



**Rodrigo Ferreira Bertoloto**

**Previsão de fretes de navios petroleiros  
no mercado *spot***

**Dissertação de Mestrado**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da PUC-Rio como requisito parcial para obtenção do grau de Mestre em Engenharia de Produção.

Orientador: Prof. Fernando Luiz Cyrino Oliveira

Rio de Janeiro  
Agosto de 2018



**Rodrigo Ferreira Bertoloto**

**Previsão de fretes de navios petroleiros no mercado spot.**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre (opção profissional) pelo Programa de Pós-Graduação em Engenharia de Produção da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Fernando Luiz Cyrino Oliveira**

Presidente e Orientador

Departamento de Engenharia Industrial - PUC-Rio

**Prof. Reinaldo Castro Souza**

Departamento de Engenharia Industrial - PUC-Rio

**Prof. Antônio Márcio Tavares Thomé**

Departamento de Engenharia Industrial - PUC-Rio

**Prof. Márcio da Silveira Carvalho**

Coordenador (a) Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 23 de agosto de 2018.

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização do autor, do orientador e da universidade.

### **Rodrigo Ferreira Bertoloto**

Graduou-se em Engenharia de Produção pela Universidade Federal Fluminense (UFF) em 2006. Iniciou suas atividades na Vale S.A. e atualmente trabalha na Petróleo Brasileiro S.A. (Petrobras), no planejamento da frota, onde atua no estudo e previsões de fretes.

#### Ficha Catalográfica

Bertoloto, Rodrigo Ferreira

Previsão de fretes de navios petroleiros no mercado *spot* / Rodrigo Ferreira Bertoloto; orientador: Fernando Luiz Cyrino Oliveira. – 2018.

69 f.; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2018.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Taxa frete. 3. Navio-tanque. 4. Regressão Dinâmica I. Oliveira, Fernando Luiz Cyrino. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. III. Título.

CDD: 658.5

## Agradecimentos

A Deus, pelo dom da vida, e por permitir que eu concluísse mais esta importante etapa da minha vida profissional.

Aos meus pais e ao meu irmão, pelo incentivo, carinho e compreensão em todos os momentos. A vocês, a minha eterna gratidão.

À minha esposa Leila e aos meus filhos Caio e Miguel, pela paciência e compreensão durante o tempo ausente para conclusão deste curso.

Ao meu orientador, Professor Fernando Luiz Cyrino Oliveira, pelas valiosas sugestões, e pela confiança e estímulo na condução deste trabalho.

À Petrobras, pela oportunidade, sem a qual este trabalho não poderia ter sido realizado.

Ao gerente de Planejamento da Frota (PLF), Walter Formosinho, pela confiança em mim depositada ao indicar-me para a vaga do curso de mestrado.

Aos colegas da PLF, em especial ao consultor José Paulo Ribeiro dos Santos, pelo apoio e colaboração na obtenção de informações utilizadas neste trabalho.

A todos aqueles que de alguma forma contribuíram e me incentivaram para a conclusão deste trabalho.

## Resumo

Bertoloto, Rodrigo Ferreira; Oliveira, Fernando Luiz Cyrino (Orientador). **Previsão de fretes de navios petroleiros no mercado spot.** Rio de Janeiro, 2018. 69p. Dissertação de Mestrado - Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

O transporte marítimo de petróleo e derivados é componente fundamental da cadeia de suprimento da indústria do petróleo, integrando fornecedores e clientes localizados em regiões geográficas distintas. Neste contexto, os valores de fretes praticados possuem grande impacto no comércio internacional destes bens. O objetivo deste trabalho é verificar o desempenho de modelos de Regressão Dinâmica em previsões de frete marítimo de curto prazo do mercado *spot* de uma rota de exportação de petróleo do oeste da África para a China, comparar a capacidade preditiva do modelo com métodos tradicionais, vastamente discutidos na literatura, como Amortecimento Exponencial e modelos ARIMA e projetar cenários para avaliar como as variáveis explicativas presentes no modelo de Regressão Dinâmica proposto neste estudo afetam o frete marítimo. O produto desenvolvido nesta dissertação mostrou a viabilidade de os modelos univariados e causais serem utilizados como ferramenta de previsão da taxa frete de navios petroleiros. Como forma de validação, os resultados foram comparados aos obtidos com a metodologia vigente em uma grande empresa de petróleo do Brasil. O protótipo de sistema de previsão proposto, via Regressão Dinâmica, apresentou resultados satisfatórios e desempenho superior ao obtido através da metodologia da empresa de petróleo.

## Palavras-chave

Taxa frete; navio-tanque; regressão dinâmica.

## Abstract

Bertoloto, Rodrigo Ferreira; Oliveira, Fernando Luiz Cyrino (Advisor). **Forecasting tanker freight rate**. Rio de Janeiro, 2018. 69p. Dissertação de Mestrado - Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

Crude oil and oil products seaborne transportation is a key component of the petroleum industry supply chain, integrating suppliers and customers located in different geographic regions. In this context, the freight rates practiced have a great impact on the international trade of these goods. This work aims to verify the performance of Dynamic Regression models in short-term maritime freight forecasts of the spot market of an oil export route from West Africa to China, to compare the predictive capacity of the model with traditional methods, widely discussed in the literature, such as Exponential Smoothing and ARIMA models and to design scenarios to evaluate how the explanatory variables present in the Dynamic Regression model proposed in this study affect freight rate. The product developed in this dissertation showed the viability of the univariate and causal models being used as a forecasting tool for the oil tankers freight rate. As a form of validation, the results were compared to those obtained with the methodology of a large Brazilian oil company. The proposed prediction system prototype, through Dynamic Regression model, presented satisfactory results and performance superior to that obtained through the methodology of the oil company.

## Keywords

Freight rate; tanker; dynamic regression.

## Sumário

1	Introdução	10
1.1.	Motivação	12
1.2.	Objetivo	13
1.3.	Estrutura do trabalho	13
2	Mercado de Contratação de Navios Petroleiros	15
2.1.	O conceito de <i>Worldscale</i>	17
2.2.	Tipos de navios	18
2.3.	Exemplo de cálculo do frete de navio tanque para uma viagem (VCP)	19
3	Metodologia	21
3.1.	Revisão da Literatura	24
3.1.1.	Síntese da Literatura	24
3.1.2.	Análise descritiva dos resultados da revisão da literatura	26
3.2.	Métodos de Previsão	30
3.2.1.	Regressão Dinâmica	30
3.2.1.1.	Estrutura do modelo	32
3.2.1.2.	Modelos de Regressão Cochrane e Orcutt Generalizados	33
3.2.1.3.	Estratégia de modelagem para modelos de Regressão Dinâmica	34
3.2.1.4.	Testes estatísticos utilizados nos modelos de Regressão Dinâmica	35
3.2.2.	Amortecimento Exponencial	38
3.2.3.	Modelagem auto-regressiva integrada de média móvel (ARIMA)	41
3.3.	Métricas de Desempenho	43
4	Resultados	44
4.1.	Aplicação do modelo de regressão dinâmica	44
4.2.	Aplicação dos modelos univariados	53
4.3.	Comparação dos modelos	55
4.4.	Análise de cenários com regressão dinâmica	60
5	Conclusão	64
5.1.	Trabalhos futuros	65
5.2.	Implicações práticas	65
6	Referências bibliográficas	67

## Lista de figuras

Figura 1 – Principais regiões exportadoras de petróleo.	10
Figura 2 – Principais regiões importadoras de petróleo.	11
Figura 3 – Evolução das taxas de frete mensais no mercado <i>spot</i> para navios VLCC e MR.	16
Figura 4 – Gráfico da série TD15 em WS de janeiro de 2010 a junho de 2018.	45
Figura 5 – Função de Autocorrelação de Erros (FAC <i>Error</i> ) – Modelo de Regressão Dinâmica.	49
Figura 6 – Previsão da variável causal produção mundial de petróleo (MMbbls/dia).	51
Figura 7 – Previsão da variável causal importação de petróleo EUA (MMbbls/dia).	51
Figura 8 – Previsão da variável causal frota VLCC (MMdwt).	51
Figura 9 – Função de Autocorrelação de Erros (FAC <i>Error</i> ) – Modelo SARIMA $(1,0,0) \times (1,0,0)_{12}$ .	55

## Lista de tabelas

Tabela 1 – Classificação dos navios petroleiros quanto ao porte bruto.	18
Tabela 2 – Classificação dos navios petroleiros quanto ao porte bruto.	19
Tabela 3 – Total de artigos por periódico.	23
Tabela 4 – Métodos e variáveis identificados na literatura para previsão de frete de navios-tanque.	27
Tabela 5 – Classificação do método de amortecimento exponencial.	38
Tabela 6 – Equações para os possíveis métodos de amortecimento exponencial.	39
Tabela 7 – Variáveis testadas no modelo de regressão dinâmica.	46
Tabela 8 – Modelo de Regressão Dinâmica com ajustes adequados.	48
Tabela 9 – Desempenho do modelo de regressão dinâmica fora da amostra.	52
Tabela 10 – Desempenho <i>in sample</i> dos modelos univariados e de regressão dinâmica.	56
Tabela 11 – Desempenho <i>out-of-sample</i> dos modelos univariados e de regressão dinâmica.	57
Tabela 12 – Desempenho do modelo de regressão dinâmica dentro e fora da amostra.	58
Tabela 13 – Comparação do desempenho do modelo atual de uma empresa de petróleo com o desempenho dos modelos avaliados neste estudo.	59
Tabela 14 – Premissas dos cenários utilizados para previsão da taxa frete através do modelo de regressão dinâmica.	60
Tabela 15 – Regressão dinâmica: Previsões da taxa frete para o cenário pessimista.	61
Tabela 16 – Regressão dinâmica: Previsões da taxa frete para o cenário moderado.	62
Tabela 17 – Regressão dinâmica: Previsões da taxa frete para o cenário otimista.	63

# 1

## Introdução

O transporte marítimo de petróleo e derivados é componente fundamental da cadeia de suprimentos da indústria do petróleo, integrando fornecedores e clientes localizados em regiões geográficas distintas. Em 2017, foram transportados, por via marítima, 11.617 milhões de toneladas de carga, das quais 2.005 milhões de toneladas de petróleo e 1.092 milhões de toneladas de derivados de petróleo. A frota de navios tanque corresponde a aproximadamente 26% da tonelagem da frota mundial (Clarksons, 2018). Neste contexto, os valores de fretes praticados possuem grande impacto no comércio internacional destes bens.

As figuras 1 e 2 abaixo mostram, respectivamente, as principais regiões exportadoras e importadoras de petróleo em 2016.



Figura 1 – Principais regiões exportadoras de petróleo. Fonte: EIA (2018) - adaptado.

Observa-se que a região do Oriente Médio aparece como a maior exportadora, seguida pela Rússia e os países do Oeste da África. Já no que tange à importação, como pode ser observado na figura 2, Estados Unidos, China, Índia e Japão são os que mais expressivamente recebem petróleos.

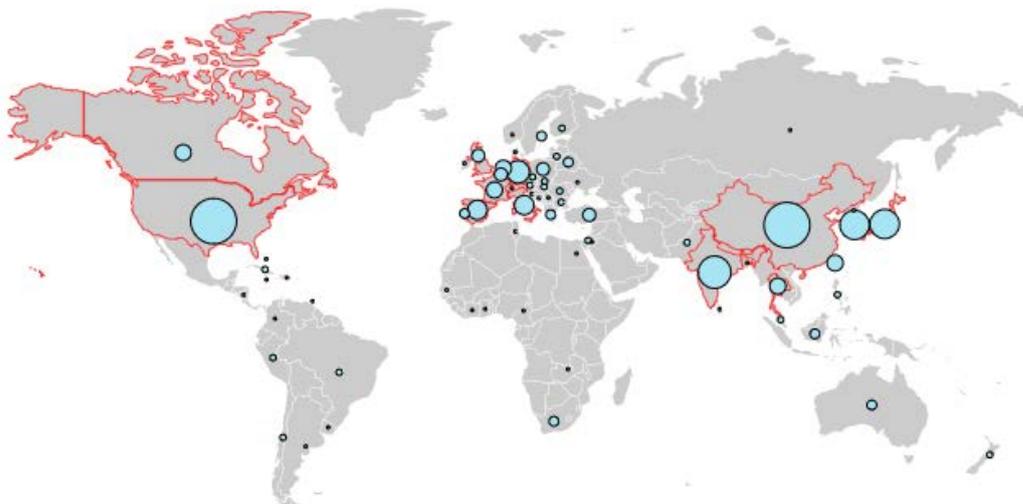


Figura 2 – Principais regiões importadoras de petróleo. Fonte: EIA (2018) - adaptado.

Para algumas rotas que compreendem os principais fluxos comerciais de petróleo e derivados, consultorias e instituições independentes divulgam valores de referência do frete do mercado *spot* expressos em taxa *Worldscale*. O conceito de taxa *Worldscale* é explicado detalhadamente no Capítulo 2.

No que lhe concerne, a contratação de transporte em navios petroleiros é realizada, basicamente, através de dois tipos de contratos: por viagem, denominado de VCP (*Voyage Charter Party*) ou por período, denominado TCP (*Time Charter Party*). Além da contratação em VCP e TCP, também é comum contratar capacidade de transporte através de *Contract of Affreightment* (COA), semelhante ao VCP, entretanto são negociadas repetidas viagens durante certo período de tempo.

Em se tratando de contratação de transporte de navios petroleiros por viagem, cuja rota e o tipo de navio demandados são os mesmos do mercado de referência reportado por instituições independentes, é de se esperar que a contratação do frete seja com base na taxa já divulgada. No entanto, comparativamente a todos os fluxos de petróleos e derivados mundiais, são poucas as rotas reportadas atualmente.

Como não existem referências de frete para a maioria das rotas que compõem a movimentação mundial de petróleos e seus derivados, as transações comerciais ocorrem, normalmente, com base nas rotas reportadas.

O Brasil, por exemplo, segundo a Clarksons (2018), ficou na 15ª posição em 2016 entre os maiores exportadores de petróleo do mundo. Não existe, atualmente, no entanto, uma rota de referência que retrate exportações a partir do Brasil. Porém, em função da proximidade da região oeste da África para o Brasil, as exportações brasileiras de petróleo são feitas, usualmente, por navios oriundos da África, uma das principais regiões de exportação de petróleo do mundo. Os fretes de exportação a partir do Brasil são negociados, portanto, tomando-se como referência os fretes reportados do mercado de exportação do oeste da África para a China.

Neste trabalho, foi dedicada atenção à previsão de frete do mercado *spot* de navio petroleiro, para uma rota cujos fretes são divulgados por instituições independentes.

## 1.1

### Motivação

A importância econômica do transporte marítimo de petróleo e derivados é um dos motivos para elaboração dessa pesquisa. Além disso, e não menos importante, entre as entidades que demandam extensivamente previsões no mercado de transporte marítimo estão bancos e companhias de navegação, servidores de entidades públicas e consultores encarregados de elaboração de estudos sobre o setor (Stopford, 1997). As empresas que afretam navios para transportar os seus produtos também possuem forte interesse em previsões de frete, tanto para elaboração de seus orçamentos como para otimizar seus resultados no processo de afretamento dos navios, dimensionamento da frota de navios e escolha de mercados para comercialização de seus produtos.

Em específico, para os agentes participantes diretamente deste mercado, o melhor entendimento do mesmo oferece vantagem competitiva. A volatilidade dos mercados de contratação de transporte de petroleiros é considerável e a possibilidade de antecipação a tendências no mercado é de extremo interesse aos agentes, uma vez que agrega valor ao processo de tomada de decisão em negociações (Junkes, 2011).

## 1.2

### Objetivo

O objetivo principal deste trabalho é verificar o desempenho de modelos de Séries Temporais, via Regressão Dinâmica, em previsões de frete marítimo de curto prazo do mercado *spot* (*Voyage Charter Party*) de uma rota de exportação de petróleo do Oeste da África para a China. A estratégia está na escolha adequada das variáveis exógenas a serem utilizadas em uma abordagem de construção *bottom-up* (Goodrich, 1989).

A pesquisa tem também como objetivo comparar a capacidade preditiva dos referidos modelos através da previsão de curto prazo para a série de frete de navio petroleiro com métodos tradicionais vastamente discutidos na literatura, como Amortecimento Exponencial e modelos ARIMA.

Visando avaliar a possibilidade dos modelos univariados e de regressão dinâmica serem utilizados como ferramenta de previsão da taxa frete de navios petroleiros, outro objetivo deste estudo é comparar o desempenho preditivo desses modelos com o desempenho de um modelo real de uma grande empresa de petróleo do Brasil e, portanto, propor uma nova abordagem para a previsão de fretes da empresa.

Por fim, tem-se o objetivo de projetar alguns cenários para avaliar como as variáveis explicativas presentes no modelo de regressão dinâmica afetam o frete marítimo.

## 1.3

### Estrutura do trabalho

O trabalho está organizado a partir do capítulo 1 de Introdução. O capítulo 2 discorre sobre o mercado de contratação de navios petroleiros e o capítulo 3 apresenta a metodologia, que contempla os esforços apresentados pela literatura acadêmica sobre modelagem do mercado de frete de transporte marítimo e a teorização e fundamentos dos métodos de previsão que foram utilizados. Neste mesmo capítulo são discutidos os parâmetros usados na aferição do desempenho das previsões deste trabalho.

No capítulo 4 é discutida a implementação e são apresentados os respectivos resultados dos modelos de previsão de frete para a rota estudada. Por fim, o capítulo 5 traz as considerações finais, sugere oportunidades para pesquisas futuras e apresenta as implicações práticas deste estudo.

## 2

### Mercado de Contratação de Navios Petroleiros

O mercado de contratação para navios petroleiros vale-se, basicamente, de dois mecanismos distintos para os agentes interessados em comprar e vender transporte.

É possível contratar capacidade de transporte através da modalidade de contrato por tempo determinado, ou período (TCP). Neste tipo de acordo o fretador disponibiliza ao afretador o controle comercial do navio mediante o pagamento de uma taxa de aluguel diário. Ficam por conta do afretador os custos de abastecimento e as despesas portuárias incorridas, uma vez que o afretador é quem instrui o transporte a ser realizado pela embarcação seguindo seus interesses comerciais. Ao fretador recai sobre todos os aspectos o custo de manter o navio operacional (tripulado, com manutenção apropriada, seguro etc.). Interessante ressaltar que embora o controle comercial da embarcação esteja com o afretador, tanto a propriedade quanto a posse do navio permanecem com o fretador (Junkes, 2011).

Os acordos em TCP têm duração usual variando de meses até anos. Vale ressaltar que nesta forma de contratação não há frete envolvido, mas sim aluguel.

Alternativamente, é possível contratar frete para uma viagem isolada, onde a contratação se dá para uma movimentação específica de um ponto a outro. Na contratação de frete para uma viagem (VCP), com origem e destino definidos, a gestão náutica e comercial do navio fica sob a responsabilidade do fretador do navio. Normalmente, o frete acordado cobre todas as despesas relacionadas com o transporte do produto, como custos com combustíveis, despesas portuárias, seguros, tripulação, mantimentos, entre outros. Este mercado é ainda conhecido como mercado de frete *spot*.

Na figura 3 a seguir pode-se observar a variação das taxas de fretes mensais de mercados de referência típicos de grandes navios petroleiros (VLCC) e de navios menores (MR), destinados ao transporte de derivados.

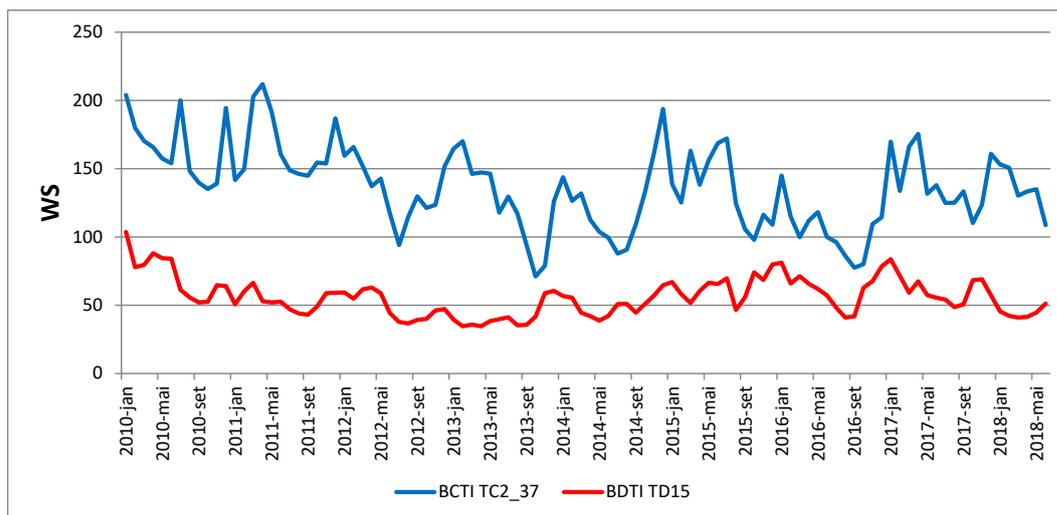


Figura 3 – Evolução das taxas de frete mensais no mercado *spot* para navios VLCC e MR.

O frete de petroleiros no mercado *spot* é usualmente negociado utilizando unidade de valoração própria deste mercado, denominada *Worldscale*. Estas unidades são convertidas em valor monetário através da fórmula apresentada pela equação 1.

$$Frete = \left( \frac{WS}{100} \right) \times Flat\ Rate \left( \frac{US\$}{tm} \right) \times Lote\ (tm) \quad (1)$$

Onde:

Frete - Valor total do frete, em dólares americanos

Lote - Quantidade efetivamente transportada, em toneladas métricas (tm)

WS - Taxa *Worldscale* negociada entre as partes (adimensional)

*Flat Rate* - Taxa publicada pela *Worldscale*, em dólares por tonelada métrica

Os valores de fretes negociados no mercado *spot* de navios petroleiros são expressos, normalmente, em US\$/tm ou, alternativamente, pelo valor total da viagem.

## 2.1

### O conceito de *Worldscale*

O *Worldscale* consiste no tabelamento dos fretes padrão (*flat rates* ou *WS100*) para todos os portos de origem e destino no mundo, sendo que em cada viagem é negociado o percentual a ser aplicado sobre o frete padrão da rota que está sendo negociada. Esse percentual é a taxa WS, que reflete o mercado *spot* de navios petroleiros.

Em 1969, o escritório de Londres juntou-se com o de Nova Iorque e foi criado o "*Worldwide Tanker Nominal Freight Scale*", conhecido mais popularmente por "*Worldscale*". Em 1989, por fim, foi criado o "*New Worldscale*", que moldou o sistema de cálculo de frete como o é até o presente.

Quando o mercado se apresenta em sua estrutura normal, lotes maiores são transportados em navios maiores, permitindo ganhos de escala e, por conseguinte, o frete em US\$/t é menor. Portanto, quanto maior o navio, em regra as taxas WS serão menores. Todavia, em momentos de grande procura por navios, a taxa WS se eleva.

Por sua vez, os *flat rates* (*Worldscale*, 2018), divulgados em dólares por tonelada métrica (US\$/tm) e atualizados anualmente, consideram a viagem de um navio padrão totalmente carregado com base em uma viagem de ida e volta do porto ou portos de carga até o porto ou portos de descarga e retorno ao primeiro porto de carregamento usando alguns fatores:

- Características do navio padrão (capacidade total, velocidade média, consumo de *bunker*);
- Tempo de porto;
- Aluguel fixo;
- Preço do Bunker;
- Despesas Portuárias;
- Tempo de trânsito pelo Canal (Canal de Panamá e Canal de Suez).

Na prática, o sistema *Worldscale* permite que se negociem livremente as taxas de frete sem se preocupar com quais portos se vai de fato operar, o que nem sempre é possível saber no momento da contratação, permitindo uma remuneração

justa independente da viagem realizada. Esse conceito é largamente utilizado no mercado de petroleiros, sendo que relatórios e fechamentos são basicamente reportados nessa unidade (Wakamatsu, 2008).

## 2.2

### Tipos de navios

Os navios podem ser classificados de acordo com a carga que transportam em petroleiros, graneleiros, gaseiros, porta-contêiner, dentre outros.

Considerando que o objetivo principal desse estudo são os navios petroleiros, o foco é nesse tipo de navio. Eles realizam o transporte de grande parte do petróleo e seus derivados, como por exemplo, o próprio petróleo, o óleo combustível, o diesel, a gasolina, a nafta, o querosene de avião entre outros. A classificação dos navios petroleiros quanto a tonelada de porte bruto (TPB) pode ser observada na tabela 1.

Tabela 1 – Classificação dos navios petroleiros quanto ao porte bruto.

Classificação	Tonelagem de Porte Bruto
ULCC – Ultra Large Crude Carriers	$tpb \geq 300.000$
VLCC – Very Large Crude Carriers	$200.000 \leq tpb < 300.000$
Suezmax	$120.000 \leq tpb < 200.000$
Aframax	$80.000 \leq tpb < 120.000$
Panamax	$60.000 \leq tpb < 80.000$
Handysize	$tpb < 60.000$

Fonte: adaptado de Saraceni (2012).

Saraceni (2012) também classifica navios do tipo “Post Panamax” como sendo navios do mesmo porte em tpb de um Panamax, porém que não podem transitar através do Canal do Panamá por restrição de dimensão física.

Os navios do tipo VLCC e Suezmax são, basicamente, empregados no transporte de petróleo, por razões logísticas e mercadológicas da indústria. Os navios das classes Aframax, Panamax e Handysize são comumente empregados tanto para transporte de petróleo quanto de derivados escuros, como, por exemplo, óleos combustíveis e asfaltos.

Os navios de derivados claros costumam ter seus tanques revestidos, a fim de evitar a contaminação da carga. Quanto ao porte bruto, esses navios chegam a 120.000 tpb, conforme classificação apresentada na tabela 2.

Tabela 2 – Classificação dos navios petroleiros quanto ao porte bruto.

Classificação	Tonelagem de Porte Bruto
LR2 – Long Range 2	$80.000 \leq \text{tpb} < 120.000$
LR 1 – Long Range 1	$50.000 \leq \text{tpb} < 80.000$
MR – Medium Range	$40.000 \leq \text{tpb} < 50.000$
SR – Short Range ou Handysize	$\text{tpb} < 40.000$

Fonte: adaptado de Saraceni (2012).

Para cálculo do *flat rate*, utiliza-se como premissa o navio da classe Aframax. Já a rota que aqui se pretende estudar, refere-se ao mercado de frete *spot* para o navio VLCC.

## 2.3

### Exemplo de cálculo do frete de navio tanque para uma viagem (VCP)

O valor do frete total de uma viagem de exportação de 260.000 toneladas de petróleo de Angra dos Reis no Brasil para Ningpo na China pode ser calculado a partir da equação 1.

Sabe-se que o *flat rate* de Angra dos Reis para Ningpo em 2018, publicado pela *Worldscale* (*Worldscale*, 2018) é de US\$ 29,38 por tonelada métrica e que o lote a ser transportado é de 260.000 toneladas métricas.

Deve-se definir, no entanto, o WS, que pode variar de acordo com o mercado da classe de navios demandada, neste exemplo o tipo de navio é o VLCC.

Na prática, no mercado de frete *spot* o que é comumente negociado é a taxa WS, tendo em vista que *flat rate* e lotes são conhecidos.

Supondo uma taxa WS negociada de 50 para a exportação de petróleo do Brasil para a China, pode-se calcular então o frete para a rota demandada tomando como base a equação 1:

$$Frete = \left(\frac{WS}{100}\right) \times \text{Flate Rate} \left(\frac{US\$}{tm}\right) \times \text{Lote (tm)}$$

$$Frete = \left(\frac{50}{100}\right) \times 29,38 \times 260.000$$

$$Frete = US\$ 3.819.400,00$$

O valor total do frete de uma viagem de exportação de 260.000 toneladas métricas de petróleo de Angra dos Reis para Ningpo, neste exemplo, é de US\$ 3.819.400,00. Para encontrar o valor do frete em US\$/tm, pode-se dividir o valor total do frete pelo lote de 260.000 tm ou simplesmente multiplicar o *flat rate* da rota, divulgado pelo *Worldscale*, pelo WS negociado.

O entendimento do conceito de taxa *Worldscale* como sendo o frete negociado no mercado *spot* é importante para esse estudo. Aqui se propõe analisar a série de frete, expressa em taxa WS, da rota de exportação de petróleo do Oeste da África para a China, identificada pela instituição que a publica, BALTIC Exchange, como BDTI TD15.

A BALTIC Exchange (BALTIC, 2018), com sede em Londres, é a principal fonte mundial de dados independentes do mercado marítimo. Suas informações são utilizadas por corretores de navios, armadores, operadores, comercializadores de cargas, financiadores e afretadores como uma visão confiável e independente do mercado de navios de carga seca e navios-tanque.

As informações da BALTIC Exchange são baseadas em avaliações feitas por um painel global de corretores de navios. Seus índices e avaliações são utilizados como ferramenta de liquidação de operações de derivativos de frete, para *benchmarking* de contratos físicos e como um indicador geral do desempenho do mercado a granel.

## 3

### Metodologia

O problema a ser tratado foi exposto dentro do contexto do mercado de contratação de navios petroleiros.

Neste capítulo, será apresentada uma revisão da literatura sobre previsão de frete marítimo, com o propósito de identificar os métodos já utilizados para previsão de frete de navios e possíveis variáveis que explicam a formação do frete. Adicionalmente, será apresentada a descrição e formulação matemática dos métodos de previsão que serão utilizados neste estudo e, por fim, as métricas para avaliação do desempenho dos modelos utilizados.

#### 3.1

##### Revisão da Literatura

Esta revisão da literatura apresenta o contexto científico no qual este trabalho está inserido. Embora existam práticas bem estabelecidas no mercado para a negociação e contratação do serviço de transporte marítimo, não existe consenso sobre os métodos para previsão de frete de navios-tanque que irão dar suporte para essa contratação.

Maçaira et al (2018) aplicaram um rigoroso protocolo de revisão sistemática da literatura a fim de identificar, por área de conhecimento, os principais métodos de séries temporais que incorporam variáveis explicativas. De acordo com o estudo, que passou pela leitura completa de 150 artigos, o método aplicado com maior frequência foi o modelo de regressão, seguido das redes neurais artificiais, modelo ARIMA de Box e Jenkins com a incorporação da variável explicativa (ARIMAX), máquina de vetor de suporte (SVM) e modelos estruturais.

Apesar de não ser um objetivo deste estudo a realização de uma revisão sistemática da literatura, a busca por métodos já utilizados especificamente para previsão de frete de navios e por variáveis que explicam a formação do frete se deu a partir de uma adaptação do processo proposto por Thomé et al. (2016) e

baseado no trabalho de Freitas (2016). Os seis passos utilizados para seleção dos artigos foram: (i) seleção da base de periódicos; (ii) identificação das palavras-chave para a pesquisa, (iii) leitura dos resumos dos artigos encontrados; (iv) aplicação de critérios de exclusão, (v) leitura completa dos artigos selecionados e (vi) inserção de outras referências consideradas relevantes.

Foi selecionada a base de dados *Scopus* para a realização da pesquisa, por se tratar de uma base vastamente conhecida e que possibilita a pesquisa de artigos das principais revistas de diversas áreas de conhecimento científico (Mongeon e Paul-Hus, 2016). A consulta a base de dados foi realizada em novembro de 2017 e dos resultados retornados foram filtrados somente aqueles classificados como artigo, artigo *in press* e *reviews*.

As palavras-chave ‘freight rate’ OR ‘tanker freight’ foram escolhidas por fornecer amplitude para a busca de periódicos e por estarem relacionadas ao objetivo do presente estudo que visa identificar os métodos de previsão de frete especificamente de navios-tanque.

O uso das palavras-chave indicadas resultou em 144 artigos recuperados, dentre os quais 73 foram publicados a partir de 2010.

No terceiro e quarto passo utilizados para seleção dos artigos, após a leitura dos 73 resumos encontrados, foram criados 3 critérios de exclusão: (i) artigos que não tratassem especificamente da previsão de valores de frete; (ii) artigos que abordassem fretes de outros modais de transporte ou outros tipos de navio que não fossem navios-tanque; e (iii) artigos publicados em períodos anteriores a 2010 para que fossem consideradas apenas as publicações mais recentes.

Com base nestes critérios de exclusão foram selecionados 7 artigos para a leitura completa durante o quinto passo para a seleção de artigos. A quantidade reduzida de artigos deve-se ao fato de a pesquisa ser direcionada e os critérios de exclusão aplicados terem sido rigorosos para filtrar apenas artigos que tratassem exclusivamente de previsão de frete de navios-tanque.

Os artigos selecionados para revisão do texto completo foram publicados em diferentes periódicos, como apresentado na tabela 3.

Tabela 3 – Total de artigos por periódico.

Periódico	Quantidade de Artigos
<i>Maritime Economics and Logistics</i>	2
<i>Applied Economics</i>	1
<i>Journal of Transportation Systems Engineering and Information Technology</i>	1
<i>Promet - Traffic - Traffico</i>	1
<i>Transport Policy</i>	1
<i>Transportation Research Part E: Logistics and Transportation Review</i>	1

Em relação à abrangência temporal, verificou-se o interesse atual pelo tema. Dos 7 artigos avaliados, 2 foram publicados no ano de 2017. Os demais artigos foram publicados nos anos de 2016 (1), 2012 (1), 2011 (2) e 2010 (1).

Por fim, em relação ao sexto e último passo para seleção dos artigos, foram inseridos mais 4 artigos relevantes que abordam a previsão de frete de navios. Tsioumas et al. (2017), a despeito de tratarem da previsão de frete de cargas secas, foi considerado pela relevância do estudo ao buscar melhorar a precisão de um índice da BALTIC. Também pela importância do estudo, dos métodos e variáveis utilizadas na previsão do frete de curto, médio e longo prazo, o estudo de Li e Parsons (1997) também foi considerado.

Um artigo publicado também na *Maritime Economics and Logistics*, de Santos et al. (2014), foi considerado por tratar da previsão do valor de aluguel em contratos de 1 e 3 anos de navios petroleiros do tipo VLCC, relevante para esse estudo. A quarta referência inserida foi o trabalho de Geomelos e Xideas (2014), que numa abordagem ampla aplicou métodos univariados e multivariados para prever fretes de navios do tipo tanque e carga seca.

De posse dos artigos selecionados a partir da adaptação do processo proposto por Thomé et al. (2016), foi realizada uma síntese da literatura e uma análise descritiva dos resultados da revisão da literatura com objetivo específico de apresentar um resumo dos métodos e variáveis identificados na literatura para previsão de frete de navios-tanque.

### 3.1.1

#### Síntese da Literatura

Tsioumas et al. (2017) buscaram melhorar a precisão de previsão do BDI, índice BALTIC de cargas secas (BDI – *Baltic Dry Index*) por meio do desenvolvimento de um modelo multivariado de vetor auto-regressivo com variáveis exógenas (VARX). O modelo proposto incorpora a produção chinesa de aço, o desenvolvimento da frota de navios de carga seca e um novo indicador composto, o índice de ambiente econômico carga seca (DBECI – *Dry Bulk Economic Climate Index*).

A abordagem do estudo foi avaliada em relação a uma estrutura ARIMA univariada, que serviu como modelo de referência. Os resultados demonstram que o modelo VARX supera a abordagem ARIMA, sugerindo que as variáveis independentes selecionadas podem melhorar substancialmente a precisão das previsões do BDI.

Para refletir a natureza não estacionária e não linear da série de preços do mercado de frete de navios-tanque, bem como para promover a compreensão das características de volatilidade, Zhang e Zeng (2017) propuseram um método baseado em decomposição do modo empírico (EMD – *Empirical Mode Decomposition*) e BEKK– *Multivariate GARCH* (MVGARCH). A série temporal utilizada no estudo foi o índice BDTI da BALTIC, que é constituído por dezoito rotas representativas que envolvem as classes de navios Aframax, Suezmax e VLCC.

Numa abordagem ainda mais ampla do que a proposta por Zhang e Zeng (2017), Geomelos e Xideas (2014) aplicaram modelos multivariados (VAR e VECM) e modelos univariados (ARIMA, GARCH e E-GARCH) para prever o frete de cinco classes de navios-tanque e três classes de navios de carga seca.

Alizadeh e Talley (2011) utilizaram um modelo estimado para investigar características do navio e da viagem (tipos de casco, fator de utilização – relação entre a carga transportada e o DWT do navio, idade do navio, rota e indicador da condição do mercado de frete de navios-tanque) e os períodos de laycan (janela de tempo para chegada do navio) nos contratos de frete de navios-tanque. Também foi investigada a relação entre essas características e os períodos de laycan dos contratos de afretamento de navios-tanque. Após aplicação de testes para

investigação de simultaneidade, concluíram que o frete e o laycan estão inter-relacionados e devem ser modelados como um sistema de equações simultâneas. Outras conclusões do estudo: (i) Na média, as taxas frete de navios de casco simples apresentam um desconto em relação aos navios de casco duplo; (ii) as taxas fretes são positivamente e negativamente relacionadas ao comprimento do período de laycan e ao fator de utilização, respectivamente; (iii) taxa frete de navio-tanque e período de laycan variam de acordo com a rota; (iv) os períodos de laycan dos contratos de navios-tanque variam diretamente com as taxas frete e indiretamente com a volatilidade da taxa frete; e (v) períodos de laycan de navios-tanque estão negativamente relacionados com as idades dos navios.

Partindo do modelo de Alizadeh e Talley (2011), Adland, Cariou e Wolff (2016) agregaram, a partir de estudos de outros pesquisadores, a contribuição dos armadores, afretadores e suas interações na formação do frete.

Tvedt (2011) desenvolveu uma estrutura teórica, através de um modelo de atribuição, para obter o frete de curto prazo no mercado de VLCC. O modelo concentra-se em três principais agentes do mercado: o armador que é caracterizado pela distância de seu navio da área de carga, o proprietário da carga ou afretador que é caracterizado pelo custo da espera, e o corretor que é caracterizado por sua ambição de maximizar as comissões esperadas.

A formação da taxa frete foi estudada por Jurčević et al (2010) sob a ótica de sistemas dinâmicos e teoria do caos. O objetivo do trabalho foi enfatizar a importância do aspecto econômico da função de tráfego e da posição do frete na economia, bem como seus aspectos positivos e negativos. Os autores concluíram que a taxa frete é uma categoria econômica que pode aumentar a capacidade de embarque e afetar a saída de navio para demolição ou para lay-up (guardado / encostado - diz-se, por exemplo, quando o navio fica parado porque o frete não cobre os seus custos operacionais).

Li e Parsons (1997) investigaram a habilidade de predição das redes neurais artificiais para previsão de negócios marítimos. Foram desenvolvidas redes neurais utilizando séries temporais univariadas e multivariadas para previsão da taxa frete mensal de curto, médio e longo prazos. As variáveis utilizadas no estudo foram (i) taxa frete de navios-tanque de produtos escuros em uma rota do Mediterrâneo, (ii) demanda por navios-tanque e (iii) oferta de navios-tanque para o período de janeiro de 1980 a outubro de 1995. Para comparar os resultados das

redes neurais com uma técnica tradicional de previsão, modelos de séries temporais (média móvel auto-regressivo ou ARMA) foram derivados e os resultados das redes neurais se mostraram consistentemente superiores ao modelo ARMA, especialmente para previsão de médio e longo prazo.

Santos et al. (2014) verificaram o desempenho das redes neurais artificiais (RNA) como ferramenta de previsão para séries temporais de valor de aluguel em contratos de 1 e 3 anos de navios petroleiros do tipo VLCC. Foram utilizadas seis variáveis explicativas defasadas para construção do modelo preditivo de RNA: aluguel VLCC para TCP 1 ano e TCP 3 anos, taxa frete do mercado spot referente a rota do Golfo Pérsico para o Japão, valor de venda do navio para demolição, produção de petróleo mundial, entrega de novos navios por estaleiros e navios retirados da frota para demolição ou por perda. A RNA ofereceu consistentemente melhores previsões que o modelo elementar ARIMA.

Eslami et al. (2017) desenvolveram um modelo híbrido de previsão de frete de navios-tanque baseado em uma RNA e um algoritmo genético adaptativo (AGA). O modelo emprega três variáveis, produtividade da frota, preço do petróleo e preço do bunker e compara o desempenho do modelo híbrido com duas aproximações tradicionais, regressão e média móvel, bem como com as descobertas dos estudos de rede neural artificial. Também utilizando RNA, porém dessa vez combinada com um modelo de heteroscedasticidade condicional auto-regressiva, Ji, Zhang e Wang (2012) estudaram o preço do petróleo bruto na determinação da taxa frete no transporte marítimo e encontraram uma acurácia maior na previsão de frete de navios-tanque a partir do modelo combinado do que a partir da aplicação dos modelos individualmente.

### 3.1.2

#### **Análise descritiva dos resultados da revisão da literatura**

A tabela 4 apresenta uma síntese dos principais métodos e variáveis encontrados nos artigos analisados na revisão da literatura.

Tabela 4 – Métodos e variáveis identificados na literatura para previsão de frete de navios-tanque.

Autores	Ano	Métodos utilizados	Variáveis consideradas
Eslami P., Jung K., Lee D., Tjolleng A.	2017	Redes Neurais Artificiais (RNA) e Algoritmo Genético Adaptativo (AGA)	Preço do petróleo, produtividade da frota e preço do combustível do navio
Tsioumas V., Papadimitriou S., Smirlis Y., Zahran S. Z.	2017	Modelo multivariável de Vetor Auto-Regressivo com variáveis exógenas (VARX) e ARIMA	Produção chinesa de aço, o desenvolvimento da frota de navios de carga seca e o índice de ambiente econômico carga seca ( <i>DBECI - Dry Bulk Economic Climate Index</i> )
Zhang J., Zeng Q.	2017	Método de decomposição em modos empíricos (EMD) e modelo de heterocedasticidade condicional auto-regressiva (MVGARCH)	Série temporal da taxa frete (BDTI)
Adland R., Cariou P., Wolff F.- C.	2016	Modelo baseado na formulação de Alizadeh e Talley (2011), agregando a contribuição de armadores, afretadores e suas interações na formação do frete.	Características dos navios e da viagem (Alizadeh e Talley, 2011), com contribuições de armadores e afretadores
Geomelos N.D., Xideas E.	2014	Modelos multivariado (VAR e VECM) e modelos univariado (ARIMA, GARCH e E-	Frete <i>spot</i> , frete por período, preço do navio usado (5 anos), preço do navio novo, preço do

		GARCH)	navio para demolição, capacidade da frota, PIB mundial e movimentação marítima
Santos A. A. P., Junkes L. N., Pires Jr. F. C. M.	2014	Redes Neurais Artificiais (RNA) e ARIMA	Aluguel VLCC para TCP 1 ano e TCP 3 anos, frete <i>spot</i> da rota do Golfo Pérsico para o Japão, valor de venda do navio para demolição, produção de petróleo mundial, entrega de novos navios e navios retirados da frota
Ji M.-J., Zhang H.-Y., Wang Q.- B.	2012	Modelo de heterocedasticidade condicional auto-regressiva (ARCH) combinado com Redes Neurais Artificiais (RNA)	Séries temporais da taxa frete e preço do petróleo
Tvedt J.	2011	Modelo de Atribuição	Distância dos navios até as áreas de carga, momento em que os afretadores preferem contratar o frete que é caracterizado pelo custo de espera e percepção dos corretores
Alizadeh A.H., Talley W.K.	2011	Modelo estimado com base em características dos navios e da viagem	Tipos de casco, taxa de utilização da capacidade, idade do navio, rota, indicador do mercado de frete de navios-tanque e períodos de <i>laycan</i> dos

			contratos marítimos
Jurčević M., Mitrović F., Nadrljanski M.	2010	Sistema dinâmico e teoria do caos	Oferta e demanda no mercado de frete
Li J., Parsons M.	1997	Redes Neurais Artificiais (RNA) e ARMA	Taxa frete de navios-tanque de produtos escuros em uma rota do Mediterrâneo, demanda por navios-tanque e oferta de navios-tanque

(conclusão)

De forma similar ao que foi estudado por Tsioumas et al (2017), esse trabalho propõe avaliar a precisão do frete *spot* da rota BDTI TD15 publicada pela BALTIC Exchange a partir de um modelo de regressão dinâmica. O objetivo é permitir que outras informações sejam incluídas nos modelos e comparar os resultados do modelo de regressão dinâmica com os resultados dos modelos univariados, ARIMA e amortecimento exponencial.

## 3.2

### Métodos de Previsão

De acordo com Hyndman e Athanasopoulos (2016), amortecimento exponencial e os modelos ARIMA são as duas abordagens mais amplamente utilizadas para previsão de séries temporais.

Tanto o método de amortecimento exponencial como os modelos ARIMA permitem a inclusão de informações de observações passadas de uma série, mas não permitem a inclusão de outras informações que também podem ser relevantes. A inclusão de variáveis explicativas no modelo pode trazer ganhos em relação a sua capacidade preditiva. Tsioumas et al. (2017), por exemplo, demonstraram que a utilização de informações referentes a produção chinesa de aço, o desenvolvimento da frota de navios de carga seca e o índice de ambiente econômico carga seca melhoram substancialmente a acurácia da previsão do índice BALTIC de carga seca (BDI), quando comparada com a previsão a partir de um modelo ARIMA.

Serão apresentadas neste subitem a descrição e a formulação matemática do modelo de regressão dinâmica e, dado o vasto conhecimento dos métodos univariados, serão apresentadas somente suas principais características.

#### 3.2.1

### Regressão Dinâmica

Para Stellwagen e Goodrich (2011), a regressão dinâmica é um modelo de regressão que combina a dinâmica de séries temporais e os efeitos de variáveis explicativas. O modelo incorpora defasagens (*lags*) da variável dependente e

também defasagens das variáveis exógenas e do termo autoregressivo de erro (Hyndman e Athanasopoulos, 2016).

Segundo Barros e Souza (1995), ao se tentar modelar uma série temporal através de um modelo de regressão, a hipótese de independência dos ruídos não é realista, e os resultados e testes usados nos modelos de regressão não são válidos. Por exemplo, segundo os autores, algumas das consequências da autocorrelação dos resíduos são:

1) Os estimadores usuais por mínimos quadrados são ainda não tendenciosos, mas não têm variância mínima.

2) Os estimadores da variância e dos erros padrões dos coeficientes da regressão são subestimados, o que levaria à conclusão de que os estimadores são mais precisos do que na realidade.

3) Os intervalos de confiança para os parâmetros da regressão e os testes de hipóteses relacionados a estes intervalos perdem a validade, como uma consequência direta de 2).

Desta forma, estes três motivos implicam na necessidade de procurar procedimentos para tratar o problema de autocorrelação dos erros, pois ignorá-los leva, em geral, a inúmeras conclusões falsas.

Em particular, dado que a hipótese de independência dos erros não é realista no contexto de séries temporais, os modelos de regressão dinâmica estendem os modelos usuais de regressão ao levantarem esta restrição.

Na escolha do modelo apropriado, deve-se levar em consideração não apenas a significância dos parâmetros, mas também sua consistência com a teoria econômica. Por exemplo, a oferta de navios afeta o preço do frete. Uma oferta maior de navios no mercado de contratação de transporte marítimo tende a reduzir o preço do frete e vice-versa. Logo, se o modelo de regressão encontrado para explicar o frete pelo tamanho da frota apresenta coeficiente positivo para a variável frota, deve-se desconfiar por mais bem ajustado que esteja o modelo, porque, em geral, a relação sugerida pelo modelo não é coerente. Ou seja, na escolha de um modelo de regressão dinâmica, não é necessário apenas encontrar um ajuste de parâmetros adequado, mas fundamentalmente faz-se imprescindível verificar a coerência dos coeficientes estimados.

Segundo Goodrich (1989), modelos de regressão dinâmica devem ser usados quando existe uma estrutura de dependência entre a variável de interesse e variáveis causais e, ao mesmo tempo, quando a estrutura de correlação da série dependente indicar que não se pode supor a independência dos erros.

### 3.2.1.1

#### Estrutura do modelo

Os modelos de regressão dinâmica podem ser descritos pela equação 2:

$$\varphi(B)y_t = \beta x_t + a_t \quad (2)$$

onde:

$y_t$  = variável dependente no instante t

$\beta$  = vetor de coeficientes das variáveis causais, que será estimado por mínimos quadrados

$x_t$  = vetor de variáveis causais (exógenas) no instante t

$a_t$  = ruído aleatório associado ao modelo, onde supomos que os  $a_t$  são independentes e identicamente distribuídos com densidade  $N(0, \sigma^2)$

$\varphi(B)$  = polinômio autoregressivo de ordem p, isto é:

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \text{ sendo } B \text{ o operador de atraso}$$

A estrutura do modelo de regressão dinâmica permite considerar como elementos  $x_t$  tanto variáveis causais como também suas defasagens.

A presença do polinômio  $\varphi(B)$  no modelo traz uma grande flexibilidade desta classe de modelos, mas, ao mesmo tempo, dificulta a procura por um modelo adequado. Observa-se que, se  $\varphi(B) = 1$ , não existem defasagens da variável dependente e a interpretação do modelo é muito simples, pois as variáveis causais influenciam diretamente a variável endógena. Ao contrário, quando  $\varphi(B) \neq 1$ , o modelo pode ser usado para representar relações bastante complicadas.

O modelo de regressão dinâmica pode ser considerado um caso particular do que é conhecido na literatura como modelos de Cochrane e Orcutt generalizados.

### 3.2.1.2

#### Modelos de Regressão Cochrane e Orcutt Generalizados

O modelo de regressão generalizado de Cochrane e Orcutt (1949) é dado por:

$$\varphi(B)y_t = \beta x_t + w_t \quad (3)$$

$$R(B)w_t = a_t \quad (4)$$

onde  $R(B)$  é um polinômio auto-regressivo.

Pode-se notar que a equação 3 tem a mesma forma da equação 2 da regressão dinâmica, entretanto os erros  $w_t$  apresentam uma estrutura AR dada pela equação 4.

Este modelo, dado pelas equações 3 e 4, ainda pode ser descrito em termos de uma única equação como a seguir. Note que da equação 3:

$$w_t = \varphi(B)y_t - \beta x_t$$

Substituindo esta última expressão na equação 4 tem-se que:

$$R(B).(\varphi(B)y_t - \beta x_t) = a_t \quad (5)$$

Desta última expressão nota-se que o modelo de regressão generalizado de Cochrane e Orcutt introduz defasagens tanto na variável dependente ( $y_t$ ) quanto nas causais. A equação 5 indica também que a relação de causalidade entre  $y_t$  e  $x_t$  não é afetada pela introdução do polinômio autoregressivo  $R(B)$ .

Esta última equação pode ainda ser escrita em termos de novas variáveis  $y_t^*$  e  $x_t^*$  dadas por:

$$y_t^* = R(B).y_t \text{ e}$$

$$x_t^* = R(B).x_t$$

onde  $R(B)$  é chamado de “fator comum” e representa a estrutura de correlação presente no erro  $w_t$ .

A equação obtida então com estas novas variáveis é:

$$\varphi(B)y_t^* = \beta x_t^* + a_t \quad (6)$$

Logo, o modelo de regressão generalizado de Cochrane e Orcutt reduz-se ao modelo de regressão dinâmica usual ao se considerar as novas variáveis  $y_t^*$  e  $x_t^*$ . O modelo original de Cochrane e Orcutt tem como fator comum  $R(B) = 1 - \alpha B$  e então a equação 6 reduz-se a:

$$\varphi(B) \cdot [y_t - \alpha y_{t-1}] = \beta \cdot [x_t - \alpha x_{t-1}] + a_t \quad (7)$$

Salienta-se que, neste modelo, o procedimento de estimação é sequencial. A estimativa inicial de  $\alpha$  é 0, e a partir dela são estimados  $\beta$  e  $\varphi(B)$  por mínimos quadrados ordinários. A partir destas estimativas encontra-se um estimador de  $R(B)$  através da equação  $R(B)w_t = a_t$ . O polinômio estimado  $R(B)$  é então usado para transformar  $y_t$  e  $x_t$  e reestimar  $\beta$  e  $\varphi(B)$ . O processo é repetido até que se alcance a convergência dos parâmetros.

### 3.2.1.3

#### **Estratégia de modelagem para modelos de Regressão Dinâmica**

A estratégia usualmente empregada para construir um modelo de regressão dinâmica é a estratégia *bottom-up*. Basicamente, parte-se de um modelo simples, com poucas variáveis, refina-o e inclui novas variáveis até encontrar um modelo apropriado. Às vezes, no entanto, o impacto de uma variável incluída em modelo de regressão dinâmica não será simples e imediato (Hyndman e Athanasopoulos, 2016). Por isso, a construção de um modelo de regressão dinâmica é muitas vezes um procedimento difícil, porque além de escolher as variáveis a serem incluídas no modelo, também é necessário definir os *lags* (defasagens) destas variáveis.

As previsões geradas por um modelo de regressão dinâmica dependem não só de valores passados da própria série, mas também dos valores previstos para as variáveis causais. Logo, para se obter as previsões da série  $y_t$  para  $t+1$ ,  $t+2$ ,  $t+3$ , etc, é necessário fornecer ao modelo os valores futuros do vetor de variáveis causais  $x_t$ . Logo, as previsões destas variáveis causais devem ser adequadas para que o modelo de regressão dinâmica não gere valores futuros para  $y_t$  inadequados. Por outro lado, esta condição possibilita a criação de cenários

futuros para as variáveis causais, possibilitando analisar os possíveis valores futuros da variável de interesse em diversas condições.

Diferentemente dos modelos univariados, onde a sazonalidade e os ciclos são fenômenos limitados à variável dependente, no modelo de regressão dinâmica, a sazonalidade e os ciclos podem ser tratados de forma muito flexível e distinta, vinculada a uma ou mais variáveis, endógenas ou exógenas, através das defasagens. Não obstante, a sazonalidade e os ciclos também podem ser introduzidos através de variáveis *dummy*. Esta flexibilidade se traduz em grande potencial de adaptação às condições e/ou expectativas para a construção e análise do modelo funcional.

#### 3.2.1.4

#### Testes estatísticos utilizados nos modelos de Regressão Dinâmica

Diversos testes estatísticos podem ser utilizados para mensurar o grau de adequação de um modelo de regressão dinâmica. Estes testes, que são em sua grande maioria variantes dos testes de Multiplicadores de Lagrange e baseados na distribuição Qui-Quadrado (Barros e Souza, 1995), são aplicados em diversos estágios da modelagem da série. Tem-se, por exemplo:

- 1) testes com o objetivo de definir a especificação do modelo explicativo;
- 2) testes visando encontrar a dinâmica do modelo, isto é, a inclusão ou não de variáveis defasadas;
- 3) testes para verificar o ajuste do modelo.

Serão abordados, de uma forma geral, quais são, na prática, os procedimentos para que os testes sejam realizados, segundo Goodrich (1989).

Primeiramente, menciona-se os testes utilizados para a verificação da “dinâmica” do modelo.

A dinâmica de um modelo acontece através das defasagens da variável dependente e/ou através da presença de erros estruturados num modelo de Cochrane-Orcutt. A cada momento da elaboração do modelo, são realizados testes de hipóteses (Dudewicz e Mishra, 1988) sobre a “dinâmica” do modelo.

Em todos os casos a seguir, a hipótese nula afirma que a dinâmica do modelo está corretamente especificada, ou seja, a inclusão de outras defasagens da variável dependente ou outros erros estruturados não é necessária. A hipótese alternativa representa, em cada caso, a necessidade de inclusão de novos termos. Sendo assim se tem:

a) Teste de defasagem da variável endógena

Suponha que a variável dependente  $y_t$  e suas defasagens  $y_{t-1}, y_{t-2}, \dots, y_{t-p-1}$  estejam presentes no modelo atual. A hipótese alternativa consiste em adicionar a variável defasada  $y_{t-p}$  ao modelo, isto é, adiciona-se a primeira defasagem ainda não presente no modelo atual. Se esta variável for considerada significativa, a hipótese nula é rejeitada e deve-se adicionar a variável  $y_{t-p}$  ao modelo.

b) Teste da defasagem sazonal da variável endógena

Este teste é semelhante ao anterior. A hipótese alternativa consiste em adicionar ao modelo atual a variável defasada até a primeira defasagem sazonal  $y_{t-pS}$  ainda não presente ao modelo. Se o coeficiente de  $y_{t-pS}$  for significativo, esta variável deve ser incluída no modelo e a hipótese nula deve ser rejeitada.

c) Teste da sequência de defasagens da variável endógena

A hipótese alternativa consiste em adicionar todas as defasagens da variável dependente que ainda não estão presentes no modelo.

d) Teste da defasagem dos resíduos

A hipótese alternativa consiste em adicionar ao modelo o primeiro termo defasado  $a_{t-p}$  ainda não incluído no modelo.

e) Teste da defasagem sazonal dos resíduos

Na hipótese alternativa adiciona-se ao modelo atual a primeira defasagem sazonal  $a_{t-pS}$  ainda não presente no modelo.

Depois de mencionar os testes para a verificação da dinâmica do modelo, o próximo teste serve para a especificação correta das variáveis causais.

O objetivo destes próximos testes é verificar se a inclusão de uma ou mais variáveis ainda não contempladas no modelo resulta numa melhora do ajuste.

a) Teste das variáveis causais excluídas

Neste teste verifica-se a necessidade de inclusão de cada uma das variáveis (escolhidas previamente para análise), mas que ainda não estão presentes no modelo. Se quaisquer destas variáveis são consideradas significantes, deve-se incluí-las no modelo (talvez sequencialmente) e “rodar” a mesma bateria de testes para verificar se a inclusão foi vantajosa.

b) Teste da defasagem das variáveis causais

Na hipótese alternativa inclui-se uma defasagem adicional das variáveis causais já presentes no modelo.

Por último, testa-se a presença de autocorrelação na série de resíduos. Podem ser feitos ainda testes para verificar a existência de variações na variância dos resíduos, ou seja, procura-se detectar a heterocedasticidade de resíduos.

O processo de construção de um modelo de regressão dinâmica deve levar conta diversos diagnósticos com o objetivo de verificar se o modelo proposto é apropriado. Em particular, deve-se sempre examinar o gráfico das autocorrelações dos resíduos. Se estas são significantes para algumas defasagens, alguma característica da variável dependente não foi capturada pelo modelo proposto. Por exemplo, no caso de dados mensais, se a autocorrelação dos resíduos é significante no *lag* 12, a observação situada num período genérico  $t-12$  meses é relevante para explicar a observação no período  $t$  e sua inclusão no modelo possivelmente resultará num decréscimo dos erros de previsão do modelo.

Segundo Barros e Souza (1995), a existência de autocorrelações significantes nos resíduos pode então indicar uma das seguintes situações: 1) deve-se incluir mais defasagens da variável dependente ou 2) deve-se incluir defasagens adicionais das variáveis exógenas já presentes no modelo ou incluir novas variáveis causais.

### 3.2.2

#### Amortecimento Exponencial

As previsões produzidas usando métodos de amortecimento exponencial são geradas com base em médias ponderadas de observações passadas, com os pesos decaindo exponencialmente à medida que as observações se afastam do tempo que está sendo previsto. Por isso, quanto mais recente a observação, maior o peso associado, ou maior o impacto da observação para a previsão, enquanto que observações mais antigas possuem um peso menor. Essa estrutura gera previsões confiáveis rapidamente e para um amplo espectro de séries temporais, o que é uma grande vantagem e de grande importância para aplicações na indústria.

A seleção do método é geralmente baseada no reconhecimento das componentes de tendência e sazonalidade da série temporal em estudo e como elas entram no método de amortecimento (de forma aditiva ou multiplicativa). A tabela 5 representa a classificação das componentes e a tabela 6 apresenta as equações para cada estado das componentes do método.

Tabela 5 – Classificação do método de amortecimento exponencial.

Componente de tendência	Componente Sazonal		
	N (Nenhum)	A (Aditivo)	M (Multiplicativo)
N (Nenhum)	N, N	N, A	N, M
A (Aditivo)	A, N	A, A	A, M
A <sub>a</sub> (Aditivo amortecido)	A <sub>a</sub> , N	A <sub>a</sub> , A	A <sub>a</sub> , M
M (Multiplicativo)	M, N	M, A	M, M
M <sub>a</sub> (Multiplicativo amortecido)	M <sub>a</sub> , N	M <sub>a</sub> , A	M <sub>a</sub> , M

Fonte: adaptado de Hyndman & Athanasopoulos, 2014.

Tabela 6 – Equações para os possíveis métodos de amortecimento exponencial.

Componente de Tendência	Componente Sazonal		
	N (Nenhum)	A (Aditivo)	M (Multiplicativo)
N (Nenhum)	$\hat{y}_{t+h/t} = l_t$ $l_t = \alpha y_t + (1 - \alpha)l_{t-1}$	$\hat{y}_{t+h/t} = l_t + s_{t-m+h_m^+}$ $l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)l_{t-1}$ $s_t = \gamma(y_t - l_{t-1}) + (1 - \gamma)s_{t-m}$	$\hat{y}_{t+h/t} = l_t s_{t-m+h_m^+}$ $l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)l_{t-1}$ $s_t = \gamma(y_t/l_{t-1}) + (1 - \gamma)s_{t-m}$
A (Aditivo)	$\hat{y}_{t+h/t} = l_t + hb_t$ $l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1}$	$\hat{y}_{t+h/t} = l_t + hb_t + s_{t-m+h_m^+}$ $l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}$	$\hat{y}_{t+h/t} = (l_t + hb_t)s_{t-m+h_m^+}$ $l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1}$ $s_t = \gamma(y_t/(l_{t-1} + b_{t-1})) + (1 - \gamma)s_{t-m}$
A <sub>a</sub> (Aditivo Amortecido)	$\hat{y}_{t+h/t} = l_t + \phi_h b_t$ $l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1}$	$\hat{y}_{t+h/t} = l_t + \phi_h b_t + s_{t-m+h_m^+}$ $l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - \phi b_{t-1}) + (1 - \gamma)s_{t-m}$	$\hat{y}_{t+h/t} = (l_t + \phi_h b_t)s_{t-m+h_m^+}$ $l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1}$ $s_t = \gamma(y_t/(l_{t-1} + \phi b_{t-1})) + (1 - \gamma)s_{t-m}$

Tabela 6 – Equações para os possíveis métodos de amortecimento exponencial.

(conclusão)

M (Multiplicativo)	$\hat{y}_{t+h/t} = l_t b_t^h$ $l_t = \alpha y_t + (1 - \alpha) l_{t-1} b_{t-1}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}$	$\hat{y}_{t+h/t} = l_t b_t^h + s_{t-m+h_m^+}$ $l_t = \alpha (y_t - s_{t-m}) + (1 - \alpha) l_{t-1} b_{t-1}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}$ $s_t = \gamma (y_t - l_{t-1} b_{t-1}) + (1 - \gamma) s_{t-m}$	$\hat{y}_{t+h/t} = l_t b_t^h s_{t-m+h_m^+}$ $l_t = \alpha (y_t / s_{t-m}) + (1 - \alpha) l_{t-1} b_{t-1}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}$ $s_t = \gamma (y_t / (l_{t-1} b_{t-1})) + (1 - \gamma) s_{t-m}$
M <sub>a</sub> (Multiplicativo amortecido)	$\hat{y}_{t+h/t} = l_t b_t^{\phi h}$ $l_t = \alpha y_t + (1 - \alpha) l_{t-1} b_{t-1}^{\phi}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}^{\phi}$	$\hat{y}_{t+h/t} = l_t b_t^{\phi h} + s_{t-m+h_m^+}$ $l_t = \alpha (y_t - s_{t-m}) + (1 - \alpha) l_{t-1} b_{t-1}^{\phi}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}^{\phi}$ $s_t = \gamma (y_t - l_{t-1} b_{t-1}^{\phi}) + (1 - \gamma) s_{t-m}$	$\hat{y}_{t+h/t} = l_t b_t^{\phi h} s_{t-m+h_m^+}$ $l_t = \alpha (y_t / s_{t-m}) + (1 - \alpha) l_{t-1} b_{t-1}^{\phi}$ $b_t = \beta^* (l_t / l_{t-1}) + (1 - \beta^*) b_{t-1}^{\phi}$ $s_t = \gamma (y_t / (l_{t-1} b_{t-1}^{\phi})) + (1 - \gamma) s_{t-m}$

Em cada caso,  $l_t$  denota o nível,  $b_t$  denota a tendência e  $s_t$  denota a componente sazonal no período  $t$ ,  $m$  denota a sazonalidade em um ano;  $\alpha, \beta, \gamma$  e  $\phi$  são parâmetros do amortecimento,  $\phi_h = \phi + \phi^2 + \dots + \phi^h$  e  $h_m^+ = [(h - 1) \text{mod } m] + 1$ .

Fonte: adaptado de Hyndman & Athanasopoulos, 2014.

Em Hyndman & Athanasopoulos (2014) podem ser encontrados maiores detalhes sobre o método de amortecimento exponencial.

### 3.2.3

#### Modelagem auto-regressiva integrada de média móvel (ARIMA)

Os modelos ARIMA, também conhecidos como modelos de Box & Jenkins (2016) ou modelos auto regressivos integrado de médias móveis, fornecem outra abordagem para a previsão de séries temporais. Enquanto os modelos de amortecimento exponencial são baseados em uma descrição de tendência e sazonalidade nos dados, os modelos ARIMA visam descrever as autocorrelações nos dados.

Os modelos ARIMA têm como pressuposto que o processo a ser modelado é estacionário de segunda ordem, ou seja, a média e variância são constantes ao longo do tempo, e a correlação depende somente da defasagem entre as observações.

Se baseiam na estrutura da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP) da série temporal aqui representada por  $Z_t$ , nas quais são identificados os parâmetros  $q$  (referente à média-móvel) e  $p$  (referente à parte auto regressiva) do modelo, respectivamente.

No modelo auto-regressivo (AR), a variável de interesse é modelada de acordo com uma combinação linear de seus valores passados e pelo ruído aleatório  $a_t$ , conforme segue abaixo:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (8)$$

onde os parâmetros  $\phi_i$  são responsáveis por descrever como  $Z_t$  relaciona-se com o valor  $Z_{t-i}$ , sendo  $i = 1, 2, \dots, p$ .

No modelo de médias móveis (MA), ao invés de usar os valores passados da variável de previsão, utiliza-se os erros de previsão anteriores, ou seja, a série é modelada através da combinação dos ruídos  $a$  defasados.

$$Z_t = a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (9)$$

onde os parâmetros  $\theta_i$  descrevem como  $Z_t$  relaciona-se com o valor de  $a_{t-i}$ , onde  $i = 1, 2, \dots, q$ .

Uma série temporal estacionária é aquela cujas propriedades não dependem do tempo em que a série é observada. Assim, séries temporais com tendências, ou com sazonalidade, não são estacionárias - a tendência e a sazonalidade afetarão o valor da série temporal em tempos diferentes. Por outro lado, uma série de ruído branco é estacionária - não importa quando você a observa, ela deve ter a mesma aparência em qualquer momento (Hyndman e Athanasopoulos, 2016).

Quando a série temporal em estudo não é estacionária, primeiramente é necessário integrá-la até que a mesma se torne estacionária. Para tal, a série é transformada através de diferenças sucessivas. O número de diferenças necessárias para tornar a série de dados estacionários representa o valor do parâmetro de integração  $d$ . A primeira diferença pode ser representada por:

$$\nabla Z_t = Z_t - Z_{t-1}$$

onde  $\nabla = (1 - B)$  é o operador diferença.

Surgem então os modelos ARIMA (p,d,q), que assumem a seguinte forma:

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (10)$$

Para assegurar a condição de estacionariedade de um conjunto de dados é possível utilizar-se de diversas ferramentas estatísticas, tais quais a Estatística Q de Box-Pierce, Estatística de Ljung-Box e o teste Aumentado de Dick-Fuller (ADF).

Os processos encontrados na prática, além de raramente serem estacionários, apresentam muitas vezes componentes sazonais. Os modelos sazonais são conhecidos como SARIMA, ou ARIMA multiplicativo e têm uma formulação semelhante à dos modelos ARIMA:

$$\Phi(B^S)\phi(B)\nabla_S^D\nabla^d Z_t = \Theta(B^S)\theta(B)a_t \quad (11)$$

onde  $\Phi$  e  $\theta$  são os parâmetros referentes à sazonalidade, e  $D$  o parâmetro que representa o total de diferenças sazonais necessárias para tornar a série estacionária na sazonalidade.

Maiores detalhes sobre os modelos ARIMA podem ser encontrados em Souza & Camargo (2004).

### 3.3

#### Métricas de Desempenho

Nesta seção serão apresentadas as métricas que serão utilizadas para comparar o desempenho do modelo de regressão dinâmica com o desempenho dos modelos univariados ARIMA e amortecimento exponencial.

A métrica MAPE, do inglês *Mean Absolute Percentage Error*, ou Erro Médio Absoluto Percentual é uma das métricas mais utilizadas na literatura de métodos de previsão, pois fornece resultado em percentual.

O MAPE é calculado pela diferença entre os valores estimados e os valores reais. É usado tanto para avaliação *in-sample* como *out-of-sample*. A métrica é dada por:

$$MAPE = \frac{1}{n} \cdot \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \cdot 100 \quad (12)$$

sendo  $y_t$  o valor da série temporal no período  $t$ ,  $\hat{y}_t$  o valor estimado pelo modelo para o período  $t$  e  $n$  o tamanho da amostra.

O BIC, do inglês *Bayesian Information Criteria*, desenvolvido por Schwarz (1978), é um critério de seleção de modelos entre uma classe de modelos paramétricos com diferentes números de parâmetros.

O critério de informação recompensa a qualidade do ajuste, medida pelo erro quadrático médio  $s$ , e penaliza por complexidade, ou seja, pelo número de parâmetros  $n$ . O BIC pode ser representado pela seguinte equação:

$$BIC = sT^{n/2T} \quad (13)$$

onde  $T$  representa o tamanho da amostra.

Um modelo específico é selecionado de uma família de modelos encontrando aquele que minimiza o BIC.

## 4

### Resultados

Este capítulo tem como objetivo apresentar os resultados das aplicações das abordagens de previsão apresentadas no Capítulo 3. Está organizado em 4 seções, nas quais serão apresentadas, respectivamente, a aplicação do modelo de regressão dinâmica, a aplicação dos modelos univariados, a comparação dos resultados da aplicação desses modelos utilizando-se as métricas de desempenho, bem como a comparação dos resultados dos modelos estatísticos com um método de previsão de uma grande empresa de petróleo e, por fim, uma análise de cenários a partir da modelagem por regressão dinâmica.

#### 4.1

##### Aplicação do modelo de regressão dinâmica

Como visto no subitem 3.2.1., a regressão dinâmica é um modelo de regressão que combina a dinâmica de séries temporais e os efeitos de variáveis explicativas.

No escopo deste trabalho foi utilizada a seguinte série temporal para implementação dos modelos de previsão:

- Série mensal entre Janeiro/2010 a Junho/2018 (102 observações) da taxa frete (WS) de navios petroleiros do tipo VLCC para a rota do Oeste da África para a China, reportada pela BALTIC Exchange como BDTI TD15.

A série acima mencionada foi extraída do banco de dados *Shipping Intelligence Network* da Clarksons, com sede em Londres e considerada uma empresa de referência no mercado de navegação.

De acordo com a equação 1 apresentada no capítulo 2, o frete de navios petroleiros é calculado a partir da multiplicação da taxa frete (WS) pelo *flat rate* (US\$/t) e pelo lote (t). Dado que o flat rate é atualizado anualmente pela *Wordscale*, a série em estudo foi ajustada com base no *flat rate* de 2018, ou seja, para cada uma das 12 observações de cada ano da série foi aplicado um ajuste que corresponde ao valor do *flat rate* do ano da observação dividido pelo *flat rate* de

2018. Com esse ajuste é garantido que as previsões geradas estarão baseadas nas taxas frete referentes ao *flat rate* do ano de 2018.

A representação gráfica da série TD15 ajustada com base no *flat rate* de 2018 encontra-se abaixo na figura 4.

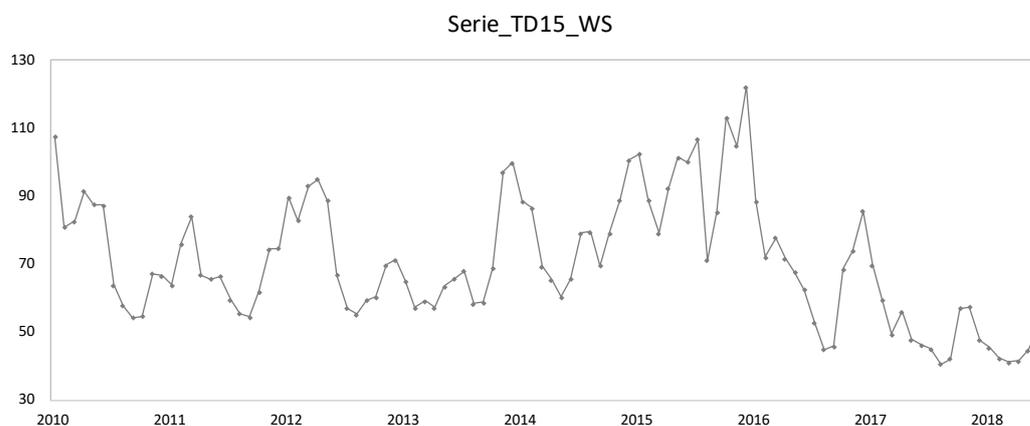


Figura 4 – Gráfico da série TD15 em WS de janeiro de 2010 a junho de 2018.

É importante destacar que todas as aplicações foram realizadas considerando a transformação logarítmica, em ambos os lados da equação, usualmente conhecida como log-log. Para maiores detalhes, ver Zanini (2000). Foi utilizado o *Forecast Pro for Windows* versão 3.50 (Stellwagen e Goodrich, 2011) para aplicação dos métodos de previsão.

Para seleção das variáveis explicativas a serem testadas no modelo de regressão dinâmica, a partir da avaliação crítica da influência de possível variável independente sobre a variável dependente, foram avaliadas aquelas utilizadas em estudos anteriores, conforme tabela 4 da seção 3.1, referente a revisão da literatura. Não obstante, o processo de construção do modelo de regressão dinâmica passa pela identificação das variáveis que melhor se adequam ao modelo.

Tabela 7 – Variáveis testadas no modelo de regressão dinâmica.

Variável	Unidade
Taxa Frete TD15 (Variável Dependente)	WS
Produção de Petroleo Mundial	MMbbls/dia
Importação de Petroleo China	MMbbls/dia
Importação de Petroleo Japão	MMbbls/dia
Importação de Petroleo EUA	MMbbls/dia
Frota VLCC	MMdwt
Valor de venda de navio para demolição (sucata)	MMUS\$
Preço do bunker	US\$/tm
Preço Petroleo Brent	US\$/bbl

bbls = barris; bunker = combustível do navio; dwt = unidade que expressa o porte do navio em "toneladas de peso morto"; tm = tonelada métrica; WS = Worldscale

As variáveis testadas no modelo estão apresentadas na tabela 7. Quanto a escolha das variáveis, destaca-se que a produção de petróleo mundial pode desencadear maior comercialização e movimentação desse produto, que por sua vez aumenta a demanda por transporte. Nesse sentido, espera-se que seja positiva a relação entre a produção de petróleo mundial e o frete. Santos et al. (2014) também utilizaram a produção de petróleo mundial como variável explicativa do valor do aluguel do VLCC para TCP 1 ano e TCP 3 anos.

A despeito de não aparecerem entre as variáveis identificadas na revisão da literatura, a importação de petróleo da China, Japão e Estados Unidos foram testadas neste estudo por representarem a demanda de três dos principais importadores de petróleo do mundo.

Por sua vez, a frota de navios foi utilizada nos estudos de Geomelos e Xideas (2014), Tsioumas et al. (2017) e Li e Parsons (1997). A frota mundial de VLCC é usada como a medida da oferta de navios e foi considerada a frota em milhões de *dwt*, unidade que expressa o porte do navio e melhor representa a capacidade da frota do que simplesmente considerar a quantidade de navios.

Foi testado o valor de venda do navio para demolição como variável explicativa, assim como Geomelos e Xideas (2014) e Santos et al. (2014) consideraram em seus trabalhos.

Assim como Eslami et al. (2017) considerou o valor do *bunker* para prever a taxa frete do VLCC na rota de Ras Tanura para Rotterdam, neste estudo também foi testado o valor do *bunker* como variável. Foi escolhido o *bunker* de Cingapura por se tratar de uma região típica de abastecimento de navios e que fica ao longo da rota avaliada, entre o oeste da África e a China. Por fim, o preço do petróleo Brent, que fez parte dos estudos de Eslami et al. (2017) e Ji, Zhang e Wang (2012), também foi testado como variável explicativa.

Assim como a série da variável dependente, todas as séries das variáveis independentes foram extraídas na base mensal do banco de dados *Shipping Intelligence Network* da Clarksons. Os dados referentes aos meses de abril, maio e junho de 2018 das variáveis produção de petróleo mundial e importação da China e referente ao mês de junho de 2018 da variável importação de petróleo EUA foram estimados utilizando-se o método de amortecimento exponencial, porque, no momento do estudo, ainda não haviam sido divulgados pela Clarksons.

Vale reiterar que as aplicações de regressão dinâmica foram realizadas considerando a forma log-log. Um dos motivos é poder fazer a leitura dos coeficientes de regressão na forma de coeficientes de elasticidade.

Para construir o modelo de regressão dinâmica, empregou-se a estratégia *bottom-up*, ou seja, partiu-se de um modelo simples, com apenas poucas variáveis e foi refinando-o, incluindo novas variáveis, avaliando as defasagens tanto da variável dependente como das variáveis explicativas, até encontrar um modelo apropriado.

Foi encontrado um modelo que apresentou ajuste adequado dos parâmetros estimados, coerência dos sinais dos coeficientes encontrados e resíduos com característica de ruído branco, ou seja, independentes e identicamente distribuídos.

A tabela 8 apresenta um resumo dos resultados estatísticos desse modelo.

Tabela 8 – Modelo de Regressão Dinâmica com ajustes adequados.

<b>Modelo de Regressão Dinâmica</b>	
MAPE ( <i>in sample</i> )	0,0940
BIC	8,8580
R <sup>2</sup> Ajustado	0,7881
Ljung-Box (18)	p=0,878
<b>Termos</b>	<b>Coefficientes</b>
Ln(TD15[-1])	0,83
Ln(TD15[-2])	-0,26
Ln(Prod Petroleo Mundial)	3,35
Ln(Importação Petroleo EUA)	-0,40
Ln (Frota VLCC Dwt)	-2,42

O teste de Ljung-Box testa a hipótese de que os resíduos não apresentam autocorrelação serial. O FPW testa a significância das correlações nos primeiros 18 *lags*. A tabela 8 apresenta o resultado deste teste para o modelo de regressão dinâmica escolhido e pode-se observar que a série de resíduos apresentou um p-valor alto, maior do que o nível de significância usual de 0,05. Dessa forma, não se rejeita a hipótese nula de que os resíduos têm características de um ruído branco. Não obstante, a figura 5 corrobora com o teste de Ljung-Box através da FAC *Error* (Função de Autocorrelação de Erros) desse modelo.

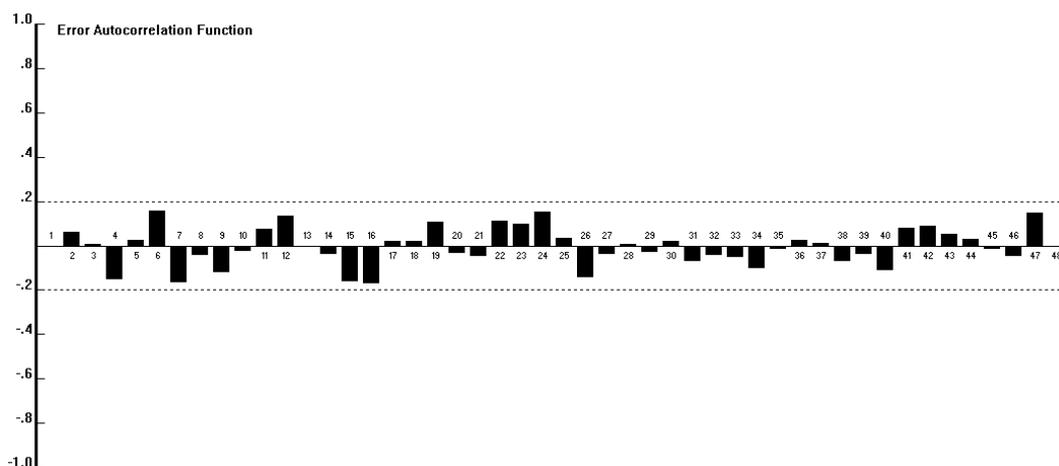


Figura 5 – Função de Autocorrelação de Erros (FAC *Error*) – Modelo de Regressão Dinâmica.

Na escolha do modelo apropriado, deve-se levar em consideração não apenas a significância dos parâmetros, mas também sua consistência com a teoria econômica. Por exemplo, a frota de navios afeta o preço do frete. Uma frota maior de navios no mercado de contratação de transporte marítimo tende a reduzir o preço do frete e vice-versa. Nesse sentido, o modelo escolhido, além de apresentar resíduos com características de um ruído branco, as variáveis que entraram no modelo são significantes e os coeficientes estimados apresentam coerência:

- A relação do TD15 com a variável produção mundial de petróleo é positiva, ou seja, quanto maior a produção, maior o valor do frete.
- Quanto a variável frota VLCC, a relação é negativa, pois quanto maior a frota (oferta de capacidade), menor o frete e vice e versa.
- A importação dos EUA também estabelece uma relação negativa com o valor do frete, pois quanto maior essa variável, maior a disponibilidade de navios no Atlântico, ou seja, maior a quantidade de navios desejando retornar para a região do Oriente Médio (principal região de exportação de petróleo). Isto posto, conseguir uma carga do Oeste da África para a China é uma oportunidade para o armador de percorrer parte da viagem de retorno carregado, o que normalmente é feito sem carga (em lastro). Sendo assim, é oportuno para os armadores oferecerem um frete com desconto na rota que está sendo analisada.

- Por fim, as defasagens da variável dependente podem ser explicadas pelo tempo de ciclo da viagem, que em média é de aproximadamente 64 dias. O coeficiente negativo do TD15 em  $t - 2$  deve-se ao fato de o período para o navio se reposicionar na área de carga ser de aproximadamente 2 meses, ou seja, o tempo necessário para o navio ser ofertado novamente ao mercado. De forma análoga, o coeficiente positivo da variável dependente defasada em 1 mês é explicado pela indisponibilidade de navios na área de carga até que o tempo de ciclo da viagem seja concluído.

Tendo em vista que o modelo de regressão dinâmica apresentou bons ajustes e consistência com a teoria econômica, partiu-se para a avaliação do seu desempenho fora da amostra.

Como visto anteriormente, para se obter previsões por um modelo de regressão dinâmica é necessário fazer primeiro as previsões das variáveis causais que compõem o modelo. Isso quer dizer que para se obter previsões da série  $y_t$  para  $t+1$ ,  $t+2$ ,  $t+3$ , etc, é necessário fornecer ao modelo os valores futuros do vetor de variáveis causais  $x_t$ .

Portanto, o primeiro passo para calcular o MAPE *out-of-sample* do modelo foi prever as variáveis causais selecionadas para o modelo, a saber: (i) produção de petróleo mundial, (ii) importação de petróleo EUA e (iii) frota VLCC.

As representações gráficas das previsões das variáveis causais encontram-se nas figuras 6, 7 e 8, respectivamente para a produção de petróleo mundial, importação de petróleo EUA e frota VLCC. O trecho sinalizado em vermelho representa a previsão encontrada através da aplicação do método de amortecimento exponencial, para o período de julho de 2017 a junho de 2018.

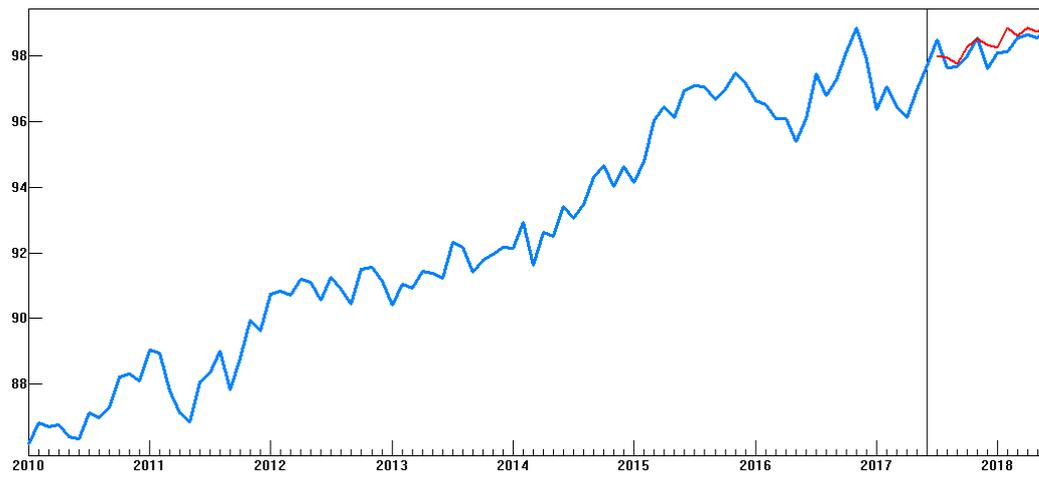


Figura 6 – Previsão da variável causal produção mundial de petróleo (MMbbls/dia).

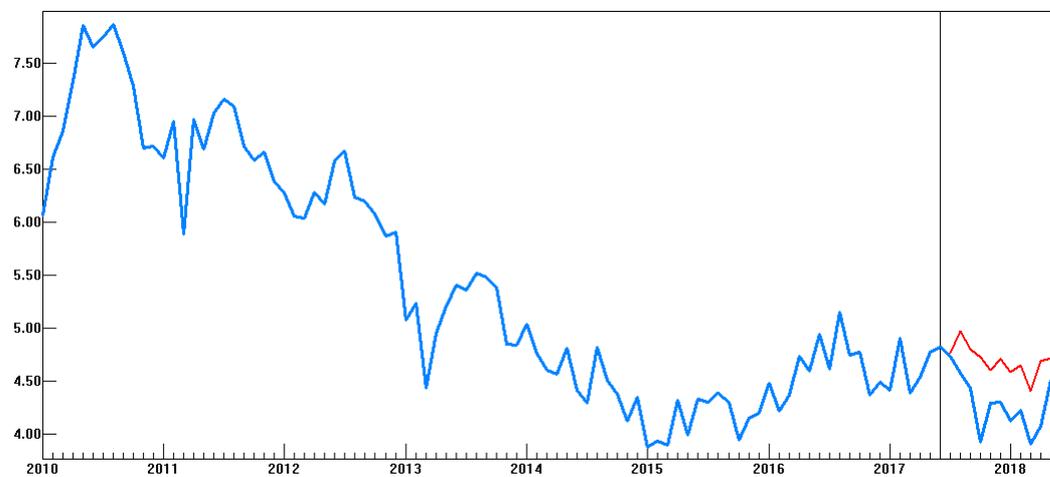


Figura 7 – Previsão da variável causal importação de petróleo EUA (MMbbls/dia).

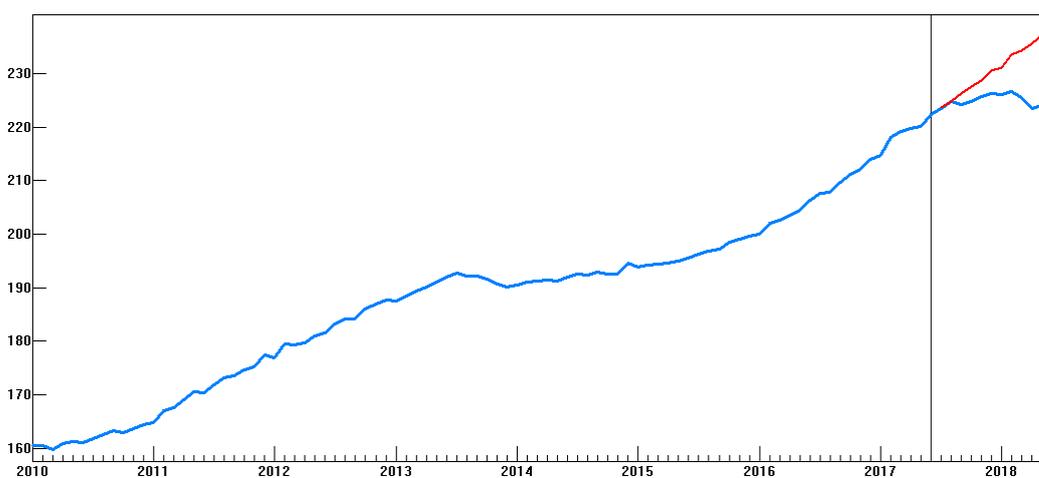


Figura 8 – Previsão da variável causal frota VLCC (MMdw).

De posse das previsões das variáveis causais, foi calculado o desempenho do modelo de regressão dinâmica fora da amostra e os resultados para o horizonte de previsão de 1 a 12 meses encontram-se na tabela 9.

Importante destacar que apesar de terem sido previstas as variáveis causais para avaliação do desempenho do modelo de regressão dinâmica fora da amostra, o ideal é que essas previsões sejam obtidas através de empresas especializadas, como a Administração de Informação de Energia dos Estados Unidos (EIA, 2018), que pode fornecer previsões para a produção de petróleo mundial, como também para as importações de petróleo dos EUA. A PIRA (PIRA,2018), empresa do grupo S&P Global Platts, uma das empresas líderes na análise mundial de energia também pode fornecer previsões para as variáveis produção mundial de petróleo e importação de petróleo EUA. A previsão da frota de navios VLCC, por sua vez, pode ser obtida através da Drewry Shipping Consultants Limited. (DREWRY, 2018), uma das principais empresas independentes, provedora de serviços de pesquisa e consultoria para a indústria marítima.

Tabela 9 – Desempenho do modelo de regressão dinâmica fora da amostra.

<b>MAPE <i>out-of-sample</i></b>			
<b>H</b>	<b>N</b>	<b>Modelo de Regressão Dinâmica</b>	
		<b>MAPE (%)</b>	<b>MAPE Acumulado (%)</b>
1	12	7,0%	7,0%
2	11	11,3%	9,1%
3	10	9,9%	9,3%
4	9	9,1%	9,3%
5	8	8,3%	9,1%
6	7	7,4%	8,9%
7	6	8,4%	8,9%
8	5	9,8%	8,9%
9	4	10,5%	9,0%
10	3	10,8%	9,1%
11	2	13,3%	9,2%
12	1	20,9%	9,4%

Nota: H = horizonte; N = Número de previsões

Como pode ser observado pela tabela 9, o modelo apresentou capacidade preditiva *out-of-sample* satisfatória, principalmente para as previsões de curto prazo. Chama-se atenção para o MAPE de 7% para o horizonte de 1 mês, resultado muito positivo para uma série de preços de frete e para o fato de que o desempenho do modelo de regressão dinâmica poderia ter sido ainda melhor caso fossem utilizadas previsões das variáveis causais de empresas especializadas.

O modelo de regressão dinâmica possui a seguinte equação:

$$\ln(Z)_t = 3,35 \ln(\text{prod petroleo mundial})_t - 2,42 \ln(\text{frota VLCC})_t \quad (14) \\ - 0,40 \ln(\text{imp petroleo EUA})_t + 0,83 \ln(Z)_{t-1} \\ - 0,26 \ln(Z)_{t-2}$$

Onde:

$\ln(z)_t$  é o logaritmo neperiano da taxa frete TD15 no tempo t;

$\ln(\text{prod petroleo mundial})_t$  é o logaritmo neperiano da produção de petróleo mundial no tempo t;

$\ln(\text{frota VLCC})_t$  é o logaritmo neperiano da frota de navios do tipo VLCC no tempo t;

$\ln(\text{imp petroleo EUA})_t$  é o logaritmo neperiano da importação de petróleo EUA no tempo t;

$\ln(Z)_{t-1}$  é o logaritmo neperiano da taxa frete TD15 no tempo t -1;

$\ln(Z)_{t-2}$  é o logaritmo neperiano da taxa frete TD15 no tempo t -2;

## 4.2

### Aplicação dos modelos univariados

Nesta seção serão apresentados os resultados obtidos a partir da aplicação dos métodos de amortecimento exponencial e modelos ARIMA, métodos vastamente conhecidos na área de séries temporais. Os modelos de Box&Jenkins também foram os mais utilizados nos trabalhos encontrados na revisão da literatura (Geomelos e Xideas, 2014; Li e Parsons, 1997; Santos et al., 2014; Tsioumas et al., 2017).

As aplicações dos modelos univariados também foram realizadas considerando a forma log-log e também foi utilizado o Forecast Pro for Windows versão 3.50 para aplicação dos modelos.

Em especial, como visto no subitem 3.2.2, as previsões produzidas usando métodos de amortecimento exponencial são geradas com base em médias ponderadas de observações passadas, com os pesos decaindo exponencialmente à medida que as observações se afastam do tempo que está sendo previsto. A seleção do método é geralmente baseada no reconhecimento das componentes de tendência e sazonalidade da série temporal em estudo e como elas entram no método de amortecimento (de forma aditiva ou multiplicativa).

Para realizar as previsões tomando-se como método o amortecimento exponencial, foi utilizada uma abordagem a partir dos estados das componentes do método, conforme exposto na tabela 6 do subitem 3.2.2. A partir da avaliação das abordagens foi identificado um modelo sem tendência e sazonalidade aditiva, que melhor se ajustou à série temporal em estudo.

Por definição, o modelo linear ARIMA também é univariado, ou seja, vale-se da própria série temporal para realização de sua previsão.

Existem alguns passos básicos para utilização da metodologia de Box & Jenkins. O primeiro passo para estimação de um modelo ARIMA (p,d,q) é a identificação da ordem de homogeneidade “d”, ou seja, caso seja necessário, trata-se de identificar o número de vezes que a série original deve ser diferenciada para se tornar uma série estacionária. Este procedimento pode ser feito através da observação do próprio gráfico da série (figura 4).

O passo seguinte da metodologia é a identificação do modelo, ou seja, da sua ordem (identificação de p e q). Para isso são utilizados os conceitos de função de autocorrelação (FAC) e autocorrelação parcial (FACP), ou seja, de modo geral, para a identificação da ordem, observa-se os comportamentos da FAC e da FACP.

Percebe-se que a FAC decresce rapidamente, o que corrobora a constatação de estacionariedade da série, observada na figura 4.

Seguindo o procedimento de Box&Jenkins de identificação de um modelo através da visualização dos gráficos da Função de Autocorrelação e Autocorrelação Parcial, pode-se perceber que, observando os *lags* não sazonais, verifica-se que a FAC decresce e que a FACP apresenta um corte no *lag* 1.

Identifica-se então a ordem  $p = 1$  e após todos os diagnósticos e constatações, identificou-se um modelo SARIMA  $(1,0,0) \times (1,0,0)_{12}$  como o mais adequado.

Foi verificado também se os erros gerados por este modelo não apresentam correlação, ou seja, se apresentam características de um ruído branco. Utilizou-se o teste de Ljung-Box, corroborado pelo gráfico da função de autocorrelação de erro, conforme figura 9.

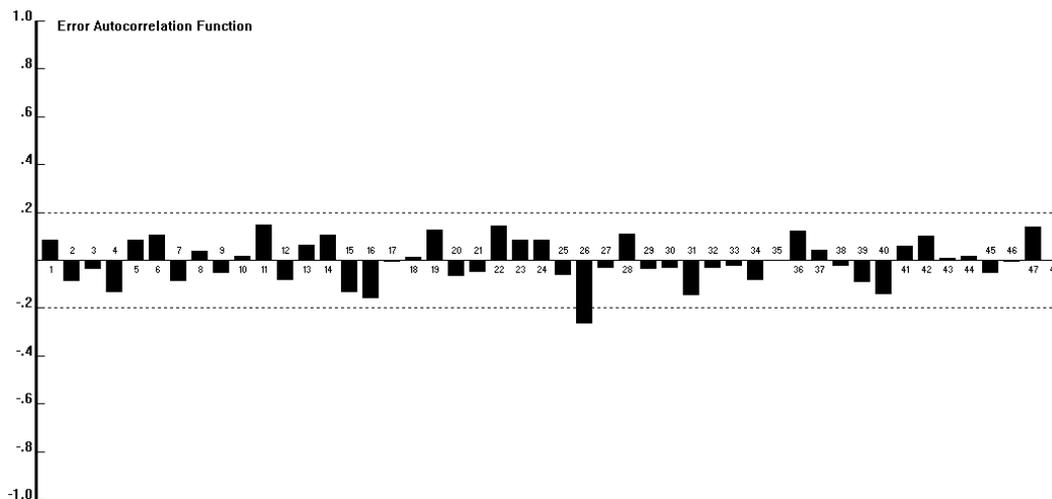


Figura 9 – Função de Autocorrelação de Erros (FAC Error) – Modelo SARIMA(1,0,0)x(1,0,0)<sub>12</sub>.

Pode parecer uma contradição o que foi dito porque o *lag* 26 ultrapassa a fronteira de significância, entretanto, não há explicação lógica para autocorrelações significativas neste *lag*. Portanto, estas serão tratadas como correlações espúrias.

### 4.3

#### Comparação dos modelos

Após obter os resultados dos modelos autoprojativos e chegar a um modelo de regressão dinâmica que inclui variáveis causais, foi realizada uma análise comparativa dos resultados obtidos através destes modelos.

Com o objetivo de enriquecer a comparação entre os modelos, foram calculadas estatísticas que visam medir o desempenho preditivo dos mesmos tanto dentro da amostra (*in-sample*) quanto fora desta (*out-of-sample*). Para analisar o desempenho fora da amostra, baseado em Dias (2008), foram utilizados os dados

dos últimos 12 meses, ou seja, foram retirados da amostra os dados referentes aos meses de julho de 2017 a junho de 2018. Feito isto, os parâmetros da equação são novamente estimados calculando-se, com origem em junho de 2017, a previsão para todo o período fora da amostra, ou seja, 12 previsões. Tem-se, neste momento, uma previsão para cada horizonte, ou seja, uma previsão para 1 mês à frente, 1 previsão para 2 meses à frente e assim sucessivamente. Depois, para maior robustez da análise, é feito um deslocamento da origem de previsão, ou seja, através do mesmo modelo estimado com dados até junho de 2017, desloca-se a origem para julho de 2017, realizando-se as previsões para o período de agosto de 2017 a junho de 2018, ou seja, 11 previsões. Este processo se repete até que se obtenha apenas uma previsão fora da amostra. Ao final, tem-se 12 previsões para 1 mês à frente, 11 previsões para 2 meses à frente, 10 previsões para 3 meses à frente e assim sucessivamente, totalizando 78 previsões fora da amostra para diferentes horizontes.

Para comparar o desempenho dos modelos utilizados *in sample* foi utilizada a métrica de desempenho MAPE (*Mean Absolute Percentage Error*), o BIC para julgar os modelos do ponto de vista da sua quantidade de parâmetros e também o coeficiente de explicação ( $R^2$  ajustado).

Tabela 10 – Desempenho *in sample* dos modelos univariados e de regressão dinâmica.

	<b>Amortecimento Exponencial</b>	<b>ARIMA</b>	<b>Regressão Dinâmica</b>
MAPE	9,9%	10,8%	<b>9,4%</b>
BIC	9,0	9,3	<b>8,9</b>
$R^2$ Ajustado	76,4%	74,7%	<b>78,8%</b>
Ljung-Box (18)	p=0,4635	p=0,685	<b>p=0,878</b>

Os desempenhos *in sample* dos modelos univariados e do modelo de regressão dinâmica encontram-se na tabela 10. Pode-se observar que o modelo de regressão dinâmica apresentou melhores resultados para as três métricas avaliadas, MAPE *in sample*, BIC e  $R^2$  ajustado. No entanto, de um modo geral, os modelos apresentaram igualmente um bom ajuste, principalmente por se tratar de

uma série de preços de frete. O MAPE de 9,4% do modelo de regressão dinâmica indica que, dentro da amostra, o modelo apresenta erro de 9,4%. Por sua vez, o  $R^2$  ajustado de 78,8% indica que o modelo explica 78,8% da variação do preço do frete estudado.

O desempenho *out-of-sample* foi avaliado através do MAPE e MAPE acumulado. Além dos bons resultados de desempenho *in sample* do modelo de regressão dinâmica, o modelo também demonstrou desempenho satisfatório na análise *out-of-sample*, conforme tabela 11, quando comparado com os desempenhos dos modelos univariados.

Tabela 11 – Desempenho *out-of-sample* dos modelos univariados e de regressão dinâmica.

MAPE <i>out-of-sample</i>							
H	N	Amortecimento Exponencial		ARIMA		Regressão Dinâmica	
		MAPE (%)	MAPE Acumulado (%)	MAPE (%)	MAPE Acumulado (%)	MAPE (%)	MAPE Acumulado (%)
1	12	7,6%	7,6%	9,4%	9,4%	7,0%	7,0%
2	11	11,4%	9,4%	15,6%	12,3%	11,3%	9,1%
3	10	11,6%	10,1%	18,1%	14,1%	9,9%	9,3%
4	9	13,0%	10,7%	22,3%	15,9%	9,1%	9,3%
5	8	13,7%	11,2%	28,2%	17,8%	8,3%	9,1%
6	7	13,5%	11,5%	34,4%	19,9%	7,4%	8,9%
7	6	9,2%	11,3%	35,8%	21,4%	8,4%	8,9%
8	5	7,0%	10,9%	35,8%	22,4%	9,8%	8,9%
9	4	7,0%	10,7%	34,0%	23,1%	10,5%	9,0%
10	3	7,0%	10,6%	32,3%	23,5%	10,8%	9,1%
11	2	6,2%	10,5%	24,6%	23,5%	13,3%	9,2%
12	1	9,6%	10,5%	16,2%	23,4%	20,9%	9,4%

Nota: H = horizonte; N = Número de previsões

Pode-se dizer que para a análise *out-of-sample*, o modelo de regressão dinâmica manteve o desempenho obtido na análise *in sample*.

Para o horizonte de até 7 meses, o modelo de regressão dinâmica apresentou melhores desempenho fora da amostra. Para horizontes maiores, de 8 a 12 meses, os resultados apresentados pelo método de amortecimento exponencial ficaram mais satisfatórios. Isso pode ter ocorrido porque as variáveis causais do

modelo de regressão dinâmica foram previstas para a análise do desempenho fora da amostra.

As estatísticas acumuladas são importantes também, pois indicam se as previsões se deterioraram rapidamente com o horizonte de previsão. Neste caso, vê-se que o MAPE acumulado do modelo de regressão dinâmica é igual a 9,4%, indicando que as previsões continuaram consistentes, mesmo com um horizonte de previsão maior. A comparação do MAPE dentro e fora da amostra, bem como o MAPE fora da amostra acumulado do modelo de regressão dinâmica podem ser vistos na tabela 12.

Tabela 12 – Desempenho do modelo de regressão dinâmica dentro e fora da amostra.

<b>Modelo de Regressão Dinâmica</b>		
<b>Dentro da Amostra</b>	<b>Fora da Amostra</b>	
<b>MAPE (%)</b>	<b>MAPE (%) H=1 e N=12</b>	<b>MAPE (%) Acumulado</b>
9,4%	7,0%	9,4%

Por fim, tendo sido avaliado o desempenho preditivo dos modelos univariados e do modelo de regressão dinâmica, buscou-se também comparar os desempenhos desses modelos com o desempenho da previsão da taxa frete (WS) da rota aqui estudada de uma grande empresa de petróleo brasileira. Como a previsão da empresa de petróleo é feita para um horizonte de 3 meses, restringiu-se também o horizonte de previsão dos três modelos avaliados para comparar seus resultados com os resultados do modelo real. Sendo assim, tomando-se como origem da previsão o mês de junho de 2017 e avaliando os resultados para o período de julho de 2017 a junho de 2018, têm-se 12 previsões para 1 mês à frente, 11 previsões para 2 meses à frente e 10 previsões para 3 meses à frente.

O desempenho do modelo da empresa de petróleo foi medido através do MAPE para o horizonte de 1, 2 e 3 meses, exatamente como é feita a previsão do frete atualmente na empresa. Seus resultados comparativamente aos modelos avaliados neste estudo estão na tabela 13.

Tabela 13 – Comparação do desempenho do modelo atual de uma empresa de petróleo com o desempenho dos modelos avaliados neste estudo.

MAPE (%)					
H	N	Amortecimento Exponencial	ARIMA	Regressão Dinâmica	Modelo Atual
1	12	7,6%	9,4%	7,0%	8,5%
2	11	11,4%	15,6%	11,3%	14,0%
3	10	11,6%	18,1%	9,9%	17,6%

Nota: H = horizonte; N = Número de previsões

Como pode ser observado na tabela 13, o modelo de regressão dinâmica e o método de amortecimento exponencial apresentaram um desempenho melhor do que o modelo atual utilizado pela empresa de petróleo para os três horizontes de previsão. O modelo ARIMA, por sua vez, apresentou desempenho inferior ao modelo real da empresa de petróleo.

Esses resultados demonstram a capacidade preditiva dos modelos estudados e, em função dos seus melhores resultados apresentados em comparação ao desempenho do modelo atual da empresa, a possibilidade de utilização desse protótipo de sistema de previsão desenvolvido neste trabalho como ferramenta empresarial para previsão de taxa frete de navios petroleiros.

Como visto no subitem 3.2.1.3, as previsões geradas por um modelo de regressão dinâmica dependem não só de valores passados da própria série, mas também dos valores previstos para as variáveis causais. Logo, as previsões destas variáveis causais devem ser adequadas para que o modelo de regressão dinâmica não gere valores futuros inadequados para a variável dependente. Por outro lado, esta condição possibilita a criação de cenários futuros para as variáveis causais, possibilitando analisar os possíveis valores futuros da variável de interesse em diversas condições.

Apresenta-se no subitem seguinte as previsões da taxa frete de navios petroleiros através de cenários, último objetivo deste trabalho.

#### 4.4

#### Análise de cenários com regressão dinâmica

O horizonte de previsão escolhido para realização da análise de cenários a partir do modelo de regressão dinâmica foi de 6 meses, ou seja, foram feitas as previsões para os meses de julho a dezembro de 2018.

Para projeção das variáveis causais foram considerados três cenários: um pessimista, um moderado e um otimista. As premissas para cada uma das variáveis, em cada um dos cenários para o período de previsão encontram-se resumidas na tabela 14. Os cenários foram construídos com base em avaliações de especialistas de empresas que são referências em pesquisas e consultorias no mercado de navegação e no mercado de energia mundial.

De acordo com a Drewry Shipping Consultants Limited., após dois anos de forte crescimento, a frota de petroleiros deverá se expandir em um ritmo relativamente mais lento nos próximos anos, com uma desaceleração nas entregas e forte atividade de demolição. No entanto, o excesso de oferta levará tempo para diminuir, já que o crescimento da demanda por tonelagem também deverá diminuir nos próximos anos. Espera-se que a frota de navios petroleiros cresça 2,8% em 2018.

Em relação a produção de petróleo mundial, a PIRA prevê um crescimento aproximado de 2% em 2018, suportado principalmente pelos preços altos do petróleo. As importações dos EUA também devem aumentar, impulsionadas pela forte demanda por derivados prevista para 2018.

Tabela 14 – Premissas dos cenários utilizados para previsão da taxa frete através do modelo de regressão dinâmica.

	CENÁRIOS		
	Pessimista	Moderado	Otimista
<b>Produção Petróleo Mundial</b>	- 1%	+ 0,5%	+ 1,0%
<b>Importação Petróleo EUA</b>	- 5%	0,0%	+ 5,0%
<b>Frota VLCC</b>	0,0%	+ 0,5%	+ 1,5%

Nota: as variações referem-se ao período de previsão de 6 meses, de julho a dezembro de 2018

O cenário pessimista consiste em uma redução da produção mundial de petróleo de 1% no período de seis meses, redução da importação de petróleo pelos EUA e a manutenção da frota de navios do tipo VLCC. As previsões obtidas para esse cenário podem ser vistas na tabela 15.

Neste momento, o período de dados utilizado como *out-of-sample*, ou seja, o período de julho de 2017 a junho de 2018 é incorporado à amostra de dados com seus valores realizados, atualiza-se novamente os parâmetros e obtêm-se as previsões.

Tabela 15 – Regressão dinâmica: Previsões da taxa frete para o cenário pessimista.

<b>Mês</b>	<b>Limite Inferior</b>	<b>Previsão</b>	<b>Limite Superior</b>
<b>jul/18</b>	42,37	53,21	66,82
<b>ago/18</b>	39,40	52,96	71,21
<b>set/18</b>	38,15	52,10	71,15
<b>out/18</b>	37,54	51,35	70,24
<b>nov/18</b>	37,18	50,85	69,56
<b>dez/18</b>	36,93	50,51	69,10

Nota: Intervalo de confiança de 95%.

Para o cenário moderado, foi considerado um crescimento de 0,5% na produção de petróleo mundial no período de 6 meses, a manutenção das importações dos EUA nos patamares do valor realizado em junho de 2018 e o crescimento da frota de VLCC de 0,5%. As previsões para o cenário moderado encontram-se na tabela 16.

Tabela 16 – Regressão dinâmica: Previsões da taxa frete para o cenário moderado.

<b>Mês</b>	<b>Limite Inferior</b>	<b>Previsão</b>	<b>Limite Superior</b>
<b>jul/18</b>	42,50	53,37	67,03
<b>ago/18</b>	39,72	53,41	71,80
<b>set/18</b>	38,74	52,90	72,24
<b>out/18</b>	38,39	52,51	71,83
<b>nov/18</b>	38,28	52,36	71,62
<b>dez/18</b>	38,28	52,37	71,63

Nota: Intervalo de confiança de 95%.

Do cenário pessimista para o moderado, nota-se um sutil acréscimo das taxas fretes, impactadas, sobretudo, pela variação da produção de petróleo mundial de -1% no cenário pessimista para +0,5% no cenário moderado. Paralelamente, a variação da frota VLCC foi de apenas 0,5%, sendo 0% no cenário pessimista e 0,5% no cenário moderado.

Foi considerado, no cenário otimista, um crescimento da produção de petróleo mundial de 1% durante o horizonte da previsão, ou seja, de julho a dezembro de 2018, aumento de 5% na importação de petróleo EUA e um crescimento da frota de 1,5%. Apesar do efeito positivo do aumento da produção de petróleo mundial no valor da taxa frete, a variação positiva da importação de petróleo EUA e, principalmente, o aumento da frota VLCC impactam negativamente o valor da taxa frete, como pode ser observado através dos coeficientes da equação 14. Percebe-se, por esta equação, a sensibilidade do modelo em relação às variáveis causais, em especial a variação da frota VLCC.

As taxas frete previstas para o cenário otimista mostraram-se inferiores às taxas frete previstas para os cenários pessimista e moderado. Atribui-se esse resultado ao fato de no modelo otimista, a premissa do crescimento da frota ter sido de 1,5%, o que compensou os efeitos das demais variáveis explicativas. De fato, o impacto de uma variação da frota VLCC na taxa frete é muito representativo.

Como visto anteriormente, o modelo de regressão dinâmica foi trabalhado com as variáveis em escala logarítmica e, portanto, é possível fazer a leitura dos

coeficientes de regressão na forma de coeficientes de elasticidade, ou seja, a variação de +1% na produção mundial de petróleo produz um aumento na taxa frete de 3,43%. Por sua vez, se a variável frota aumenta 1%, a taxa frete reduz 2,47%.

As previsões para o cenário otimista encontram-se na tabela 17.

Tabela 17 – Regressão dinâmica: Previsões da taxa frete para o cenário otimista.

<b>Mês</b>	<b>Limite Inferior</b>	<b>Previsão</b>	<b>Limite Superior</b>
<b>jul/18</b>	42,29	53,11	66,70
<b>ago/18</b>	39,23	52,74	70,90
<b>set/18</b>	37,86	51,71	70,61
<b>out/18</b>	37,11	50,76	69,44
<b>nov/18</b>	36,62	50,09	68,52
<b>dez/18</b>	36,26	49,60	67,84

Nota: Intervalo de confiança de 95%.

## 5

### Conclusão

Como visto durante o desenvolvimento do trabalho, o transporte marítimo de petróleo e derivados é componente fundamental da cadeia de suprimento da indústria do petróleo e, neste contexto, os valores de fretes praticados possuem grande impacto no comércio internacional destes bens.

A aplicação de modelos de previsão de frete no mercado de transporte marítimo parece terreno fértil para novos estudos. Em função da importância econômica da atividade este direcionamento ganha ainda mais motivação.

No tocante a modelagem com objetivo específico de previsão de frete no mercado de transporte marítimo, em especial de navios petroleiros, os poucos trabalhos encontrados na literatura exploraram métodos estatísticos diversos, porém não foram encontrados, na pesquisa realizada, estudos envolvendo o modelo de regressão dinâmica. Isso é um diferencial deste trabalho em relação aos encontrados na literatura.

Tanto os modelos univariados, amortecimento exponencial e ARIMA, quanto o modelo de regressão dinâmica que inclui variáveis causais se mostraram adequados para a modelagem de previsão de fretes de navios petroleiros. Todavia, a incorporação de variáveis exógenas nos modelos de previsão demonstrou uma melhora representativa na precisão das previsões de frete. Essa conclusão atendeu ao objetivo principal deste estudo que era verificar o desempenho de modelos de séries temporais, via regressão dinâmica, em previsões de frete marítimo do mercado *spot*.

Para atender ao objetivo de estabelecer uma comparação entre o desempenho do modelo causal com os modelos univariados foram calculadas estatísticas para medir a capacidade preditiva dos mesmos tanto dentro da amostra (*in-sample*) quanto fora desta (*out-of-sample*). O modelo de regressão dinâmica foi o que apresentou os melhores desempenhos tanto *in-sample* como *out-of-sample*.

Um ponto que merece maior atenção nesse estudo é a comparação do desempenho de cada um dos três modelos avaliados com os resultados de uma

metodologia utilizada por uma grande empresa brasileira de petróleo. O produto desenvolvido nesta dissertação mostrou a viabilidade de os modelos univariados e causais serem utilizados como ferramenta empresarial de previsão da taxa frete de navios petroleiros.

O modelo de regressão dinâmica apresentou um desempenho superior ao da metodologia da empresa de petróleo. Enquanto o MAPE da metodologia atual da empresa de petróleo para os horizontes de previsão de 1, 2 e 3 meses foi, respectivamente, 8,5%, 14,0% e 17,6%, o MAPE do modelo de regressão dinâmica para o horizonte de 1 mês foi 7,0%, para o horizonte de 2 meses foi 11,3% e para o horizonte de 3 meses, 9,9%. O método de amortecimento exponencial também apresentou desempenho melhor do que a metodologia da empresa de petróleo para os horizontes de 1, 2 e 3 meses.

Por fim, a criação de cenários futuros para as variáveis causais atendeu ao último objetivo desta dissertação, permitindo analisar os possíveis valores futuros da variável de interesse em diversas condições, além de permitir uma avaliação do impacto de cada uma das variáveis explicativas na taxa frete.

## 5.1

### Trabalhos futuros

O estudo desenvolvido, apesar de atingir o objetivo proposto, apresenta uma limitação por ter sido aplicado somente a taxa frete (WS) de navios petroleiros da classe VLCC para a rota do Oeste da África para a China. Este fato surge como oportunidade de continuidade do desenvolvimento da aplicação dos mesmos modelos de previsão em outras rotas e para outras classes de navios. A principal proposta é dar sequência a este trabalho aplicando-o em outras rotas de referência da própria BALTIC Exchange.

## 5.2

### Implicações práticas

Como implicações práticas, ficam como sugestões: avaliar a aplicação dos modelos desenvolvidos neste estudo como ferramentas de previsão de fretes de navios petroleiros; e suportar os estudos de frete com o modelo de regressão

dinâmica, em especial valendo-se da análise de cenários proporcionada por este modelo.

## Referências bibliográficas

ADLAND, R., CARIOU, P., WOLFF, F.-C., **The influence of charterers and owners on bulk shipping freight rates.** Transportation Research Part E: Logistics and Transportation Review, 2016, vol. 86, p. 69-82.

ALIZADEH, A. H., TALLEY, W. K., **Vessel and voyage determinants of tanker freight rates and contract times.** Transport Policy, 2011, vol. 18, Issue 5, p. 665-675.

\_\_\_, **BALTIC Exchange.** Londres, 2018. Disponível em: <<https://www.balticexchange.com/>> Acessado em junho de 2018.

BARROS, M., SOUZA, R. C., **Regressão Dinâmica.** Núcleo de Estatística Computacional. PUC-Rio, 1995.

BOX, G. E. P., JENKINS, G. M., REINSEL, G. C., LJUNG, G. M., **Time Series Analysis: Forecasting and Control.** Fifth Edition. Wiley, 2016.

\_\_\_, **Shipping Intelligence Network.** Londres, 2018. Disponível em: <<https://sin.clarksons.net/>> Acessado em junho de 2018.

COCHRANE, D., ORCUTT, G. H., **Application of Least Squares Regression to Relationships Containing Autocorrelated Error Terms.** Journal of American Statistical Association, 1949, 44, p. 32-61.

DIAS, E. D. M., **Previsão de médio prazo do consumo de energia elétrica no Brasil: Estimação via metodologia Box&Jenkins e regressão dinâmica,** Juiz de Fora: UFJF, 2008.

\_\_\_, **Tanker Forecaster.** Londres, 2018. Disponível em: <<https://www.drewry.co.uk/>> Acessado em junho de 2018.

DUDEWICZ, E. J., MISHRA, S. N., **Modern Mathematical Statistics.** Wiley, 1988.

\_\_\_, **EIA.** Estados Unidos, 2018. Disponível em: <<https://www.eia.gov/beta/international/>> Acessado em junho de 2018.

ESLAMI, P., JUNG, K., LEE, D., TJOLLENG, A., **Predicting tanker freight rates using parsimonious variables and a hybrid artificial neural network with an adaptive genetic algorithm.** Maritime Economics and Logistics, 2017, vol. 19, Issue 3, p. 538-550.

FREITAS, T., **Modelos e aplicações para séries temporais hierárquicas: abordagens de reconciliação ótima e proporções de previsão,** Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2016.

GEOMELOS, N. D.; XIDEAS, E., **Forecasting spot prices in bulk shipping using multivariate and univariate models.** Cogent Economics & Finance, 2014, vol. 2, Issue 1.

GOODRICH, R. L., **Applied Statistical Forecasting**. Belmont, Business Forecast Systems, 1989.

HYNDMAN, R.J., ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2014. Disponível em: <https://otexts.org/fpp/>. Acessado em maio de 2018.

HYNDMAN, R.J., ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2016. Disponível em: <https://otexts.org/fpp2/>. Acessado em maio de 2018.

JI, M.-J., ZHANG, H.-Y., WANG, Q.-B., **Analysis and forecasting of the tanker freight rates based on combined forecasting model**. Journal of Transportation Systems Engineering and Information Technology, 2012, vol. 12, Issue 1, p. 199-204.

JUNKES, L. N., **Previsão de taxas de afretamento por período para navios petroleiros através de redes neurais**, Rio de Janeiro: UFRJ/COPPE, 2011.

JURČEVIĆ, M., MITROVIĆ, F., NADRLJANSKI, M., **System dynamics and theory of chaos in freight rate forming in shipping**. Promet - Traffic – Traffico, 2010, vol. 22, Issue 6, p. 433-438.

LI, J., PARSONS, M., **Forecasting tanker freight rate using neural networks**. Maritime Policy and Management, 1997, 24:1, 9-30.

MAÇAIRA, P. M., THOMÉ, A. M. T., OLIVEIRA, F. L. C., FERRER, A. L. C., **Time series analysis with explanatory variables: A systematic literature review**. Environmental Modelling & Software, 2018, p. 199-209.

MONGEON, P., PAUL-HUS, A., **The journal coverage of Web of Science and Scopus: a comparative analysis**. Scientometrics, 2016, vol. 106, Issue 1, p. 213-228.

\_\_\_\_\_, **Pira World Oil Market Forecast**. Londres, 2018. <<https://www.pira.com/>> Acessado em junho de 2018.

SANTOS, A. A. P., JUNKES, L. N., PIRES JR., F. C. M., **Forecasting period charter rates of VLCC tankers through neural networks: A comparison of alternative approaches**. Maritime Economics & Logistics, 2014, vol. 16, Issue 1, p. 72-91.

SARACENI, P. P., **Transporte Marítimo de Petróleo e Derivados**. 2 ed. Rio de Janeiro: Interciência, 2012.

SCHWARZ, G., **Estimating the dimension of a model**. The annals of statistics, 1978, vol. 6, Nº 2, p. 461-464.

SOUZA, R. C.; CAMARGO, M. E. **Análise e Previsão de Séries Temporais: os Modelos ARIMA**. 2 ed. Rio de Janeiro, 2004.

STELLWAGEN, E.; GOODRICH, R. **Forecast Pro Statistical Reference Manual**. Belmont, MA: Business Forecast Systems, 2011.

STOPFORD, M., **Maritime Economics**. Routledge, 1997.

THOMÉ, A. M. T., SCAVARDA, L. F., SCAVARDA, A. J., **Conducting systematic literature review in operations management**. *Production Planning & Control*, 2016, vol. 27, Issue 5, p. 408-420.

TVEDT, J., **Short-run freight rate formation in the VLCC market: A theoretical framework**. *Maritime Economics and Logistics*, 2011, vol. 13, Issue 4, p. 442-455.

TSIOUMAS, V., PAPADIMITRIOU, S., SMIRLIS, Y., ZAHRAN, S. Z., **A Novel Approach to Forecasting the Bulk Freight Market**. *The Asian Journal of Shipping and Logistics*, 2017, vol. 33, Issue 1, p. 33-41.

WAKAMATSU, C., **Análise dos fatores que influenciam o frete no transporte marítimo de petroleiros no mercado *spot***, Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2008.

\_\_\_**WORLDSCALE**\_. Londres, 2018. Disponível em: <https://www.worldscale.co.uk/BookPage/2018/PreambleIndex.html?embed=True>. Acessado em abril de 2018.

ZANINI, A., **Redes neurais e regressão dinâmica: um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva do Brasil**, Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 2000.

ZHANG, J., ZENG, Q., **Modelling the volatility of the tanker freight market based on improved empirical mode decomposition**. *Applied Economics*, 2017, vol. 49, Issue 17, p. 1655-1667.