

PREVISÃO DO CONSUMO DE GÁS NATURAL EM UMA FÁBRICA DE CIMENTO – ESTUDO DE CASO

IGOR TONA PERES – igor.peres@puc-rio.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO – PUC-RIO

NICHOLAS DE MARCO RECKMAN - nicholasreckman@hotmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO – PUC-RIO

PAULA MAÇAIRA – paulamacaira@puc-rio.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO – PUC-RIO

ÁREA: ***03. PESQUISA OPERACIONAL***
SUBÁREA: ***3.6 – ANÁLISE DA DEMANDA***

RESUMO: *ESTE ESTUDO INVESTIGA A PREVISÃO DO CONSUMO DE GÁS NATURAL EM UMA FÁBRICA DE CIMENTO LOCALIZADA NO ESTADO DO RIO DE JANEIRO, EM MEIO À TRANSIÇÃO DO MERCADO REGULADO PARA O MERCADO LIVRE DE GÁS NATURAL, NO CONTEXTO DA ABERTURA DE MERCADO E DA "NOVA LEI DO GÁS" DO BRASIL. A ANÁLISE VISA OTIMIZAR A PREVISÃO DA DEMANDA PARA REDUZIR OS CUSTOS DE TRANSPORTE E ESTOQUE DE GÁS NATURAL NOS GASODUTOS DE TRANSPORTE E O CUSTO ENVOLVIDO NA COMPRA DO GÁS A SER FORNECIDO. PARA ESTE PROPÓSITO SÃO UTILIZADOS DADOS HISTÓRICOS DE PREVISÃO E CONSUMO REAL ASSIM COMO OUTRAS SÉRIES TEMPORAIS PARA O TREINAMENTO DOS MODELOS DE PREVISÃO UNIVARIADOS E MULTIVARIADOS. APÓS O TREINAMENTO DOS MODELOS, ESTES SÃO UTILIZADOS PARA REALIZAR AS PREVISÕES SOBRE O PERÍODO DE VALIDAÇÃO DOS DADOS E SUAS PERFORMANCES SÃO COMPARADAS COM AS PREVISÕES INTERNAS DA COMPANHIA PARA O MESMO PERÍODO, DESTACANDO ASSIM A PERFORMANCE E ADEQUAÇÃO DE CADA MODELO. OS RESULTADOS INDICAM QUE OS MODELOS MULTIVARIADOS APRESENTAM UMA PRECISÃO SIGNIFICATIVAMENTE SUPERIOR EM COMPARAÇÃO AOS UNIVARIADOS NO PERÍODO DE TESTES, AINDA ASSIM, NÃO ALCANÇAM A PERFORMANCE DAS PREVISÕES INTERNAS EM D+1 REALIZADAS PELA COMPANHIA. O ESTUDO REALIZA ASSIM UMA ANÁLISE DE PREVISÃO EXÓGENA COM LIMITAÇÃO DE ACESSO A INFORMAÇÃO E A MEDE CONTRA UMA PERFORMANCE ENDÓGENA DA COMPANHIA.*

PALAVRAS-CHAVES: *PREVISÃO DE CONSUMO; GÁS NATURAL; SÉRIES TEMPORAIS, MERCADO LIVRE DE GÁS.*

1. INTRODUÇÃO

A promulgação da Nova Lei do Gás (Lei nº 14.134, de 8 de abril de 2021) representa um marco significativo para o mercado brasileiro de gás natural, visando promover a competitividade, reduzir os custos e atrair novos investimentos. A iniciativa faz parte do programa Novo Mercado de Gás, lançado pelo Governo Federal, que busca estabelecer um mercado mais dinâmico e integrado, alinhado com as melhores práticas internacionais.

A nova legislação visa desverticalizar o mercado, permitindo a entrada de novos agentes e facilitando o acesso à infraestrutura essencial, como os gasodutos. Esta mudança é crucial para melhorar a competitividade do setor e alinhar-se às tendências globais de mercados mais abertos e diversificados (EPE, 2021).

É esperado que essas transformações não apenas aumentem a oferta e reduzam os custos do gás natural no Brasil, mas também que fomentem investimentos em infraestrutura e melhorem a competitividade da indústria nacional em diversos segmentos, como petroquímica, siderurgia e geração termelétrica (MME, 2021).

Neste novo contexto de Mercado, a previsibilidade da demanda do consumidor de gás é crucial para os fornecedores por várias razões. Primeiramente, a precisão na previsão da demanda permite que os fornecedores planejem adequadamente a oferta, garantindo que haja gás suficiente disponível para atender às necessidades dos consumidores sem interrupções. Estudos mostram que a previsibilidade da demanda ajuda a otimizar a operação das redes de distribuição, minimizando custos operacionais e evitando desperdícios de recursos (Liu et al., 2023)

Por esse motivo, é de interesse estratégico se realizar previsões de demanda sobre as curvas de consumo dos consumidores, para esse propósito, podem ser utilizados modelos de previsão de séries temporais treinados em cima de dados históricos de consumo assim como sobre outras séries temporais relacionadas.

Sobre esta análise será compreendido um estudo de caso de uma fábrica de cimento consumidora de Gás Natural no estado do Rio de Janeiro. A intenção será treinar modelos de previsão sobre uma série temporal diária de consumo se utilizando de dados históricos, posteriormente, estes modelos serão testados sobre um período de validação e comparados com a performance histórica de nomeação da própria companhia, que efetivamente funciona como uma previsão de demanda interna para D+1.

2. MATERIAIS E MÉTODOS

Para a realização deste trabalho, é necessário definir em etapas uma série de informações e definições críticas de acordo com a seguinte descrição:

2.1 Coleta e tratamento de dados

É necessário coletar e tratar os dados relevantes para o treinamento e validação dos modelos de previsão de séries temporal. Para tanto, foi cedido pela companhia uma base de dados com 972 observações contendo as séries temporais históricas em base diária entre o intervalo de 2021-02-01 e 2023-09-30.

Nesta base estão contidas duas séries temporais de interesse deste estudo. A primeira é a série da Quantidade Diária Realizada (QDR), que destaca o volume em metros cúbicos de gás natural que realmente foi consumido a cada dia, esta será a série que será prevista neste estudo. Adicionalmente, tem-se a série da Quantidade Diária Solicitada (QDS), esta série descreve o volume em metros cúbicos que a companhia solicitava ao dia seguinte para seu antigo fornecedor. Consequentemente, esta série servirá como uma base de comparação de performance para os modelos, sendo efetivamente a previsão histórica da própria companhia para D+1.

Também foram adicionadas à base de dados três séries temporais públicas para se testar serem utilizadas como séries explicativas para a série alvo a ser prevista. Estas séries são:

- Taxa Cambial R$ - US$ (fechamento diário) FX [R$ / US$]
- Brent (futuro diário) BRENT [US$ / bbl]
- Indice Mercado US Não-Ferrosos DJUSNF [-]

A escolha por estas séries temporais adicionais foi feita de maneira empírica e pode não explicar de forma adequada a série alvo.

Os valores das séries foram verificados como reais e seus formatos foram validados com facilidade. Nesta análise também não foi necessária a remoção de nenhum valor outlier de nenhuma das séries temporais, uma vez que todos os valores são reais e nenhum deles deturpa os resultados da análise como um todo.

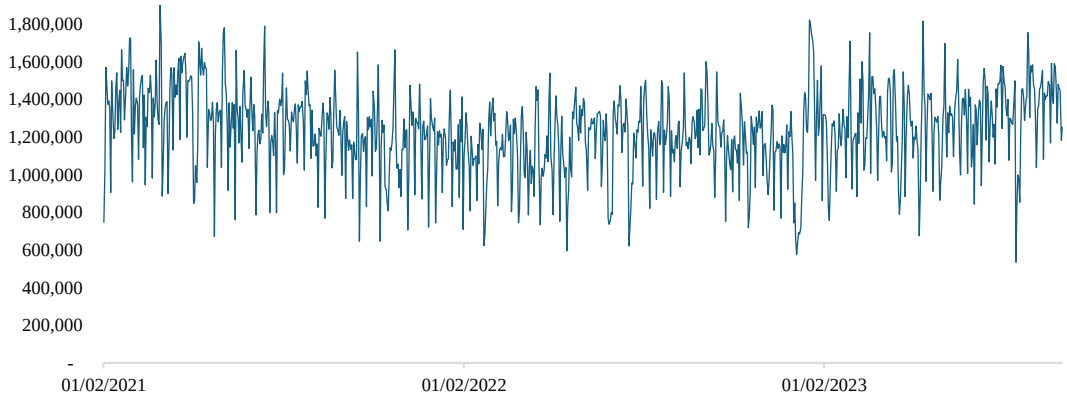
Neste ponto, é necessário realizar a divisão das séries temporais entre período de treinamento e período de validação, estes representarão, respectivamente, 80% e 20% das observações da base de dados de forma sequencial. O período te treinamento será utilizado para

treinar e ajustar os modelos de previsão, enquanto o período de validação será utilizado para simular uma previsão dos modelos treinados e, comparativamente, medir suas performances de erro.

2.2 Análise exploratória da série alvo

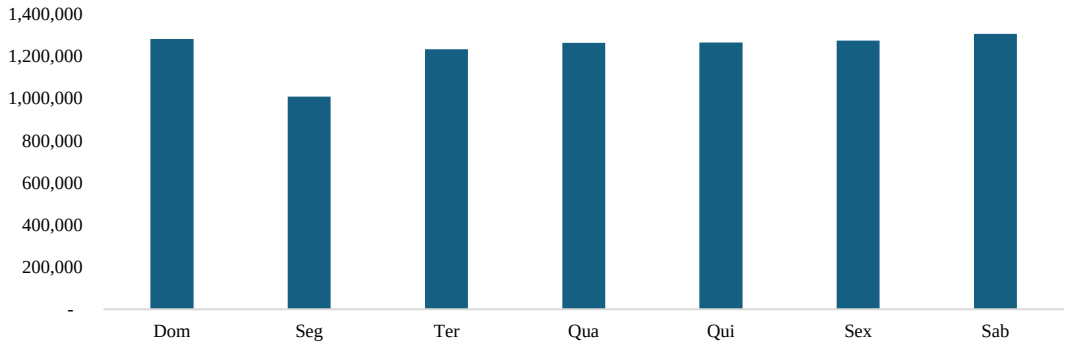
Deve-se estudar o comportamento da curva histórica de consumo da companhia como a série temporal alvo desta análise. Para se realizar o treinamento dos modelos de previsão da melhor forma possível é necessário detectar tendências, sazonalidades e comportamentos anormais na série, para tal, realiza-se uma simples análise exploratória.

Figura 1 - Gráfico: Curva histórica de consumo de gás natural [m³ / dia]



Fonte: Própria, autor

Figura 2 - Gráfico: Média de consumo de gás natural por dia da semana [m³ GN / dia]



Fonte: Própria, autor

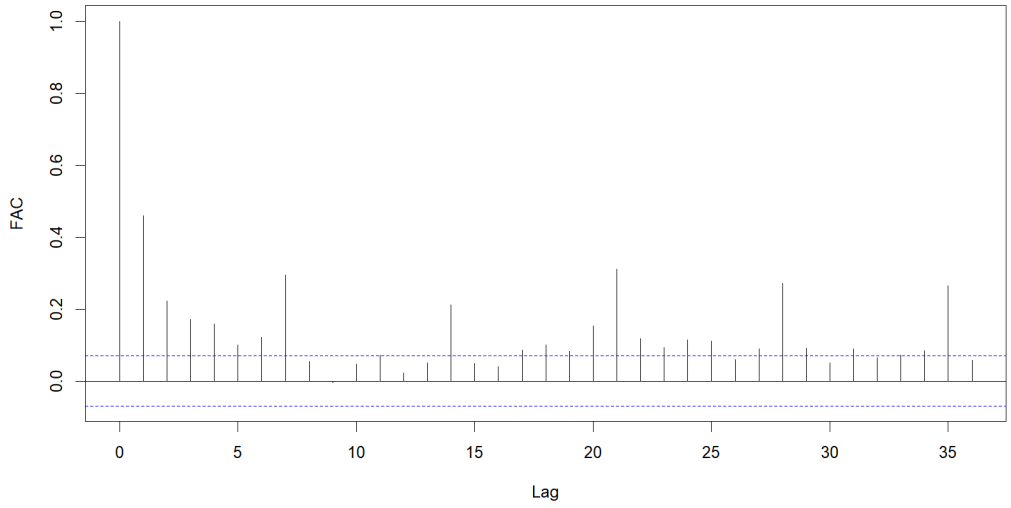
Observando os dados brutos tem-se uma média de consumo no período de 1,233,061 m³/dia, com um mínimo de 534,887 m³/dia e máximo de 1,904,930 m³/dia. No entanto, pode-se perceber que os valores de consumo nas segundas são muito inferiores a todos os outros dias.

Esse fato é condizente com as informações disponíveis ao autor, que a fábrica da companhia em questão realiza manutenções preventivas às segundas, paralisando parcialmente e temporariamente os fornos nestes processos.

A série também apresenta um desvio padrão de 219,336 m³/dia, um valor significativo, considerando que este representa mais que 10% do valor máximo da série no intervalo.

Adicionalmente, deve-se realizar a função de autocorrelação (FAC) (Venables & Ripley, 2002) para identificar exaustivamente padrões de sazonalidade e tendência presentes na série. Para este proposito a função mede valores de correlação entre a série alvo e defasagens (lags) dela mesma.

Figura 3 - Gráfico: Função Auto Correlação da Série Alvo



Fonte: Própria, autor

O resultado da FAC apresenta valores além da margem de significância para os valores abaixo do lag 5 e para os lags múltiplos de 7. Esses valores na FAC podem indicar, respectivamente, uma leve tendencia de crescimento e a presença de uma sazonalidade semanal, provavelmente causada pelos eventos de manutenção preventiva realizados nas segundas-feiras.

2.3 Modelos de previsão univariados

Com a análise exploratória e a FAC completas sobre a série temporal alvo, são treinados os modelos de previsão univariados. Para este ponto no estudo são escolhidos três modelos de previsão.

2.3.1 Modelo Naive

Neste modelo a previsão segue o mesmo valor da última observação da série temporal, assim, obedecendo a seguinte formulação:

$$\hat{Z}_{T+h} = Z_T, \text{ onde:}$$

$$\hat{Z}_{T+h} = previsão\ \ de\ Z_t\ feita\ no\ instante\ T\ para\ o\ horizonte\ h$$
$$Z_T = ultima\ observação\ de\ uma\ série\ temporal$$

Nesse caso o único parâmetro relevante para o ajuste do modelo é a definição de Z_T que, para o período de treinamento, é igual a 1,006,760 m³ GN / dia. Consequentemente, as previsões do modelo NAIVE para o período de Validação serão todas iguais a Z_T.

2.3.2 Modelo do Método da Média

Neste modelo a previsão vai seguir o valor da média de todas as observações da série temporal alvo no intervalo de treinamento. Dessa forma ela segue a seguinte formula:

$$\hat{Z}_{T+h} = \frac{1}{T}\sum_{t=1}^{T} Z_t$$

Com os componentes da fórmula já tendo sido explicados no modelo anterior.

Aqui, a previsão para o período de validação do modelo será igual a média das observações do período de treinamento, que, nesse caso, fica igual a 1,215,337 m³ GN / dia.

2.3.3 Modelo de Suavização Exponencial

A suavização exponencial é um método de previsão que aplica pesos decrescentes exponencialmente a observações passadas. A suavização exponencial produz previsões que capturam tendencias e padrões de curto prazo ao calcular uma média ponderada dos valores passados, onde os pesos diminuem conforme os dados ficam mais antigos.

Existem 3 principais variações do método de suavização Exponencial, a Suavização Exponencial Simples (SES), o Modelo de Holt (Holt, 2004) e o Modelo Holt-Winters (Winters, 1960). Como no caso estudado, ao se analisar a FAC da série temporal alvo, percebeu-se que a

série indica a presença de sazonalidade, mas não de tendência, opta-se pela escolha do método de Suavização Exponencial Dupla, uma vez que este é mais adequado para séries temporais com estas características sazonais. A formulação deste modelo segue o seguinte padrão:

$$\hat{Z}_{T+h} = N_t + hT_t + S_{t+h-m(k+1)}, \text{ onde:}$$

$$N_t = \alpha(Z_t - S_{t-m}) + (1-\alpha)(N_{t-1} + T_{t-1})$$
$$T_t = \beta(N_t - N_{t-1}) + (1-\beta)T_{t-1}$$
$$S_t = \gamma(Z_t - N_{t-1} - T_{t-1}) + (1-\gamma)S_{t-m}$$
$$N_t = o\ nível\ da\ série\ no\ tempo\ t$$
$$T_t = a\ tendência\ da\ série\ no\ tempo\ t$$
$$S_t = a\ sazonalidade\ da\ série\ no\ tempo\ t$$
$$\alpha = parâmetro\ de\ suavização\ de\ Nível\ (0 \leq \alpha \leq 1)$$
$$\beta = parâmetro\ de\ suavização\ de\ Tendência\ (0 \leq \beta \leq 1)$$
$$\gamma = parâmetro\ de\ suavização\ de\ Sazionalidade\ (0 \leq \gamma \leq 1)$$
$$k = mod\left(\frac{h-1}{m}\right)$$
$$h = horizonte\ de\ previsão$$
$$m = período\ de\ sazonalidade$$

Para este método devem ser calibrados os parâmetros α, β e γ, para isto é feita a otimização da minimização da soma dos erros quadrados entre o modelo a ser calibrado e os valores da série alvo no período de treinamento. Ao realizar esse processo de ajuste o modelo indica um valor de α otimizado em 0.19, de β em 0.0 e de γ em 1.0. Isso indica que o modelo treinado não detecta nenhuma tendência e indica a clara presença de sazonalidade com o m equivalente a 7, o modelo também indica uma baixa relação da série com o fator anterior.

2.3.4 Métricas de acurácia dos modelos

Para se medir a performance dos modelos de previsão durante o período de validação, serão utilizadas diferentes métricas de erro de previsão, estas são:

- ME (Mean Error) – Erro Médio
- RMSE (Root Mean Squared Error) – Raiz do Erro Quadrático Médio

- MAE (Mean Absolute Error) – Erro Absoluto Médio
- MPE (Mean Percentage Error) – Erro Percentual Médio
- MAPE (Mean Absolute Percentage Error) – Erro Percentual Absoluto Médio

Além de se medir essas métricas para as previsões univariadas, as mesmas métricas também serão apuradas sobre as previsões históricas da companhia durante o período de validação para servirem de base de comparação.

2.3.5 Previsões dos modelos univariados

Neste ponto da análise, já com os três modelos treinados, realiza-se a previsão sobre os valores esperados para o período de validação. Os resultados serão analisados graficamente e pelo ponto de vista das métricas de acurácia previamente descritas neste estudo.

2.4 Modelo do Previsão Multivariada

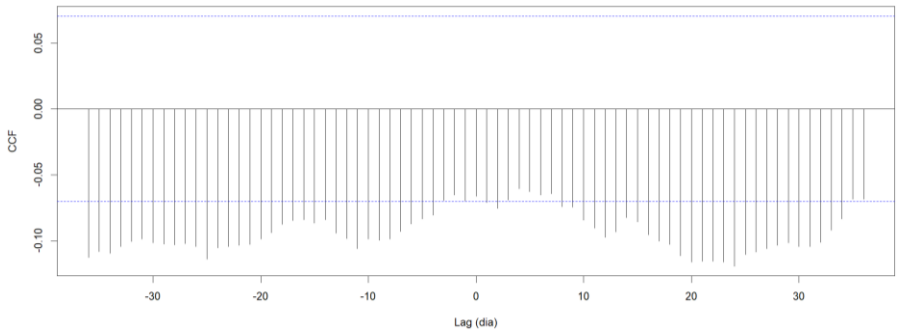
Neste ponto do estudo será moldado um modelo de previsão multivariado para a série temporal alvo, utilizando as séries adicionadas a base (FX, BRENT e DJUSNF) como séries explicativas a serem utilizadas em um processo de Regressão Dinâmica que treinará o modelo de previsão.

2.4.1 Correlações cruzadas entre as séries (CCF)

Para buscar relações uteis entre as séries explicativas e a série alvo para se montar o modelo de previsão multivariado, deve-se inicialmente calcular a função de correlação cruzada (Venables & Ripley, 2002) entre todas as séries explicativas e a série alvo. A CCF segue a mesma formulação da FAC, porém, ao invés de se calcularem as correlações entre lags da mesma série, se calculam as correlações entre lags de séries diferentes.

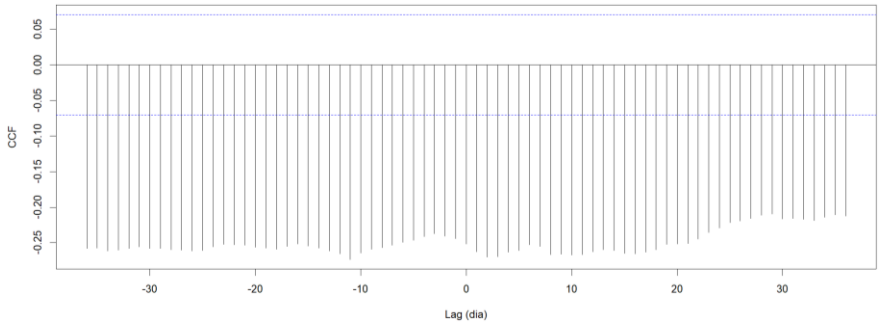
Dessa forma, montam-se nesse caso 3 análises de CCF, uma para cada variável explicativa da base de dados.

Figura 4 - Gráfico: Função de Correlação Cruzada (QDR – DJUSNF)



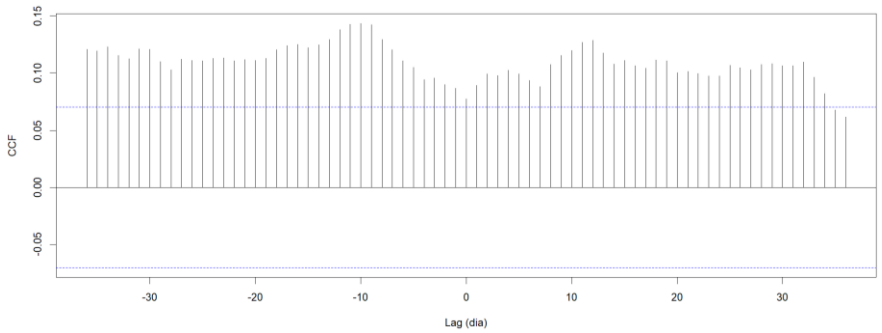
Fonte: Própria, autor

Figura 5- Gráfico: Função de Correlação Cruzada (QDR – BRENT)



Fonte: Própria, autor

Figura 6 - Gráfico: Função de Correlação Cruzada (QDR – FX)



Fonte: Própria, autor

Entre essas análises, somente os valores de correlação para lags negativos entre as séries serão relevantes para a regressão, uma vez que a previsão na realidade não poderia se beneficiar de valores futuros de outras séries no momento da previsão D+1.

No geral, as CCFs apresentam valores relativamente baixos, entre -0.30 e 0.15, ainda assim, se apresentam valores além da faixa de significância entre todas as combinações.

2.4.2 Regressão dinâmica

Para montar uma regressão dinâmica (Lütkepohl, 1999) para previsão baseada nas funções de correlação cruzada (CCFs) analisadas, deve-se estruturar o modelo considerando os lags que mostraram correlações significativas. A regressão dinâmica permite incluir valores passados (lags negativos somente) das variáveis explicativas para capturar essas correlações.

O modelo seguirá a seguinte formulação:

$$QDR_t = \alpha_0 + \sum_{l=1}^{o} \eta_l QDR_{t-o} + \sum_{k=1}^{p} \alpha_k DJUSNF_{t-k} + \sum_{j=1}^{q} \beta_j BRENT_{t-j} + \sum_{m=1}^{r} \gamma_m FX_{t-m} + \epsilon_t, \text{ onde:}$$

$$QDR_t = Quantidade\ Diária\ Realizada\ (série\ alvo)$$
$$DJUSNF_t = Indice\ Dow\ Jones\ US\ Não - Ferrosos$$
$$BRENT_t = Futuro\ Diário\ Brent$$
$$FX_t = Taxa\ Cambial\ US\$ - R\$\ (fechamento\ venda)$$
$$\alpha_0 = Intercepto$$
$$\eta_k = Coeficientes\ dos\ lags\ de\ QDR_t$$
$$\alpha_k = Coeficientes\ dos\ lags\ de\ DJUSNF_t$$
$$\beta_j = Coeficientes\ dos\ lags\ de\ BRENT_t$$
$$\gamma_m = Coeficientes\ dos\ lags\ de\ FX_t$$
$$\epsilon_t = termo\ de\ erro$$

Para a FAC da série alvo e cada CCF entre variáveis, até somente os 3 lags negativos com valores de correlação mais significativos serão considerados no modelo de regressão inicial.

A partir deste modelo de regressão inicial será realizado o ajuste dos coeficientes dos lags das variáveis selecionadas para fazer a minimização do erro no período de treinamento.

Dados os coeficientes obtidos, serão avaliados seus níveis de significância no contexto da regressão dinâmica. Se o p-valor de ao menos um dos coeficientes for maior que 5% (o que indicaria que não se pode rejeitar a H_0: coef. = 0), rejeita-se o modelo, remove-se a variável com o coeficiente menos significante e se refaz a otimização da minimização do erro.

Esse processo se repete até que todos os coeficientes utilizados no modelo sejam significativos. No caso em análise o processo de Regressão Dinâmica resultou em um modelo

com as seguintes características sobre os coeficientes do modelo:

Figura 7 - Tabela: Parametros do modelo de previsão multivariado de regressão dinâmica

Coeficiente	Estimativa	Erro Padrão	t-valor	Pr(>| t |)
Intercept	5.630e+05	7.688e+04	7.323	6.15e-13
Lag (QDR, -1)	4.121e-01	3.184e-02	12.946	< 2e-16
Lag (QDR, -7)	2.213e-01	3.187e-02	6.944	8.15e-12
Lag (BRENT, -10)	-1.373e+03	4.535e+02	-3.028	0.00254

Fonte: Própria, autor

Nesse cenário o modelo ainda apresentou um R^2 de 0.285, o que indica que 28.5% das mudanças na série alvo são explicadas pelas variações nas séries de lags selecionadas, um valor que não é significante, porém segue-se para o ajuste do modelo de previsão no período de validação.

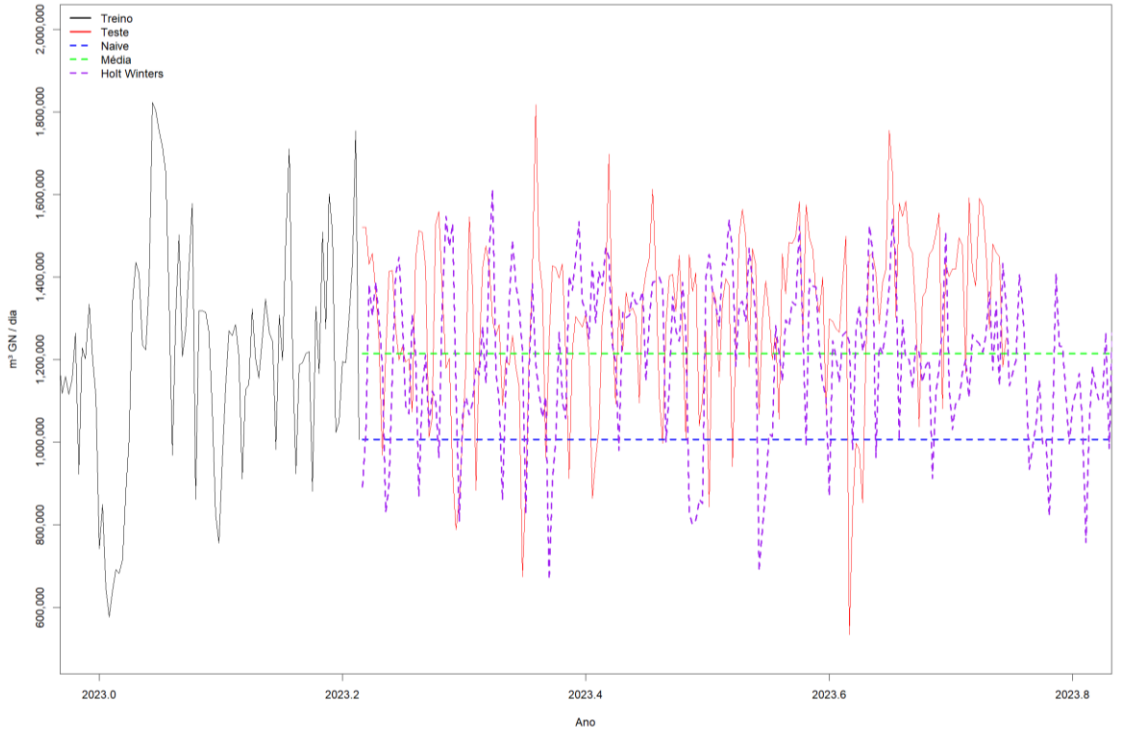
2.4.3 Previsão do modelo multivariado

Realiza-se a previsão em base D+1 para o período de validação utilizando o modelo multivariado ajustado através da Regressão Dinâmica. Na seção de resultados do estudo as previsões serão analisadas pelos seus gráficos e pelas métricas de acurácia em conjuntura aos resultados das previsões obtidas através dos modelos univariados.

3. RESULTADOS

Inicialmente, para a análise dos resultados, realiza-se a previsão dos modelos univariados sobre o período de validação, estes modelos são o Modelo Naive, Modelo por Método de Média e o Modelo de Suavização Exponencial.

Figura 8 - Gráfico: Previsão dos modelos univariados no período de validação



Fonte: Própria, autor

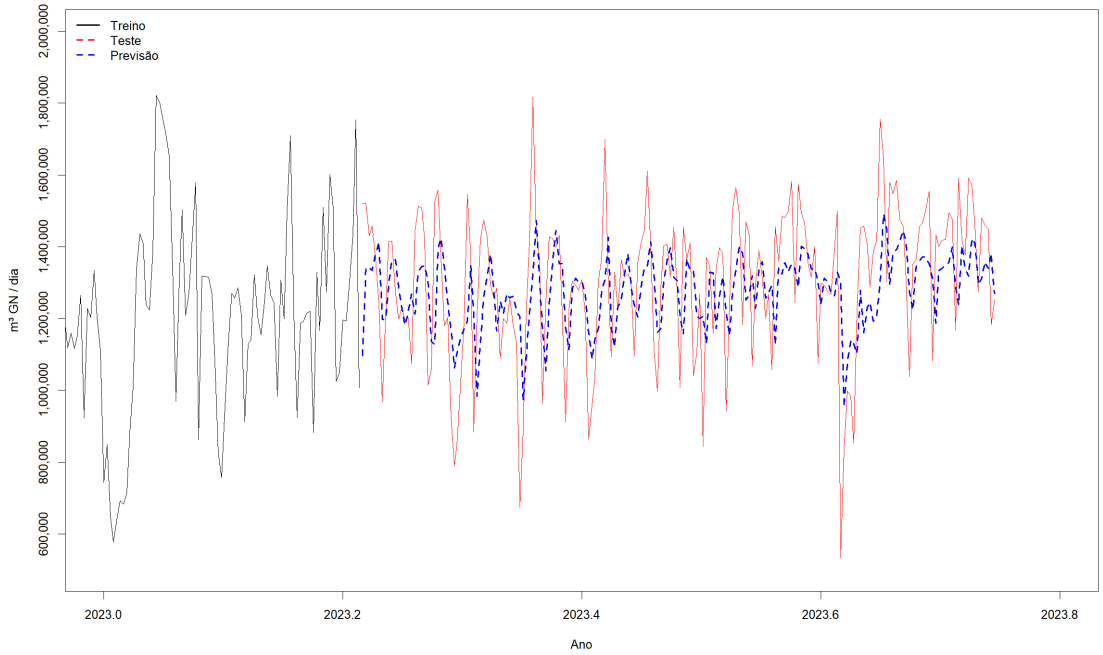
Figura 9- Tabela: Métricas de acuracia dos modelos de previsão univariados

Modelo	ME	RMSE	MAE	MPE	MAPE
Naive	297,379.5	361,394.6	322,558.7	20.4%	23.7%
Média	88,802.5	223,735.1	186,566.9	3.9%	14.9%
Holt-Winters	82,843.5	286,225.0	228,841.6	3.5%	18.4%
Histórico	7,095.1	96,578.7	73,402.9	0.4%	5.9%

Fonte: Própria, autor

Adiciona-se neste ponto os resultados da previsão feita utilizando o modelo multivariado baseado em regressão dinâmica para o período de validação.

Figura 10 - Gráfico: Previsão do modelo multivariado no período de validação



Fonte: Própria, autor

Figura 11- Tabela: Métricas de acuracia para todos os modelos de previsão

Modelo	ME	RMSE	MAE	MPE	MAPE
Naive	297,379.5	361,394.6	322,558.7	20.4%	23.7%
Média	88,802.5	223,735.1	186,566.9	3.9%	14.9%
Holt-Winters	82,843.5	286,225.0	228,841.6	3.5%	18.4%
Multivariado	27,068.8	181,299.1	141,811.4	-0.3%	11.8%
Histórico	7,095.1	96,578.7	73,402.9	0.4%	5.9%

Fonte: Própria, autor

4. DISCUSSÃO

A análise sugere que a abordagem convencional de estabelecer a previsão com base na média histórica pode resultar em melhores resultados em cenários onde deve-se realizar a previsão sem informações adicionais dos processos internos da fábrica ou de séries temporais relacionadas.

Ainda que o modelo Holt-Winters seja o único dos modelos univariados capaz de capturar o comportamento de sazonalidade entre os três, a sua performance ainda é insuficiente frente à modelos significativamente mais simples como o Naive e o Modelo de Método de

Média, que, no geral, é o mais preciso entre os modelos univariados. A melhor performance do modelo de média pode ser atribuída ao fato de a série alvo não apresentar tendencia de crescimento ou decrescimento no período de validação, desta forma se mantendo próxima a média total histórica.

No caso do modelo de previsão multivariado baseado em Regressão Dinâmica, os baixos índices de correlação entre as séries temporais selecionadas como explicativas e a série alvo acabaram resultando em um modelo quase que somente dependente dos lags da própria série alvo. Ainda assim este modelo conseguiu captar o padrão de sazonalidade semanal melhor que o modelo de suavização exponencial Holt-Winters.

É possível perceber visualmente pela análise do gráfico (figura 10) que a série de previsão do modelo multivariado se adere muito melhor ao intervalo de validação quando comparada às previsões construídas pelos modelos univariados, ainda que o processo de regressão não tenha rendido um R^2 satisfatório para o modelo.

Vale se destacar também que, ainda que os coeficientes mais proeminentes no modelo de previsão multivariado sejam referentes aos lags da própria série alvo, a acurácia deste modelo ainda é bem superior à dos modelos univariados (figura 11).

A presença do coeficiente no modelo sobre um lag da série do BRENT indica uma relação inversa entre o preço do Gás Natural e seu volume consumido, o que faz sentido, uma vez que os valores desta série são comumente usados como índices de correção de preço em contratos de compra e venda de gás natural no Brasil.

A performance histórica de previsões da companhia no período de validação ainda é vastamente superior à de qualquer um dos modelos treinados, naturalmente devido ao fato ao acesso limitado de informações deste estudo como uma parte externa à companhia.

5. CONCLUSÃO

Reconhece-se que a metodologia de previsão aplicada neste estudo foi realizada se utilizando dados específicos à esta curva de consumo e área de mercado da indústria consumidora, entretanto, é inteiramente possível replicá-la para outras séries de consumo de outros consumidores industriais de gás natural.

A metodologia pode gerar resultados mais precisos se o trabalho for realizado em parceria com a empresa consumidora, uma vez que esta pode fornecer séries temporais explicativas internas adicionais que melhor se correlacionem com a curva de consumo da série temporal alvo.

No geral, este caso de estudo, com uma visão limitada dos processos internos da companhia, não rendeu previsões D+1 mais precisas que as já realizadas pela própria companhia, isso não descarta a possibilidade que o mesmo processo seja mais benéfico para outros consumidores em situações similares, com menos previsibilidade sobre suas demandas.

Finalmente, o autor sugere a extensão da metodologia para a inclusão de modelos não lineares de previsão, em destaque, modelos de previsão baseados em redes neurais recorrentes para que possam ser melhor capturadas padrões recorrentes nas séries temporais.

REFERÊNCIAS

EPE (Empresa de Pesquisa Energética), (2021); Plano Decenal de Expansão de Energia 2031; Web page: https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-2031

HOLT, C.C. (2004); Forecasting seasonals and trends by exponentially weighted moving averages. International Journal of Forecasting, v.20, n.1; p. 5-10.

LIU, H.; Liu, Y.; Wang, C.; Song, Y.; Jiang, W.; Li, C.; Zhang, S.; Hong, B. (2023); Natural Gas Demand Forecasting Model Based on LASSO and Polynomial Models and Its Application: A Case Study of China, Energies, 16, 4268.

LÜTKEPOHL H., Teräsvirta T., Wolters J. (1999), Investigating Stability and Linearity of a German M1 Money Demand Function, Journal of Applied Econometrics, 14, 511–525.

MME (Ministério de Minas e Energia), (2021); Manual Orientativo de Boas Práticas Regulatórias do Comitê de Monitoramento da Abertura do Mercado de Gás Natural (CMGN); Web page: https://www.gov.br/mme/pt-br/assuntos/secretarias/petroleo-gas-natural-e-biocombustiveis/novo-mercado-de-gas/cmgn/publicacoes

Série Temporal: USD/BRL - Dólar Americano Real Brasileiro; Web page: https://br.investing.com/currencies/usd-brl-historical-data. Acessado: 2024-06-27

Série Temporal: Dow Jones Nonferrous Metals (DJUSNF); Web page: https://www.investing.com/indices/dj-nonferrous-metals. Acessado: 2024-06-27

Série Temporal: Petróleo Brent Futuros; Web page: https://br.investing.com/commodities/brent-oil-historical-data. Acessado: 2024-06-27

VENABLES, B. & Ripley, B. (2002). Modern Applied Statistics With S. 10.1007/b97626.

WINTERS, P.R. (1960) Forecasting Sales by Exponentially Weighted Moving Averages. Management Science 6(3):324-342.