	3,382	3,118	3,206	3,206
	%Rotura	47,059%	23,529%	22,857%	32,353%	32,353%	32,353%	32,353%
	PEI médio	-86	-22	-8	-175	-186	-181	-11
265/70R16 83 Un. 34 Obs	REQM	2,424	2,413	2,171	2,381	2,387	2,383	2,383
	Inv.Médio	5,242	1,727	3,882	2,061	2,000	2,061	2,061
	%Rotura	9,091%	39,394%	17,647%	42,424%	42,424%	42,424%	42,424%
	PEI médio	109	-26	37	-82	-89	-85	-8
265/70R19,5 91 Un. 34 Obs	REQM	2,418	2,312	2,265	2,778	2,649	2,311	2,310
	Inv.Médio	5,970	2,606	3,088	2,758	3,758	3,606	3,606
	%Rotura	9,091%	27,273%	23,529%	51,515%	24,242%	15,152%	15,152%
	PEI médio	-37	-28	11	-340	-194	-32	-3
650R16 130 Un. 34 Obs	REQM	3,496	3,513	3,128	4,280	4,260	3,376	3,376
	Inv.Médio	16,758	4,788	4,471	4,212	10,303	8,455	8,455
	%Rotura	3,030%	18,182%	14,706%	57,576%	39,394%	9,091%	9,091%
	PEI médio	92	-33	-45	-708	-438	29	2
700R16 113 Un. 32 Obs	REQM	2,878	2,904	2,449	2,830	2,826	2,819	2,819
	Inv.Médio	17,000	2,935	9,406	3,645	2,065	2,387	2,387
	%Rotura	3,226%	32,258%	6,250%	25,806%	32,258%	29,032%	29,032%
	PEI médio	231	-64	55	-249	-283	-266	-17

3. Medidas de pneus com vendas agrupadas por semestre

Tabela 44 - Resultados das medidas de avaliação para os diferentes métodos de previsão, para as medidas de pneus com vendas agrupadas por semestre. Apresentam-se as medidas, o número de unidades vendidas e o número de semestres com observações.

Medida De Pneus	Medida De Avaliação	AES	Holt	RLM / MLG	Croston	ASB	Previsão Combinada	
							Média simples	Média ponderada
135/80R13 52 Un. 18 Obs	REQM	2,749	2,963	2,272	2,915	2,827	2,628	2,628
	Inv.Médio	7,647	9,118	2,667	1,824	1,941	4,118	4,118
	%Rotura	0,000%	23,529%	27,778%	47,059%	47,059%	23,529%	23,529%
	PEI médio	54	11	4	-103	-74	-10	-1
145/70R13 79 Un. 18 Obs	REQM	3,348	3,205	2,751	3,365	3,409	3,173	3,171
	Inv.Médio	13,235	2,235	3,278	2,353	1,588	5,118	5,118
	%Rotura	0,000%	29,412%	22,222%	47,059%	52,941%	5,882%	5,882%
	PEI médio	96	-1	35	-106	-128	47	4
175/65R15 78 Un. 18 Obs	REQM	3,162	3,196	2,239	2,964	3,292	2,510	2,462
	Inv.Médio	7,000	2,118	6,444	3,412	1,118	3,765	3,765
	%Rotura	23,529%	29,412%	22,222%	41,176%	58,824%	23,529%	23,529%
	PEI médio	53	-13	5	-52	-83	-24	-3
175/80R14 74 Un. 18 Obs	REQM	2,990	2,889	2,476	3,097	3,149	2,855	2,855
	Inv.Médio	2,353	7,412	2,667	3,706	1,294	4,353	4,353
	%Rotura	35,294%	29,412%	22,222%	29,412%	52,941%	29,412%	29,412%
	PEI médio	-89	-16	-24	-93	-129	-53	-5
185/55R14 84 Un. 18 Obs	REQM	3,418	2,690	2,387	3,671	3,764	2,505	2,498
	Inv.Médio	2,941	6,000	1,389	3,706	1,059	3,765	3,176
	%Rotura	17,647%	11,765%	44,444%	29,412%	58,824%	11,765%	11,765%
	PEI médio	-96	33	-8	-138	-175	12	2

185/70R14 88 Un. 17 Obs	REQM	3,820	4,668	3,200	4,200	4,323	3,976	3,967
	Inv.Médio	1,250	9,313	4,059	1,563	0,813	1,313	1,313
	%Rotura	68,750%	37,500%	11,765%	62,500%	75,000%	68,750%	68,750%
	PEI médio	-79	-67	-6	-119	-139	-99	-15
185R15 94 Un. 18 Obs	REQM	3,810	4,173	3,305	4,321	4,211	3,822	3,814
	Inv.Médio	2,412	14,059	3,000	7,471	1,941	7,176	6,529
	%Rotura	47,059%	23,529%	33,333%	29,412%	58,824%	23,529%	23,529%
	PEI médio	-103	9	-19	-103	-169	-47	-5
195/60R14 78 Un. 18 Obs	REQM	4,267	3,862	3,166	4,192	4,138	3,721	3,716
	Inv.Médio	16,882	12,000	6,278	8,000	2,294	6,882	6,882
	%Rotura	5,882%	5,882%	11,111%	29,412%	41,176%	11,765%	11,765%
	PEI médio	118	43	38	-91	-144	-51	-5
195/65R16 83 Un. 18 Obs	REQM	3,638	3,952	3,245	4,087	3,908	3,568	3,563
	Inv.Médio	4,000	5,529	3,389	6,000	2,471	2,412	2,471
	%Rotura	17,647%	29,412%	22,222%	35,294%	52,941%	58,824%	58,824%
	PEI médio	17	-1	3	-58	-130	-56	-8
195/70R14 66 Un. 18 Obs	REQM	2,852	3,065	2,454	2,844	2,910	2,613	2,671
	Inv.Médio	10,824	2,176	5,278	2,118	1,118	3,941	8,059
	%Rotura	5,882%	47,059%	16,667%	41,176%	58,824%	11,765%	5,882%
	PEI médio	74	10	11	-82	-102	-4	5
195R14 74 Un. 18 Obs	REQM	2,936	2,756	2,562	3,653	3,627	2,566	2,563
	Inv.Médio	4,529	2,529	3,444	2,647	1,882	2,706	2,529
	%Rotura	29,412%	47,059%	27,778%	35,294%	47,059%	41,176%	41,716%
	PEI médio	-28	-18	-23	-149	-152	-23	-4
205/45R16 91 Un. 17 Obs	REQM	4,405	4,036	3,468	4,773	4,824	3,986	3,978
	Inv.Médio	2,250	3,438	4,941	2,500	1,625	2,063	2,063
	%Rotura	50,000%	37,500%	17,647%	43,750%	50,000%	56,250%	56,250%
	PEI médio	-136	-6	-32	-171	-193	-71	-10
205/45R17 48 Un. 18 Obs	REQM	2,701	2,935	2,567	2,958	2,980	2,722	2,718
	Inv.Médio	5,059	5,000	2,833	2,294	1,882	4,294	4,294
	%Rotura	5,882%	17,647%	27,778%	35,294%	41,176%	11,765%	11,765%
	PEI médio	45	-1	16	-63	-66	22	3
205/55R15 56 Un. 17 Obs	REQM	3,657	4,296	3,232	3,756	3,828	3,553	2,422
	Inv.Médio	11,000	1,875	5,294	3,250	2,813	5,875	3,765
	%Rotura	0,000%	31,250%	17,647%	31,250%	37,500%	12,500%	23,529%
	PEI médio	73	-16	6	-60	-64	7	-3
205/65R16 78 Un. 18 Obs	REQM	3,375	3,135	2,305	3,021	3,317	2,468	2,610
	Inv.Médio	1,588	1,882	3,000	4,353	0,882	4,059	3,688
	%Rotura	41,176%	35,294%	16,667%	23,529%	47,059%	23,529%	25,000%
	PEI médio	-47	-65	-8	-39	-93	-24	-2
215/50R17 49 Un. 17 Obs	REQM	2,772	2,752	2,501	2,838	2,888	2,610	3,505
	Inv.Médio	1,625	6,313	3,529	1,813	1,813	3,688	1,100
	%Rotura	43,750%	25,000%	29,412%	43,750%	43,750%	25,000%	70,000%
	PEI médio	-28	-15	-8	-64	-71	-21	-8
215/55R17 55 Un. 11 Obs	REQM	3,715	3,348	2,820	3,956	4,171	3,515	2,841
	Inv.Médio	1,000	1,100	2,091	1,500	0,700	1,100	4,000
	%Rotura	60,000%	70,000%	18,182%	70,000%	70,000%	70,000%	11,765%
	PEI médio	-33	-33	1	-50	-62	-33	-1

215/60R16 69 Un. 18 Obs	REQM	3,187	3,835	2,826	3,205	3,314	2,841	2,922
	Inv.Médio	11,471	11,882	7,889	1,353	1,176	4,000	4,111
	%Rotura	5,882%	11,765%	11,111%	41,176%	41,176%	11,765%	33,333%
	PEI médio	88	75	20	-103	-120	-7	-6
225/50R16 52 Un. 19 Obs	REQM	2,942	3,085	2,616	3,300	3,313	2,924	2,178
	Inv.Médio	1,778	6,333	3,474	2,556	2,556	4,167	4,000
	%Rotura	38,889%	22,222%	10,526%	38,889%	38,889%	33,333%	23,529%
	PEI médio	-92	-23	-14	-143	-145	-58	3
225/70R15 47 Un. 18 Obs	REQM	2,208	2,160	1,885	2,515	2,412	2,178	2,521
	Inv.Médio	5,176	3,647	2,778	1,353	3,235	4,000	1,824
	%Rotura	0,000%	29,412%	16,667%	58,824%	47,059%	23,529%	52,941%
	PEI médio	29	7	4	-104	-79	18	-6
235/70R16 49 Un. 18 Obs	REQM	2,638	2,516	2,226	2,699	2,595	2,521	2,892
	Inv.Médio	7,353	2,412	3,278	1,824	2,412	1,882	2,750
	%Rotura	0,000%	29,412%	22,222%	52,941%	47,059%	47,059%	37,500%
	PEI médio	73	-22	19	-56	-48	-35	-7
235/75R15 75 Un. 17 Obs	REQM	3,040	2,841	2,561	3,350	3,471	2,896	2,669
	Inv.Médio	2,000	3,188	4,471	1,188	0,688	2,500	2,294
	%Rotura	31,250%	37,500%	11,765%	50,000%	56,250%	37,500%	17,647%
	PEI médio	-68	-16	-17	-112	-129	-42	-5
245/40R17 50 Un. 18 Obs	REQM	3,098	3,127	2,510	2,645	2,706	2,669	2,771
	Inv.Médio	13,000	3,471	9,278	2,294	2,176	2,294	1,412
	%Rotura	5,882%	23,529%	11,111%	17,647%	23,529%	17,647%	52,941%
	PEI médio	83	-2	10	-40	-53	-47	-6
245/45R18 65 Un. 18 Obs	REQM	2,959	2,700	2,404	2,903	3,092	2,775	2,177
	Inv.Médio	1,765	1,529	3,278	1,412	0,882	1,412	1,765
	%Rotura	47,059%	52,941%	16,667%	52,941%	64,706%	52,941%	29,412%
	PEI médio	-21	-17	0	-54	-74	-36	-2
285/70R19,5 61 Un. 18 Obs	REQM	2,262	2,227	2,020	2,368	2,478	2,177	2,880
	Inv.Médio	1,471	1,824	1,500	1,353	0,294	1,765	2,235
	%Rotura	47,059%	35,294%	44,444%	41,176%	76,471%	29,412%	41,176%
	PEI médio	7	-18	14	-53	-77	-5	-5
295/80R22,5 50 Un. 18 Obs	REQM	3,024	3,182	2,761	2,995	2,892	2,881	2,645
	Inv.Médio	1,176	1,588	2,944	3,529	1,588	2,412	1,400
	%Rotura	47,059%	41,176%	16,667%	29,412%	52,941%	41,176%	53,333%
	PEI médio	-15	-22	7	-19	-54	-37	-9
385/55R22,5 53 Un. 16 Obs	REQM	2,877	3,213	1,789	2,638	2,814	2,648	2,054
	Inv.Médio	1,133	5,733	2,063	2,867	0,467	1,400	1,438
	%Rotura	46,667%	33,333%	37,500%	33,333%	73,333%	53,333%	43,750%
	PEI médio	-55	-17	-22	-42	-84	-63	-3
750R16 37 Un. 17 Obs	REQM	2,217	2,000	1,742	2,323	2,343	2,059	2,422
	Inv.Médio	1,438	8,063	1,706	1,375	1,375	1,438	3,765
	%Rotura	43,750%	6,250%	29,412%	43,750%	43,750%	43,750%	23,529%
	PEI médio	-57	-4	-25	-73	-77	-31	-3

Anexo III – Pneus: Resultados obtidos para as previsões futuras

1. Medidas de pneus agrupadas por mês

Tabela 45 – Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por mês, sem revisão dos dados e com revisão a cada 1, 2, 4 e 6 meses.

Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB	Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB
155/70R13 84,48% 320 Un. 99 Obs	Modelo	2,537	2,567	2,335	2,612	2,538	195/60R15 84,43% 376 Un. 104 Obs	Modelo	2,694	2,838	2,624	2,976	2,883
	Igual a mar/20	1,535	1,548		1,576	1,539		Igual a mar/20	2,913	2,037		3,078	2,953
	Mensal	1,596	1,393	1,599	1,681	1,580		Mensal	2,759	1,434	2,494	2,903	2,700
	2M	1,610	1,468		1,615	1,540		2M	2,772	1,528		2,996	2,830
	4M	1,645	1,552		1,653	1,583		4M	2,802	1,645		2,923	2,721
	6M	1,546	1,579		1,576	1,539		6M	2,832	1,740		3,078	2,953
155/80R13 59,24% 171 Un. 94 Obs	Modelo	2,197	2,392	2,114	2,318	2,319	195/65R15 98,10% 1255 Un. 104 Obs	Modelo	6,343	6,753	5,958	6,852	6,987
	Igual a mar/20	1,803	1,917		1,819	1,819		Igual a mar/20	5,197	5,485		5,149	5,776
	Mensal	1,803	1,665	1,798	1,826	1,826		Mensal	5,124	4,902	5,375	5,704	6,023
	2M	1,803	1,789		1,825	1,824		2M	5,267	5,242		5,877	6,191
	4M	1,803	1,808		1,827	1,826		4M	5,281	5,630		5,906	6,190
	6M	1,803	1,941		1,819	1,819		6M	5,309	5,071		5,309	5,685
165/65R14 82,79% 430 Un. 103 Obs	Modelo	3,223	3,186	3,072	3,358	3,273	195/70R15 71,92% 347 Un. 106 Obs	Modelo	3,227	3,330	3,005	3,500	3,498
	Igual a mar/20	2,423	2,406		2,469	2,375		Igual a mar/20	2,169	1,717		3,055	3,049
	Mensal	2,505	2,355	2,614	2,580	2,478		Mensal	2,023	1,611	1,949	3,011	2,996
	2M	2,554	2,412		2,575	2,474		2M	2,017	1,731		3,048	3,038
	4M	2,434	2,425		2,605	2,533		4M	2,040	1,686		3,049	3,039
	6M	2,416	2,369		2,589	2,478		6M	2,081	1,755		3,043	3,032
165/70R13 92,04% 545 Un. 105 Obs	Modelo	4,079	3,961	3,667	4,417	4,397	195/75R16 86,56% 496 Un. 104 Obs	Modelo	4,339	4,487	4,210	4,565	4,537
	Igual a mar/20	2,761	2,666		2,998	2,827		Igual a mar/20	5,410	3,306		5,408	5,357
	Mensal	2,798	2,586	2,987	2,977	2,879		Mensal	5,478	3,189	5,384	5,507	5,516
	2M	2,855	2,735		2,910	2,818		2M	5,471	3,361		5,504	5,521
	4M	2,776	2,694		2,957	2,870		4M	5,444	3,324		5,300	5,280
	6M	2,799	2,781		2,966	2,843		6M	5,398	3,388		5,387	5,352
165/70R14 71,74% 316 Un. 102 Obs	Modelo	2,800	2,720	2,622	2,796	2,800	205/50R17 68,46% 257 Un. 103 Obs	Modelo	2,810	2,900	2,705	2,801	2,803
	Igual a mar/20	4,107	4,351		4,115	4,104		Igual a mar/20	2,672	2,897		2,835	2,815
	Mensal	4,276	4,342	4,154	4,247	4,228		Mensal	2,705	2,722	2,569	3,000	2,974
	2M	4,287	4,367		4,183	4,169		2M	2,710	2,847		2,988	2,962
	4M	4,334	4,366		4,391	4,379		4M	2,712	2,941		2,985	2,961
	6M	4,107	4,338		4,147	4,130		6M	2,715	2,894		3,033	3,012

175/65R14 100,000% 1539 Un. 104 Obs	Modelo	6,526	6,542	6,063	7,964	8,237	205/55R16 100,000% 2391 Un. 104 Obs	Modelo	9,140	9,145	8,130	10,780	11,221
	Igual a mar/20	6,386	6,201		6,243	6,460		Igual a mar/20	14,045	15,910		13,952	15,523
	Mensual	6,419	6,165	6,816	7,544	7,162		Mensual	13,619	14,517	12,382	15,104	15,551
	2M	6,461	6,210		6,786	6,710		2M	13,907	14,753		16,120	16,347
	4M	6,374	6,204		6,262	6,425		4M	13,910	15,310		16,546	16,775
175/70R13 80,47% 314 Un. 104 Obs	6M	6,383	6,182		7,123	6,593	205/60R15 89,47% 565 Un. 103 Obs	6M	13,596	14,837		13,435	14,796
	Modelo	2,610	2,611	2,475	2,663	2,630		Modelo	4,144	4,427	4,011	4,463	4,410
	Igual a mar/20	2,345	3,688		3,985	3,784		Igual a mar/20	3,374	3,246		4,053	3,444
	Mensual	2,138	2,930	2,486	3,557	3,272		Mensual	3,289	2,084	2,820	2,881	2,496
	2M	2,146	2,964		3,805	3,578		2M	3,297	2,248		2,598	2,200
175/70R14 54,65% 171 Un. 101 Obs	4M	2,184	3,029		3,616	3,358	215/55R16 63,19% 266 Un. 104 Obs	4M	3,311	2,369		2,769	2,311
	6M	2,222	3,041		3,985	3,784		6M	3,329	2,414		3,223	2,686
	Modelo	1,917	1,942	1,835	1,877	1,876		Modelo	2,337	2,361	2,197	2,295	2,290
	Igual a mar/20	1,976	2,280		1,984	1,982		Igual a mar/20	2,110	1,947		2,615	2,518
	Mensual	2,014	2,203	2,115	2,071	2,070		Mensual	1,944	1,685	2,785	2,494	2,390
185/55R15 83,07% 391 Un. 104 Obs	2M	1,994	2,274		2,034	2,032	215/75R16 68,15% 168 Un. 93 Obs	2M	1,956	1,854		2,495	2,391
	4M	1,979	2,255		2,010	2,008		4M	1,989	1,886		2,534	2,435
	6M	1,974	2,271		1,984	1,982		6M	2,032	1,908		2,615	2,518
	Modelo	3,039	3,170	2,952	3,252	3,156		Modelo	1,775	1,899	1,710	1,847	1,849
	Igual a mar/20	3,109	2,692		3,004	2,842		Igual a mar/20	1,803	1,868		1,841	1,840
185/60R14 98,13% 860 Un. 106 Obs	Mensual	3,109	2,475	2,907	3,141	3,140	225/45R17 96,26% 772 Un. 104 Obs	Mensual	1,804	1,550	1,745	1,868	1,864
	2M	3,109	2,795		3,187	3,226		2M	1,804	1,847		1,890	1,887
	4M	3,109	2,934		3,169	3,161		4M	1,804	1,822		1,842	1,840
	6M	3,109	2,737		2,955	2,883		6M	1,804	1,896		1,882	1,879
	Modelo	5,028	5,171	4,625	5,163	5,183		Modelo	4,893	5,060	4,545	5,114	5,144
185/60R14 98,13% 860 Un. 106 Obs	Igual a mar/20	4,282	4,000		4,534	4,135	225/45R17 96,26% 772 Un. 104 Obs	Igual a mar/20	6,359	6,871		6,499	6,354
	Mensual	4,258	3,293	4,069	4,545	4,224		Mensual	6,560	5,765	5,829	7,246	6,925
	2M	4,496	3,863		4,362	4,037		2M	6,555	6,719		7,307	6,988
	4M	4,106	3,967		4,207	3,924		4M	6,472	6,839		7,089	6,802
	6M	4,238	4,092		4,560	4,147		6M	6,669	7,343		7,921	7,424

185/60R15 62,26% 256 Un. 100 Obs	Modelo	2,702	2,577	2,435	2,521	2,525	225/55R16 68,00% 278 Un. 103 Obs	Modelo	2,765	2,919	2,697	2,810	2,700
	Igual a mar/20	3,106	3,098		3,121	3,092		Igual a mar/20	1,938	2,423		2,752	2,194
	Mensal	3,160	3,125	3,820	3,368	3,317		Mensal	1,805	1,994	2,329	2,817	2,245
	2M	3,137	3,224		3,367	3,318		2M	1,828	2,033		2,811	2,254
	4M	3,091	3,248		3,241	3,198		4M	1,853	2,064		2,752	2,194
185/65R14 57,30% 224 Un. 103 Obs	6M	3,097	3,195		3,371	3,328	235/45R17 63,58% 210 Un. 104 Obs	6M	1,863	2,114		2,752	2,194
	Modelo	2,631	2,759	2,439	2,782	2,957		Modelo	2,310	2,112	2,090	2,136	2,136
	Igual a mar/20	1,858	1,889		2,179	2,389		Igual a mar/20	1,708	1,992		2,143	2,156
	Mensal	1,838	1,653	1,745	2,184	2,503		Mensal	1,564	1,759	2,149	2,245	2,256
	2M	1,866	1,702		2,177	2,326		2M	1,568	1,793		2,198	2,205
185/65R15 95,37% 804 Un. 104 Obs	4M	1,846	1,848		2,179	2,368	315/70R22,5 58,33% 273 Un. 106 Obs	4M	1,687	1,829		2,211	2,219
	6M	1,886	1,836		2,172	1,877		6M	1,571	1,826		2,143	2,156
	Modelo	4,582	4,457	4,174	4,577	4,685		Modelo	3,128	2,975	2,820	2,900	2,882
	Igual a mar/20	6,720	7,306		6,264	5,691		Igual a mar/20	4,560	3,646		4,159	3,973
	Mensal	6,010	6,025	7,396	6,020	5,588		Mensal	4,044	3,349	4,432	3,999	3,972
185R14 74,82% 348 Un. 105 Obs	2M	6,124	6,295		6,098	5,626	315/80R22,5 99,06% 2216 Un. 106 Obs	2M	4,225	3,461		3,942	3,761
	4M	6,174	6,508		6,054	5,609		4M	4,085	3,439		4,070	3,953
	6M	6,212	6,605		6,134	5,627		6M	4,198	3,758		3,988	3,822
	Modelo	2,782	2,769	2,665	2,951	2,814		Modelo	12,102	12,093	10,397	13,281	13,388
	Igual a mar/20	4,126	4,061		4,246	4,143		Igual a mar/20	12,318	14,530		12,594	13,643
195/50R15 86,44% 374 Un. 103 Obs	Mensal	4,327	3,824	4,041	4,496	4,421	385/65R22,5 100% 1208 Un. 104 Obs	Mensal	11,983	9,481	10,326	12,281	12,748
	2M	4,319	4,223		4,609	4,503		2M	11,964	10,188		11,826	12,385
	4M	4,200	4,127		4,504	4,402		4M	11,683	10,742		11,435	12,231
	6M	4,126	4,051		4,206	4,114		6M	11,740	11,960		11,420	12,129
	Modelo	2,988	2,901	2,774	3,073	3,036		Modelo	6,978	7,064	6,414	7,550	7,689
195/55R15 72,54% 270 Un. 104 Obs	Igual a mar/20	2,600	2,410		3,193	2,783	385/65R22,5 100% 1208 Un. 104 Obs	Igual a mar/20	9,140	9,195		10,725	11,530
	Mensal	2,225	2,201	2,573	3,145	2,743		Mensal	8,389	7,167	8,678	7,544	8,418
	2M	2,245	2,230		3,212	2,822		2M	8,413	7,297		7,724	8,796
	4M	2,327	2,309		3,092	2,679		4M	8,419	7,625		8,588	9,617
	6M	2,388	2,343		3,193	2,783		6M	8,724	8,664		7,948	9,067
195/55R15 72,54% 270 Un. 104 Obs	Modelo	2,687	2,792	2,569	2,903	2,782							
	Igual a mar/20	2,264	2,760		2,134	2,353							
	Mensal	2,240	1,999	2,244	2,150	2,484							
	2M	2,226	2,049		2,139	2,295							
	4M	2,227	2,302		2,147	2,457							
	6M	2,222	2,072		2,115	2,417							

2. Medidas de pneus com vendas agrupadas por trimestre

Tabela 46 - Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por trimestre, sem revisão dos dados e com revisão a cada 1 e 2 trimestres.

Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB	Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB
9,5R17,5 85,00% 110 Un. 35 Obs	Modelo	3,113	3,103	2,695	3,154	3,168	215/75R17,5 75,00% 89 Un. 34 Obs	Modelo	2,794	2,742	2,425	2,776	2,787
	Igual a abr/20	2,598	2,630		2,787	2,706		Igual a abr/20	2,265	3,682		2,896	2,798
	Trim	2,709	2,688	2,234	2,687	2,582		Trim	2,221	3,555	2,701	2,686	2,557
	2 Trim	2,608	2,619		2,741	2,656		2 Trim	2,162	3,501		2,896	2,798
13,5R22,5 61,82% 137 Un. 35 Obs	Modelo	4,178	4,366	3,712	3,976	3,968	225/40R18 53,57% 94 Un. 31 Obs	Modelo	3,585	3,341	2,696	3,590	3,703
	Igual a abr/20	2,048	2,048		3,207	2,221		Igual a abr/20	8,163	8,685		8,507	9,089
	Trim	2,170	2,255	3,877	2,639	2,263		Trim	9,110	8,774	2,899	8,758	9,162
	2 Trim	2,079	2,113		2,366	1,792		2 Trim	8,367	8,927		8,611	9,210
145/80R13 69,57% 94 Un. 33 Obs	Modelo	2,464	2,595	2,478	2,849	2,600	225/50R17 86,84% 143 Un. 34 Obs	Modelo	3,517	3,383	3,047	3,518	3,580
	Igual a abr/20	3,494	3,800		2,737	3,090		Igual a abr/20	3,120	3,277		3,224	3,401
	Trim	3,550	3,845	3,937	3,442	3,309		Trim	3,383	3,407	3,521	3,370	3,405
	2 Trim	4,472	5,082		3,858	3,403		2 Trim	3,201	3,251		3,439	3,493
165/65R13 85,00% 165 Un. 35 Obs	Modelo	3,853	3,953	3,615	4,055	3,920	225/65R16 70,83% 75 Un. 35 Obs	Modelo	2,199	2,225	1,848	1,978	1,973
	Igual a abr/20	2,743	1,028		2,385	1,519		Igual a abr/20	3,304	3,339		3,407	3,310
	Trim	2,726	1,044	2,000	2,298	1,488		Trim	3,521	3,625	5,119	3,386	3,325
	2 Trim	2,732	1,038		2,437	1,546		2 Trim	3,393	3,583		3,436	3,371
175/75R16 86,84% 160 Un. 34 Obs	Modelo	3,566	3,815	3,156	4,210	4,161	235/75R17,5 82,93% 134 Un. 35 Obs	Modelo	3,865	3,928	3,636	4,122	4,132
	Igual a abr/20	3,712	4,313		3,642	3,800		Igual a abr/20	1,803	3,242		3,157	3,054
	Trim	3,720	4,640	3,978	4,089	4,221		Trim	1,803	3,303	3,540	2,982	2,806
	2 Trim	3,725	5,066		3,970	4,096		2 Trim	1,803	3,307		3,075	2,901
185/75R16 68,89% 124 Un. 32 Obs	Modelo	4,104	4,301	3,864	4,055	3,933	245/40R18 82,50% 109 Un. 34 Obs	Modelo	2,820	2,690	2,336	2,667	2,618
	Igual a abr/20	2,598	3,387		2,725	2,598		Igual a abr/20	1,631	1,469		1,480	1,856
	Trim	3,011	3,381	3,224	2,796	2,621		Trim	1,675	1,589	1,947	1,586	2,135
	2 Trim	2,606	2,868		2,745	2,576		2 Trim	1,759	1,644		1,575	2,150
195/55R16 80,95% 133 Un. 35 Obs	Modelo	3,110	3,159	2,454	3,002	3,081	245/45R17 72,34% 99 Un. 35 Obs	Modelo	2,964	3,110	2,761	2,938	2,949
	Igual a abr/20	9,712	9,765		9,236	9,529		Igual a abr/20	1,816	2,264		2,413	2,104
	Trim	10,203	10,393	9,076	10,508	10,686		Trim	1,806	2,092	2,376	2,889	2,563
	2 Trim	9,436	9,403		9,924	10,196		2 Trim	1,794	2,088		2,726	2,394

205/60R16 68,00% 115 Un. 35 Obs	Modelo	2,798	2,730	2,337	2,388	2,556	265/70R16 73,33% 83 Un. 34 Obs	Modelo	2,424	2,413	2,171	2,381	2,387
	Igual a abr/20	3,932	3,639		4,219	4,901		Igual a abr/20	2,426	2,295		2,707	2,557
	Trim	4,183	4,015	3,341	3,682	4,346		Trim	2,484	2,410	3,216	2,710	2,567
205/65R15 89,47% 126 Un. 35 Obs	2 Trim	3,755	3,655		4,492	5,072	265/70R19,5 78,57% 91 Un. 34 Obs	2 Trim	2,644	2,633		2,691	2,529
	Modelo	3,286	2,642	2,605	2,639	2,663		Modelo	2,418	2,312	2,265	2,778	2,649
	Igual a abr/20	3,245	3,347		3,138	3,240		Igual a abr/20	2,646	2,699		2,643	2,471
205/75R17,5 76,74% 83 Un. 34 Obs	Trim	3,726	3,537	2,886	3,055	3,212	650R16 75,00% 130 Un. 34 Obs	Trim	2,646	2,699	2,531	2,694	2,710
	2 Trim	3,710	3,593		3,138	3,240		2 Trim	2,646	2,666		2,608	2,355
	Modelo	2,386	2,290	1,584	2,317	2,350		Modelo	3,496	3,513	3,128	4,280	4,260
205/80R16 82,93% 139 Un. 35 Obs	Igual a abr/20	3,549	3,374		3,270	3,297	700R16 88,57% 113 Un. 32 Obs	Igual a abr/20	1,559	1,463		2,644	2,520
	Trim	3,644	3,478	5,004	3,176	3,189		Trim	1,533	1,463	1,291	2,730	3,297
	2 Trim	3,512	3,278		3,270	3,297		2 Trim	1,516	1,338		2,742	3,625
215/70R15 73,91% 114 Un. 35 Obs	Modelo	3,254	3,295	2,935	3,548	3,533	215/55R17 100,00% 55 Un. 11 Obs	Modelo	2,878	2,904	2,449	2,830	2,826
	Igual a abr/20	2,717	2,708		2,778	2,692		Igual a abr/20	6,370	6,656		5,863	6,308
	Trim	2,813	2,882	2,677	2,707	2,616		Trim	6,033	6,180	6,326	5,694	6,029
215/70R15 73,91% 114 Un. 35 Obs	2 Trim	2,758	2,779		2,795	2,712	215/55R17 100,00% 55 Un. 11 Obs	2 Trim	6,033	6,187		5,670	5,984
	Modelo	2,697	2,766	2,523	2,822	2,838							
	Igual a abr/20	5,014	5,008		4,862	4,925							
215/70R15 73,91% 114 Un. 35 Obs	Trim	5,285	5,502	5,103	5,496	5,505							
	2 Trim	5,626	6,062		5,489	5,516							

3. Medidas de pneus com vendas agrupadas por semestre

Tabela 47 - Previsões calculadas para cada uma das medidas de pneus com vendas agrupadas por semestre, sem revisão dos dados e com revisão a cada 6 meses.

Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB	Medida de Pneus	REQM	AES	Holt	RLM/MLG	Croston	ASB
135/80R13 73,91% 52 Un. 18 Obs	Modelo	2,749	2,963	2,272	2,915	2,827	205/65R16 80,95% 78 Un. 18 Obs	Modelo	3,375	3,135	2,305	3,021	3,317
145/70R13 94,44% 79 Un. 18 Obs	Igual a jul/20	3,753	3,878		3,533	3,503	215/50R17 66,67% 49 Un. 17 Obs	Igual a jul/20	3,012	4,671		4,507	3,019
	6M	4,076	5,364	3,565	3,471	2,856		6M	3,308	4,671	2,679	2,227	2,384
175/65R15 85,00% 78 Un. 18 Obs	Modelo	3,348	3,205	2,751	3,365	3,409	215/55R17 100,00% 55 Un. 11 Obs	Modelo	2,772	2,752	2,501	2,838	2,888
	Igual a jul/20	3,002	3,352		3,025	3,028		Igual a jul/20	8,076	6,438		7,083	7,339
215/70R15 73,91% 114 Un. 35 Obs	6M	3,787	3,661	2,827	3,025	3,028	215/55R17 100,00% 55 Un. 11 Obs	6M	8,106	6,438	7,280	7,074	7,327
	Modelo	3,162	3,196	2,239	2,964	3,292		Modelo	3,715	3,348	2,820	3,956	4,171
215/70R15 73,91% 114 Un. 35 Obs	Igual a jul/20	3,536	6,313		6,441	4,879	215/55R17 100,00% 55 Un. 11 Obs	Igual a jul/20	3,049	4,714		3,069	4,002
	6M	3,536	5,631	5,531	4,957	3,820		6M	3,454	4,714	3,946	2,872	3,879

175/80R14	Modelo	2,990	2,889	2,476	3,097	3,149	215/60R16	Modelo	3,187	3,835	2,826	3,205	3,314
94,44%	Igual a jul/20	3,333	5,199		3,020	2,170	89,47%	Igual a jul/20	2,089	6,010		2,034	2,050
74 Un.	6M	3,013	4,837	3,765	3,065	2,211	69 Un.	6M	2,433	6,010	2,013	2,168	2,124
18 Obs	Modelo	3,418	2,690	2,387	3,671	3,764	225/50R16	Modelo	2,942	3,085	2,616	3,300	3,313
185/55R14	Igual a jul/20	3,088	2,886		3,727	3,181	66,67%	Igual a jul/20	2,002	3,100		2,147	2,138
94,44%	6M	3,428	2,886	3,597	3,360	2,900	52 Un.	6M	2,010	3,100	1,494	2,218	2,201
84 Un.	Modelo	3,820	4,668	3,200	4,200	4,323	19 Obs	Modelo	2,208	2,160	1,885	2,515	2,412
18 Obs	Igual a jul/20	2,703	10,601		4,243	3,027	225/70R15	Igual a jul/20	1,221	1,377		1,826	1,710
100%	6M	2,544	10,601	4,355	3,742	2,732	68,00%	6M	1,282	1,398	1,190	1,826	1,710
88 Un.	Tudo	3,810	4,173	3,305	4,321	4,211	47 Un.	Modelo	2,638	2,516	2,226	2,699	2,595
17 Obs	Igual a jul/20	3,163	1,680		4,747	3,143	235/70R16	Igual a jul/20	2,993	2,498		3,239	2,482
185R15	6M	3,119	1,943	2,786	3,177	1,849	73,91%	6M	2,871	2,390	3,265	3,239	2,482
89,47%	Modelo	4,267	3,862	3,166	4,192	4,138	49 Un.	Modelo	3,040	2,841	2,561	3,350	3,471
94 Un.	Igual a jul/20	2,234	0,722		3,332	2,073	18 Obs	Igual a jul/20	4,064	4,054		4,014	4,022
18 Obs	6M	2,024	0,757	2,224	3,265	2,003	195/60R14	6M	4,402	4,120	4,577	4,315	4,242
80,95%	Modelo	3,638	3,952	3,245	4,087	3,908	80,95%	Modelo	3,098	3,127	2,510	2,645	2,706
78 Un.	Igual a jul/20	2,121	5,309		1,532	1,996	78 Un.	Igual a jul/20	3,862	5,799		4,361	3,591
18 Obs	6M	2,121	4,549	0,592	2,562	2,223	18 Obs	6M	3,306	4,866	3,378	4,361	3,591
195/65R16	Modelo	2,852	3,065	2,454	2,844	2,910	245/40R17	Modelo	2,959	2,700	2,404	2,903	3,092
85,00%	Igual a jul/20	1,570	0,473		2,253	1,289	70,83%	Igual a jul/20	4,369	5,320		5,917	4,481
83 Un.	6M	1,431	0,435	1,133	2,860	1,838	50 Un.	6M	3,960	5,133	5,581	5,719	4,364
18 Obs	Modelo	2,936	2,756	2,562	3,653	3,627	18 Obs	Modelo	2,262	2,227	2,020	2,368	2,478
195/70R14	Igual a jul/20	1,368	0,856		4,061	3,362	245/45R18	Igual a jul/20	2,000	3,173		2,065	2,243
89,47%	6M	1,848	0,904	2,045	3,913	3,173	77,27%	6M	2,000	3,173	3,082	2,546	2,488
66 Un.	Modelo	4,405	4,036	3,468	4,773	4,824	65 Un.	Modelo	3,024	3,182	2,761	2,995	2,892
18 Obs	Igual a jul/20	3,973	0,853		6,938	5,715	18 Obs	Igual a jul/20	2,352	1,654		3,003	1,967
205/45R16	6M	3,727	0,877	3,537	6,255	5,083	285/70R19,5	6M	2,317	1,463	4,104	3,003	1,967
80,00%	Modelo	2,701	2,935	2,567	2,958	2,980	94,44%	Modelo	2,877	3,213	1,789	2,638	2,814
91 Un.	Igual a jul/20	2,236	5,252		2,508	2,457	61 Un.	Igual a jul/20	6,566	5,900		5,505	6,038
17 Obs	6M	2,236	5,252	2,577	2,580	2,496	18 Obs	6M	6,685	6,547	4,615	4,292	5,731
205/45R17	Modelo	3,657	4,296	3,232	3,756	3,828	385/55R22,5	Modelo	2,217	2,000	1,742	2,323	2,343
62,96%	Igual a jul/20	4,000	7,108		4,229	3,803	88,24%	Igual a jul/20	1,379	1,803		1,294	1,178
48 Un.	6M	4,000	6,377	5,262	4,229	3,803	53 Un.	6M	1,382	1,803	2,022	1,852	1,734
18 Obs	Modelo	2,936	2,756	2,562	3,653	3,627	16 Obs	Modelo	3,024	3,182	2,761	2,995	2,892
205/55R15	Igual a jul/20	1,368	0,856		4,061	3,362	750R16	Igual a jul/20	2,352	1,654		3,003	1,967
57,14%	6M	1,848	0,904	2,045	3,913	3,173	84,21%	6M	2,317	1,463	4,104	3,003	1,967
56 Un.	Modelo	4,405	4,036	3,468	4,773	4,824	37 Un.	Modelo	2,877	3,213	1,789	2,638	2,814
17 Obs	Igual a jul/20	3,973	0,853		6,938	5,715	17 Obs	Igual a jul/20	6,566	5,900		5,505	6,038
	6M	3,727	0,877	3,537	6,255	5,083		6M	6,685	6,547	4,615	4,292	5,731
	Modelo	2,701	2,935	2,567	2,958	2,980		Modelo	2,217	2,000	1,742	2,323	2,343
	Igual a jul/20	2,236	5,252		2,508	2,457		Igual a jul/20	1,379	1,803		1,294	1,178
	6M	2,236	5,252	2,577	2,580	2,496		6M	1,382	1,803	2,022	1,852	1,734
	Modelo	3,657	4,296	3,232	3,756	3,828							
	Igual a jul/20	4,000	7,108		4,229	3,803							
	6M	4,000	6,377	5,262	4,229	3,803							

Anexo IV – Combustíveis: Cronogramas, Funções de Autocorrelação e Testes não paramétricos

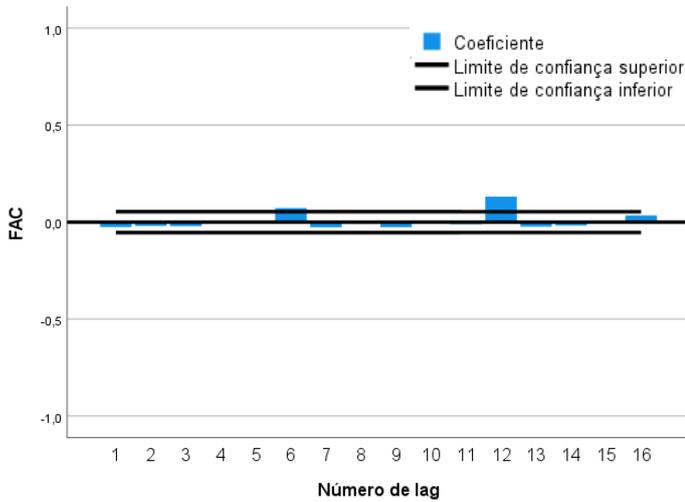


Figura 23 – Função de autocorrelação das vendas diárias de gásóleo simples (Fonte: elaboração própria).

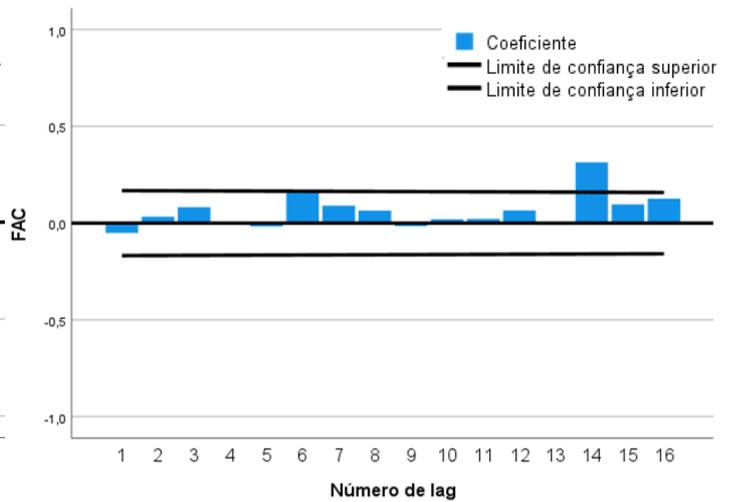


Figura 24 - Função de autocorrelação das vendas diárias de gásóleo aditivado (Fonte: elaboração própria).

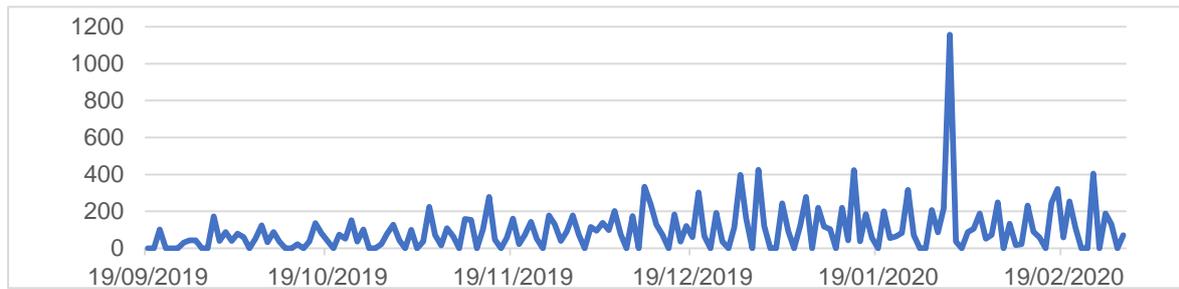


Figura 25 – Cronograma das vendas diárias de gásóleo aditivado (Fonte: elaboração própria).

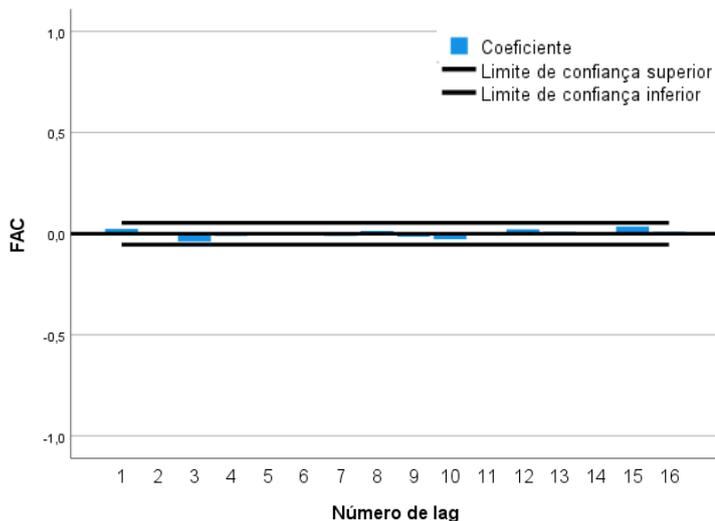


Figura 26 - Função de autocorrelação das vendas diárias de gasolina 95 (Fonte: elaboração própria).

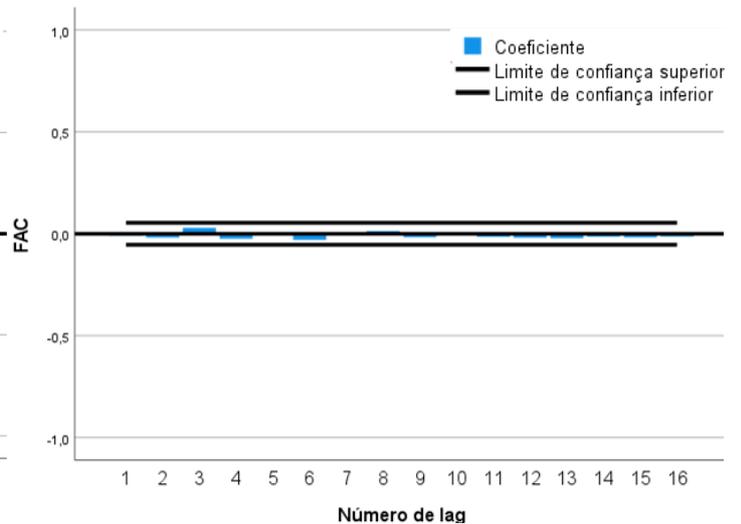


Figura 27 - Função de autocorrelação das vendas diárias de gasolina 98 (Fonte: elaboração própria).

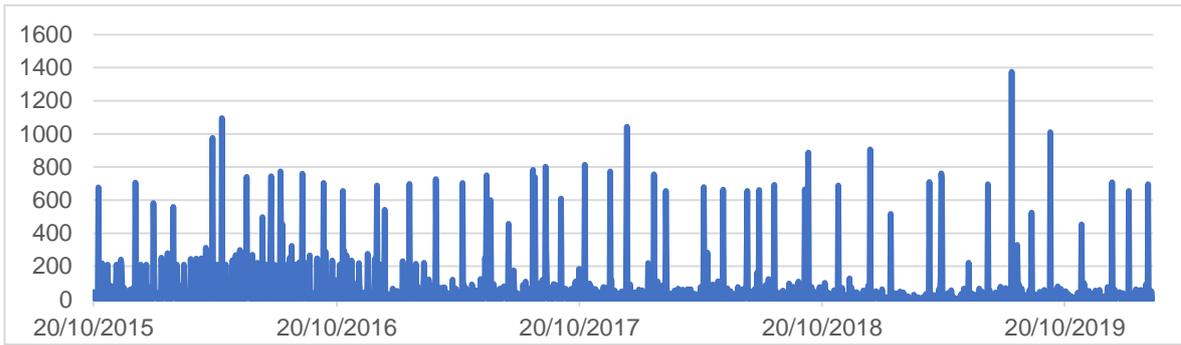


Figura 28 - Cronograma das vendas diárias de gasolina 95 (Fonte: elaboração própria).

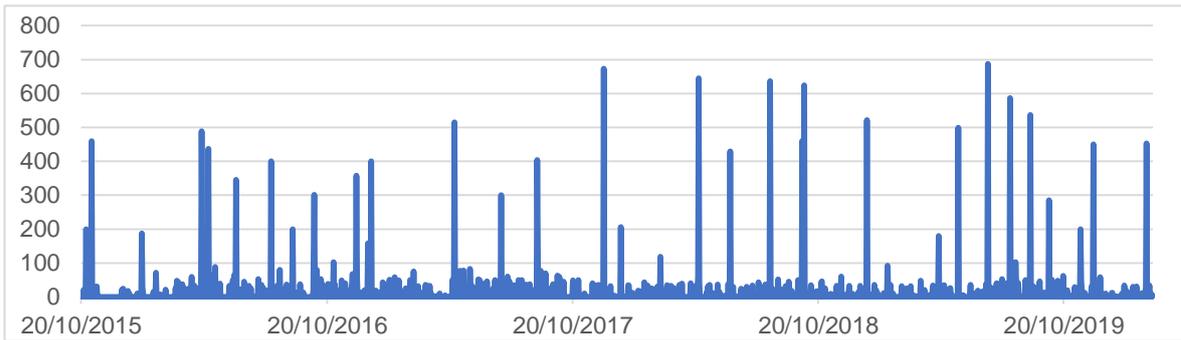


Figura 29 - Cronograma das vendas diárias de gasolina 98 (Fonte: elaboração própria).

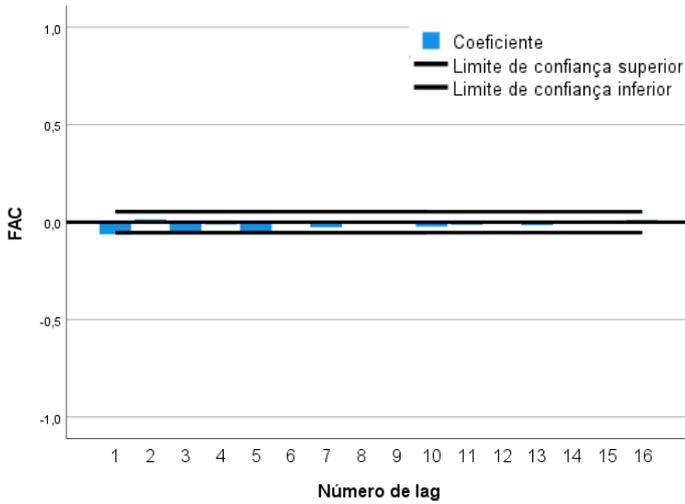


Figura 30 - Função de autocorrelação das vendas diárias de gasóleo agrícola (Fonte: elaboração própria).

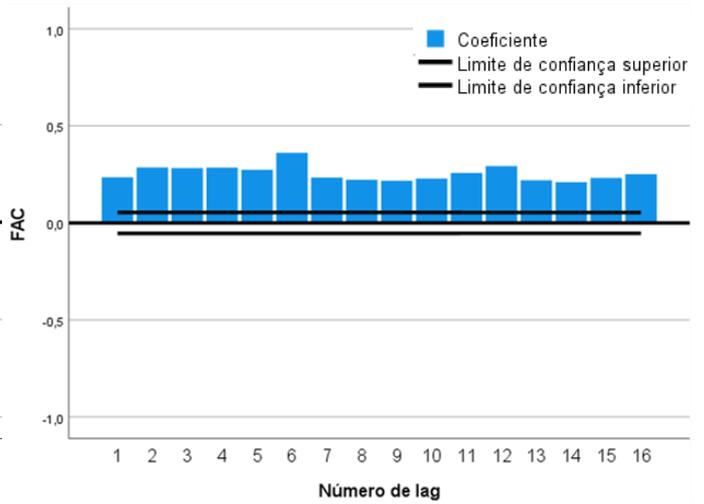


Figura 31 - Função de autocorrelação das vendas diárias de gasóleo para aquecimento (Fonte: elaboração própria).

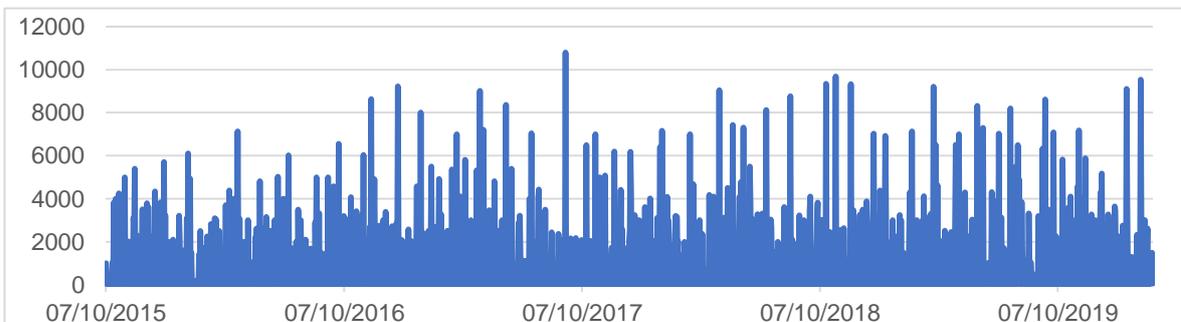


Figura 32 - Cronograma das vendas diárias de gasóleo agrícola (Fonte: elaboração própria).

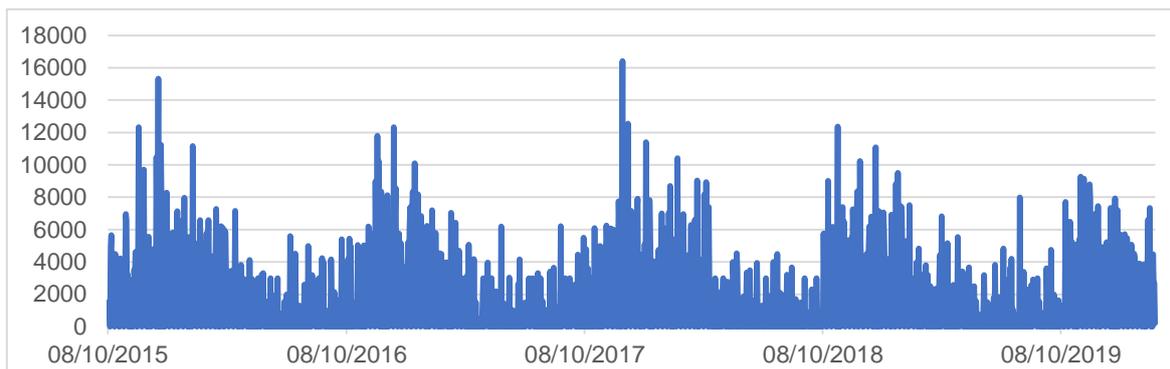


Figura 33 - Cronograma das vendas diárias de gásóleo para aquecimento (Fonte: elaboração própria).

Tabela 48 – Resultado dos testes não paramétricos aos dados diários e semanais dos diferentes combustíveis.

Média	Gasóleo Simples	Gasóleo Aditivado	Gasolina 95	Gasolina 98	Gasóleo Agrícola	Gasóleo P/ Aquecimento
Dados Diários	0,999	0,036	0,117	0,465	0,795	0,000
Dados Semanais	0,233	0,219	0,615	0,834	0,003	0,000

A análise dos gráficos da função de autocorrelação empírica dos dados diários não revela correlações estatisticamente significativas (como se pode verificar nas Figuras 23, 24, 26, 27, 30 e 31), com as observações a não apresentarem um padrão ao longo do tempo (de acordo com os cronogramas neste anexo).

Já o resultado dos testes não paramétricos (Tabela 48) permite concluir que, para todos os combustíveis, os dados diários são independentes em relação à média, com exceção do gásóleo aditivado e do gásóleo para aquecimento, e que no caso dos dados semanais, estes são independentes em relação à média em todos os combustíveis, exceto no caso do gásóleo agrícola e do gásóleo para aquecimento.

Anexo V – Combustíveis: Modelos determinados

Nas Tabelas 49 a 61 encontram-se os modelos obtidos, com menor REQM, para os dados diários, semanais e mensais de todos os combustíveis. O modelo de RLM resulta do procedimento *stepwise*, o MLG recorre à distribuição possível de aplicar (normal ou gama) e a identificação dos modelos SARMA e ARMA resulta da execução do procedimento no SPSS com deteção automática de *outliers*.

Relativamente aos dados diários, nos modelos de RLM o pressuposto de normalidade dos resíduos falha em todos os combustíveis. Adicionalmente, o pressuposto de homocedasticidade falha para o combustível gásóleo aditivado.

Quanto aos MLG, verifica-se que os resíduos não se encontram distribuídos uniformemente em torno de zero em todos os combustíveis.

Uma vez aplicado o método SARMA, observa-se que a normalidade dos resíduos continua a não ser cumprida em todos os combustíveis. Mais, a homocedasticidade dos resíduos não se verifica para o combustível gasóleo aditivado.

Já em relação aos dados semanais, no modelo de RLM o pressuposto de normalidade dos resíduos não é respeitado na gasolina 95. No método ARMA aplicado ao mesmo combustível, a normalidade e a homocedasticidade dos resíduos não são cumpridas. Em relação aos modelos MLG e ARMA determinados para as vendas semanais de gasolina 98, verifica-se que a normalidade dos resíduos não é cumprida em nenhum modelo.

Tabela 49 – Modelos obtidos para os dados diários do combustível gasóleo simples.

GASÓLEO SIMPLES					
RLM		MLG		SARMA (0,0,0)(1,0,1)	
REQM	1885,159	REQM	1888,211	REQM	1102,952
				R ²	0,902
R ²	0,713	Distribuição normal e <i>link</i> log		Outliers manuais	
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	1836,760	β_0	7,154	β_0	1456,488
β_1 tempo	-0,326	β_1 segunda-feira	0,246	AR sazonal	0,990
β_2 sábado	-586,522	β_2 terça-feira	0,202	MA sazonal	0,959
β_3 dia com grande quantidade de vendas	6566,179	β_3 quarta-feira	0,154	β_1 maio	-285,914
		β_4 quinta-feira	0,178	β_2 junho	327,819
		β_5 sexta-feira	0,178	β_3 julho	388,235
		β_6 dia com grande quantidade de vendas	1,666	β_4 novembro	239,541

Tabela 50 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo simples

GASÓLEO SIMPLES					
DADOS SEMANAIS			Dados mensais		
REQM	8128,982	REQM	15985,647		
R ²	0,045	R ²	0,340		
Variáveis	Coef.	Variáveis	Coef.		
β_0	22660,903	β_0	58283,317		
β_1 tempo	-26,472	β_1 tempo	-335,482		
		β_2 quantidade vendida no mês anterior	0,429		

Tabela 51 - Modelos obtidos para os dados diários do combustível gasóleo agrícola. O modelo de RLM com melhor ajuste obtido com o procedimento *stepwise* utiliza a raiz quadrada da quantidade vendida.

GASÓLEO AGRÍCOLA					
RLM		MLG		SARMA (0,0,3)(1,0,1)	
REQM	0,723	REQM	1155,314	REQM	279,564
R ²	1179,591	Distribuição normal e <i>link</i> log		R ²	0,975
				Outliers manuais	
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	10,554	β_0	5,391	β_0	202,096
β_1 dia com grande quantidade de vendas	41,285	β_1 junho	0,232	MA	-0,082
		β_2 dezembro	-0,199	MA retardo 2	0,252
		β_3 quinta-feira	-0,138	MA retardo 3	-0,029
		β_4 dia com grande quantidade de vendas	2,635	AR sazonal	0,839
		β_5 quantidade vendida no dia anterior	2,729E ⁻⁵	MA sazonal	0,760
				β_1 novembro	265,361

Tabela 52 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo agrícola. O modelo de RLM para as vendas semanais utiliza a raiz quadrada da quantidade vendida.

GASÓLEO AGRÍCOLA					
DADOS SEMANAIS			Dados mensais		
REQM	4140,419		REQM		5143,553
R ²	0,051		R ²		0,389
Variáveis	Coef.		Variáveis		Coef.
β_0	79,587		β_0		39103,906
β_1 novembro	12,764		β_1 novembro		7819,361
β_2 dezembro	16,393		β_2 dezembro		11736,505
			β_3 desemprego no concelho de Leiria		-2,718

Tabela 53 - Modelos obtidos para os dados diários do combustível gasóleo para aquecimento.

GASÓLEO PARA AQUECIMENTO					
RLM		MLG		SARMA (1,0,1)(1,0,1)	
REQM	1386,186	REQM	1417,312	REQM	1213,714
R ²	0,677	Distribuição normal e link log		R ²	0,752
				Outliers manuais	
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	496,245	β_0	7,258	β_0	2310,267
β_1 sábado	-977,928	β_1 abril	-0,196	AR	0,969
β_2 janeiro	1380,186	β_2 maio	-0,658	MA	0,956
β_3 fevereiro	1334,751	β_3 junho	-0,872	AR sazonal	1,00
β_4 março	1214,816	β_4 julho	-0,797	MA sazonal	0,992
β_5 abril	602,150	β_5 agosto	-0,712	β_1 abril	-801,986
β_6 outubro	531,593	β_6 setembro	-0,655	β_2 maio	-1257,666
β_7 novembro	1421,330	β_7 outubro	-0,207	β_3 junho	-1512,297
β_8 dezembro	1675,712	β_8 dezembro	0,103	β_4 julho	-1454,126
β_9 dia do mês com menos vendas	-774,198	β_9 segunda-feira	0,539	β_5 agosto	-1411,014
β_{10} dia com grande quantidade de vendas	4608,991	β_{10} terça-feira	0,457	β_6 setembro	-1306,945
		β_{11} quarta-feira	0,474	β_7 outubro	-877,997
		β_{12} quinta-feira	0,503		
		β_{13} sexta-feira	0,469		
		β_{14} dia com grande quantidade de vendas	1,121		
		β_{15} dia do mês com menos vendas	-0,325		

Tabela 54 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo para aquecimento. O modelo de RLM para as vendas semanais utiliza a raiz quadrada da quantidade vendida.

GASÓLEO PARA AQUECIMENTO					
Dados Semanais			Dados mensais		
REQM	0,665		REQM		5565,323
R ²	5427,963		R ²		0,873
Variáveis	Coef.		Variáveis		Coef.
β_0	112,293		β_0		25312,479
β_1 janeiro	74,044		β_1 janeiro		69931,739
β_2 fevereiro	57,213		β_2 fevereiro		48895,882
β_3 março	50,349		β_3 março		48706,638
β_4 abril	26,621		β_4 abril		23076,286
β_5 outubro	36,234		β_5 outubro		27170,597
β_6 novembro	79,255		β_6 novembro		77381,291
β_7 dezembro	78,073		β_7 dezembro		80608,874
β_8 preço	-36,209				

Tabela 55 - Modelos obtidos para os dados diários do combustível gasóleo aditivado.

GASÓLEO ADITIVADO					
RLM		MLG		SARMA (0,0,0)(1,0,1)	
REQM	83,496	REQM	79,323	REQM	83,846
R ²	0,590	Distribuição normal e <i>link</i> log		R ²	0,583
Outliers automáticos					
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	43,505	β_0	3,671	β_0	113,194
β_1 tempo	0,847	β_1 tempo	0,020	AR sazonal	0,828
β_2 quantidade vendida no dia anterior	-0,159	β_2 janeiro	-0,658	MA sazonal	0,708
β_3 segunda-feira	41,091	β_3 fevereiro	-1,266	β_1 setembro	-60,485
β_4 sexta-feira	49,636	β_4 segunda-feira	0,390	β_2 outubro	-47,018
β_5 dezembro	50,730	β_5 sexta-feira	0,510	β_3 dezembro	37,502
β_6 dia com grande quantidade de vendas	1001,818	β_6 dia com grande quantidade de vendas	1,790		
		β_7 quantidade vendida no dia anterior	-0,022		
		β_8 dia do mês com menos vendas	-2,727		

Tabela 56 - Modelos obtidos para os dados semanais e mensais do combustível gasóleo aditivado. Em ambos o modelo recorre à raiz quadrada da quantidade vendida para obter a menor REQM.

GASÓLEO ADITIVADO					
Dados Semanais			Dados mensais		
REQM	223,370	REQM	313,440		
R ²	0,677	R ²	0,955		
Variáveis	Coef.	Variáveis	Coef.		
β_0	14,083	β_0	12,841		
β_1 tempo	1,012	β_1 tempo	11,785		
β_2 fevereiro	-9,013	β_2 fevereiro	-27,694		

Tabela 57 - Modelos obtidos para os dados diários do combustível gasolina 95.

GASOLINA 95 – DADOS DIÁRIOS					
RLM		MLG		SARMA (0,0,0)(1,0,1)	
REQM	131,359	REQM	131,319	REQM	26,107
R ²	0,185	Distribuição normal e <i>link</i> log		R ²	0,986
Outliers automáticos					
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	77,260	β_0	4,041	β_0	24,509
β_1 tempo	-0,037	β_1 tempo	-0,001	AR sazonal	0,937
β_2 agosto	38,943	β_2 fevereiro	0,384	MA sazonal	0,912
β_3 dia do mês com mais vendas	90,004	β_3 junho	0,523	β_1 fevereiro	5,286
β_4 dia com grande quantidade de vendas	1029,643	β_4 julho	0,607	β_2 julho	5,799
		β_5 agosto	0,902	β_3 agosto	9,977
		β_6 setembro	0,589		
		β_7 dia com grande quantidade de vendas	2,680		
		β_8 dia do mês com mais vendas	0,512		
		β_9 dia do mês com menos vendas	-0,898		

Tabela 58 - Modelos obtidos para os dados semanais do combustível gasolina 95.

GASOLINA 95 – DADOS SEMANAIS					
RLM		MLG		ARMA (1,0,1)	
REQM	346,061	REQM	342,180	REQM	276,920
R ²	0,088	Distribuição gama com link potência		R ²	0,416
Outliers automáticos					
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	476,556	β_0	0,002	β_0	1260,264
β_1 tempo	-1,242	β_1 tempo	9,673E ⁻⁶	AR	0,478
β_2 julho	175,387	β_2 julho	-0,001	MA	0,829
β_3 agosto	217,685	β_3 agosto	-0,001	β_1 março	-128,543
		β_4 novembro	0,001	β_2 agosto	173,235
				β_3 setembro	85,834
				β_4 novembro	-98,962
				β_5 preço	-603,793

Tabela 59 - Modelos obtidos para os dados mensais e trimestrais do combustível gasolina 95.

GASOLINA 95				
DADOS MENSAIS			Dados trimestrais	
REQM		661,879	REQM	1356,839
R ²		0,337	R ²	0,356
Variáveis		Coef.	Variáveis	Coef.
β_0		44,247	β_0	6506,920
β_1 agosto		1317,263	β_1 tempo	-194,584
β_2 desemprego no concelho de Leria		0,444		

Tabela 60 - Modelos obtidos para os dados diários do combustível gasolina 98.

GASOLINA 98 – DADOS DIÁRIOS					
RLM		MLG		SARMA (0,0,0)(1,0,1)	
REQM	67,189	REQM	63,935	REQM	12,954
R ²	0,014	Distribuição normal e link log		R ²	0,963
Outliers automáticos					
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	12,702	β_0	7,439	β_0	6,256
β_1 sábado	9,982	β_1 tempo	0,002	AR sazonal	0,967
β_2 abril	14,734	β_2 janeiro	2,175	MA sazonal	0,936
β_3 agosto	15,556	β_3 março	2,610	β_1 julho	2,625
β_4 dia do mês com mais vendas	26,060	β_4 abril	2,991	β_2 outubro	4,205
		β_5 maio	3,218		
		β_6 junho	4,168		
		β_7 julho	2,205		
		β_8 agosto	5,378		
		β_9 setembro	5,092		
		β_{10} outubro	3,574		
		β_{11} novembro	2,614		
		β_{12} segunda-feira	-1,167		
		β_{13} terça-feira	-3,331		
		β_{14} quarta-feira	-2,926		
		β_{15} quinta-feira	-4,050		
		β_{16} sexta-feira	-3,218		
		β_{17} dia do mês com mais vendas	2,778		
		β_{18} dia do mês com menos vendas	-4,134		
		β_{19} quantidade vendida no dia anterior	-0,031		
		β_{20} preço	-6,529		

Tabela 61 - Modelos obtidos para os dados semanais e mensais do combustível gasolina 98.

GASOLINA 98 - DADOS SEMANAIS				DADOS MENSAIS	
MLG		ARMA (1,0,1)			
REQM		REQM	31,562	REQM	0,416
162,007					
Distribuição normal e <i>link log</i>		R ²	0,964	R ²	243,100
Outliers automáticos					
Variáveis	Coef.	Variáveis	Coef.	Variáveis	Coef.
β_0	4,867	β_0	45,956	β_0	290,832
β_1 janeiro	-0,977	AR	0,909	β_1 abril	458,346
β_2 fevereiro	-0,696	MA	0,788	β_2 junho	276,963
β_3 março	-0,928	β_1 dezembro	-16,427	β_3 agosto	540,599
β_4 outubro	-0,585			β_4 setembro	360,230
				β_5 dezembro	388,578

Anexo VI – Combustíveis - Eliminação de variáveis não estatisticamente significativas: MLG

1. Gasóleo Simples

Tabela 62 – Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo simples.

MLG	Variáveis eliminadas	Valor-p
Distribuição normal com <i>link log</i>	1ª tempo, janeiro, fevereiro, julho, setembro, dia 1, preço	>0,500
	2ª dezembro	0,798
	3ª quantidade vendida no dia anterior	0,512
	4ª junho	0,233
	5ª novembro	0,300
	6ª outubro	0,252
	7ª maio	0,272
	8ª março	0,176
	9ª abril	0,221
	10ª dia 16	0,184
	11ª agosto	0,189
	12ª sábado (é redundante)	-
Modelo	segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira, grande quantidade de vendas	

2. Gasóleo Aditivado

Tabela 63 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo aditivado.

MLG	Variáveis eliminadas	Valor-p
Distribuição normal com <i>link log</i>	1ª março, abril, maio, junho, julho, agosto (são redundantes)	-
	2ª setembro, outubro, novembro, dia 31	>0,500
	3ª dezembro	0,578
	4ª quarta-feira	0,361
	5ª quinta-feira	0,972
	6ª terça-feira	0,710
	7ª sábado	0,163
	8ª preço	0,280
Modelo	tempo, janeiro, fevereiro, segunda-feira, sexta-feira, grande quantidade de vendas, quantidade vendida no dia anterior, dia 1	

3. Gasolina 95

Tabela 64 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasolina 95.

Dados Diários	Variáveis Eliminadas	Valor-P
Distribuição Normal Com Link Log	1ª janeiro, março, maio, outubro, novembro, terça-feira, quantidade vendida no dia anterior, preço	>0,500
	2ª sábado	0,799
	3ª dezembro	0,736
	4ª sexta-feira	0,183
	5ª quinta-feira	0,319
	6ª quarta-feira	0,185
	7ª segunda-feira	0,194
	8ª abril	0,164
Modelo	tempo, fevereiro, junho, julho, agosto, setembro, grande quantidade de vendas, dia 30, dia 20	

Tabela 65 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados semanais de gasolina 95.

Dados semanais	Variáveis eliminadas	Valor-p
Distribuição gama com link potência	1ª fevereiro, abril, junho, setembro, preço	>0,500
	2ª dezembro	0,905
	3ª maio	0,356
	4ª outubro	0,331
	5ª março	0,148
	6ª janeiro	0,157
Modelo	tempo, julho, agosto, novembro	

4. Gasolina 98

Tabela 66 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasolina 98.

MLG	Variáveis eliminadas	Valor-p
Distribuição normal com link log	1ª fevereiro	0,393
	2ª dezembro	0,393
	3ª sábado, grande quantidade de vendas (são redundantes)	-
Modelo	tempo, janeiro, março, abril, maio, junho, julho, agosto, setembro, outubro, novembro, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira, quantidade vendida no dia anterior, dia 29, dia 7, preço	

Tabela 67 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados semanais de gasolina 98.

Dados Semanais	Variáveis Eliminadas	Valor-P
Distribuição Normal Com Link Log	1ª tempo, abril, junho, julho, agosto, setembro, preço	>0,500
	2ª dezembro	0,816
	3ª maio	0,289
	4ª novembro	0,262
Modelo	janeiro, fevereiro, março, outubro	

5. Gasóleo Agrícola

Tabela 68 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo agrícola.

MLG	Variáveis eliminadas	Valor-p
Distribuição normal com link log	1 ^a tempo, janeiro, agosto, segunda-feira, sexta-feira, dia 3, preço	>0,500
	2 ^a março	0,891
	3 ^a sábado	0,786
	4 ^a novembro	0,771
	5 ^a outubro	0,688
	6 ^a abril	0,732
	7 ^a julho	0,679
	8 ^a fevereiro	0,589
	9 ^a dia 31	0,498
	10 ^a quarta-feira	0,455
	11 ^a terça-feira	0,356
	12 ^a maio	0,321
	13 ^a setembro	0,307
Modelo	junho, dezembro, quinta-feira, grande quantidade de vendas, quantidade vendida no dia anterior	

6. Gasóleo para Aquecimento

Tabela 69 - Processo de eliminação das variáveis não estatisticamente significativas no MLG dos dados diários de gasóleo para aquecimento.

MLG	Variáveis eliminadas	Valor-p
Distribuição normal com link log	1 ^a tempo, quantidade vendida no dia anterior, dia 21, preço	>0,500
	2 ^a novembro	0,163
	3 ^a fevereiro	0,803
	4 ^a janeiro	0,484
	5 ^a março	0,132
	6 ^a sábado (é redundante)	-
Modelo	abril, maio, junho, julho, agosto, setembro, outubro, dezembro, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira, grande quantidade de vendas, dia 1	

Anexo VII – Combustíveis - Eliminação de variáveis não estatisticamente significativas: modelos SARMA e ARMA

Tabela 70 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gasóleo simples e de gasóleo aditivado.

1. Gasóleo Simples			2. Gasóleo Aditivado		
SARMA	Variáveis eliminadas	Valor-p	SARMA	Variáveis eliminadas	Valor-p
(0,0,0) (1,0,1)	1 ^a dezembro	0,996	(0,0,0) (1,0,1)	1 ^a março, abril, maio, junho, julho, agosto (são redundantes)	-
	2 ^a março	0,992			
	3 ^a maio	0,860			
	4 ^a novembro	0,682			
	5 ^a fevereiro	0,557		2 ^a fevereiro (estimativa de menor valor)	-
	6 ^a agosto	0,527		3 ^a janeiro	0,969
	7 ^a setembro	0,373		4 ^a preço	0,834
	8 ^a outubro	0,337		5 ^a novembro	0,385
	9 ^a junho	0,380			
	10 ^a abril	0,322			
	11 ^a preço	0,215			
Modelo	julho		Modelo	setembro, outubro, dezembro	

Tabela 71 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gasolina 95 e 98.

3. Gasolina 95				4. Gasolina 98			
SARMA	Variáveis eliminadas	Valor-p	SARMA	Variáveis eliminadas	Valor-p		
(0,0,0) (1,0,1)	1ª novembro	0,378	(0,0,0) (1,0,1)	1ª fevereiro	0,886		
	2ª março	0,452		2ª dezembro	0,797		
	3ª abril	0,439		3ª preço	0,711		
	4ª dezembro	0,480		4ª novembro	0,606		
	5ª setembro	0,181		5ª maio	0,398		
	6ª preço	0,124		6ª abril	0,272		
	7ª maio	0,163		7ª setembro	0,186		
	8ª outubro	0,180		8ª agosto	0,125		
	9ª junho	0,105		9ª março	0,155		
					10ª junho	0,204	
Modelo	fevereiro, julho, agosto		Modelo	julho, outubro			

Tabela 72 - Processo de eliminação das variáveis não estatisticamente significativas no modelo ARMA dos dados semanais de gasolina 95 e 98.

ARMA	Variáveis eliminadas	Valor-p	ARMA	Variáveis eliminadas	Valor-p
(0,0,0) (1,0,1)	1ª julho	0,852	(0,0,0) (1,0,1)	1ª preço	0,963
	2ª abril	0,733		2ª março	0,828
	3ª outubro	0,685		3ª fevereiro	0,683
	4ª maio	0,444		4ª outubro	0,500
	5ª dezembro	0,427		5ª maio	0,350
	6ª fevereiro	0,441		6ª novembro	0,262
	7ª junho	0,163		7ª agosto	0,565
				8ª setembro	0,595
				9ª abril	0,322
				10ª junho	0,934
				11ª julho	0,117
Modelo	março, agosto, setembro, novembro, preço		Modelo	dezembro	

Tabela 73 - Processo de eliminação das variáveis não estatisticamente significativas no modelo SARMA dos dados diários de gásóleo agrícola e de gásóleo para aquecimento.

5. Gásóleo Agrícola			6. Gásóleo para aquecimento		
SARMA	Variáveis eliminadas	Valor-p	SARMA	Variáveis eliminadas	Valor-p
(0,0,3) (1,0,1)	1ª Abril	0,979	(1,0,1) (1,0,1)	1ª dezembro	0,471
	2ª Outubro	0,773		2ª novembro	0,114
	3ª Julho	0,803			
	4ª Preço	0,736			
	5ª Fevereiro	0,854			
	6ª Março	0,874			
	7ª Junho	0,623			
	8ª Maio	0,577			
	9ª Setembro	0,452			
	10ª Agosto	0,356			
Modelo	novembro, dezembro		Modelo	fevereiro, março, abril, maio, junho, julho, agosto, setembro, outubro, preço	