



**Rebeca da Silva Oliveira Farias**

**Previsão de demanda de gás natural:  
análise comparativa de modelos de séries  
temporais para dados diários e semanais  
de consumo de gás natural no Brasil**

**Dissertação de Mestrado (Opção profissional)**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Logística, do Departamento de Engenharia Industrial da PUC-Rio.

Orientador: Prof. Fernando Luiz Cyrino Oliveira  
Coorientador: Prof. Antônio Márcio Tavares Thomé

Rio de Janeiro  
maio de 2024



**Rebeca da Silva Oliveira Farias**

**Previsão de demanda de gás natural:  
análise comparativa de modelos de séries  
temporais para dados diários e semanais  
de consumo de gás natural no Brasil**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Logística, do Departamento de Engenharia Industrial da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Fernando Luiz Cyrino Oliveira**

Orientador

Departamento de Engenharia Industrial – PUC-Rio

**Prof. Antônio Márcio Tavares Thomé**

Coorientador

Departamento de Engenharia Industrial – PUC-Rio

**Prof. Igor Tona Peres**

Departamento de Engenharia Industrial – PUC-Rio

**Prof. Reinaldo Castro Souza**

Departamento de Engenharia Industrial – PUC-Rio

Rio de Janeiro, 16 de maio de 2024

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

### **Rebeca da Silva Oliveira Farias**

Graduou-se em Engenharia Química na UERJ (Universidade do Estado do Rio de Janeiro) em 2006. Concluiu MBA (Master of Business Administration) em Finanças no IBMEC (Instituto Brasileiro de Mercado de Capitais) em 2014. Trabalha na Petróleo Brasileiro S.A. desde 2010, atuando na área de Gás Natural desde 2014.

#### Ficha Catalográfica

Farias, Rebeca da Silva Oliveira

Previsão de demanda de gás natural : análise comparativa de modelos de séries temporais para dados diários e semanais de consumo de gás natural no Brasil / Rebeca da Silva Oliveira Farias ; orientador: Fernando Luiz Cyrino Oliveira ; coorientador: Antônio Márcio T. Thomé. – 2024.

93 f. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2024.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Demanda de gás natural. 3. Métodos de previsão. 4. Séries temporais. I. Oliveira, Fernando Luiz Cyrino. II. Thomé, Antônio Márcio Tavares. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Para o meu filho, Mateus,  
Pelo amor, paciência e compreensão.

## **Agradecimentos**

Ao meu orientador, Professor Fernando Luiz Cyrino Oliveira, ao meu coorientador, Professor Antônio Márcio Tavares Thomé, e à Tuany Esthefany Barcellos de C. Silva, que se dedicaram e garantiram todo o apoio necessário para a conclusão do meu mestrado.

Aos pareceristas da Indústria, André Bittencourt Martins e Rafael Rigueira, por todo apoio e ensinamentos.

Aos meus gestores Érico Moraes Leite, João Marcello Rangel Barreto, Álvaro Ferreira Tupiassu, Gabriela Damasceno Duarte e Rafael Senna Santos Imbuzeiro por todo apoio e pela oportunidade de realizar este trabalho. Aos meus colegas Gabriel Seber, Gustavo Mauricio da Silva, Marcos Bruno Bianchi Carnevale, Raoni Oliveira Bentim, Cleiton Soares Camilo Junior, Artur Rodrigues Machado e Alexandre Folco Cruz, bem como aos demais colegas da comercialização de infraestruturas de gás natural, por todo apoio e colaboração neste trabalho.

Aos meus pais pelo apoio na busca de uma educação de qualidade e suporte na base da minha formação acadêmica e profissional, assim como ao meu filho e à minha rede de apoio, por terem sido fundamentais para que eu me superasse e atingisse as minhas metas.

Aos meus colegas da PUC-Rio, aos professores que participaram da Comissão examinadora, a todos os professores e funcionários do Departamento pelos ensinamentos e a todos aqueles que, de alguma forma contribuíram, para a conclusão deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## Resumo

Farias, Rebeca da Silva Oliveira; Oliveira, Fernando Luiz Cyrino; Thomé, Antônio Márcio Tavares. **Previsão de demanda de gás natural: análise comparativa de modelos de séries temporais para dados diários e semanais de consumo de gás natural no Brasil**. Rio de Janeiro, 2024. 93p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro – PUC-Rio.

O setor energético brasileiro passou por transformações significativas, destacando o papel crucial do gás natural para garantir a segurança energética diante da transição para fontes menos dependentes de combustíveis fósseis. A previsão da demanda de gás natural é essencial para a gestão eficiente do setor. Enquanto a literatura tem se concentrado na previsão de demanda de eletricidade, há uma lacuna em estudos sobre modelagem e previsão da demanda de gás natural, especialmente em contextos industriais e de médio/longo prazo. A necessidade de modelos mais precisos e abrangentes para prever a demanda de gás natural é evidente a partir da análise dos estudos existentes. Dessa forma, o objetivo deste trabalho é abordar uma análise comparativa da previsão de demanda de gás natural, por meio de modelos sugeridos na literatura recente de séries temporais, com aplicação no software R, para dados diários e semanais de consumo de gás natural, obtidos dos Relatórios de Movimentação de Gás Natural em Gasodutos de Transporte, divulgados mensalmente pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, no período de 2021 a 2023. Os modelos fornecem as previsões para uma amostra teste de trinta dias futuros para dados diários e de quatro semanas para dados semanais e é realizada uma análise comparativa fora da amostra com base em métricas de desempenho, para identificar o modelo mais adequado para a série de dados. Ao final do estudo, os modelos de previsão utilizando redes neurais e *tbats* (transformação Box-Cox, erros ARMA, tendência e componentes sazonais trigonométricas) foram aqueles que demonstraram melhor desempenho para dados diários, enquanto o método de decomposição com modelagem autorregressiva e ajuste sazonal (*stlar*) e o *seasonal naive method* (método ingênuo sazonal) foram os que apresentaram melhor desempenho para as séries temporais em base semanal.

## Palavras-chave

Demanda de gás natural; métodos de previsão; séries temporais.

## Abstract

Farias, Rebeca da Silva Oliveira; Oliveira, Fernando Luiz Cyrino; Thomé, Antônio Márcio Tavares. **Natural gas demand forecast: comparative analysis of time series models for daily and weekly natural gas consumption data in Brazil**. Rio de Janeiro, 2024. 93p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro – PUC-Rio.

The Brazilian energy sector has undergone significant transformations, highlighting the crucial role of natural gas in ensuring energy security in the face of the transition to sources less dependent on fossil fuels. Forecasting natural gas demand is essential for efficient management of the sector. While the literature has focused on forecasting electricity demand, there is a gap in studies on modeling and forecasting natural gas demand, especially in industrial and medium/long-term contexts. The need for more accurate and comprehensive models to forecast natural gas demand is evident from the analysis of existing studies. Therefore, the objective of this work is to address a comparative analysis of natural gas demand forecasting, using models suggested in recent time series literature, with application in the R software, for daily and weekly natural gas consumption data, obtained of the Natural Gas Movement Reports in Transport Gas Pipelines, released monthly by the National Agency for Petroleum, Natural Gas and Biofuels, in the period from 2021 to 2023. The models provide forecasts for a test sample of thirty days in the future for daily and four weeks for weekly data and an out-of-sample comparative analysis is performed based on performance metrics to identify the most suitable model for the data series. At the end of the study, the forecast models using neural networks and tbats (Box-Cox transformation, ARMA errors, trend and trigonometric seasonal components) were those that demonstrated the best performance for daily data, while the decomposition method with autoregressive modeling and seasonal adjustment (stlar) and the seasonal naive method were the ones which showed better performance for time series on a weekly basis.

## Keywords

Natural gas demand; forecasting methods; time series.

## Sumário

1. Introdução .....	16
2. Referencial Teórico .....	20
3. Metodologia .....	27
4. Resultados e Discussões .....	36
4.1. Dados Diários .....	36
4.2. Dados convertidos em médias semanais .....	54
4.3. Comparativo com os métodos aplicados pela empresa .....	59
5. Conclusões .....	52
6. Referências Bibliográficas .....	65
Apêndice I – Descrição dos métodos aplicados .....	68
Apêndice II – Código em linguagem R para dados diários .....	76
Apêndice III – Código em linguagem R para dados semanais .....	80



## Lista de figuras

Figura 1: Mapa brasileiro de gasodutos e terminais de GNL	20
Figura 2: Séries temporais da demanda diária de gás natural no GASFOR, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	34
Figura 3: Séries temporais da demanda diária de gás natural no trecho Catu-Guamaré, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	34
Figura 4: Séries temporais da demanda diária de gás natural no trecho Malha Bahia, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	35
Figura 5: Séries temporais da demanda diária de gás natural no GASENE, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	35
Figura 6: Séries temporais da demanda diária de gás natural no trecho Cabiúnas-Replan, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	36
Figura 7: Séries temporais da demanda diária de gás natural no GASPAJ, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	36
Figura 8: Séries temporais da demanda diária de gás natural no GASBEL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	37
Figura 9: Séries temporais da demanda diária de gás natural no trecho São Paulo, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	37
Figura 10: Séries temporais da demanda diária de gás natural no trecho norte do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	38

Figura 11: Séries temporais da demanda diária de gás natural no trecho sul 1 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	38
Figura 12: Séries temporais da demanda diária de gás natural no trecho sul 2 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	39
Figura 13: Séries temporais da demanda média semanal de gás natural, em base diária, no GASFOR, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	40
Figura 14: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho Catu Guamaré, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	41
Figura 15: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho Malha Bahia, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	41
Figura 16: Séries temporais da demanda média semanal de gás natural, em base diária, no GASENE, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	42
Figura 17: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho Cabiúnas Replan, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	42
Figura 18: Séries temporais da demanda média semanal de gás natural, em base diária, no GASPAJ, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	43
Figura 19: Séries temporais da demanda média semanal de gás natural, em base diária, no GASBEL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	43
Figura 20: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho São Paulo, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m <sup>3</sup> /d)	44

Figura 21: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho norte do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )	44
Figura 22: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho sul 1 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )	45
Figura 23: Séries temporais da demanda média semanal de gás natural, em base diária, no trecho sul 2 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )	45
Figura 24: MAPE para aplicação dos modelos de previsão, para categoria de frequência diária	51
Figura 25: Previsão com modelo de redes neurais para série de GASFOR, em base diária	53
Figura 26: Previsão com a técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) para série de dados GASFOR, em base diária	53
Figura 27: MAPE para aplicação dos modelos de previsão, para categoria de frequência semanal	57
Figura 28: Previsão com redes neurais para série de dados GASFOR, em base semanal	59
Figura 29: Previsão com a técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) para para série de dados GASFOR, em base semanal	59

## Lista de tabelas

Tabela 1: Resumo dos métodos e modelos utilizados nos artigos estudados para previsão de demanda de gás	28
Tabela 2: Proposta de mercado na malha integrada de gasodutos	31
Tabela 3: MAPE da amostra teste para dados diários, em %.	50
Tabela 4: RMSE da amostra teste para dados diários, em mil m <sup>3</sup> /d.	50
Tabela 5: MASE da amostra teste para dados diários	51
Tabela 6: Modelos mais precisos por área de mercado, em base diária	52
Tabela 7: MAPE da amostra teste para dados convertidos em médias semanais, em %.	54
Tabela 8: RMSE da amostra teste para dados convertidos em médias semanais, em mil m <sup>3</sup> /d.	55
Tabela 9: MASE da amostra teste para dados convertidos em médias semanais.	56
Tabela 10: Escolha dos modelos mais precisos por grupo de mercado, em base semanal	57
Tabela 11: Descrição dos métodos que melhor se aplicam a diferentes frequências de séries temporais.	Apêndice I

## **Lista de siglas**

ALGAS – Gás de Alagoas S.A.

ARIMA – Modelo autorregressivo integrado de médias móveis

ARMA – Modelo autorregressivo de médias móveis

BAHIAGAS – Companhia de Gás da Bahia

CEG – Companhia Estadual de Gás (adquirida pela Naturgy)

CEGAS – Companhia de Gás do Ceará

COMGAS – Companhia de Gás de São Paulo

COMPAGAS – Companhia Paranaense de Gás

COPERGAS – Companhia Pernambucana de Gás

EDG Catu – Estação de Distribuição de Gás

E&P – Setor de Exploração e Produção de Óleo e Gás

ESGAS – Espírito Santo Gás

ETS – Algoritmo de Suavização Exponencial

FAFEN-BA – Fábrica de Fertilizantes da Bahia

FAFEN-SE – Fábrica de Fertilizantes de Sergipe

GASALP – Gasoduto Alagoas-Pernambuco

GASAN – Gasoduto Santos-São Paulo

GASBEL – Gasoduto Rio de Janeiro-Belo Horizonte

GASBOL – Gasoduto Bolívia-Brasil

GASCAC – Gasoduto Cacimbas-Catu

GASCAR – Gasoduto Campinas-Rio

GASCAV – Gasoduto Cabiúnas-Vitória

GASDUC III – Gasoduto Cabiúnas-Reduc III

GASENE – Gasoduto da Integração Sudeste-Nordeste

GASFOR – Gasoduto Guamaré-Pecém

GASJAP – Gasoduto Japeri-Reduc

GASMIG – Companhia de Gás de Minas Gerais

GASPAJ – Gasoduto Paulínia-Jacutinga

GASPAL – Gasoduto que interliga Volta Redonda a São Paulo

GASTAU – Gasoduto Caraguatatuba-Taubaté

GASVOL – Gasoduto Reduc-Volta Redonda

GBD – Gás Brasileiro Distribuidora S.A.

LUBNOR – Refinaria de Lubrificantes e Derivados do Nordeste

MSGAS – Companhia de Gás do Estado de Mato Grosso do Sul

MSTLARIMA – Multiple seasonal decomposition with ARIMA modeling of the seasonally adjusted series (Decomposição sazonal múltipla com modelagem ARIMA da série com ajuste sazonal)

MSTLETS – Multiple seasonal decomposition with ETS modeling of the seasonally adjusted series (Decomposição sazonal múltipla com modelagem ETS da série com ajuste sazonal)

NN – Redes neurais

PBGAS – Companhia Paraibana de Gás

POTIGAS – Companhia Potiguar de Gás

RECAP – Refinaria de Capuava

REDUC – Refinaria Duque de Caxias

REFAP – Refinaria Alberto Pasqualini

REPAR – Refinaria do Paraná

RPBC – Refinaria Presidente Bernardes

REPLAN – Refinaria de Paulínia

REVAP – Refinaria do Vale do Paraíba

RNEST – Refinaria Abreu e Lima

RW – Random walk (passeio aleatório)

RWD – Random Walk with drift (passeio aleatório com derivada)

SARIMA – Modelo autorregressivo integrado de médias móveis com sazonalidade

SCGAS – Companhia de Gás de Santa Catarina

SERGÁS – Sergipe Gás S.A.

SNAIVE – Seasonal naive method (Método ingênuo sazonal)

SPSUL – Distribuidora de Gás Natural São Paulo Sul

STLAR – Seasonal decomposition with AR modeling of the seasonally adjusted series (Decomposição sazonal com modelagem autoregressiva com ajuste sazonal)

SULGAS – Companhia de Gás do Estado do Rio Grande do Sul

TBATS – Transformação Box-Cox, erros ARMA, tendência e componentes sazonais trigonométricas

THETA – modelo utilizado na decomposição e previsão de séries temporais

TN GASBOL – Trecho Norte do GASBOL

TS1 GASBOL – Trecho Sul 1 do GASBOL

TS2 GASBOL – Trecho Sul 2 do GASBOL

UPGN – Unidade de processamento de gás natural

UTGCAB – Unidade de Tratamento de Gás Natural de Cabiúnas

WN – white noise (ruído branco)

## **1. Introdução**

O setor energético brasileiro passou por mudanças significativas nas últimas décadas. A transição para um mundo menos dependente de combustíveis fósseis coloca o gás natural como elemento chave para manter a segurança energética e complementar a intermitência da geração renovável (Economides e Wood, 2009) – (Li et al., 2021).

Descobertas recentes (como os enormes volumes de gás natural localizados em campos offshore, quais sejam, BM-C-33 - Projeto Raia, Sergipe Águas Profundas e Margem Equatorial), a partida do gasoduto de escoamento do gás do pré-sal (Rota 3) e novas pesquisas sobre depósitos não convencionais indicam um aumento nas reservas comprovadas de gás natural do Brasil e no volume de oferta de gás natural num futuro próximo.

À medida que a demanda por gás aumenta, a sua cadeia de abastecimento também precisa se desenvolver, uma vez que a disponibilidade de infraestrutura é uma barreira relevante ao crescimento dos mercados de gás (Zhang et al., 2019). Os países com reservas abundantes de gás enfrentam o desafio de encontrar a melhor opção para alocar este recurso, garantindo ao mesmo tempo uma produção ótima e flexibilidade para satisfazer diferentes demandas.

Historicamente, países com grandes reservas de gás, como a Indonésia (Purwanto et al., 2016), Qatar (Chedid et al., 2007), Emirados Árabes Unidos (Kazim, 2007) e Venezuela (Khol, 1992), tiveram o desafio de criar alternativas para explorar o potencial do gás, uma vez que não havia demanda interna suficiente (Thomas e Dawe, 2003). A solução veio dos mercados europeu e asiático, uma vez que apresentavam uma produção doméstica de gás decrescente ou inexistente e uma demanda



crescente, à medida que tentavam substituir o mix de fornecimento de energia com elevado teor de carbono por outro com menores emissões (EPE, 2017). Nestas regiões, as importações de Gás Natural Liquefeito (GNL) tornaram-se uma opção para gerir as variações sazonais de gás e da demanda de eletricidade das termelétricas, proporcionando maior flexibilidade ao sistema energético (Devine e Russo, 2019).

No caso brasileiro, a matriz elétrica é composta de 88% de fontes renováveis, sendo que, nesta composição, 50,6% hidrelétricas, 12,8% eólicas, 12,1% de micro e minigeração distribuída (pequenas centrais de geração de energia elétrica locais por meio de fontes renováveis ou cogeração qualificada, cuja finalidade é que os consumidores possam produzir sua própria eletricidade e, com isso, economizar no valor das suas contas de luz) e 5% solar (ONS, 2023). Além disso, 18,5% correspondem a fonte térmica como gás natural, carvão, óleo combustível ou diesel e biomassa. A expansão da matriz elétrica conta com um grande aumento de fontes intermitentes, como usinas eólicas, de biomassa e solares, e a participação da capacidade hídrica na matriz de oferta está diminuindo (EPE, 2017). Os desafios ambientais restringiram a construção de novos projetos hidroelétricos com grandes reservatórios (dos Santos et al., 2022), expondo o fornecimento de eletricidade à vulnerabilidade climática. Consequentemente, quando a estação chuvosa não é capaz de nivelar adequadamente os reservatórios de água ou durante um evento inesperado (por exemplo, picos de demanda ou interrupções repentinas de grandes unidades geradoras), há uma necessidade urgente de geração de energia térmica (Fernandes et al., 2008; Arango-Aramburo et al., 2019).

O gás do pré-sal pode ser utilizado para aumentar a participação da geração controlável com termelétricas a gás, garantindo a segurança do mercado e o abastecimento energético (Dantas et al., 2017).

Segundo o Boletim de Recursos e Reservas de Petróleo e Gás Natural (ANP, 2023), em 2020, foram produzidos 45,9 bilhões de metros

cúbicos de gás natural e as reservas provadas do pré-sal equivalem a 198.835 MMm<sup>3</sup>.

Cerca de 80% da produção de gás natural brasileira é de gás associado ao petróleo, de origem offshore. Desse modo, a maior parte das reservas de gás natural brasileiras está associada às reservas de petróleo (gás associado) e ambas são produzidas simultaneamente, fato que caracteriza a necessidade de que o gás natural seja produzido e utilizado de forma regular, contribuindo para a produção de petróleo (EPE, 2023).

As principais fontes de gás são a própria oferta nacional ou o gás importado por gasodutos, da Bolívia e da Argentina ou na forma de gás natural liquefeito (GNL). Os principais destinos do gás são a geração de energia termelétrica, veicular, comercial, de serviços e residencial, e não energética, utilizada como matéria-prima nas indústrias petroquímica e de fertilizantes (ANP, 2023).

O modelo de geração termelétrico é flexível e a característica principal deste modelo é a necessidade de se garantir uma oferta de combustível flexível para usinas que deverão suprir uma demanda termelétrica igualmente flexível. O Brasil apresenta assim um *trade-off* entre os setores elétrico e de gás na medida em que, enquanto o setor elétrico necessita de gás flexível para abastecer as usinas termelétricas em períodos de hidrologia desfavorável, o setor de gás prefere uma demanda de gás inflexível para pagar seus custos, que são principalmente fixos e garante a otimização da produção de petróleo (França, 2017).

No Brasil, o Operador Nacional do Sistema Elétrico (ONS) é o órgão responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (Aneel). A capacidade instalada de geração do SIN é composta, principalmente, por

usinas hidrelétricas distribuídas em dezesseis bacias hidrográficas nas diferentes regiões do país. Nos últimos anos, a instalação de usinas eólicas, principalmente nas regiões Nordeste e Sul, apresentou um forte crescimento, aumentando a importância dessa geração para o atendimento do mercado. As usinas térmicas, em geral localizadas nas proximidades dos principais centros de carga, desempenham papel estratégico relevante, pois contribuem para a segurança do SIN. Essas usinas são despachadas em função das condições hidrológicas vigentes e da capacidade de geração das demais fontes renováveis (principalmente eólicas e solar), permitindo a gestão dos estoques de água armazenada nos reservatórios das usinas hidrelétricas bem como a intermitência das fontes eólicas e solar, de modo a assegurar o atendimento da demanda elétrica. Os sistemas de transmissão integram as diferentes fontes de produção de energia e possibilitam o suprimento do mercado consumidor.

Com o aumento de despacho termoeletrico, a flexibilidade de suprimento exigida pelo setor elétrico gera crescentes custos para o setor de gás natural, seja pela necessidade de importação de GNL no mercado *spot*, seja pela necessidade de desenvolver estratégias de comercialização envolvendo mercados âncora, mercados secundários e infraestrutura de armazenamento (FGV, 2015).

O Brasil é um dos países que lidera o processo de implementação de instalações de regaseificação de GNL na América Latina (Barroso et al., 2008). O Brasil abriga, hoje, cinco terminais de regaseificação: na Baía de Guanabara (Petrobras) e Porto do Açu (GNA), no Rio de Janeiro; no Porto do Pecém (fora de operação), no Ceará; no Porto de Sergipe (Eneva); e na Baía de Todos os Santos (Petrobras), na Bahia. Em 2024, mais três terminais privados de regaseificação entraram em operação, nos estados de São Paulo (Compass/Cosan), Santa Catarina (New Fortress Energy) e Pará (New Fortress Energy). As unidades têm o objetivo de ampliar o suprimento de gás em mais 44 milhões de metros cúbicos por dia, ao

mesmo tempo em que a Bolívia diminui sua produção e espera-se que diminua ainda mais no curto prazo.

Os terminais no Brasil têm a mesma filosofia de armazenamento e regaseificação em embarcações flutuantes do tipo FSRU (Floating, Storage, Regaseification Unit). Essas unidades flutuantes, dentre outras vantagens têm grande flexibilidade operacional e podem armazenar o GNL em tanques criogênicos até que a regaseificação seja necessária (Mendes, 2019).

O gás natural é injetado na rede de gasodutos através de pontos de recebimento distribuídos pelo território brasileiro e que recebem a produção nacional e o gás importado via dutos ou por navios. A movimentação do gás é realizada por transportadoras até os *city gates*, conjunto de instalações que representa a etapa de entrega do gás natural para a concessionária estadual que realiza a distribuição.

A figura 1, abaixo, apresenta os traçados dos gasodutos existentes no Brasil.

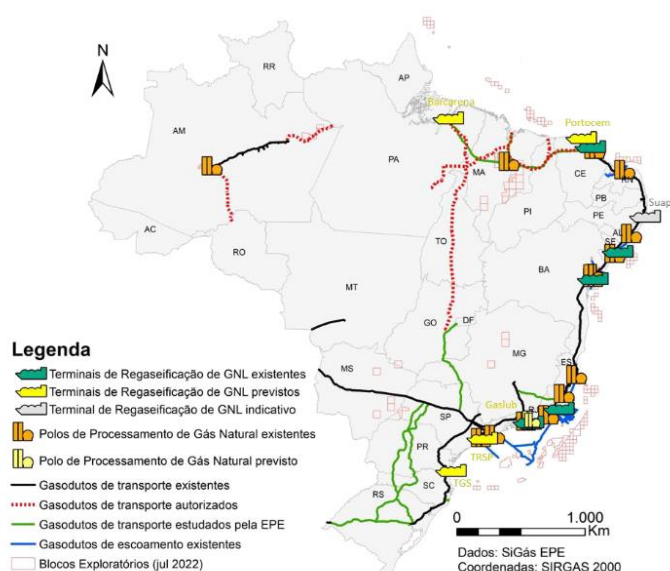


Figura 1: Mapa brasileiro de gasodutos e terminais de GNL  
Fonte: Estudos do Plano Decenal de Expansão de Energia 2032 – Gás Natural, março de 2023, EPE, MME. <https://www.epe.gov.br>

Nos últimos anos, vem aumentando no Brasil o número de empresas atuando na produção, importação e na comercialização de gás, o que torna ainda mais relevante o tema de aperfeiçoamento de metodologias de projeção de demanda mais precisas e acessíveis, para decisões de negócio como a compra de cargas de GNL, contratação de capacidade de transporte de curto prazo e os investimentos em tecnologias de armazenamento subterrâneo de gás.

No mercado nacional, uma grande empresa brasileira do setor de óleo e gás atuou praticamente sozinha na comercialização de gás natural nas últimas décadas, enxergando o balanço nacional de forma integrada e tomando as suas decisões de importação de gás para balanceamento do mercado. A mudança do perfil de demanda por gás e a multiplicidade de atores e de fontes deste combustível no Brasil aumentam ainda mais a necessidade de se obter métodos de previsão mais precisos, para evitar falhas ou custos desnecessários com estocagem e compras de cargas com sobrepreço para essa empresa.

Neste contexto, as informações pesquisadas nesta dissertação têm o objetivo de abordar uma análise comparativa dos métodos de previsão de demanda de gás natural, com base em literatura recente de séries temporais, com aplicação no software R.

Para tal, esta dissertação é dividida em 5 seções: o capítulo 1 introduz o tema que será discutido; o capítulo 2 apresenta uma revisão da literatura sobre aplicação de modelos de previsão de séries temporais, o capítulo 3 expõe a metodologia aplicada; no capítulo 4, são registrados os resultados obtidos e as discussões, comparando os diferentes modelos apresentados; por fim, o capítulo 5 apresenta a conclusão do trabalho e as sugestões para próximas pesquisas. A lista de modelos de previsão aplicados e os códigos utilizados para obtenção dos resultados são expostos nos Apêndices I a III.

## **2. Referencial Teórico**

Embora a previsão de curto prazo constitua a base para a comercialização de energia elétrica e do cálculo do preço spot, diversas decisões são tomadas com base na previsão da demanda de energia a médio/longo prazo, tais como a construção de novas instalações de produção, a aquisição de unidades geradoras existentes, desenvolvimento de sistemas de transmissão e distribuição, entre outros (EPE, 2023).

Não só estimativas confiáveis permitem que as empresas se posicionem de forma competitiva nos mercados, mas também ajudam os operadores de sistemas de energia a equilibrar a oferta e a demanda de eletricidade. Consequentemente, as previsões do consumo natural são importantes para manter as margens de reserva de gás e eletricidade e, em última análise, para garantir o abastecimento de energia. Alguns estudos abordaram como prever a demanda de gás natural. No entanto, não há consenso sobre quais abordagens são mais adequadas e há poucas evidências de como os métodos funcionam em uma ampla gama de dados (Saldarriaga, 2016).

A maioria dos artigos aborda o problema de previsões de curto prazo, enquanto a previsão de demanda é bastante incomum para a energia de médio e longo prazo. Por exemplo, Hippert et al. (2001) examinaram quase 100 artigos (publicados entre 1991 e 1999) relativos apenas à previsão de demanda de eletricidade de curto prazo.

A literatura sobre previsão de séries temporais mostra diferentes modelos e métodos (ver De Gooijer e Hyndman, 2005). Os principais desenvolvimentos para a previsão de séries temporais de médio e longo prazos estão intimamente relacionados à extrapolação dos modelos de decomposição.

Os modelos de decomposição estão entre as abordagens mais antigas para análise de séries temporais e previsão (para uma revisão

histórica e resumo dos métodos clássicos, consulte, por exemplo, o capítulo 3 de Makridakis et al., 1998). Os métodos de decomposição mais populares são Census X-12-ARIMA (Findley et al., 1998), TRAMO-SEATS (Gómez e Maravall, 2001) e STL (Cleveland et al., 1990). Para obter previsões de componentes individuais (geralmente ciclo de tendência, sazonalidade e ciclo), esses componentes identificados são projetados separadamente para o futuro e finalmente recombinados. No entanto, Assimakopoulos e Nikolopoulos (2000) argumentaram que esta abordagem não é frequentemente utilizada na prática. Por outro lado, estes são métodos quantitativos (ou seja, as previsões são obtidas a partir da análise estatística dos dados), não permitindo previsões qualitativas diretas. De acordo com Makridakis et al. (1998), métodos qualitativos podem ser usados com sucesso em conjunto com métodos quantitativos.

Os modelos de decomposição usam como blocos de construção elementares não paramétricos existentes (suavizadores) e modelos básicos paramétricos. Os suavizadores geralmente são baseados em médias móveis locais ou linhas retas, e elas podem ser aplicadas a uma função desconhecida complicada e arbitrária. Assim, os suavizadores são amplamente utilizados no contexto de técnicas de decomposição. Loess, o modelo central usado em STL (Cleveland et al., 1990), e o Supersmoother (Friedman, 1984) são exemplos de suavizadores sofisticados. Por outro lado, modelos paramétricos como polinômios ou modelos lineares de regressões são ferramentas básicas para previsões de médio prazo. Sánchez-Úbeda e Wehenkel (1998) apresentam uma abordagem híbrida para ajuste de curva unidimensional combinando aspectos tanto de metodologias não paramétricas (Supersmoother) quanto paramétricas (polinômio por partes).

A pesquisa literária também indica que estudos anteriores sobre previsão de demanda de gás natural destacam métodos como regressão não linear, redes neurais artificiais, algoritmos genéticos e modelos

baseados em séries temporais, além de enfatizarem a escassez de estudos que utilizam dados regionais diários para prever a demanda de gás natural.

Sánchez-Úbeda e Berzosa (2007) consideram um conjunto de séries diárias de demanda de gás natural para utilização final industrial na Espanha. Vondráček et al. (2008) utilizam um modelo de regressão não linear para estimar o consumo de gás natural de clientes residenciais e pequenos clientes comerciais de maio de 2005 a abril de 2006 na Boêmia Ocidental, República Checa. Azadeh et al. (2011) fizeram projeções anuais da demanda de gás natural em quatro países do Oriente Médio entre 2008 e 2015. Taspinar et al. (2013) consideraram o consumo diário de gás natural na província turca de Sakarya e testaram o desempenho de três métodos - ARIMA sazonal com regressores (SARIMAX), Redes Neurais Artificiais (ANN) com Perceptron Multicamadas (ANN-MLP) e com uma camada de Função de Base Radial (ANN-RBF). Potočník et al. (2014) investigaram modelos estáticos e adaptativos ao prever a demanda diária de gás natural de um distribuidor local na Croácia. Bai and Li (2016) consideram uma abordagem de regressão vetorial de suporte (SVR) para prever o consumo diário de gás natural em Anqing, China. Panapakidis e Dagoumas (2017) combinaram Transformada Wavelet (WT), Algoritmo Genético (GA), Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) e Redes Neurais Feed-Forward (FFNN) para prever a demanda de gás natural para o dia seguinte em pontos de distribuição gregos selecionados. Özmen et al. (2018), por sua vez, usaram de regressão adaptativa Splines multivariada e cônica (MARS e CMARS) para prever o consumo de gás residencial para o dia seguinte em Ancara, Turquia. Beyca et al. (2019) concentram-se em ferramentas de machine learning para prever o consumo de gás natural com 12 meses de antecedência na província de Istambul.

De toda forma, observa-se um número limitado de estudos sobre modelos de previsão de demanda de gás natural usando dados regionais



em base diária. Entre estes modelos, métodos de previsão estatística e estocástica são empregados para estimativa de energia de curto prazo em poucos países. Yumurtaci e Asmaz (2004) e Akay e Atak (2007) propuseram uma abordagem baseada em previsão com mecanismo de rolamento para prever o consumo total e industrial de energia da Turquia. Ceylan et al. (2008) desenvolveram uma abordagem para prever a demanda de energia para transporte usando o algoritmo de busca de harmonia. Ozturk et al. (2004) usaram o algoritmo genético para estimar a demanda de energia para a Turquia. Eles desenvolveram um algoritmo genético baseado no modelo de estimativa para prever a demanda de energia residencial-comercial da Turquia com base no PIB, população, importação, exportação, previsão de habitação, produção de cimento e números de consumo de eletrodomésticos básicos. Hamzaçebi (2009) usou de redes neurais artificiais (ANN) para estimar consumo líquido de eletricidade setorial da Turquia. Kavaklioglu (2011) desenvolveu metodologia de regressão vetorial para prever o consumo de eletricidade da Turquia. Toksari (2007) propôs o algoritmo de colônia de formigas para estimar a demanda de energia para a Turquia. Além desses estudos, um pequeno número de métodos é utilizado por poucos investigadores para estimar a demanda de gás natural para a Turquia. Kiliç (2006) estudou consumo de gás natural e política energética na Turquia e concluiu que o gás desempenha um papel fundamental para alcançar os objetivos social e econômico da Turquia como fonte de energia primária. Durmayaz et. al (2000) empregaram o método graus-hora para estimar necessidade de energia para aquecimento residencial e consumo sazonal de gás natural em Istambul. Gumrah et al. (2010) usaram abordagem grau-dia para modelar a demanda de gás natural para Ancara, Turquia. Sarak e Satman (2003) implementaram o método graus-dia para estimar consumo de gás natural para aquecimento residencial na Turquia. Gorucu et al. (2004) usaram as ANNs para prever o consumo de gás natural na Província de Ancara. Demirel et al. (2012) propuseram um método para prever o

consumo de gás natural em Istambul usando ANNs e métodos de séries temporais multivariadas. Aras e Aras (2004) dividiram o ano em estações de aquecimento e de não aquecimento e utilizaram quantidade mensal de consumo de gás natural nas residências e temperaturas médias diárias, a fim de modelar e prever consumo de gás natural nas residências. Erdogdu (2010) focou nas características da demanda de gás natural e estimou o preço de curto e longo prazos e elasticidade à renda e estimou o crescimento futuro da demanda usando uma modelagem ARIMA e comparando esses resultados com as projeções oficiais. Toksari (2012) apresentou uma abordagem heurística para estimar a demanda de gás natural da Turquia com base em indicadores econômicos. Kizilaslan e Karlik (2009) usaram a informação de consumo mensal de gás natural com dados adicionais de temperatura para sete diferentes algoritmos treinados em ANNs para previsão de consumo mensal de gás natural em Istambul. Isik (2010) examinou o papel do consumo de gás natural no crescimento econômico turco, utilizando o modelo de lag distribuído autorregressivo (ARDL) durante o período de 1977–2008.

Ou seja, os estudos abordaram a demanda de gás em diferentes contextos, incluindo setores residenciais, industriais e comerciais e métodos como algoritmos genéticos, redes neurais e modelos SARIMAX são empregados para prever a demanda diária de gás natural em várias regiões da Turquia.

Existem também alguns estudos semelhantes realizados em diferentes países. Xiong et al. (2021) estimaram a demanda de gás natural para áreas residenciais e industriais na Ásia com base em indicadores econômicos usando o Algoritmos de otimização de Bee e Particle Swarm. Nessa pesquisa, crescimento populacional, o PIB, a produção de gás natural e exportação de gás foram usados para estimar o consumo de gás natural usando um modelo linear. Iranmanesh et al. (2011) propuseram um modelo baseado em uma combinação de mínimos quadrados e de técnicas

de suporte vetorial para estimar o consumo de gás natural a curto prazo no Irã e EUA. Forouzanfar et al. (2010) empregaram uma programação não linear com algoritmos genéticos para prever o consumo de gás natural em locais residenciais e não residenciais, considerando conjunto de dados medidos sazonalmente e anualmente, respectivamente. Tavakoli e Montazerin (2011) estudaram o consumo de gás natural em edifícios residenciais e comerciais em Tehrân usando diversas características de consumo com abordagem de análise probabilística e emprego de distribuição binomial analítica para encontrar o consumo médio em dois casos diferentes de 500 e 1000 edifícios. Wadud et al. (2011) desenvolveram um modelo econométrico dinâmico para prever a demanda de gás natural tanto no país todo quanto em regiões em Bangladesh. Ozturk et al. (2004) desenvolveram um algoritmo genético baseado em dados de entrada de energia para prever a demanda futura de insumos de energia residencial-comercial com base no PIB, população, importação, exportação, previsão de casas, produção de cimento e números de consumo de eletrodomésticos básicos. Unler (2008) propôs um modelo, usando previsão de demanda de energia baseada em PSO (Particle swarm optimization), para prever a demanda de energia da Turquia. Para mostrar a precisão do modelo proposto, o autor comparou seu estudo com o modelo de estimativa de demanda de energia de otimização de colônia de formigas (ACO). Fatih Taspınar et al. (2013) modelaram o consumo diário de gás natural usando o modelo SARIMAX, modelos ANN-MLP e ANN-RBF utilizando alguns dados meteorológicos. Dados meteorológicos incompletos foram preenchidos por técnicas de regressão local e depois analisado estatisticamente para pré-processar. Posteriormente, o modelo de série temporal mais apropriado foi escolhido usando métodos estatísticos em dados estacionários e foram estimados os parâmetros do modelo SARIMAX. Da mesma forma, estrutura dos modelos de ANN-MLP e ANN-RBF foram projetados de acordo com o desempenho de índices e parâmetros de rede neural, como taxa de aprendizagem, contagem de

neurônios ocultos na camada intermediária e função de ativação. Em última análise, todos os modelos são comparados entre si em termos de desempenho de previsão. O SARIMAX, ANN-MLP, ANN-RBF e modelos OLS multivariados são usados para exibir relações entre o consumo diário de gás natural e alguns parâmetros meteorológicos. O modelo SARIMAX funciona bem para previsões de consumo local de curto prazo de gás natural na província de Sakarya, na Turquia, em relação a outros modelos propostos. A temperatura ambiente e a cobertura de nuvens são altamente influentes no consumo de gás natural, conforme esperado. O consumo de gás natural aumenta de acordo com a base do desenvolvimento regional.

A tabela 1 apresenta o resumo dos métodos e modelos utilizados nos artigos estudados para previsão de demanda de gás.

Tabela 1: resumo dos métodos e modelos utilizados nos artigos estudados para previsão de demanda de gás

<b>Autor</b>	<b>Método</b>
Sánchez-Úbeda e Berzosa (2007)	Método de decomposição
Vondráček et al. (2008)	Regressão não linear
Azadeh et al. (2011)	Modelo estocástico
Taspinar et al (2013)	Redes neurais e SARIMAX
Potočník et al. (2014)	Modelo AR e redes neurais
Bai and Li (2016)	Regressão vetorial de suporte
Panapakidis e Dagoumas (2017)	Redes neurais
Özmen et al. (2018)	Regressão multivariada
Beyca et al. (2019)	<i>Machine learning</i>
Durmaz et al (2000)	Método graus-hora
Gumrah et al. (2010)	Redes neurais
Sarak e Satman (2003)	Método graus-dia
Gorucu et al (2004)	Redes neurais
Demirel et al. (2012)	Redes neurais e métodos multivariados
Aras e Aras (2004)	Métodos autoregressivos
Erdogdu (2010)	ARIMA
Toksari (2012)	Método heurístico
Kizilaslan e Karlik (2009)	Redes neurais
Isik (2010)	Método regressivo com crescimento populacional

<b>Autor</b>	<b>Método</b>
Xiong et al. (2021)	Modelo cinza gama incompleto de ordem fracionária
Iranmanesh et al. (2011)	Regressão vetorial de suporte
Forouzanfar et al. (2010)	Programação não linear e algoritmo genético
Tavakoli e Montazerin (2011)	Método estocástico
Wadud et al. (2011)	Modelo econométrico
Fatih Taspınar et al. (2013)	SARIMAX e redes neurais

Talagala et al. (2023) abordam a crescente necessidade das empresas de prever grandes volumes de séries temporais para operar de forma eficiente, como vendas, custos e demanda de produtos, e destacam a dificuldade na seleção do modelo mais apropriado para previsão. O artigo propõe então o FFORMS, um algoritmo rápido de seleção de modelos com base em meta-aprendizado, que utiliza características das séries temporais para automatizar a escolha do modelo.

A tarefa do algoritmo de Talagala et al. (2023) foi identificar o melhor método de previsão para uma determinada frequência de uma série temporal, dentre os modelos white noise (ruído branco), processo autorregressivo de média móvel (ARMA), combinação entre os métodos de diferenciação e os modelos de autoregressão e média móvel (ARIMA), autorregressivo integrado de médias móveis com sazonalidade (SARIMA), teoria do passeio aleatório (random walk), teoria do passeio aleatório com constante (random walk with drift), método de decomposição da série temporal em duas séries temporais chamadas linhas theta (método theta, onde a primeira linha theta remove completamente a curvatura dos dados, sendo assim um estimador para a tendência a longo prazo, e a segunda linha theta dobra a curvatura da série sendo assim um estimador para a componente de curto prazo), método de decomposição com modelagem autorregressiva com ajuste sazonal, a técnica de classificação probabilística seasonal naive (método ingênuo sazonal), técnica de suavização exponencial agregada com a transformação de Box-Cox, erros

ARMA e componentes de tendência e sazonalidade (tbats), método de padrão de comportamento com base em redes neurais, decomposição múltipla com modelagem de suavização exponencial (ETS) da série com ajuste sazonal (mstlets) e decomposição múltipla com modelagem ARIMA da série com ajuste sazonal (mstlarima).

Como resultado, Talagala et al. (2023) indicam os modelos de previsão mais apropriados a depender da frequência dos dados das séries temporais. O apêndice desta dissertação reproduz os resultados de Talagala et al., resumindo quais métodos que melhor se aplicam a diferentes frequências de séries temporais.

A leitura dos artigos indica a necessidade de desenvolver modelos mais precisos e abrangentes para prever a demanda de gás natural, especialmente considerando fatores regionais e usando abordagens que combinem métodos quantitativos e qualitativos. Existe uma falta de unanimidade sobre a aplicação de métodos amplamente divulgados na literatura científica para a previsão de demanda de gás natural e a proposta deste trabalho é de utilizar os modelos indicados pelo artigo da Talagala (2023), para dados reais de demanda, nas frequências diária e semanal, de gás natural, referentes aos anos de 2021 a 2023, por meio da aplicação de funções modeladas nos pacotes de previsão do software R (Hyndman et al., 2021).

Os resultados devem ter a função de apoiar os processos de tomada de decisão de planejamento de produção e importação de gás de uma grande empresa brasileira do setor de óleo e gás, considerando a gama de pontos de oferta de gás na malha nacional, incluindo os terminais de regaseificação estrategicamente localizados na costa do Brasil.

**3. Metodologia**

Os dados de consumo diário de gás utilizados neste trabalho foram obtidos dos Relatórios de Movimentação de Gás Natural em Gasodutos de Transporte, divulgados mensalmente pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, 2024).

São utilizados os dados de volumes diários realizados pelos cento e oitenta e cinco pontos de entrega medidos ao longo da malha de gasodutos distribuída no território nacional, no período entre 01 de janeiro de 2021 a 31 de dezembro de 2023.

É proposto um método de organização dos pontos de entrega em onze conglomerados de pontos e gasodutos, intitulados de grupos de mercado, com base nos mercados atendidos, conforme detalhado na tabela 2. Foram excluídos os pontos de consumo relacionados aos sistemas de gasodutos isolados, ou seja, não conectados à malha integrada nacional de gasodutos.

Tabela 2: Proposta de mercado na malha integrada de gasodutos

<b>Grupo de mercado</b>	<b>Gasodutos</b>	<b>Pontos de entrega (pontos de consumo)</b>
GASFOR	GASFOR	Fazenda Belém, CEGAS, POTIGAS – somente o ponto de consumo localizado em Mossoró – e Refinaria de Lubrificantes e Derivados do Nordeste (LUBNOR), descontados o consumo das usinas termoeletricas Termofortaleza, Termoceará e Jesus Soares Pereira.
Catu-Guamaré	Atalaia, Catu-Pilar, GASALP, Nordestão, Pilar, Pilar-Ipojuca	POTIGAS – exceto o ponto de consumo localizado em Mossoró –, PBGAS, COPERGAS, ALGAS, SERGAS, FAFENSE, usina termoeletrica Termopernambuco, RNEST e Fazendas Bálsamo, Alvorada e Araçás (consumo E&P).

Malha Bahia	Aratu, Camaçari, Candeias-Catu 12", Candeias-Camaçari 12", Catu	BAHIAGAS – pontos de consumo de Caboto, Catu EDG, Catu UPGN, Camaçari, Chesf, Camaçari-Manati, Cadeias Residual, Candeias-Manati, Cia Salvador, usinas termelétricas Celso Furtado, Rômulo Almeida, Chesf Camaçari, Refinaria de Mataripe (antiga Refinaria Landulpho Alves), Cexis e FAFEN-BA.
GASENE	Cacimbas-Vitória, Gasene-Lagoa-Parda-Vitória, GASCAC, Cacimbas-Vitória e GASCAV	BAHIAGAS – pontos de consumo de Mucuri, Eunápolis, Itabuna e Veracel, ESGAS, Naturgy (antiga CEG-RIO) - ponto de consumo de Campos do Goytacazes - e usina termelétrica de Linhares.
Cabiúnas-REPLAN	GASDUC III, Anel de Gás, Campos Elíseos, GASCAR, GASJAP, GASPAL, GASTAU e GASVOL	Naturgy (antiga CEG-RIO) – pontos de consumo de Cabiúnas, Guapimirim, Metropolitano, Paracambi, Piraí, Volta Redonda, Cidade do Aço, Barra Mansa e Resende, CEG (também adquirida pela Naturgy), COMGAS – pontos de consumo de Cruzeiro, Lorena, Pindamonhangaba, Taubaté, São José dos Campos, Bragança Paulista, Caçapava e Guaratinguetá –, usinas termelétricas Norte Fluminense, Mário Lago, Governador Leonel Brizola, Barbosa Lima Sobrinho, Baixada Fluminense, Santa Cruz, Unidade de Tratamento de Gás Natural de Cabiúnas, REDUC e REVAP.
GASPAJ	GASPAJ	GASMIG – ponto de consumo de Jacutinga.
GASBEL	GASBEL I, GABEL II	CEG-RIO (Rio das Flores), GASMIG – exceto ponto de consumo de Jacutinga, usinas termelétricas de Juiz de Fora e Aureliano Chaves e Refinaria Gabriel Passos.
São Paulo	GASAN, GASAN II, GASPAL II e GASPAL (parcial)	COMGÁS – pontos de saída Suzano, Capuava, São Bernardo do Campo, São Bernardo do Campo 2 e Cubatão -, usinas termelétricas Fernando Gasparian e Euzébio Rocha, RECAP e RPBC.
TN GASBOL	Trecho norte do GASBOL	MSGAS, GBD, usinas termelétricas Luis Carlos Prestes e Willian Arjona, Refinaria



		de Paulínia e COMGAS – pontos de consumo de Rio Claro, Itirapina, Limeira, Americana, Jaguariúna, Itatiba e Guararema.
TS 1 GASBOL	Trecho sul do GASBOL	Demais pontos da COMGAS – pontos de consumo de Sumaré, Campinas e Indaiatuba, GEMINI, SPSUL, COMPAGAS, Usina Termelétrica de Araucária, REPAR, SCGAS – pontos de consumo Joinville, Guaramirim, Gaspar (Blumenau), Brusque e Tijucas.
TS 2 GASBOL	Trecho extremo sul do GASBOL	SCGAS – pontos de consumo de São Pedro Alcântara, Tubarão, Urussanga (Cocal do Sul) e Nova Veneza, SULGAS, Usina Termelétrica Sepé Tiaraju e REFAP.

Especificamente no que tange ao grupo de mercado ‘GASFOR’, foram descontados da base de dados o consumo das usinas termelétricas Termofortaleza, Termoceará e Jesus Soares Pereira. A Termofortaleza é de propriedade da Eneva Energia e teve a sua operação suspensa a partir de 28 de dezembro de 2023 devido à “ausência de perspectiva de suprimento de combustível e o fim do contrato de venda de energia vigente” (Megawhat Energy, 2024), após a parada do terminal de regaseificação de GNL de Pecém/CE, então supridor de gás na região. A Termoceará é de propriedade da Petróleo Brasileiro S.A. e foi convertida para óleo diesel, combustível alternativo até a retomada da operação de GNL de Pecém/CE (Brasil Energy, 2024). Já a usina Jesus Soares Pereira tem o fornecimento de gás natural condicionado à oferta que chega na região.

Após a organização dos dados, obtém-se um total de 1.064 entradas (observações) por grupo de mercado. A seguir, são apresentados os gráficos com as séries temporais da demanda diária de gás natural, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ ).




Figura 2: Séries temporais da demanda diária de gás natural no GASFOR, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 3: Séries temporais da demanda diária de gás natural no trecho Catu-Guamaré, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 4: Séries temporais da demanda diária de gás natural no trecho Malha Bahia, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 5: Séries temporais da demanda diária de gás natural no GASENE, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 6: Séries temporais da demanda diária de gás natural no trecho Cabiúnas-Replan, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m³/d)




Figura 7: Séries temporais da demanda diária de gás natural no GASPAJ, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m³/d)




Figura 8: Séries temporais da demanda diária de gás natural no GASBEL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m³/d)




Figura 9: Séries temporais da demanda diária de gás natural no trecho São Paulo, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia (x1000 m³/d)




Figura 10: Séries temporais da demanda diária de gás natural no trecho norte do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 11: Séries temporais da demanda diária de gás natural no trecho sul 1 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 12: Séries temporais da demanda diária de gás natural no trecho sul 2 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )

As séries temporais demonstram, em sua maioria, características de sazonalidade devido principalmente à volatilidade do despacho térmico. Em 2021, observou-se que o consumo de gás natural pelas termelétricas do país cresceu 160% no 3º trimestre de 2021, na comparação com o mesmo período de 2020. O aumento da destinação para as usinas térmicas se deve ao aumento no despacho dessa fonte para o SIN, em função da escassez hídrica. Com a queda no fornecimento por parte das hidrelétricas brasileiras, as usinas a gás foram as principais responsáveis por atender à demanda no sistema elétrico (Poder 360, 2021).

A partir de 2022, verifica-se um forte aumento da geração hidráulica decorrente da melhora dos índices pluviométricos e da mudança das estratégias adotadas na gestão da crise hídrica de 2021 (MME, 2022). Além disso, verifica-se também um aumento da geração eólica e solar nos últimos anos, o que também altera o propósito da geração térmica, que passa a ter um papel de complementar as outras fontes de geração em razão do comportamento intermitente ao longo do dia. Durante as primeiras horas do dia, a energia solar tem maior pico de geração, substituída pela geração eólica na parte da tarde, mas que não necessariamente consegue

cobrir o déficit solar, tendo a geração térmica cumprido a função de compensar as demais fontes renováveis.

Diante da indicação da pesquisa literária acerca da escassez de estudos que utilizam dados regionais diários para prever a demanda de gás natural e da relevância da demanda de gás no segmento térmico, neste trabalho optou-se por utilizar também dados médios semanais, através da conversão dos dados referentes ao período que se inicia às 00:00 do sábado e termina às 23:59 da sexta-feira. No setor elétrico brasileiro, convencionou-se que a semana operativa tem seu início no sábado e seu término na sexta-feira.

A base de dados convertida em médias semanais totaliza 157 observações por cada um dos onze grupos de mercado. A seguir, são apresentados os gráficos com as séries temporais da demanda de gás natural, convertidos para médias semanais, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ ).




Figura 13: Séries temporais da demanda média semanal de gás natural no GASFOR, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )






Figura 14: Séries temporais da demanda média semanal de gás natural no trecho Catu Guamaré, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 15: Séries temporais da demanda média semanal de gás natural no trecho Malha Bahia, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 16: Séries temporais da demanda média semanal de gás natural no GASENE, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 17: Séries temporais da demanda média semanal de gás natural no trecho Cabiúnas Replan, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 18: Séries temporais da demanda média semanal de gás natural no GASPAJ, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 19: Séries temporais da demanda média semanal de gás natural no GASBEL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )



Figura 20: Séries temporais da demanda média semanal de gás natural no trecho São Paulo, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 21: Séries temporais da demanda média semanal de gás natural no trecho norte do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 22: Séries temporais da demanda média semanal de gás natural no trecho sul 1 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )




Figura 23: Séries temporais da demanda média semanal de gás natural no trecho sul 2 do GASBOL, no período entre 1 de janeiro de 2021 a 31 de dezembro de 2023, em mil metros cúbicos por dia ( $\times 1000 \text{ m}^3/\text{d}$ )

A aplicação das funções foi realizada através dos pacotes de previsão do software RStudio, *forecast*, de acordo com os modelos indicados por Talagala (2023) para cada tipo de frequência. Para a base de dados diários, foram aplicados nove modelos, quais sejam, *wn*, *rwd*, *rw*, *theta*, *stlar*, *snaive*, *tbats*, *nn* e *mstlets*. Para a base de dados semanais, foram executadas as funções *wn*, *arima*, *rwd*, *rw*, *theta*, *stlar*, *snaive*, *tbats*, *nn* e *mstlets*.

Os dados de 01 de janeiro de 2021 a 30 de novembro de 2023 foram utilizados como base histórica e ajustados para cada modelo candidato de previsão, denominada de período ‘treino’, tendo sido excluídos das bases os dados relativos a dezembro de 2023.

Os modelos de previsão foram utilizados para obtenção de previsões para uma amostra a partir do ‘treino’, sendo estabelecido o período de trinta dias futuros para dados diários, e quatro semanas para dados médios semanais, os quais foram denominados ‘teste’.

Para efetivar a implementação dessa abordagem nos dados diários, foram aplicadas as seguintes funções do pacote *forecast* do R: *rwf*, com e sem drift, *thetaf*, *stlm*, *snaive*, *tbats*, *nnetar* e *mstl* com *ets*. Para a abordagem de ruído branco, a média dos últimos trinta dias foi repetida para os 30 passos à frente.

No caso da previsão para dados semanais, foram utilizadas as seguintes funções do pacote *forecast* do R: *auto.arima*, *rwf*, com e sem drift, *thetaf*, *stlm*, *snaive*, *tbats*, *nnetar* e *mstl* com *ets*. Na abordagem ruído branco, foi repetida a média das últimas 4 semanas para os 4 passos à frente.

Os modelos são utilizados para gerar as previsões para cada uma das séries temporais no horizonte de previsão ‘teste’ e é realizada uma avaliação da precisão dos métodos a partir de uma análise comparativa das métricas de desempenho dos resultados oriundos dos métodos de previsão e os dados reais fora da amostra.

A primeira métrica de desempenho utilizada é o erro Percentual Absoluto Médio (MAPE - do inglês Mean Absolute Percentual Error), que mostra a porcentagem de erro em relação aos valores reais. A equação abaixo representa o cálculo de MAPE.

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)}$$

Onde  $y_i$  é o valor real,  $\hat{y}_i$  é o valor previsto e  $n$  é o número de pontos ajustados. O resultado de MAPE significa que o modelo faz previsões que, em média, a diferença entre o valor previsto e o real equivale ao percentual indicado tanto para mais quanto para menos. Ou seja, um percentual baixo representa um modelo mais preciso.

A segunda métrica para avaliação da precisão dos métodos é a Raiz do Erro Quadrático Médio (RMSE - do inglês, Root Mean Squared Error), que é a raiz quadrada da média dos erros quadrados (quadrado da diferença entre o valor predito e o valor real).

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Onde  $y_i$  é o valor real,  $\hat{y}_i$  é o valor previsto e  $n$  é o número de pontos ajustados. A unidade da métrica é a própria unidade da variável que está sendo prevista e uma resultante mais baixa indica um modelo mais preciso.

Por fim, a terceira métrica é o Erro Médio Escalado Absoluto (MASE - do inglês, Mean Absolute Scaled Error), calculada dividindo o erro médio por um fator de escalabilidade. Esse fator de escalabilidade depende do valor da sazonalidade, que é selecionado com base na frequência da previsão.

$$MASE = \frac{1}{T} \sum_{t=1}^T \left( \frac{|e_t|}{\frac{1}{T-m} \sum_{t=m+1}^T |Y_t - Y_{t-m}|} \right) = \frac{\sum_{t=1}^T |e_t|}{\frac{T}{T-m} \sum_{t=m+1}^T |T_t - Y_{t-m}|}$$

Onde  $t$  é a variável tempo,  $m$  é a frequência e  $e$  é o erro. O MASE é ideal para conjuntos de dados de natureza cíclica ou com propriedades sazonais. Um valor mais baixo indica um modelo mais preciso.

Com base nas três métricas, o modelo com a menor medida de erro de previsão durante o período de teste é considerado “melhor”. O resultado

esperado é indicar qual modelo de previsão apresenta maior acurácia para as séries analisadas.

Talagala (2023) avaliou o desempenho dos modelos através do MASE para cada horizonte de previsão e pela média dos MASE de todas as séries para cada categoria de frequência.



#### **4. Resultados e Discussões**

O objetivo deste trabalho foi de propor um novo método de organização dos dados, com base nos diferentes mercados de gás natural e os balanços regionais de oferta e demanda, para analisar o desempenho dos métodos de previsão na aplicação em séries de dados, em bases diária e semanal, a partir da indicação do artigo de Talagala (2023).

As métricas resultantes da aplicação de cada método de previsão foram avaliadas para que aqueles que indiquem maior precisão possam ser replicados pela empresa para dados futuros, de modo a apoiar os processos de tomada de decisão de planejamento de produção e importação de gás de uma grande empresa brasileira do setor de óleo e gás, considerando a gama de pontos de oferta de gás na malha nacional.

Nas seções a seguir, são descritos os resultados para cada categoria de frequência.

##### **4.1. Dados Diários**

O estudo para previsão da demanda de gás se iniciou com a coleta dos dados diários, desde 01 de janeiro de 2021 até 31 de dezembro de 2023, as quais foram organizadas em onze grupos de mercado, perfazendo um total de 1064 observações.

Após a adequação dos modelos aos dados, para cada uma das séries, as previsões foram geradas para o horizonte de 30 dias. Assim, dos 1064 dados, 1034 foram utilizados para o treino e 30 para o teste, e foram calculadas as métricas de desempenho.

As tabelas a seguir indicam os resultados das métricas MAPE, RMSE e MASE dos modelos de previsão em relação aos valores reais 30 passos à frente para cada área de mercado. Os valores em negrito destacam o modelo de previsão com melhor desempenho para cada área de mercado, a depender da métrica utilizada.

Tabela 3: MAPE da amostra teste para dados diários, em %.

Áreas de Mercado	snaive	rwd	rw	theta	stlar	Wn	tbats	nn	mstlets
GASFOR	10,77	7,85	7,95	8,23	11,40	7,84	7,04	<b>6,75</b>	8,25
Catu-Guamaré	16,96	10,43	10,66	10,18	9,86	23,61	9,94	<b>8,17</b>	10,46
Malha Bahia	64,24	16,84	16,62	16,13	15,30	43,04	14,32	<b>11,48</b>	15,99
GASENE	22,81	<b>5,11</b>	5,35	5,11	6,18	21,11	5,50	9,39	5,23
Cabiúnas-Replan	<b>23,01</b>	29,56	29,66	29,51	32,31	44,73	24,08	25,20	26,17
GASPAJ	15,32	7,74	7,74	7,27	7,42	6,85	<b>5,82</b>	7,34	7,34
GASBEL	17,18	10,94	10,95	10,92	<b>10,12</b>	25,06	10,78	25,07	10,95
São Paulo	10,25	9,18	9,20	9,08	12,36	11,95	<b>7,81</b>	8,73	9,20
TN GASBOL	10,24	8,31	8,34	8,53	8,87	11,58	7,28	<b>7,21</b>	8,39
TS1 GASBOL	11,32	12,00	11,36	11,01	15,39	11,53	12,14	<b>7,21</b>	11,37
TS2 GASBOL	12,85	6,66	6,65	7,36	8,11	10,66	8,58	<b>4,94</b>	7,17

Tabela 4: RMSE da amostra teste para dados diários, em mil m<sup>3</sup>/d.


Áreas de Mercado	snaive	rwd	rw	theta	stlar	wn	tbats	nn	mstlets
GASFOR	76,3	57,2	57,8	58,6	81,0	57,4	<b>52,3</b>	58,9	58,7
Catu-Guamaré	826,8	591,1	598,4	583,9	647,2	1095,2	576,9	<b>528,3</b>	592,6
Malha Bahia	2459,3	717,2	709,1	690,2	666,3	1654,3	619,9	<b>512,0</b>	685,3
GASENE	567,2	<b>145,8</b>	150,2	146,8	177,1	508,5	173,4	274,2	148,5
Cabiúnas-Replan	4782,9	4311,5	<b>4278,9</b>	4320,5	4984,3	5942,6	4663,5	5075,3	4443,6
GASPAJ	42,5	20,5	20,5	19,4	22,4	18,5	<b>16,9</b>	19,5	19,5
GASBEL	552,1	531,8	529,9	535,6	<b>453,9</b>	786,9	530,9	1056,9	530,0
São Paulo	930,9	834,0	835,3	826,3	1120,2	1029,2	759,6	<b>758,2</b>	835,3
TN GASBOL	923,0	891,6	<b>884,5</b>	1030,7	997,0	1009,8	889,9	935,9	1013,1
TS 1 GASBOL	709,4	643,7	621,3	608,2	849,2	628,0	671,4	<b>419,3</b>	621,5
TS2 GASBOL	380,5	231,7	231,3	254,0	279,1	327,5	287,9	<b>165,6</b>	247,3

Tabela 5: MASE da amostra teste para dados diários

Áreas de Mercado	snaive	rwd	rw	theta	stlar	tbats	nn	mstlets
GASFOR	0,67	0,49	0,50	0,52	0,73	<b>0,44</b>	0,53	0,52
Catu-Guamaré	0,41	0,26	0,26	0,25	0,25	<b>0,24</b>	0,30	0,26
Malha Bahia	1,77	0,44	0,44	0,42	0,40	0,37	<b>0,34</b>	0,42
GASENE	0,86	0,20	<b>0,20</b>	0,20	0,23	0,22	0,37	0,20
Cabiúnas-Replan	0,40	0,42	0,42	0,42	0,48	<b>0,40</b>	0,43	0,41
GASPAJ	0,98	0,50	0,50	0,48	0,49	<b>0,39</b>	0,48	0,48
GASBEL	0,72	0,53	0,53	0,53	<b>0,48</b>	0,52	1,17	0,53
São Paulo	0,56	0,48	0,49	0,48	0,66	<b>0,44</b>	0,47	0,49
TN GASBOL	0,49	0,41	0,41	0,44	0,44	<b>0,37</b>	0,37	0,43
TS 1 GASBOL	0,42	0,41	0,39	0,37	0,55	0,45	<b>0,26</b>	0,39
TS2 GASBOL	0,80	0,44	0,44	0,49	0,52	0,56	<b>0,31</b>	0,47

Conforme já mencionado, valores mais baixos indicam modelos mais precisos. A figura 24 mostra que os dados oriundos dos grupos de mercado GASFOR, GASPAJ, São Paulo, trecho norte do GASBOL, trecho sul 1 do GASBOL e trecho sul 2 do GASBOL indicam menores valores de MAPE, o que pode ser explicado por bases de dados menos afetadas pela sazonalidade do mercado térmico, impactando positivamente os modelos.

Figura 24: MAPE para aplicação dos modelos de previsão, para categoria de frequência diária



No geral, os resultados do nn e tbats foram os que apresentaram melhor desempenho do que os demais modelos de previsão para as séries temporais em base diária.

Tabela 6: Modelos mais precisos por área de mercado, em base diária

Áreas de Mercado	Modelo de previsão com menor MAPE	Modelo de previsão com menor RMSE	Modelo de previsão com menor MASE
GASFOR	nn	tbats	tbats
Catu-Guamaré	nn	nn	tbats
Malha Bahia	nn	nn	nn
GASENE	theta	rwd	theta
Cabiúnas-Replan	snaive	rw	tbats
GASPAJ	tbats	tbats	tbats
GASBEL	stlar	stlar	stlar
São Paulo	tbats	nn	tbats
TN GASBOL	nn	rw	tbats
TS 1 GASBOL	nn	nn	nn
TS2 GASBOL	nn	nn	nn

A previsão de séries temporais utilizando redes neurais foi melhor em quatorze aplicações dos modelos. Trata-se de um método mais sofisticado que se baseia no funcionamento do cérebro, se assemelham ao neurônio humano, onde sinais são recebidos pelo mesmo com intensidades diferentes, provocando uma determinada reação por parte da célula nervosa. O segundo modelo com maior destaque foi a técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats), com dez aparições, que tem alta capacidade para modelar séries temporais com padrões sazonais complexos. Ambos os modelos são complexos, mas demonstraram uma maior precisão para dados diários.

Abaixo, a título de exemplo, são apresentados os gráficos contendo a série temporal histórica de teste, em preto, e o treino com 30 passos à

frente, em azul, para aplicação dos modelos de redes neurais e técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) na série de dados do GASFOR, em base diária.

Figura 25: Previsão com modelo de redes neurais para série de dados GASFOR, em base diária.





Figura 26: Previsão com a técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) para série de dados GASFOR, em base diária



A aplicação dos modelos para os grupos Malha Bahia, GASENE, Cabiúnas-Replan e GASBEL foram aqueles que apresentaram piores métricas de desempenho. No caso, da Malha Bahia, o comportamento dos volumes relativos à Bahiagas é bastante estável, entretanto, as três usinas termelétricas, UTE Celso Furtado, UTE Rômulo Almeida e UTE CHESF Camaçari, além da unidade de fertilizantes localizada no estado impactam

o comportamento devido ao consumo a depender da operação ou não de tais unidades, diretamente influenciadas pela necessidade de geração térmica para complementar a matriz elétrica brasileira ou preço do gás, no caso das unidades de fertilizantes.

No caso de GASENE, Cabiúnas-Replan e GASBEL, o mercado térmico é a principal fonte do comportamento volátil apresentado, dado que, conforme já descrito, em 2021 há grande despacho térmico, não continuado nos anos de 2022 e 2023 em que se verificou o aumento da geração hidráulica decorrente da melhora dos índices pluviométricos e da mudança das estratégias adotadas pelo ONS.

No caso de Talagala (2023), os modelos que apresentaram menores valores de MASE para dados diários foram random walk with drift (passeio aleatório com derivada), random walk (passeio aleatório) e o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats), este último coincidindo com o resultado encontrado no presente trabalho.

#### 4.2. Dados convertidos em médias semanais

Tabela 7: MAPE da amostra teste para dados convertidos em médias semanais, em %.

Áreas de Mercado	arima	snaive	rwd	rw	theta	stlar	wn	tbats	nn	mstlets
GASFOR	11,93	<b>1,85</b>	17,71	17,46	14,24	5,11	8,57	3,68	15,58	14,09
Catu-Guamaré	28,10	17,47	27,63	28,10	25,93	<b>15,99</b>	35,60	28,04	20,58	26,61
Malha Bahia	4,04	53,25	4,11	4,07	4,11	4,85	26,28	9,83	<b>3,72</b>	4,07
GASENE	4,22	27,49	4,79	4,22	4,48	<b>3,08</b>	18,84	4,22	4,32	4,22
Cabiúnas-Replan	27,60	<b>23,02</b>	23,82	25,28	24,15	24,41	69,23	29,43	42,20	25,51
GASPAJ	25,47	24,40	30,30	30,41	26,75	24,24	25,46	<b>20,23</b>	28,59	26,92
GASBEL	14,36	14,19	17,50	17,76	14,89	<b>6,92</b>	29,68	10,12	19,88	15,28
São Paulo	17,20	13,01	14,59	14,97	16,75	<b>9,05</b>	31,10	17,15	16,08	17,46

Áreas de Mercado	arima	snaive	rwd	rw	theta	stlar	wn	tbats	nn	mstlets
Trecho norte do GASBOL	17,18	<b>6,58</b>	16,72	17,24	15,96	10,00	26,82	10,17	17,86	16,30
Trecho Sul 1 do GASBOL	30,95	<b>13,30</b>	32,21	32,94	35,08	13,81	52,87	14,83	76,31	36,25
Trecho Sul 2 do GASBOL	10,04	3,53	12,09	12,29	11,11	2,60	20,17	<b>1,37</b>	7,50	11,47

Tabela 8: RMSE da amostra teste para dados convertidos em médias semanais, em mil m<sup>3</sup>/d.

Áreas de Mercado	arima	snaive	rwd	rw	theta	stlar	wn	tbats	nn	mstlets
GASFOR	73	<b>11</b>	104	102	87	33	59	24	94	86
Catu-Guamaré	1.218	771	1.192	1.218	1.100	<b>758</b>	1.499	1.214	839	1.136
Malha Bahia	252	2.304	195	194	195	228	1.137	449	<b>187</b>	194
GASENE	129	665	137	129	132	<b>93</b>	452	129	131	129
Cabiúnas-Replan	3.108	<b>2.531</b>	2.709	2.840	2.737	3.041	7.403	3.284	4.947	2.866
GASPAJ	59	51	69	70	61	52	57	<b>45</b>	65	62
GASBEL	424	433	528	537	447	<b>218</b>	878	344	601	459
São Paulo	1.222	867	1.049	1.084	1.195	<b>656</b>	2.009	1.219	1.108	1.236
Trecho norte do GASBOL	1.322	<b>520</b>	1.314	1.349	1.267	735	1.914	769	1.280	1.298
Trecho Sul 1 do GASBOL	1.110	<b>530</b>	1.156	1.180	1.236	594	1.768	550	2.768	1.273
Trecho Sul 2 do GASBOL	262	102	314	319	290	70	510	<b>62</b>	202	299


Tabela 9: MASE da amostra teste para dados convertidos em médias semanais.

Áreas de Mercado	arima	snaive	rwd	rw	theta	stlar	tbats	nn	mstlets
GASFOR	0,96	<b>0,16</b>	1,43	1,41	1,14	0,41	0,31	1,25	1,13
Catu-Guamaré	0,60	0,37	0,59	0,60	0,56	<b>0,35</b>	0,60	0,46	0,57
Malha Bahia	0,13	1,64	0,13	0,13	0,13	0,15	0,30	<b>0,12</b>	0,13
GASENE	0,18	1,12	0,20	0,18	0,19	<b>0,12</b>	0,18	0,18	0,18
Cabiúnas-Replan	0,31	<b>0,26</b>	0,27	0,28	0,27	0,28	0,33	0,48	0,29
GASPAJ	1,37	1,49	1,63	1,63	1,45	1,45	<b>1,30</b>	1,54	1,46
GASBEL	0,64	0,62	0,76	0,77	0,66	<b>0,32</b>	0,48	0,87	0,67
São Paulo	0,86	0,67	0,72	0,74	0,83	<b>0,47</b>	0,85	0,81	0,87
Trecho norte do GASBOL	0,70	<b>0,29</b>	0,67	0,69	0,64	0,41	0,43	0,74	0,65
Trecho Sul 1 do GASBOL	0,88	0,40	0,91	0,94	1,01	<b>0,38</b>	0,42	2,19	1,04
Trecho Sul 2 do GASBOL	0,70	0,25	0,85	0,86	0,78	0,19	<b>0,10</b>	0,53	0,80

A figura 27 mostra que os dados oriundos dos grupos de mercado GASFOR e trecho extremo sul do GASBOL indicam uma distribuição de menores valores de MAPE.



Figura 27: MAPE para aplicação dos modelos de previsão, para categoria de frequência semanal



Já a tabela 10 indica que os resultados do snaive e stlar, no geral, foram os que apresentaram melhor desempenho do que os demais modelos de previsão para as séries temporais em base semanal.

Tabela 10: Escolha dos modelos mais precisos por grupo de mercado, em base semanal

Área de Mercado	Modelo de previsão com menor MAPE	Modelo de previsão com menor RMSE	Modelo de previsão com menor MASE
GASFOR	snaive	snaive	snaive
Catu-Guamaré	stlar	stlar	stlar
Malha Bahia	nn	nn	nn
GASENE	stlar	stlar	stlar
Cabiúnas-Replan	snaive	snaive	snaive
GASPAJ	tbats	tbats	tbats
GASBEL	stlar	stlar	stlar
São Paulo	stlar	stlar	stlar
TN GASBOL	snaive	snaive	snaive
TS 1 GASBOL	snaive	snaive	stlar
TS2 GASBOL	tbats	tbats	tbats

A previsão de séries temporais utilizando o modelo stlar foi melhor em treze aplicações dos modelos. O segundo modelo com maior destaque foi o snaive, com onze aparições.

O stlar é o modelo de decomposição sazonal com modelo autorregressivo (AR) e com ajuste sazonal, que utiliza a própria variável alvo para projetá-la a partir da variável no passado. Ou seja, o valor presente da série temporal é definido como uma combinação de valores passados da própria série multiplicados por constantes, cuja ordem equivale ao número de termos anteriores (defasagens) utilizados. Já o snaive é um modelo simples que parte da premissa de que o futuro repetirá o passado e se baseia no período imediatamente anterior. Ambos os modelos são relativamente simples e demonstraram um melhor desempenho para dados semanais.

Os modelos de redes neurais e o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) não apresentaram o mesmo desempenho para dados semanais. A título ilustrativo, as figuras 28 e 29 apresentam os gráficos contendo a série temporal histórica de teste, em preto, e o treino com 4 passos à frente, em azul, para a série de dados GASFOR, em base semanal, para os modelos de redes neurais e o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats), respectivamente.

Figura 28: Previsão com redes neurais para série de dados GASFOR, em base semanal.





Figura 29: Previsão com a técnica de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) para série de dados GASFOR, em base semanal.



Para dados semanais, no artigo de Talagala (2023), os modelos que apresentaram menores valores de MASE foram o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats), modelo utilizado na decomposição e previsão de séries temporais theta e random walk with drift (passeio aleatório com derivada).

#### 4.3. Comparativo com os métodos aplicados pela empresa

Para conduzir as operações do dia a dia, a empresa realiza uma organização de dados de forma distinta à proposta no presente trabalho.

Nela, a demanda brasileira de gás é distribuída em quatro segmentos de mercado, quais sejam, térmico, não térmico, refino e fertilizantes.

O mercado térmico reflete o suprimento das térmicas que são despachadas conforme designado pelo Operador Nacional do Sistema Elétrico (ONS), de modo a atender o mercado com segurança e com o menor custo operacional possível, e por isso, resultam em comportamento mais flexíveis. O mercado não térmico corresponde a uma demanda mais estável, composta pela indústria, transportes e usos residenciais. O segmento de refino reflete o consumo do parque de refino nacional, e normalmente apresentam um comportamento também mais estável. Já o consumo das fábricas de fertilizantes reflete à oportunidade de preço, apresentando um comportamento mais discreto.

Nesse sentido, a variável onde se encontra maior volatilidade e mais complexidade para prever é a demanda para o despacho térmico, diretamente afetada pelo regime de chuvas.

Atualmente, para modelagem dos dados não térmicos é aplicada uma função linear, considerando as variáveis exógenas de Produto Interno Bruto – PIB e do indicador de Pesquisa Industrial Mensal – PIM, publicado pelo Instituto Brasileiro de Geografia e Estatística – IBGE. Em geral, a base de dados utilizada ultrapassa um horizonte de 10 anos e outros métodos de previsão não são aplicados.

No caso dos dados térmicos, as previsões de cenários hidrológicos e dos preços de liquidação das diferenças (PLD) são os insumos para a previsão de despacho por mérito das térmicas, considerando as usinas disponíveis. A partir da previsão de despacho das usinas, obtém-se a demanda de gás natural. A principal ferramenta utilizada é o modelo estocástico univariado desenvolvido pelo CEPEL. Os modelos estocásticos do sistema variam desde os clássicos autorregressivos  $AR(p)$ , ou autorregressivos e de médias  $ARMA(p,q)$  propostos na literatura (Box e

Jenkins, 1970) até modelos periódicos mais sofisticados como o modelo PARMA (p,q) (Hipel e Mcleod, 1994), para os quais são admitidas investigações de até quarta ordem. A previsão de vazões é de suma importância, pois serve de insumo básico para o cálculo do custo marginal e para a definição da geração, objetivando a otimização dos recursos hidrotérmicos e de transmissão existentes.

O uso de múltiplas projeções de demanda reflete, portanto, os propósitos variados. Atualmente, essas previsões são elaboradas para o horizonte de cinco anos à frente, sendo realizados ajustes diários de forma manual, de modo a melhor refletir o dado realizado no horizonte de curto prazo. Sendo assim, a comparação da metodologia apresentada não se mostra adequada, dado que, neste trabalho, é apresentada uma proposta de previsão de demanda de gás, sem discussão dos parâmetros hidrológicos e dos preços de liquidação das diferenças (PLD).

## 5. Conclusões

A previsão é essencial para o bom desempenho das operações logísticas. Os métodos de projeção ajudam a antecipar as decisões, evitar sobrecustos com estoques, falhas de suprimento ou compras de gás e cargas de GNL sem o adequado planejamento. Nesse sentido, a abordagem de séries temporais surge como uma solução para auxiliar a tomada de decisão em diferentes níveis do negócio e aumentar a precisão das previsões.

A revisão literária apresentada neste trabalho destaca a importância das estimativas confiáveis para empresas e operadores de sistemas de energia, especialmente na previsão da demanda de gás natural. Enquanto a literatura tem se concentrado na previsão de demanda de eletricidade, há uma lacuna em estudos sobre modelagem e previsão da demanda de gás natural, especialmente no contexto industrial. Não há consenso sobre quais abordagens são mais adequadas e há poucas evidências de como os métodos funcionam em uma ampla gama de dados.

Neste trabalho, foi proposta uma metodologia para utilização de diferentes métodos de previsão de séries temporais, com diferentes níveis de complexidade, mas acessíveis e de rápida solução, de forma automatizada através da solução do *software* RStudio, para previsão de demanda de 30 passos à frente (equivalentes a 4 passos à frente no caso das séries semanais).

Mais precisamente, este trabalho se propôs a avaliar os métodos de previsão com base no artigo de Talagala (2023), em razão da lacuna em estudos sobre modelagem e previsão da demanda de gás natural. O Capítulo 2 deste trabalho reúne as informações relevantes encontradas sobre o tema em questão

Nesse contexto, foram levantadas informações relevantes sobre o desempenho de cada modelo para previsão de séries temporais e foi

adotada metodologia detalhada no Capítulo 3, que inovou na organização dos dados na forma de grupos de mercado.

As métricas selecionadas, MAPE, RMSE e MASE demonstram a superioridade dos modelos de redes neurais e o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats) para dados diários, enquanto o método de decomposição sazonal com modelagem autorregressiva com ajuste sazonal (stlar) e o método ingênuo sazonal (snaive) foram os que apresentaram melhor desempenho para as séries temporais em base semanal, conforme resultados e discussões apresentadas no Capítulo 4.

A literatura de referência (Talagala, 2023) demonstra que os modelos que apresentaram menores valores de MASE para dados diários foram random walk with drift (passeio aleatório com derivada), random walk (passeio aleatório) e o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats). Já para dados semanais, os modelos que apresentaram menores valores de MASE foram o método de suavização exponencial agregada com a transformação de Box-Cox, erros ARMA e componentes de tendência e sazonalidade (tbats), modelo utilizado na decomposição e previsão de séries temporais theta e random walk with drift (passeio aleatório com derivada).

O trabalho foi capaz de fornecer, de forma simples, direta e satisfatória, a previsão de demanda de gás natural para apoiar os processos de tomada de decisão de planejamento de produção e importação de gás de uma grande empresa brasileira do setor de óleo e gás, considerando a gama de pontos de oferta de gás na malha nacional. Os resultados, mesmo com a inclusão da demanda de gás natural do segmento térmico, altamente volátil, apresentaram desempenho satisfatórios em alguns dos métodos de previsão e têm o propósito de

simplificar as metodologias indireta e complexas para o cálculo de projeção de demanda.

A ferramenta de previsão de demanda de gás por área de mercado poderia ser utilizada para balanceamento regional, considerando as fontes de gás disponíveis e as características logísticas para decisão de produção nacional e importação de gás natural, incluindo a compra de cargas de GNL que requerem antecipação para que o gás possa atravessar o oceano e chegar ao terminal de regaseificação a contento.

Como sugestão de pesquisa futura, pode-se propor a exploração de outras metodologias de organização dos dados, como a divisão dos dados em diferentes mercados e até mesmo na conversão para bases mensais, de modo a avaliar o desempenho dos métodos de previsão de demanda. Considerando ainda a influência dos fatores externos relacionados ao despacho ou não de usinas termelétricas, que por sua vez estão intimamente relacionados aos ciclos de chuvas e estoque dos reservatórios, recomenda-se, para avaliações futuras, aplicar modelos de previsão que incluam variáveis exógenas, como o despacho de térmicas ou a previsão de chuvas como fator explicativo.

Além disso, uma sugestão futura poderia ser também a segmentação dos dados por tipo de demanda, para agregação do estudo com séries hierárquicas.

Por fim, recomenda-se que a mesma metodologia seja aplicada em outros setores buscando encontrar padrões de comportamento e, conseqüentemente, formular conclusões mais generalistas sobre o modelo mais adequado para aplicação em dados diários e semanais.



## **6. Referências Bibliográficas**

Akay, D. & Atak, M. (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy* Volume 32, Issue 9, September 2007, Pages 1670-1675.

ANP, Boletim de Recursos e Reservas de Petróleo e Gás Natural 2022, elaborado por Superintendência de Desenvolvimento e Produção - SDP (acessado em 2023).

ANP, 2024. <https://www.gov.br/anp/pt-br/centrais-de-conteudo/dados-abertos/dados-consolidados-movimentacao-de-gas-natural-em-gasodutos-de-transporte>, acessado em janeiro de 2024.

Arango-Aramburo, S., Turner, Sean., Daenzer, K., Ríos-Ocampo, J., Hejazi, M., Kober, T., Álvarez-Espinosa, A., Romero-Otalora, G. & Zwaan, B. Climate impacts on hydropower in Colombia: A multi-model assessment of power sector adaptation pathways. *Energy Policy* Volume 128, May 2019, Pages 179-188.

Aras, H. & Aras, N. (2004). Forecasting Residential Natural Gas Demand. *Energy Sources* Volume 26, 2004 - Issue 5.

Assimakopoulos, V. & Nikolopoulos, K. The theta model: a decomposition approach to forecasting. *International Journal of Forecasting*. Volume 16, Issue 4, October–December 2000, Pages 521-530.

Azadeh, A., Asadzadeh, S., Saberi, M., Nadimi, V., Tajvidi, A. & Sheikalishahi, M. A Neuro-fuzzy-stochastic frontier analysis approach for long-term natural gas consumption forecasting and behavior analysis: The cases of Bahrain, Saudi Arabia, Syria, and UAE. *Applied Energy* Volume 88, Issue 11, November 2011, Pages 3850-3859.

Bai, Y. & Li, C. Daily natural gas consumption forecasting based on a structure-calibrated support vector regression approach. *Energy and Buildings*.

Volume 127, 1 September 2016, Pages 571-579.

Barroso, L. A., Rudnick, H., Mocarquer, S., Kelman, R. & Bezerra, B (2008). LNG in South America: the markets, the prices and the security of supply. IEEE Xplore.

Beyca, O., Ervural, B., Tatoglu, E., Ozuyar, P. & Zaim, S. Using machine learning tools for forecasting natural gas consumption in the province of Istanbul. *Energy Economics*, Volume 80, May 2019, Pages 937-949.

Brasil Energy, <https://brasilenergia.com.br/energia/termoceara-e-liberada-para-gerar-energia-com-oleo-diesel/>, acessado em 2024.

Ceylan, H., Ceylan, H., Haldenbilen, S. & Baskan, O. (2008). Transport energy modeling with meta-heuristic harmony search algorithm, an application to Turkey. *Energy Policy*, Volume 36, Issue 7, July 2008, Pages 2527-2535.

Chedid, R., Kobrosly, M & Ghajar, R. The potential of gas-to-liquid technology in the energy market: The case of Qatar. *Energy Policy*. Volume 35, Issue 10, October 2007, Pages 4799-4811.

Cleveland, R., Cleveland W., McRae, J. & Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*. Vol.6, nº1, 1990, pp 3-73. Statistics Sweden.

Dantas, G., Castro, N., Brandão, R., Rosental, R. & Lafrenque, A. Prospects for the Brazilian electricity sector in the 2030s: Scenarios and guidelines for its transformation. *Renewable and Sustainable Energy Reviews* Volume 68, Part 2, February 2017, Pages 997-1007.

Demirel, O., Zaim, D., Çaliskan, A. & Özuyar, P. (2012). Forecasting natural gas consumption in İstanbul using neural networks and multivariate time

series methods. Turkish Journal of Electrical Engineering and Computer Sciences, Vol. 20 (2012), No. 5.

Devine, M. & Russo, M. Liquefied natural gas and gas storage valuation: Lessons from the integrated Irish and UK markets. Applied Energy Volume 238, 15 March 2019, Pages 1389-1406.

dos Santos, I., Filho, G., Vasconcellos, B., Júnior, O. & dos Santos, I. Energy and economic study of the increased energy production of cascaded hydroelectric plants due to the heightening of the upstream reservoir: A case study in Cipó-Rio das Antas dam. Renewable Energy Volume 198, October 2022, Pages 228-245.

Economides MJ, Wood DA (2009) The state of natural gas. J Nat Gas Sci Eng 1(1–2):1–3.

Erdogdu, E. (2010). Natural gas demand in Turkey. Applied Energy. Volume 87, Issue 1, January 2010, Pages 211-219.

Fernandes, E., Oliveira, J. C. S., Oliveira P. R. & Alonso, P. S. R. Natural-gas-powered thermoelectricity as a reliability factor in the Brazilian electric sector. Energy Policy.

Volume 36, Issue 3, March 2008, Pages 999-1018.

Findley, D., Monsell, B., Bell, W., Otto, M. & Chen, B. New Capabilities and Methods of the X-12-ARIMA Seasonal-Adjustment Program. Pages 127-152 | Published online: 02 Jul 2012.

Forouzanfar, M., Doustmohammadi, A., Menhaj, M. & Hasanzadeh, S. (2010). Modeling and estimation of the natural gas consumption for residential and commercial sectors in Iran. Applied Energy, Volume 87, Issue 1, January 2010, Pages 268-274.

Friedman, J. H. (1984). A Variable Span Smoother.

Gómez, V. & Maravall, A.. A course in time series analysis, 2001 - Citeseer

Gorucu, F. B. (2004). Artificial Neural Network Modeling for Forecasting Gas Consumption. *Energy Sources* Volume 26, 2004 - Issue 3

Gümrah, F., Katircioglu, D., Aykan, Y., Okumus, S. & Kiliçer, N. (2010). Modeling of Gas Demand Using Degree-Day Concept: Case Study for Ankara. *Energy Sources* Volume 23, 2001 - Issue 2.

Hamzaçebi, C., Akay, D. & Kutay, F. Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting. *Expert Systems with Applications*. Volume 36, Issue 2, Part 2, March 2009, Pages 3839-3844.

Hippert H.S., Pedreira, C.E. & Souza, R.C. (2001). Neural networks for short-term load forecasting: a review and evaluation. *IEEE Xplore*.

Iranmanesh, H. & Abdollahzade, N. (2011). Forecasting natural gas consumption using pso optimized least squares support vector machines. *International Journal of Artificial Intelligence & Applications (IJAIA)*, Vol. 2, n°4, October, 2011.

Isik, C. (2010). Natural gas consumption and economic growth in Turkey: a bound test approach. *Energy Systems*. Volume 1, pages 441–456, (2010)

Kavaklioglu, K. (2011). Modeling and prediction of Turkey's electricity consumption using Support Vector Regression. *Applied Energy*. Volume 88, Issue 1, January 2011, Pages 368-375.

Kazim, A. Assessments of primary energy consumption and its environmental consequences in the United Arab Emirates. *Renewable and Sustainable Energy Reviews*, Volume 11, Issue 3, April 2007, Pages 426-446.

Khol, B. Venezuela: Petroleum & Natural Gas Reserves. University of New Mexico UNM Digital Repository. 3-31-1992.

Kiliç, A. M. (2006). Turkey's natural gas necessity, consumption and future perspectives. *Energy Policy*. Volume 34, Issue 14, September 2006, Pages 1928-1934.

Kızılaslan, R. & Karlık, B. (2009). Combination of Neural Networks Forecasters for Monthly Natural Gas Consumption Prediction.

Hollanda, L., Gonçalves, F. & Moreno, B.. *O Gás Natural e o Planejamento Energético*, 2015, FGV Energia.

Makridakis, S. & Gaba, A. (1998). Judgment: its role and value for strategy.

Megawhat Energy, <https://megawhat.energy/noticias/destaques-do-diario-empresas/152036/sem-perspectiva-para-novos-contratos-termofortaleza-antecipa-fim-de-outorga>, acessado em 2024.

Meira, E., Oliveira, F. & Menezes, L. Forecasting natural gas consumption using bagging and modified regularization techniques. *Energy Economics*, volume 106, 2022. Science Direct.

Melo, J. M., Souza, R. C. Previsão de demanda de importação de gás natural liquefeito (GNL) no mercado Brasileiro. Rio de Janeiro, 2019. 67p. Dissertação de Mestrado - Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro).

MME, 2022, <https://www.gov.br/mme/pt-br/assuntos/noticias/geracao-hidraulica-cresce-em-2022-enquanto-geracao-termica-cai>, acessado em 2024.

Nota técnica - Monetização de Gás Natural Offshore no Brasil. n.d. <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-502/EPE,%202020%20-%>.

ONS - Operador Nacional do Sistema Elétrico. [https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/2023-Relatorio-Anual-acessivel\\_21032024.pdf](https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/2023-Relatorio-Anual-acessivel_21032024.pdf) (acessado em 2023).

Özmen, A., Yilmaz, Y. & Weber, G. Natural gas consumption forecast with MARS and CMARS models for residential users. *Energy Economics*, Volume 70, February 2018, Pages 357-381.

Ozturk, H., Canyurt, O., Hepbasli, A. & Utlü, Z. (2004). Residential-commercial energy input estimation based on genetic algorithm (GA) approaches: an application of Turkey. *Energy and Buildings*. Volume 36, Issue 2, February 2004, Pages 175-183.

Ozturk, H., Ceylan, H., Hepbasli, A. & Utlü, Z. (2004). Estimating petroleum exergy production and consumption using vehicle ownership and GDP based on genetic algorithm approach. *Renewable and Sustainable Energy Reviews*, Volume 8, Issue 3, June 2004, Pages 289-302.

Paim, M.A, Dalmarco, A., Yang, C. H., Salas, P., Lindner, S., Mercure, J. F., Guerra, J., Silva, T. & Vinuales, J. Evaluating regulatory strategies for mitigating hydrological risk in Brazil through diversification of its electricity mix, *Energy Policy*. Volume 128, May 2019, Pages 393-401.

Panapakidis, I. & Dagoumas, A. Day-ahead natural gas demand forecasting based on the combination of wavelet transform and ANFIS/genetic algorithm/neural network model. *Energy* Volume 118, 1 January 2017, Pages 231-245.

Plano Decenal de Expansão de Energia 2032. EPE n.d. <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2032> (accessed January 26, 2023).

Potočnik, P., Soldo, B., Simunovic, G., Saric, T., Jeromen, A. & Govekar, E. Comparison of static and adaptive models for short-term residential natural gas forecasting in Croatia. *Applied Energy* Volume 129, 15 September 2014, Pages 94-103.

Poder 360, 2021, <https://www.poder360.com.br/brasil/consumo-de-gas-em-termoeletricas-cresceu-160-no-3o-trimestre/>, acessado em 2024.

Purwanto, W., Muharam, Y., Pratama, Y., Hartono, D., Soedirman, H. & Anindhito, R. Status and outlook of natural gas industry development in Indonesia. Elsevier Journal of Natural Gas Science and Engineering. Volume 29, February 2016, Pages 55-65.

Saldarriaga, C. & Salazar, H. Security of the Colombian energy supply: The need for liquefied natural gas regasification terminals for power and natural gas sectors. Energy, Volume 100, 1 April 2016, Pages 349-362.

Sanchez-Ubeda, E. & Berzosa, A.. Modeling and forecasting industrial end-use natural gas consumption. Energy Economics Volume 29, Issue 4, July 2007, Pages 710-742.

Sanchez-Ubeda, E. & Wehenkel, L. (1998). The Hinges model: A one-dimensional continuous piecewise polynomial model.

Sarak, H. & Satman, A. (2003). The degree-day method to estimate the residential heating natural gas consumption in Turkey: a case study. Energy, Volume 28, Issue 9, July 2003, Pages 929-939.

Talagala, Thiyanga S., Hyndman, Rob J., Athanasopoulos, George. Meta-learning how to forecast time series, 2023; Research Article, Wiley, p. 1476-1501, DOI 10.1002/for.2963.

Taspinar, F., Çelebi, N. & Tutkun, N. (2013). Forecasting of daily natural gas consumption on regional basis in Turkey using various computational methods. Energy and Buildings, Volume 56, January 2013, Pages 23-31.

Tavakoli, E. & Montazerin, N. (2011). Stochastic analysis of natural gas consumption in residential and commercial buildings. Energy and Buildings, Volume 43, Issue 9, September 2011, Pages 2289-2297.

Thomas, S. & Dawe, R. A. Review of ways to transport natural gas energy from countries which do not need the gas for domestic use. Energy, Volume 28, Issue 14, November 2003, Pages 1461-1477.

Toksari, M. & Toksari, M. (2012). Ant Colony Optimization Based on Multi-Searching to Estimate the Natural Gas Demand: Case of Turkey. *Energy Exploration & Exploitation*, Volume 30, Issue 2.

Toksari, M. (2007). Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy* Volume 35, Issue 8, August 2007, Pages 3984-3990.

Unler, A. (2004). Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025. *Energy Policy*, Volume 36, Issue 6, June 2008, Pages 1937-1944.

Vondráček, J., Pelikán, E., Konár, O., Cermáková, J., Eben, K., Malý, M. & Brabec, M. A statistical model for the estimation of natural gas consumption. *Applied Energy*, Volume 85, Issue 5, May 2008, Pages 362-370.

Wadud, Z. Dey, H., Kabir, Md. & Khan, S. (2011). Modeling and forecasting natural gas demand in Bangladesh. *Energy Policy*, Volume 39, Issue 11, November 2011, Pages 7372-7380.

Xiong, P., Kailing, L., Hui, S. & Wang, J. (2021). Forecast of natural gas consumption in the Asia-Pacific region using a fractional-order incomplete gamma grey model. *Energy*, Volume 237, 15 December 2021, 121533.

Yumurtaci, Z. & Asmaz, E. (2004). Electric Energy Demand of Turkey for the Year 2050. *Energy Sources*. Volume 26, 2004 - Issue 12.

Zhang, G., Dou, L. & Xu, Y. (2019). Opportunities and challenges of natural gas development and utilization in China. *Clean Technologies and Environmental Policy*.



**Apêndice I – Descrição dos métodos aplicados**

Tabela 11: Descrição dos métodos que melhor se aplicam a diferentes frequências de séries temporais. (Tabela adaptada de Talagala et. al., 2023)

Rótulo	Descrição dos modelos de previsão	Frequência da série de dados			
		A <sup>(1)</sup>	T/M <sup>(2)</sup>	S <sup>(3)</sup>	D/H <sup>(4)</sup>
wn	White noise (ruído branco)	√	√	√	√
ARMA	AR, MA, ARMA	√	√	√	-
ARIMA	ARIMA	√	√	√	-
SARIMA	ARIMA sazonal	-	√	√	-
rwd	Random walk with drift (Passeio aleatório com derivada)	√	√	√	√
rw	Random walk	√	√	√	√
theta	Theta padrão	√	√	√	√

stlar	Seasonal decomposition with AR modeling of the seasonally adjusted series (Decomposição com modelagem AR com ajuste sazonal)	-	√	√	√
ETS_NT NS	ETS (Error, Trend, Seasonal) without trend and seasonal components (ETS sem componentes de tendência e sazonal)	√	√	-	-
ETS_T	ETS with trend component and without seasonal component (ETS com componente de tendência e sem sazonalidade)	√	√	-	-
ETS_DT	ETS with damped trend component and without seasonal component (ETS com componente de tendência amortecida e sem componente sazonal)	√	√	-	-
ETS_TS	ETS with trend and seasonal component (ETS com tendência e componente sazonal)	-	√	-	-
ETS_DTS	ETS with damped trend and seasonal component (ETS	-	√	-	-

	com tendência amortecida e com componente sazonal)				
ETS-S	ETS with seasonal component and without trend component (ETS com componente sazonal e sem componente de tendência)	-	√	-	-
snaive	Seasonal naive method (Método ingênuo sazonal)	-	√	√	√
tbats	TBATS forecasting (Previsão TBATS)	-	√	√	√
nn	Neural network time series forecasts (Previsões de séries temporais de redes neurais)	√	√	√	√
mstlets	Multiple seasonal decomposition with ETS modeling of the seasonally adjusted series (Decomposição sazonal múltipla com modelagem ETS da série com ajuste sazonal)	-	-	√	√
mstlarima	Multiple seasonal decomposition with ARIMA modeling of the seasonally adjusted series (Decomposição sazonal múltipla com modelagem	-	-	-	√

	ARIMA da série com ajuste sazonal)				
--	------------------------------------	--	--	--	--

(1) Anual

(2) Trimestral/Mensal

(3) Semanal

(4) Diário/Horário

## Apêndice II – Código em linguagem R para dados diários

```
# Carregar os pacotes necessários
```

```
library(forecast)
```

```
library(ggplot2)
```

```
library(reshape2)
```

```
library(readxl)
```

```
dados_completos = read_excel("input_gas_diaria21.xlsx")
```

```
dados = data.frame(dados_completos$GASFOR)
```

```
# Criar a série temporal
```

```
dados_ts <- ts(dados, start = c(2021, 1), frequency = 365)
```

```
# Dividir os dados em treino e teste
```

```
tamanho_treino <- length(dados_ts) - 30
```

```
treino <- window(dados_ts, end = c(2021 + tamanho_treino %/% 365,  
tamanho_treino %% 365))
```

```
teste <- window(dados_ts, start = c(2021 + (tamanho_treino + 1) %/%  
365, (tamanho_treino + 1) %% 365))
```

```
# Ajustar os modelos no conjunto de treino
```

```
modelo_ets <- ets(treino)
```

```

modelo_rw_drift <- rwf(treino, drift = TRUE, h = 30)
modelo_rw <- rwf(treino, drift = FALSE, h = 30)
modelo_theta <- thetaf(treino, h = 30)
stl_resultados <- stlm(treino, s.window = "periodic")

# Fazer previsões para 30 passos ? frente
previsao_ets <- forecast::forecast(modelo_ets, h = 30)
previsao_rw_drift <- forecast::forecast(modelo_rw_drift, h = 30)
previsao_rw <- forecast::forecast(modelo_rw, h = 30)
previsao_theta <- forecast::forecast(modelo_theta, h = 30)
previsao_stlar <- forecast::forecast(stl_resultados, h = 30)

# Calcular métricas de erro para cada modelo
metricas_ets <- accuracy(previsao_ets, teste)
metricas_rw_drift <- accuracy(previsao_rw_drift, teste)
metricas_rw <- accuracy(previsao_rw, teste)
metricas_theta <- accuracy(previsao_theta, teste)
metricas_stlar <- accuracy(previsao_stlar, teste)

#####

#install.packages("openxlsx")
#library(openxlsx)

```

```
#write.xlsx(metricas_arma,"C:/Users/U38S/Previsao -  
metricas_arma.xlsx")
```

```
# Exibir as métricas de erro
```

```
metricas_ets
```

```
metricas_rw_drift
```

```
metricas_rw
```

```
metricas_theta
```

```
metricas_stlar
```

```
#Modelo White noise forecasting
```

```
#####
```

```
# Previsão usando a média da série de treino como uma abordagem de  
'ruído branco'
```

```
# Isso é conceitualmente similar a tratar a série como ruído branco para  
fins de previsão
```

```
media_treino <- mean(treino)
```

```
previsoes <- rep(media_treino, 30) # Repetir a média para os 30 passos ?  
frente
```

```
# Criar uma série temporal para as previsões
```

```
previsoes_ts <- ts(previsoes, start = c(2021 + (tamanho_treino + 1) %/%  
365, (tamanho_treino + 1) %% 365), frequency = 365)
```

```
# Avaliar a precis?o das previs?es contra a s?rie de teste
```

```
accuracies <- accuracy(previsoes_ts, teste)
```

```
# Imprimir as precis?es
```

```
print(accuracies)
```

```
#####
```

```
#Modelo tbats TBATS forecasting
```

```
#####
```

```
# Aplicar o modelo TBATS ? s?rie de treinamento
```

```
modelo_tbats <- tbats(treino)
```

```
# Fazer previs?es para os pr?ximos 30 passos ? frente
```

```
previsoes_tbats <- forecast(modelo_tbats, h = 30)
```

```
# Plotar as previs?es junto com os dados reais de treino e teste
```

```
autoplot(previsoes_tbats) +
```

```
  ggtitle("Previs?es do Modelo TBATS") +
```

```
  xlab("Tempo") + ylab("Valor")
```

```
accuracy(previsoes_tbats, teste)
```



```
#####
```

```
#Modelo nn Neural network time series forecasts
```

```
#####
```

```
# Aplicar o modelo de rede neural autorregressiva ? s?rie de treinamento
```

```
modelo_nn <- nnetar(treino)
```

```
# Fazer previs?es para os pr?ximos 30 passos ? frente
```

```
previsoes_nn <- forecast(modelo_nn, h = 30)
```

```
# Plotar as previs?es junto com os dados reais de treino e teste
```

```
autoplot(previsoes_nn) +
```

```
  ggtitle("Previs?es do Modelo de Rede Neural") +
```

```
  xlab("Tempo") + ylab("Valor")
```

```
accuracy(previsoes_nn, teste)
```

```
#####
```

```
#####
```

```
#Modelo mstlets Multiple seasonal decomposition with ETS modeling of
```

```
#the seasonally adjusted series
```

```
#####
```

```
#####
```

#A decomposi??o MSTL ? mais adequada para s?ries temporais com m?ltiplas sazonalidades ou s?ries longas o suficiente para capturar v?rias inst?ncias da sazonalidade. Se a s?rie temporal n?o atender a esses crit?rios, a fun??o pode n?o funcionar como esperado.

# Carregar os dados

```
#dados_completos = read_excel("input_gas_diaria.xlsx")
```

```
#dados = data.frame(dados_completos$GASFOR)
```

# Criar a s?rie temporal com frequ?ncia di?ria

```
#dados_ts <- ts(dados, start = c(2021, 1), frequency = 365)
```

# Dividir os dados em treino e teste

```
#tamanho_treino <- length(dados_ts) - 30
```

```
#treino <- window(dados_ts, end = c(2021 + tamanho_treino %/% 365, tamanho_treino %% 365))
```

# Aplicando MSTL para decompor a s?rie temporal

```
decomposicao_mstl <- mstl(treino)
```

# Ajustando o modelo ETS na s?rie de dados ajustada pela sazonalidade

# Aqui usaremos a soma das componentes trend e remainder, pois a MSTL j? ajustou a sazonalidade

```

modelo_ets <- ets(decomposicao_mstl$trend +
decomposicao_mstl$remainder)

# Fazer previsões para os próximos 30 passos a frente
previsoes_ets <- forecast(modelo_ets, h = 30)

# Plotar as previsões junto com os dados de treino
autoplot(previsoes_ets) +
  ggtitle("Previsões do Modelo ETS após Decomposição MSTL para
Dados Diários") +
  xlab("Tempo") + ylab("Valor")

# Avaliar a precisão das previsões em relação à série de teste, se
disponível
accuracy(previsoes_ets, teste) # Supondo que 'teste' esteja definido

#####
#####

# Modelo mstlarima Multiple seasonal decomposition with ARIMA
modeling
#of the seasonally adjusted series

#####
#####

#Para este modelo também tente utilizar a série diária

```

```
is.atomic(dados_ts)
```

```
# Suponha que 'dados_completos' e 'treino' j? foram definidos conforme  
seus comandos anteriores
```

```
# Decompor a s?rie temporal usando MSTL
```

```
decomposicao_mstl <- mstl(treino)
```

```
# A s?rie ajustada sazonalmente ? a soma das componentes trend e  
remainder
```

```
serie_ajustada <- decomposicao_mstl$trend +  
decomposicao_mstl$remainder
```

```
#modelo_arima<-auto.arima(decomposicao_mstl$trend +  
decomposicao_mstl$remainder)
```

```
# Aplicar modelagem ARIMA ? s?rie ajustada sazonalmente
```

```
modelo_arima <- auto.arima(serie_ajustada)
```

```
# Fazer previs?es para os pr?ximos 30 passos ? frente
```

```
previsoes_arima <- forecast(modelo_arima, h = 30)
```

```
# Plotar as previs?es junto com os dados de treino
```

```
autoplot(previsoes_arima) +
```

```
  ggtitle("Previs?es do Modelo ARIMA ap?s Decomposi??o MSTL para  
  Dados Di?rios") +
```

```

xlab("Tempo") + ylab("Valor")

# Avaliar a precis?o das previs?es em rela??o ? s?rie de teste, se
dispon?vel

accuracy(previsoes_arma, teste) # Supondo que 'teste' esteja definido

#####

# Modelo SNaive (Seasonal Naive)

#####

modelo_snaive <- snaive(treino)

previsao_snaive <- forecast(modelo_snaive, h = 30)

metricas_snaive <- accuracy(previsao_snaive, teste)

# Exibir as metricas de erro

print(metricas_snaive)

```

### Apêndice III – Código em linguagem R para dados semanais

```
# Carregar os pacotes necessários
```

```
library(forecast)
```

```
library(ggplot2)
```

```
library(reshape2)
```

```
library(readxl)
```

```
dados_completos = read_excel("input_gas_semanal21.xlsx")
```

```
# Suponha que 'dados' é o seu dataframe GASFOR
```

```
dados = data.frame(dados_completos[, "GASBOL TRECHO SUL 2"])
```

```
# Criar a série temporal
```

```
dados_ts <- ts(dados, start = c(2021, 1), frequency = 52)
```

```
# Dividir os dados em treino e teste
```

```
tamanho_treino <- length(dados_ts) - 4
```

```
treino <- window(dados_ts, end = c(2021 + tamanho_treino %/% 52,  
tamanho_treino %%% 52))
```

```
teste <- window(dados_ts, start = c(2021 + (tamanho_treino + 1) %/% 52,  
(tamanho_treino + 1) %%% 52))
```

```
# Ajustar os modelos no conjunto de treino
```

```

modelo_arima <- auto.arima(treino)
modelo_ets <- ets(treino)
modelo_rw_drift <- rwf(treino, drift = TRUE, h = 4)
modelo_rw <- rwf(treino, drift = FALSE, h = 4)
modelo_theta <- thetaf(treino, h = 4)
stl_resultados <- stlm(treino, s.window = "periodic")

# Fazer previsões para 30 passos ? frente
previsao_arima <- forecast(modelo_arima, h = 4)
previsao_ets <- forecast(modelo_ets, h = 4)
previsao_rw_drift <- forecast(modelo_rw_drift, h = 4)
previsao_rw <- forecast(modelo_rw, h = 4)
previsao_theta <- forecast(modelo_theta, h = 4)
previsao_stlar <- forecast(stl_resultados, h = 4)

# Calcular métricas de erro para cada modelo
metricas_arima <- accuracy(previsao_arima, teste)
metricas_ets <- accuracy(previsao_ets, teste)
metricas_rw_drift <- accuracy(previsao_rw_drift, teste)
metricas_rw <- accuracy(previsao_rw, teste)
metricas_theta <- accuracy(previsao_theta, teste)
metricas_stlar <- accuracy(previsao_stlar, teste)

#install.packages("openxlsx")

```

```
#library(openxlsx)
```

```
#write.xlsx(mtricas_arima,"C:/Users/U38S/Previsao  
metricas_arima.xlsx")
```

```
# Exibir as m?tricas de erro
```

```
metricas_arima
```

```
metricas_ets
```

```
metricas_rw_drift
```

```
metricas_rw
```

```
metricas_theta
```

```
metricas_stlar
```

```
#####
```

```
#Modelo White noise forecasting
```

```
#####
```

```
# Previs?o usando a m?dia da s?rie de treino como uma abordagem de  
'ru?do branco'
```

```
# Isso ? conceitualmente similar a tratar a s?rie como ru?do branco para  
fins de previs?o
```

```
media_treino <- mean(treino)
```

```
previsoes <- rep(media_treino, 4) # Repetir a m?dia para os 4 passos ?  
frente
```



```

# Criar uma s?rie temporal para as previs?es

previsoes_ts <- ts(previsoes, start = c(2021 + (tamanho_treino + 1) %% 52,
(tamanho_treino + 1) %% 52), frequency = 52)

# Avaliar a precis?o das previs?es contra a s?rie de teste

accuracies <- accuracy(previsoes_ts, teste)

# Imprimir as precis?es

print(accuracies)

#####

#Modelo tbats TBATS forecasting

#####

# Aplicar o modelo TBATS ? s?rie de treinamento

modelo_tbats <- tbats(treino)

# Fazer previs?es para os pr?ximos 4 passos ? frente

previsoes_tbats <- forecast(modelo_tbats, h = 4)

# Plotar as previs?es junto com os dados reais de treino e teste

autoplot(previsoes_tbats) +

  ggtitle("Previs?es do Modelo TBATS") +

  xlab("Tempo") + ylab("Valor")

```

```
accuracy(previsoes_tbats, teste)
```

```
#####
```

```
#Modelo nn Neural network time series forecasts
```

```
#####
```

```
# Aplicar o modelo de rede neural autorregressiva ? s?rie de treinamento
```

```
modelo_nn <- nnetar(treino)
```

```
# Fazer previs?es para os pr?ximos 4 passos ? frente
```

```
previsoes_nn <- forecast(modelo_nn, h = 4)
```

```
# Plotar as previs?es junto com os dados reais de treino e teste
```

```
autoplot(previsoes_nn) +
```

```
  ggtitle("Previs?es do Modelo de Rede Neural") +
```

```
  xlab("Tempo") + ylab("Valor")
```

```
accuracy(previsoes_nn, teste)
```

```
#####
```

```
#####
```

```
#Modelo mstlets Multiple seasonal decomposition with ETS modeling of
```

```
#the seasonally adjusted series
```

```
#####  
#####
```

```
#Esse modelo n?o funciona pra serie semanal, tente na serie diaria  
#sugere que a s?rie temporal treino n?o ? adequada para a decomposi??o  
MSTL conforme fornecida,  
#possivelmente devido ? sua estrutura ou ao n?mero de per?odos  
dispon?veis para an?lise.  
#A decomposi??o MSTL ? mais adequada para s?ries temporais com  
m?ltiplas sazonalidades ou s?ries  
#longas o suficiente para capturar v?rias inst?ncias da sazonalidade. Se a  
s?rie temporal n?o  
#atender a esses crit?rios, a fun??o pode n?o funcionar como esperado.
```

```
# Aplicando MSTL para decompor a s?rie temporal  
decomposicao_mstl <- mstl(treino)
```

```
# Ajustando o modelo ETS na s?rie de dados ajustada pela sazonalidade  
# Aqui usaremos a soma das componentes trend e remainder, pois a MSTL  
j? ajustou a sazonalidade  
modelo_ets <- ets(decomposicao_mstl$trend +  
decomposicao_mstl$remainder)
```

```
# Fazer previs?es para os pr?ximos 4 passos ? frente  
previsoes_ets <- forecast(modelo_ets, h = 4)
```

```

# Plotar as previsões junto com os dados de treino

autoplot(previsoes_ets) +

  ggtitle("Previsões do Modelo ETS após Decomposição MSTL para Dados
Semanais") +

  xlab("Tempo") + ylab("Valor")


# Avaliar a precisão das previsões em relação à série de teste, se
disponível

accuracy(previsoes_ets, teste) # Supondo que 'teste' esteja definido


# Criar um dataframe para os gráficos

df <- data.frame(

  Tempo = c(time(treino), time(teste)),

  Original = c(as.numeric(treino), rep(NA, length(teste))),

  ARIMA = c(as.numeric(fitted(modelo_arima)),
as.numeric(previsao_arima_ajustada)),

  ETS = c(as.numeric(fitted(modelo_ets)),
as.numeric(previsao_ets_ajustada)),

  RW_Drift = c(as.numeric(fitted(modelo_rw_drift)),
as.numeric(previsao_rw_drift_ajustada)),

  RW = c(as.numeric(fitted(modelo_rw)),
as.numeric(previsao_rw_ajustada)),

  Theta = c(as.numeric(fitted(modelo_theta)),
as.numeric(previsao_theta_ajustada)),

```

```

    STLAR          =          c(as.numeric(fitted(stl_resultados)),
as.numeric(previsao_stlar_ajustada))
)

```

```

# Dados para o gráfico (fazer pra todos os modelos)

```

```

#df_arima <- data.frame(
# Tempo = c(time(treino), time(teste)),
# Valor = c(as.numeric(treino), rep(NA, length(teste))),
# Previsao = c(fitted(modelo_arima), as.numeric(previsao_arima$mean))

```

```

# Fazer previsões para 4 passos à frente com o modelo SNaive

```

```

modelo_snaive <- snaive(treino)
previsao_snaive <- forecast::forecast(modelo_snaive, h = 4)

```

```

# Calcular métricas de erro para cada modelo
metricas_snaive <- accuracy(previsao_snaive, teste)

```

```

# Imprimir as métricas de erro
print(metricas_snaive)

```