



**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA QUIMICA
CURSO DE ENGENHARIA DE PETRÓLEO**

PAULO VITOR LIRA MOREIRA

MODELOS DE PREVISÃO DE DEMANDA DE DERIVADOS DE PETRÓLEO

**FORTALEZA
2017**

PAULO VITOR LIRA MOREIRA

MODELOS DE PREVISÃO DE DEMANDA DE DERIVADOS DE PETRÓLEO

Monografia apresentada ao Programa de Graduação em Engenharia de Petróleo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de graduado em Engenharia de Petróleo.

Orientador: Prof. Dr. Vitor Moreira da Rocha Ponte

FORTALEZA

2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- L745m Lira Moreira, Paulo Vitor.
Modelos de previsão de demanda em derivados de petróleo / Paulo Vitor Lira Moreira. –
2017.
65 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro
de Tecnologia, Curso de Engenharia de Petróleo, Fortaleza, 2017.
Orientação: Prof. Dr. Vitor Moreira da Rocha Ponte.
1. Previsão de demanda. 2. Planejamento de produção. 3. Derivados de Petróleo. 4.
Séries Temporais. I. Título.

CDD 665.5092

PAULO VITOR LIRA MOREIRA

MODELOS DE PREVISÃO DE DEMANDA DE DERIVADOS DE PETRÓLEO

Monografia apresentada ao Programa de Graduação em Engenharia de Petróleo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de graduado em Engenharia de Petróleo.

Aprovada em: 18/07/2017.

BANCA EXAMINADORA

Prof. Dr. Vitor Moreira da Rocha Ponte (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Me. Pedro Felipe Gadelha Silvino
Universidade Federal do Ceará (UFC)

Prof. Me. Filipe Xavier Feitosa
Universidade Federal do Ceará (UFC)

RESUMO

Realizar previsões de demanda é importante para auxiliar na determinação dos recursos necessários para qualquer empresa incluindo refinarias. Neste trabalho foram realizadas análises de previsão de curto prazo para produção e consumo de derivados de petróleo utilizando séries temporais. O objetivo é testar vários métodos para cada derivado a fim de determinar a precisão de cada um deles. Dos métodos utilizados, Winters mostrou-se o mais preciso, seguido de Suavização Exponencial. Entretanto a diferença no erro do melhor método em relação aos demais muitas vezes é menor do que dois pontos percentuais. A previsão de produção utilizando dados nacionais possui um erro menor do que quando se usa dados regionais, mostrando que a produção nacional é mais sistemática e menos aleatória do que a produção regional. A previsão de consumo final foi bastante acurada tanto em dados nacionais quanto regionais, mostrando que distribuidoras de combustíveis podem usar tais métodos para realizar seus planejamentos.

Palavras-chave: Previsão de demanda. Planejamento da produção. Derivados de petróleo. Séries temporais.

ABSTRACT

Making demand forecasts is essential to help determine the necessary resources to any company including oil refineries. In this work, it has been made short term forecast analysis for oil production and consumption using time series. The goal is to test different methods to each derivate in order to determine the accuracy of each one. Among the methods, Winters turned to be the most accurate, followed by Exponential Smoothing. However the difference in accuracy between the best method and the others was often below two percentage points. The forecast for production using national data was more accurate than the ones using regional data, showing that the national production is more systematic and less random than the regional one. The forecast for consumption was very accurate in both national and regional data, showing that fuel distributors can use these methods in its planning.

Keywords: Demand forecast. Production planning. Oil derivates. Time series.

LISTA DE FIGURAS

Figura 1 – Alguns padrões típicos de demanda regular (adaptado de Ballou, 2006)	16
Figura 2 – Exemplo de padrão de demanda incerta (adaptado de Ballou, 2006)	17
Figura 3 – Modelo de disponibilização dos dados (fonte: ANP)	26
Figura 4 – Funções de importação e checagem	27
Figura 5 – Output da função <i>view</i>	27
Figura 6 – Transformando os dados em séries temporais	28
Figura 7 – Comportamento da demanda (produção) de asfalto	31
Figura 8 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Asfalto	31
Figura 9 – Comportamento da demanda (produção) de Coque	34
Figura 10 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Coque	35
Figura 11 – Comportamento da demanda (produção) de gasolina tipo A	36
Figura 12 – Comportamento da demanda (consumo) de gasolina tipo C	37
Figura 13 – Demanda real (preto) e previsão (vermelho) VS tempo para consumo nacional de Gasolina tipo C	38
Figura 14 – Comportamento da demanda (produção) de querosene de aviação ..	39
Figura 15 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Querosene de Aviação	40
Figura 16 – Comportamento da demanda (consumo) de querosene de aviação ..	41
Figura 17 – Comportamento da demanda (produção) de GLP	42
Figura 18 – Comportamento da demanda (consumo) de GLP	43
Figura 19 – Comportamento da demanda (produção) de Nafta	45

Figura 20 – Demanda real (preto) e previsão (vermelho) VS tempo para Nafta (São Paulo)	46
Figura 21 – Comportamento da demanda (produção) de Óleo Combustível	47
Figura 22 – Comportamento da demanda (consumo) de Óleo Combustível	48
Figura 23 – Comportamento da demanda (produção) de Óleo Diesel	50
Figura 24 – Comportamento da demanda (produção) de Óleo Diesel	51
Figura 25 – Comportamento da demanda (consumo) de Etanol Hidratado	53

LISTA DE TABELAS

Tabela 1	– Exemplo de aplicação de média móvel (4 períodos)	19
Tabela 2	– Temperatura e consumo de café em campos de futebol (Bowersox e Closs, 2011)	22
Tabela 3	– Análise de melhor método para Asfalto (produção)	32
Tabela 4	– Análise de melhor método para Coque (produção)	34
Tabela 5	– Análise melhor método para Gasolina A (produção)	37
Tabela 6	– Análise melhor método para Gasolina C (consumo)	38
Tabela 7	– Análise melhor método para Querosene de Aviação (produção)	40
Tabela 8	– Análise melhor método para Querosene de Aviação (consumo)	42
Tabela 9	– Análise melhor método para GLP (produção)	43
Tabela 10	– Análise melhor método para GLP (consumo)	45
Tabela 11	– Análise melhor método para Nafta (produção)	46
Tabela 12	– Análise melhor método para Óleo Combustível (produção)	48
Tabela 13	– Análise melhor método para Óleo Combustível (consumo)	49
Tabela 14	– Análise melhor método para Óleo Diesel (produção)	50
Tabela 15	– Análise melhor método para Óleo Diesel (Consumo)	52
Tabela 16	– Análise melhor método para Etanol Hidratado (Consumo)	53
Tabela 17	– Erro de previsão por método por derivado	54

LISTA DE ABREVIATURAS E SIGLAS

ANP	Agência Nacional de Petróleo, Gás Natural e Biocombustíveis
SE	Suavização Exponencial
EPAM	Erro Percentual Absoluto Médio
DMA	Desvio Médio Absoluto
EQM	Erro Quadrático Médio
QAV-1	Querosene de Aviação

LISTA DE SÍMBOLOS

T	Período de tempo (meses)
F_{t+1}	Previsão para o período seguinte
D	Demanda real para determinado período
α	Constante ponderada de nível
S	Previsão inicial para determinado período
T	Tendência para determinado período
β	Constante ponderada de tendência
γ	Constante de ponderação do índice sazonal
I	Índice sazonal para determinado período
P	Tempo de uma estação sazonal completa
E_t	Erro para determinado período

SUMÁRIO

1	INTRODUÇÃO	14
2	PREVISÃO DE DEMANDA EM REFINARIAS	14
3	TIPOS DE DEMANDA	15
3.1	Demanda Espacial VS Demanda Temporal	15
3.2	Demanda Regular VS Demanda Irregular	15
3.3	Demanda Dependente VS Demanda Independente	17
4	MÉTODOS DE PREVISÃO	17
4.1	Métodos Qualitativos	18
4.2	Métodos de Projeção Histórica	18
4.2.1	Média Móvel	18
4.2.2	Alisamento Exponencial Simples	18
4.2.3	Alisamento Exponencial corrigido pela Tendência (modelo de Holt)	20
4.2.4	Alisamento Exponencial corrigido pela Tendência e Sazonalidade (modelo de Winters)	21
4.4	Métodos Causais	22
4.5	Simulação	22
5	MEDIÇÃO DE ERROS DE PREVISÃO	22
5.1	Erro Quadrático Médio (EQM)	23
5.2	Desvio Médio Absoluto (DMA)	23
5.3	Erro Percentual Absoluto Médio (EPAM)	24
5.4	Parâmetros para detecção de previsão enviesada	24
5.4.1	Viés	24
5.4.2	Sinal de acompanhamento (SA)	25

6	ESTUDO DE CASO	25
6.1	Preparação dos dados	25
6.1.1	Preparação de dados no Excel	26
6.1.2	Preparação de dados no R	27
6.2	Avaliação do melhor método	28
6.3	Visão por Região	29
6.4	Resultados por derivado	30
6.4.1	Asfalto	30
6.4.2	Coque	33
6.4.3	Gasolina (Tipo A e C)	35
6.4.4	Querosene de Aviação	39
6.4.5	GLP	42
6.4.6	Nafta	45
6.4.7	Óleo Combustível	47
6.4.8	Óleo Diesel	49
6.4.9	Etanol Hidratado	52
6.5	Resumo de resultados	54
7	CONCLUSÃO	54
7.1	Erros de produção e consumo por derivado	54
7.2	Melhores métodos	55
7.3	Segmentação da demanda	55
7.3.1	Produção	55
7.3.2	Consumo	55
7.4	Próximos trabalhos	55
	REFERÊNCIAS	56
	ANEXO A – CÓDIGO UTILIZADO NO R	58

1 INTRODUÇÃO

A cadeia de produção de petróleo vai desde a prospecção até a comercialização, passando por diversas áreas importantes como o planejamento de produção, armazenagem, transporte, refino e distribuição.

Uma forma de segmentar essas atividades encontradas na literatura é dividindo em *downstream*, *upstream* e *midstream*. *Upstream* é a parte de exploração e produção. *Midstream* refere-se somente ao refino. *Downstream* é a parte de comercialização de derivados acabados.

Este trabalho irá focar na parte *midstream* da cadeia de produção, ou seja, no refino. O gerenciamento de uma refinaria de petróleo se preocupa fortemente com o planejamento de suas operações, sendo um grande fator a se levar em consideração devido à natureza dinâmica da economia. Companhias devem avaliar o potencial impacto de variação na demanda para a especificação dos produtos finais (MAGALHÃES et al., 1998).

Diferentemente de outras indústrias, no refino de petróleo um único insumo pode ser transformado em diversos produtos. Este trabalho busca auxiliar na predição de quanto de cada derivado deverá ser produzido através de uma análise de dados de produção e consumo mensais.

Para isso serão utilizados diversos métodos de previsão de demanda e analisar qual possui o menor erro para cada derivado. Este teste será realizado para o consolidado de todas as refinarias do Brasil e por região. Os dados utilizados nas análises são de produção/consumo mensal de derivados fornecidos pela Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP).

2 PREVISÃO DE DEMANDA EM REFINARIAS

Segundo Werner e Ribeiro (2003), realizar previsões de demanda é importante para auxiliar na determinação dos recursos necessários para a empresa. Em tempos de abertura de mercados, essa atividade torna-se fundamental. Os mercados que podem ser acessados pela empresa, assim como a concorrência que os disputam, mudam continuamente, exigindo novas previsões de demanda em períodos mais curtos. Zhao et Al (2002) afirmam que, em um contexto mais amplo de cadeia de suprimentos, a previsão de demanda determina o valor da informação

compartilhada, uma função que reduz custos e melhora o desempenho de entrega.

Para Ballou (2006), a previsão dos níveis de demanda é vital para a empresa como um todo, pois proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais, entre as quais Logística, Marketing, Produção e Finanças.

No contexto de refino de petróleo, temos no Brasil refinarias concentradas espacialmente, maximizando as economias de escala na produção e minimizando as deseconomias de escala na distribuição (GIRARD, 2007). A previsão de demanda auxilia na predição da quantidade de derivados a serem produzidos por cada uma das refinarias e também na quantidade a, eventualmente, ser importada.

A Petrobrás afirma que o nível de processamento das nossas refinarias é definido mensalmente, buscando o melhor resultado econômico para a empresa. Para tal, são considerados vários fatores, entre eles a previsão de demanda de derivados (entrevista em resposta ao Valor Econômico, 2015).

3 TIPOS DE DEMANDA

Para Ballou (2006), a demanda pode ser segmentada de três maneiras diferentes.

3.1 Demanda Espacial VS Demanda Temporal

A logística possui dimensões tanto no espaço quanto no tempo, portanto, precisamos saber onde e quando o volume de demanda se manifestará.

A localização espacial da demanda é de suma importância para planejar a localidade de centros de distribuição, determinar o balanceamento de estoques ao longo da rede logística e alocar geograficamente os recursos de transporte.

Com relação ao tempo, a variação na demanda é resultado de fatores como o crescimento ou decréscimo nas vendas, sazonalidade e flutuações em geral causadas por inúmeras razões.

3.2 Demanda Regular VS Demanda Irregular

Diz-se que a demanda é regular quando sua representação típica possui padrões que podem ser divididos em componentes de tendência, sazonais ou aleatórios, desde que variações aleatórias representem uma pequena parcela no restante da série de tempo. A figura 1 demonstra graficamente típicos padrões aleatórios, sazonais e de tendência.

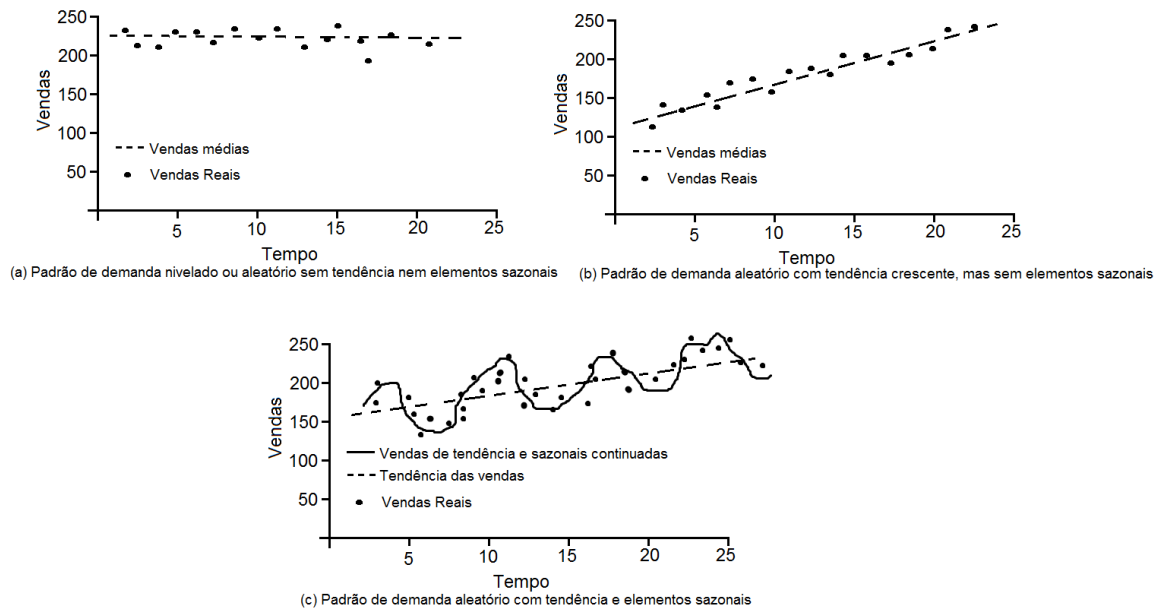


Figura 1 – Alguns padrões típicos de demanda regular (Adaptado de Ballou, 2006)

Quando a demanda possui baixo volume geral e não há certeza quanto ao seu surgimento, diz-se que tal demanda é irregular ou incerta. Esse tipo de demanda é comum no varejo, onde há produtos que vendem muito pouco, os chamados *slow movers*. A figura 2 representa graficamente um padrão de demanda incerta.




Figura 2 – Exemplo de padrão de demanda incerta (adaptado de Ballou, 2006)

3.3 Demanda Dependente VS Demanda Independente

Para Bertaglia (2010) a demanda independente é determinada pelas condições de mercado, não sendo afetada pela necessidade de produção. Ela é gerada diretamente pelo consumidor ou cliente.

A demanda dependente é determinada pelas decisões de produção e está vinculada a uma demanda independente. Por exemplo: o número de pneus novos a serem encomendados por um fornecedor é múltiplo do número de carros novos que um fabricante colocará em produção.

4 MÉTODOS DE PREVISÃO

Para Ballou (2006) e Bowersox, Closs (2011), os métodos de previsão podem ser segmentados em três tipos: Qualitativos, Projeção Histórica e Métodos Causais. Chopra (2010) inclui Simulação como um quarto tipo. Chopra (2010) afirma que para selecionar uma técnica de previsão apropriada, a empresa deverá entender as dimensões relevantes à previsão, como área geográfica, grupo de produtos e de clientes. Entendendo as diferenças na demanda de cada dimensão facilitará na escolha do melhor método. Muitas vezes uma combinação de mais de um método é mais eficaz.

4.1 Métodos Qualitativos

Métodos qualitativos são aqueles que recorrem a julgamento, intuição, pesquisas ou técnicas comparativas a fim de produzir estimativas quantitativas sobre o futuro. Ballou (2006), Chopra (2010) e Bowersox, Closs (2011) concordam que este tipo de método é mais eficaz na ausência de dados históricos, como no lançamento de novos produtos ou entrada em uma nova região.

4.2 Métodos de Projeção Histórica

De acordo com Ballou (2006, p. 245)

Quando se dispõe de um número razoável de dados históricos e a tendência e variações sazonais nas séries de tempo são bem definidas, a projeção desses dados no futuro pode representar uma maneira eficiente de previsão de curto prazo. A premissa básica é que o padrão de tempo no futuro será uma repetição do passado, pelo menos em sua maior parte.

Devido à disponibilidade de dados de derivados e da natureza curta da previsão, métodos de projeção histórica vão ser testados para realizar as projeções. O racional dos principais modelos de projeção histórica é descrito a seguir.

4.2.1 Média móvel

A média móvel é mais utilizada quando não são observados padrões de tendência ou sazonalidade no comportamento da demanda.

Esta média representa um valor médio de “N” períodos anteriores como é demonstrado na equação a seguir:

$$F_{t+1} = \frac{D_t + D_{t-1} + D_{t-2} + \dots + D_{t-N+1}}{N} \quad (4.1)$$

Onde:

t = Período atual (normalmente em semanas ou meses)

F_{t+1} = Previsão para o período seguinte

D = Demanda real de determinado período

N = Número total de períodos utilizados para média móvel

A Tabela 1 a seguir demonstra um exemplo fictício de utilização da média móvel de quatro períodos (N=4):

Tabela 1 – Exemplo de aplicação de média móvel (4 períodos)

Período	1	2	3	4	5	6	7	8	9
Demanda real	248	233	189	311	244	198	213	277	261
Previsão	-	-	-	-	245	244	236	242	233

Perceba que a previsão de determinado período é sempre a média dos 4 períodos anteriores (daí o nome média móvel). Além disso, durante os 4 períodos iniciais não é possível realizar uma previsão devido à ausência de dados. Por isso métodos qualitativos são mais indicados para produtos novos.

4.2.2 Alisamento exponencial simples

O alisamento exponencial simples dá pesos maiores para períodos mais recentes de acordo com a equação 4.2

$$F_{t+1} = \alpha D_t + (1 - \alpha)F_t \quad (4.2)$$

Onde α é uma constante de ponderação que varia de 0 a 1 e deve ser otimizada periodicamente. Quanto mais próximo de 1, mais peso a previsão dará para dados mais recentes. A vantagem é que o modelo responderá rapidamente e a desvantagem é que a previsão poderá ser muito volátil. O contrário ocorre para α próximos de zero: a previsão será suave, mas responderá mais lentamente a mudanças no comportamento da demanda.

Se continuarmos desenvolvendo essa equação para períodos seguintes, fica mais fácil de perceber que o método dá um maior peso para períodos mais recentes e vai decaindo exponencialmente para períodos mais antigos.

$$F_{t+1} = \alpha D_t + (1 - \alpha)F_t \quad (4.2)$$

$$F_{t+2} = \alpha D_{t+1} + (1-\alpha)[\alpha D_t + (1-\alpha)F_t]$$

$$F_{t+3} = \alpha D_{t+2} + (1-\alpha)\{\alpha D_{t+1} + (1-\alpha)[\alpha D_t + (1-\alpha)F_t]\}$$

Realizando as operações de multiplicação em F_{t+3} vem:

$$F_{t+3} = \alpha D_{t+2} + (1-\alpha)[\alpha D_{t+1} + \alpha(1-\alpha)D_t + (1-\alpha)^2 F_t]$$

$$F_{t+3} = \alpha D_{t+2} + \alpha(1-\alpha)D_{t+1} + \alpha(1-\alpha)^2 D_t + (1-\alpha)^3 F_t$$

Colocando o α em evidência encontramos um formato mais fácil de interpretar:

$$F_{t+3} = \alpha[D_{t+2}(1-\alpha)^0 + D_{t+1}(1-\alpha)^1 + D_t(1-\alpha)^2] + F_t(1-\alpha)^3$$

Perceba que a potência do termo $(1-\alpha)$ aumenta quão mais antigo for o período. Como α está entre 0 e 1, o termo $(1-\alpha)$ também estará nesse intervalo. Sendo assim, quanto maior a potência, menor o resultado. Portanto quanto mais antigo for o período, menor será seu peso.

Devido a esse fato, o valor inicial para a previsão F_t pouco importa quando pegamos períodos longos o suficiente. Tal valor pode ser calculado por um método mais simples como média móvel ou mesmo ser substituído por zero.

4.2.3 Alisamento exponencial corrigido pela tendência (modelo de Holt)

O alisamento exponencial simples pode representar um bom método para demandas que não possuem tendência de crescimento ou decrescimento. O modelo de Holt visa capturar essa tendência acrescentando um nível a mais como mostram as equações 4.3 a 4.5:

$$S_{t+1} = \alpha D_t + (1-\alpha)(S_t + T_t) \quad (4.3)$$

$$T_{t+1} = \beta(S_{t+1} - S_t) + (1-\beta)T_t \quad (4.4)$$

$$F_{t+1} = S_{t+1} + T_{t+1} \quad (4.5)$$

Onde:

S = previsão inicial para determinado período

T = tendência para determinado período

β = constante ponderada de tendência variando entre 0 e 1

4.2.4 Alisamento exponencial corrigido pela tendência e sazonalidade (Modelo de Winter)

O comportamento sazonal da demanda também pode ser levado em consideração. Mas para Ballou (2006), isso só deve ser feito se duas condições forem satisfeitas:

- a) Os picos devem possuir motivos conhecidos e ocorrer sempre na mesma época do ano.
- b) A variação sazonal deve ser maior que a variação aleatória.

As equações que descrevem o modelo são as seguintes:

$$S_{t+1} = \alpha(D_t/I_{t-P}) + (1-\alpha)(S_t + T_t) \quad (4.6)$$

$$T_{t+1} = \beta((S_{t+1} - S_t) + (1-\beta)T_t) \quad (4.7)$$

$$I_t = \gamma(D_t/S_t) + (1-\gamma)I_{t-P} \quad (4.8)$$

$$F_{t+1} = (S_{t+1} + T_{t+1}) / I_{t-P+1} \quad (4.9)$$

Onde:

γ = Constante de ponderação do índice sazonal variando entre 0 e 1

I = Índice sazonal para determinado período

P = Tempo de uma estação completa (normalmente um ano)

4.3 Métodos Causais

Métodos causais correlacionam a demanda com outros fatores conjunturais. Bowersox e Closs (2011) mostram que existe uma relação entre a temperatura e vendas de café em jogos de futebol representados na Tabela 2.

Tabela 2 – Temperatura e consumo de café em campos de futebol (Bowersox e Closs, 2011)

Data	Temperatura (°F)	Consumo de café (milhares de xícaras)
10/9	65	21
24/9	42	32
1/10	58	19
15/10	32	29
29/10	28	40
12/11	20	43
16/9	72	18
30/9	62	24
14/10	40	33
21/10	56	24
11/11	25	36
18/11	30	38

Desta forma, é possível prever a venda de cafés pela correlação: $y = 49,775 - 0,45x$, onde y é o consumo de café em milhares de xícaras e x é a temperatura em °F.

4.4 Simulação

Chopra (2010) afirma que simulação é uma combinação entre métodos temporais e causais. O exemplo utilizado pelo autor é o de companhias aéreas que simulam o comportamento de compra dos clientes para prever a demanda de assentos com tarifa mais elevada quando os assentos econômicos estão esgotados. Além disso, simulações podem ajudar na projeção do impacto de uma promoção ou entrada de um novo concorrente.

5 MEDIÇÕES DE ERRO DE PREVISÃO

Para Chopra (2010), todo caso de demanda possui um componente aleatório. Um bom método de previsão deverá capturar somente o componente sistemático, mas não o componente aleatório. Desta forma, a previsão da demanda conterá um

erro. A análise desse erro é importante por 3 principais motivos:

- Comparar métodos de previsão.

Diversos métodos de previsão podem ser utilizados para projetar uma demanda. O erro gerado por esses métodos é um dos principais parâmetros para escolher o método ideal.

- Detectar previsões enviesadas.

O comportamento esperado do erro deve ser aproximadamente igual tanto para mais quanto para menos. Porém, se a previsão produz consistentemente um erro positivo ou negativo, significa que ela está enviesada e deve ser corrigida.

- Elaborar planos de contingência.

Imagine que uma empresa possui dois fornecedores: um local e um distante. O fornecedor local é mais caro, mas entrega mais rápido. Enquanto o distante é mais barato e demora mais a entregar. Assim, a empresa deve comprar certa quantidade do fornecedor local caso a quantidade pedida do fornecedor mais barato tenha sido subestimada. O erro auxilia o gestor a calcular quanto ele tem que estar preparado para comprar do fornecedor local caso seja necessário.

Ballou (2006), Bowersox, Closs (2011) e Chopra (2010) afirmam que o erro de previsão é calculado simplesmente pela diferença entre a demanda real e a demanda prevista, como representa a equação 5.1:

$$E_t = F_t - D_t \quad (5.1)$$

Esta medida de erro pode não ser muito útil. Por exemplo, 100 unidades pode ser muito ou pouco dependendo da quantidade total da demanda real. Por isso existem outras formas de calcular o erro que fornecem um maior leque de interpretações. Chopra (2010) descreve outros 3 tipos de erros.

5.1 Erro quadrático médio (EQM)

O erro quadrático médio é dado pela seguinte equação:

$$EQM(n) = \frac{1}{n} \sum_{t=1}^n E_t^2 \quad (5.2)$$

O erro está relacionado à variância da previsão. Assume-se o que o componente aleatório da demanda possui média 0 e variância EQM.

5.2 Desvio médio absoluto (DMA)

O desvio médio absoluto é dado pela média aritmética dos módulos dos erros como mostrado na equação 5.3:

$$DMA(n) = \frac{1}{n} \sum_{t=1}^n |E_t| \quad (5.3)$$

O DMA pode ser utilizado para estimar o desvio padrão do componente aleatório. Caso o componente seja distribuído normalmente o desvio padrão é dado por:

$$\sigma = 1,25 \text{ DMA} \quad (5.4)$$

5.3 Erro percentual absoluto médio (EPAM)

O erro percentual absoluto médio é dado pela média dos erros em módulo em relação a demanda real como demonstrado na equação 5.5:

$$EPAM(n) = \frac{1}{n} \sum_{t=1}^n \frac{|E_t|}{D_t} 100 \quad (5.5)$$

A vantagem deste método é ter o valor relativo à demanda real, facilitando sua interpretação. Já a sua desvantagem é que se a demanda real em um dos

períodos da análise for zero, o erro será infinito. Ignorar esses dados de demanda real nula subestimará o erro real.

5.4 Parâmetros para detecção de previsão enviesada

Como já discutido, previsões enviesadas são aquelas que possuem um erro consistentemente positivo ou negativo. Para facilitar a detecção de tal problema, CHOPRA (2010) fornece dois parâmetros: Viés e Sinal de Acompanhamento (SA).

5.4.1 Viés

O viés é dado pelo somatório dos valores absolutos dos erros como demonstrado na equação 5.6:

$$Viés(n) = \sum_{t=1}^n E_t \quad (5.6)$$

O esperado é que o viés flutue em torno de zero caso o erro seja realmente aleatório.

5.4.2 Sinal de acompanhamento (SA)

O sinal de acompanhamento é calculado pela razão entre o Viés e o DMA de determinado período:

$$SA_t = \frac{viés_t}{DMA_t} \quad (5.7)$$

O esperado é que o SA esteja entre -6 e 6. Caso o valor seja menor que -6 significa que a demanda está sendo subestimada, o contrário ocorre quando o valor é maior que 6.

6 ESTUDO DE CASO

Iremos aplicar o conhecimento discutido para prever a demanda de produção de derivados de petróleo utilizando o software R. A ANP disponibiliza dados de produção e consumo de janeiro de 2000 até 29 de maio de 2017. Utilizaremos esses dados para classificar as demandas quanto ao tipo e posteriormente prevê-las. Um método de previsão terá mais sucesso dependendo do tipo de demanda. Por exemplo: uma demanda sazonal será melhor projetada por Winters do que por suavização exponencial. Entretanto, vamos testar todos os métodos de previsão de séries temporais descritos para avaliar qual possui menor erro.

6.1 Preparação dos dados

Antes de iniciar as análises no R, foi necessário preparar os dados tanto no Excel quanto no próprio R.

6.1.1 Preparação de dados no Excel

Os dados da ANP são disponibilizados em Excel através de uma *pivot table* como mostra a figura 3:

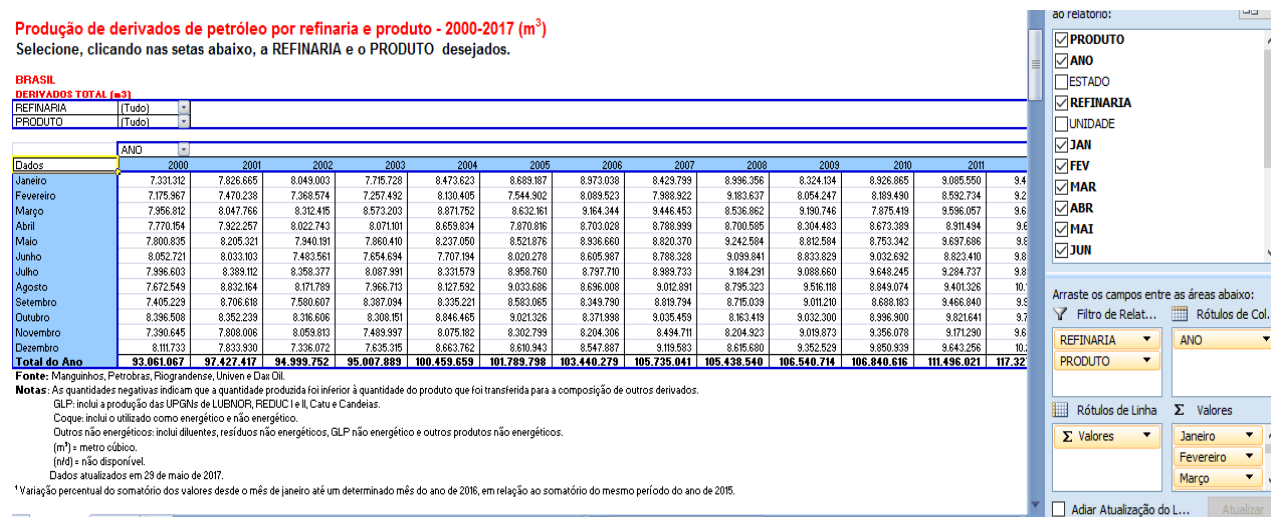


Figura 3 – Modelo de disponibilização dos dados (fonte: ANP)

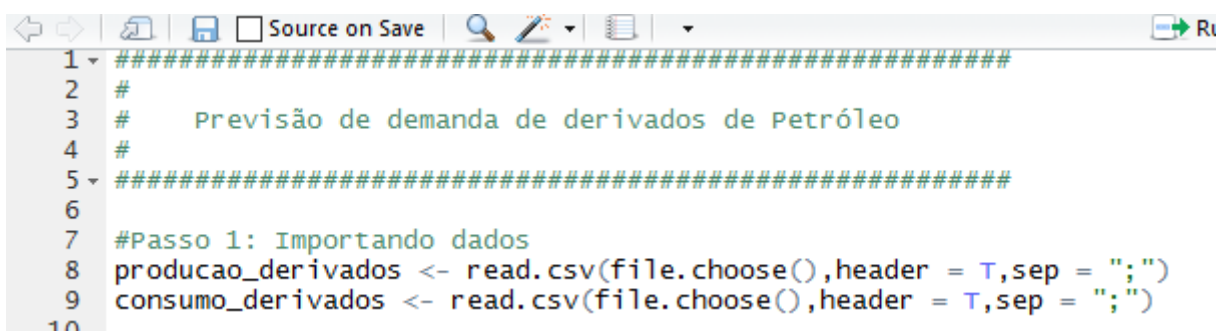
Para poder importar esses dados para o R, foi necessário seguir 3 passos:

- Alterar os campos da pivot table colocando produto nas colunas e ano nas linhas.
- Copiar a tabela para um arquivo em branco de Excel.
- Adicionar uma coluna com o mês e salvar o arquivo no formato .csv (*column separetade values*).

O arquivo final para produção possui uma coluna com o mês (de 1 a 208, representando todo o período) e mais 15 colunas de produção de derivados.

6.1.2 Preparação de dados no R

O arquivo adaptado foi importado para o R através da função “read.csv” e armazenado em “producao_derivados” e “consumo_derivados”. Após isso, usou-se a função “view” para assegurar que os dados foram importados corretamente. As figuras 4 e 5 mostram esse processo. O código completo pode ser observado em anexo.

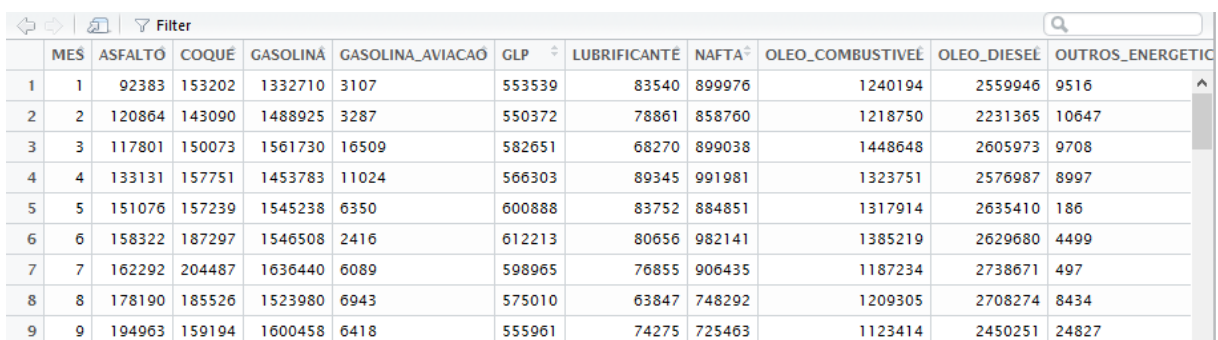


```

1 #####
2 #
3 #   Previsão de demanda de derivados de Petróleo
4 #
5 #####
6
7 #Passo 1: Importando dados
8 producao_derivados <- read.csv(file.choose(),header = T,sep = ";")
9 consumo_derivados <- read.csv(file.choose(),header = T,sep = ";")
10

```

Figura 4 – Funções de importação e checagem



	MES	ASFALTO	COQUÉ	GASOLINÁ	GASOLINA_AVIACAÓ	GLP	LUBRIFICANTÉ	NAFTA	OLEO_COMBUSTIVÉ	OLEO_DIESEÉ	OUTROS_ENERGETIC
1	1	92383	153202	1332710	3107	553539	83540	899976	1240194	2559946	9516
2	2	120864	143090	1488925	3287	550372	78861	858760	1218750	2231365	10647
3	3	117801	150073	1561730	16509	582651	68270	899038	1448648	2605973	9708
4	4	133131	157751	1453783	11024	566303	89345	991981	1323751	2576987	8997
5	5	151076	157239	1545238	6350	600888	83752	884851	1317914	2635410	186
6	6	158322	187297	1546508	2416	612213	80656	982141	1385219	2629680	4499
7	7	162292	204487	1636440	6089	598965	76855	906435	1187234	2738671	497
8	8	178190	185526	1523980	6943	575010	63847	748292	1209305	2708274	8434
9	9	194963	159194	1600458	6418	555961	74275	725463	1123414	2450251	24827

Figura 5 – Output da função view para produção

Após checar que a importação foi realizada com sucesso, utilizou-se a função “ts” (de *time series*) para transformar todas as colunas em séries temporais. Cada derivado tornou-se uma série temporal com os seus respectivos nomes, como mostra a figura 6:

```

15 #Passo 3: Transformando os dados em séries temporais
16
17 #3.1 Produção
18 Prod_Asfalto <- ts(producao_derivados$ASFALTO,start = c(2000.1),frequency = 12)
19 Prod_Coque <- ts(producao_derivados$COQUE,start = c(2000.1),frequency = 12)|
20 Prod_Gasolina_A <- ts(producao_derivados$GASOLINA,start = c(2000.1),frequency = 12)
21 Prod_Gasolina_Aviacao <- ts(producao_derivados$GASOLINA_AVIACAO,start = c(2000.1),frequer
22 Prod_GLP <- ts(producao_derivados$GLP,start = c(2000.1),frequency = 12)
23 Prod_Lubrificante <- ts(producao_derivados$LUBRIFICANTE,start = c(2000.1),frequency = 12)
24 Prod_Nafta <- ts(producao_derivados$NAFTA,start = c(2000.1),frequency = 12)
25 Prod_Oleo_Combustivel <- ts(producao_derivados$OLEO_COMBUSTIVEL,start = c(2000.1),frequer
26 Prod_Oleo_Diesel <- ts(producao_derivados$OLEO_DIESEL,start = c(2000.1),frequency = 12)
27 Prod_Outros_Energeticos <- ts(producao_derivados$OUTROS_ENERGETICOS,start = c(2000.1),fre
28 Prod_Outros_Nao_Energeticos <- ts(producao_derivados$OUTROS_NAO_ENERGETICOS,start = c(200
29 Prod_Parafina <- ts(producao_derivados$PARAFINA,start = c(2000.1),frequency = 12)
30 Prod_Querosene_Aviacao <- ts(producao_derivados$QUEROSENE_AVIACAO,start = c(2000.1),frequ
31 Prod_Querosene_Iluminante <- ts(producao_derivados$QUEROSENE_ILUMINANTE,start = c(2000.1)
32 Prod_Solvente <- ts(producao_derivados$SOLVENTE,start = c(2000.1),frequency = 12)

```

Figura 6 – Transformando os dados em séries temporais (produção)

A partir de agora, o R interpretará esses dados como sendo mensais e começando em janeiro de 2000. Isso finaliza a preparação de dados. O mesmo processo foi realizado para dados de consumo.

6.2 Avaliação do melhor método

Com o objetivo de melhor prever a demanda de derivados, será analisada para cada um deles o erro de SE, Holt e Winters.

Para fazer essa análise, foram criados 3 modelos para cada série temporal (um para cada método). A representação dos modelos para produção de Asfalto vem abaixo.

- SE

```
Prod_SE_GLP <- HoltWinters(Prod_GLP,beta = F,gamma = F)
```

- Holt

```
Prod_Holt_GLP <- HoltWinters(Prod_GLP,gamma = F)
```

- Winters

```
Prod_Winters_GLP<- HoltWinters(Prod_GLP,optim.start=c(alpha=0.2,beta=0.1,gamma=0.1))
```

A função utilizada é a mesma para os 3 modelos, porém as constantes de tendência e sazonalidade só foram aplicadas quando pertinentes. Para o modelo de

Winters, o R encontrou dificuldades em otimizar as constantes, por isso foi sugerido um ponto de partida somente nesse caso. Tal procedimento foi realizado para todos os derivados tanto para produção quanto para consumo.

O output da função “HoltWinters” disponibiliza os valores previstos e as constantes alpha, beta e gamma. O erro foi calculado através da função “accuracy”, que funciona da seguinte maneira: accuracy (“valores previstos”, “valores reais”).

6.3 Visão por Região

Os dados fornecidos pela ANP podem ser filtrados por região, estado ou refinaria. Foi realizada a mesma análise por grupo de estados por 3 motivos:

- Observar se a produção está muito concentrada em uma região e o componente sistemático da demanda nessa região é mais relevante. Assim, podemos eliminar a aleatoriedade das outras regiões e realizar uma projeção mais precisa.
- Comparar o comportamento de demanda geral e entre as regiões e procurar entender suas diferenças/semelhanças.
- Analisar se a eficiência dos métodos encontrada no consolidado Brasil se mantém na análise por regiões.

Para os dados de consumo, utilizou-se a divisão como sendo Norte, Nordeste, Sudeste, Centro-Oeste e Sul.

Já para os dados de produção esse mesmo critério não pôde ser utilizado, pois fazendo assim a representatividade de cada região ficaria má distribuída, concentrando-se muito no Sudeste. Para contornar esse problema, separou-se São Paulo do Sudeste e acrescentou-se Amazonas (único representante com refinaria do Norte) ao Nordeste. O agrupamento final é representado a seguir (nem todos os estados possuem refinarias):

Norte-Nordeste: Amazonas, Bahia, Ceará, Rio Grande do Norte e Pernambuco

São Paulo: São Paulo

Rio-Minas: Rio de Janeiro e Minas Gerais

Sul: Rio Grande do Sul e Paraná

6.4 Resultados por derivado

Esta seção descreve o comportamento da demanda nacional e por região; média de produção e consumo no período; erro por método nacional e por região; visualização gráfica de como o melhor método segue a demanda para alguns casos em que se julgou pertinente. Além disso, foi realizada uma interpretação do comportamento da demanda levantando hipóteses para explicar tendências e sazonalidades.

6.4.1 Asfalto

Produção média período: 169.161 m³

O asfalto é um derivado de petróleo de elevada viscosidade, com propriedades impermeabilizantes e adesivas, não voláteis, de cor preta ou marrom. São constituídos basicamente por asfaltenos, resinas e hidrocarbonetos de natureza aromática.

Dos diversos tipos de Asfalto, a Petrobrás comercializa somente os cimentos Asfálticos de Petróleo (CAP), que tem como principal aplicação a construção e manutenção de pavimentos asfálticos. Abaixo tem-se as informações de produção Nacional e por região.

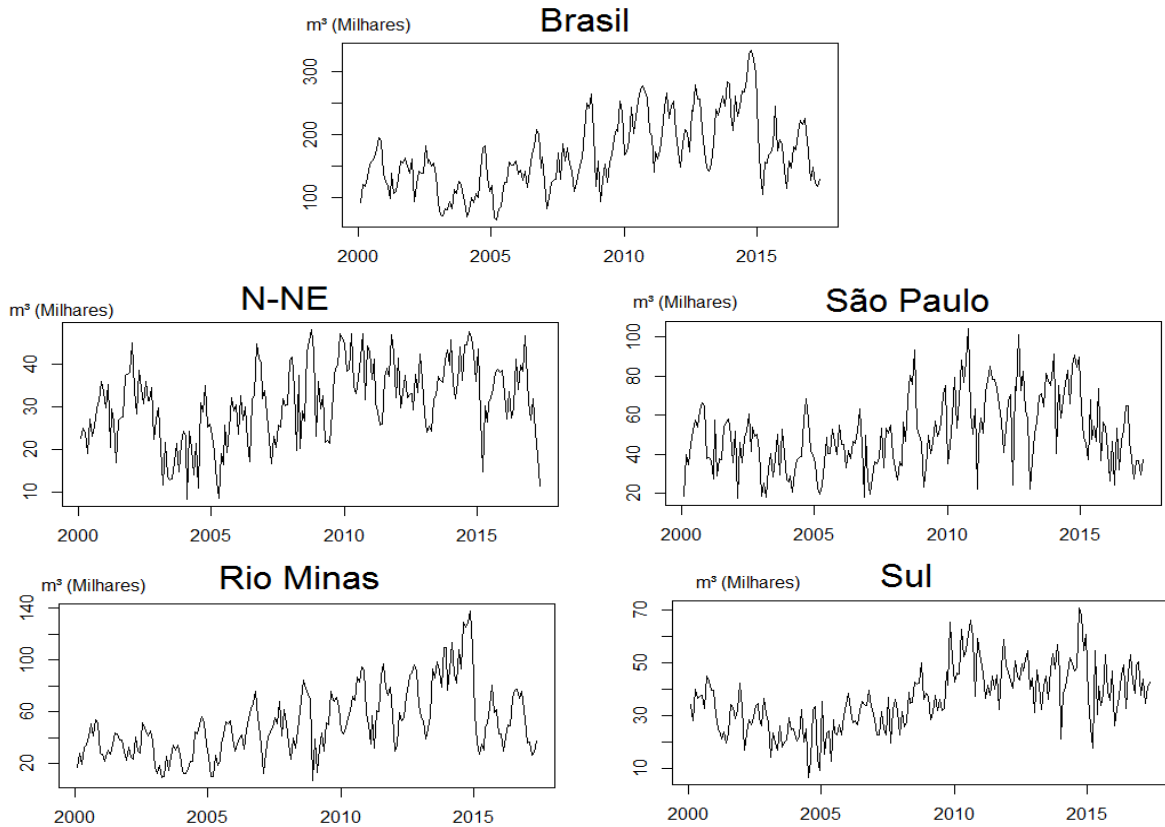


Figura 7 – Comportamento da demanda (produção) de asfalto

Através da figura 7 percebe-se que no cenário nacional há uma clara sazonalidade e uma redução em 2015 (provavelmente devido à crise econômica). O comportamento também é observado na região Rio-Minas e, menos claramente, em São Paulo. Para analisar tal sazonalidade foi criado um gráfico com a média mensal de todo o período.




Gráfico 1 Produção média mensal de Asfalto

Nos período de julho a outubro a produção mensal supera a média anual em 15%. O fato dessa marca ser superada em meses consecutivos caracteriza o comportamento sazonal. Tal sazonalidade pode acontecer devido a esse ser um período de poucas chuvas no sudeste, que vai de abril a setembro.

Outra possibilidade de sazonalidade é em ano eleitoral. Analisando os dados mensais percebe-se que, em média, se produz 22% mais asfalto nos meses de janeiro a setembro em ano de eleição (ano par). Esse comportamento se repete nas regiões (com destaque para Rio-Minas onde a produção é 28% maior que a média até setembro).




Gráfico 2 Produção média mensal de Asfalto ano eleitoral e não eleitoral

Caso essas relações se confirmem com mais evidências, é possível utilizar métodos causais para auxiliar na previsão de Asfalto. A análise estritamente por série temporal é descrita na tabela 3.

Tabela 3 – Análise de melhor método para Asfalto (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	18	30	30	21
SE	15,3%	20,9%	28,1%	31,0%	21,2%
Holt	16,3%	21,5%	30,8%	33,1%	22,3%
Winters	12,3%	19,4%	23,2%	25,2%	21,8%
Melhor Método	Winters	Winters	Winters	Winters	SE

Com exceção da região Sul, Winters foi o melhor método. Este resultado era esperado devido a esse método ser o único a possuir um componente sazonal. Para avaliar como a previsão segue a demanda real mês a mês, as duas curvas foram plotadas na mesma figura.




Figura 8 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Asfalto

Analisando a figura 8 percebe-se que em poucas ocasiões a demanda real fugiu consideravelmente da prevista, em 2003, 2010 e 2015. Isso mostra que o modelo proposto é uma boa ferramenta na previsão da produção de Asfalto.

6.4.2 Coque

Produção média período: 263.614 m³

O coque verde de petróleo (CVP) é um produto sólido, obtido a partir do craqueamento de óleos residuais pesados em unidades de conversão de resíduos denominadas Unidades de Coqueamento Retardado (UCR). A aplicação do CVP é diversa e isso influencia no comportamento de sua demanda. Alguns exemplos de aplicação são siderurgia, abrasivos, termelétricas a carvão, secagem de grãos e indústria química.

Outro fator que pode influenciar na demanda de coque é a decrescente disponibilidade de petróleos de maior qualidade nos últimos anos citada por Marcelo de Camargo, Marcelo Kobayoshi e Marcius de Carvalho (2006).

Através da figura 9 pode-se ver o comportamento da produção de coque no Brasil e por região nos últimos anos.

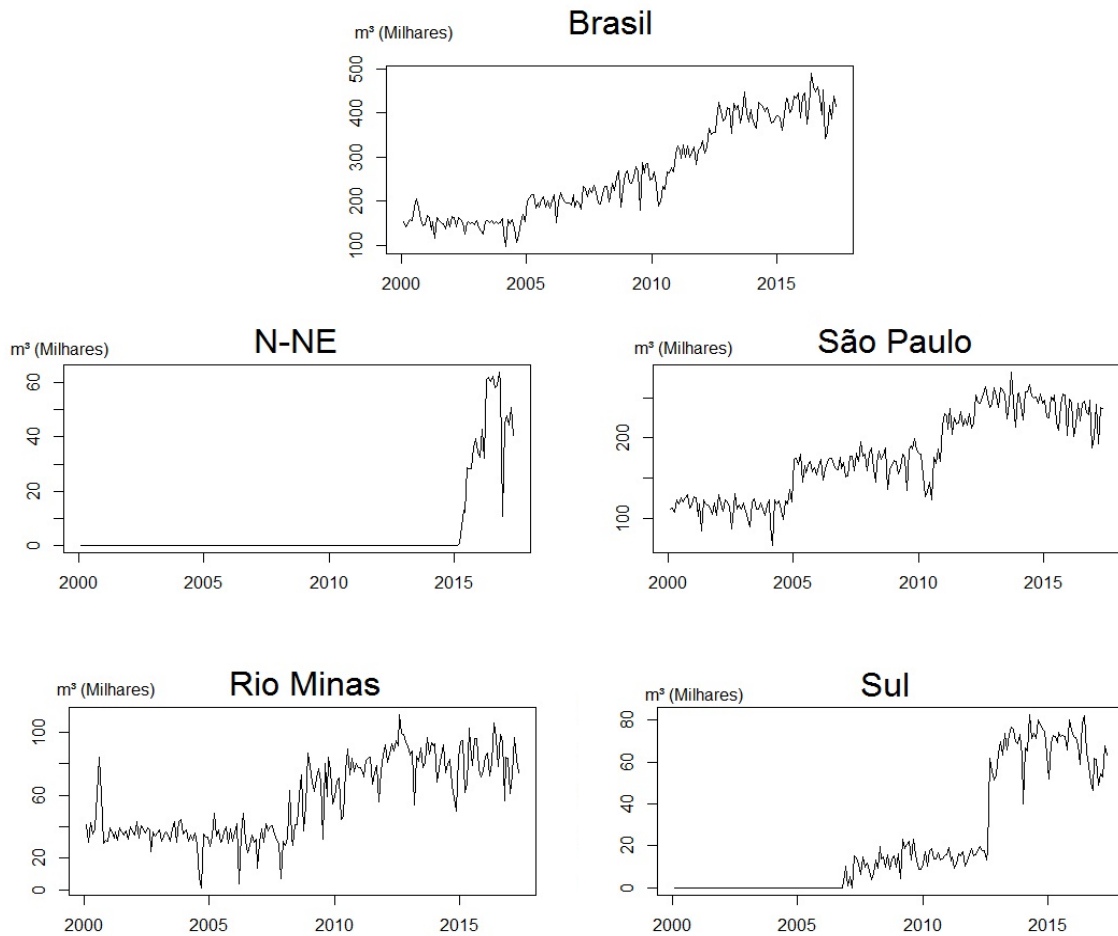


Figura 9 – Comportamento da demanda (produção) de Coque

Percebe-se que nacionalmente há uma tendência de crescimento o que sugere que Holt será um bom método de previsão por levar em conta esse fator. Com exceção de São Paulo, as demandas regionais aparentam ser mais aleatórias que a demanda nacional, no caso de N-NE e Sul a produção só começou a partir de 2015 e 2007 respectivamente.

Os resultados por método tanto para a visão nacional quanto para a visão regional é apresentado na Tabela 4.

Tabela 4 – Análise de melhor método para Coque (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	2	68	22	9
SE	8,1%	41,4%	8,2%	33,1%	14,4%
Holt	8,5%	41,5%	8,3%	32,7%	14,3%
Winters	8,6%	40,5%	8,1%	40,2%	14,9%
Melhor Método	SE	Winters	Winters	Holt	Holt

Ao contrário do esperado, Suavização Exponencial foi o melhor método para prever a demanda nacional, ainda que por uma vantagem pequena. Abaixo há a representação de como esse método segue a demanda real.




Figura 10 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Coque

Diferentemente de Winters, a SE é mais suave ao acompanhar a demanda, evitando grandes discrepâncias, mas não respondendo tão rápido a mudanças bruscas. Como a comparação entre os erros foi pequena, este pode ser um fator a ser considerado na escolha do método.

6.4.3 Gasolina (Tipo A e C)

A Gasolina é o segundo principal combustível automotivo no Brasil perdendo apenas para o Diesel.

A gasolina produzida pelas refinarias é do tipo A, ou seja, sem aditivo de etanol. Já a comercializada nos postos de combustíveis é do tipo C, que leva etanol. Isto é possível devido a tecnologia dos motores flex. A proporção média de etanol na gasolina é de 25%, este valor varia de acordo com a safra de cana de açúcar.

- **Produção de gasolina tipo A**

Produção média período: 1.838.836 m³




Figura 11 – Comportamento da demanda (produção) de gasolina tipo A

Nacionalmente, há uma tendência de crescimento até 2015 e seguido de um decréscimo, provavelmente relacionado à crise econômica. Este indício pode ser verificado através de outro trabalho relacionando a produção de gasolina com o PIB e, caso se confirme, pode ser uma ferramenta auxiliar nas predições.

Regionalmente é interessante ressaltar dois saltos na produção N-NE em 2001 e 2010, o segundo, provavelmente relacionado com a construção da refinaria Potiguar Clara Camarão (criada em setembro de 2010). A tabela 5 apresenta os erros de cada método

Tabela 5 – Análise melhor método para Gasolina A (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	13	48	18	21
SE	4,9%	16,1%	7,4%	8,9%	9,1%
Holt	5,4%	16,8%	8,6%	9,6%	9,7%
Winters	4,6%	16,2%	7,4%	10,0%	9,8%
Melhor Método	Winters	SE	SE ou Winters	SE	SE

Pela primeira vez um derivado apresentou um erro de produção menor do que 5%, tal fator provavelmente ocorre devido ao grande volume produzido. Mesmo regionalmente onde o erro é normalmente maior, há um desvio aceitável com exceção de N-NE.

- **Consumo de gasolina tipo C**

Consumo médio período: 2.522.750 m³

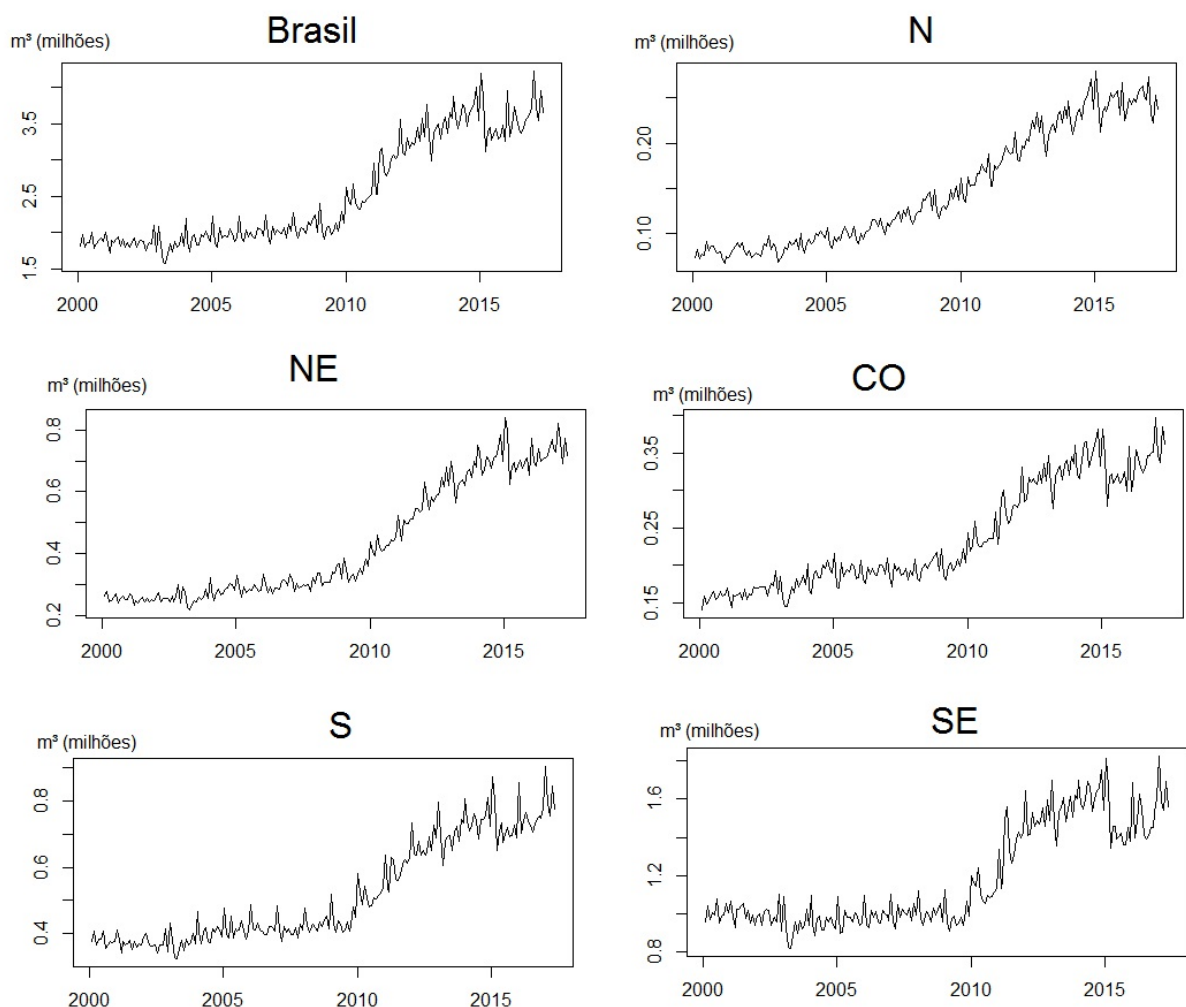


Figura 12 – Comportamento da demanda (consumo) de gasolina tipo C

Observa-se que no consumo além do decréscimo em 2015, há também um leve elemento sazonal. É possível que tal sazonalidade esteja relacionada à presença de etanol, que depende da safra. Quando há um maior teor de etanol (safra), é necessário um maior volume de gasolina para percorrer a mesma distância. O contrário ocorre na intersafra, gerando o comportamento sazonal.

Tabela 6 – Análise melhor método para Gasolina C (consumo)

Região	Brasil	N	NE	CO	S	SE
%Total	100	6	17	9	21	47
SE	4,8%	6,1%	5,0%	5,2%	5,0%	5,1%
Holt	5,5%	6,8%	5,5%	6,0%	6,0%	5,8%
Winters	3,7%	3,5%	3,7%	3,7%	3,8%	4,0%
Melhor Método	Winters	Winters	Winters	Winters	Winters	Winters

Os resultados mostram que a divisão por região mantém um erro próximo ao nacional. O fato de Winters ter sido o melhor método em todos os casos sugere que realmente há uma sazonalidade envolvida.

A figura 13 mostra como o comportamento da demanda se compara à previsão para os dados nacionais.




Figura 13 – Demanda real (preto) e previsão (vermelho) VS tempo para consumo nacional de Gasolina tipo C

O erro de 3,7% é observado graficamente a partir da figura 13. Somente em 2015 houve uma discrepância um pouco mais acentuada entre o real e o previsto. Previsões regionais possuem erro de mesma magnitude, mostrando que é possível realizar projeções por com uma granularidade maior quando se trata de consumo.

6.4.4 Querosene de Aviação

Segundo site da Petrobrás, o querosene de aviação, também conhecido pela sigla QAV-1, é o combustível utilizado em aviões e helicópteros dotados de motores à turbina, como jato-puro, turboélices ou turbo-fans. Aqui, além dos elementos nacionais, fatores internacionais podem influenciar no comportamento da demanda.

- **Produção de querosene de aviação**

Produção média período: 384.423 m³

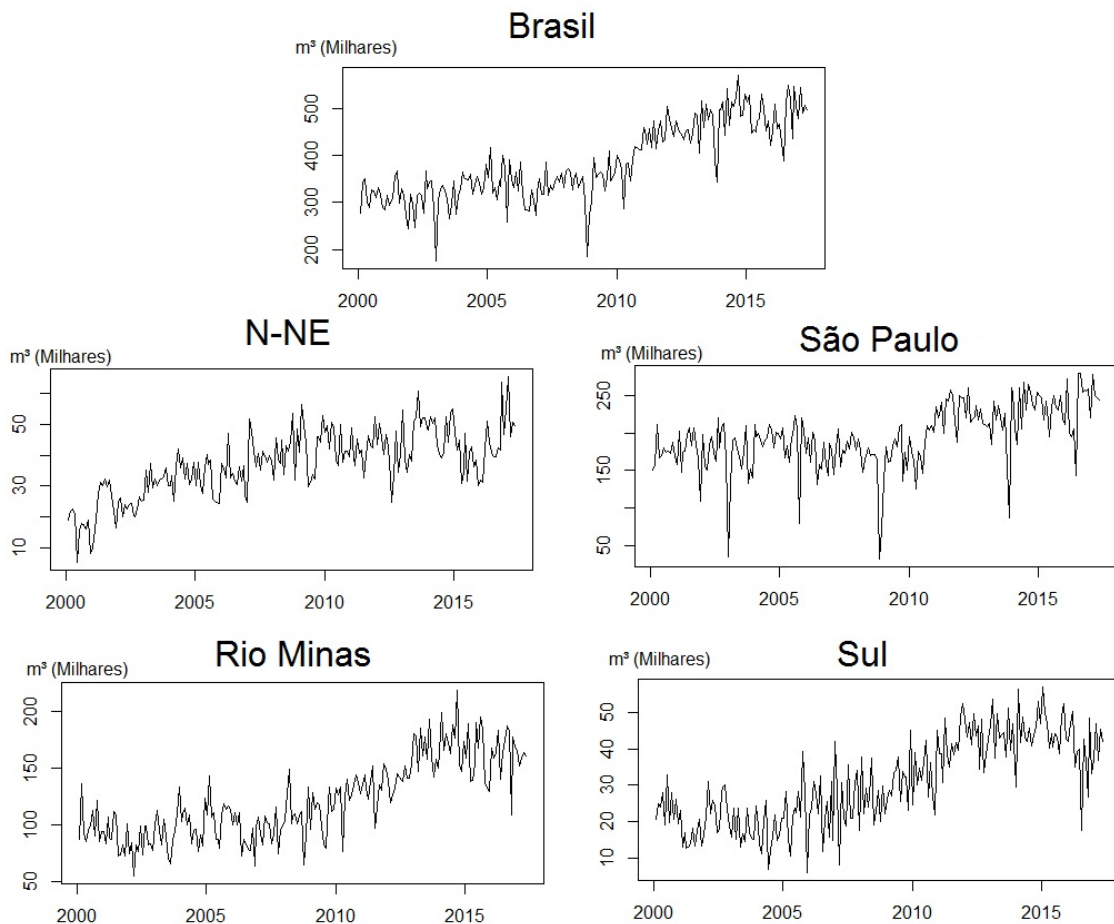


Figura 14 – Comportamento da demanda (produção) de querosene de aviação

A produção de querosene de aviação é bem aleatória. Em São Paulo, há presenças de vales em 2004, 2009 e 2014 que inclusive tiveram efeito na produção nacional. Uma possível razão para isso ocorrer é parada programada de refinaria.

Tal fator pode ser facilmente levado em consideração nas previsões, mas não é capturado tão bem pelas análises de séries temporais. O resultado de tais análises é descrito na tabela 7.

Tabela 7 – Análise melhor método para Querosene de Aviação (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	10	51	32	8
SE	8,3%	15,6%	16,6%	12,8%	23,1%
Holt	9,8%	17,2%	17,3%	16,1%	25,6%
Winters	8,6%	16,0%	17,6%	13,8%	24,3%
Melhor Método	SE	SE	SE	SE	SE

Suavização exponencial foi o melhor método em todas as ocasiões. Utilizar dados externos de parada programada pode diminuir o elevado erro tanto de dados regionais quanto nacionais. Para a visão nacional, a demanda é seguida de forma satisfatória pela previsão com exceção dos vales causados por São Paulo como mostra a figura abaixo.




Figura 15 – Demanda real (preto) e previsão (vermelho) VS tempo para produção nacional de Querosene de Aviação

Caso SE seja escolhida, é recomendado que se elabore um plano de contingência para lidar com o possível surgimento de vales. Um possível plano de contingência é buscar o mercado internacional caso haja produção em excesso (mesmo que a margem seja menor).

Analisando o comportamento da previsão diante dos vales, percebe-se

que após eles, a previsão se mantém menor que a demanda real durante certo período. Desta forma produzir-se-ia menos do que o necessário, escoando o estoque gerado no vale.

- **Consumo de querosene de aviação**

Consumo médio período: 469.742 m³

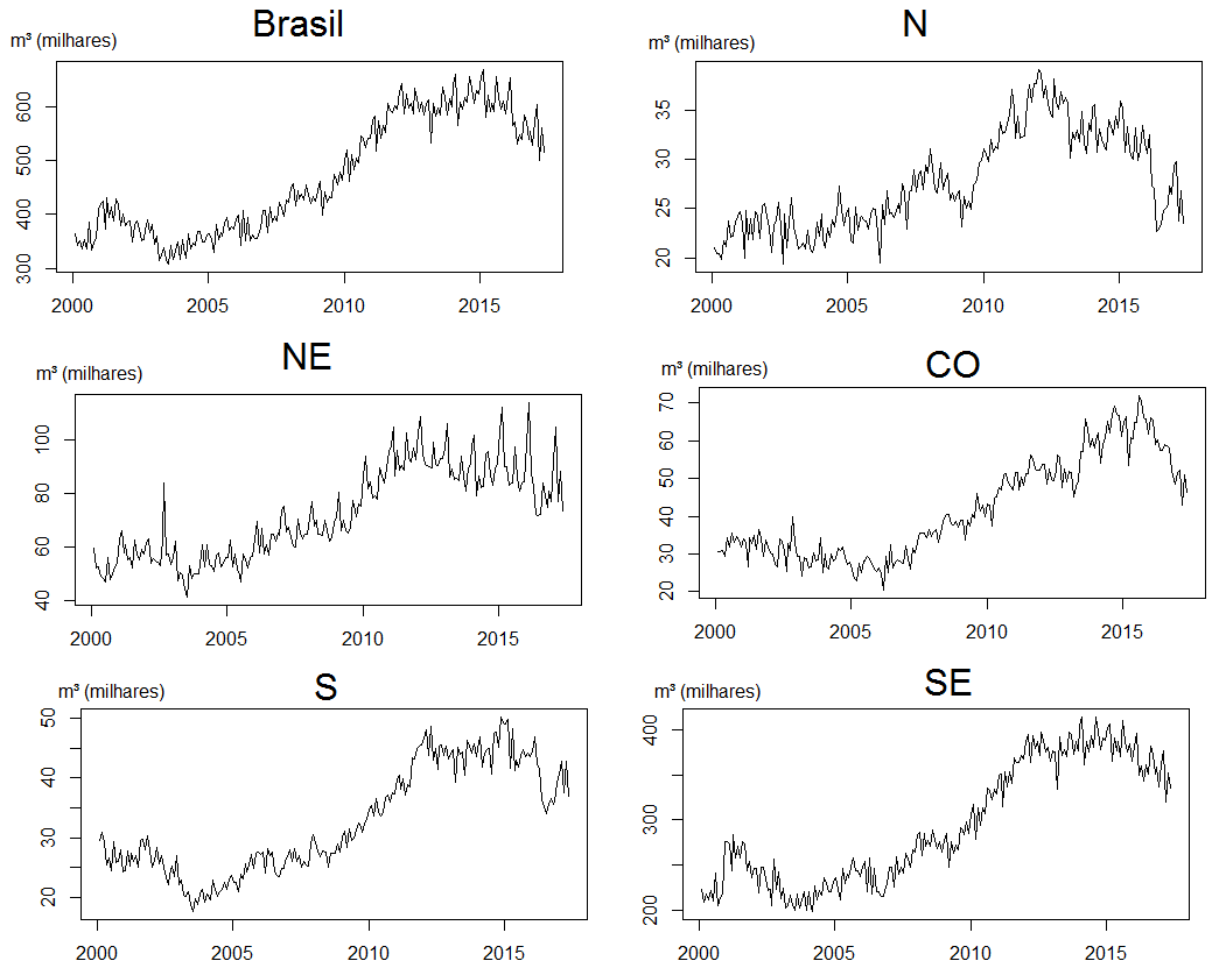


Figura 16 – Comportamento da demanda (consumo) de querosene de aviação

Comparando os dados de consumo com o de produção (figura 14), percebe-se que a aleatoriedade é bem menor. Tal fato é observado na tabela 8, onde os erros encontrados também são menores em todos os casos.

Tabela 8 – Análise melhor método para Querosene de Aviação (consumo)

Região	Brasil	N	NE	CO	S	SE
%Total	100	6	15	9	7	63
SE	4,4%	5,5%	7,6%	6,4%	5,3%	4,5%
Holt	4,6%	5,7%	8,2%	6,4%	5,5%	4,7%
Winters	3,1%	4,3%	4,3%	4,9%	4,7%	3,4%
Melhor Método	Winters	Winters	Winters	Winters	Winters	Winters

6.4.5 GLP

O Gás Liquefeito de Petróleo (GLP) é uma fração leve do petróleo que é gasosa na pressão atmosférica, mas armazenado na forma líquida.

Sua principal utilização é na cocção de alimentos, mas devido a sua queima limpa ele também é utilizado industrialmente na fabricação de vidros, cerâmicas e alimentos.

- **Produção de GLP**

Produção média período: 656.210 m³

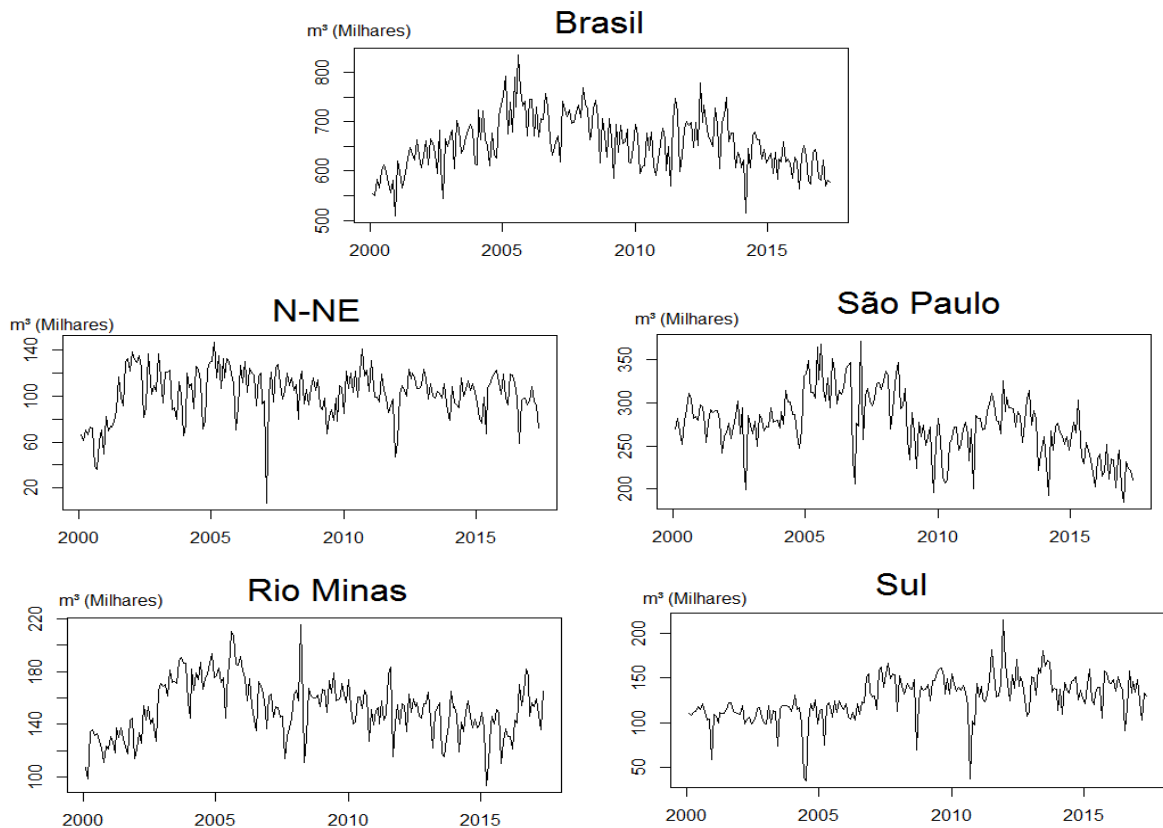


Figura 17 – Comportamento da demanda (produção) de GLP

A figura 17 conclui que a produção de GLP é aleatória e sem forte componente de tendência. Entretanto é observada uma tendência decrescente nos últimos anos para São Paulo, que teve leve efeito no comportamento nacional. A tabela 9 mostra que, com exceção das refinarias no sul e N-NE, é possível realizar uma boa previsão.

Tabela 9 – Análise melhor método para GLP (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	16	42	23	19
SE	5,2%	21,0%	7,5%	8,2%	13,2%
Holt	5,3%	21,3%	8,1%	8,7%	13,3%
Winters	4,8%	23,3%	7,4%	7,8%	14,2%
Melhor Método	Winters	SE	Winters	SE	SE

- **Consumo de GLP**

Consumo médio período: 1.041.044 m³

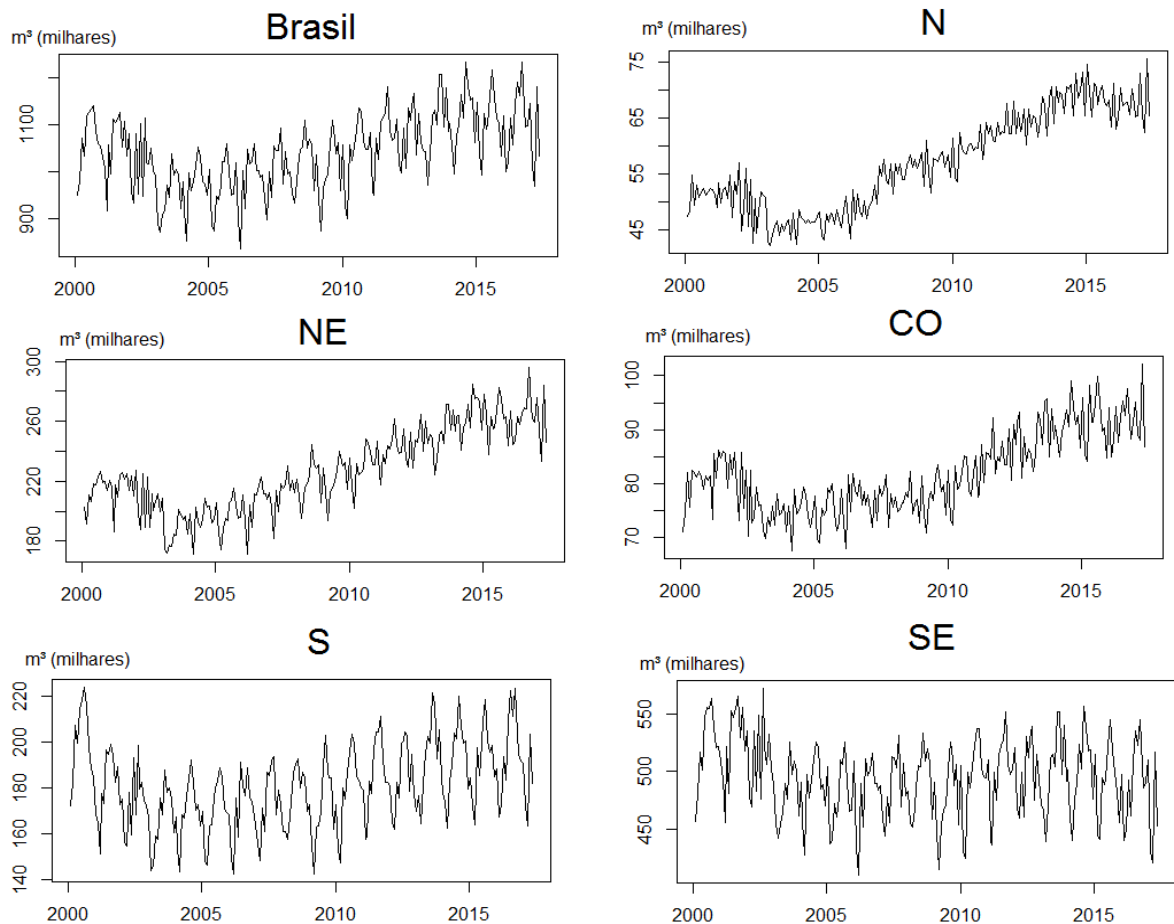


Figura 18 – Comportamento da demanda (consumo) de GLP

Primeiramente é importante observar que a quantidade consumida é bem maior que a produzida, mostrando que há bastante importação desse derivado. Analisando o comportamento do consumo fica muito clara a presença de sazonalidade nas regiões sul e sudeste e um pouco menos clara na região nordeste. Uma hipótese para essa sazonalidade é que em meses frios há uma maior utilização de aquecedores a gás. Nesse período a temperatura da água é menor, necessitando uma maior quantidade de gás para aquecê-la até a temperatura ideal. Para testar essa hipótese, foi criado um gráfico semelhante ao gráfico 1 para o GLP somente nas regiões sul e sudeste.




Gráfico 3 Consumo de GLP regiões sul e sudeste

Não é percebida uma diferença tão forte quanto no caso do Asfalto onde no período sazonal a produção é mais de 15% maior que a média, mas ainda assim é possível observar um comportamento sazonal.

Nos meses de junho a setembro que é o inverno no Brasil, é onde se observa o maior consumo de GLP, superando a média em mais de 5%. Na fronteira desses meses a média também é superada, mas com margem menor.

Uma possível explicação para os meses de janeiro e fevereiro possuírem um consumo tão baixo é de que pessoas que moram em regiões frias viajam para lugares onde é quente o ano inteiro.

A tabela 10 representa o resultado dos métodos para o consumo de GLP.

Tabela 10 – Análise melhor método para GLP (consumo)

Região	Brasil	N	NE	CO	S	SE
%Total	100	5	22	8	17	48
SE	5,1%	4,1%	4,7%	4,2%	6,1%	5,5%
Holt	5,3%	4,2%	5,2%	4,6%	6,4%	5,7%
Winters	2,7%	3,2%	2,7%	3,0%	3,4%	2,8%
Melhor Método	Winters	Winters	Winters	Winters	Winters	Winters

Aparentemente a importação é realizada de forma a sistematizar a demanda, pois o erro de consumo é bem menor que o de produção.

6.4.6 Nafta

Produção média período: 620.519 m³

A Nafta é um derivado utilizado principalmente na indústria petroquímica para produção de eteno, propeno, benzeno, tolueno e xilenos.




Figura 19 – Comportamento da demanda (produção) de Nafta

Percebe-se uma tendência decrescente na produção nacional de Nafta puxado por São Paulo e Sul principalmente. Até 2002 a Petrobrás era a única responsável por abastecer o mercado nacional de Nafta, a quebra desse monopólio pode ter sido a razão pela qual a produção vem caindo desde então, pois as petroquímicas agora importam tal produto. A tabela 11 apresenta os erros por método para Nafta.

Tabela 11 – Análise melhor método para Nafta (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	32	27	24	18
SE	10,0%	13,4%	210%	20,3%	90,0%
Holt	10,2%	13,6%	159%	20,2%	84,9%
Winters	11,3%	15,6%	313%	17,0%	97,0%
Melhor Método	SE	SE	Holt	Winters	Holt

Mais uma vez dados nacionais mostram-se mais sistemáticos que os regionais. Este alto erro em São Paulo ocorre por que a previsão nunca acerta com exatidão a demanda real, estando sempre acima ou abaixo da mesma. Isso pode ser observado na figura 20.




Figura 20 – Demanda real (preto) e previsão (vermelho) VS tempo para Nafta (São Paulo)

No começo da série histórica a adesão das curvas foi pequena devido à ausência de dados, mas após isso os formatos se assemelham. É possível observar que sempre que há decrescimento a previsão é maior que a demanda real e o contrário ocorre para o crescimento.

6.4.7 Óleo Combustível

O óleo combustível é um derivado do petróleo obtido no processo de refino. De acordo com os processos e misturas que passa nas refinarias, ele apresenta uma diversidade de tipos que atendem as mais variadas exigências do mercado. O produto é utilizado pela indústria para aquecimento de caldeiras e fornos, ou em motores de combustão interna para geração de calor.

- **Produção de óleo combustível**

Produção média período: 1.241.568 m³

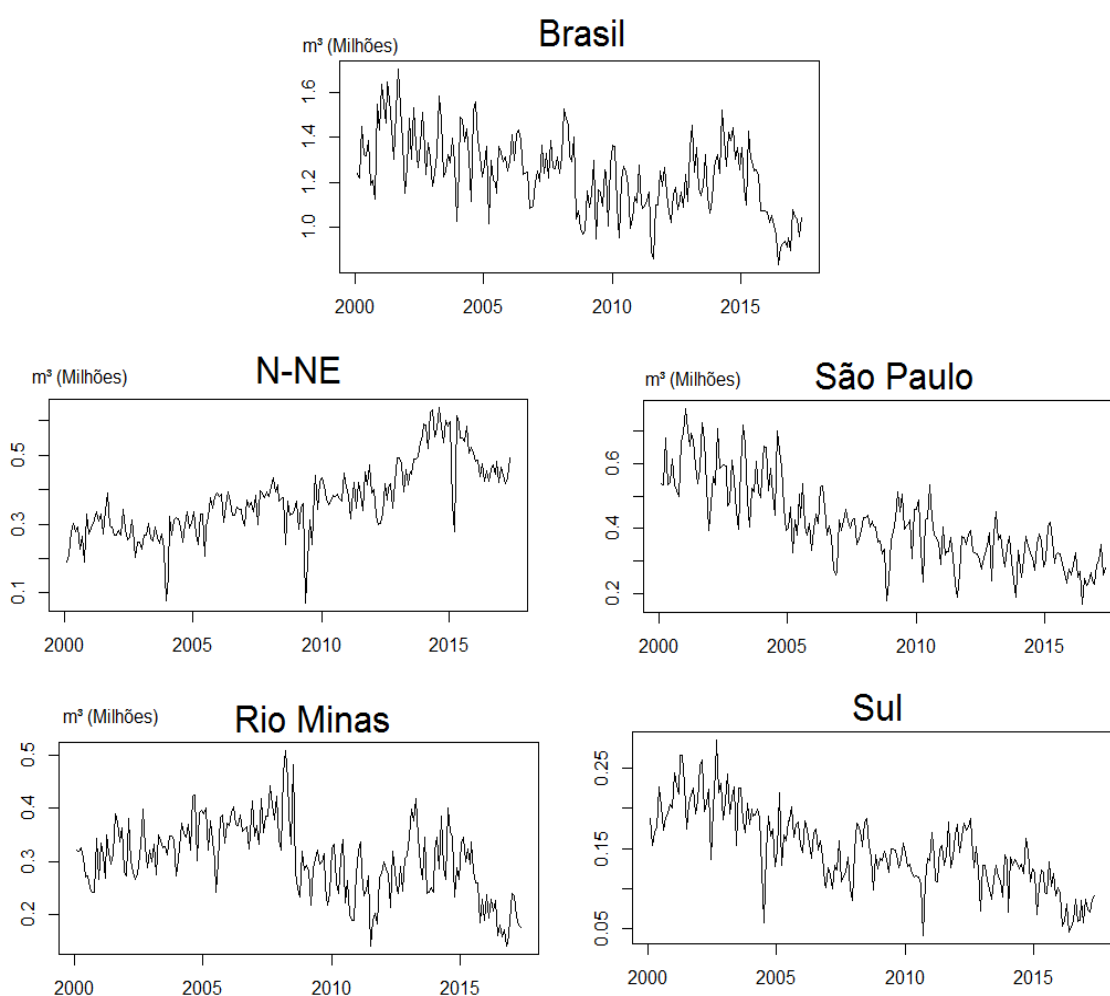


Figura 21 – Comportamento da demanda (produção) de Óleo Combustível

Observa-se que mesmo com o aumento da produção no N-NE houve uma queda acentuada nacionalmente nos últimos anos puxada pelas outras regiões. Como esse é um derivado exportado (produção maior que consumo), os motivos

dessa queda são variados, indo desde a perda de competitividade ou desaquecimento do mercado internacional à escassez de petróleos que favoreçam esse corte de destilação.

A tabela 12, a seguir, mostra que o modelo de Holt captura bem a tendência de decrescimento na maioria dos casos.

Tabela 12 – Análise melhor método para Óleo Combustível (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	30	33	25	12
SE	8,1%	13,8%	14,8%	13,5%	16,7%
Holt	8,1%	14,4%	14,5%	13,3%	18,2%
Winters	8,8%	15,0%	16,1%	13,6%	18,8%
Melhor Método	SE ou Holt	SE	Holt	Holt	SE

- **Consumo de óleo combustível**

Consumo médio período: 467.885 m³

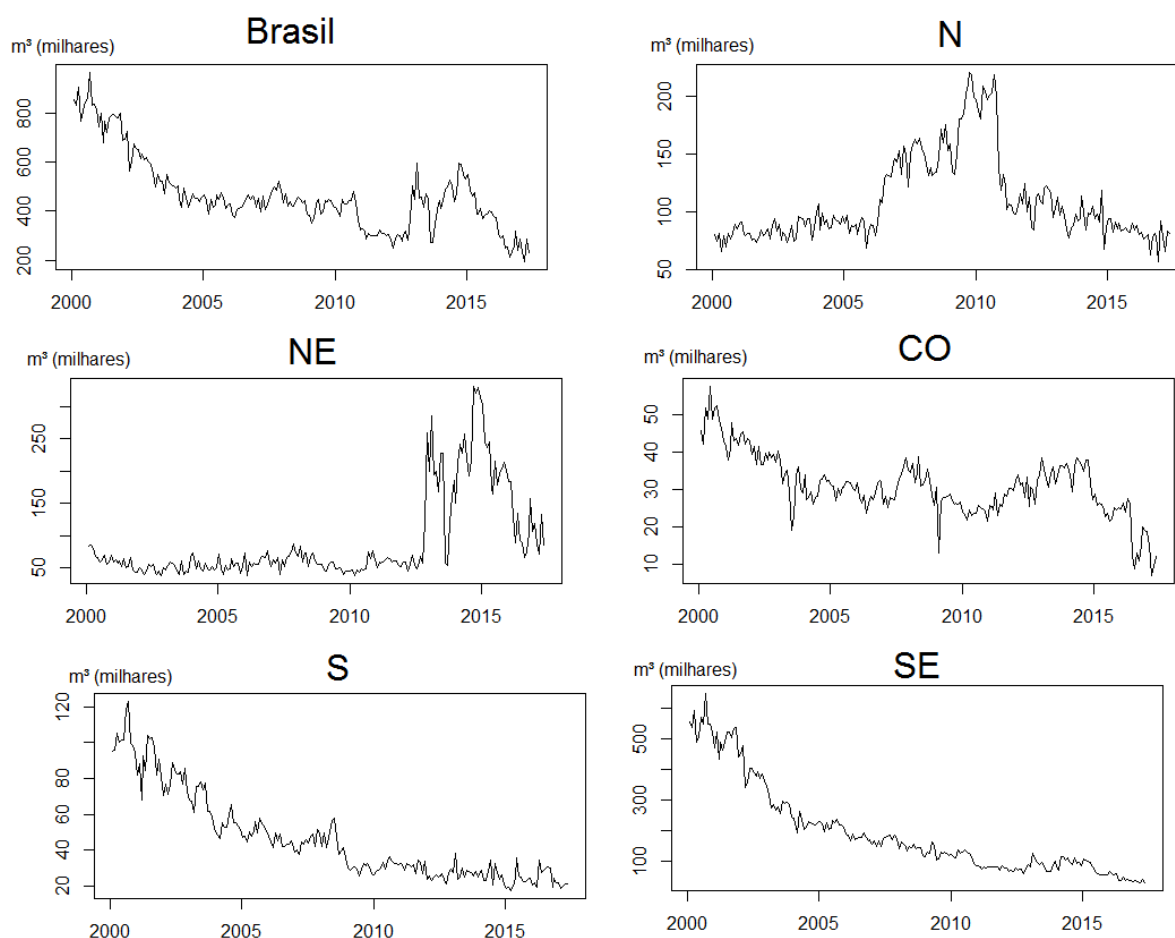


Figura 22 – Comportamento da demanda (consumo) de Óleo Combustível

A figura 22 sugere que a queda na produção de óleo combustível pode ter sido causada pelo desaquecimento do mercado nacional. Sudeste e Sul apresentam uma queda consistente desde o início do período histórico, as outras regiões tiveram quedas mais acentuadas nos anos mais recentes.

Os erros de consumo possuem magnitude similar aos de produção como pode ser observado na tabela 13.

Tabela 13 – Análise melhor método para Óleo Combustível (consumo)

Região	Brasil	N	NE	CO	S	SE
%Tot	100	23	19	7	10	41
SE	7,5%	8,6%	17,4%	10,1%	9,7%	9,1%
Holt	7,7%	9,0%	18,3%	10,3%	9,8%	9,0%
Winters	7,7%	8,4%	19,2%	11,5%	10,9%	11,9%
Melhor método	SE	Winters	SE	SE	SE	Holt

6.4.8 Óleo Diesel

O óleo Diesel, em suas diversas denominações, é o principal combustível comercializado no mercado brasileiro, utilizado no transporte de cargas e de passageiros, em embarcações, na indústria, na geração de energia, nas máquinas para construção civil, nas máquinas agrícolas e locomotivas, atendendo as necessidades dos consumidores e as mais avançadas tecnologias em motores e combustão.

Os dados mostrados a seguir não fazem distinção quanto ao teor de enxofre encontrado no derivado, que pode ser mais elevado se comercializado em zona rural.

Outro fator importante de ser mencionado é que há uma parcela de biodiesel adicionada ao diesel, assim como há etanol na gasolina. Entretanto essa proporção não é tão alta, sendo somente 8%, mas podendo gradualmente alcançar 15% nos anos futuros.

Assim como o etanol, o biodiesel depende da safra para ser produzido, podendo ser extraído de mamona, dendê, girassol, babaçu, amendoim, pinhão manso e soja. Sendo o último a principal fonte.

- **Produção de óleo diesel**

Produção média período: 3.411.414 m³

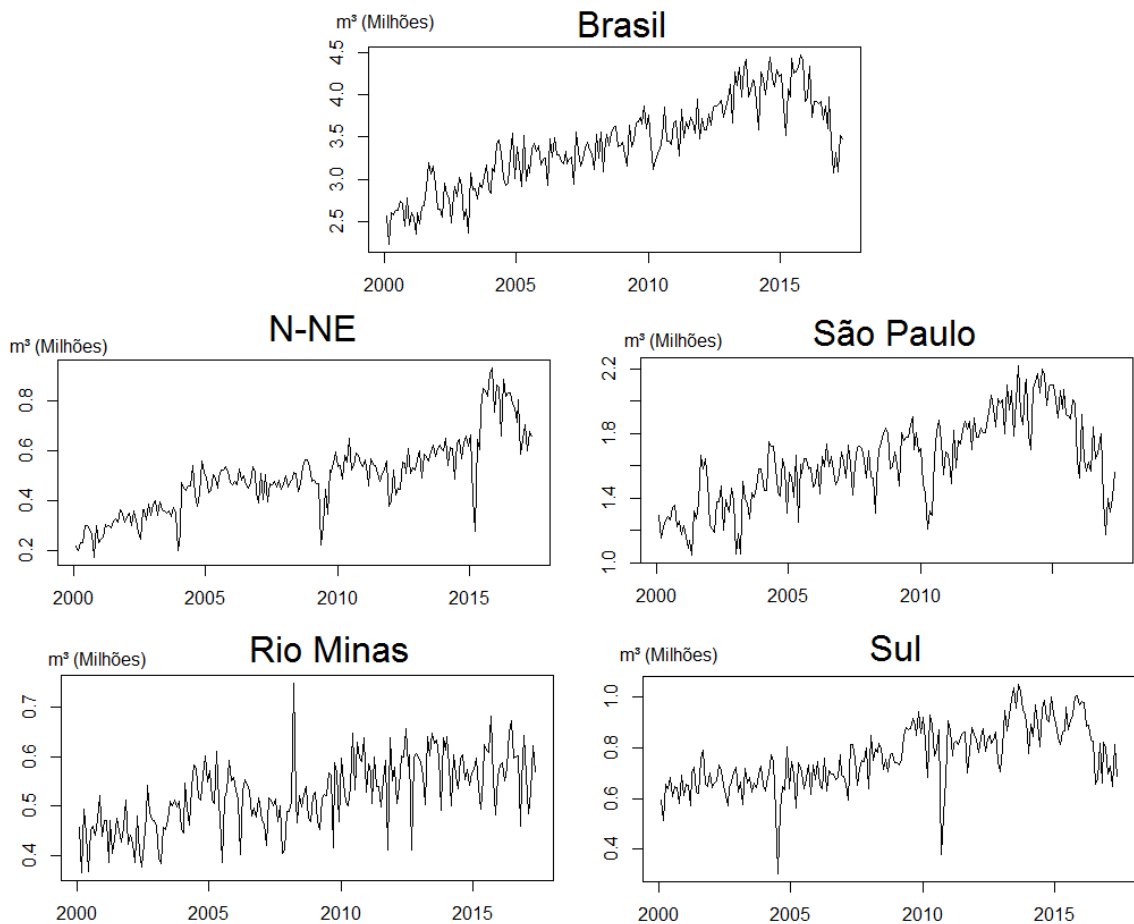


Figura 23 – Comportamento da demanda (produção) de Óleo Diesel

O diesel sofreu uma forte queda na produção em 2015 (exceção de Rio Minas), provavelmente devido à crise econômica. Excluindo alguns picos e vales nas produções regionais, o comportamento da curva não é tão aleatório. A tabela 14 mostra isso, onde somente N-NE teve um erro alto.

Tabela 14 – Análise melhor método para Óleo Diesel (produção)

Região	Brasil	N-NE	SP	Rio Minas	Sul
%Total	100	15	48	15	22
SE	5,2%	10,7%	7,3%	8,1%	8,6%
Holt	5,9%	14,4%	7,8%	10,1%	9,6%
Winters	4,4%	15,0%	6,9%	7,6%	8,3%
Melhor Método	Winters	SE	Winters	Winters	Winters

- **Consumo de óleo diesel**

Consumo médio período: 3.842.342 m³

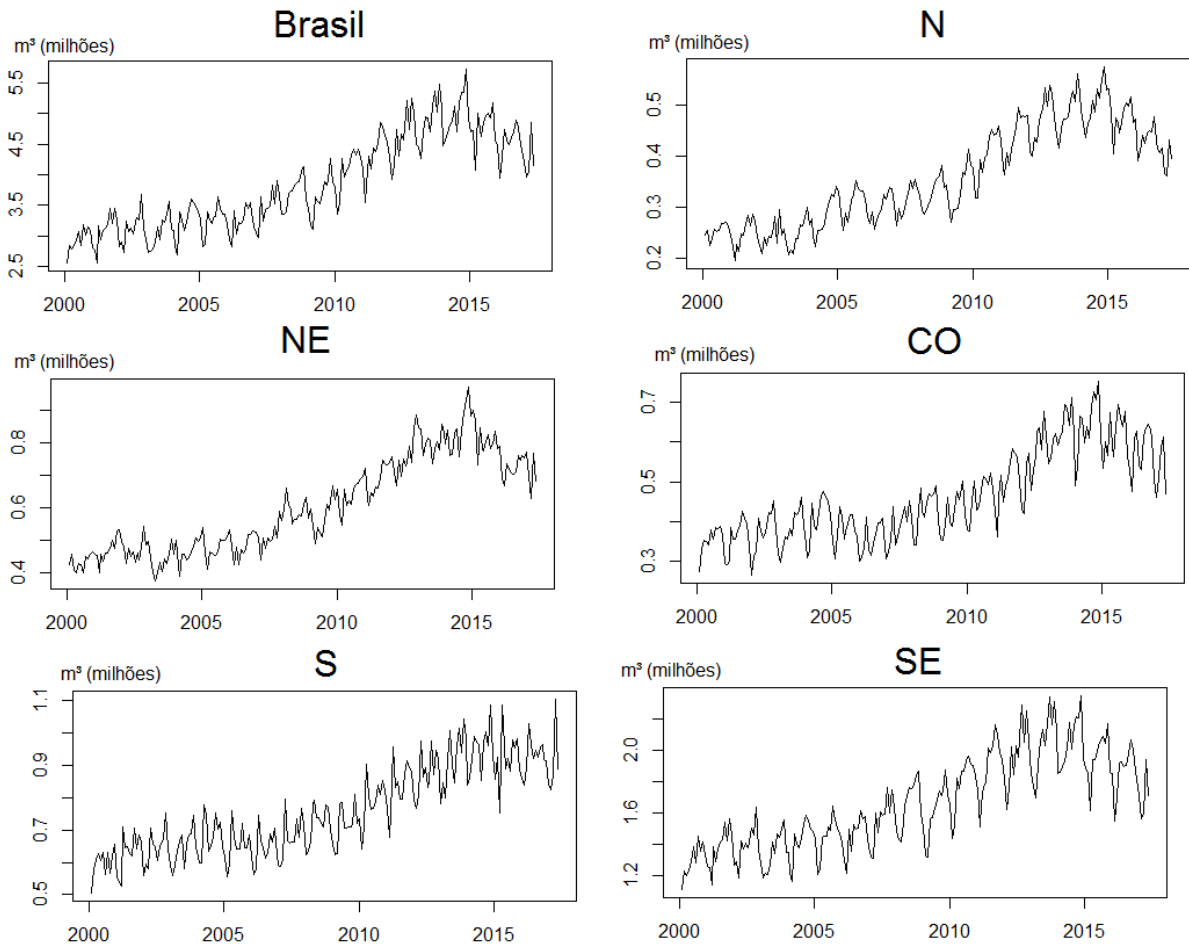


Figura 24 – Comportamento da demanda (produção) de Óleo Diesel

Como o consumo é levemente maior que a produção, supõe-se que importação e adição de biodiesel sejam marginais. Além da queda em 2015, observa-se também um comportamento sazonal para o consumo. O gráfico 4 representa o mesmo procedimento que foi realizado para Asfalto e GLP.




Gráfico 4 Produção mensal média de óleo Diesel (Brasil)

O comportamento do Diesel é mais similar com o GLP do que com o Asfalto, há uma sazonalidade, mas não tão acentuada. O pico sazonal ocorre entre agosto e novembro.

A tabela 15 indica que Winters foi o melhor método para todos os casos com uma diferença considerável para o segundo melhor método. Isso corrobora ainda mais para a presença de sazonalidade.

Tabela 15 – Análise melhor método para Óleo Diesel (Consumo)

Região	Brasil	N	NE	CO	S	SE
%Total	100	9	16	12	20	43
SE	5,9%	6,5%	5,4%	9,2%	6,9%	6,3%
Holt	6,3%	6,6%	5,9%	9,9%	7,8%	6,7%
Winters	3,2%	3,7%	3,9%	4,5%	4,0%	3,6%
Melhor Método	Winters	Winters	Winters	Winters	Winters	Winters

6.4.9 Etanol Hidratado

Consumo médio período: 800.037 m³

O etanol é uma substância química com fórmula molecular C₂H₆O, produzida especialmente via fermentação de açúcares. É um biocombustível utilizado em motores de combustão interna com ignição por centelha (Ciclo Otto) em substituição especialmente à gasolina e em contraponto a outros combustíveis fósseis.

O Brasil é pioneiro na utilização em larga escala de etanol combustível desde o fim da década de 1970. Atualmente, é um dos que mais utilizam o produto e ainda o segundo maior produtor mundial.

O etanol pode ser anidro (utilizado como aditivo em gasolina) ou hidratado (utilizado como combustível). O segundo é o que será analisado neste tópico.

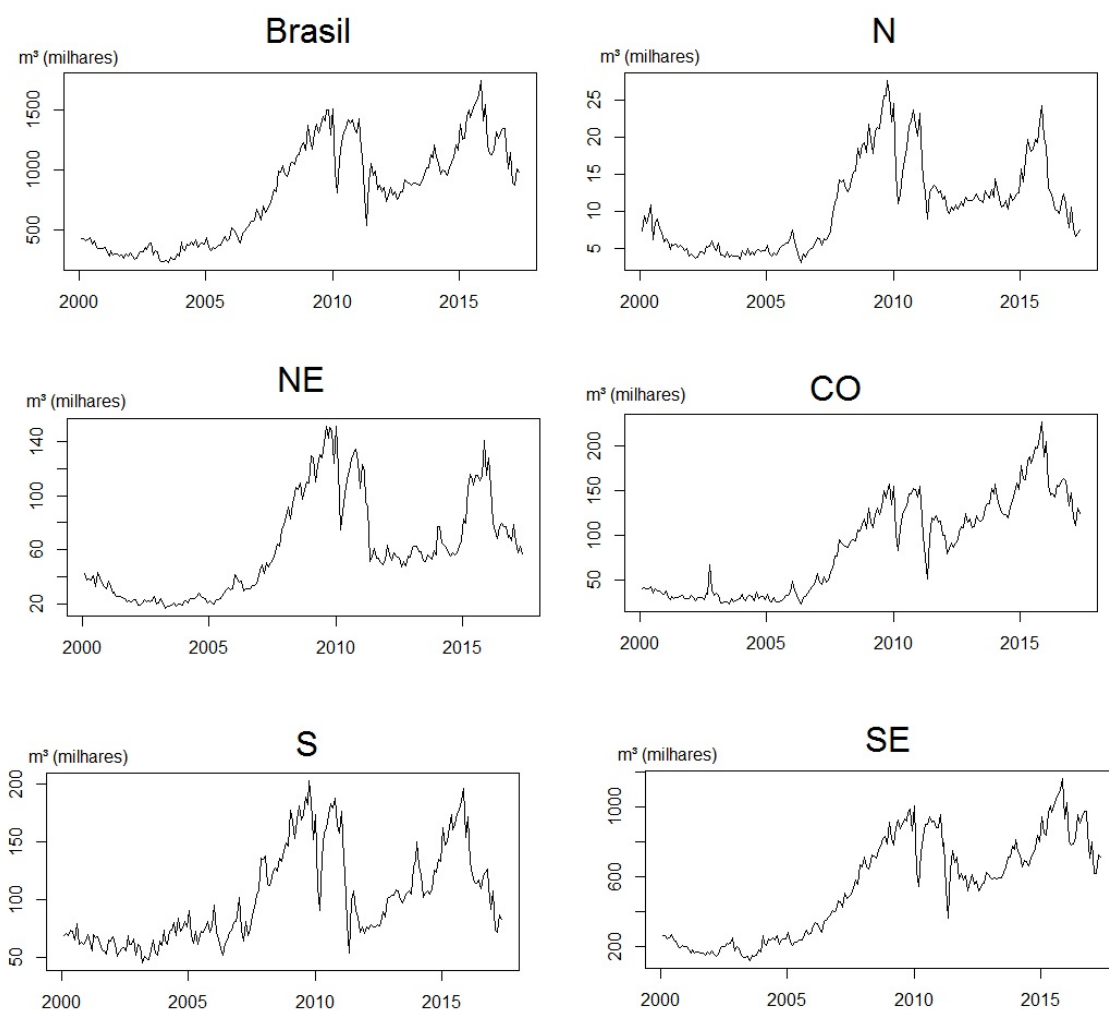


Figura 25 – Comportamento da demanda (consumo) de Etanol Hidratado

Houve crescimento acentuado em 2006, queda e estabilização em 2011 e pico seguido de queda em 2015. Tais fatos dificilmente estão relacionados com a safra de cana de açúcar devido ao seu alto espaçamento. Uma razão mais plausível seria a competitividade com a gasolina.

A Tabela 16 mostra que o erro foi um pouco mais acentuado comparado com outros dados de consumo e que Winters foi o melhor método no geral.

Tabela 16 – Análise melhor método para Etanol Hidratado (Consumo)

Região	Brasil	N	NE	CO	S	SE
%Total	100	1	8	11	13	67
SE	8,1%	10,9%	8,9%	9,8%	10,3%	8,3%
Holt	8,2%	11,6%	9,5%	10,1%	10,4%	8,4%
Winters	7,4%	10,2%	9,5%	8,6%	9,7%	7,9%
Melhor Método	Winters	Winters	SE	Winters	Winters	Winters

6.5 Resumo de resultados

Para consolidar toda a informação contida na seção 6.4, foi criada a tabela 17. A legenda significa:

- Verde: Melhor método
- Amarelo: Possui erro até 2 pontos percentuais maior que o melhor método
- Vermelho: Possui erro superior a 2 pontos percentuais do melhor método

Tabela 17 – Erro de previsão por método por derivado

Derivado	Produção (Brasil)			Consumo (Brasil)		
	SE	Holt	Winters	SE	Holt	Winters
Asfalto	15,3%	16,3%	12,3%	-	-	-
Coque	8,1%	8,5%	8,6%	-	-	-
Gasolina	4,9%	5,4%	4,6%	4,8%	5,5%	3,7%
Querosene de Aviação	8,3%	9,8%	8,6%	4,4%	4,6%	3,1%
GLP	5,2%	5,3%	4,8%	5,1%	5,3%	2,7%
Nafta	10,0%	10,2%	11,3%	-	-	-
Óleo Combustível	8,1%	8,1%	8,8%	7,5%	7,7%	7,7%
Óleo Diesel	5,2%	5,9%	4,4%	5,9%	6,3%	3,2%
Etanol Hidratado	-	-	-	8,1%	8,2%	7,4%

A tabela 17 indica que Winters e SE são os melhores métodos para produção e Winters é o melhor método para consumo. Entretanto Holt fica, no geral, pouco atrás do melhor método.

7 CONCLUSÃO

7.1 Erros de produção e consumo por derivado

Em todos os casos comparáveis o erro de consumo é menor do que o de produção. Com isso conclui-se que as refinarias possuem certa aleatoriedade de produção que não é causada por variações de comportamento do consumidor final, já que tal comportamento é sistemático.

7.2 Melhores métodos

Quanto aos métodos testados, Suavização Exponencial e Winters demonstraram ser os mais precisos. Entretanto, para a maioria dos casos, é recomendado utilizar SE já que Winters deve ser utilizado somente quando se conhece a causa da sazonalidade (Asfalto e GLP, por exemplo).

7.3 Segmentação da demanda

A segmentação foi realizada diferentemente para produção e consumo. Os resultados também foram distintos.

7.3.1 Produção

As projeções nacionais tiveram uma precisão sempre maior do que as regionais. Isso gera uma dificuldade, pois embora se saiba com certa precisão qual será a produção do país no mês seguinte, não se sabe quanto ficará para cada região.

7.3.2 Consumo

Os erros de previsão de consumo nacional e regional tiveram pouca diferença. Com isso as distribuidoras não possuem a mesma dificuldade que as refinarias nesse aspecto. Os métodos apresentados neste trabalho poderiam ser utilizados por distribuidoras para predição de demanda de curto prazo.

7.4 Próximos trabalhos

Durante o trabalho foram levantadas várias hipóteses que não foram testadas. As mais relevantes para próximos trabalhos seria verificar a relação entre precipitação/eleições e produção de asfalto e temperatura e consumo de GLP. Caso tais relações sejam confirmadas e quantificadas, é possível utilizá-las como ferramenta auxiliar na predição desses derivados.

REFERÊNCIAS

1. Magalhães, M.V.O., Moro, L.F.L., Smania, P., Hassimotto, M.K., Pinto, J.M. and Abadia, G.J. (1998) SIPP – a solution for refinery scheduling. Em: 1998 **NPRA Computer Conference, National Petroleum Refiners' Association**, 16 – 18 de Novembro, San Antonio.
2. Werner, L., Ribeiro J., **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais**. 2003, Rio Grande do Sul.
3. Zhao, X., Xie, J., & Leung, J. (2002). The impact of forecasting model selection on the value of information sharing in a supply chain, **European Journal of Operational Research**, **142**, 321-344.
4. PETROBRAS, Produção nacional de gasolina: Resposta ao Valor Econômico. 2015. Disponível em: <<http://www.petrobras.com.br/fatos-e-dados/producao-nacional-de-gasolina-resposta-ao-valor-economico.htm>> Acessado em: <07/06/2017>
5. GIRARD, Mário Hermínio, Apuração de custos em uma refinaria de petróleo: um caso simulado. 2007 137p. Dissertação (mestrado em Ciências Contábeis) pelo programa multi-institucional UnB/UFPE/UFPB/UFRN. Recife, 2007
6. BALLOU, R. H. **Gerenciamento da cadeia de suprimentos / logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.
7. BERTAGLIA, P. R. **Logística e gerenciamento da cadeia de abastecimento**. 2.ed. São Paulo: Saraiva, 2009.
8. Chopra, S. **Gestão da cadeia de suprimentos: Estratégia, planejamento e operações**. 4. Ed. São Paulo: Pearson, 2010.

9. Bowersox, D. J., Closs, D. J., **Logística empresarial: O processo de integração da cadeia de suprimento**. São Paulo: Atlas, 2011.
10. CAMARGO, M., KOBAYOSHI, M., CARVALHO, M. **Produção de coque de petróleo e sua estratégia de negociação**. Bauru, SP. 2006

ANEXO A – CÓDIGO UTILIZADO NO R

```
#####
```

```
#
```

```
# Previsão de demanda de derivados de Petróleo
```

```
#
```

```
#####
```

```
#Passo 1: Importando dados
```

```
producao_derivados <- read.csv(file.choose(),header = T,sep = ";")
```

```
consumo_derivados <- read.csv(file.choose(),header = T,sep = ";")
```

```
#Passo 2: Checando importação
```

```
View(producao_derivados)
```

```
View(consumo_derivados)
```

```
#Passo 3: Transformando os dados em séries temporais
```

```
#3.1 Produção
```

```
Prod_Asfalto <- ts(producao_derivados$ASFALTO,start = c(2000.1),frequency = 12)
```

```
Prod_Coque <- ts(producao_derivados$COQUE,start = c(2000.1),frequency = 12)
```

```
Prod_Gasolina_A <- ts(producao_derivados$GASOLINA,start = c(2000.1),frequency = 12)
```

```
Prod_Gasolina_Aviacao <- ts(producao_derivados$GASOLINA_AVIACAO,start = c(2000.1),frequency = 12)
```

```
Prod_GLP <- ts(producao_derivados$GLP,start = c(2000.1),frequency = 12)
```

```
Prod_Lubrificante <- ts(producao_derivados$LUBRIFICANTE,start = c(2000.1),frequency = 12)
```

```
Prod_Nafta <- ts(producao_derivados$NAFTA,start = c(2000.1),frequency = 12)
```

```
Prod_Oleo_Combustivel <- ts(producao_derivados$OLEO_COMBUSTIVEL,start = c(2000.1),frequency = 12)
```

```
Prod_Oleo_Diesel <- ts(producao_derivados$OLEO_DIESEL,start = c(2000.1),frequency = 12)
```

```
Prod_Outros_Energeticos <- ts(producao_derivados$OUTROS_ENERGETICOS,start = c(2000.1),frequency = 12)
```

```
Prod_Outros_Nao_Energeticos <- ts(producao_derivados$OUTROS_NAO_ENERGETICOS,start = c(2000.1),frequency = 12)
```

```
Prod_Parafina <- ts(producao_derivados$PARAFINA,start = c(2000.1),frequency = 12)
```

```
Prod_Querosene_Aviacao <- ts(producao_derivados$QUEROSENE_AVIACAO,start = c(2000.1),frequency = 12)
```

```
Prod_Querosene_Iluminante <- ts(producao_derivados$QUEROSENE_ILUMINANTE,start = c(2000.1),frequency = 12)
```

```
Prod_Solvente <- ts(producao_derivados$SOLVENTE,start = c(2000.1),frequency = 12)
```

#3.2 Consumo

```
Consumo_Etanol_Hidratado <- ts(consumo_derivados$ETANOL_HIDRATADO,start = c(2000.1),frequency = 12)
Consumo_Gasolina_C <- ts(consumo_derivados$GASOLINA_C,start = c(2000.1),frequency = 12)
Consumo_Gasolina_Aviacao <- ts(consumo_derivados$GASOLINA_DE_AVIACAO,start = c(2000.1),frequency = 12)
Consumo_GLP <- ts(consumo_derivados$GLP,start = c(2000.1),frequency = 12)
Consumo_Querosene_Aviacao <- ts(consumo_derivados$QUEROSENE_DE_AVIACAO,start = c(2000.1),frequency = 12)
Consumo_Querosene_Iluminante <- ts(consumo_derivados$QUEROSENE_ILUMINANTE,start = c(2000.1),frequency = 12)
Consumo_Oleo_Combustivel <- ts(consumo_derivados$OLEO_COMBUSTIVEL,start = c(2000.1),frequency = 12)
Consumo_Oleo_Diesel <- ts(consumo_derivados$OLEO_DIESEL,start = c(2000.1),frequency = 12)
```

#Passo 4: Plotando o comportamento da demanda

#4.1 Produção

```
plot.ts(Prod_Asfalto/1000,axes = T)
plot.ts(Prod_Coque/1000,axes = T)
plot.ts(Prod_Gasolina_A/1000000,axes = T)
plot.ts(Prod_Gasolina_Aviacao,axes = F)
plot.ts(Prod_GLP/1000,axes = T)
plot.ts(Prod_Lubrificante,axes = F)
plot.ts(Prod_Nafta/1000,axes = T)
plot.ts(Prod_Oleo_Combustivel/1000000,axes = T)
plot.ts(Prod_Oleo_Diesel/1000000,axes = T)
plot.ts(Prod_Outros_Energeticos,axes = F)
plot.ts(Prod_Outros_Nao_Energeticos,axes = F)
plot.ts(Prod_Parafina,axes = F)
plot.ts(Prod_Querosene_Aviacao/1000,axes = T)
plot.ts(Prod_Querosene_Iluminante,axes = F)
plot.ts(Prod_Solvente,axes = F)
```

#4.2 Consumo

```
plot.ts(Consumo_Etanol_Hidratado/1000,axes = T)
plot.ts(Consumo_Gasolina_C/1000000,axes = T)
plot.ts(Consumo_Gasolina_Aviacao,axes = F)
```

```
plot.ts(Consumo_GLP/1000,axes = T)
```

```
plot.ts(Consumo_Querosene_Aviacao/1000,axes = T)
```

```
plot.ts(Consumo_Querosene_Iluminante,axes = F)
```

```
plot.ts(Consumo_Oleo_Combustivel/1000,axes = T)
```

```
plot.ts(Consumo_Oleo_Diesel/1000000,axes = T)
```

```
#Passo 5: Suavização exponencial simples
```

#5.1 Produção

```
Prod_SE_Asfalto <- HoltWinters(Prod_Asfalto,beta = F,gamma = F)
```

```
Prod_SE_Coque <- HoltWinters(Prod_Coque,beta = F,gamma = F)
```

```
Prod_SE_Gasolina_A <- HoltWinters(Prod_Gasolina_A,beta = F,gamma = F)
```

```
Prod_SE_Gasolina_Aviacao <- HoltWinters(Prod_Gasolina_Aviacao,beta = F,gamma = F)
```

```
Prod_SE_GLP <- HoltWinters(Prod_GLP,beta = F,gamma = F)
```

```
Prod_SE_Lubrificante <- HoltWinters(Prod_Lubrificante,beta = F,gamma = F)
```

```
Prod_SE_Nafta <- HoltWinters(Prod_Nafta,beta = F,gamma = F)
```

```
Prod_SE_Oleo_Combustivel <- HoltWinters(Prod_Oleo_Combustivel,beta = F,gamma = F)
```

```
Prod_SE_Oleo_Diesel <- HoltWinters(Prod_Oleo_Diesel,beta = F,gamma = F)
```

```
Prod_SE_Outros_Energeticos <- HoltWinters(Prod_Outros_Energeticos,beta = F,gamma = F)
```

```
Prod_SE_Outros_Nao_Energeticos <- HoltWinters(Prod_Outros_Nao_Energeticos,beta = F,gamma = F)
```

```
Prod_SE_Parafina <- HoltWinters(Prod_Parafina,beta = F,gamma = F)
```

```
Prod_SE_Querosene_Aviacao <- HoltWinters(Prod_Querosene_Aviacao,beta = F,gamma = F)
```

```
Prod_SE_Querosene_Iluminante <- HoltWinters(Prod_Querosene_Iluminante,beta = F,gamma = F)
```

```
Prod_SE_Solvente <- HoltWinters(Prod_Solvente,beta = F,gamma = F)
```

#5.2 Consumo

```
Consumo_SE_Etanol_Hidratado <- HoltWinters(Consumo_Etanol_Hidratado,beta = F,gamma = F)
```

```
Consumo_SE_Gasolina_C <- HoltWinters(Consumo_Gasolina_C,beta = F,gamma = F)
```

```
Consumo_SE_Gasolina_Aviacao <- HoltWinters(Consumo_Gasolina_Aviacao,beta = F,gamma = F)
```

```
Consumo_SE_GLP <- HoltWinters(Consumo_GLP,beta = F,gamma = F)
```

```
Consumo_SE_Oleo_Combustivel <- HoltWinters(Consumo_Oleo_Combustivel,beta = F,gamma = F)
```

```
Consumo_SE_Oleo_Diesel <- HoltWinters(Consumo_Oleo_Diesel,beta = F,gamma = F)
```

```
Consumo_SE_Querosene_Aviacao <- HoltWinters(Consumo_Querosene_Aviacao,beta = F,gamma = F)
```

```
Consumo_SE_Querosene_Iluminante <- HoltWinters(Consumo_Querosene_Iluminante,beta = F,gamma = F)
```

#Passo 6: Modelo de Holt

#6.1 Produção

```
Prod_Holt_Asfalto <- HoltWinters(Prod_Asfalto,gamma = F)
Prod_Holt_Coque <- HoltWinters(Prod_Coque,gamma = F)
Prod_Holt_Gasolina_A <- HoltWinters(Prod_Gasolina_A,gamma = F)
Prod_Holt_Gasolina_Aviacao <- HoltWinters(Prod_Gasolina_Aviacao,gamma = F)
Prod_Holt_GLP <- HoltWinters(Prod_GLP,gamma = F)
Prod_Holt_Lubrificante <- HoltWinters(Prod_Lubrificante,gamma = F)
Prod_Holt_Nafta <- HoltWinters(Prod_Nafta,gamma = F)
Prod_Holt_Oleo_Combustivel <- HoltWinters(Prod_Oleo_Combustivel,gamma = F)
Prod_Holt_Oleo_Diesel <- HoltWinters(Prod_Oleo_Diesel,gamma = F)
Prod_Holt_Outros_Energeticos <- HoltWinters(Prod_Outros_Energeticos,gamma = F)
Prod_Holt_Outros_Nao_Energeticos <- HoltWinters(Prod_Outros_Nao_Energeticos,gamma = F)
Prod_Holt_Parafina <- HoltWinters(Prod_Parafina,gamma = F)
Prod_Holt_Querosene_Aviacao <- HoltWinters(Prod_Querosene_Aviacao,gamma = F)
Prod_Holt_Querosene_Iluminante <- HoltWinters(Prod_Querosene_Iluminante,gamma = F)
Prod_Holt_Solvente <- HoltWinters(Prod_Solvente,gamma = F)
```

#7.2 Consumo

```
Consumo_Holt_Etanol_Hidratado <- HoltWinters(Consumo_Etanol_Hidratado,gamma = F)
Consumo_Holt_Gasolina_C <- HoltWinters(Consumo_Gasolina_C,gamma = F)
Consumo_Holt_Gasolina_Aviacao <- HoltWinters(Consumo_Gasolina_Aviacao,gamma = F)
Consumo_Holt_GLP <- HoltWinters(Consumo_GLP,gamma = F)
Consumo_Holt_Oleo_Combustivel <- HoltWinters(Consumo_Oleo_Combustivel,gamma = F)
Consumo_Holt_Oleo_Diesel <- HoltWinters(Consumo_Oleo_Diesel,gamma = F)
Consumo_Holt_Querosene_Aviacao <- HoltWinters(Consumo_Querosene_Aviacao,gamma = F)
Consumo_Holt_Querosene_Iluminante <- HoltWinters(Consumo_Querosene_Iluminante,gamma = F)
```

#Passo 7: Modelo de Winters

#7.1 Produção

```
Prod_Winters_Asfalto <- HoltWinters(Prod_Asfalto, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
```

```
Prod_Winters_Coque <- HoltWinters(Prod_Coque, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Gasolina_A <- HoltWinters(Prod_Gasolina_A, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Gasolina_Aviacao <- HoltWinters(Prod_Gasolina_Aviacao, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_GLP <- HoltWinters(Prod_GLP, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Lubrificante <- HoltWinters(Prod_Lubrificante, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Nafta <- HoltWinters(Prod_Nafta, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Oleo_Combustivel <- HoltWinters(Prod_Oleo_Combustivel, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Oleo_Diesel <- HoltWinters(Prod_Oleo_Diesel, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Outros_Energeticos <- HoltWinters(Prod_Outros_Energeticos, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Outros_Nao_Energeticos <- HoltWinters(Prod_Outros_Nao_Energeticos, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Parafina <- HoltWinters(Prod_Parafina, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Querosene_Aviacao <- HoltWinters(Prod_Querosene_Aviacao, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Querosene_Iluminante <- HoltWinters(Prod_Querosene_Iluminante, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Prod_Winters_Solvente <- HoltWinters(Prod_Solvente, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
```

#7.2 Consumo

```
Consumo_Winters_Etanol_Hidratado <- HoltWinters(Consumo_Etanol_Hidratado, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Gasolina_C <- HoltWinters(Consumo_Gasolina_C, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Gasolina_Aviacao <- HoltWinters(Consumo_Gasolina_Aviacao, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_GLP <- HoltWinters(Consumo_GLP, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Oleo_Combustivel <- HoltWinters(Consumo_Oleo_Combustivel, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Oleo_Diesel <- HoltWinters(Consumo_Oleo_Diesel, optim.start = c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Querosene_Aviacao <- HoltWinters(Consumo_Querosene_Aviacao, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
Consumo_Winters_Querosene_Iluminante <- HoltWinters(Consumo_Querosene_Iluminante, optim.start =
c(alpha=0.2,beta=0.1,gamma=0.1))
```

#Passo 8: Medição de erros

#8.1 Produção

#8.1.1 Erro de SE

accuracy(Prod_SE_Asfalto\$fitted,Prod_Asfalto)
accuracy(Prod_SE_Coque\$fitted,Prod_Coque)
accuracy(Prod_SE_Gasolina_A\$fitted,Prod_Gasolina_A)
accuracy(Prod_SE_Gasolina_Aviacao\$fitted,Prod_Gasolina_Aviacao)
accuracy(Prod_SE_GLP\$fitted,Prod_GLP)
accuracy(Prod_SE_Lubrificante\$fitted,Prod_Lubrificante)
accuracy(Prod_SE_Nafta\$fitted,Prod_Nafta)
accuracy(Prod_SE_Oleo_Combustivel\$fitted,Prod_Oleo_Combustivel)
accuracy(Prod_SE_Oleo_Diesel\$fitted,Prod_Oleo_Diesel)
accuracy(Prod_SE_Outros_Energeticos\$fitted,Prod_Outros_Energeticos)
accuracy(Prod_SE_Outros_Nao_Energeticos\$fitted,Prod_Outros_Nao_Energeticos)
accuracy(Prod_SE_Parafina\$fitted,Prod_Parafina)
accuracy(Prod_SE_Querosene_Aviacao\$fitted,Prod_Querosene_Aviacao)
accuracy(Prod_SE_Querosene_Iluminante\$fitted,Prod_Querosene_Iluminante)
accuracy(Prod_SE_Solvente\$fitted,Prod_Solvente)

#8.1.2 Erro de Holt

accuracy(Prod_Holt_Asfalto\$fitted,Prod_Asfalto)
accuracy(Prod_Holt_Coque\$fitted,Prod_Coque)
accuracy(Prod_Holt_Gasolina_A\$fitted,Prod_Gasolina_A)
accuracy(Prod_Holt_Gasolina_Aviacao\$fitted,Prod_Gasolina_Aviacao)
accuracy(Prod_Holt_GLP\$fitted,Prod_GLP)
accuracy(Prod_Holt_Lubrificante\$fitted,Prod_Lubrificante)
accuracy(Prod_Holt_Nafta\$fitted,Prod_Nafta)
accuracy(Prod_Holt_Oleo_Combustivel\$fitted,Prod_Oleo_Combustivel)
accuracy(Prod_Holt_Oleo_Diesel\$fitted,Prod_Oleo_Diesel)
accuracy(Prod_Holt_Outros_Energeticos\$fitted,Prod_Outros_Energeticos)
accuracy(Prod_Holt_Outros_Nao_Energeticos\$fitted,Prod_Outros_Nao_Energeticos)
accuracy(Prod_Holt_Parafina\$fitted,Prod_Parafina)
accuracy(Prod_Holt_Querosene_Aviacao\$fitted,Prod_Querosene_Aviacao)
accuracy(Prod_Holt_Querosene_Iluminante\$fitted,Prod_Querosene_Iluminante)
accuracy(Prod_Holt_Solvente\$fitted,Prod_Solvente)

#8.1.3 Erro de Winters

accuracy(Prod_Winters_Asfalto\$fitted,Prod_Asfalto)

accuracy(Prod_Winters_Coque\$fitted,Prod_Coque)

accuracy(Prod_Winters_Gasolina_A\$fitted,Prod_Gasolina_A)

accuracy(Prod_Winters_Gasolina_Aviacao\$fitted,Prod_Gasolina_Aviacao)

accuracy(Prod_Winters_GLP\$fitted,Prod_GLP)

accuracy(Prod_Winters_Lubrificante\$fitted,Prod_Lubrificante)

accuracy(Prod_Winters_Nafta\$fitted,Prod_Nafta)

accuracy(Prod_Winters_Oleo_Combustivel\$fitted,Prod_Oleo_Combustivel)

accuracy(Prod_Winters_Oleo_Diesel\$fitted,Prod_Oleo_Diesel)

accuracy(Prod_Winters_Outros_Energeticos\$fitted,Prod_Outros_Energeticos)

accuracy(Prod_Winters_Outros_Nao_Energeticos\$fitted,Prod_Outros_Nao_Energeticos)

accuracy(Prod_Winters_Parafina\$fitted,Prod_Parafina)

accuracy(Prod_Winters_Querosene_Aviacao\$fitted,Prod_Querosene_Aviacao)

accuracy(Prod_Winters_Querosene_Iluminante\$fitted,Prod_Querosene_Iluminante)

accuracy(Prod_Winters_Solvente\$fitted,Prod_Solvente)

#8.2 Consumo

#8.2.1 SE

accuracy(Consumo_SE_Etanol_Hidratado\$fitted,Consumo_Etanol_Hidratado)

accuracy(Consumo_SE_Gasolina_C\$fitted,Consumo_Gasolina_C)

accuracy(Consumo_SE_Gasolina_Aviacao\$fitted,Consumo_Gasolina_Aviacao)

accuracy(Consumo_SE_GLP\$fitted,Consumo_GLP)

accuracy(Consumo_SE_Oleo_Combustivel\$fitted,Consumo_Oleo_Combustivel)

accuracy(Consumo_SE_Oleo_Diesel\$fitted,Consumo_Oleo_Diesel)

accuracy(Consumo_SE_Querosene_Aviacao\$fitted,Consumo_Querosene_Aviacao)

accuracy(Consumo_SE_Querosene_Iluminante\$fitted,Consumo_Querosene_Iluminante)

#8.2.1 Holt

accuracy(Consumo_Holt_Etanol_Hidratado\$fitted,Consumo_Etanol_Hidratado)

accuracy(Consumo_Holt_Gasolina_C\$fitted,Consumo_Gasolina_C)

accuracy(Consumo_Holt_Gasolina_Aviacao\$fitted,Consumo_Gasolina_Aviacao)

accuracy(Consumo_Holt_GLP\$fitted,Consumo_GLP)


```
accuracy(Consumo_Holt_Oleo_Combustivel$fitted,Consumo_Oleo_Combustivel)
accuracy(Consumo_Holt_Oleo_Diesel$fitted,Consumo_Oleo_Diesel)
accuracy(Consumo_Holt_Querosene_Aviacao$fitted,Consumo_Querosene_Aviacao)
accuracy(Consumo_Holt_Querosene_Iluminante$fitted,Consumo_Querosene_Iluminante)
```

#8.2.3 Winters

```
accuracy(Consumo_Winters_Etanol_Hidratado$fitted,Consumo_Etanol_Hidratado)
accuracy(Consumo_Winters_Gasolina_C$fitted,Consumo_Gasolina_C)
accuracy(Consumo_Winters_Gasolina_Aviacao$fitted,Consumo_Gasolina_Aviacao)
accuracy(Consumo_Winters_GLP$fitted,Consumo_GLP)
accuracy(Consumo_Winters_Oleo_Combustivel$fitted,Consumo_Oleo_Combustivel)
accuracy(Consumo_Winters_Oleo_Diesel$fitted,Consumo_Oleo_Diesel)
accuracy(Consumo_Winters_Querosene_Aviacao$fitted,Consumo_Querosene_Aviacao)
accuracy(Consumo_Winters_Querosene_Iluminante$fitted,Consumo_Querosene_Iluminante)
```

#Passo 9: Gráficos Demanda/Previsão x Tempo das melhores previsões (Brasil)

#9.1 Produção

```
plot(Prod_Winters_Asfalto)
plot(Prod_SE_Coque)
plot(Prod_Winters_Gasolina_A)
plot(Prod_Winters_GLP)
plot(Prod_SE_Nafta)
plot(Prod_SE_Oleo_Combustivel)
plot(Prod_Winters_Oleo_Diesel)
plot(Prod_SE_Querosene_Aviacao)
```

#9.2 Consumo

```
plot(Consumo_Winters_Gasolina_C)
plot(Consumo_Winters_Querosene_Aviacao)
plot(Consumo_Winters_GLP)
plot(Consumo_SE_Oleo_Combustivel)
plot(Consumo_Winters_Oleo_Diesel)
plot(Consumo_Winters_Etanol_Hidratado)
```