

PEDRO PEREIRA LIMA JUNIOR

**PREVISÃO DE DEMANDA DE VEÍCULOS AUTOMOTORES ATRAVÉS DO
MODELO DE REGRESSÃO LINEAR MÚLTIPLA**

Guaratinguetá
2015

Pedro Pereira Lima Junior

**PREVISÃO DE DEMANDA DE VEÍCULOS AUTOMOTORES ATRAVÉS DO
MODELO DE REGRESSÃO LINEAR MÚLTIPLA**

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia Mecânica da Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Mecânica.

Orientador: Prof. Francisco Alexandre Oliveira

Guaratinguetá
2015

L732p	<p>Lima Junior, Pedro Pereira</p> <p>Previsão de demanda de veículos automotores através do modelo de regressão linear múltipla / Pedro Pereira Lima Junior – Guaratinguetá, 2015.</p> <p>64 f. : il.</p> <p>Bibliografia : f. 54-58</p> <p>Trabalho de Graduação em Engenharia Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2015.</p> <p>Orientador: Prof. Dr. Francisco Alexandre de Oliveira</p> <p>1. Análise de regressão 2. Multicolinearidade 3. Método de Monte Carlo 4. Automóveis - Oferta e procura I. Título</p> <p>CDU 519.233.5</p>
-------	---

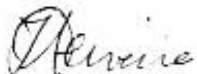
PEDRO PEREIRA LIMA JUNIOR

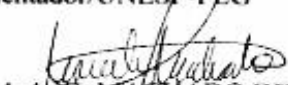
ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE
"GRADUADO EM ENGENHARIA MECÂNICA"

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA

Prof. Dr. MARCELO SAMPAIO MARTINS
Coordenador

BANCA EXAMINADORA:


Prof. Dr. FRANCISCO ALEXANDRE DE OLIVEIRA
Orientador/UNESP-FEG


Prof. Dr. MARCELA A. G. MACHADO DE FREITAS
UNESP-FEG


Me. ERICA XIMENES DIAS
UNESP-FEG

Dezembro de 2015

DADOS CURRICULARES

Pedro Pereira Lima Junior

- NASCIMENTO** 15.05.1991 – SÃO JOSÉ DOS CAMPOS / SP
- FILIAÇÃO** Pedro Pereira Lima
Alexandrina Isabel dos Santos Lima
- 2010/2015** Curso de Graduação em Engenharia Mecânica
na Faculdade de Engenharia do Campus de
Guaratinguetá da Universidade Estadual Paulista.
- 2013/2014** Intercâmbio Internacional na Faculdade de
Engenharia do Campus de Tampa da Universidade
do Sul da Flórida.

DEDICATÓRIA

Dedico este trabalho a uma pessoa muito próxima que precisou nos deixar durante essa jornada. Trouxe-me pela primeira vez para Guaratinguetá, e sempre me apoiou e esteve ao meu lado não apenas durante esse período, mas por toda a minha vida, independentemente de onde estivesse. Muito obrigado por tudo, tio Zezão. Saudades eternas.

AGRADECIMENTOS

Primeiramente, gostaria de agradecer a minha família por todo o apoio prestado a mim e por terem me auxiliado na realização de não apenas o meu sonho de me graduar, como também todos os sonhos envolvidos no processo, independente da distância que estes me deixariam deles.

a Deus por ter me iluminado em toda essa jornada, dando-me forças para vencer todos os obstáculos encontrados no caminho, permitindo-me aprender com essas dificuldades e concretizar esse sonho.

a meus amigos, de São José dos Campos e adquiridos durante a universidade, por todos os momentos vividos durante esse período fazendo com que este tenha sido, de fato, um dos melhores da minha vida. Em especial, aos meus companheiros de república e outras pessoas com quem tive a oportunidade de morar junto, pois todos me propiciaram um aprendizado a sua maneira, e por isto serei eternamente grato.

ao meu orientador, *Prof. Dr. Francisco Alexandre de Oliveira*, por ter adotado esse novo papel em minha formação, e por ter se mostrado sempre disposto a me ajudar no desenvolvimento deste trabalho, independente do momento.

a minha avó *Isabel*, que esteve comigo em todos os momentos, desde minha primeira provação, o vestibular, durante todo o meu período em Wintergreen Resort e em Tampa, e com certeza no instante em que este Trabalho de Graduação estiver sendo defendido.

A todos, meu muito obrigado.

LIMA JUNIOR, P. P. **Previsão de demanda de veículos automotores através do modelo de regressão linear múltipla**. 2015. 64 f. Trabalho de Graduação (Bacharel em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

RESUMO

Este trabalho teve como objetivo modelar uma equação de demanda por automóveis e comerciais leves novos, com base nos dados de Fevereiro de 2007 a Julho de 2014, através de uma análise de regressão múltipla. A revisão bibliográfica consta de um levantamento histórico sobre a indústria automotiva que contribuiu para o entendimento da atual crise que acomete tal mercado, cuja consequência foi uma grande redução nas vendas. O modelo elaborado foi avaliado através de uma análise residual e também pela realização de um teste de aderência – teste “F” – com nível de significância de 5%. Além disso, foi encontrado um coeficiente de determinação (R^2) de 0,8159, o que indica que 81,59% da demanda por automóveis e comerciais leves pode ser explicada através das variáveis regressoras: taxa de juros, taxa de desemprego, índice de preços ao consumidor amplo (IPCA), produto interno bruto (PIB), e imposto sobre produtos industrializados (IPI). Finalizando, foram testadas outras dez amostras, referentes ao período de Agosto de 2014 a Maio de 2015, no modelo com o objetivo de validar sua qualidade de previsão. Por fim, realizou-se uma Simulação de Monte Carlo com o objetivo de obter uma distribuição de probabilidades de demandas futuras. A partir dela notou-se que a demanda real nos quatro meses posteriores ao período amostral pertenceu ao intervalo com maior probabilidade de ocorrência, e que o PIB e o IPCA são as variáveis que têm maior influência sob o modelo desenvolvido.

PALAVRAS-CHAVE: Regressão linear múltipla. Simulação de Monte Carlo. Demanda de automóveis.

LIMA JUNIOR, P. P. **Automotive vehicles demand forecasting using multiple linear regression model**. 2015. 64 f. Graduate Work (Graduate in Mechanical Engineering) - Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

ABSTRACT

This study aimed to model an equation for the demand of automobiles and light commercial vehicles, based on the data from February 2007 to July 2014, through a multiple regression analysis. The literature review consists of an information collection of the history of automotive industry, and it has contributed to the understanding of the current crisis that affects this market, which consequence was a large reduction in sales. The model developed was evaluated by a residual analysis and also was used an adhesion test - "F" test – with a significance level of 5%. In addition, a coefficient of determination (R^2) of 0.8159 was determined, indicating that 81.59% of the demand for automobiles and light commercial vehicles can be explained by the regression variables: interest rate, unemployment rate, broad consumer price index (CPI), gross domestic product (GDP) and tax on industrialized products (IPI). Finally, other ten samples, from August 2014 to May 2015, were tested in the model in order to validate its forecasting quality. Finally, a Monte Carlo Simulation was run in order to obtain a distribution of probabilities of future demands. It was observed that the actual demand in the period after the sample was in the range that was most likely to occur, and that the GDP and the CPI are the variable that have the greatest influence on the developed model.

KEYWORDS: Multiple linear regression. Monte Carlo Simulation. Car demand.

LISTA DE FIGURAS

Figura 1 - Licenciamento total de automóveis novos.....	16
Figura 2 - Produção de autoveículos montados.....	17
Figura 3 - Estoque de autoveículos.....	17
Figura 4 - Requisitos do programa INOVAR-AUTO.....	21
Figura 5 - Processo de simulação de Monte Carlo com quatro variáveis.....	29
Figura 6 - Comportamento das variáveis candidatas em 2008. (a) taxa de juros; (b) rendimento médio mensal; (c) taxa de desemprego; (d) IPCA; (e); PIB.....	36
Figura 7 - Comportamento dos resíduos: (a) taxa de juros; (b) taxa de desemprego; (c) IPCA; (d) PIB; (e) IPI.....	42
Figura 8 - Comparação da demanda real com os valores obtidos através do modelo de previsão.....	45
Figura 9 - Variação dos valores obtidos através do modelo de previsão em relação a demanda real.....	46
Figura 10 - Distribuição de probabilidades das variáveis de entrada (a) taxa de desemprego; (b) IPCA; (c) taxa de juros e; (d) PIB.....	48
Figura 11 - Histograma de frequência acumulada para a demanda de automóveis.....	49
Figura 12 - Intervalo de demanda futura com maior probabilidade de ocorrência.....	50
Figura 13 - Influência das variáveis na determinação da demanda.....	50

LISTA DE TABELAS

Tabela 1 - Alíquota do IPI de veículos nacionais antes e depois da redução.	19
Tabela 2 - Alíquota do IPI de veículos importados antes e depois da redução.	19
Tabela 3 - Requisitos do programa INOVAR-AUTO.	21
Tabela 4 - Métodos qualitativos para previsão de demanda.	23
Tabela 5 - Séries temporais para previsão de demanda.	25
Tabela 6 - Modelos causais para previsão de demanda.	26
Tabela 7 - Meses de maior demanda de automóveis e comerciais leves nos anos de (a) 2011; (b) 2012; (c) 2013; e (d) 2014.	37
Tabela 8 - Teste de significância da regressão.	43
Tabela 9 - Determinação da soma dos quadrados da regressão (SQ_R).	59
Tabela 10 - Determinação da soma dos quadrados dos erros (SQ_E).	62

SUMÁRIO

1	INTRODUÇÃO	12
1.1	JUSTIFICATIVA	13
1.2	OBJETIVOS	14
1.3	ESTRUTURA DO TRABALHO	14
2	REVISÃO BIBLIOGRÁFICA	15
2.1	INDÚSTRIA AUTOMOTIVA	15
2.2	IPI – IMPOSTO SOBRE PRODUTOS INDUSTRIALIZADOS	18
2.3	INOVAR-AUTO	20
2.4	PREVISÃO DE DEMANDA	22
2.4.1	Técnicas Qualitativas	23
2.4.2	Técnicas Quantitativas	23
2.4.2.1	Modelo de Séries Temporais	24
2.4.2.2	Modelos Causais	25
2.4.2.2.1	Regressão Linear Múltipla	26
2.5	SIMULAÇÃO DE MONTE CARLO	28
3	ELABORAÇÃO DO MODELO DE PREVISÃO DE DEMANDA	31
3.1	DEFINIÇÃO DO PROBLEMA	33
3.2	DIMENSIONAMENTO DO PROCESSO	34
3.3	OBTENÇÃO DE INFORMAÇÕES	35
3.4	ANÁLISE PRELIMINAR DOS DADOS	35
3.5	SELEÇÃO DA TÉCNICA DE PREVISÃO	38
3.6	IMPLEMENTAÇÃO DA TÉCNICA DE PREVISÃO	39
3.7	AVALIAÇÃO DA TÉCNICA DE PREVISÃO	40
3.7.1	Análise Residual	40
3.7.2	Teste para a Significância da Regressão	41
3.7.3	Coefficiente de Determinação	44
3.8	USO DA PREVISÃO	45
4	SIMULAÇÃO DE MONTE CARLO	47
5	CONCLUSÃO	52

5.1	RECOMENDAÇÃO PARA FUTURAS PESQUISAS	53
	REFERÊNCIAS BIBLIOGRÁFICAS	54
	APÊNDICE A - SOMA DOS QUADRADOS DA REGRESSÃO.....	59
	APÊNDICE B - SOMA DOS QUADRADOS DOS ERROS	62

1 INTRODUÇÃO

Em menos de cem anos de presença no mercado brasileiro, a indústria automotiva já conseguiu se consolidar como uma das mais valiosas no país, e também como uma das mais importantes do mundo. Além de ser composta por múltiplas montadoras cujo capital é forte o suficiente para acompanhar as inovações tecnológicas do momento, o Brasil está entre os maiores produtores do mundo, estando atrás apenas de potências mundiais como China, Estados Unidos, Japão e Alemanha.

Em 2007, o setor automotivo brasileiro vivia um momento de destaque, visto que além de apresentar um aumento na produção de veículos, tornando-se o 5º maior produtor do mundo, destacou-se ainda por exportar seus itens para o resto do mundo.

Na época, tal crescimento era auxiliado por uma boa situação político-econômica brasileira, resultante de fortalecimento e expansão de seu mercado interno, e também pela estabilidade em suas taxas de inflação, o que possibilitava melhores prazos para pagamento, e também aumento da disponibilidade de crédito ao financiamento, e do prazo para pagamento.

Porém, em 2008, a crise financeira que atingiu os Estados Unidos teve impactos em todo mundo, inclusive no Brasil, obrigando o governo a criar medidas paliativas para que pudessem contrabalançar a desaceleração vivida no mercado do país. Dentre essas medidas, pode-se citar a redução de até 100% no Imposto sob Produtos Industrializados, o IPI, nos produtos de linha branca.

Tal medida se mostrou eficaz, visto que segundo o relatório da Fenabrave (2009) que disponibiliza informações mensais sobre a aquisição de novos veículos no país, durante o período inicial de redução do IPI, houve um crescimento de 16,73% na compra de automóveis e comerciais leves no mês de Setembro de 2009 quando em comparação com o mesmo período no ano anterior. Ademais, houve um acréscimo de 19,84% em relação ao mês anterior.

Entretanto, após consecutivos adiamentos para manutenção do benefício, no início de 2015 o governo findou tal privilégio devido a necessidade de reequilibrar os cofres públicos, já que através de tal medida, impostos deixaram de ser arrecadados resultando em perdas financeiras para as contas públicas.

As consequências de tal ação para a indústria automotiva se mostraram imediatas, visto que apenas em Fevereiro, o segundo mês após ao retorno do IPI a sua “alíquota cheia”, segundo o

relatório da Fenabreve, houve uma queda de 27,29% no consumo em relação ao mesmo mês no ano anterior; e ainda teve um decréscimo de 26,68% na aquisição de veículos entre Janeiro e Fevereiro deste ano.

Isto é, o mercado antes em ascensão tem se visto obrigado a buscar estratégias internas para contornar sua situação econômica, agora sem auxílios governamentais, para que seja possível contrabalancear as perdas decorrentes as baixas nas vendas. Tais táticas têm sido apresentadas de diferentes formas, seja através de demissões voluntárias ou obrigatórias, planos de férias coletivas, e também através de realizações de layoffs, uma suspensão temporária do contrato de trabalho. Apenas no primeiro dia de Junho de 2015, 16,6 mil trabalhadores foram afastados de suas posições em grandes montadoras, como a Volkswagen e a General Motors, com o objetivo de ajustar a produção à demanda. Um número que no final daquele mês chegou a 40 mil empregados afastados através de uma das estratégias mencionadas anteriormente (Veja, 2015).

1.1 JUSTIFICATIVA

Levando em consideração os fatos históricos mencionados e a carência de estudos envolvendo este tema, este trabalho trata de uma análise de previsão de demanda por automóveis e comerciais leves novos no país. Conforme visto anteriormente, o ritmo de crescimento acelerado do mercado automotivo requer atenção especial, ainda mais quando considerada a queda nas vendas devido à crise financeira que mostra o quanto este mercado é dinâmico e suscetível às variações econômicas do país. Ou seja, são requeridas pesquisas para que sejam minimizados os efeitos resultantes de períodos de dificuldades.

Além disso, conforme confirmado historicamente, houve um crescimento bastante expressivo da demanda após a instalação de benefícios fiscais, e melhorias na qualidade de vida do brasileiro, proporcionado pelo aumento da renda e redução do desemprego. Tais fatores permitiram para que muitos brasileiros, ainda que portadores de um poder de compra menos privilegiado, pudessem adquiridos veículos próprios devido aos baixos custos de venda.

Sendo assim, as perguntas que surgem são:

- I) Quais os fatores de maior influência na demanda por automóveis?
- II) Como esses fatores influenciam o comportamento dessa demanda?

1.2 OBJETIVOS

O objetivo principal deste trabalho é identificar quais são as variáveis que afetam diretamente a procura por automóveis e comerciais leves no Brasil, e através da elaboração de um modelo de regressão múltipla, verificar como tais fatores influenciam a demanda, e analisar o comportamento da mesma, possibilitando que sejam realizados estudos de previsão para períodos futuros. Ademais, o modelo desenvolvido será aplicado em uma Simulação de Monte Carlo visando obter uma distribuição de probabilidades de demandas futuras.

1.3 ESTRUTURA DO TRABALHO

Este estudo está dividido em cinco capítulos, incluindo a introdução. Após, na segunda seção, apresenta-se uma introdução teórica, tendo como base referências bibliográficas, sobre os diversos temas abordados durante a execução deste trabalho apresentando a evolução do mercado automotivo brasileiro e as principais políticas de incentivos fiscais, e também uma breve apresentação do contexto de previsão de demanda e as técnicas comumente utilizadas na elaboração de modelos.

No terceiro capítulo, define-se a metodologia utilizada na elaboração do modelo de previsão, e também o detalhamento da mesma, apresentando o passo-a-passo conforme sugerido por Makridakis et al. (1998). Ainda neste capítulo são apresentados os resultados, referenciando, dados estatísticos do mercado.

No quarto capítulo é realizada uma Simulação de Monte Carlo utilizando o modelo desenvolvido. Utilizando valores randômicos gerados com base nas distribuições estatísticas dos dados das variáveis, serão criados cenários possibilitando uma previsão de demanda para meses futuros.

E, por fim, na quinta e última seção, são tratadas as considerações finais do trabalho seguidas de sugestões para trabalhos futuros ainda no tema desenvolvido.

2 REVISÃO BIBLIOGRÁFICA

Este trabalho tem como base em seu desenvolvimento fundamentações teóricas a respeito do tema proposto, sendo utilizadas referências bibliográficas como embasamento. Na primeira parte, referencia-se à indústria automotiva brasileira e estratégias econômicas governamentais nos últimos anos; enquanto na segunda e terceira partes, o objetivo é contextualizar o contexto de previsão de demanda e técnicas utilizadas em seu desenvolvimento, dando ênfase na análise de regressão múltipla e na simulação de Monte Carlo.

2.1 INDÚSTRIA AUTOMOTIVA

De acordo com Senhoras & Dias (2005), a implementação do setor automobilístico no Brasil, iniciada em 1957, coincidiu com a política de internacionalização da produção de autoveículos através de incentivos, financeiros e administrativos, fornecidos pelo governo. Ainda segundo eles, tal inserção foi originada a partir de interesses lucrativos das transnacionais e intervenções estatais seguindo a ideia de que o Brasil cresceria extraordinariamente a partir da produção de automóveis. Além disso, quando comparada a outros países, a mão-de-obra brasileira tinha um custo baixo, o que impulsionava as vantagens para as multinacionais se instalarem no Brasil. Sendo as primeiras a General Motors, a Volkswagen e a Ford, que devido à ausência de competitividade por parte de empresas brasileiras, dominaram o setor automotivo (Ribeiro, 2014).

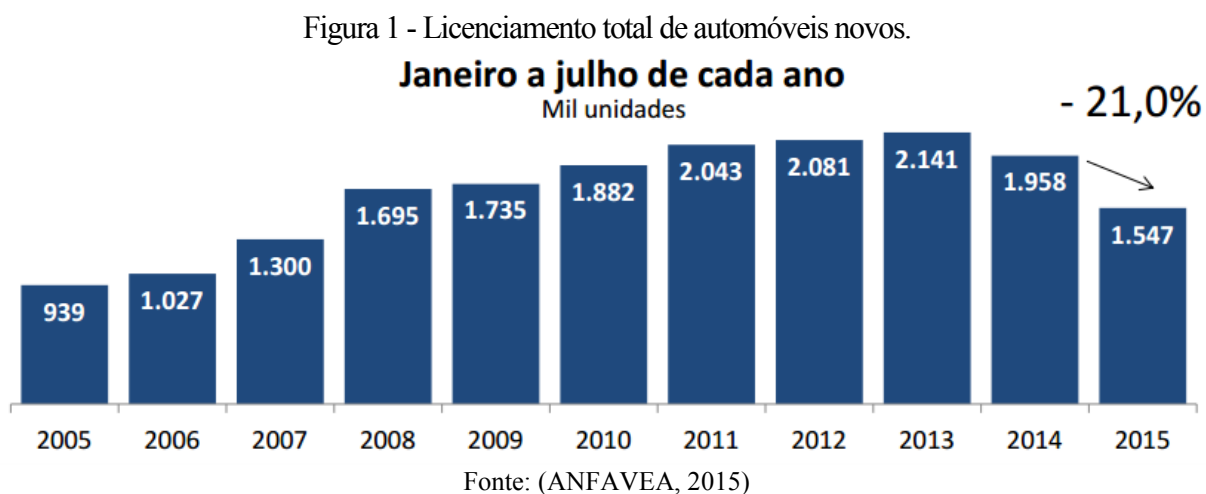
Na década de 80, o mercado interno brasileiro sofreu com as crises do petróleo e inflação, obrigando o governo a mudar suas prioridades, provocando um menor apoio estatal ao setor automotivo (Senhoras & Dias, 2005). De acordo com Porsse (1998), tal crise obrigou as montadoras a focar no mercado externo, uma estratégia pouco explorada até então, baseando-se numa política de diferenciação de produto e adotando novas tecnologias. Porém, a modernização tecnológica das montadoras já estava em andamento, e as empresas mundiais transferiam tecnologia já retrógrada, o que acabou resultando em um atraso tecnológico nos veículos produzidos no país quando em comparação com os fabricados fora, com baixa produtividade e qualidade.

Ainda de acordo com Senhoras & Dias (2005), a prática de globalização de mercados realizada pelo Estado e pelas empresas na segunda metade da década de 90 trouxe novas montadoras para o

país, extinguindo um grande número de produtores nacionais e compondo o setor automobilístico brasileiro por empresas com capital suficiente para acompanhar as inovações tecnológicas do período.

Segundo Confessor (2012), desde então, o mercado automotivo brasileiro vinha crescendo e consolidando sua importância no mercado global. Em 2011, mesmo ainda sob efeitos da crise financeira mundial, conforme matéria publicada pela revista *Veja* (2010), o mercado automotivo brasileiro era um dos maiores do país e do mundo, sendo o 5º maior produtor mundial, atrás apenas das potências China, Estados Unidos, Japão e Alemanha, tornando-o um mercado muito atraente. O setor é composto por múltiplas montadoras, sendo as montadoras veteranas Ford, Fiat, Volkswagen e General Motors (GM), e as montadoras “entrantes” Renault, PSA Peugeot Citroën, Toyota, Honda, e Daimler Chrysler as principais no mercado brasileiro (Anfavea, 2011).

Porém, devido à crise financeira, o setor tem sofrido desacelerações no ritmo de vendas nos últimos anos, sendo que segundo o relatório do mês de Julho da Anfavea (2015), as vendas de automóveis no mês esse ano foram 22,8% inferiores às do mesmo mês no ano anterior. Além disso, como mostra a Figura 1, quando comparados o primeiro semestre desde e do último ano, houve uma queda de 21% nas vendas.



Ainda no mesmo relatório, as estatísticas mostram que para se adequar ao mercado, o nível de produção no primeiro semestre desse ano caiu 18,1% quando comparado ao mesmo período em 2014, vide Figura 2. Como consequência desse nível de produção menor que o normal, os pátios das montadoras têm permanecido cheios, uma vez que com a baixa nas vendas, os estoques em montadoras têm sido reduzidos quando comparados aos meses anteriores, vide Figura 3.

Figura 2 - Produção de autoveículos montados.





Figura 3 - Estoque de autoveículos.



Fonte: (ANFAVEA, 2015)

Ainda assim, conforme o relatório de perspectivas de investimento publicado pelo BNDES (2014), o setor automotivo terá investimentos estimados em aproximadamente US\$ 23 bilhões entre 2015 e 2018, com recursos destinados ao desenvolvimento de novos produtos, à modernização fabril, e também à ampliação da capacidade produtiva em até 50% através da expansão de plantas existentes.

2.2 IPI – IMPOSTO SOBRE PRODUTOS INDUSTRIALIZADOS

O IPI, Imposto sobre Produtos Industrializados, de acordo com Ramos & Teixeira (2009), é um imposto que incide sobre produtos nacionais ou internacionais, desde que de origem industrializada. Isto é, oriundo de operações que ocasione alterações em sua finalidade, acabamento, funcionamento, independente do processo ou meio de obtenção ou localização de origem deste. Tais produtos são tributados, ainda que sob alíquota zero, obedecendo as especificações constantes na Tabela de Incidência do Imposto sobre Produtos Industrializados, a TIPI, e suas disposições estão regulamentadas pelo Decreto 7.212/2010.

Segundo Angelo & Neutzling Junior (2014), trata-se de um imposto extrafiscal, cuja principal função não é a de arrecadar recursos financeiros, mas de incentivar determinados mercados através de alíquotas menores, sendo em alguns casos até zero. Ou seja, através dele, o governo pode estimular o comércio de certos produtos e desestimular o de outros, inibindo a compra de produtos importados e incentivando o consumo de produtos nacionais.

Devido à crise financeira mundial, cujo início se deu em 2008 com o estopim da crise imobiliária dos Estados Unidos, o Governo brasileiro passou a interferir mais frequentemente na condução da economia do país, com o objetivo de combater os efeitos dessa crise econômica no Brasil. Portanto, foram adotadas medidas de redução de alíquotas do IPI para automóveis e bens domésticos da “linha branca”, com a intenção de evitar uma recessão e preservar o equilíbrio econômico através de um aumento no consumo de produtos do mercado interno.

Com início em Dezembro de 2008, a primeira redução total, feita por meio da MP nº 451/08 tinha previsão de duração de apenas três meses, porém, devido a prorrogações consecutivas, essa se estendeu por mais seis meses além do previsto, encerrando-se no final de Setembro de 2009. Porém, em frente ao agravamento da crise financeira mundial, tal medida foi aplicada novamente entre Maio e Dezembro de 2012 visando atenuar problemas provenientes da crise. Entretanto, a partir de Janeiro de 2013 as alíquotas foram subindo gradualmente, da mesma forma como atuou entre Outubro de 2009 e Março de 2010, e mesmo com previsão de término para Agosto de 2013, o incentivo se estendeu até o final do ano seguinte (Wilbert et al., 2014).

A Tabela 1 mostra o comportamento da alíquota do IPI para veículos nacionais desde sua primeira implementação. Já a Tabela 2 apresenta o mesmo comportamento para os automóveis importados.

Tabela 1 - Alíquota do IPI de veículos nacionais antes e depois da redução.

Mês/Ano	Cilindradas	Antes da Redução	Depois da Redução
Dezembro de 2008 a Setembro de 2009	Até mil (1.0)	7%	0%
	De mil (1.0) a duas mil (2.0) – Álcool e Biocombustível	11%	5,5%
	De mil (1.0) a duas mil (2.0) – Gasolina	13%	6,5%
	Veículos utilitários	4%	1%
Maio a Dezembro de 2012	Até mil (1.0)	7%	0%
	De mil (1.0) a duas mil (2.0) – Álcool e Biocombustível	11%	5,5%
	De mil (1.0) a duas mil (2.0) – Gasolina	13%	6,5%
	Veículos utilitários	4%	1%
2013	Até mil (1.0)	7%	2%
	De mil (1.0) a duas mil (2.0) – Álcool e Biocombustível	11%	7%
	De mil (1.0) a duas mil (2.0) – Gasolina	13%	8%
	Veículos utilitários	4%	2%

Fonte: (WILBERT et al., 2014)

Porém, por mais benefícios que essas sequências de reduções no IPI trouxeram ao país, também resultaram em perdas para o governo, visto que apenas nos últimos três anos, R\$ 11 bilhões foram deixados de ser arrecadados do setor automotivo. E devido à forte deterioração que as contas públicas sofreram em 2014, tal arrecadação será necessária para reequilibrá-las. Por essa razão, conforme publicado pela Secretaria da Receita Federal do Brasil (2015), desde Janeiro de 2015, o IPI para automóveis voltou a chamada “alíquota cheia”, ou seja, ausência de incentivos nesse setor através desse imposto.

Tabela 2 - Alíquota do IPI de veículos importados antes e depois da redução.

Cilindradas	Até 12/2014	A partir de 01/2015
Até mil (1.0)	3%	7%
De mil (1.0) a duas mil (2.0) – Álcool e Biocombustível	9%	11%
De mil (1.0) a duas mil (2.0) – Gasolina	10%	13%
Veículos utilitários	3%	4-8%

Fonte: (WILBERT et al., 2014)

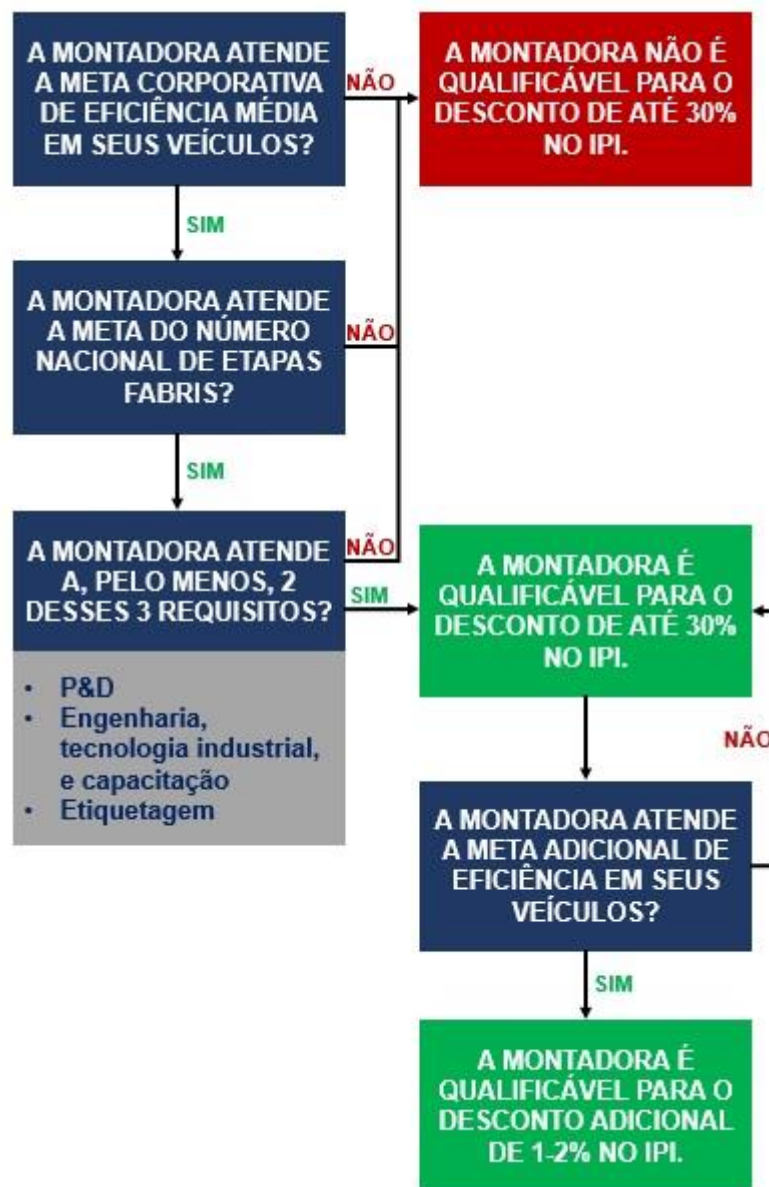
2.3 INOVAR-AUTO

De acordo com sua página oficial no website do Ministério do Desenvolvimento, Indústria e Comércio Exterior (2015), o Programa de Incentivo à Inovação Tecnológica e Adensamento da Cadeia Produtiva de Veículos Automotores, anunciado em 2012 e conhecido como INOVAR-AUTO, é um regime automotivo do Governo Brasileiro criado em substituição ao regime vigente de redução de alíquotas de IPI. Seus objetivos são criar condições para o aumento de competitividade no setor automotivo, investir na cadeia de fornecedores, engenharias, tecnologias industriais básicas, pesquisa e desenvolvimento, e produzir veículos mais econômicos, seguros, e energeticamente eficientes reduzindo a emissão de CO₂ a níveis aceitáveis.

Apresentado pela Medida Provisória 563/2012 e posteriormente convertido na Lei 12.715/12, o programa está em vigor desde o início de 2013, beneficia empresas que produzem veículos no país ou, ao menos, os comercializam, ou apresentam projetos de investimento para a produção nesse setor (Leão & Goulart, 2012).

Segundo Façanha (2013), o projeto, cuja duração é de cinco anos, beneficiará as montadoras com descontos de até 30 pontos percentuais adicionais no IPI para veículos de produção nacional e importados. Porém, para serem aptos a receber esse desconto, deverão melhorar a eficiência média de seus novos veículos em cerca de 12%, e terão que cumprir com requisitos ou etapas determinadas pela legislação investindo determinadas porcentagens de suas vendas em – (1) investimentos em pesquisas e desenvolvimento, (2) investimentos em engenharia, tecnologia industrial, e capacitação, e (3) participação no Programa Brasileiro de Etiquetagem Veicular. Além disso, as montadoras também podem receber de 1 a 2% adicionais de desconto se cumprirem metas de eficiência mais rigorosas nos veículos. Os requisitos que as montadoras deverão cumprir para cada etapa anual do INOVAR-AUTO estão indicados na Figura 4 e na Tabela 3.

Figura 4 - Requisitos do programa INOVAR-AUTO.



Fonte: (FAÇANHA, 2013)

Tabela 3 - Requisitos do programa INOVAR-AUTO.

Ano	Número Mínimo de Etapas Fabris	Pesquisa & Desenvolvimento	Engenharia / Tecnologia Industrial	Etiquetagem
2013	6	0,15%	0,50%	36%
2014	7	0,30%	0,75%	49%
2015	7	0,50%	1,00%	64%
2016	8	0,50%	1,00%	81%
2017	8	0,50%	1,00%	100%

Fonte: (FAÇANHA, 2013)

Leão e Goulart (2012) afirmam também que ainda que com o fortalecimento da indústria nacional, o nível de competitividade do país aumente, o novo regime pode trazer barreiras à inserção do mercado brasileiro no contexto mundial de fornecedores globais de novas e modernas tecnologias, e dificultar a instalação de novas fábricas no país, visto que montadoras estrangeiras têm processos estabelecidos obtendo menor custo e melhor tecnologia, atendendo aos avanços do mercados, o que é inviável em um país que só beneficiará maiores produtores locais. Apesar do regime ter previsão de cinco anos, a competitividade do mercado automobilístico brasileiro poderá ter um avanço mais lento em comparação ao restante do mundo.

2.4 PREVISÃO DE DEMANDA

Em qualquer mercado, uma das maiores preocupações de fornecedores é realizar uma efetiva previsão de demanda, pois é através dela que é possível evitar prejuízos e obter bons lucros. Segundo a página online do dicionário Michaelis (2015),

Demanda é a quantidade de um determinado produto ou serviço que uma coletividade está necessitando e procurando, ou que, por previsões, se avalia que ela necessitará e procurará em certa data.

A partir desse conceito de coletividade, origina-se o que é denominado demanda de mercado. (Werner, 2004).

Segundo Kotler (1998), uma previsão de demanda pode variar em nível de produto (item ou linha do produto), em nível de espaço (consumidor e região de consumo) e em nível de tempo de prazo. Ainda assim, são poucos os produtos cuja demanda é facilmente previsível, pois em grande parte, os mercados são instáveis, o que torna a precisão da previsão de demanda um fator-chave para o sucesso.

De acordo com Makridakis et al. (1998), usualmente, as técnicas de previsão são caracterizadas como qualitativa, baseadas em opiniões e preferências, ou quantitativa, baseadas em modelos estatísticos com informações acessíveis sob forma numérica.

2.4.1 Técnicas Qualitativas

Para Moreira (2009), as técnicas qualitativas baseiam-se em informações subjetivas, como julgamento e experiência das pessoas, contanto que essas tenham capacidade de contribuir positivamente com o julgamento de uma demanda futura. Tais técnicas dispensam a utilização de modelos matemáticos, e quando utilizadas de forma eficiente, são capazes de ter resultados mais objetivos do que as técnicas quantitativas. (Pinto e Mazzon, 2010)

Moreira (2009) ainda cita como exemplo de técnicas nessa categoria a popularmente conhecida Pesquisa de Mercado. Ademais, também são bastante utilizadas as Opiniões de Executivos, a Opinião das Forças, a Técnica Delphi, e a Analogia Histórica, sendo a última a mais utilizada por empresas para realizar previsão de demanda de novos produtos utilizando dados de produtos similares para estimar as vendas, uma vez que estes ainda não possuem um histórico de demanda.

Guimarães et al. (2008) descrevem algumas técnicas qualitativas conforme a Tabela 4.

Tabela 4 - Métodos qualitativos para previsão de demanda.

TÉCNICA DE PREVISÃO	CARACTERÍSTICAS
Método Delphi	Processo de aprendizado interativo envolvendo um grupo de especialistas que respondem a um questionário. Um mediador reúne os resultados e formula um novo questionário, que é apresentado ao mesmo grupo de especialistas.
Pesquisa de mercado	Consiste em coletar dados de várias maneiras (levantamentos, entrevistas, etc.) para testar hipóteses sobre o mercado. É tipicamente utilizada para realizar previsões de longo prazo e para a venda de novos produtos.
Analogia histórica	Relacionada com a previsão de demanda de um produto similar. É importante no planejamento de novos produtos, no qual uma previsão é derivada da trajetória de um produto similar existente.

Fonte: (GUIMARÃES et al., 2008)

2.4.2 Técnicas Quantitativas

As técnicas quantitativas, segundo Ruschel et al. (2007), diferente das técnicas qualitativas, são métodos que utilizam de modelos matemáticos para poder descrever o comportamento da demanda em função do tempo. Para isso, utilizam-se de dados históricos que podem contribuir para que o padrão passado se repita no futuro.

Além disso, Guimarães et al. (2008) afirmam que tais técnicas possuem uma abordagem mais objetiva, e para isso utilizam informações estatísticas que possam ser medidas e contadas. Dentre os principais métodos utilizados em previsão de demanda estão séries temporais e os modelos causais, que aborda a análise de regressão múltipla.

2.4.2.1 Modelo de Séries Temporais

Figueredo (2008) define uma série temporal como uma coleção de n observações de uma dada variável realizada ao longo do tempo t (horas, dias, semanas, meses, etc.), sendo tais observações interdependentes realizadas sequencialmente em intervalos de tempo discretos e equiespaçados, podendo ser representada sob a forma $\{Z_t, t = 1, 2, \dots, n\}$, ou seja, $\{Z_1, Z_2, Z_3, \dots, Z_{n-1}, Z_n\}$.

O objetivo da análise de séries temporais é a identificação de padrões nas propriedades ou características da variável de interesse, e avaliar se o comportamento da mesma no passado pode auxiliar na previsão de informações futuras, possibilitando a construção de um modelo matemático como representação da realidade.

De acordo com Werneck (2007), uma série temporal normalmente é composta por três elementos: tendência, sazonalidade e o erro. A tendência é um comportamento apresentado pela série durante um período de tempo, sendo ela ascendente ou descendente; a sazonalidade é caracterizada por padrões cíclicos de variação que ocorrem em intervalos constantes de tempo, ou então aproximadamente constantes; e o erro é uma variabilidade inerente que não pode ser modelado (Furtado, 2006). Dessa forma, como poder ser verificado na equação 1, um modelo clássico para séries temporais pode ser de forma aditiva ou multiplicativa, sendo composto pelos elementos citados acima: tendência (T_t), sazonalidade (S_t) e um termo aleatório ou erro (a_t). (Pacheco & Silva, 2003)

$$Z_t = T_t + S_t + a_t \text{ ou } Z_t = T_t \times S_t \times a_t \quad (1)$$

Alguns modelos de previsão elaborados através de séries temporais são apresentados na Tabela 5.

Tabela 5 - Séries temporais para previsão de demanda.

TÉCNICA DE PREVISÃO	CARACTERÍSTICAS
Média móvel simples	Média de um dado número de períodos que é atualizada, substituindo os dados do período anterior pelos dados do período mais recente. Se a demanda de um produto não cresce nem decresce rapidamente, e se também não apresenta nenhuma característica sazonal, uma média móvel simples pode ser útil na identificação de uma tendência dentro da flutuação de dados.
Média móvel ponderada	Variação simples da técnica de média móvel que aceita pesos para serem designados de acordo com a natureza dos dados da média. Permite a cada elemento ser ponderado por um fator, no qual a soma de todos os pesos é igual a um. É possível também utilizar a técnica para prever mais de um período no tempo futuro.
Média ponderada exponencial	Técnica de previsão de demanda por séries temporais que não requer grande quantidade de dados históricos. Se a importância dos dados diminui com o passar do tempo, então, a média ponderada exponencial pode ser o método mais lógico e fácil a ser utilizado. Cada incremento do passado é diminuído por $(1 - \alpha)$, sendo α uma constante entre 0 e 1. Faz, praticamente, o mesmo que a previsão de média móvel, mas requer, relativamente, um menor número de dados. Apenas três grupos de dados são necessários para prever o futuro: as previsões mais recentes, a demanda real que ocorreu para este período de previsão e a constante (α) .

Fonte: (GUIMARÃES et al., 2008)

Vale ressaltar que nem toda observação realizada em um intervalo de tempo pode ser caracterizada como série temporal, como por exemplo jogos de azar, pois as informações do passado não podem prever resultados futuros (Werneck, 2007).

2.4.2.2 Modelos Causais

De acordo com Guimarães, Fortes e Paiva (2008), os modelos causais buscam estabelecer regras ou leis que descrevam a relação existente entre a variável de resposta e os diferentes fatores que a influenciam com intuito de realizar a previsão desejada. Ainda afirmam que essas análises permitem avaliar suas influências e impor alterações na intenção de determinar seu impacto na geração da previsão. A Tabela 6 descreve cinco técnicas que utilizam modelos causais.

Tabela 6 - Modelos causais para previsão de demanda.

TÉCNICAS DE PREVISÃO	CARACTERÍSTICAS
Modelos causais univariados	São aqueles modelos cuja variável dependente é função de uma única variável explicativa. Suas principais vantagens são a simplicidade e a operacionalidade. São frágeis do ponto de vista da aceitação teórica. Além disso, muitas vezes, eles não apresentam bons resultados empíricos, em razão de sua extrema simplificação da realidade.
Modelos causais multivariados	Estes modelos incluem duas ou mais variáveis explicativas na modelagem da variável estudada. Em comparação com aqueles de variável explicativa única, aproximam-se mais da complexidade do mundo real.
Modelos causais auto-regressivos	São aqueles que incluem, entre as variáveis explicativas, valores defasados da própria variável dependente. Diferem dos modelos de defasagem distribuída por apresentarem, na forma defasada, a variável estudada, ao invés da conhecida. Quando causais, estes modelos devem incluir também variáveis explicativas comuns, presentes na forma defasada ou não. Se excluídas as variáveis explicativas comuns, a equação resulta em um modelo auto-regressivo univariado, utilizado como método de estimação de modelos de séries temporais.
Modelos estruturais multivariados de séries temporais	Os modelos estruturais univariados de séries temporais podem ser incrementados a partir da inclusão de variáveis explicativas, resultando em um modelo estrutural multivariado de séries temporais.
Análise de regressão múltipla	Neste modelo, mais de uma variável independente é considerada, juntamente com os efeitos de cada um dos elementos de interesse. É muito apropriada quando um número de fatores pode influenciar uma variável de interesse. É a técnica causal mais utilizada na projeção de demanda. Esse tipo de sistema examina a influência que têm os fatores escolhidos, como níveis de renda dos turistas, custos da viagem ao destino, preços relativos ou a taxa de câmbio.

Fonte: (GUIMARÃES et al., 2008)

2.4.2.2.1 Regressão Linear Múltipla

Segundo Montgomery et al. (2001), a regressão linear é uma ferramenta estatística cuja função é modelar e investigar a relação entre diferentes variáveis. Essa técnica de previsão pode ser classificada em duas variações: a Regressão Linear Simples, e a Regressão Linear Múltipla. A diferença principal entre ambas é bastante simples: enquanto na regressão linear simples existe apenas uma variável explicativa que influencia o comportamento do modelo, na regressão linear

múltipla ao menos duas variáveis independentes explicam o modelo regressivo, podendo esse número de regressores ser muito maior (Rodrigues, 2012).

Taconelli (2010) afirma que na regressão linear múltipla, o objetivo é compreender a natureza e a significância da relação entre as variáveis dependente e independentes; e que quanto maior é o número de variáveis regressoras incluídas no modelo, mais adequada será a explicação da variável resposta e melhor será o desempenho do preditivo. Ele ainda considera que para uma melhor elaboração do modelo, alguns critérios devem ser observados: (1) Avaliação e quantificação do efeito das variáveis independentes nos resultados da variável de resposta; (2) Verificação da possibilidade de retirada de algum desses regressores devido à ausência de efeito sobre a variável dependente, e; (3) Verificação de possíveis variáveis candidatas a serem incluídas no modelo.

Segundo Montgomery & Runger (2009), a equação característica de um modelo de regressão múltipla é dada pela equação 2,

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon \quad (2)$$

sendo Y a variável dependente ou de resposta, x_j ($j = 0, 1, \dots, k$) as variáveis independentes, β_j ($j = 0, 1, \dots, k$) os coeficientes parciais de regressão, e ϵ o erro. Entretanto, podem haver algumas variações desse modelo devido a interações entre as variáveis, como mostra a equação 3,

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2 + \dots + \beta_k x_k + \epsilon \quad (3)$$

ou até mesmo exponencialização de alguma variável devido a sua interação com ela mesma, criando modelos de segunda ordem.

De acordo com Neter et al. (2004), na medida de adequação dos parâmetros destes modelos, o teste de significância da regressão, também conhecido como teste de aderência ou ANOVA, é uma importante ferramenta, visto que a partir da realização deste, é possível verificar a existência de relação linear entre o preditando e os preditores. As hipóteses desse teste indicam que para H_0 , os coeficientes de regressão são nulos, eliminando a significância do modelo, enquanto para H_1 existe ao menos um coeficiente diferente de zero, indicando que ao menos uma das variáveis de controle é estatisticamente significativa para o modelo (Montgomery et al., 2001).

Montgomery & Runger (2009) ainda complementam com outro método de avaliação do preditor, o coeficiente de determinação (R^2). Este avalia a proporção da variação nas variáveis

dependentes que é explicada pela linha de regressão. Seu valor varia na faixa $0 \leq R^2 \leq 1$, ou seja, seu valor é zero quando nenhuma parcela da variação de Y é explicada pela regressão, e um quando toda a variação de Y é explicada pela regressão (McGuigan, Moyer e Harris, 2010).

Dessa forma, é possível, através da examinação de tais funções, compreender ou descobrir as causas do relacionamento entre diversos atributos pesquisados, e relacioná-los a algum tipo de equação matemática, que mesmo inicialmente insignificante, pode ser de grande utilidade na previsão de fenômenos e antecipação de resultados que apenas seriam conhecidos ao final do processo (Guimarães, 2011).


2.5 SIMULAÇÃO DE MONTE CARLO

De acordo com Lima et al. (2008), a simulação de Monte Carlo é uma técnica originada em 1949, pelos matemáticos John von Neumann e Stanislaw Ulam, cujo objetivo é a resolução de problemas através da utilização da probabilidade e números aleatórios. O nome desta técnica é uma homenagem a cidade homônima, localizada em Mônaco, devido a sua atividade principal, os jogos de cassino.

Tal método, segundo Fernandes (2005), permite simular processos cujo funcionamento dependa de fatores aleatórios, atuando como uma ferramenta universal para a solução de problemas matemáticos.

As variáveis de entrada do modelo apresentam um certo padrão de distribuição, e a partir desses, são gerados valores randômicos para cada variável obedecendo os padrões da distribuição. Os resultados de cada iteração são armazenados, e ao final do processo, finalizadas as iterações, a sequência de resultados é convertida em uma distribuição cujos parâmetros estatísticos podem ser calculados (Almeida Filho, 2008). Este processo, para um modelo com quatro variáveis, é ilustrado na Figura 5.

Figura 5 - Processo de simulação de Monte Carlo com quatro variáveis.



Fonte: (PONCIANO et al., 2004)

Ainda segundo Lima et al. (2008), uma das grandes vantagens dessa técnica é que uma simulação pode envolver mais de 10.000 avaliações do modelo estudado, algo que no passado era exequível apenas por supercomputadores. Vose (1996) ainda complementa com outros benefícios em relação aos outros métodos, como melhor precisão a partir do aumento do número de iterações; facilidade na realização de alterações no modelo; e existência de softwares amplamente disponíveis no mercado.

Ainda de acordo com Vose (1996), esta técnica é mundialmente utilizada e reconhecida como válida, o que permite a aceitação dos resultados sem dificuldades. Muito utilizada diversos campos, diversos autores utilizaram da mesma em seus projetos, desde quantificação de incertezas

ambientais a previsão de variações nos custos de produção na companhia Vale do Rio Doce (Monteiro, Santos & Werner, 2012).

3 ELABORAÇÃO DO MODELO DE PREVISÃO DE DEMANDA

Segundo Furtado (2006), a previsão é uma atividade essencial para qualquer empresa, visto que é através dela, ainda na etapa de planejamento, que se definem estratégias e planos de ação orientados para o futuro. Além disso, o ato de prever é inerente ao ser humano, visto que mesmo não as reconhecendo como tal, estamos sempre fazendo previsões, seja em como organizar nossas atividades do dia, ou até mesmo viagens (Abraham & Ledolter, 1983).

Abraham & Ledolter (1983) ainda afirmam que prever é antecipar resultados futuros, e mesmo que bem executados nunca serão perfeitas, já que ainda incluirão incertezas. Portanto, um dos objetivos principais da previsão é reduzir o erro da mesma.

Segundo Makridakis et al (1998), quaisquer previsores possuem uma grande variedade de técnicas disponíveis para sua elaboração, e as mesmas diferenciam em exatidão, objetivo, horizonte de tempo, entre outros. Para ele, a estruturação adequada de um sistema de previsão requer que sejam cumpridas diversas etapas. Dessa forma, é possível obter um modelo de previsão que satisfaça as condições impostas no objetivo, de forma precisa, e dentro do tempo desejado.

As etapas mencionadas para a elaboração do modelo de previsão de demanda deste trabalho são:

1. Definição do problema;
2. Dimensionamento do processo;
3. Obtenção de informações;
4. Análise preliminar dos dados;
5. Seleção da técnica de previsão;
6. Implementação da técnica de previsão;
7. Avaliação da técnica de previsão;
8. Uso da previsão.

Além de facilitar a elaboração do modelo, cada etapa contribui para que ele seja desenvolvido gradativamente e sendo analisado e avaliado a cada passo executado, reduzindo então a possibilidade de erros ao final do processo oriundos de etapas anteriores.

De acordo com Makridakis et al. (1998), a primeira etapa do desenvolvimento do modelo de previsão costuma ser uma das mais complexas, pois é aonde é definido o problema de previsão, e é a partir dessa noção que são originadas a compreensão de como deve ser utilizada e como ela se ajusta a adversidade em questão.

Após, no dimensionamento do processo, são especificados quais os tipos de entrada que estão disponíveis, os resultados que desejam obter e quais as suposições sobre o comportamento das variáveis que irão ser utilizadas (Murdoch & Georgoff, 1993). A importância dessa etapa se dá na definição das variáveis que serão utilizadas no processo de modelagem, levando em conta sua possível influência no resultado em questão.

Definidas as variáveis do modelo, a próxima etapa consiste na obtenção de informações das mesmas, que normalmente são disponibilizadas nas formas de dados estatísticos, quando quantitativas, e opiniões de especialistas, quando qualitativas.

Na análise preliminar dos dados, é realizada uma exploração dos dados obtidos e interpretação do comportamento dos mesmos para que seja definido qual o modelo a ser utilizado, seja ele qualitativo ou quantitativo, e através de qual técnica esses dados deverão ser manipulados. Segundo Makridakis et al. (1998), nos casos onde há a disponibilidade de dados estatísticos, o primeiro passo a ser seguido nesta etapa é a inspeção visual das informações através de gráficos. Assim, é possível verificar padrões, sazonalidades e tendências e agrega-los à previsão.

A seleção da técnica de previsão a ser utilizada depende basicamente da exatidão, do objetivo, do horizonte de tempo desejados, ou seja, das características das informações obtidas para as variáveis. A escolha também sofrerá influência dos resultados obtidos em etapas anteriores, como por exemplo, influência de dados históricos nos futuros, e também o comportamento das variáveis analisados na etapa anterior (Makridakis et al., 1998).

Na sexta etapa é realizada a implementação da técnica de previsão que consiste na construção de modelos relevantes aos dados, e nos casos onde há teoria econômica, deve-se levar em consideração a mesma. Segundo Makridakis et al. (1998), após a implementação bem-sucedida, é possível realizar uma avaliação do modelo através das informações disponibilizadas pela aplicação da previsão. A partir dessa referência, são medidos os erros e caso estes sejam aceitáveis, o modelo pode ser utilizado e, conseqüentemente, os resultados obtidos a partir dele.

Além de medir os erros de previsão, existem outros métodos para avaliação do modelo. De acordo com Montgomery & Runger (2009), a análise residual e o teste ANOVA são importantes meios de se investigar a qualidade do modelo criado.

Destarte, na elaboração do modelo de previsão de demanda, foi utilizada a metodologia sugerida por Makridakis visando a facilitação do desenvolvimento, e a obtenção de resultados de adequada acurácia.

3.1 DEFINIÇÃO DO PROBLEMA

Antes, em rápido crescimento devido aos investimentos governamentais como redução da alíquota do IPI e crédito farto, o mercado automotivo se tornava um dos maiores produtores de veículos no mundo, com sucessivos anúncios de expansão de capacidade produtiva e outros investimentos no país. Porém, nos últimos meses, durante períodos de altas vendas, a eliminação de tais benefícios governamentais e a crise que tem acometido o mercado financeiro nos últimos anos tem atingido diretamente o faturamento da indústria automotiva.

Com risco de inadimplência, e medo de elevação da taxa de inflação, o mercado interno tem perdido suas vantagens gerando grande retração. Conforme mencionado na seção 2.1, as vendas entre Janeiro e Junho caíram cerca de 21% em relação ao mesmo período no ano passado, e além disso, com a redução no ritmo de vendas, as indústrias se vêm com altos estoques e concessionárias cheias de veículos, o que tem acarretado em medidas preventivas como redução de turnos, mão-de-obra, layoffs, demissões, e até encerramento de atividades de revendedoras.

Em contrapartida, em substituição a redução da alíquota do IPI, o governo lançou o Programa INOVAR-AUTO com o intuito de incentivar não apenas aumentar a competitividade no setor automotivo, mas também reduzir as emissões de gases do efeito estufa; para isto, as montadoras devem atender uma série de requisitos até o final de 2017 para receberem como recompensa descontos em pontos percentuais no IPI.

Sendo assim, o problema que deve ser tratado por esse modelo é a previsão de demanda de automóveis e comerciais leves no país, com o objetivo de reduzir tamanha discrepância entre os índices de demanda e vendas existentes atualmente neste mercado, e por consequência possibilitar o desenvolvimento de políticas de planejamento nos mais diversos campos.

3.2 DIMENSIONAMENTO DO PROCESSO

Na etapa de dimensionamento foram especificadas quais são as informações de entrada que possivelmente teriam relação com a variável de saída, ou seja, a demanda de veículos.

Uma vez que a situação econômica do país tem grande peso na variação da demanda de automóveis, podem ser consideradas como possíveis variáveis de entrada o Produto Interno Bruto real do país e a taxa de juros para financiamento de veículos novos vigente no período. A primeira representando o crescimento financeiro, enquanto a outra apresenta o comportamento do crédito disponibilizado para a aquisição do produto em questão.

Uma vez que o poder de compra do consumidor também tem relação com o nível das vendas, o rendimento médio nominal do trabalhador e o índice de Preço ao Consumidor Amplo (IPCA) também são candidatas a variáveis de entrada. O rendimento representa diretamente o poder aquisitivo do consumidor, enquanto o IPCA é o índice oficial de inflação.

Além destas, uma outra candidata que tem relação direta com o poder de compra do consumidor é a taxa de desemprego, pois quando esta se encontra em alta, o poder aquisitivo do indivíduo é consideravelmente reduzido. Ademais, também é fortemente afetado pela economia, e seu comportamento também é um indicativo do momento econômico do país.

Conforme mencionado na seção 2.1, os incentivos governamentais foram grandes impulsionadores de vendas no mercado automotivo, sendo assim plausível supor que a alíquota do IPI, em suas variações, também possui ligação com a variável dependente em questão.

Sendo assim, em resumo, consideradas como candidatas a variáveis explicativas:

- Taxa média de juros para pessoas físicas nas operações de crédito para aquisição de veículos.
- Rendimento médio nominal do trabalho principal.
- Taxa média de desemprego.
- Índice de preço ao consumidor amplo.
- Produto interno bruto real do país.
- Alíquota de imposto sobre produtos industrializados em automóveis novos.

3.3 OBTENÇÃO DE INFORMAÇÕES

Segundo Pellegrini & Fogliatto (2001), para que as possíveis variáveis de entrada sejam avaliadas, é necessário que exista ao menos um tipo de informações das mesmas: dados estatísticos e/ou o julgamento de especialistas, para que sejam realizadas análises qualitativas e/ou quantitativas.

Por se tratarem de variáveis macroeconômicas, quase todas dentre as hipóteses escolhidas possuem dados históricos estatísticos que podem ser utilizados como embasamento para a análise de previsão.

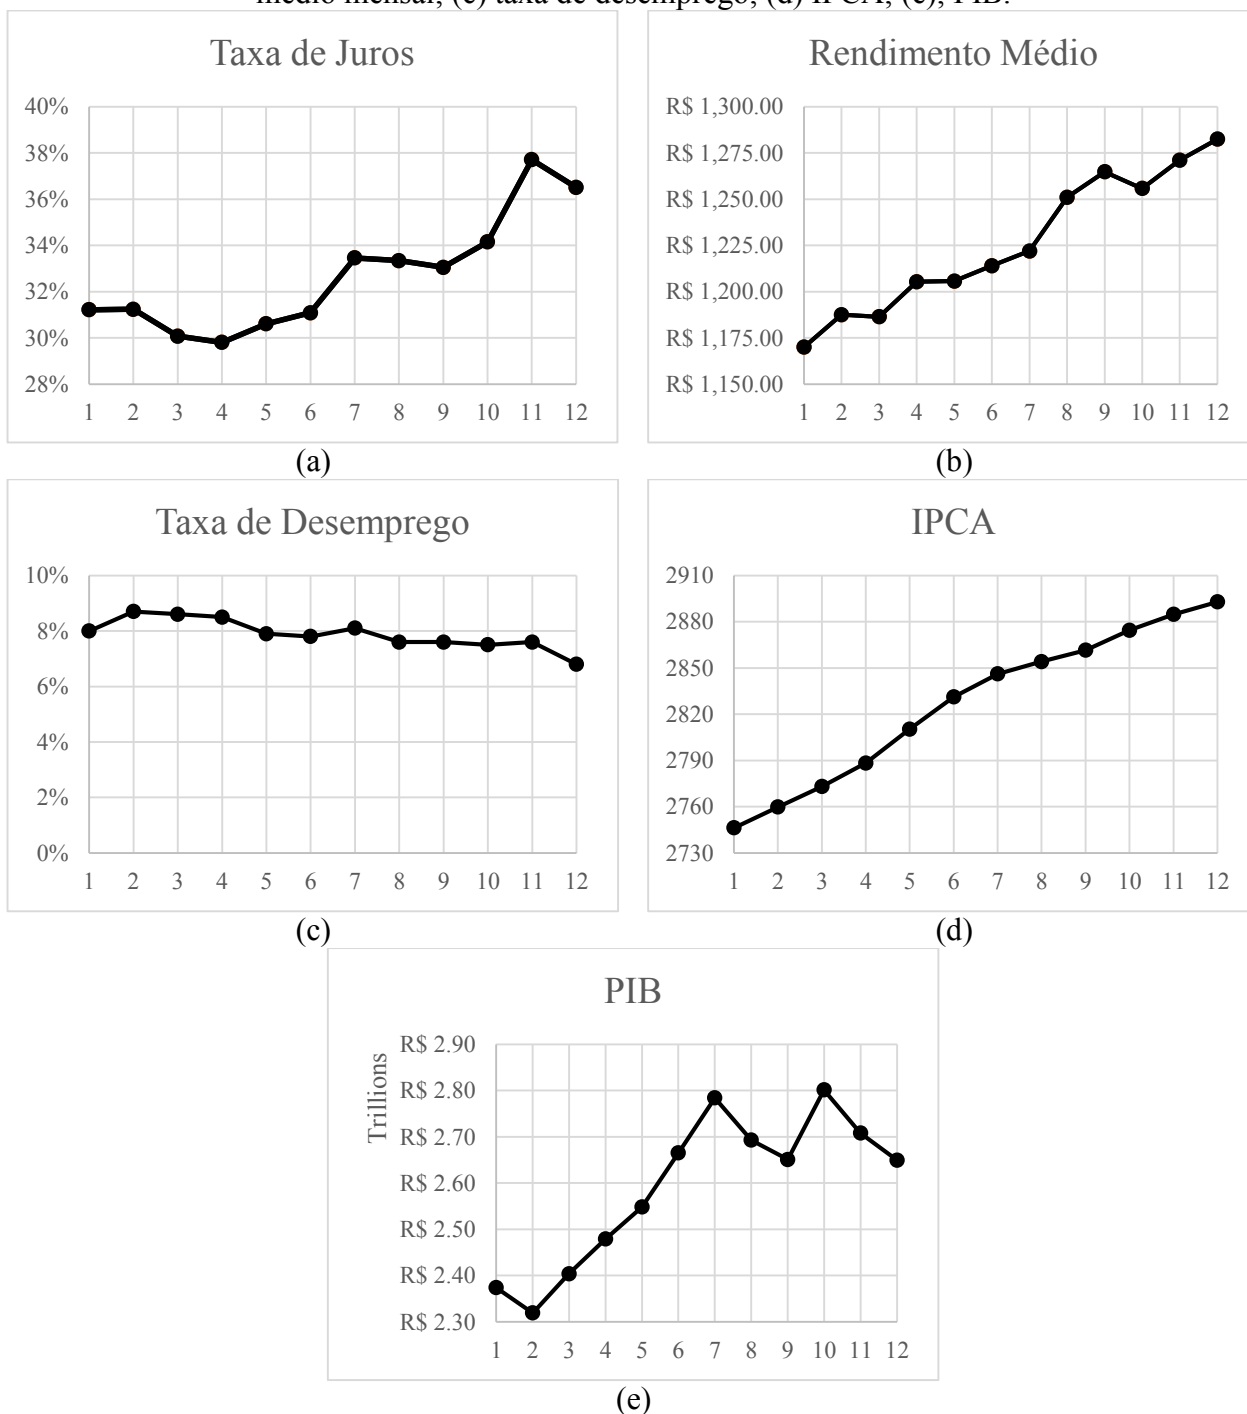
Dentre as principais referências bibliográficas destacam-se o site da FENABRAVE (Federação Nacional de Distribuição de Veículos Automotores) que disponibiliza em relatórios mensais a demanda de todos os segmentos veiculares, e inclusive cada modelo de automóvel, correspondente àquele mês, e também comparações históricas desses dados; do BCB (Banco Central do Brasil), fonte para a obtenção de taxas de juros mensais para cada aplicação do mercado; do IBGE (Instituto Brasileiro de Geografia e Estatística), que disponibiliza informações estatísticas econômicas e socioeconômicas do país; além de outros mais.

3.4 ANÁLISE PRELIMINAR DOS DADOS

Esta etapa é essencial para a visualização de tendências e sazonalidades. Por exemplo, verificar a existência de possíveis meses onde há preferências populares para o consumo do produto, ou então, se existe uma possível interdependência dos dados estatísticos obtidos.

Na Figura 6, apenas para efeito de comparação, são apresentados os dados estatísticos de cada variável referente ao ano de 2008, no período de Janeiro (representado pelo numérico um) a Dezembro (aqui denotado sob o número doze). O objetivo deste confronto é avaliar a existência de possível correlação entre as variáveis candidatas.

Figura 6 - Comportamento das variáveis candidatas em 2008. (a) taxa de juros; (b) rendimento médio mensal; (c) taxa de desemprego; (d) IPCA; (e); PIB.



Fonte: (O AUTOR, 2015)

Com base na Figura 6, é possível observar uma aleatoriedade nos dados de cada variável candidata. Desta forma, pode-se afirmar de que não existe interdependência entre as mesmas, ou seja, através de um aumento ou decréscimo da taxa de juros, não há possibilidade de realizar

nenhuma afirmação sobre o comportamento das outras variáveis candidatas, pois cada uma possui sua variação independente.

Já através da variável de resposta, é possível verificar a existência de sazonalidades no modelo. Ou seja, neste trabalho, a presença de meses em que a aquisição de carros é mais frequente, e meses em que esta não ocorre em tanta intensidade. Na Tabela 7, é possível observar nos últimos quatro anos, os meses em que mais foram adquiridos veículos automotores e comerciais leves no país.

Tabela 7 - Meses de maior demanda de automóveis e comerciais leves nos anos de (a) 2011; (b) 2012; (c) 2013; e (d) 2014.

2011		2012	
Dezembro	329202	Agosto	405469
Agosto	307764	Julho	351385
Novembro	305191	Junho	340667
Maio	300486	Dezembro	335926
Setembro	293579	Outubro	326911
Março	288710	Novembro	297000
(a)		(b)	
2013		2014	
Dezembro	335926	Dezembro	353567
Julho	323917	Janeiro	299737
Abril	316670	Outubro	291377
Outubro	313472	Setembro	282487
Agosto	312689	Novembro	279814
Junho	302887	Julho	279789
(c)		(d)	

Fonte: (O AUTOR, 2015)

Conforme pode ser notado na Tabela 7, não existe um período específico em que há tendência de maior demanda. Ainda que dezembro tenha sido um mês com os maiores índices de vendas nos últimos anos, existe uma grande variabilidade nestes rankings. Por exemplo, no ano de 2011 julho não estava entre os meses de maior demanda, porém no ano seguinte foi um dos meses com os maiores números de vendas.

Dessa forma, uma vez que não há indicativo de períodos específicos no ano em que há tendências de aumento ou decréscimo no número de vendas, pode-se afirmar que não há necessidade da adição de uma variável de sazonalidade no modelo, já que não há um padrão nas vendas em determinados meses no ano.

Deve-se ressaltar que não foi realizada uma análise das amostras com relação ao IPI. Isso se deve ao fato deste ser uma variável periódica constante, havendo momentos na história em que este não sofreu alteração, enquanto em outros houve uma redução em sua alíquota. Porém, essas alterações não ocorreram mensalmente, mas sim em um certo intervalo de tempo.

Ademais, no caso desta última variável, foi necessária uma padronização das informações. Isso porque a alíquota do IPI é diferente para cada uma de suas categorias. Por exemplo, a alíquota cheia para carros de até de mil cilindradas é de 7%, enquanto para potências maiores ele varia entre 11% e 13% conforme o combustível utilizado no automóvel. Essa diferença permanece nas situações onde o IPI é reduzido, ou no popularmente conhecido “IPI zero”.

Assim, foram adotados valores entre 0 (zero) e 1 (um) para padronizar de forma numérica esses períodos. No caso das amostras de IPI cuja alíquota é o seu valor normal, a alíquota cheia, estas têm seu valor nulo, o que representa a ausência de redução. Já para os casos popularmente conhecidos como “IPI zero”, nome que se deve ao fato de carros de até mil cilindradas serem isentos dessa alíquota, foi adotado o valor unitário. Entretanto, existem amostras cuja alíquota era reduzida, porém não isentava categoria alguma de tributação. Esse período, onde por exemplo, os carros de mil cilindradas foram tarifados em cerca de 2-3% são representados pelo valor 0,5 (meio), uma vez que se encontra entre as duas situações anteriores. Assim, possibilitou-se trabalhar com o IPI como uma das variáveis explicativas do problema.

3.5 SELEÇÃO DA TÉCNICA DE PREVISÃO

Uma vez que os dados disponíveis para as variáveis selecionadas são apresentados de forma numérica, ou seja, informações estatísticas que podem ser medidas e contadas, foi escolhido o método quantitativo para a elaboração do modelo. Esse método é normalmente expresso através de equações matemáticas, econométricas, entre outras. Ademais, devido ao grande número de amostras coletadas, é possível levar em consideração, ainda que em forma matemática, a variação do cenário econômico do país, e converter seu impacto em resultados numéricos também, uma característica propícia para a previsão de médio a longo prazo.

Visto que foi constatado que existem diversas variáveis macroeconômicas, independentes, que descrevem o comportamento da demanda, a variável de interesse, determina-se que o modelo pode ser desenvolvido através de uma análise de regressão múltipla.

A razão para a escolha desse modelo e não séries temporais é que conforme observado na seção 3.4, nenhuma das variáveis selecionadas apresenta interdependência, o que foi verificado na etapa anterior, e também é válido considerar que não existe uma relação entre o passado e o presente, pois o histórico de acontecimentos do mercado automotivo não terá influência sobre o comportamento da demanda no futuro distante.

3.6 IMPLEMENTAÇÃO DA TÉCNICA DE PREVISÃO

Segundo Makridakis et al. (1998), nessa etapa inicia-se a construção do modelo pertinente aos dados e a teoria aplicada. Para a construção desse modelo foram coletadas 100 amostras de cada variável, sendo o período das mesmas mensal entre Fevereiro de 2007 a Maio de 2015. Na elaboração do modelo, foram consideradas apenas as noventa primeiras amostras (Fevereiro de 2007 a Julho de 2014), enquanto as dez restantes serão utilizadas para testes do modelo, visando avaliar sua eficácia. Conforme visto na seção 3.5, a técnica de previsão selecionada é regressão linear múltipla, e a partir da análise das primeiras noventa amostras foi encontrada a equação 4.

$$\begin{aligned} \text{DEM} = & 800033 - 1622 \times \text{JUR} - 10379 \times \text{DES} - 324.3 \times \text{IPCA} + \\ & + 182375 \times \text{PIB} + 16435 \times \text{IPI} - 5535 \times \text{JUR} \times \text{IPI} + 22544 \times \text{DES} \times \text{IPI} \end{aligned} \quad (4)$$

Onde:

- DEM: Demanda por automóveis e comerciais leves.
- JUR: Taxa média de juros para pessoas físicas nas operações de crédito para aquisição de veículos.
- DES: Taxa média de desemprego.
- IPCA: Índice de preço ao consumidor amplo.
- PIB: Produto interno bruto real do país.
- IPI: Alíquota de imposto sobre produtos industrializados em automóveis novos.

Em relação ao modelo elaborado, percebe-se que, como era esperado, o aumento no PIB e a redução do IPI influenciam positivamente a compra de veículos automotivos. Isso se deve ao fato

de que quanto maior for o Produto Interno Bruto, maior foi o crescimento da economia do país, o que possibilita uma maior demanda de veículos. Da mesma forma, a redução do IPI reduz o preço do bem, permitindo que este seja acessível a uma maior parcela da população.

Também conforme esperado, as taxas de juros, desemprego e IPCA influenciam negativamente a demanda por automóveis e comerciais leves. Isso porque conforme maiores forem os juros, menos acessíveis são as condições de crédito, reduzindo a acessibilidade da população a esse bem. A taxa de desemprego apresenta uma justificativa similar, já que se esta cresce, maior é o número de pessoas sem renda, o que impossibilita a aquisição desse produto. Assim como as duas taxas anteriores, um aumento no IPCA representa um aumento na inflação, o que é um empecilho na aquisição de automóveis, pois maior é o preço do bem, reduzindo assim a quantidade vendida.

Embora considerado inicialmente como uma variável hipotética, o rendimento médio nominal acabou não apresentando grande correlação com a demanda, ou seja, não tendo grande influência nesta, eliminando-o da equação. Era esperado que este impactasse positivamente, visto que um aumento no rendimento do trabalho pode ser traduzido, em certas condições, como um aumento no poder de compra, viabilizando um aumento no número de vendas.

3.7 AVALIAÇÃO DA TÉCNICA DE PREVISÃO

Como ferramentas de avaliação da técnica, foram realizadas análises residual e de significância do modelo, a fim de analisar a qualidade do modelo de previsão elaborado. E, por fim, foi determinado o coeficiente de determinação do mesmo.

3.7.1 Análise Residual

A realização de uma análise residual é uma etapa importante para investigação da adequabilidade do modelo desenvolvido através da regressão linear múltipla. De acordo com Montgomery & Runger (2009), os resíduos têm um papel muito importante no julgamento de ajustes do modelo, da mesma forma que para a regressão linear simples. Através de observações em seus comportamentos através de gráficos, é possível analisar como o mesmo pode ser melhorado com a adição de variáveis candidatas.

O objetivo desta análise é verificar se os resíduos se apresentam de forma aleatória, ou seja, não possuem padrão evidente algum. Caso esta condição seja satisfeita, o modelo pode ser considerado adequado.

A partir disso, conforme apresenta a Figura 7, é possível afirmar que o modelo elaborado neste trabalho é adequado, pois, em todas as variáveis utilizadas, os resíduos se apresentaram de forma aleatória, ou seja, não houve a formação de um padrão.

3.7.2 Teste para a Significância da Regressão

De acordo com Montgomery & Runger (2009), o teste de significância é uma ferramenta para determinação da existência de uma relação linear entre as variáveis regressoras ($x_1, x_2, x_3, \dots, x_k$) e a de resposta y .

Esta análise é realizada através do teste “F” e conjunto de hipóteses apropriadas são as seguintes:

$$\begin{aligned} H_0: \beta_1 = \beta_2 = \beta_3 = \dots = \beta_n = 0 \\ H_1: \text{ao menos um } \beta_k \neq 0 \end{aligned}$$

isto é, H_0 para o caso de não existir relação linear entre as variáveis de resposta e regressoras, ou seja, os coeficientes das variáveis podem ser nulos; e H_1 para o caso de existir relação linear entre essas variáveis, ou ao menos entre a variável dependente e uma das variáveis independentes.

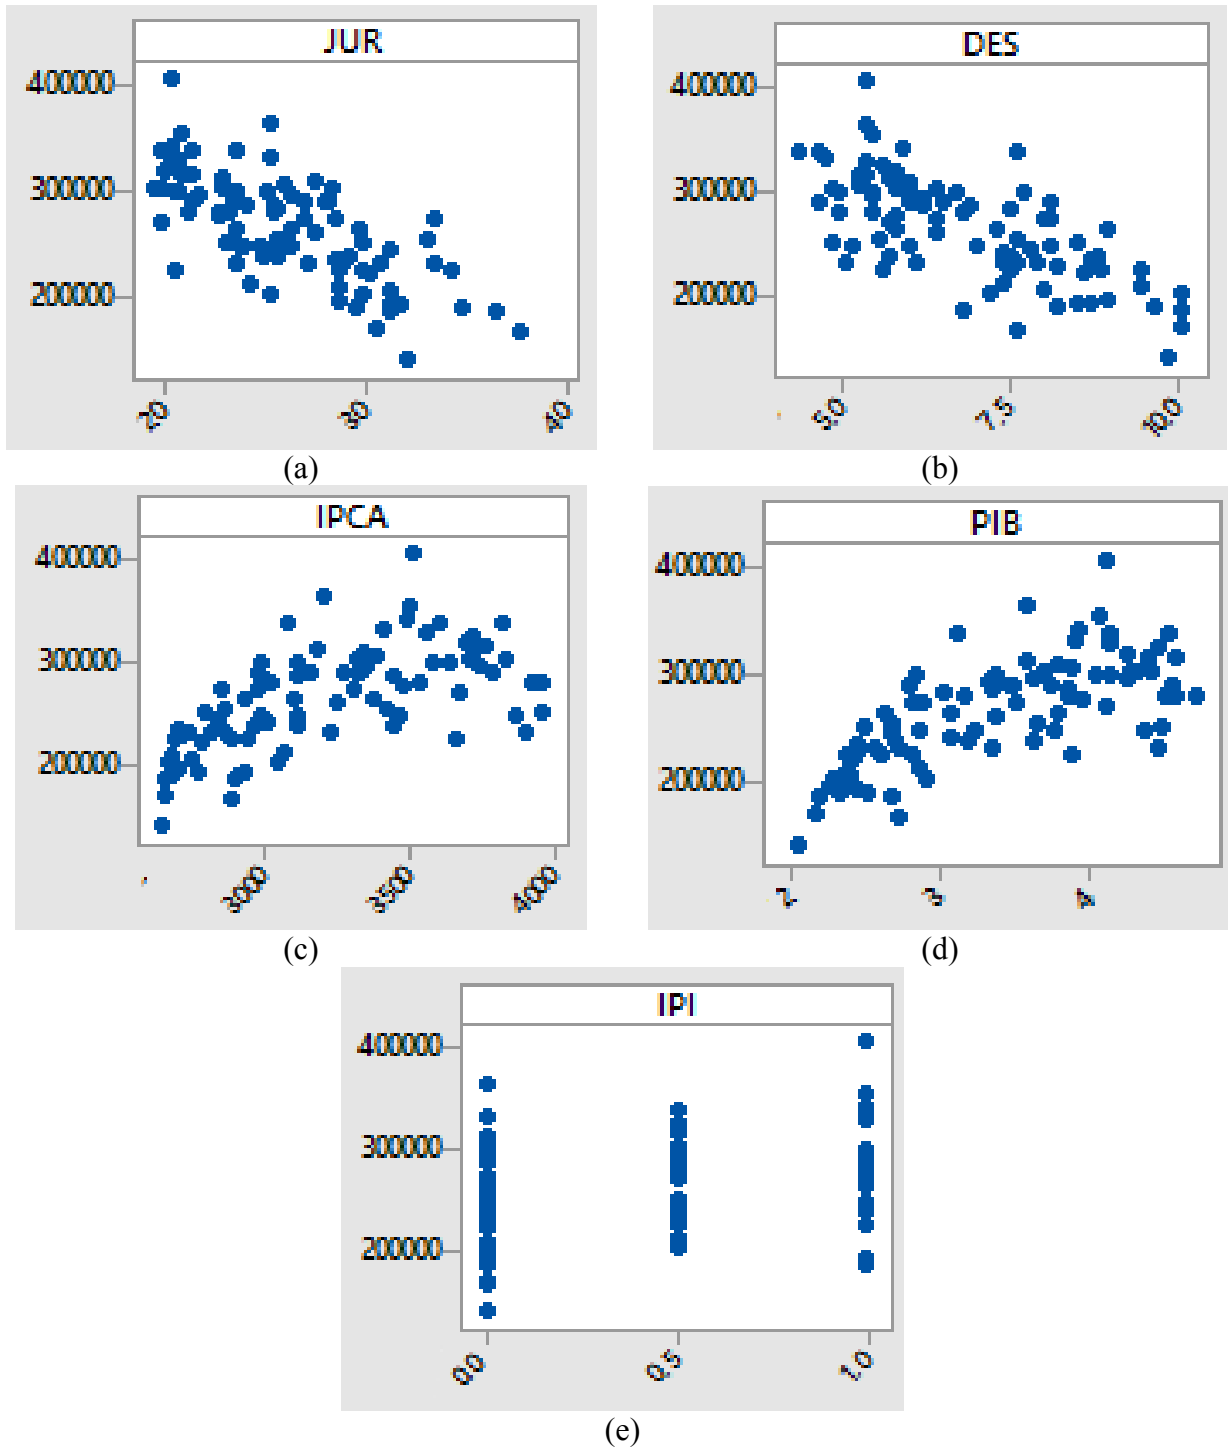
Ainda segundo com Montgomery & Runger (2009), assim como na regressão linear simples, o procedimento para a realização do teste de significância é iniciado a partir da determinação da soma total dos quadrados (SQ_T). Esse termo é resultante da soma de suas duas parcelas, a soma dos quadrados devido à regressão (SQ_R) e ao erro (SQ_E).

O valor de SQ_R é resultante das distâncias entre os valores obtidos através do modelo e a média dos valores amostrais, conforme mostra a equação 5,

$$SQ_R = \sum (Y - \bar{Y})^2 - \sum (Y - \hat{Y})^2 = \sum (\hat{Y} - \bar{Y})^2 \quad (5)$$

onde no caso deste trabalho, $Y = DEM$.

Figura 7 - Comportamento dos resíduos: (a) taxa de juros; (b) taxa de desemprego; (c) IPCA; (d) PIB; (e) IPI.



Fonte: (MINITAB®, 2015)

Uma vez que a média dos valores amostrais da demanda é $\bar{Y} = 263303$. Tem-se que $SQ_R = 1,75236 \times 10^{11}$, vide demonstração no Apêndice A.

Já SQ_E é o valor da soma dos quadrados dos erros expressa através da equação 6,

$$SQ_E = \sum (Y - \hat{Y})^2 = \sum (Y - \hat{\beta}_0 - \hat{\beta}_1 X)^2 = \sum e^2 \quad (6)$$

O valor de SQ_E , conforme apresentado no Apêndice B, é $SQ_E = 39550881019$.

Sendo assim, como a soma total dos quadrados é o resultado da soma de SQ_R e SQ_E , tem-se que $SQ_T = 2,14787 \times 10^{11}$.

As médias quadráticas da regressão (MQ_R) e do erro (MQ_E) são definidas pelos quocientes de suas somas dos quadrados pelos graus de liberdade para cada fonte de variação, como mostram as equações 7 e 8, respectivamente.

$$MQ_R = \frac{SQ_R}{p - 1} = \frac{1,75236 \times 10^{11}}{8 - 1} = 25033714290 \quad (7)$$

$$MQ_E = \frac{SQ_E}{n - p} = \frac{39550881019}{90 - 8} = 482327817 \quad (8)$$

Obtidos os valores das médias quadráticas, é possível determinar o valor de f_0 , o quociente de MQ_R por MQ_E , vide equação 9.

$$F_0 = \frac{MQ_R}{MQ_E} = \frac{25033714290}{482327817} = 51,90 \quad (9)$$

Portanto, para um nível de significância de 5%, ou seja, $\alpha = 0,05$, usando os dados amostrais, encontramos o valor de $f_0 = 51,90$.

A Tabela 8 apresenta, de forma resumida, os valores estatísticos encontrados neste procedimento.

Tabela 8 - Teste de significância da regressão.

Fonte de Variação	Soma dos Quadrados	Graus de Liberdade	Média Quadrática	F ₀	Valor P
Regressão	$1,75236 \times 10^{11}$	7	25033714290	51,90	0,000
Erro ou resíduo	39550881019	82	482327817		
Total	$2,14787 \times 10^{11}$	89			

Fonte: (O AUTOR, 2015)

O valor crítico de f pode ser encontrado em uma tabela de distribuição F de Fisher-Snedecor no nível de significância desejado. Desta forma, para um $\alpha = 0,05$; $k = 7$; e $(n - p) = 82$, temos $f_{0,05; 7; 82} = 2,123$.

Como $f_0 > f_{0,05; 7; 82}$, pode-se rejeitar a hipótese nula, e assim concluímos que através a demanda de veículos está relacionada linearmente a pelo menos uma das variáveis independentes selecionadas neste trabalho, ou seja, que a regressão é significativa. Esta afirmação pode também ser constatada pelo fato do valor de P ser consideravelmente menor do que $\alpha = 0,05$.

3.7.3 Coeficiente de Determinação

Segundo Montgomery & Runger (2009), pode-se também utilizar como estatística global de avaliação do ajuste do modelo o coeficiente de determinação múltipla, R^2 . Ele avalia a proporção da variação nas variáveis dependentes que é explicada pela linha de regressão. Seu valor varia na faixa $0 \leq R^2 \leq 1$, ou seja, seu valor é zero quando nenhuma parcela da variação de Y é explicada pela regressão, e um quando toda a variação de Y é explicada pela regressão. (McGuigan, Moyer & Harris, 2010). O valor de R^2 é o quociente da soma dos quadrados da regressão pelo total do modelo, conforme mostra a equação 10.

$$R^2 = \frac{SQ_R}{SQ_T} = \frac{1,75236 \times 10^{11}}{2,14787 \times 10^{11}} = 0,8159 \quad (10)$$

Sendo assim, o modelo de previsão obtido possui um coeficiente de determinação (R^2) igual a 0,8159. Uma vez que a qualidade deste é dada por sua proximidade do valor unitário, o coeficiente da equação de previsão obtida pode ser considerado um valor alto. Isto indica que 81,59% da variação da demanda de automóveis pode ser explicada pelo modelo de regressão proposto.

É válido mencionar que, uma vez que durante a elaboração do modelo, foram testadas diferentes combinações das variáveis e diferentes critérios, como obter apenas equações de primeiro grau e sem interação entre as variáveis, foram obtidos diferentes modelos, cada um com seus coeficientes de determinação. Dentre os resultados obtidos, o modelo em questão obteve o maior R^2 , justificando sua escolha.

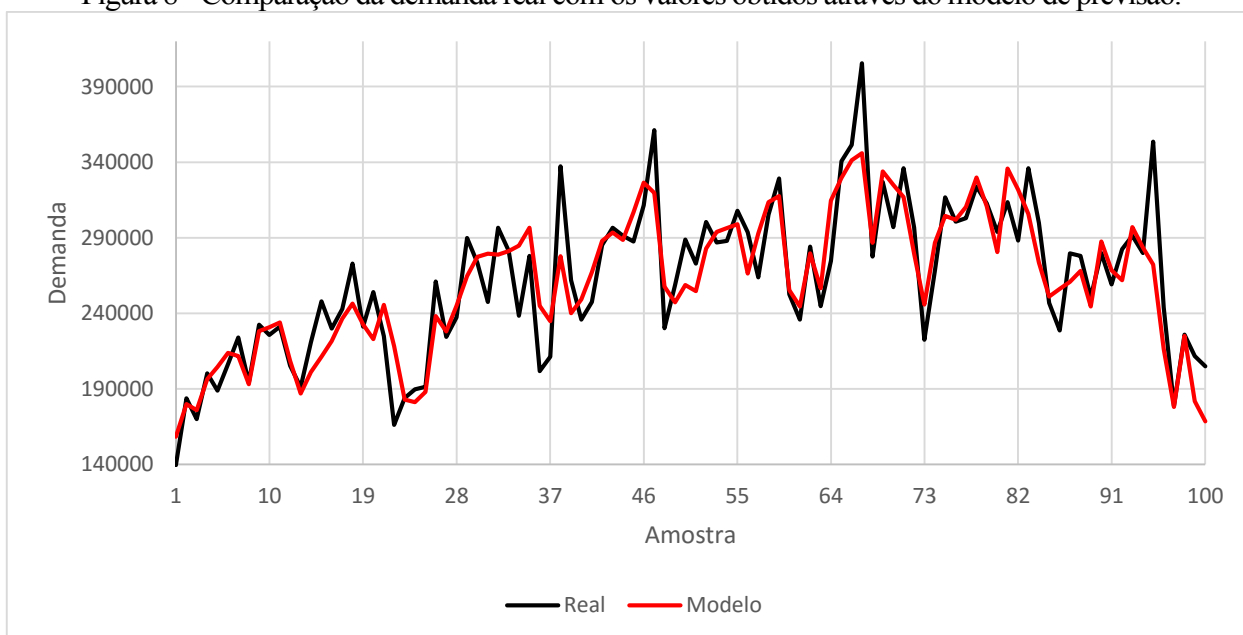
3.8 USO DA PREVISÃO

Visto que a regressão é significativa, pode ser estimada então a demanda de veículos automotivos no país. Desta forma, pode-se ser utilizado o modelo, de forma a comparar os valores de saída obtidos a partir da equação com os valores reais de demanda por automóveis e comerciais leves.

Para isso, foram coletadas 100 amostras durante a elaboração do trabalho, das quais 90 (dados do período de Fevereiro de 2007 a Julho e 2014) foram utilizadas na elaboração do modelo, e as 10 restantes (referentes ao período de Agosto de 2014 a Maio de 2015) reservadas como dados complementares para validação do modelo. É válido ressaltar que todas as amostras foram obtidas através das mesmas fontes e aplicadas sob a mesma metodologia.

A Figura 8 permite uma comparação entre os resultados para previsão de demanda obtidos através do modelo e os valores reais de demanda por automóveis e comerciais leves no período amostral. Para efeito de representação, a amostra de número um é referente ao mês de Fevereiro de 2007, seguindo em ordem crescente, até a amostra de número cem que condiz ao mês de Maio de 2015.

Figura 8 - Comparação da demanda real com os valores obtidos através do modelo de previsão.

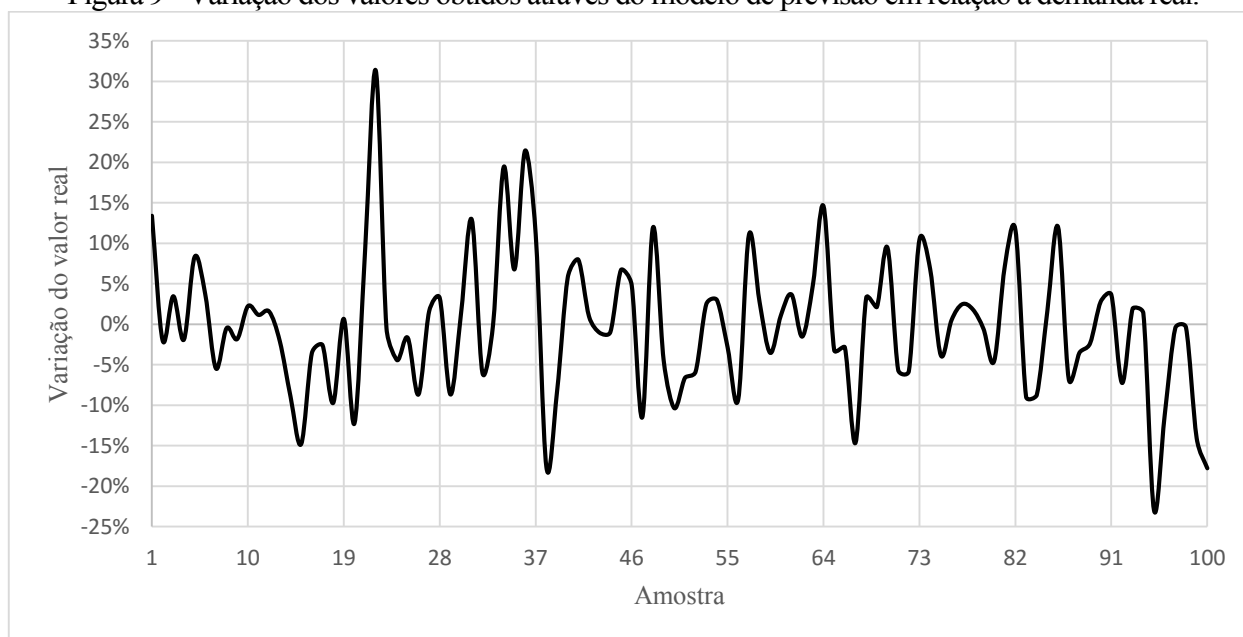


Fonte: (O AUTOR, 2015)

Com base na Figura 8, o modelo construído mostrou-se satisfatório, sendo notada uma maior acurácia para as amostras reservadas e um acompanhamento da queda do volume de vendas, comprovando a validação do modelo de previsão elaborado neste trabalho.

Além disso, observa-se na Figura 9 a variação dos valores estimados em relação a demanda real, o que mostra 94% destes se encontram em uma faixa de até 15% acima ou abaixo da demanda real. Ademais, pode-se observar que 80% dos valores preditos são 10% maiores ou menores que a demanda real. E, em 10% dos casos, a previsão foi aproximadamente exata, igualando-se ao valor real. Baseando-se nessa informação, pode-se afirmar que as estimativas muito próximas da realidade.

Figura 9 - Variação dos valores obtidos através do modelo de previsão em relação a demanda real.



Fonte: (O AUTOR, 2015)

4 SIMULAÇÃO DE MONTE CARLO

Conforme mencionado na seção 2.5, a Simulação de Monte Carlo permite que, a partir de variáveis de entrada com padrão de distribuição definido, sejam gerados parâmetros estatísticos de previsão de um modelo previamente estabelecido. Sendo assim, nesta seção objetiva-se obter tais parâmetros aplicados ao modelo de previsão de demanda de automóveis e comerciais leves elaborado através da regressão linear múltipla, podendo então realizar previsões de possíveis demandas futuras. Diferentemente do desenvolvido no capítulo anterior, onde são necessários valores reais para a obtenção da demanda, a simulação gera uma distribuição de demandas por suas probabilidades de ocorrência.

Para a realização da Simulação de Monte Carlo, primeiramente devem ser definidas as distribuições determinísticas de cada uma das variáveis de entrada, pois ainda que os valores gerados sejam aleatórios, eles respeitam a distribuição histórica desses dados estatísticos, portanto, não criando valores absurdos como aumentos de 100% no PIB, ou desemprego de 95% da população.

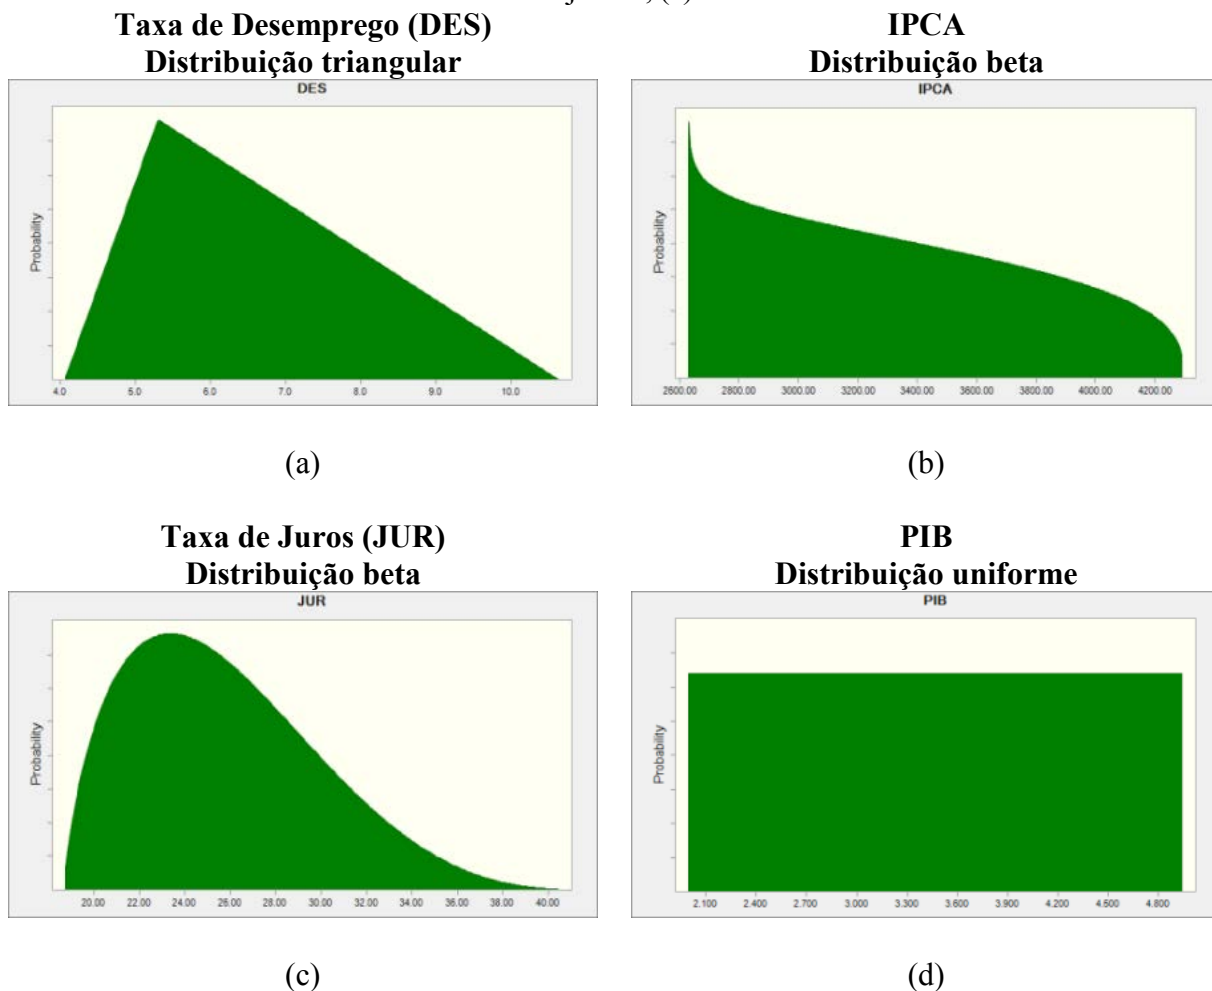
O Crystal Ball® define as distribuições de probabilidades de cada variável através da seleção das amostras, criando então um gráfico relacionando cada intervalo amostral e a frequência em que houve algum dado naquele intervalo. A Figura 10 apresenta as distribuições de probabilidade de cada variável.

É válido ressaltar que uma vez que o IPI tem atuado em sua alíquota cheia desde o início do ano, e o mesmo não é passível de variações como as outras variáveis, o mesmo foi fixado como zero (valor adotado para períodos sem redução), reduzindo então a equação 4. A equação 11 mostra o modelo a ser utilizado na simulação.

$$\text{DEM} = 800033 - 1622 \times \text{JUR} - 10379 \times \text{DES} - 324.3 \times \text{IPCA} + 182375 \times \text{PIB} \quad (11)$$

A partir da equação de demanda, são gerados valores aleatórios para cada uma das variáveis, que quando aplicadas no modelo de previsão previamente desenvolvido, criam diferentes cenários futuros de demanda de automóveis e comerciais leves.

Figura 10 - Distribuição de probabilidades das variáveis de entrada (a) taxa de desemprego; (b) IPCA; (c) taxa de juros e; (d) PIB.

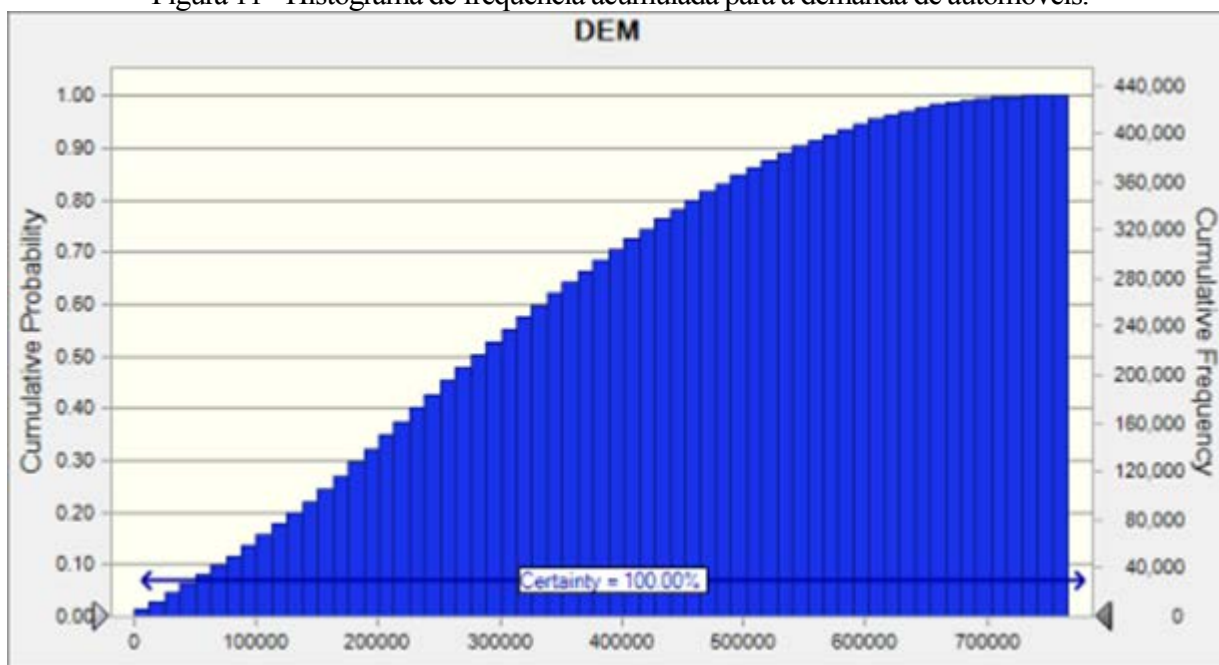


Fonte: (CRYSTAL BALL®, 2015)

Cada cenário é gerado a partir de uma iteração, e através do conjunto de 500.000 iterações realizado, pode-se obter um histograma da distribuição da demanda obtida a partir dos valores aleatórios. Uma vez que esses valores foram gerados baseando-se na distribuição de probabilidade associada a cada variável, esses números podem ser considerados diferentes situações futuras possíveis do mercado.

A Figura 11 apresenta o histograma gerado a partir da realização da simulação de Monte Carlo que mostra as frequências acumuladas. A partir das informações fornecidas, pode-se avaliar as possíveis condições de mercado futuras. Como, por exemplo, de acordo com a simulação realizada que a probabilidade de ser vendidos pelo menos 140.000 automóveis e comerciais leves no próximo mês é de 20%.

Figura 11 - Histograma de frequência acumulada para a demanda de automóveis.




Fonte: (CRYSTAL BALL®, 2015)

Além disso, o histograma permite estipular quais são as faixas de demanda com maior possibilidade de ocorrência na realidade. Isso pode ser observado na curva de crescimento como o intervalo com maior inclinação, ou seja, onde houve um maior acúmulo de frequências em menor faixa de demanda. Neste caso, observando a Figura 12, pode-se assumir que essa faixa ocorre quando o intervalo da demanda está entre cerca de 175.000 e 275.000, o que nos indica que existe maior probabilidade que a demanda do próximo mês esteja neste intervalo. É válido afirmar que segundo o relatório da Fenabrave (2015), as demandas reais de automóveis e comerciais leves nos quatro meses posteriores aos amostrais (Junho a Setembro de 2015) variaram de 192.610 a 219.410 unidades, pertencendo então ao intervalo aferido como de maior probabilidade, podendo então atestar que a simulação realizada se mostra adequada.

A simulação também apresenta um gráfico de sensibilidade, como mostrado na Figura 13, onde é possível verificar quais são as variáveis que têm maior influência sobre a variação da demanda.

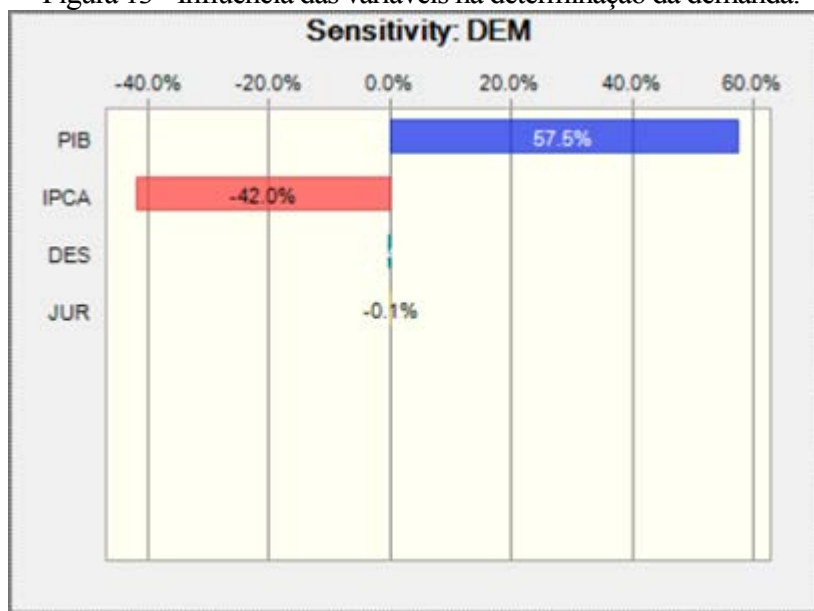
Com a análise de sensibilidade da demanda pode-se enxergar que apenas duas (PIB e IPCA) das quatro variáveis, representam 99,5% de toda a variação da demanda. Este resultado afirma que o PIB real tem uma forte influência positiva na variável de saída, enquanto o IPCA tem um efeito contrário.

Figura 12 - Intervalo de demanda futura com maior probabilidade de ocorrência.



Fonte: (CRYSTAL BALL®, 2015)

Figura 13 - Influência das variáveis na determinação da demanda.



Fonte: (CRYSTAL BALL®, 2015)

Estes resultados indicam que variações no PIB e no IPCA terão maior efeito na demanda de automóveis do que as outras variáveis independentes. Ou seja, quanto maior for o aumento no PIB e menor for a variação da taxa de inflação, pode ser esperada uma maior procura por esses produtos.

5 CONCLUSÃO

O objetivo inicial deste trabalho era determinar fatores que influenciasssem a demanda de veículos e comerciais leves, e uma vez obtidas essas informações, elaborar um modelo de previsão que pudesse estimar tal demanda no Brasil. Desta forma, foi possível desenvolver um modelo matemático a partir de uma análise de regressão linear múltipla que pudesse explicar tal variável de saída.

O modelo desenvolvido foi considerado adequado, apresentando resíduos com comportamento de forma aleatória, e um coeficiente de determinação R^2 de 0,8159, demonstrando que 81,59 % da demanda por automóveis e comerciais leves pode ser explicado pelas variáveis explicativas (taxa de juros, taxa de desemprego, PIB e IPCA). Diferente do que se esperava, o rendimento médio nominal do trabalhador não apresentou forte correlação com a variável de saída. Uma possível explicação para essa ocorrência é o fato da demanda ser geral, e não para modelos específicos, sendo assim possível para um indivíduo, independente da renda, adquirir um automóvel, seja de valor menor para pessoas com poder aquisitivo mais restrito, ou de valores maiores para indivíduos com maior poder de compra.

Com o intuito de validação do modelo foi realizado um teste de aderência, onde para as condições $\alpha = 0,05$; $k = 7$; e $(n - p) = 82$, foi encontrado um valor de “F” crítico igual a 2,123 a um nível de 5% de significância. Esse valor se mostrou inferior ao valor de “ F_0 ” encontrado através do modelo de regressão, sendo esse igual a 51,90, rejeitando então a hipótese H_0 , e possibilitando a conclusão de que o modelo elaborado é significativo, ou seja, que ao menos uma das variáveis independentes selecionadas está relacionada a variável de saída.

Uma vez que o modelo foi elaborado com base em noventa das cem amostras coletadas, foi realizado um teste com as amostras restantes para checar a eficácia da previsão. Foi possível obter previsões adequadas com essas amostras restantes, assim como com as outras noventa também, obtendo valores cerca de 10 % acima ou abaixo da demanda real. É interessante destacar que uma vez que o modelo teve em sua elaboração dados de diversos momentos econômicos do país, ele obteve resultados que acompanharam os efeitos da crise, ou seja, prevendo a queda na demanda por veículos e comerciais leves nos últimos anos.

Portanto, pode-se concluir que o modelo de regressão elaborado é adequado para a previsão de demanda de automóveis no Brasil.

Além disso, com o intuito de aplicar o modelo desenvolvido a uma nova técnica, foi realizada uma Simulação de Monte Carlo, que possibilitou a partir dos dados amostrais e suas distribuições pertinentes, através de dados aleatórios gerados com base nestes, obter um histograma de frequências acumuladas relacionando cada cenário de demanda a sua possibilidade de real ocorrência.

A simulação afirmou que o PIB e o IPCA são as variáveis que influenciam o modelo, o primeiro positivamente e o segundo negativamente, de forma mais intensa, tendo mais efeitos na demanda quando estes variam.

Ademais, foi possível observar as possibilidades de demanda de veículos, e notou-se que a maior probabilidade devido ao número de ocorrências de iterações é a de cerca de 175.000 a 275.000. Uma vez que a demanda por automóveis e comerciais leves nos quatro meses seguintes ao período amostral pertence a esse intervalo, pode-se concluir que a simulação realizada aferiu com sucesso a possibilidade de demanda nos meses seguintes.

Sendo assim, pode-se concluir que o trabalho obteve os resultados esperados, e o modelo pode ser utilizado ativamente mediante atualização mensal do banco de dados, acrescentando as informações referentes as variáveis explicativas. Além disso, este estudo pode servir de base para projetos futuros relacionados ao tema, ou então o próprio trabalho pode ser melhorado através da adição de novas variáveis explicativas, se determinadas futuramente, possibilitando uma melhoria no coeficiente de regressão, obtendo um modelo com melhor explicação a partir das variáveis regressoras.

5.1 RECOMENDAÇÃO PARA FUTURAS PESQUISAS

Como possibilidade para futuras pesquisas, sugere-se que este trabalho seja tomado como referência para a elaboração de um modelo de previsão de demanda mais específico, focando em determinados modelos, algo bastante útil para as montadoras. Este modelo pode ser elaborado através de uma combinação dos resultados obtidos nesse trabalho com técnicas de previsão qualitativas, visto que é necessário adicionar ao modelo variáveis que representem a preferência do consumidor, ou então qualificação de determinado modelo de carro por meio de pesquisa popular, entre outras.

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAHAM, B.; LEDOLTER, J. **Statistical Methods for Forecasting**. New York: John Wiley & Sons, 1983. 445 p.

ALMEIDA FILHO, B. F. **Análise de regressão e simulação na avaliação de tempos e custos em processos de usinagem pesada**. 2008. 73 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Itajubá, Itajubá, 2008.

ANFAVEA. **Desempenho da Indústria Automobilística Brasileira**. 2015. Disponível em: <www.anfavea.com.br/coletiva.pdf>. Acesso em: 22 ago. 2015.

ANFAVEA. **Guia Setorial da Indústria Automobilística Brasileira 2011**. 2011. Disponível em: <<http://www.anfavea.com.br/catalogos.html>>. Acesso em: 20 ago. 2015.

ANGELO, Pedro Henrique Araujo; NEUTZLING JUNIOR, João. **Redução do IPI em 2012 e a venda de veículos**. 2013. 25 f. TCC (Graduação em Processos Gerenciais) - Faculdade de Tecnologia Senac, Pelotas, 2013.

BNDES. **Perspectivas do investimento 2015-2018 e panoramas setoriais**. 2014. Disponível em: <<https://web.bndes.gov.br/bib/jspui/handle/1408/2842>>. Acesso em: 23 ago. 2015.

CONFESSOR, W. **Tendências do setor automotivo brasileiro: Plataformas globais**. 2012. 64 f. Monografia (Especialização em Engenharia Automotiva) - Centro Universitário do Instituto Mauá de Tecnologia, São Caetano do Sul, 2012.

FAÇANHA, C. **Brazil's INOVAR-AUTO incentive program**. 2013. ICCT. Disponível em: <http://www.theicct.org/sites/default/files/publications/ICCTupdate_Brazil_InovarAuto_feb2013.pdf>. Acesso em: 24 ago. 2015.

FERNANDES, C. A. B. A. **Gerenciamento de riscos em projetos: Como usar o Microsoft Excel para realizar a simulação Monte Carlo**. Curitiba, 2005. 6 p.

FIGUEREDO, C. J. **Previsão de Séries Temporais Utilizando a Metodologia Box & Jenkins e Redes Neutrais para Inicialização de Planejamento e Controle de Produção**. 2008. 176 f. Dissertação (Mestrado em Métodos Numéricos em Engenharia) - Universidade Federal do Paraná, Curitiba, 2008.

FURTADO, M. R. **Aplicação de um modelo de previsão de demanda total nos credenciados Belgo Pronto**. 2006. 32 f. TCC (Graduação em Engenharia de Produção) - Universidade Federal de Juiz de Fora, Juiz de Fora, 2006.

GUIMARÃES, B. V. C. **Regressão linear simples e múltipla para predição de colheita em bananeiras tipo prata**. 2011. 82 f. Dissertação (Mestrado em Produção Vegetal no Semiárido) - Universidade Estadual de Montes Claros, Janaúba, 2011.

GUIMARÃES, F. A. R.; FORTES, M.; PAIVA, R. V. C. Revisão de Métodos de Previsão de Demanda Turística. **Reuna**, Belo Horizonte, v. 13, n. 3, p.55-65, set. 2008.

INOVAR-AUTO – Ministério do Desenvolvimento, Indústria e Comercio Exterior. **Conheça o INOVAR-AUTO**. Disponível em <<http://inovarauto.mdic.gov.br>>. Acesso em: 22 ago. 2015.

KOTLER, P. **Administração de marketing: análise, planejamento, implementação e controle**. 5. ed. São Paulo: Atlas, 1998. 725 p.

LEÃO, C.; GOULART, L. O **INOVAR AUTO e os investimentos em P&D no setor automotivo**. 2012. Disponível em: <<http://inventta.net/inovar-auto.pdf>>. Acesso em: 25 ago. 2015.

LIMA, E. C. P; VIANA, J. C.; LEVINO, N. A.; MOTA, C. M. M. Simulação de Monte Carlo auxiliando a análise de viabilidade econômica de projetos. In: CONGRESSO NACIONAL DE EXCELÊNCIA EM GESTÃO, 4., 2008, Niterói. **Anais...** Niterói: 2014. p. 1 - 13.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: Methods and Applications**. 3. ed. New York: John Wiley & Sons, 1998. 656 p.

MCGUIGAN, J. R.; MOYER, R. C.; HARRIS, F. H. DEB. **Economia de Empresas**. 11. ed. São Paulo: Cengage Learning, 2010. 500 p.

Moderno Dicionário Michaelis da Língua Portuguesa. **Significado de “Demanda”**. Disponível em <http://michaelis.uol.com.br/moderno/portugues/index.php?lingua=portugues-portugues&palavra=demanda>. Acesso em: 23 ago. 2015.

MONTEIRO, C. A.; SANTOS, L. S.; WERNER, L. Simulação de Monte Carlo em decisão de investimento para implantação de projeto hospitalar. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 32., 2012, Bento Gonçalves. **Anais...** Bento Gonçalves: Abepro, 2012. p. 1 - 13.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 3. ed. New York: Wiley-Interscience, 2001. 641 p.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 4. ed. Rio de Janeiro: LTC, 2009. 490 p.

MOREIRA, D. A. **Administração da produção e operações**. 2 ed. São Paulo: Cengage Learning, 2009. 624 p.

NETER, J.; KUTNER, M.; NACHTSHEIM, C.; LI, W. **Applied Linear Statistical Models**. 5. ed. New York: Mc Graw-Hill/Irwin, 2004. 1396 p.

PACHECO, Ricardo Ferrari; SILVA, Alisson Vitor Forti. Aplicação de modelos quantitativos de previsão em uma empresa de transporte ferroviário. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 23., 2003, Ouro Preto. **Anais...** Ouro Preto: Abepro, 2003. p. 1 - 8.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para Implantação de Sistemas de Previsão de Demanda - Técnicas e Estudo de Caso. **Produção**, Porto Alegre, v. 11, n. 1, p.43-64, nov. 2011.

PINTO, L. R. L.; MAZZON, J. A. **Proposição de um Modelo de Simulação de Vendas: uma análise dos influenciadores das vendas da cesta de bens de consumo auditada pela Nielsen**. 2010. TCC. (Graduação em Administração) - Universidade de São Paulo, São Paulo, 2010.

PONCIANO, N. J.; SOUZA, P. M.; MATA, H. T. C.; VIEIRA, J. R.; MORGADO, I. F. **Análise de Viabilidade Econômica e de Risco da Fruticultura na Região Norte Fluminense**. Revista de Economia e Sociologia Rural, Rio de Janeiro, vol. 42, n. 04, p. 615-635, 2004.

PORSSE, A. A. Tecnologia e Emprego na Indústria Automobilística: evidências empíricas. **Revista Paranaense de Desenvolvimento**, Curitiba, n. 94, p. 69-86, maio/dez. 1998.

RAMOS, J. F. V.; TEIXEIRA, P. H. **Manual de Escrituração Fiscal ICMS/IPI**. Curitiba: Maph Editora, 2015. 230 p.

RIBEIRO, Pedro Luiz Franco. Mercado automobilístico nacional: competitividade, inovações tecnológicas e perspectivas. In: CONGRESSO NACIONAL DE EXCELÊNCIA EM GESTÃO, 10., 2014, Niterói. **Anais...** Niterói: 2014. p. 1 - 14.

RODRIGUES, S. C. A. **Modelo de Regressão Linear e suas Aplicações**. 2012. 78 f. TCC (Graduação em Matemática) - Universidade da Beira Interior, Covilhã, 2012.

RUSCHEL, L. P.; WERNER, L.; LEMOS, F. O. Previsão de demanda de novos produtos: aplicação integrada de métodos quantitativo e qualitativo. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 27., 2007, Foz do Iguaçu. **Anais...** Foz do Iguaçu: Abepro, 2007. p. 1 - 10.

Secretaria da Receita Federal do Brasil. **Novas alíquotas de IPI de automóveis estão em vigor desde 1º de janeiro**. 2015. Disponível em <<http://idg.receita.fazenda.gov.br/noticias/ascom/2015/janeiro/aliquotas-de-ipi-de-automoveis-a-partir-de-1o-de-janeiro>>. Acesso em: 20 ago. 2015.

SENHORAS, E. M.; DIAS, J. M. **Tendências da indústria automotiva brasileira: Um estado do caso FIAT**. Campinas: 2005. 12 p.

TACONELLI, C. A. **Análise de Regressão Múltipla**. 2010. Disponível em: <<http://people.ufpr.br/~niveam/ce071/Apostila.pdf>>. Acesso em: 16 ago. 2015.

VEJA. **O Brasil em 10 vocações**. Ed. 2180, p. 131. 01/09/2010. Disponível em: <<http://veja.abril.com.br/acervodigital/home.asp>>. Acesso em: 25 ago. 2015.

VOSE, D. **Quantitative risk analysis: A guide to Monte Carlo simulation modelling**. Chichester: John Wiley & Sons, 1996. 328 p.

WERNECK, R. F. **Análise e Previsão de Demanda numa Empresa de Distribuição de Medicamentos**. 2007. 34 f. TCC (Graduação em Engenharia de Produção) - Universidade Federal de Juiz de Fora, Juiz de Fora, 2007.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião**. 2004. 166 f. Tese (Doutorado em Engenharia de Produção) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

WILBERT, M. D.; SERRANO, A. L. M.; GONÇALVES, R. S.; ALVES, L. S. Redução do imposto sobre produtos industrializados e seu efeito sobre a venda de automóveis no Brasil: uma análise do período de 2006 a 2013. **Revista Contemporânea de Contabilidade**, Florianópolis, v. 11, n. 24, p.107-124, set. 2014.

APÊNDICE A - SOMA DOS QUADRADOS DA REGRESSÃO

Tabela 9 - Determinação da soma dos quadrados da regressão (SQ_R).

Amostra	Mês de Referência	\widehat{DEM}_i	$(\widehat{DEM}_i - \overline{DEM}_i)$	$(\widehat{DEM}_i - \overline{DEM}_i)^2$
1	Fev/07	158298	-105005	11025970303
2	Mar/07	180058	-83246	6929813855
3	Abr/07	175898	-87405	7639630269
4	Mai/07	196470	-66833	4466667668
5	Jun/07	204430	-58873	3465985181
6	Jul/07	213910	-49393	2439628183
7	Ago/07	211645	-51658	2668567511
8	Set/07	193116	-70187	4926172561
9	Out/07	228220	-35083	1230815320
10	Nov/07	230744	-32559	1060102751
11	Dez/07	233930	-29373	862780157
12	Jan/08	208613	-54690	2990987802
13	Fev/08	186999	-76304	5822305607
14	Mar/08	201111	-62192	3867859232
15	Abr/08	211271	-52032	2707296779
16	Mai/08	221702	-41601	1730679052
17	Jun/08	236552	-26751	715622148
18	Jul/08	246390	-16913	286035828
19	Ago/08	232590	-30713	943282058
20	Set/08	223005	-40298	1623943141
21	Out/08	245513	-17790	316486711
22	Nov/08	218313	-44990	2024122821
23	Dez/08	182953	-80350	6456183469
24	Jan/09	181298	-82005	6724890699
25	Fev/09	188085	-75219	5657825659
26	Mar/09	238295	-25008	625397395
27	Abr/09	227929	-35374	1251342419
28	Mai/09	244977	-18326	335860571
29	Jun/09	264579	1276	1628506
30	Jul/09	277452	14149	200200430
31	Ago/09	279500	16197	262330309
32	Set/09	278827	15524	240981252
33	Out/09	281115	17812	317270265
34	Nov/09	284778	21475	461185664
35	Dez/09	296655	33352	1112342429
36	Jan/10	244935	-18368	337400080
37	Fev/10	234723	-28580	816842430
38	Mar/10	277799	14495	210119031
39	Abr/10	240076	-23227	539494917
40	Mai/10	249287	-14016	196446553

Amostra	Mês de Referência	\widehat{DEM}_i	$(\widehat{DEM}_i - \overline{DEM}_i)$	$(\widehat{DEM}_i - \overline{DEM}_i)^2$
41	Jun/10	267152	3849	14811133
42	Jul/10	287880	24577	604032689
43	Ago/10	293376	30073	904402177
44	Set/10	288528	25225	636288548
45	Out/10	306820	43517	1893733955
46	Nov/10	326410	63106	3982429378
47	Dez/10	319677	56374	3178007890
48	Jan/11	257588	-5715	32664966
49	Fev/11	247278	-16025	256811775
50	Mar/11	258722	-4581	20988358
51	Abr/11	254757	-8546	73040996
52	Mai/11	282860	19557	382466074
53	Jun/11	293936	30633	938360425
54	Jul/11	296491	33188	1101469753
55	Ago/11	298933	35630	1269472982
56	Set/11	266346	3043	9257135
57	Out/11	292851	29548	873083395
58	Nov/11	313502	50199	2519947594
59	Dez/11	317490	54187	2936238798
60	Jan/12	255391	-7912	62597432
61	Fev/12	244442	-18861	355726208
62	Mar/12	279702	16399	268920690
63	Abr/12	256646	-6657	44322278
64	Mai/12	314514	51211	2622537649
65	Jun/12	329708	66405	4409620969
66	Jul/12	341257	77954	6076764667
67	Ago/12	346027	82724	6843231841
68	Set/12	286577	23274	541684533
69	Out/12	333816	70513	4972016832
70	Nov/12	325005	61702	3807116394
71	Dez/12	316893	53590	2871880435
72	Jan/13	279570	16267	264621438
73	Fev/13	245752	-17551	308028642
74	Mar/13	286580	23277	541819851
75	Abr/13	304463	41160	1694173094
76	Mai/13	302000	38697	1497428877
77	Jun/13	310296	46993	2208312325
78	Jul/13	329813	66510	4423618325
79	Ago/13	310891	47588	2264643773
80	Set/13	280450	17146	294000953
81	Out/13	335824	72521	5259264164
82	Nov/13	321705	58402	3410775556
83	Dez/13	305776	42473	1803918352
84	Jan/14	273454	10151	103050094
85	Fev/14	251095	-12209	149049444

Amostra	Mês de Referência	\widehat{DEM}_i	$(\widehat{DEM}_i - \overline{DEM}_1)$	$(\widehat{DEM}_i - \overline{DEM}_1)^2$
86	Mar/14	256128	-7175	51485730
87	Abr/14	260760	-2543	6467273
88	Mai/14	268029	4726	22331904
89	Jun/14	244641	-18662	348269717
90	Jul/14	158298	24247	587904794
$\sum (\widehat{DEM}_i - \overline{DEM}_1)^2 = 1,75236 \times 10^{11}$				

Fonte: (O AUTOR, 2015)

APÊNDICE B - SOMA DOS QUADRADOS DOS ERROS

Tabela 10 - Determinação da soma dos quadrados dos erros (SQ_E).

Amostra	Mês de Referência	DEM _i	\widehat{DEM}_i	e _i	e _i ²
1	Fev/07	139619	158298	-18679	348922543
2	Mar/07	183763	180058	3705	13730098
3	Abr/07	170042	175898	-5856	34294029
4	Mai/07	200299	196470	3829	14661579
5	Jun/07	188777	204430	-15653	245031143
6	Jul/07	206332	213910	-7578	57433609
7	Ago/07	223906	211645	12261	150334343
8	Set/07	194098	193116	982	963556
9	Out/07	232508	228220	4288	18385990
10	Nov/07	225745	230744	-4999	24988699
11	Dez/07	231310	233930	-2620	6864239
12	Jan/08	205446	208613	-3167	10030933
13	Fev/08	191106	186999	4107	16866998
14	Mar/08	220906	201111	19795	391843079
15	Abr/08	248014	211271	36743	1350018747
16	Mai/08	229960	221702	8258	68200213
17	Jun/08	242855	236552	6303	39728137
18	Jul/08	272973	246390	26583	706629565
19	Ago/08	231107	232590	-1483	2199857
20	Set/08	254146	223005	31141	969767424
21	Out/08	224758	245513	-20755	430770668
22	Nov/08	166278	218313	-52035	2707624197
23	Dez/08	183894	182953	941	886028
24	Jan/09	189766	181298	8468	71712817
25	Fev/09	191343	188085	3258	10617369
26	Mar/09	260987	238295	22692	514920408
27	Abr/09	224394	227929	-3535	12494601
28	Mai/09	237363	244977	-7614	57966749
29	Jun/09	289765	264579	25186	634323615
30	Jul/09	273611	277452	-3841	14755655
31	Ago/09	247540	279500	-31960	1021422616
32	Set/09	296653	278827	17826	317778407
33	Out/09	281312	281115	197	38742
34	Nov/09	238466	284778	-46312	2144831227
35	Dez/09	277894	296655	-18761	351970876
36	Jan/10	201724	244935	-43211	1867159020
37	Fev/10	211360	234723	-23363	545812644
38	Mar/10	337359	277799	59560	3547444584
39	Abr/10	261870	240076	21794	474975864
40	Mai/10	235758	249287	-13529	183037890

Amostra	Mês de Referência	DEM _i	\widehat{DEM}_i	e _i	e _i ²
41	Jun/10	247471	267152	-19681	387326503
42	Jul/10	285197	287880	-2683	7199376
43	Ago/10	296565	293376	3189	10167368
44	Set/10	291405	288528	2877	8277995
45	Out/10	287580	306820	-19240	370183083
46	Nov/10	311358	326410	-15052	226550098
47	Dez/10	361217	319677	41540	1725578942
48	Jan/11	230113	257588	-27475	754862526
49	Fev/11	258789	247278	11511	132509084
50	Mar/11	288710	258722	29988	899293121
51	Abr/11	272881	254757	18124	328490744
52	Mai/11	300486	282860	17626	310681913
53	Jun/11	286908	293936	-7028	49389384
54	Jul/11	287947	296491	-8544	73008254
55	Ago/11	307764	298933	8831	77990919
56	Set/11	293579	266346	27233	741655741
57	Out/11	263781	292851	-29070	845069173
58	Nov/11	305191	313502	-8311	69075522
59	Dez/11	329202	317490	11712	137167170
60	Jan/12	252655	255391	-2736	7486982
61	Fev/12	235830	244442	-8612	74173150
62	Mar/12	284089	279702	4387	19246731
63	Abr/12	244819	256646	-11827	139868255
64	Mai/12	274535	314514	-39979	1598305009
65	Jun/12	340667	329708	10959	120098237
66	Jul/12	351385	341257	10128	102582567
67	Ago/12	405469	346027	59442	3533361157
68	Set/12	277585	286577	-8992	80859771
69	Out/12	326911	333816	-6905	47673757
70	Nov/12	297000	325005	-28005	784275740
71	Dez/12	335926	316893	19033	362254428
72	Jan/13	296852	279570	17282	298657920
73	Fev/13	222479	245752	-23273	541648547
74	Mar/13	268317	286580	-18263	333541296
75	Abr/13	316670	304463	12207	149000525
76	Mai/13	300582	302000	-1418	2009916
77	Jun/13	302887	310296	-7409	54889912
78	Jul/13	323917	329813	-5896	34767253
79	Ago/13	312689	310891	1798	3231501
80	Set/13	293917	280450	13467	181372348
81	Out/13	313472	335824	-22352	499606238
82	Nov/13	288186	321705	-33519	1123518962
83	Dez/13	335926	305776	30150	909043673
84	Jan/14	299737	273454	26283	690772533
85	Fev/14	246904	251095	-4191	17560358

Amostra	Mês de Referência	DEM_i	\widehat{DEM}_i	e_i	e_i²
86	Mar/14	228700	256128	-27428	752280544
87	Abr/14	279727	260760	18967	359746880
88	Mai/14	277886	268029	9857	97165313
89	Jun/14	250619	244641	5978	35735252
90	Jul/14	279789	158298	-7761	60230591
				$\sum e_i^2 = 39550881019$	

Fonte: (O AUTOR, 2015)