

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
DEE - DEPARTAMENTO DE ENGENHARIA ELÉTRICA

RYAN MAURICIO TEIXEIRA FEITOSA

**COMPARAÇÃO DE MÉTODOS CLÁSSICOS E AVANÇADOS DE
PREVISÃO APLICADOS AO CONSUMO DE ENERGIA ELÉTRICA**

SÃO CARLOS
2023

RYAN MAURICIO TEIXEIRA FEITOSA

**COMPARAÇÃO DE MÉTODOS CLÁSSICOS E AVANÇADOS DE
PREVISÃO APLICADOS AO CONSUMO DE ENERGIA ELÉTRICA**

Trabalho de Conclusão de Curso apresentado ao DEE -
Departamento de Engenharia Elétrica da Universidade
Federal de São Carlos, para obtenção do título de Bacharel
em Engenharia Elétrica.

Orientador: Prof. Dr. Pedro Henrique Aquino Barra

SÃO CARLOS
2023

AGRADECIMENTOS

Dedico este trabalho à minha família, que sempre me apoiou e possibilitou que eu pudesse estudar e focar na minha vida profissional, em especial ao meu pai e minha mãe, Eduardo e Gisele, que sempre acreditaram em meu potencial. Em memória de minha vó Leontina, e em especial ao meu avô, Gilberto, que é a principal razão de eu ser quem eu sou, tanto como profissional quanto como pessoa, me servindo de exemplo para trilhar caminhos com respeito, paciência e honra.

Agradeço ao meu orientador, Prof. Pedro, que me orientou e me ajudou a concluir minha graduação, mesmo com todos empecilhos no caminho.

E meus agradecimentos a todos professores e colegas que passaram por minha vida, tanto acadêmica quanto profissional, agregando tanto conhecimento e me permitindo crescer e evoluir constantemente, como disse Sir. Issac Newton: “Se eu vi mais longe, foi porque estava sobre os ombros de gigantes.”

RESUMO

A garantia de um abastecimento de energia eficiente depende de uma previsão de demanda adequada, permitindo uma gestão eficiente dos recursos e otimização de processos, manutenções e investimentos. Este estudo avalia o processo de planejamento em diversas granularidades geográficas e setoriais, analisando as séries de consumo energético do Brasil, do subsistema Sudeste/Centro Oeste e do estado de São Paulo, com o propósito de compreender de maneira abrangente como a demanda de energia se insere no contexto de planejamento. Ademais, busca-se comparar quatro modelos preditivos, avaliando qual melhor se encaixa nos dados de consumo de energia do Brasil: Holt-Winters, SARIMA, SARIMAX com incorporação de dados do PIB e o Prophet. A análise comparativa entre os modelos foi realizada utilizando métricas de acurácia dos dados previstos, quais sejam, o erro percentual absoluto médio (MAPE), erro percentual médio (MPE) e raiz do erro quadrático médio (RMSE). Os resultados obtidos indicaram que o modelo que melhor se adequou aos dados propostos foi o Holt-Winters, com MAPE de apenas 0,6% de erro para o consumo do país em sua melhor configuração e uma média de 2,8% de MAPE ao considerar as 15 diferentes granularidades analisadas.

Palavras-chave: Energia Elétrica; Planejamento de demanda; Modelos de previsão; Modelos Avançados; Modelos Clássicos

LISTA DE FIGURAS

Figura 1 – Formato de dados no relatório da EPE	27
Figura 2 – Serie histórica do PIB Brasil	29
Figura 3 – Granularidade dos dados da EPE	30
Figura 4 – Série histórica de consumo de energia do Brasil	32
Figura 5 – Série histórica de consumo de energia de todas granularidades	33
Figura 6 – Decomposição da série de consumo total Brasil	34
Figura 7 – Decomposições das séries de consumo total Sudeste e SP	35
Figura 8 – Decomposições das séries de nível comercial	36
Figura 9 – Decomposições das séries de nível residencial	37
Figura 10 – Decomposições da séries de nível outros	38
Figura 11 – Decomposições da séries de nível industrial	39
Figura 12 – Período de queda no consumo de energia causado pela pandemia	40
Figura 13 – Dados da queda no consumo normalizados	41
Figura 14 – Dados tratados no Python	42
Figura 15 – Granularidade dos dados da EPE	43
Figura 16 – Teste realizado variando o período de treinamento (janela) em função do MAPE	44
Figura 17 – Fluxograma do processo de definição do melhor modelo	45
Figura 18 – Previsão ingênua do consumo total Brasil	46
Figura 19 – Resultados do modelo dummy para todas as séries	48
Figura 20 – MAPE dos dados obtidos pelo modelo ingênuo	49
Figura 21 – Métricas de erros do modelo <i>dummy</i>	49
Figura 22 – Previsão Holt-Winters do consumo total Brasil	50
Figura 23 – Resultados do modelo Holt-Winters para todas as séries	51
Figura 24 – MAPE dos dados obtidos pelo modelo Holt-Winters	52
Figura 25 – Métricas de erro do modelo Holt-Winters	52
Figura 26 – Previsão SARIMA do consumo total Brasil	53
Figura 27 – Resultados do modelo SARIMA para todas as séries	54
Figura 28 – MAPE dos dados obtidos pelo modelo SARIMA	55
Figura 29 – Métricas de erro do modelo SARIMA	56
Figura 30 – Previsão SARIMAX do consumo total Brasil	56
Figura 31 – Resultados do modelo SARIMAX para todas as séries	58
Figura 32 – MAPE dos dados obtidos pelo modelo SARIMAX	59
Figura 33 – Métricas de erro do modelo SARIMAX	59
Figura 34 – Previsão Prophet do consumo total Brasil	60
Figura 35 – Resultados do modelo Prophet para todas as séries	61

Figura 36 – MAPE dos dados obtidos pelo modelo Prophet	62
Figura 37 – Métricas de erro do modelo Phophet	62
Figura 38 – MAPE de todos os modelos para todas granularidades	63
Figura 39 – RMSE de todos os modelos para todas granularidades	64
Figura 40 – MPE de todos os modelos para todas granularidades	66
Figura 41 – Exemplo de overfitting em dados	68
Figura 42 – Consumo total Brasil dado pelo modelo final	68
Figura 43 – Consumo total Sudeste e Centro Oeste dado pelo modelo final	69
Figura 44 – Consumo total São Paulo dado pelo modelo final	69
Figura 45 – MAPE do modelo final para as três granularidades escolhidas	70

LISTA DE TABELAS

Tabela 1 – Granularidades escolhidas para o modelo	31
Tabela 2 – Tabela resumo com os elementos de tendência e sazonalidade dos modelos SARIMA	55
Tabela 3 – Tabela resumo com os elementos de tendência e sazonalidade dos modelos SARIMAX	57
Tabela 4 – Indicação da escolha do melhor modelo por granularidade	65

LISTA DE ABREVIATURAS E SIGLAS

ONS	Operador Nacional do Sistema Elétrico
EE	Energia Elétrica
EPE	Empresa de Pesquisa Energética
ANEEL	Agência Nacional de Energia Elétrica
SP	São Paulo
IA	Inteligência Artificial
ML	Machine Learning
HW	Holt-Winters
MMS	Média Móvel Simples
SMA	Simple Moving Average
MAPE	Mean Absolute Percentage Error
MPE	Mean Percentage Error
RMSE	Root Mean Squared Error
AIC	Akaike Information Criterion
MWh	Megawatt-hora
GWh	Gigawatt-hora
PIB	Produto Interno Bruto
IBGE	Instituto Brasileiro de Geografia e Estatística
FVA	Forecast Added Value

SUMÁRIO

1 – INTRODUÇÃO	12
1.1 Motivação	12
1.2 Objetivos	13
1.3 Estrutura do trabalho	14
2 – FUNDAMENTAÇÃO TEÓRICA	15
2.1 Demanda e consumo de energia	15
2.2 As etapas do processo de planejamento da demanda	16
2.3 Planejamento e previsão de consumo de energia	18
2.4 Séries temporais	19
2.5 Modelos quantitativos de previsão	21
2.5.1 Média Móvel Simples (MMS)	21
2.5.2 Amortecimento Exponencial Triplo (Holt-Winters)	21
2.5.3 FbProphet	22
2.5.4 SARIMAX	22
2.6 Métricas para avaliação	23
2.6.1 MPE (<i>Mean Percentual Error</i>)	24
2.6.2 MAPE (<i>Mean Absolute Percentual Error</i>)	24
2.6.3 RMSE (<i>Root Mean Squared Error</i>)	25
2.6.4 Critério de informação de Akaike (AIC)	25
2.7 Trabalhos correlatos	25
3 – METODOLOGIA	27
3.1 Obtenção dos dados	27
3.1.1 Dados de consumo de energia	27
3.1.2 Dados de PIB	28
3.2 Ferramentas utilizadas	28
3.3 Escolhas de granularidades e horizonte de previsão	29
3.3.1 Granularidades e níveis dos dados	29
3.3.2 Horizonte de previsão	31
3.4 Séries temporais de consumo de energia	32
3.5 Decomposição de séries temporais	34
3.6 Limpeza de <i>baseline</i>	35
3.7 Agrupamento da série histórica de dados	41
3.8 Períodos de treinamento e teste	42
3.9 Comparação entre métodos de previsão	44

4 – RESULTADOS DO MODELO	46
4.1 Resultados dos modelos clássicos	46
4.1.1 Resultados do modelo <i>dummy</i>	46
4.1.2 Resultados do modelo Holt-Winters	49
4.2 Resultado dos modelos avançados	52
4.2.1 Resultados do modelo SARIMA	52
4.2.2 Resultados do modelo SARIMAX com variável exógena do PIB	53
4.2.3 Resultados do modelo FB-Prophet	60
4.3 Definição do melhor modelo	63
4.4 Discussão dos resultados do modelo escolhido	66
4.5 Estudo de caso e validação final do modelo	67
5 – CONCLUSÃO	71
REFERÊNCIAS	73
Anexos	75
ANEXO A – Código Fonte	76

1 INTRODUÇÃO

Discute-se nesta sessão a estrutura do trabalho, bem como a motivação e os objetivos em dissertar sobre o tema: “Comparação de Métodos Clássicos e Avançados de Previsão Aplicados ao Consumo de Energia Elétrica”.

1.1 Motivação

O planejamento, segundo (FARIA, 1994), é quase tão antigo quanto a história da humanidade. Desde a antiguidade é feito um processo para minimizar as surpresas que as incertezas podem trazer. Portanto, estar o mais preparado possível para lidar com elas é essencial para o sucesso e prosperidade da humanidade. Atualmente, o planejamento é parte fundamental de qualquer organização, dado o aumento de complexidade em termos de processos, números de produtos e dados processados.

O processo de planejamento é muito mais amplo que um modelo matemático de previsão, englobando diversas áreas, processos e ferramentas. Um conceito importante é a diferença entre previsão e planejamento: a previsão é o uso de técnicas estatísticas para melhor aferir um dado futuro com base em uma série histórica, enquanto o planejamento é a definição da quantidade de recursos que serão alocados para atender uma determinada demanda. Ou seja, o planejamento tem como um de seus componentes essenciais, a previsão.

Um modelo preditivo só fornece bons resultados quando a qualidade dos dados inseridos nele segue a organização e qualidade esperada. Dessa maneira, verifica-se a importância das outras etapas do planejamento, que conforme abordado por (HYNDMAN; ATHANASOPOULOS, 2014), podem ser divididos em alguns aspectos principais, que são:

- A organização das informações a serem trabalhadas: os dados possuem granularidades diferentes e é preciso entender qual o nível que minimiza os erros e os esforços, mas que as informações obtidas tenham utilidade.
- Abordagem *Top-Down* vs. *Bottom-up*: há duas formas de executar o processo, realizando a previsão nas séries individuais para cada segmento (*bottom-up*) ou utilizando os dados de maneira mais agrupada, dividindo a previsão geral de acordo com premissas pré-estabelecidas (*top-down*).
- Limpeza de *baseline*: a base histórica a ser utilizada deve passar por um processo de “limpeza”, retirando inconsistências, erros de coleta, medição incorreta e/ou falta de dados, para que a projeção com base no passado seja mais próxima ao futuro.
- Definição do horizonte de planejamento: o tempo da previsão impacta no ciclo de decisão do modelo. Modelos de curto prazo auxiliam em tomadas de decisões mais imediatas, e geram uma maior capacidade de previsão, enquanto modelos de longo prazo ajudam em decisões mais estratégicas com uma menor capacidade de previsão.

No consumo de energia elétrica não é diferente, vista a necessidade de um processo de planejamento e dado que a energia elétrica não é um recurso integralmente armazenável. Esse processo é realizado por distribuidoras, companhias e organizações que fazem a distribuição ou o controle deste consumo, em diversas granularidades, níveis e períodos. Conhecer a previsão de demanda de energia tanto em longo quanto em curto prazo permite que se equilibre os custos da falta e do excesso. Por um lado tem-se os custos da falta, relacionados a não servir a energia (conceito de energia não suprida), ou seja, a falta de capacidade para atender uma demanda, o que pode resultar na perda de contratos, perda de público para outras fontes ou companhias, ou em caso mais severos, em um colapso na estabilidade do sistema. Por outro lado, tem-se o custo de excesso, que acarreta em desperdícios e má alocação de recursos, bem como em riscos à integridade da operação do sistema elétrico. Por conseguinte, uma previsão adequada permite um planejamento mais assertivo, por exemplo, de quando entrarão no cronograma projetos de expansão e manutenções programadas. Ainda nesse contexto, segundo (KAYTEZ et al., 2014), a previsão do consumo de eletricidade é a base para o crescimento de países em desenvolvimento.

Do ponto de vista de uma operadora a previsão de demanda a longo prazo é necessária para a contratação da energia a ser comprada e a de curto prazo é importante para garantir que o sistema de distribuição e transmissão trabalhe dentro dos limites contratados, evitando o pagamento de multas por ultrapassagem. Por exemplo, conforme a Resolução Normativa ANEEL nº 666 a ultrapassagem de demanda pode ser de até 10% sem o pagamento de multas e ao menos uma vez ao ano a demanda deve chegar em 90% do total contratado (ANEEL, 2015).

1.2 Objetivos

Este trabalho busca entender melhor as etapas do processo de planejamento voltados à demanda de energia, assim como estudar seus fatores e características que afetam os resultados de modelos preditivos, tanto clássicos como avançados. Entende-se por modelos avançados aqueles que participam de competições internacionais e são utilizados como *benchmarking* para modelos de previsão em geral. O trabalho tem como objetivo principal desenvolver uma ferramenta robusta que possa servir para comparação dentre alguns destes modelos e a escolha do que melhor se adapta aos dados de consumo energético do Brasil independente da granularidade, ou seja, aquele que resulta em dados previstos que mais se aproximam dos dados reais de consumo.

Os objetivos específicos são:

- Fazer a preparação dos dados da série histórica, entendendo qual a melhor abordagem a ser utilizada, limpando os *baselines*, selecionando as melhores granularidades e o horizonte de planejamento.
- Com os atributos selecionados, aplicar técnicas quantitativas de previsão e avaliar os

resultados, observando como cada uma das etapas anteriores afetam os resultados.

- Escolher o melhor modelo baseado em métricas de erros e abordagens matemáticas e lógicas.
- Usar o modelo criado em um estudo de caso, realizando uma aplicação e previsão real.

1.3 Estrutura do trabalho

Este trabalho é dividido em 5 capítulos. Este primeiro é a introdução, em que são abordados temas sobre o trabalho em geral. É uma breve introdução ao tema e a motivação em escrever sobre ele. Também são detalhados os objetivos do trabalho. O Capítulo 2 traz uma fundamentação teórica para o entendimento da previsão e planejamento da demanda. É discutida a significância desse processo, bem como as etapas que o compõem. Em sequência, são abordados os modelos quantitativos de previsão que serão utilizados ao longo deste trabalho, trazendo ao leitor um entendimento geral do processo teórico. Nesse capítulo, detalham-se também as métricas utilizadas para a avaliação dos modelos e trabalhos correlatos deste mesmo tema.

O Capítulo 3 apresenta a metodologia utilizada, forma de obtenção dos dados, maneira como eles foram tratados, quais foram as considerações e atributos selecionados para a aplicação dentro dos modelos preditivos, assim como o estudo e entendimento das séries históricas utilizadas. No Capítulo 4 são avaliados os resultados da ferramenta, os dados previstos de cada modelo, suas comparações e a escolha do que melhor se adapta aos dados utilizados. Neste capítulo também é feito um estudo de caso, utilizando a ferramenta criada para a previsão real de dados de demanda de energia obtidos por fontes oficiais. No Capítulo 5 é feita a conclusão de todo trabalho e possíveis próximos passos.

2 FUNDAMENTAÇÃO TEÓRICA

Para melhor entender o processo de planejamento e a integração dos modelos preditivos na previsão da demanda de energia elétrica, este capítulo traz uma fundamentação teórica sobre todo o processo, assim como as abordagens e modelos utilizados durante o desenvolvimento deste trabalho.

O capítulo inicia-se abordando aspectos chaves do consumo de energia, e o que pode afetar seu comportamento, em seguidos aspectos do planejamento aplicados a este consumo e sua importância. Em sequência, são apresentados os modelos preditivos, as diferentes abordagens e especificidades de cada um deles, assim como a explanação das ferramentas e métricas matemáticas utilizadas na avaliação e validação dos resultados das previsões. Portanto, este capítulo oferece um alicerce conceitual sólido para compreender tanto a demanda de energia elétrica quanto o processo de planejamento associado.

2.1 Demanda e consumo de energia

O funcionamento e a dinâmica do setor energético no Brasil sofrem alterações significativas com o tempo. Assim sendo, conforme ocorrem transformações sociais, econômicas e tecnológicas do país, o perfil de consumo muda. Por exemplo, o Brasil vem passando por um constante crescimento tanto econômico quanto populacional nas últimas décadas, o que aumenta constantemente a demanda de energia, dado que conforme a população aumenta e seu poder aquisitivo cresce, a demanda por energia dispara.

A expansão da economia afeta não só o consumo populacional residencial, mas também dos setores da indústria, comércio e serviços. A demanda de energia é amplamente utilizada como um indicador do desenvolvimento de um país, conforme abordado por (SMILL, 2010), já que ela é um resultado direto do crescimento do mesmo, e fornecer essa energia para sempre atender essa demanda crescente é o que permite que o crescimento continue. Caso os setores e as populações não tenham acesso a energia, o crescimento econômico pode ser afetado substancialmente, até podendo causar uma recessão econômica.

No entanto, é importante ressaltar que a demanda de energia não é homogênea em todo o país. A região Sudeste, por exemplo, concentra uma parcela significativa da demanda total de energia no Brasil. Essa região é composta por estados como São Paulo, Rio de Janeiro, Minas Gerais e Espírito Santo, que possuem uma infraestrutura industrial e urbana desenvolvida, resultando em uma maior necessidade de energia.

Outros aspectos importantes do panorama energético no Brasil são os subsistemas elétricos que compõem o sistema interligado brasileiro. O Brasil possui quatro subsistemas que integram o SIN (Sistema Integrado Nacional): Sul, Sudeste/Centro-Oeste, Nordeste e Norte, (ONS, 2023a). Cada subsistema abrange diferentes estados e apresenta características

distintas em termos de demanda e oferta de energia. E a interconexão dos sistemas através da malha de transmissão permite a obtenção de ganhos sinérgicos e explora a diversidade entre os regimes hidrológicos das bacias. Por exemplo, o subsistema Sudeste/Centro-Oeste é o mais populoso e industrializado, com uma alta demanda de energia elétrica. Já o subsistema Nordeste é caracterizado por uma grande disponibilidade de recursos renováveis, como a energia eólica e solar.

A tendência é que a demanda futura continue em uma constante crescente, impulsionada pelo crescimento econômico e pelo avanço tecnológico. Em paralelo, existe uma pressão para tornar o sistema elétrico cada vez mais limpo e sustentável, com uma maior utilização de matrizes solares e eólicas. Entender essas dinâmicas, de como o crescimento afeta cada subsistema, da mudança da matriz energética/elétrica e padrões de consumo é essencial para garantir um suprimento energético seguro, sustentável e adequado às necessidades do país.

2.2 As etapas do processo de planejamento da demanda

Segundo (KWASNCIKA, 1986), o processo de planejamento resulta em seis benefícios diretos, que são listados abaixo:

1. O planejamento contribui para reduzir ambiguidade e conflito de posições dentro da estrutura organizacional;
2. O planejamento limita ações aleatórias;
3. O planejamento reduz o grau de incerteza dentro da organização;
4. O planejamento permite à organização ter maior capacidade de tratar com as incertezas;
5. O processo de planejamento considera fatores, para efeito de tomada de decisão, que dificilmente seriam considerados sem ele;
6. O planejamento é importante, pois contribui para o desempenho das demais funções do processo administrativo. Sem a definição de um caminho como referência, todas as funções administrativas teriam dificuldades em dirigir suas atividades em torno de um objetivo.

No entanto, como abordado por (FARIA, 1994), o processo de planejamento é muito mais que um modelo matemático preditivo; são etapas de preparação, que contribuem diretamente para o resultado final.

A primeira etapa é a organização das informações: é necessário pensar o que se quer planejar e quais os dados principais a serem examinados, visto que os dados a serem inseridos no modelo também produzem resultados diferentes. Um dado muito granular, como o consumo de energia em cada município por hora, gera para apenas alguns anos de dados, milhões de linhas de informações. Logo, o processamento desses dados e o modelo necessário para prevê-los pode gerar um esforço imenso, que para uma visão macro do consumo no Brasil, pode não ser interessante. Alternativamente, um dado muito pouco

granular, como o consumo em cada subsistema por ano, gera muito menos dados, e muito menos esforço para tratá-los. Não obstante, o nível gerado de informação não traz grande utilidade para as organizações. Logo, é necessário pensar qual a granularidade que trará resultados relevantes para seu uso, minimizando os erros e o esforço utilizado, bem como maximizando a utilidade das projeções e resultados obtidos.

O segundo passo compreende entender a abordagem a ser utilizada. (MAKRIDAKIS; WHEELWRIGHT, 1989) destaca duas abordagens possíveis no planejamento, quais sejam: a abordagem *top-down* e a *bottom-up*. Na abordagem *top-down*, inicia-se em dados agrupados, prevendo-os e depois dividindo essas informações nos grupos que o compõem com o uso de premissas. Por exemplo, prevê-se o consumo Brasil, e de acordo com o histórico de proporções entre os subsistemas, divide-se esse consumo entre eles. Já em uma abordagem *bottom-up*, se inicia em modelos mais granulares, ou seja, no exemplo anterior é feito para cada subsistema individualmente.

Para definir a melhor abordagem, se utiliza a correlação entre as séries a serem previstas. Quando as séries históricas de consumo tem uma correlação positiva entre si, ou seja, o aumento de consumo de uma delas resulta no aumento de outras dentro do mesmo grupo, a série de consumo agrupada tende a apresentar uma variância maior do que a soma das variâncias individuais de cada uma de suas componentes. Desse modo, o erro da previsão calculada pela abordagem *top-Down* será maior do que o erro da abordagem *bottom-Up*.

No caso de uma forte correlação negativa, quando o aumento de uma série resulta necessariamente na queda das outras, o efeito inverso será observado e a abordagem *top-Down* apresentará vantagens sobre a abordagem *bottom-Up*. No contexto do consumo de energia onde a correlação não é negativa, dado que o consumo de energia em um subsistema não necessariamente substitui o de outro, a correlação entre as séries é levemente positiva ou neutra, a abordagem *bottom-Up* é a mais indicada neste caso. Então neste trabalho será analisada cada série individualmente.

Em seguida, com os dados selecionados e a melhor abordagem escolhida, é necessária uma limpeza do *baseline*, que consiste em tirar pontos que não retratam o consumo real, erros de coleta, entre outros, que geram comportamentos e padrões que não são desejáveis para o aprendizado do modelo. Por exemplo, um vale no consumo devido a um apagão pontual em certa cidade deveria ser removida da base, dado que o apagão foi um acontecimento pontual, e se mantido, o modelo entenderá que aquele evento se repetirá em cada ciclo. Esta limpeza normalmente é feita manualmente, entendendo com especialistas cada um dos pontos a serem removidos. Atualmente, algoritmos de Inteligência Artificial (IA) e *Machine Learning* (ML) podem auxiliar na identificação desses padrões e no auxílio da sanitização das bases.

Por fim, tem-se a definição de um horizonte de planejamento, ou seja, quanto tempo no futuro o modelo irá prever. Aqui, podem ser apontados dois tipos principais:

os modelos de longo e curto prazo. Os modelos de curto prazo auxiliam nas tomadas de decisões pontuais, como um modelo para auxiliar na decisão de compra e venda de energia para uma cooperativa. Esses dados normalmente são bem precisos, dado que o modelo não estima um futuro longínquo que carrega muitas incertezas. Alternativamente, um modelo de longo prazo auxilia em decisões estratégicas, como a implementação de uma nova usina ou linha de transmissão, ou a troca programada de um reator. Nesses, longo prazo carrega erros maiores na medida que o horizonte de tempo aumenta. Por isso é imprescindível o entendimento exato do objetivo do modelo para a escolha do melhor horizonte.

Com todas as definições e preparações finalizadas é possível partir para o modelo em si, que também carrega etapas específicas. (TUBINO, 2009) divide essas etapas em 5 principais:

1. Objetivo do modelo;
2. Coleta e análise dos dados;
3. Seleção da técnica de previsão;
4. Obtenção das previsões;
5. Monitoramento do modelo.

Inicialmente é determinado o objetivo do modelo, isto é, a razão pela qual a previsão é necessária. Após isso, são realizadas as coletas e análise dos dados que serão muito importantes para a próxima etapa, que consiste na seleção da técnica de previsão adequada. A quarta etapa resume-se na obtenção das previsões e a última é o monitoramento das previsões, que consiste em comparar o real (à medida que as previsões forem alcançadas), com o resultado obtido no modelo.

2.3 Planejamento e previsão de consumo de energia

As etapas de um processo de planejamento abordados anteriormente podem ser aplicadas em todas as previsões de consumo de energia, seja qual for a organização das informações, de curto ou longo prazo, de âmbito local ou nacional. Estas previsões desempenham um papel crucial em decisões e soluções estratégicas para garantir o fornecimento de energia para todo o país.

Ao se ter uma estimativa acurada do consumo/demanda de energia futura, empresas de geração, transmissão e distribuição podem planejar a expansão da capacidade de geração, dimensionar a infraestrutura de transmissão e distribuição e antecipar possíveis gargalos no sistema, evitando interrupções no sistema, obras emergenciais e outros problemas de confiabilidade. Além de otimizar os recursos disponíveis, programando a operação de maneira eficiente, ajustando a produção de acordo com a variação na demanda, podendo operar usinas na capacidade necessária e não nominal, diminuir a participação de usinas termoelétricas que são ligadas apenas em momentos de alta demanda, assim é possível atender a demanda de forma econômica. Em síntese, equilibrando e minimizando os custos do excesso e da falta.

Se a demanda for subestimada, corre-se o risco da não garantia de fornecimento para atender à demanda real, resultando em cortes de energia programados ou até mesmo falta de energia, gerando graves consequências tanto em termos econômicos, como perdas financeiras para empresas e indústrias, quanto em termos sociais, afetando o conforto e a segurança. Por outro lado, se a demanda for superestimada, pode-se ter um excesso de capacidade de geração, resultando em custos desnecessários. O investimento em infraestrutura de geração e a operação de usinas com baixa utilização podem gerar custos elevados, portanto, encontrar o equilíbrio adequado entre a oferta e a demanda de energia é fundamental para garantir a eficiência econômica do sistema elétrico.

Como a demanda futura de energia afeta diversas empresas relacionados a distribuição, não existe apenas uma previsão, cada empresa realiza o seu processo de planejamento de acordo com suas necessidades, em diferentes granularidades. Empresas de geração de energia podem se concentrar mais na previsão da oferta e demanda para otimizar a produção de usinas, enquanto empresas de distribuição podem se concentrar na previsão de carga para otimizar a distribuição e minimizar perdas .

Uma das abordagens mais conhecidas, é a previsão de carga nacional do ONS (Operador Nacional do Sistema Elétrico), que divulga relatórios para planejamento com previsões de cargas de longo prazo, normalmente 5 anos (ONS, 2023b), sendo fundamentais para a operação do sistema elétrico.

Portanto, o processo de planejamento e previsão de consumo de energia é complexo e envolve uma série de considerações técnicas, econômicas e estratégicas. A combinação de modelos preditivos, análise de dados históricos, conhecimento especializado e tecnologias avançadas, como inteligência artificial e *machine learning*, desempenha um papel fundamental na obtenção de previsões precisas e confiáveis. Essas previsões são essenciais para o funcionamento eficiente do sistema elétrico, a tomada de decisões informadas e a garantia do fornecimento de energia elétrica de maneira sustentável e econômica para toda a sociedade.

2.4 Séries temporais

As séries temporais são conjuntos de dados onde as observações são coletadas em intervalos de tempo sucessivos e constantes. Os dados obtidos tanto de consumo de energia da EPE (Empresa de Pesquisa Energética) quanto os dados de PIB (Produto Interno Bruto) do IBGE (Instituto Brasileiro de Geografia e Estatística) são séries temporais, ou seja, dados relacionados com o tempo. Nesse caso, os dados de consumo, indicando a variação histórica do consumo de energia elétrica, e os dados do PIB, indicando a variação do produto interno no Brasil ao longo do tempo.

A seleção da granularidade temporal, depende do dado e da forma como ele é coletado, podendo ser de anos, meses e até minutos. No caso de ambos dados abordados neste trabalho, trabalha-se com meses. A temporalidade da série reflete as flutuações e

padrões que ocorrem no consumo de energia elétrica os quais são influenciados por fatores sazonais, climáticos, econômicos e comportamentais.

Os modelos preditivos recebem como parâmetro de entrada principal, séries temporais do dado a ser tratado, assim, é feita a relação do dado no tempo, o modelo entende padrões históricos e aplicando técnicas estatísticas, extrapolam esses padrões no futuro. As séries temporais também auxiliam a visualizar e entender os padrões de consumo e possíveis *outliers* que necessitam de tratamento e atenção, também é possível qualitativamente estimar os resultados, embora quando a previsão é feita sem auxílios de ferramentas matemáticas e computacionais, ou seja, feita humanamente, ele é sujeita a diversos erros e tendenciamentos, um *check* de sanidade é possível, por exemplo, em uma série de constante crescimento, um modelo que prevê uma queda brusca, possa precisar de uma validação mais a fundo.

Segundo (MONKS, 1987), as séries temporais podem ser decompostas em Tendência (*Trend*), Sazonalidade (*Seasonal*), Ciclo (*Cycle*) e Erro (*Error*). Esses componentes de uma série definem seu comportamento e sua composição, e podem ser analisados individualmente realizando uma decomposição matemática. Quando realizado a decomposição é possível avaliar e entender mais a fundo a série em questão. O nível representa a grandeza de valor que a série trata, milhões, milhares, no caso do consumo de energia, milhares de GWh todo mês. Para as componentes, (MOREIRA, 1993), define os quatro comportamentos ou efeitos associados a elas:

1. Efeito tendência: Quando a série apresenta uma tendência de crescimento ou decréscimo no tempo.
2. Efeito sazonal: Padrões ou comportamentos cíclicos em determinados períodos do ano.
3. Ciclo: Relacionado aos ciclos econômicos, ocorrem de forma geral, em períodos entre 3 a 5 anos.
4. Variações irregulares ou acaso: São variações por um curto período de tempo, por causas não identificadas, que destoam do nível normal da série.

Outro conceito importante intrínseco as séries temporais é a estacionariedade, que ocorre quando suas propriedades estatísticas, como média, mediana, variância, estão distribuídos ao redor de uma média fixa com o decorrer do tempo, ou seja, a série é estacionária. Uma série não estacionária é aquela que apresenta tendência, nível e/ou sazonalidade.

Alguns modelos estatísticos assumem que a série seja estacionária, que na maioria das vezes, não é verdade, logo é necessário o ajuste dos dados, sendo o mais comum a diferenciação da série, quando calcula-se a diferença entre os valores da série em diferentes intervalos de tempo removendo tendências. Outro método é a decomposição da série nos 4 elementos aqui abordados, para que cada um seja abordado individualmente (HYNDMAN; ATHANASOPOULOS, 2014).

2.5 Modelos quantitativos de previsão

Os modelos quantitativos utilizam técnicas matemáticas e abordagens estatísticas para analisar e encontrar tendências e parâmetros em dados históricos, com esse aprendizado ele estima valores desta série para o futuro. Os métodos quantitativos incluem técnicas como a média móvel, suavização exponencial, regressão linear, análise de séries temporais, SARIMA e outros modelos estatísticos avançados.

2.5.1 Média Móvel Simples (MMS)

A média móvel simples, do inglês *Simple moving average* (SMA), é calculada com base na média aritmética dos últimos n períodos escolhidos e replica-ló na previsão de dados futuros, de acordo com a seguinte equação:

$$\text{MMS} = \frac{1}{n} \sum_{i=1}^n x_i, \quad (1)$$

em que n é o número de observações e x_i são os valores das observações, a quantidade de observações permanece fixa, definida inicialmente com a série a ser prevista, e os valores do dados vão avançando no tempo, de acordo com o avanço temporal da série. A MMS é um método simples, que normalmente não gera bons resultados em séries mais complexas, caso sua série tenha sazonalidade e/ou tendência, os resultados do modelo serão insatisfatórios.

2.5.2 Amortecimento Exponencial Triplo (Holt-Winters)

O método de Holt-Winters, ou amortecimento exponencial triplo, foi proposto por Peter Winters, baseando-se no modelo desenvolvido pelo seu professor Charles Holt. Esta técnica, diferente de do amortecimento exponencial simples e duplo, leva em consideração a sazonalidade e/ou tendência da série temporal tratada, como abordado por (HYNDMAN; ATHANASOPOULOS, 2014), e até hoje é uma das técnicas mais utilizadas em previsões.

No HW é realiza a decomposição da série em parâmetros de suavização a serem utilizados na previsão, esses parâmetros servem para atribuir diferentes pesos aos dados históricos, atribuindo assim influencias diferentes em dados mais recentes e considerar a variação da sazonalidade nos modelos.

Sendo eles, α , o parâmetro de valores passados, β , de tendência e γ para a sazonalidade, eles são utilizados na definição dos :

$$L_t = \alpha \cdot \frac{y_t}{S_{t-m}} + (1 - \alpha) \cdot (L_{t-1} + T_{t-1}) \quad (2)$$

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot T_{t-1} \quad (3)$$

$$S_t = \gamma \cdot \frac{y_t}{L_t} + (1 - \gamma) \cdot S_{t-m} \quad (4)$$

$$y_{t+m} = (L_t + m \cdot T_t) \cdot S_{t-m+1} \quad (5)$$

sendo L_t a componente de nível, T_t a de tendência e S_t de sazonalidade, m é o período de sazonalidade, t é o tempo, y_t o valor da série no tempo, por fim o valor a ser previsto para cada valor de t é $y_t + m$.

2.5.3 FbProphet

Desenvolvido por Sean Taylor, pesquisador do Facebook, o FbProphet é um método de previsão avançado que busca ser simples e ao mesmo tempo trazer bons resultados de projeção de forma semiautomática, calculando os parâmetros matemáticos intrínsecos a ele sozinho. Ele se baseia em modelos de decomposição, como o amortecimento exponencial triplo, dividindo a série em parâmetros de tendência e sazonalidade, só que diferentemente dos modelos clássicos esta técnica adiciona um parâmetro de feriados, buscando entender o efeito que feriados e datas festivas podem exercer na demanda. Obviamente, esse modelo funciona melhor em séries que tem efeitos sazonais mais proeminentes (TAYLOR; LETHAM, 2017).

As três principais componentes do modelo são combinadas de acordo com a seguinte equação:

$$y_t = (T_t) + (S_t) + (H_t) + \epsilon_t, \quad (6)$$

em que T_t é a componente a de tendência, S_t de sazonalidade, H_t a de feriados, ϵ_t é o parâmetro de erro, que representa valores idiossincráticos que não são representados pelo modelo.

2.5.4 SARIMAX

O SARIMAX é uma variação do modelo de dependência temporal ARIMA. O ARIMA junto com os modelos de amortecimento exponencial são os dois métodos mais utilizados de previsão na literatura. Os modelos de amortecimento se baseiam na decomposição da série em parâmetros de sazonalidade e/ou tendência, modelos ARIMA buscam analisar a correlação existente nos dados e com ela realizar a previsão (HYNDMAN; ATHANASOPOULOS, 2014).

Ele é composto por alguns princípios que são demonstrados no seu próprio nome. AR de *autoregressive*, I de *integrated*, MA de *moving average*, o SARIMA, adiciona a componente S, de *seasonal* e o SARIMAX, o X, de *exogenous*. Os princípios são detalhados abaixo:

- AR (autorregressivo): Considera a correlação dos dados, ou seja, que dados passados são usados para prever dados futuros, o modelo utiliza ponderação para dar peso a dados mais recentes.
- I (integrado): Propriedade de modelo que retira a tendência da série, transformando-a em estacionária.

- MA (média móvel): Propriedade repensável por eliminar erros não determinísticos ou movimentos aleatórios da série.
- S (sazonalidade): Componente que inclui a sazonalidade na previsão, funciona fazendo com que a série não se compare, necessariamente, com o período anterior ao analisado e sim com o período anterior considerando o ciclo de sazonalidade definido.
- X (exógena): Utiliza a correlação dos dados do modelo com variáveis externas para encontrar possíveis correlações que ajudem a explicar os dados futuros.

O SARIMA é calculado de acordo com a seguinte equação:

$$y_t = \sum_{i=1}^p \phi_i B^i \sum_{j=1}^P \Phi_j B^{sj} \sum_{k=0}^D (-1)^k \binom{D}{k} B^{sk} (Y_t - \mu) + \sum_{l=1}^q \theta_l B^l \sum_{m=1}^Q \Theta_m B^{sm} \varepsilon_t \quad (7)$$

Onde:

- p : ordem do componente autoregressivo.
- d : número de diferenças não sazonais.
- q : ordem do componente de média móvel.
- P : ordem do componente autoregressivo sazonal.
- D : número de diferenças sazonais.
- Q : ordem do componente de média móvel sazonal.
- s : período de sazonalidade.
- ϕ_i : coeficientes autorregressivos não sazonais.
- Φ_i : coeficientes autorregressivos sazonais.
- θ_i : coeficientes de média móvel não sazonais.
- Θ_i : coeficientes de média móvel sazonais.
- B : operador de atraso.
- Y_t : valor da série temporal no tempo t .
- μ : média da série temporal.
- ε_t : erro no tempo t .

Os valores de alguns parâmetros precisam ser inseridos são eles $(p, d, q)(P, D, Q, s)$, as outras componentes são definidas pela série. Definir esses parâmetros não é algo simples, no entanto (HYNDMAN; ATHANASOPOULOS, 2014), desenvolveu uma técnica que consiste no teste de valores pré definidos para essas componentes e a escolha do melhor conjunto baseado no critério de informação de Akaike (AIC), qual foi o modelo que teve melhor desempenho, o AIC será abordado em detalhes oportunamente.

2.6 Métricas para avaliação

Para validar a acurácia de um modelo são utilizadas métricas correspondentes aos erros previstos, essa definição de métricas é fundamental para que se avalie o modelo de forma correta e que se adéque aos dados a serem previstos da melhor maneira possível.

A escolha dos indicadores a avaliarem o modelo não é padrão, e depende dos objetivos e dos dados previstos, cada indicador pode apontar pra algo, para algumas previsões pode ser interessante um indicador absoluto, que esconde se o erro é positivo ou negativo, apontando apenas para o tamanho deste. Já para outra séries, é de extrema valia que os dados não prevejam valores com erros positivos. Então é importante ter mais de um indicador, que abordem alguns pontos importantes, indicador por (NICOLAS, 2023) ele deve ser facilmente interpretável, não linear, não sensível a *outliers*, não tendencioso e dimensionado.

Neste trabalho, com o objetivo de ter métricas que tenham uma ampla abordagem, foram escolhidos os seguintes indicadores de erros: MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Square Error*) e MPE (*Mean Percentage Error*), os quais são descritos na sequência, como abordado por (BOTCHKAREV, 2019).

2.6.1 MPE (*Mean Percentual Error*)

É a média das somas percentuais do erro, por não se tratar de valores absolutos, os dados previstos positivos e negativos se anulam, deixando a métrica com valores próximos de 0%, sendo assim, é utilizado para identificar se o modelo tem algum tipo de viés, se as previsões estão sistematicamente abaixo (ou acima) dos dados reais, é dado por:

$$MPE = \frac{1}{n} \sum_{t=1}^n \left(\frac{A_t - F_t}{A_t} \right) \times 100\%, \quad (8)$$

onde:

- n = número total de observações,
- A_t = valor real (observado) no tempo t ,
- F_t = valor previsto no tempo t .

2.6.2 MAPE (*Mean Absolute Percentual Error*)

Similar ao MPE, o MAPE, média do erro percentual absoluto, mede os erros de previsão em uma escala de porcentagem, mas de maneira absoluta não cancela os erros positivos com negativos, apresentado uma porcentagem média de erro pra todos os dados do período. É a métrica mais utilizada em métodos de previsão, por ser extremamente fácil de interpretar e por representar bem a qualidade preditiva. Sua equação é:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left(\frac{|A_t - F_t|}{A_t} \right) \times 100\%, \quad (9)$$

onde:

- n = número total de observações,
- A_t = valor real (observado) no tempo t ,
- F_t = valor previsto no tempo t .

2.6.3 RMSE (*Root Mean Squared Error*)

Calcula a raiz quadrada da média das somas dos quadrados dos erros. A soma dos quadrados atribui peso maior aos maiores erros e o quadrado retorna esse erro para a escala dos dados trabalhados. Por atribuir pesos diferentes aos erros, é utilizado quando erros maiores são indesejáveis, mas é uma métrica extremamente sensível a *outliers*. Sua equação é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2}, \quad (10)$$

onde:

- n = número total de observações,
- A_t = valor real (observado) no tempo t ,
- F_t = valor previsto no tempo t .

2.6.4 Critério de informação de Akaike (AIC)

Métrica que mensura a qualidade de um modelo estatístico visando também a sua simplicidade. Fornece, portanto, um parâmetro para comparação e seleção entre modelos levando em consideração o ajuste dos modelos aos dados e a sua complexidade, garantindo assim que modelos com uma pontuação maior, sejam não só mais precisos como também mais simples. Sua equação é dada por:

$$AIC = 2k - 2\ln(\hat{L}), \quad (11)$$

onde:

- k = número de parâmetros no modelo,
- \hat{L} = valor máximo da função de verossimilhança do modelo.

2.7 Trabalhos correlatos

Na sequência, alguns trabalhos correlatos, encontrados na literatura, são apresentados.

Santos (2019) realizou uma previsão de médio prazo da demanda de energia do setor industrial na região sul e sudeste do Brasil, utilizando um modelo ETS e modelos ARIMA, com sazonalidade e duas variáveis exógenas, o PIB (produto interno bruto) e o (IBCR) índice de atividade econômica regional. Concluiu-se que os modelos apresentaram resultados satisfatórios, com o ETS sendo escolhido como o melhor. O PIB foi definido como tendo uma baixa correlação e o IBCR uma correlação melhor com os dados de consumo.

Drebes (2020) empregou inteligência artificial e o software *WEKA* para a previsão de energia diária para uma cooperativa, minerando os dados diretamente de um banco de dados e realizando uma correlação com variáveis climáticas. O software permitiu alguns modelos como rede neural e *random forests*, chegando no final em erros de apenas 3%.

O cenário pandêmico afetou bastante o perfil de consumo de energia, e Barbosa (2021) abordou um modelo de previsão dentro do cenário da pandemia com o uso de inteligência artificial. Os dados foram aplicados em um rede neural do tipo LSTM (*Long Short Term Memory*), correlacionando dados das mortes de COVID no consumo de energia, concluindo que o número de mortes realmente afeta o consumo e que um enfoque socio-econômico-ambiental permite uma melhor previsão de consumo.

Carvalho (2019) comparou dois métodos de previsão (ARIMA e Holt-Winters) aplicados a um grande número de dados, por número de residências por mês. Utilizando-se da ferramenta *Apache Spark* do R, os dados foram tratados e previstos resultando em uma vantagem do ARIMA frente ao Holt-Winters, que apresentou dados de erro 4,6 vezes maiores.

O trabalho realizado por Santiago e Junior (2021) englobou uma ferramenta de comparação entre diversos modelos preditivos, dentro eles modelos avançados, mas aplicado a um cenário de uma empresa do segmento de joias. Percebeu-se que todos os modelos aplicados apresentaram resultados melhores que modelos básicos de previsão, principalmente o SARIMA, o Prophet e o SilverKite.

O consumo de energia previsto em curtíssimo prazo foi abordado por Klein (2014), onde foi aplicado em séries de consumo brasileiros e gaúchos, modelos de redes neurais e correlações comparando temperatura intra-diária, intensidade de uso da luminosidade artificial e uma aproximação em modelo autorregressivo para obter um resultado de previsão de demanda de energia elétrica para as próximas vinte e quatro horas com erros médios em torno de 8%, que levando em conta o prazo de planejamento, foi considerado satisfatório pelo autor.

Do exposto, pode-se perceber que este trabalho diferencia-se da literatura existente. Neste trabalho, modelos avançados de previsão são aplicados ao consumo de energia elétrica considerando distintas granularidades. Assim sendo, acredita-se que o trabalho traz contribuições interessantes na temática de previsão do consumo de energia elétrica.

3 METODOLOGIA

Com a base teórica desenvolvida, aqui será apresentada a metodologia de pesquisa e desenvolvimento dos dados para sua aplicação nos modelos preditivos, assim como o desenvolvimento de cada uma das etapas que foram abordadas nos capítulos anteriores e as ferramentas utilizadas durante todo este processo.

3.1 Obtenção dos dados

3.1.1 Dados de consumo de energia

Os dados de consumo de energia utilizados neste trabalho foram obtidos pelo relatório de consumo da EPE (Empresa de Pesquisa Energética), que mensalmente divulga um relatório de consumo de energia elétrica em níveis nacional, regional e por subsistemas, segmentado-os pelas classes residencial, industrial, comercial e outros, este último englobando consumo rural e de serviços e iluminações públicas. Os dados foram obtidos em 14 de maio de 2023, no relatório mais recente disponível na data de coleta. Os últimos dados de consumo eram do mês de março de 2023, assim todos as análises e testes consideram o corte neste período.

A Figura 1 ilustra o formato dos dados disponibilizados pela EPE, onde a informação é dada em períodos de tempo mensais, nas granularidades já apontadas e o consumo de energia elétrica na rede em Megawatt-hora (MWh). Em função do grande volume de dados, esta figura tem o objetivo apenas de caracterizar a forma com que os dados são obtidos.

Figura 1 – Formato de dados no relatório da EPE

	2023*												ANO	
	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ		
TOTAL BRASIL	42,812,708	42,896,553	45,712,223	44,693,095	-	-	-	-	-	-	-	-	-	176,114,579
REGIÃO GEOGRÁFICA														
Norte	3,178,215	2,962,136	3,327,449	3,213,111	-	-	-	-	-	-	-	-	-	12,680,911
Nordeste	7,649,099	7,491,621	7,855,653	7,824,545	-	-	-	-	-	-	-	-	-	30,820,918
Sudeste	20,422,809	20,584,858	22,140,643	21,551,007	-	-	-	-	-	-	-	-	-	84,699,317
Sul	8,316,139	8,622,232	8,957,674	8,637,518	-	-	-	-	-	-	-	-	-	34,533,562
Centro-Oeste	3,246,447	3,235,705	3,430,805	3,466,914	-	-	-	-	-	-	-	-	-	13,379,871
SUBSISTEMA ELÉTRICO														
Sistemas Isolados	236,327	223,815	249,457	246,960	-	-	-	-	-	-	-	-	-	956,558
Norte	3,571,001	3,364,943	3,756,769	3,658,729	-	-	-	-	-	-	-	-	-	14,351,441
Nordeste	6,659,377	6,523,348	6,789,724	6,767,275	-	-	-	-	-	-	-	-	-	26,739,724
Sudeste/C.Oeste	24,029,865	24,162,215	25,958,600	25,382,614	-	-	-	-	-	-	-	-	-	99,533,294
Sul	8,316,139	8,622,232	8,957,674	8,637,518	-	-	-	-	-	-	-	-	-	34,533,562

Fonte: Adaptado da EPE

A EPE foi escolhida como fonte dos dados desse trabalho pois fornece os dados de forma gratuita e totalmente aberta, por ser uma organização oficial ligada ao Ministério de Minas e Energia (MME), os dados são de qualidade e credibilidade, com relatórios de atualização divulgados mensalmente, pontos importantes para validar o uso e resultados

da ferramenta. E por fim, os dados da EPE tem diversas granularidades, permitindo a seleção e o teste em diversas delas, dado que um dos objetivos do trabalho é criar uma ferramenta robusta que suporte diversos níveis e formatos de informações distintos, o teste em diferentes níveis é essencial.

Portanto, ao selecionar os dados da EPE, não só se tem o embasamento que a ferramenta necessita, como baseia-se o trabalho em informações sólidas, confiáveis e atualizadas.

3.1.2 Dados de PIB

O produto interno bruto (PIB) do Brasil é o maior indicador do desempenho econômico do país, abrangendo a produção de bens e serviços, sendo assim, o PIB reflete diretamente a demanda por energia, dado que, as atividades produtivas estão fortemente relacionadas ao uso de recursos energéticos. A ONS reconhece essa forte ligação, utilizando o PIB como um indicador chave para realizar os relatórios de previsão anual de carga.

Assim, os dados históricos do PIB são frequentemente utilizados como inputs de modelos preditivos para auxiliar na precisão dos resultados, o comportamento de uma variável pode explicar a outra e vice-versa. Essa relação não é totalmente linear, e sofre pela soma de diversos fatores, como avanços tecnológicos que alteram o perfil de consumo, então para prever a demanda é essencial analisar além do PIB, fatores como políticas energéticas e mudanças demográficas, mas ainda assim, o PIB é uma variável exógena fundamental na previsão de demanda de energia, e será utilizada neste trabalho para auxiliar os modelos de previsão a melhorar sua acurácia.


Os dados de PIB são facilmente encontrados, dado a importância deste, os dados aqui utilizados foram obtidos pelo site do IBGE, uma fonte governamental oficial de divulgação, utilizando a mesma base histórica dos dados obtidos de consumo de energia, ou seja uma serie histórica mensal até março de 2023. Os dados obtidos, podem ser observados plotados na Figura 2.

3.2 Ferramentas utilizadas

Para este trabalho, os modelos e os tratamentos da base serão feitos computacionalmente utilizando o Python, que é uma linguagem de programação *open-source*, com suporte amplo e consolidado pela comunidade, assim como disponibilidade de diversas ferramentas e bibliotecas já desenvolvidas que auxiliam em métodos preditivos. Algumas das principais bibliotecas utilizadas foram:

- *sklearn*: O *scikit-learn* é uma biblioteca de *machine-learning* em Python que fornece ferramentas para análise de dados e previsão, com indicadores de erros e funções de modelos preditivos.

Figura 2 – Serie histórica do PIB Brasil



Fonte: autor

- *statsmodels*: O *statsmodels* é uma biblioteca estatística em Python que possibilita o uso com facilidade de parâmetros, testes estatísticos e modelagem de séries temporais.
- *matplotlib*: É uma biblioteca de visualização em Python, permite criar gráficos de maneira simples.
- *seaborn*: Outra biblioteca de visualização, que permite a criação de gráficos não abrangidos pelo *matplotlib*.
- *pandas*: O *pandas* é uma biblioteca de análise de dados, auxiliando no tratamento e análise de conjunto grande de dados.

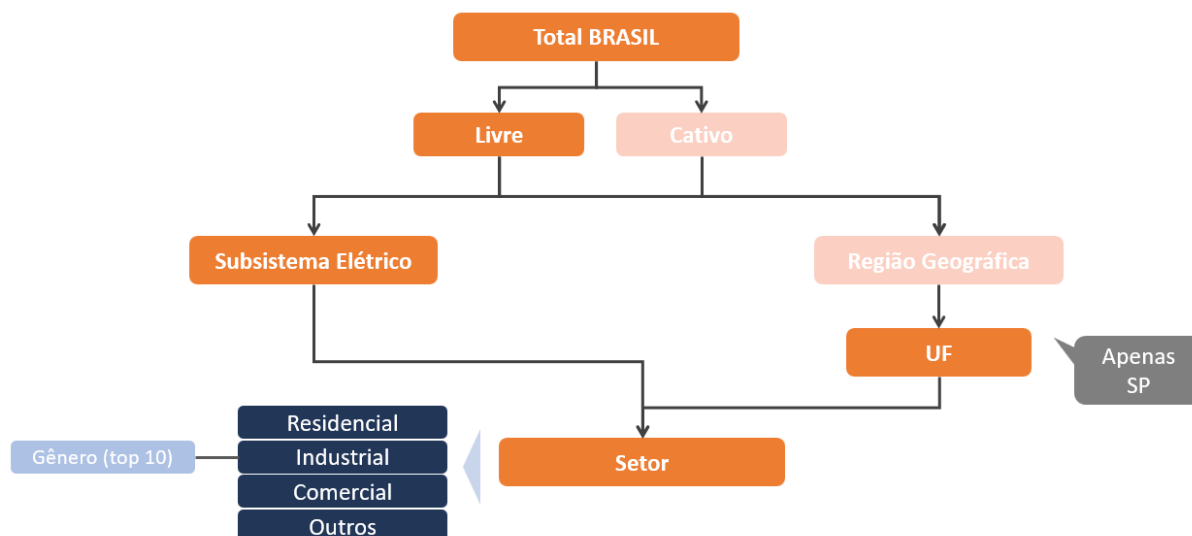
3.3 Escolhas de granularidades e horizonte de previsão

3.3.1 Granularidades e níveis dos dados

Como mencionado, a EPE divulga os dados de consumo em algumas granularidades principais. No entanto, o uso de todas elas se torna inviável devido ao grande número de combinações possíveis. Logo, foram selecionadas algumas principais para se trabalhar, como ilustrado pela Figura 3. Assim sendo, neste trabalho não serão utilizadas granularidade geográficas como regiões e UF, e nem o consumo cativo destas mesmas granularidades. Como resultado, foi escolhido o total Brasil como sendo a série completa de consumo, logo em seguida os subsistemas elétricos, e por fim, para cada subsistema elétrico, foram selecionadas as granularidades de setor, onde não foi aberto por gênero para o setor industrial, se limitando ao primeiro nível de quebra da informação.

Essas granularidades foram escolhidas considerando a necessidade de teste no modelo, de maneira a validar a ferramenta em granularidades que abrangessem o maior número de especificidades possíveis. Assim foi escolhido uma série para cada uma das quebras de grandes granularidades: Brasil, subsistema elétrico e UF, e quebras por setor para cada

Figura 3 – Granularidade dos dados da EPE



Fonte: autor

uma delas, com uma perspectiva de aplicação da ferramenta de maneira prática que pode beneficiar diferentes entidades, por exemplo:

- No nível Brasil tem-se o nível de Governo Central, que com as agências reguladoras e instituições responsáveis utilizam a informação para as tomadas de decisões relacionadas a investimento de infraestruturas, políticas de eficiência energética, operação e expansão do SIN.
- Para os subsistemas elétricos, os operadores do sistema que são as entidades responsáveis pela operação e planejamento do sistema elétrico, como o ONS, podem utilizar essas previsões para otimizar o despacho de geração e garantir a confiabilidade e a estabilidade do sistema, bem como estudar necessidades de expansão.
- E no nível UF, no caso São Paulo, as distribuidoras de energia podem usar a informação para suprimento de energia de maneira mais precisa para atender às necessidades específicas de cada UF.

Para cada um dos 3 níveis acima, tem-se 4 composições em setores de consumo, industrial, comercial, residencial e outros, onde outros engloba serviços públicos e consumo rural. É importante ter a quebra por setores para testes extensivos dos modelos, dado que o perfil de consumo muda bastante para cada granularidade; o residencial tende a ser mais estável com o crescimento populacional, já o industrial depende muito do momento econômico nacional.

Sendo assim, as escolhas feitas resultaram em 15 granularidades finais para testes e aplicações do modelo, abrangendo diversas áreas e perfis de consumo para o teste exaustivo dos processos de previsão. De modo a sumariá-las, as granularidades que serão utilizadas podem ser observadas na Tabela 1.

Tabela 1 – Granularidades escolhidas para o modelo

Séries de dados selecionados
Total Brasil
Brasil Industrial
Brasil Comercial
Brasil Residencial
Brasil Outros
Total Sudeste Centro Oeste
Sudeste Centro Oeste Industrial
Sudeste Centro Oeste Comercial
Sudeste Centro Oeste Residencial
Sudeste Centro Oeste Outros
Total São Paulo
São Paulo Industrial
São Paulo Comercial
São Paulo Residencial
São Paulo Outros

Fonte: autor

3.3.2 Horizonte de previsão

A escolha de um horizonte de previsão adequado é essencial para minimizar os erros e os esforços relacionados ao processo de planejamento, podendo ser de curto ou longo prazo. A escolha feita neste estudo foi considerando a precisão e a utilidade das projeções realizadas, dado que a ideia do trabalho é criar uma ferramenta robusta, um modelo que conseguisse abordar os dois extremos é o ideal. Dado isso, uma previsão de médio prazo se encaixa melhor na escolha do período de tempo previsto pelo modelo. O período previsto deve ser capaz de identificar tendências sazonais e padrões cíclicos de consumo, como por exemplo, o aumento da demanda durante meses mais frios, pelo uso de equipamentos de aquecimento.


As informações coletadas pela EPE tem uma granularidade de tempo em meses, assim o horizonte previsto seria de 12 meses. Considerando todos os pontos levantados, um horizonte de previsão de 1 ano atende todos eles, ou seja, é um período que abrange um ciclo completo de sazonalidade e padrões cíclicos, passa por todas estações e periodizações humanas, como datas festivas, férias, entre outros, e também um abrange um período longo o suficiente de tempo, mas que ainda pode ser considerado de médio prazo.

Todos os resultado dos modelos serão testados, então, com 12 meses de projeção. Ressalta-se que o período selecionado é para testes do modelo, e que para usos específicos do modelo, esse horizonte pode ser ajustado para necessidades pontuais a fim de tomar decisões informadas e estratégicas no contexto de cada usuário realizando a previsão.

3.4 Séries temporais de consumo de energia

As séries históricas das granularidades selecionadas, foram plotadas com o auxílio do *matplotlib*, para serem visualmente inspecionadas em busca de possíveis inconsistências. Na Figura 4, a série do consumo de energia total do Brasil, é possível, qualitativamente tirar algumas conclusões, como um constante crescimento, assim como ciclos de picos e vales que se repetem periodicamente, indicando a sazonalidade de consumo.

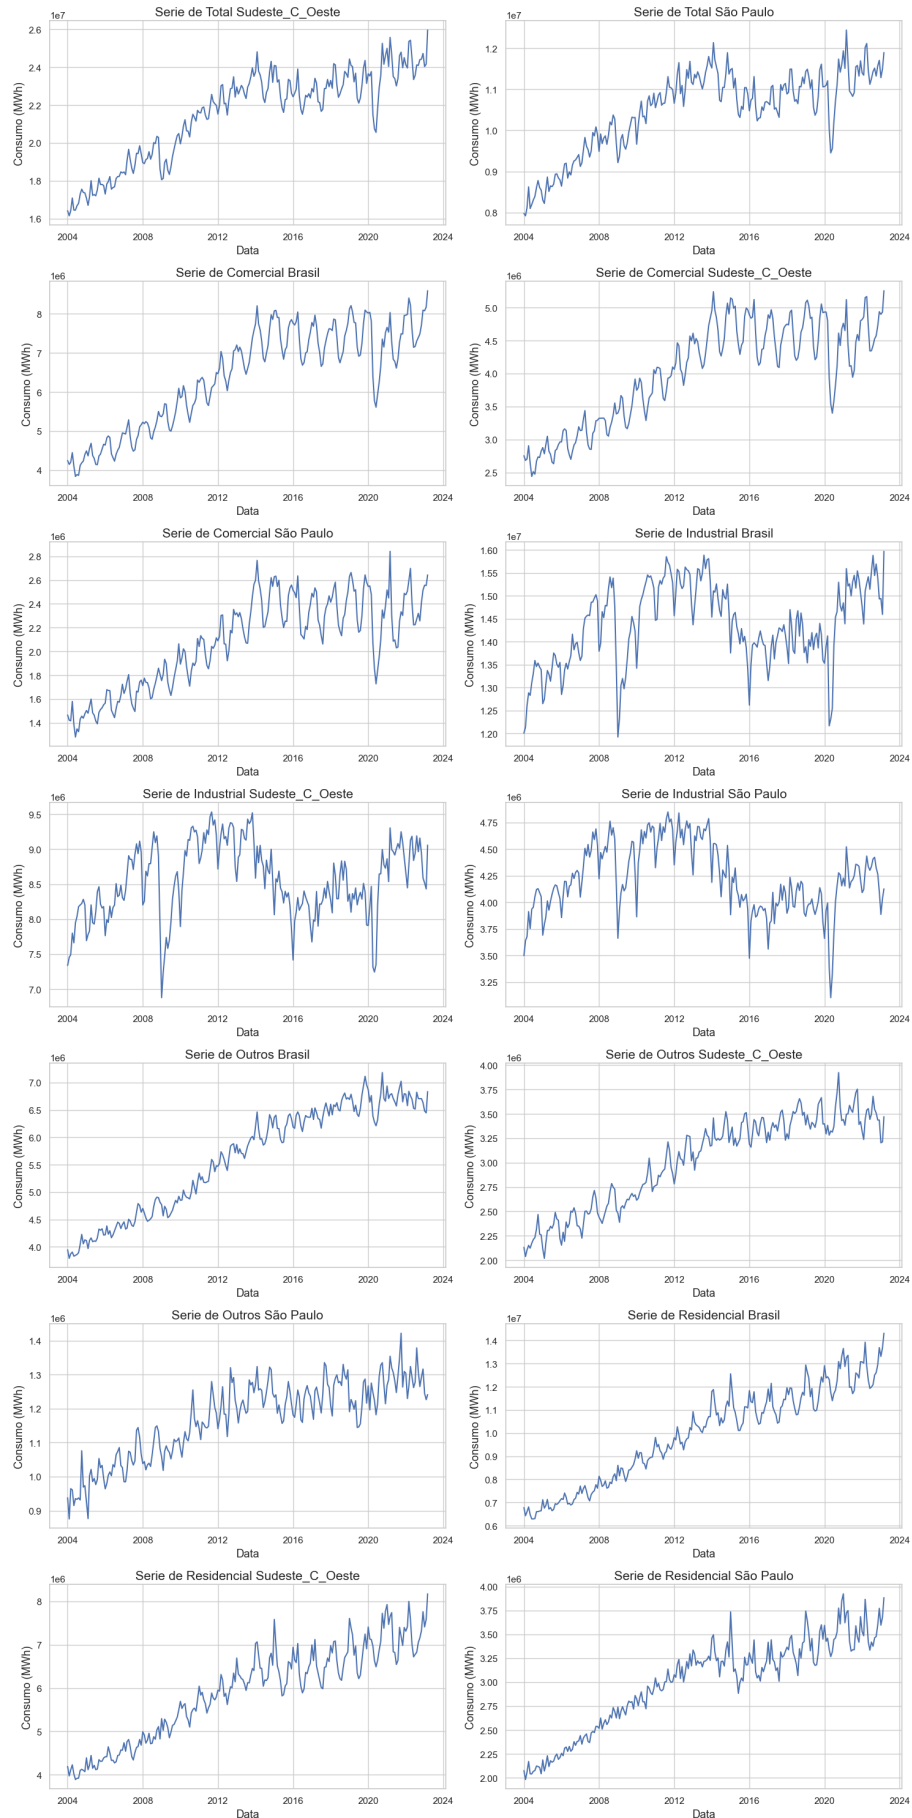
Figura 4 – Série histórica de consumo de energia do Brasil



Fonte: autor


Já a Figura 5 ilustra as séries das outras 14 granularidades que serão consideradas. Visualmente, as séries são semelhantes, ou seja, crescem e se comportam de maneira parecida com o Brasil como um todo, se diferenciando apenas as séries industriais, que apresentam um perfil de consumo diferente, não sendo de crescimento constante, e sim de variações mais bruscas e imprevisíveis.

Figura 5 – Série histórica de consumo de energia de todas granularidades



Fonte: autor

Figura 6 – Decomposição da série de consumo total Brasil



Fonte: autor


3.5 Decomposição de séries temporais

Quando aplicada a decomposição temporal nos dados aqui trabalhados, pode-se observar individualmente os elementos que compõem a série (tendência, nível, sazonalidade e erro) e analisar melhor os resultados de cada uma. Como pode ser feito na Figura 6, a decomposição do consumo de energia total do Brasil traz algumas informações relevantes. Primeiro, é possível observar no 2º gráfico a tendência de crescimento quase linear da série, ao passo que na componente de sazonalidade, fica muito claro o ciclo sazonal de 12 meses de consumo, que se repete sem mudanças significativas nas últimas décadas. Importante destacar que essa sazonalidade está livre dos outros elementos, ou seja, não tem o crescimento ou variações, e por isso se comporta de forma tão constante no tempo. Já no último gráfico têm-se os resíduos ou variações, que mostra pontos que fogem da normalidade. Na série observam-se alguns poucos pontos que destoam, mas em sua maioria, próximos do eixo 0, ou seja, uma série com poucos resíduos.

Com essas informações é possível obter algumas impressões acerca dos dados a serem tratados. Do consumo do Brasil, conclui-se que é uma série com tendência de crescimento quase constante, com sazonalidade de 12 meses, e sem grandes variações. Essas conclusões auxiliam na definição do melhor modelo, e como tratar e abordar os dados a serem modelados.

Para a decomposição das outras granularidades, a Figura 7 representa as séries de consumo total para o subsistema Sudeste/Centro Oeste e o Estado de São Paulo. A Figura 8 para o setor comercial, a Figura 9 para o residencial, a Figura 10 para o setor outros e finalmente a Figura 11 mostra as séries decompostas no setor industrial. É possível observar que todos os setores têm comportamentos semelhantes em seus elementos, exceto o setor industrial que, como observado anteriormente, não tem uma tendência clara de crescimento, embora mantenha a sazonalidade de 12 meses como a de outros níveis de dados.

Figura 7 – Decomposições das séries de consumo total Sudeste e SP



Fonte: autor


3.6 Limpeza de *baseline*

A limpeza dos dados a serem tratados, o seu *baseline*, garante que o modelo receba apenas dados que deseja-se que ele aprenda, caso os dados de entrada contenham padrões errôneos ou comportamentos esporádicos, esses podem ser replicados pelo modelo em projeções futuras, logo eles precisam ser tratados ou retirados dos seus dados. Esse processo deve ser feito com cautela, para que os dados sejam limpos de maneira a corrigir os padrões, uma correção errada pode resultar em resultados piores do que os dados sem nenhum tipo de tratamento.

Na Figura 12 observa-se o padrão de consumo no Brasil, e destaca-se uma queda nos primeiros meses de 2020, que foi resultado da pandemia de COVID-19 como analisado por Maciel e Carvalho (2023), que reduziu o consumo nesse período em quase 10% devido as medidas de contenções impostas pelo governo. Como essas medidas foram pontuais e não devem se repetir, esses dados precisam ser tratados e retirados da série para não afetar o resultado do modelo.


Para tal, pode-se aplicar a estes meses, uma normalização utilizando o consumo de meses anteriores dos anos passados, assim os dados deste meses serão normalizados com bases em consumos passados, feito isso os dados tendem a ser mais representativos

Figura 8 – Decomposições das séries de nível comercial




Fonte: autor

Figura 9 – Decomposições das séries de nível residencial




Fonte: autor

Figura 10 – Decomposições da séries de nível outros




Fonte: autor

Figura 11 – Decomposições da séries de nível industrial



Fonte: autor


Figura 12 – Período de queda no consumo de energia causado pela pandemia



Fonte: autor

de anos posteriores, já que as medidas de contenção tendem a não se repetir no futuro, não se desejando, então, que o modelo replique este comportamento. Esta limpeza feita, o resultado é ilustrado na Figura 13, onde nota-se os dados destacados alterados. Quando essas séries temporais são aplicadas a um modelo de teste, experimenta-se um MAPE de 1,12%, comparado com o MAPE da base sem tratamento de 1,17%. Assim, verifica-se uma redução do erro de 0,05%, validando que esse queda no consumo estava afetando negativamente os dados preditivos do modelo, e que a limpeza melhora a acurácia do modelo.

Figura 13 – Dados da queda no consumo normalizados



Fonte: autor

Uma limpeza de *baseline* pode ser muito positiva aos resultados, trazendo um modelo mais aderente aos dados reais futuros de uma série. Não obstante, realizar essa sanitização de padrões que não refletem o comportamento padrão do consumo é trabalhoso e demanda tempo e conhecimento para que sejam detectados e apontado o motivo daqueles padrões serem desconexos do real. Uma queda no consumo, pode tanto ser um acontecimento pontual, como abordado acima, quanto ser um padrão de consumo que se repetirá, logo, que seu modelo deve aprender e replicar. Por conseguinte, não se pode remover padrões de uma série sem a certeza que a ação será benéfica ao modelo e que esta ação seja aderente à realidade.

Embora o resultado da limpeza realizada acima tenha sido levemente positiva, ela não será tratada no decorrer deste trabalho, dado que o ganho foi consideravelmente pequeno e que a série tem uma base grande de tempo. Esse ajuste pontual foi apenas um de muitos que deveriam ser realizados, e apenas foi o mais claro e simples de se realizar, feito como um exemplo desta etapa do processo de planejamento. O ganho pela limpeza não afetará no desenvolvimento da ferramenta, visto que o objetivo geral é uma ferramenta comparativa, e o ganho afetaria todos modelos por igual. Fica aqui noticiado, portanto, que a limpeza do *baseline* como uma ferramenta pode, e muitas vezes deve, ser realizada na série a ser trabalhada. Mas, ainda assim, trata-se de uma etapa opcional, que deve ser levado em consideração o trabalho e tempo despendido para realiza-lá versus o ganho potencial obtido.

3.7 Agrupamento da série histórica de dados

Os modelos preditivos, funcionam com formatos de dados específicos, e os modelos em Python lidam com esses dados no formato de séries temporais, *timestamps*, com uma coluna de informação temporal, no caso do estudo, um dado de mês/ano e o valor de consumo de energia em megawatt-hora (MWh) correspondente aquele mês. O dado

também precisa de uma coluna de granularidade tratada, para a diferenciação de cada série abordada neste estudo. Tratou-se os dados em Python, obtendo-se os dados com as colunas e formatos como apresentados na Figura 14, que mostra o formato destes dados que servirão de entrada.

Figura 14 – Dados tratados no Python

	Data padrao	Granularidade	Valor
0	2004-01-01	Total Brasil	2.697836e+07
1	2004-02-01	Total Brasil	2.650817e+07
2	2004-03-01	Total Brasil	2.728433e+07
3	2004-04-01	Total Brasil	2.804618e+07
4	2004-05-01	Total Brasil	2.724451e+07
...
3460	2022-11-01	Residencial São Paulo	3.599979e+06
3461	2022-12-01	Residencial São Paulo	3.773234e+06
3462	2023-01-01	Residencial São Paulo	3.597226e+06
3463	2023-02-01	Residencial São Paulo	3.681364e+06
3464	2023-03-01	Residencial São Paulo	3.885348e+06

Fonte: autor

Os dados são divididos em 3 colunas, de “Data padrao”, que representa a quebra temporal em que aquele dado está inserido, a “Granularidade”, que representa o nível de quebra dos dados e o “Valor”, que é o consumo relacionado aquela data e granularidade em MWh.

3.8 Períodos de treinamento e teste


Quando um modelo de previsão é criado, existem dois períodos importantes de dados a serem adicionados a ele, quais sejam, o período de treinamento e de teste (HYNDMAN; ATHANASOPOULOS, 2014). Os dados de treinamento são aqueles que irão ensinar ao modelo os padrões a serem identificados. Logo, são com esses dados que o modelo tentará identificar o comportamento e prever os dados futuros. São esses dados abordados até agora, que sofreram todos ajustes, limpezas e definições de parâmetros. Na grande maioria dos processos de planejamentos eles são todos os dados históricos disponíveis para aquela granularidade, dado que se quer prever algo a frente dos dados disponíveis até aquele momento.

Por outro lado, tem-se os dados de teste. No processo de criação e validação do modelo, se reserva o último ciclo dos dados, com um horizonte de tempo igual ao definido para previsão. Neste caso, como se quer prever 12 meses a frente, foram reservados os 12

últimos meses para a validação e análise dos resultados do modelo. Depois de validados, esses dados são destinados a um novo treinamento do modelo, visto que dados mais recentes sempre auxiliam na previsão futura.

A Figura 15 mostra a divisão destes dados, aplicados na série temporal de consumo total do Brasil. A linha azul representa dados que serão aplicados no treinamento do modelo, enquanto a linha laranja indica os dados de consumo que serão reservados ao teste. Logicamente, os resultados dos modelos preditivos, não tem como entrada os dados de teste, assim eles se tornam isentos desses valores e os resultados obtidos podem ser validados sem viés de confirmação.

Figura 15 – Granularidade dos dados da EPE




Fonte: Autor

Outra definição importante a ser feita, é o tempo de treinamento, visto que os dados de entrada do modelo são responsáveis pela acurácia dos resultados. Logo, a definição acertada de um período de tempo adequado garante a validação ou o descarte de um modelo. Como abordado anteriormente, normalmente se utiliza toda a série histórica disponível, mas nem sempre o uso de todos os seus dados é benéfico. No caso dos dados da EPE, existem registros de consumo desde 2004, sendo que dados mais antigos podem não representar mais, fidedignamente, os padrões do consumo atual.

Para a validação dos dados de treinamento foi realizado um teste variando de mês em mês o período de treinamento (janela) de um modelo genérico de teste, onde cada número de meses de treinamento resulta em um modelo diferente. O número mínimo de dados de entrada, normalmente requeridos pelos modelos é de 2 períodos de ciclo completos, ou seja, 24 meses, então este é o período mínimo para o teste. Para cada um dos modelos calcula-se o valor do erro de previsão percentual absoluto (MAPE) onde observa-se na

Figura 16 os resultados deste teste. Nesta figura, o número de meses de treinamento é representado no eixo horizontal, e o MAPE é disposto como resultado no eixo vertical.

Figura 16 – Teste realizado variando o período de treinamento (janela) em função do MAPE



Fonte: autor

Observa-se na Figura 16 uma tendência de queda inicial do erro, começando em torno de 3 a 4% e reduzindo a valores próximos de 1% em torno de 100 meses de teste, o que corrobora a ideia de que mais dados de treinamento ajudam o modelo a identificar padrões. No entanto, a partir de mais de 150 meses de treinamento observa-se uma tendência de crescimento do erro, corroborando com o fato de que o aumento exacerbado de dados a partir desses pontos pioram os resultados do modelo. Logo, tem-se um forte indicativo que os dados mais antigos, realmente, não refletem os padrões de consumo atuais.

Com base nessas informações, e buscando a melhor acurácia possível é definido o período de teste para os modelos de 12 meses, e o período de treinamento como sendo de 10 anos, ou 120 meses. Destaca-se que o teste foi realizado apenas para a série de consumo total do Brasil, mas devido a correlação entre as séries, a tendência é que este comportamento se repita para todas as outras, e sequenciando a ideia de criar uma ferramenta única e robusta, replicar este método para cada uma das granularidades segmentaria muito a ferramenta, tornando-a muito específica e destoando-a dos objetivos deste trabalho. Portanto, os períodos supra postos serão considerados como padrão para todos os modelos.

3.9 Comparação entre métodos de previsão

Os resultados projetados por cada modelo precisam de alguma forma serem comparados, para que com análises objetivas e matemáticas, seja escolhido o melhor

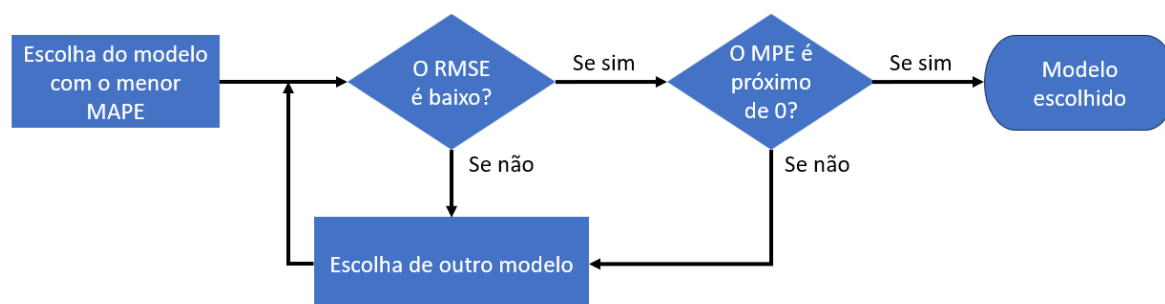
modelo. A escolha do melhor modelo não se baseia apenas e puramente naquele que retorna os dados mais próximos da realidade. Torna-se necessário analisar algumas métricas, discutidas no Capítulo 2, e aqui aplicá-las para avaliar não só os resultados, mas também estimar a saúde do modelo preditivo. Para a comparação entre os modelos utilizados, e a definição do melhor, serão utilizadas quatro métricas principais, já abordadas no Capítulo 2, resumidamente dispostas na sequência:

- MAPE: métrica mais utilizada para modelos preditivos, sendo o seu resultado um percentual de erro dos dados previstos e do real, com interpretação bastante simples.
- RMSE: métrica muito utilizada em campeonatos de previsão, elevando os dados ao quadrado e assim impedindo que os erros positivos e negativos se cancelem.
- MPE: por ser um erro não absoluto ajuda identificar viés no modelo preditivo.
- AIC: o critério de Akaike mensura tanto a precisão quanto a simplicidade do modelo.

O MAPE será o principal critério de comparação entre os modelos. Logo, modelos que apresentarem erros menores serão favorecidos em detrimento de outros, sendo que o RMSE servirá como suporte ao MAPE, de modo a garantir que não existam dados se cancelando e diminuindo o erro. Portanto, o RMSE servirá como uma confirmação dos valores do MAPE, de modo que um modelo que tenha um MAPE muito bom mas um RMSE ruim, será descartado. Por outro lado, o MPE servirá como validação da saúde do modelo, ajudando na identificação de vieses no processo de previsão. Dessa maneira, caso um modelo apresente MPE muito longe de zero, também será descartado. Por fim, o AIC será utilizado para comparação entre mesmos modelos, mas com parâmetros diferentes. Por exemplo, uma comparação de vários modelos de regressão, mas cada um com métricas diferentes.

A Figura 17 mostra em um formato de fluxograma, como se comporta o processo da definição dos melhores modelos. Torna-se importante destacar, que para o dado ser considerado “alto” ou “baixo”, depende de sua comparação dentro do ambiente de resultados de outros modelos.

Figura 17 – Fluxograma do processo de definição do melhor modelo



Fonte: autor

4 RESULTADOS DO MODELO

Este capítulo tem por objetivo, discutir e analisar os resultados dos modelos preditivos utilizados. Com os resultados, faz-se um comparativo entre os modelos, discutindo mais a fundo o que apresentou a maior acurácia. Por fim, o melhor modelo é utilizado para um estudo de caso final de previsão real dos dados de consumo.


4.1 Resultados dos modelos clássicos

4.1.1 Resultados do modelo *dummy*

O modelo *dummy*, ou método ingênuo é um modelo de média móvel simples (SMA), onde assume-se que os dados futuros serão iguais a média dos meses anteriores, ou seja, esse valor irá se repetir para o futuro. Ele normalmente não é um método de previsão que gera resultados precisos, principalmente em séries mais complexas, mas serve como um ponto de partida, uma base comparativa para os outros modelos. Dado que ele não leva em conta nenhuma complexidade dos dados, tendência, sazonalidade e nível, os valores obtidos não tem valor prático, ele apenas é utilizado para entender o desempenho mínimo esperado em outras previsões.

Na Figura 18, apresenta-se os resultados obtidos para a série de consumo de energia total no Brasil, onde são utilizados 120 meses de treinamento e 12 meses de teste, como definido no Capítulo 3. A linha pontilhada representa os dados de consumo previstos pelo modelo, enquanto a linha contínua laranja indica os dados reais de teste e a linha azul, os dados de treinamento. Nota-se como resultado uma previsão completamente linear, a média de meses passados, e distante do real. Com este modelo, obteve-se um MAPE de quase 5% nessa granularidade.

Figura 18 – Previsão ingênuo do consumo total Brasil

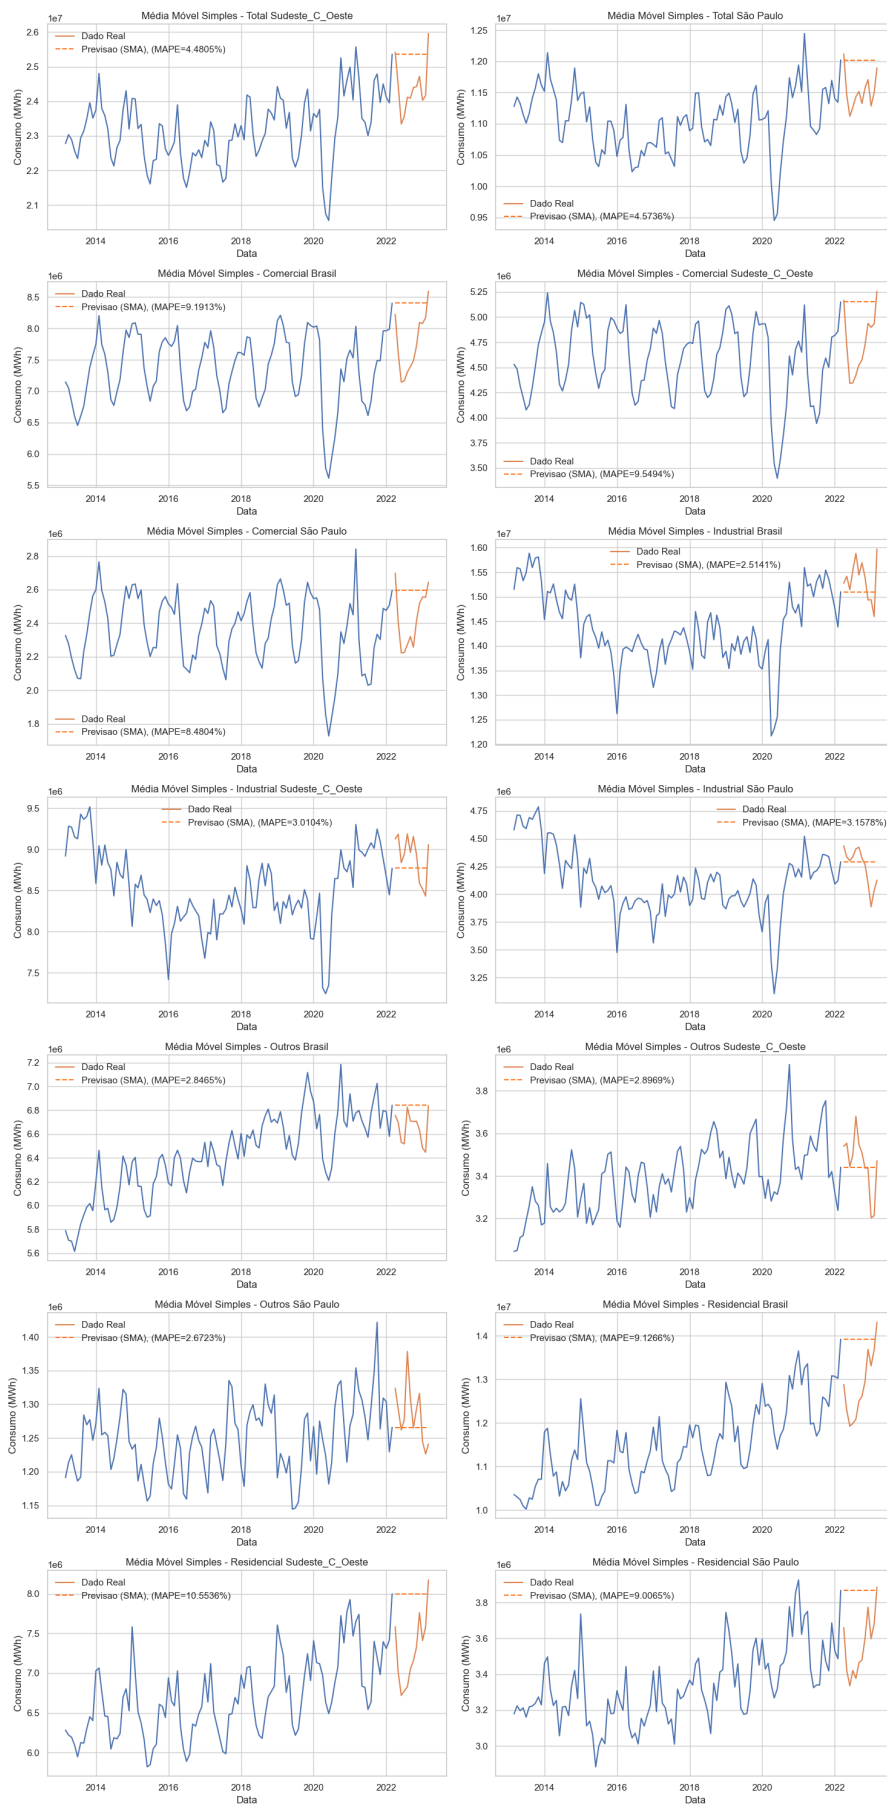


Fonte: autor

Os resultados para todas as outras 14 séries estão representados na Figura 19, onde nota-se que todos os resultados apresentam resultados distantes do real, mostrando que usar de forma simplória o consumo de meses anteriores não representa bem o consumo futuro, como esperado. A Figura 20 mostra todos os resultados dos MAPEs, onde observa-se que todas as séries geram erros percentuais em torno de 5 a 10%, o que era esperado dado a simplicidade do método preditivo.

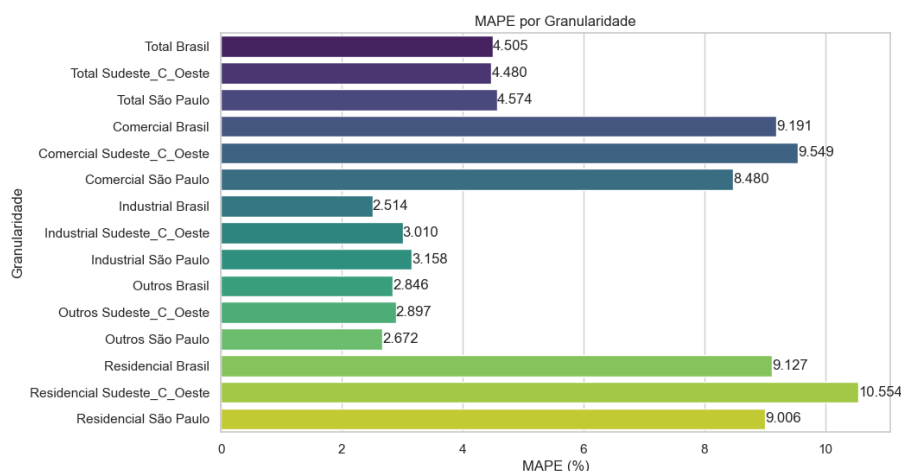
Por fim a Figura 21 compila as métricas de erros que são resultados do modelo e que serão utilizada como base de comparação para os modelos futuros deste trabalho, sendo o MAPE, MPE e RMSE de cada uma das granularidades.

Figura 19 – Resultados do modelo dummy para todas as séries



Fonte: autor

Figura 20 – MAPE dos dados obtidos pelo modelo ingênuo



Fonte: autor

Figura 21 – Métricas de erros do modelo *dummy*

Granularidade	MAPE_SMA	MPE_SMA	RMSE_SMA
Total Brasil	4.5	-4	2e+06
Total Sudeste_C_Oeste	4.5	-4.1	1.2e+06
Total São Paulo	4.6	-4.4	5.7e+05
Comercial Brasil	9.2	-8.8	8e+05
Comercial Sudeste_C_Oeste	9.5	-9.2	5.1e+05
Comercial São Paulo	8.5	-7.5	2.3e+05
Industrial Brasil	2.5	1.6	4.6e+05
Industrial Sudeste_C_Oeste	3	1.5	2.9e+05
Industrial São Paulo	3.2	-1.2	1.7e+05
Outros Brasil	2.8	-2.8	2.3e+05
Outros Sudeste_C_Oeste	2.9	0.44	1.3e+05
Outros São Paulo	2.7	1.4	4.5e+04
Residencial Brasil	9.1	-8.7	1.3e+06
Residencial Sudeste_C_Oeste	11	-10	8.3e+05
Residencial São Paulo	9	-8.9	3.5e+05

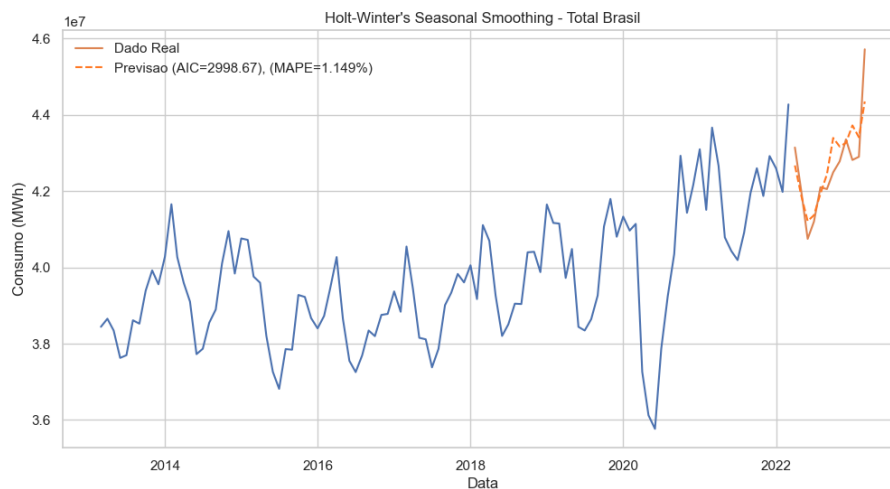
Fonte: autor

4.1.2 Resultados do modelo Holt-Winters

O modelo de Holt-Winter considera sazonalidade, nível e tendência da série na decomposição dos fatores, e posteriormente, na previsão. Então eles precisam ser considerados como aditivos ao modelo utilizando a função *ExponentialSmoothing* no Python. A Figura 22 apresenta os valores futuros reais e previstos pelo modelo para o consumo total Brasil, onde diferentemente do modelo *dummy*, os dados já se comportam muito mais próximos dos dados reais de consumo, refletindo em um MAPE muito menor, de 1,15%.

A Figura 23, mostra os resultados de previsão do modelo Holt-Winters em todas as granularidades, e a Figura 24 ilustra o MAPE comparativo por granularidade, em

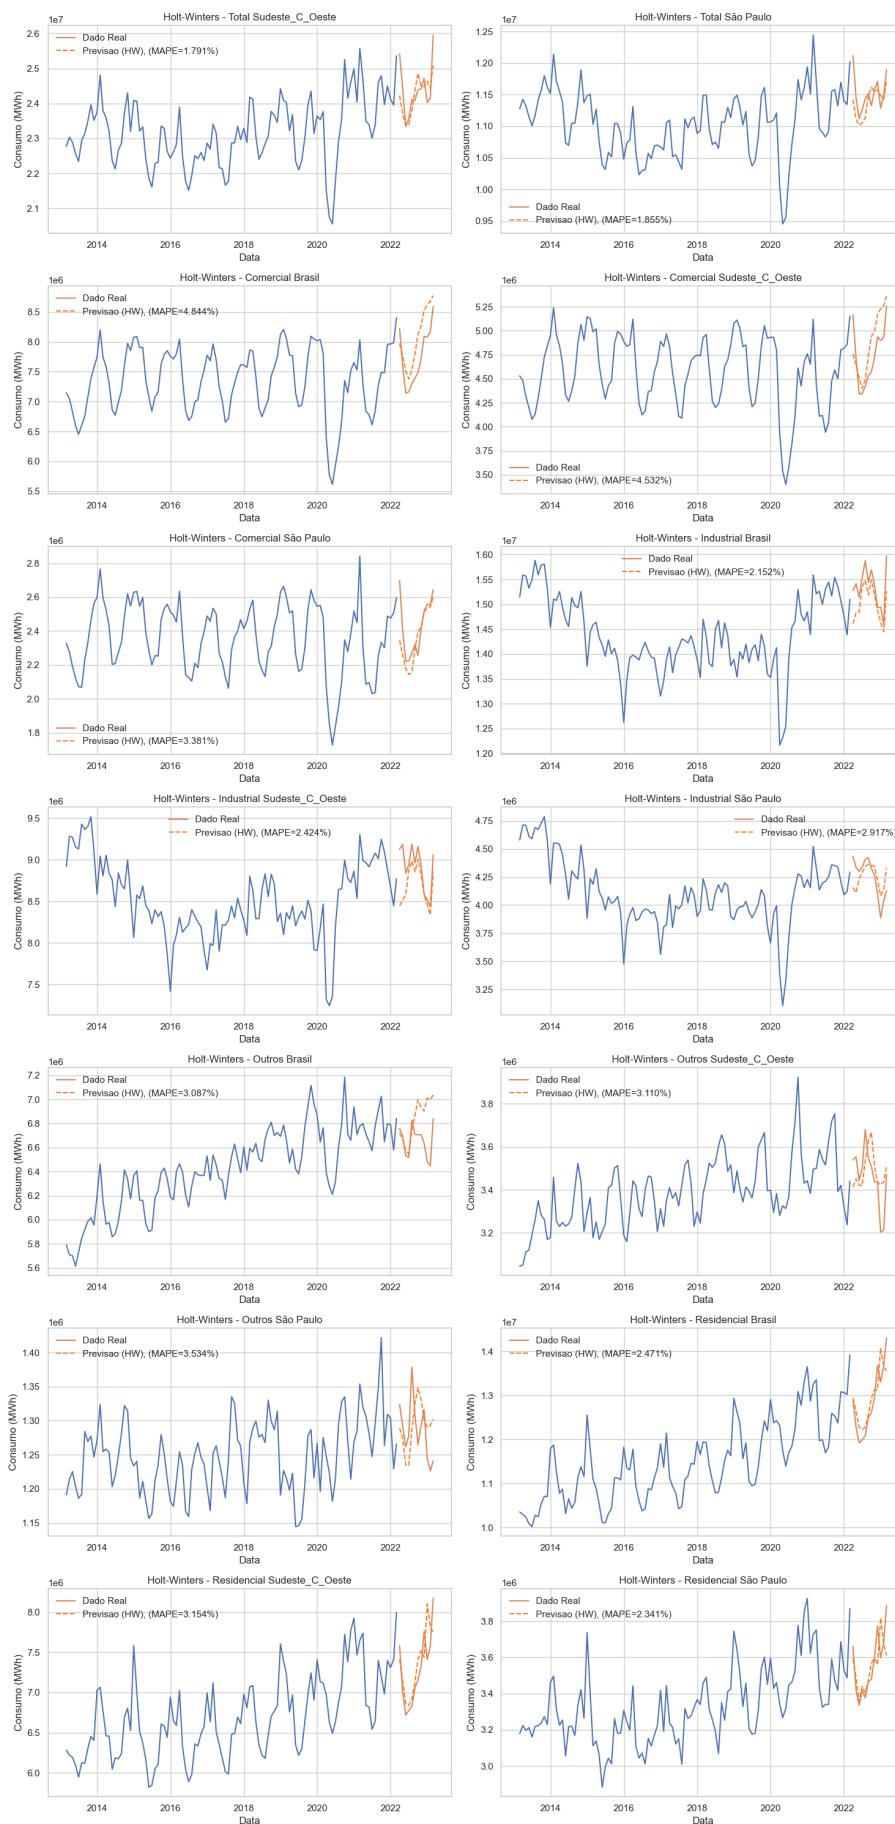
Figura 22 – Previsão Holt-Winters do consumo total Brasil



Fonte: autor

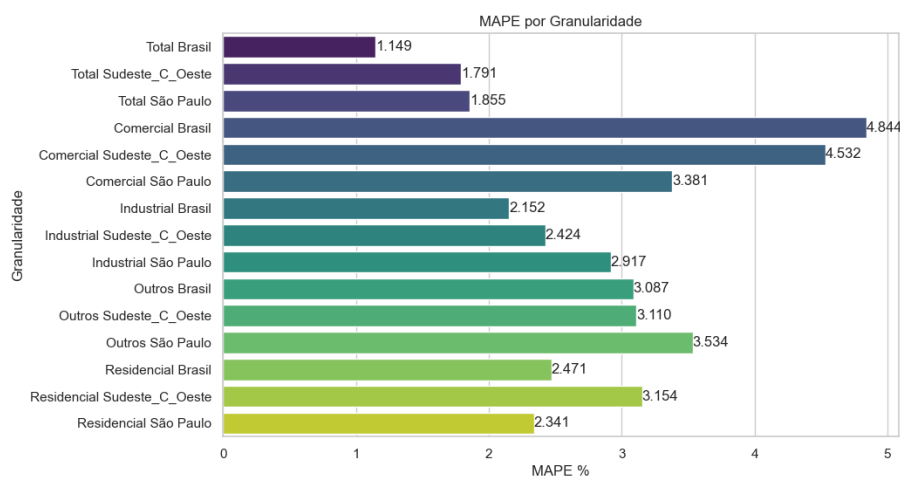
que o comportamento observado na série total Brasil, se repete, com dados de consumo previstos com comportamento muito próximo do real e métricas de erro muito melhores que o modelo ingênuo. Destaca-se aqui a quebra de dados comerciais, que apresentaram o maior erro de previsão.

Figura 23 – Resultados do modelo Holt-Winters para todas as séries



Fonte: autor

Figura 24 – MAPE dos dados obtidos pelo modelo Holt-Winters



Fonte: autor

Finalmente, na Figura 25 apresenta-se as métricas de previsões completas do modelo. Este sendo um modelo regressivo, já apresenta o critério de informação de Aikake (AIC) para monitoramento da saúde e desempenho do modelo.

Figura 25 – Métricas de erro do modelo Holt-Winters

Granularidade	MAPE_HW	MPE_HW	RMSE_HW	AIC_HW
Total Brasil	1.1	-0.32	6.2e+05	3e+03
Total Sudeste_C_Oeste	1.8	0.59	5.6e+05	2.9e+03
Total São Paulo	1.9	1.1	2.8e+05	2.8e+03
Comercial Brasil	4.8	-4.3	4.1e+05	2.7e+03
Comercial Sudeste_C_Oeste	4.5	-3	2.5e+05	2.7e+03
Comercial São Paulo	3.4	2.3	1.3e+05	2.6e+03
Industrial Brasil	2.2	2.2	3.9e+05	2.8e+03
Industrial Sudeste_C_Oeste	2.4	2.4	3.1e+05	2.7e+03
Industrial São Paulo	2.9	-0.083	1.5e+05	2.6e+03
Outros Brasil	3.1	-2.7	2.7e+05	2.6e+03
Outros Sudeste_C_Oeste	3.1	-0.88	1.3e+05	2.5e+03
Outros São Paulo	3.5	-0.63	5.2e+04	2.3e+03
Residencial Brasil	2.5	-0.89	4.1e+05	2.8e+03
Residencial Sudeste_C_Oeste	3.2	-1.2	2.9e+05	2.7e+03
Residencial São Paulo	2.3	0.16	1.3e+05	2.6e+03

Fonte: autor

4.2 Resultado dos modelos avançados


4.2.1 Resultados do modelo SARIMA

O SARIMA que gera os melhores resultados para a série depende dos parâmetros específicos do modelo, como abordados no capítulo de aprofundamento teórico, são os 3

elementos de tendência (p , d , q) e os 4 de sazonalidade (P , D , Q , m). Esses valores podem ser simulados dentro de um *range* definido e testados um a um, até a definição do melhor modelo baseado no AIC. A função *autoarima* realiza esse teste no Python, apontando para o modelo mais preciso.

A Figura 26 mostra os resultados preditivos de 12 meses para a série do consumo total do Brasil. Embora o SARIMA seja um modelo de autorregressão, diferente do modelo de decomposição de Holt-Winters, observa-se um bom resultado dos dados futuros gerados pelo modelo, que se aproxima dos dados reais, assim como o modelo de decomposição, com comportamento similar e erro baixo. Logo, este modelo retorna os resultados mais baixos até agora para esta série, com um MAPE de apenas 0,93%.

Figura 26 – Previsão SARIMA do consumo total Brasil



Fonte: autor

Os resultados preditivos do SARIMA para as outras séries tratadas, podem ser observados na Figura 27. Em todos os casos, verifica-se bons resultados do modelo, sendo o destaque para a série "Comercial São Paulo", que como pode ser observado na Figura 28, que consolida o MAPE de todos os conjuntos de dados, é a única que ultrapassa a marca de 5%, chegando a quase 10%.

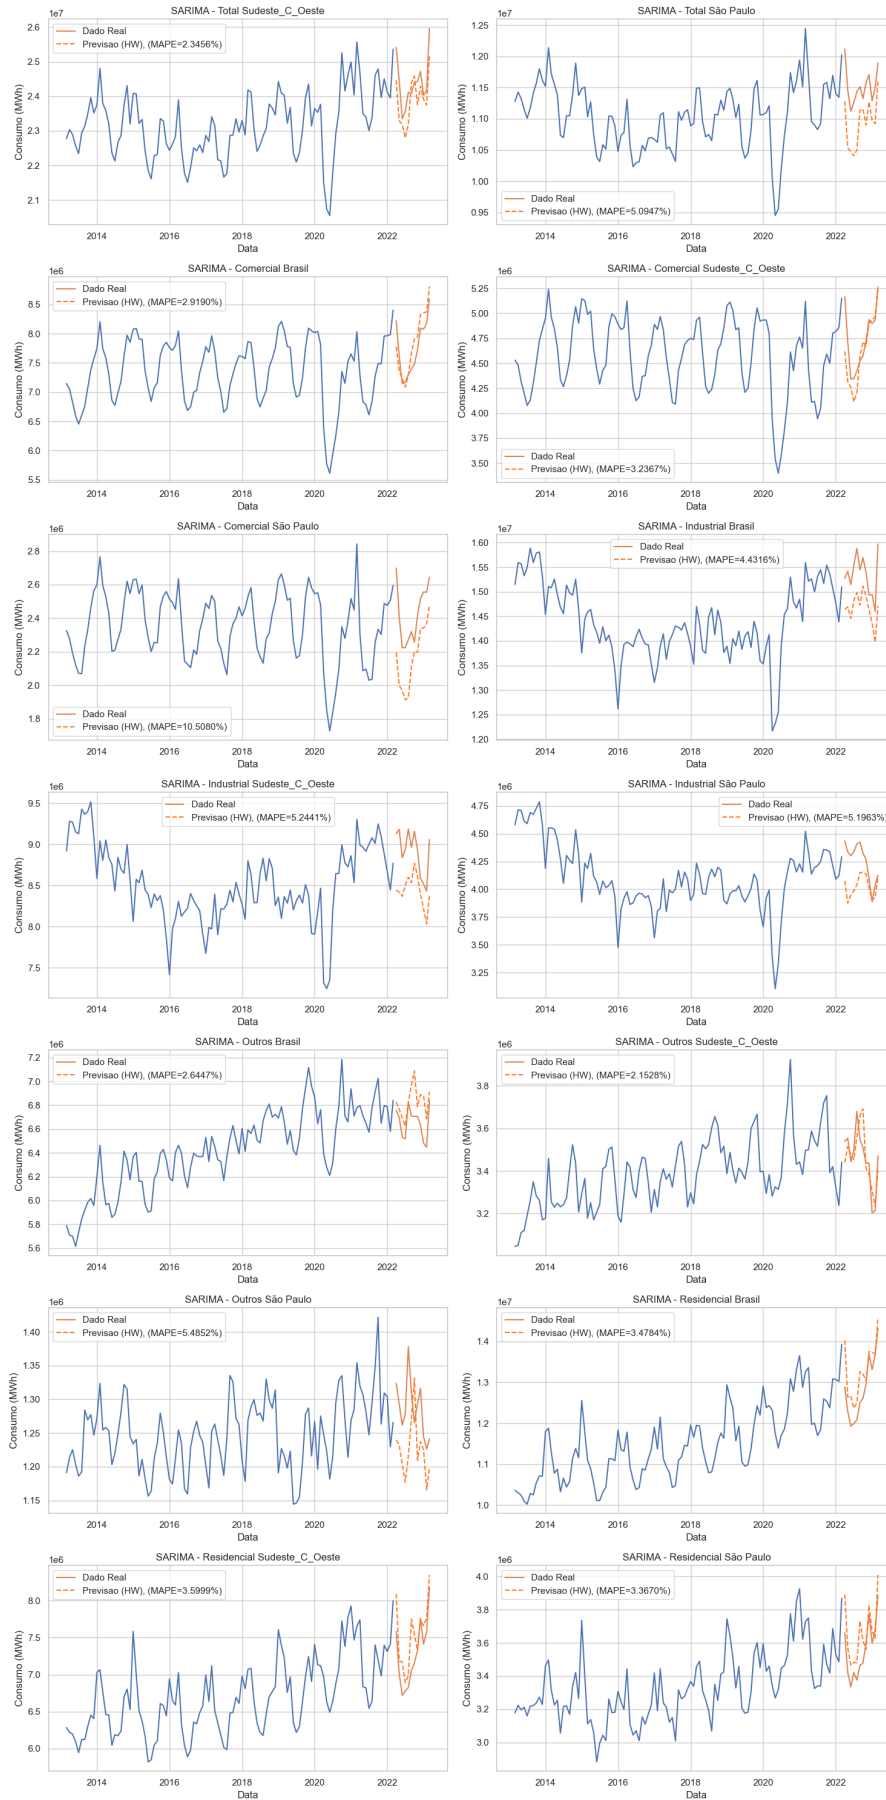
A Tabela 2 mostra quais foram os elementos que geraram os melhores resultados para cada uma das granularidades. Vale notar o valor de m é 12 para todos os modelos, já que o ciclo de consumo, como abordado anteriormente, é de 12 meses (1 ano). Nota-se também os mesmos padrões para os elementos de tendência, ou seja, todas as séries tem tendências similares.

A Figura 29, por fim, consolida todas as métricas para análises e comparação posterior do modelo SARIMA.

4.2.2 Resultados do modelo SARIMAX com variável exógena do PIB

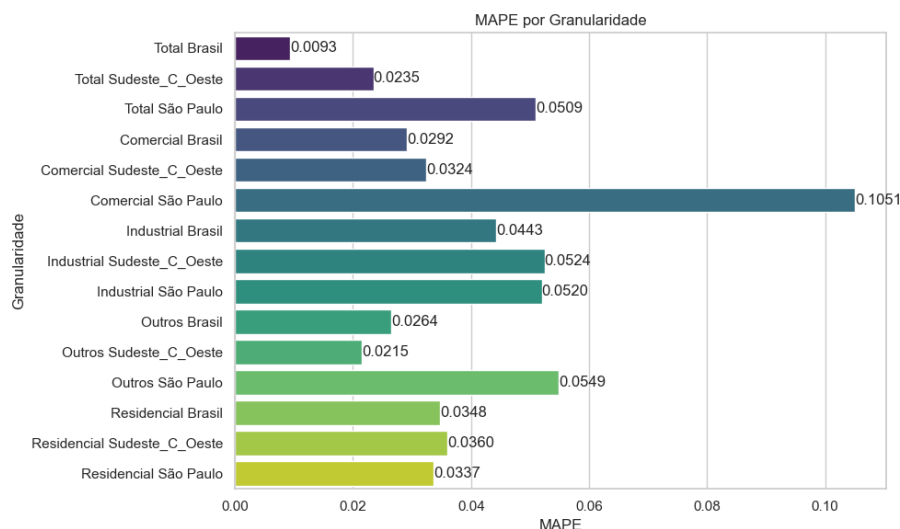
O modelo do SARIMAX tem os mesmos parâmetros e cálculos do SARIMA, com a inclusão do X (*exogenous*), que considera a correlação de variáveis exógenas ao dado a ser

Figura 27 – Resultados do modelo SARIMA para todas as séries



Fonte: autor

Figura 28 – MAPE dos dados obtidos pelo modelo SARIMA



Fonte: autor

Tabela 2 – Tabela resumo com os elementos de tendência e sazonalidade dos modelos SARIMA

Granularidade	Elementos do modelo
Total Brasil	$(0,1,0), (4,1,0)$ [12]
Total Sudeste e Centro Oeste	$(0,1,0), (0,1,0)$ [12]
Total São Paulo	$(0,1,0), (0,1,0)$ [12]
Comercial Brasil	$(0,1,0), (1,1,1)$ [12]
Comercial Sudeste e Centro Oeste	$(0,1,0), (1,1,1)$ [12]
Comercial São Paulo	$(0,1,0), (1,1,1)$ [12]
Industrial Brasil	$(0,1,0), (0,1,1)$ [12]
Industrial Sudeste e Centro Oeste	$(0,1,0), (0,1,1)$ [12]
Industrial São Paulo	$(0,1,0), (0,1,2)$ [12]
Outros Brasil	$(0,1,0), (0,1,1)$ [12]
Outros Sudeste e Centro Oeste	$(0,1,0), (2,1,1)$ [12]
Outros São Paulo	$(0,1,0), (0,1,2)$ [12]
Residencial Brasil	$(0,1,0), (4,1,1)$ [12]
Residencial Sudeste e Centro Oeste	$(0,1,0), (0,1,0)$ [12]
Residencial São Paulo	$(0,1,0), (0,1,0)$ [12]

Fonte: autor

tratado. Quando se insere os dados de PIB ao modelo, ele o correlaciona com o consumo de energia total do Brasil, procurando padrões onde as variações e comportamentos do PIB possam explicar as variações do consumo. É possível calcular sua contribuição no resultado com o uso do FVA (*forecast added value*), o valor adicionado a previsão. Não necessariamente esta adição é positiva, sendo que algumas variáveis exógenas não explicam o comportamento da série e não geram contribuições na previsão do modelo.

A Figura 30 mostra o resultado do modelo SARIMAX com série do PIB aplicado


Figura 29 – Métricas de erro do modelo SARIMA

Granularidade	MAPE_HW	MPE_HW	RMSE_HW	AIC_HW
Total Brasil	1.1	-0.32	3.8e+11	3e+03
Total Sudeste_C_Oeste	1.8	0.59	3.1e+11	2.9e+03
Total São Paulo	1.9	1.1	7.7e+10	2.8e+03
Comercial Brasil	4.8	-4.3	1.6e+11	2.7e+03
Comercial Sudeste_C_Oeste	4.5	-3	6.2e+10	2.7e+03
Comercial São Paulo	3.4	2.3	1.6e+10	2.6e+03
Industrial Brasil	2.2	2.2	1.5e+11	2.8e+03
Industrial Sudeste_C_Oeste	2.4	2.4	9.4e+10	2.7e+03
Industrial São Paulo	2.9	-0.083	2.1e+10	2.6e+03
Outros Brasil	3.1	-2.7	7.2e+10	2.6e+03
Outros Sudeste_C_Oeste	3.1	-0.88	1.6e+10	2.5e+03
Outros São Paulo	3.5	-0.63	2.7e+09	2.3e+03
Residencial Brasil	2.5	-0.89	1.7e+11	2.8e+03
Residencial Sudeste_C_Oeste	3.2	-1.2	8.5e+10	2.7e+03
Residencial São Paulo	2.3	0.16	1.6e+10	2.6e+03

Fonte: autor

ao consumo do Brasil, em que é possível notar pouca diferença em relação ao modelo do SARIMA, significando que os dados do PIB pouco conseguiram explicar a evolução do consumo nesta granularidade, piorando o modelo, com um erro de 1,19%, comparado com o 0,93% do SARIMA.

Figura 30 – Previsão SARIMAX do consumo total Brasil



Fonte: autor

Os resultados da previsão realizada pelo SARIMAX para as outras séries tratadas, encontram-se na Figura 27, onde nota-se que assim como no modelo sem a inclusão de variáveis exógenas, a série comercial São Paulo apresenta os dados mais descolados do real. Os valores de MAPE obtidos para cada granularidade são destacados na Figura 32. Quando comparado os MAPEs dos modelos obtidos com o SARIMAX com os obtidos

através SARIMA, algumas das séries tiveram melhoras consideráveis, destacando-se as séries residências para todas as granularidades testadas, enquanto outras, como a séries de consumo em “outros”, tiveram resultados negativos com a inclusão.

As séries “Total Brasil”, “Outros Brasil” e “Outros Sudeste Centro Oeste” tiveram um FVA negativo, com a inclusão de uma variável externa, os seus dados de previsão pioraram, “Residencial Brasil”, “Residencial Sudeste Centro Oeste” e “Residencial São Paulo”, tiveram FVAs positivos, enquanto as outras não tiveram alterações em seus valores.

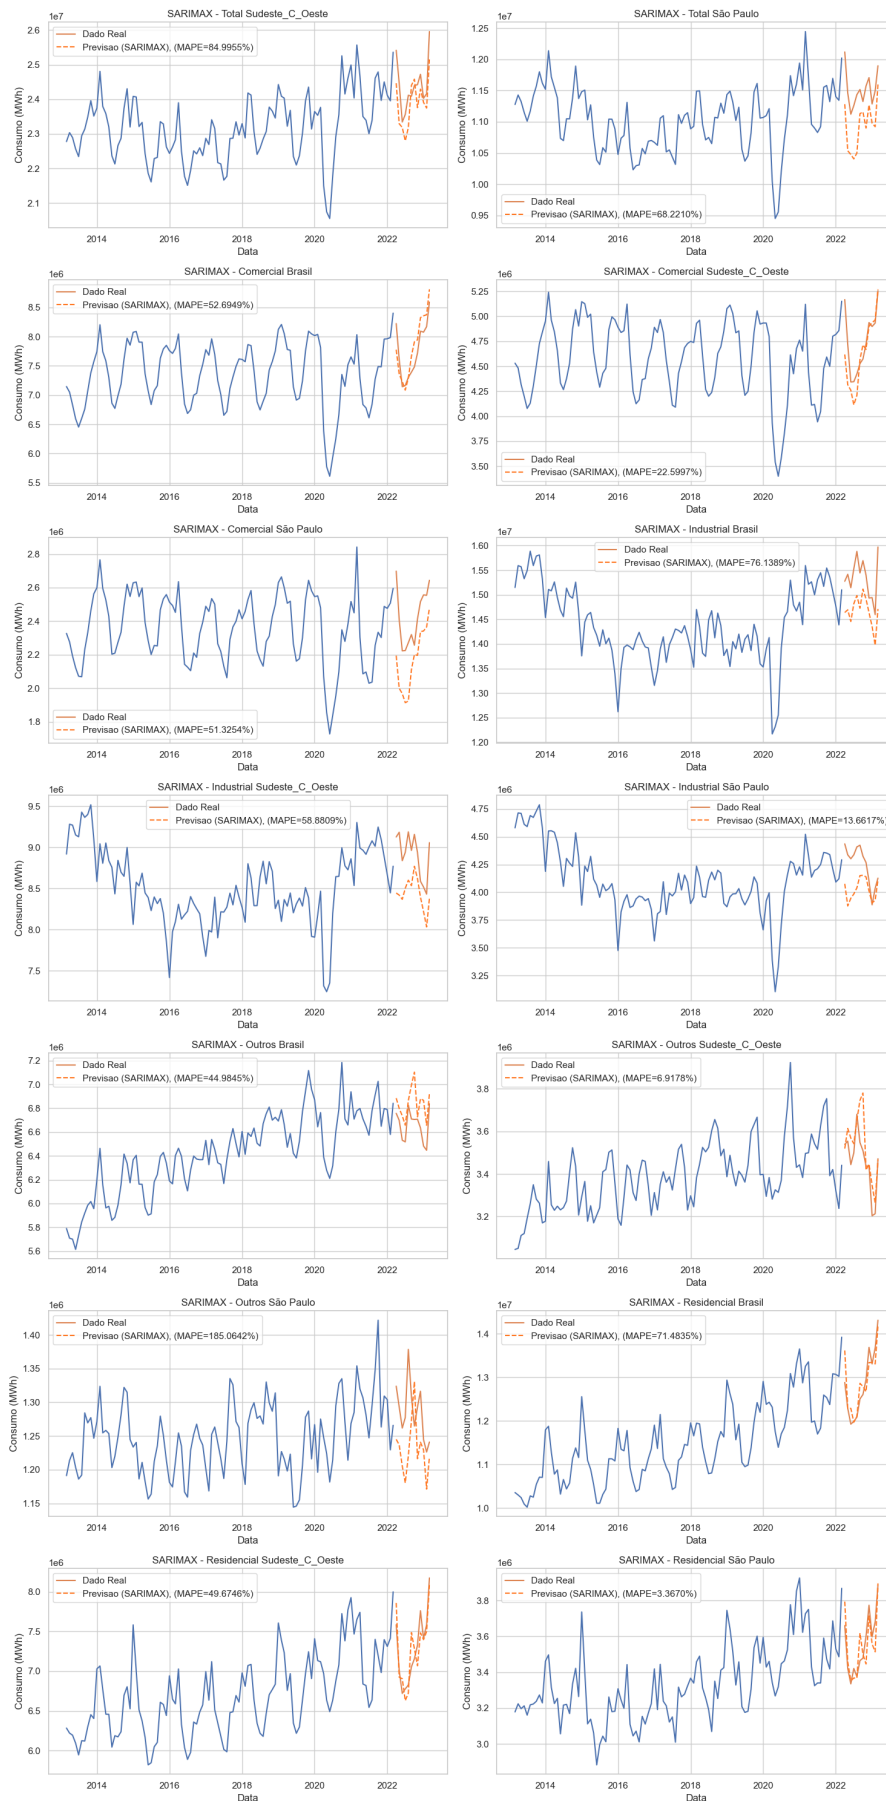
A Tabela 3 mostra os elementos que geraram os melhores resultados para cada uma das granularidades, que podem sofrer alterações para os modelos do SARIMA devido a inclusão da variável exógena. A Figura 33 consolida todas as métricas para análises e comparação posterior do modelo.

Tabela 3 – Tabela resumo com os elementos de tendência e sazonalidade dos modelos SARIMAX

Granularidade	Elementos do modelo
Total Brasil	(0,0,1),(0,1,0)[12]
Total Sudeste e Centro Oeste	(0,1,0),(0,1,0)[12]
Total São Paulo	(0,1,0),(0,1,0)[12]
Comercial Brasil	(0,1,0),(1,1,1)[12]
Comercial Sudeste e Centro Oeste	(0,1,0),(1,1,1)[12]
Comercial São Paulo	(0,1,0),(1,1,1)[12]
Industrial Brasil	(0,1,0),(0,1,1)[12]
Industrial Sudeste e Centro Oeste	(1,1,0),(0,1,2)[12]
Industrial São Paulo	(0,1,0),(0,1,1)[12]
Outros Brasil	(0,0,1),(0,1,1)[12]
Outros Sudeste e Centro Oeste	(0,0,1),(0,1,0)[12]
Outros São Paulo	(1,1,0),(2,1,2)[12]
Residencial Brasil	(1,0,1),(0,1,2)[12]
Residencial Sudeste e Centro Oeste	(0,0,1),(0,1,0)[12]
Residencial São Paulo	(0,0,1),(0,1,0)[12]

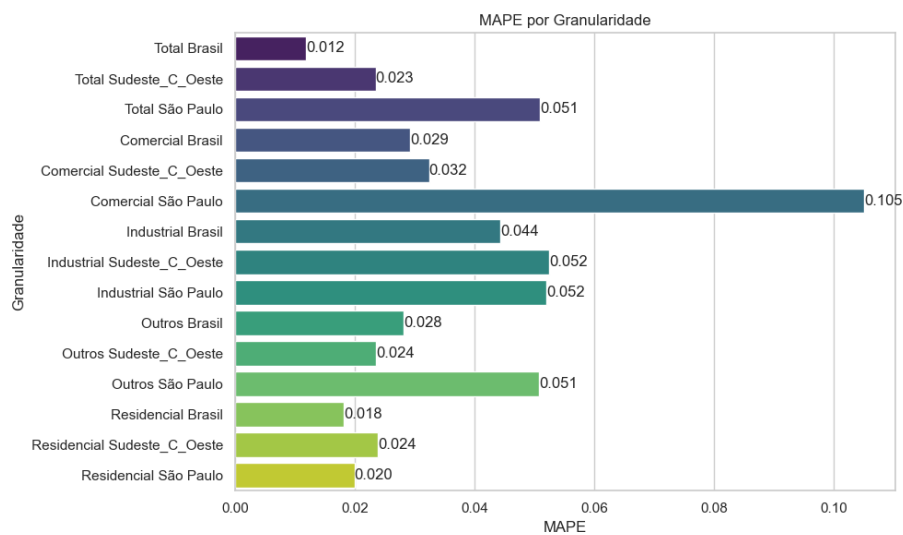
Fonte: autor

Figura 31 – Resultados do modelo SARIMAX para todas as séries



Fonte: autor

Figura 32 – MAPE dos dados obtidos pelo modelo SARIMAX



Fonte: autor

Figura 33 – Métricas de erro do modelo SARIMAX

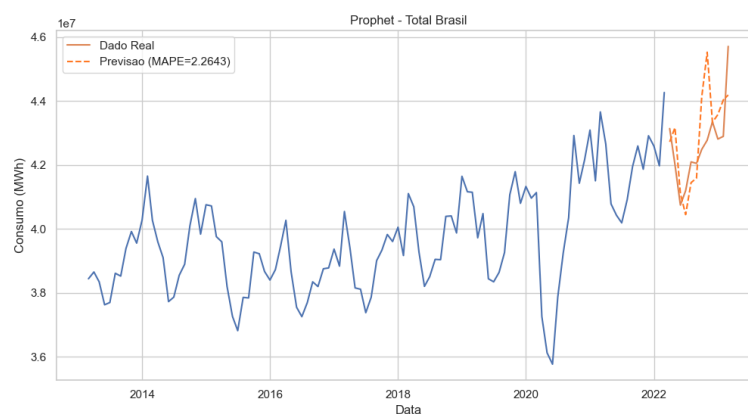
Granularidade	MAPE_SARIMAX	MPE_SARIMAX	RMSE_SARIMAX	AIC_SARIMAX
Total Brasil	0.012	0.96	4e+11	2.6e+03
Total Sudeste_C_Oeste	0.023	2	4.5e+11	2.6e+03
Total São Paulo	0.051	5.1	4.1e+11	2.6e+03
Comercial Brasil	0.029	-1.3	6.7e+10	2.6e+03
Comercial Sudeste_C_Oeste	0.032	2.3	5e+10	2.6e+03
Comercial São Paulo	0.11	11	7.8e+10	2.6e+03
Industrial Brasil	0.044	4.4	5.2e+11	2.6e+03
Industrial Sudeste_C_Oeste	0.052	5.2	2.5e+11	2.6e+03
Industrial São Paulo	0.052	5.1	7.2e+10	2.6e+03
Outros Brasil	0.028	-2.8	4.9e+10	2.6e+03
Outros Sudeste_C_Oeste	0.024	-2	1.3e+10	2.6e+03
Outros São Paulo	0.051	4.2	5.6e+09	2.6e+03
Residencial Brasil	0.018	-0.42	9.9e+10	2.6e+03
Residencial Sudeste_C_Oeste	0.024	0.0095	4.3e+10	2.6e+03
Residencial São Paulo	0.02	0.23	8.6e+09	2.6e+03

Fonte: autor

4.2.3 Resultados do modelo FB-Prophet

O modelo do prophet funciona com o mesmo princípio dos modelos de decomposições clássicas, acrescidos de parâmetros sazonais mais completos. Logo, é esperado que seu resultado seja próximo ao de Holt-Winters. Na Figura 34 é ilustrado o resultado da previsão de 12 meses para o consumo total do país, onde nota-se um erro baixo, com dados preditivos que se aproximam aos reais, mas com precisão menor que os modelos anteriores.

Figura 34 – Previsão Prophet do consumo total Brasil



Fonte: autor

A Figura 35 mostra os resultados de previsão do modelo de todas as séries temporais, onde novamente verifica-se resultados coerentes, mas com erros maiores que o modelo de Holt-Winters que segue princípios preditivos similares.

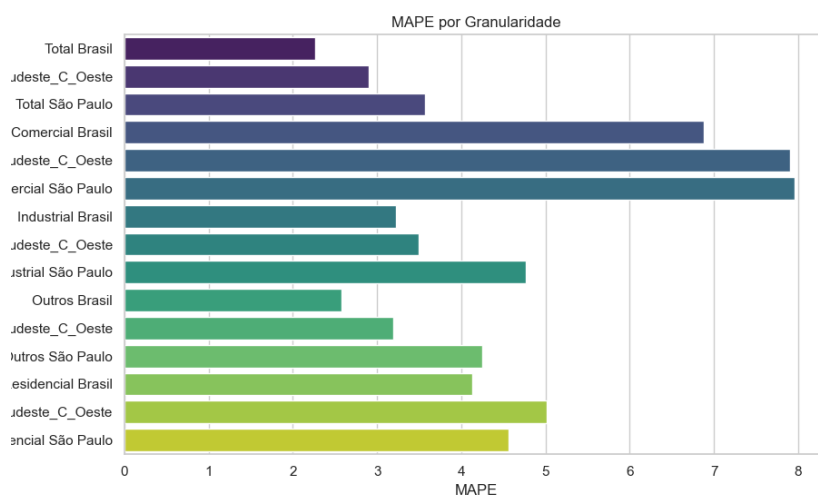
Figura 35 – Resultados do modelo Prophet para todas as séries



Fonte: autor

A Figura 36 consolida todos os MAPEs para as granularidades do estudo, com destaque negativo, novamente para as séries de dados comerciais. Por fim, a Figura 37 sumariza as métricas de previsões completas do modelo.

Figura 36 – MAPE dos dados obtidos pelo modelo Prophet



Fonte: autor

Figura 37 – Métricas de erro do modelo Phophet

Granularidade	MAPE_FB	MPE_FB	RMSE_FB
Total Brasil	2.3	-0.8	1.4e+12
Total Sudeste_C_Oeste	2.9	-0.46	7.3e+11
Total São Paulo	3.6	-0.026	2.6e+11
Comercial Brasil	6.9	6.5	3.8e+11
Comercial Sudeste_C_Oeste	7.9	7.2	1.8e+11
Comercial São Paulo	8	6.2	4.7e+10
Industrial Brasil	3.2	-2.1	3.7e+11
Industrial Sudeste_C_Oeste	3.5	-3.1	1.6e+11
Industrial São Paulo	4.8	-2.5	6.1e+10
Outros Brasil	2.6	-1.9	5.2e+10
Outros Sudeste_C_Oeste	3.2	-1.9	2e+10
Outros São Paulo	4.2	-2.3	4.5e+09
Residencial Brasil	4.1	-1.7	3.7e+11
Residencial Sudeste_C_Oeste	5	-2	2e+11
Residencial São Paulo	4.6	-2.6	3.8e+10

Fonte: autor

O Prophet segue princípios estatísticos similares ao de modelos de decomposição clássicos, como o *Holt-Winters*, mas acrescidos de análises sazonais mais completas, como a inclusão de feriados e datas festivas. Com essas adições se espera que os resultados

sejam melhores, no entanto, ele se comportou de maneira inferior ao modelo clássico de decomposição.


Essa discrepância se deve a alguns fatores, o impacto de feriados pode ser mais pronunciado em uma base diária, trabalhando com dados mensais, esses impactos podem se diluir em uma média mensal de consumo. O Prophet é uma ferramenta desenvolvida originalmente para previsão de uso de redes sociais, e para aplicá-lo em outros tipos de dados, alguns ajustes internos da decomposição, podem precisar de ajuste para melhor refletir os dados de consumo de energia, ajustes esses, que aqui não foram realizados.

4.3 Definição do melhor modelo

O melhor modelo foi escolhido de acordo com as métricas definidas no Capítulo 3, sendo o critério principal o MAPE para escolha de um modelo mais preciso, seguido do RMSE e com validações do MPE para identificar vieses. Já o critério de Akaike é destinado apenas a alguns modelos, e por isso, ele é utilizado apenas como um critério de desempate de modelos similares.

A Figura 38 mostra os MAPE dos 5 modelos para cada uma das 15 granularidades aqui utilizadas. Nota-se que não existe um único modelo que atende a todas as séries, sendo que para cada uma delas, uma das opções apresentou resultados melhores que outros. Considerando os quatro modelos matemáticos, os resultados foram próximos com alguns pontos importantes de diferenças entre eles.

Figura 38 – MAPE de todos os modelos para todas granularidades



Fonte: autor


Os modelos no geral apresentaram erros menores que o modelo ingênuo (como esperado). Para as séries de consumo total, em todos os casos, o modelo de decomposição

de Holt-Winters foi o melhor. Para os casos da quebra no consumo comercial, obteve-se uma previsão melhor no SARIMA com resultados iguais para o SARIMAX. No entanto, as séries de São Paulo se destacaram negativamente pra estes modelos, com o maior erro entre todos modelos. Neste caso específico das séries de São Paulo, o melhor modelo foi o de Holt-Winters. Para as séries industriais, o modelo de Holt-Winters foi o que melhor performou novamente, seguido de perto pelo Prophet. Para a série de consumo em outros, o resultado é dividido, onde o Brasil tem como melhor modelo o Prophet e o subsistema Sudeste/Centro Oeste teve resultados melhores com o SARIMA. Mas assim como na quebra industrial São Paulo, aqui apresenta resultados ruins, e surpreendentemente o menor erro é do modelo ingênuo, ou seja, nenhum modelo conseguiu replicar o padrão de consumo, mas a média representou bem, dada a baixa variação de consumo desta série em específico. Este comportamento, de bons resultados do modelo ingênuo se repete para as séries industriais e de outros consumos, ou seja, as séries de menor variação. Por fim, o residencial apresenta ótimos resultados com o modelo SARIMAX.

Do exposto, evidencia-se a importância do RMSE, visto que o MAPE, em alguns casos, como no modelo ingênuo, pode indicar para um erro baixo, mas pode estar mascarado pelo dado estar errando positivamente e negativamente em iguais proporções.

Na Figura 39 a análise anterior se repete para o RMSE, com comportamentos similares ao MAPE, onde o SARIMA e SARIMAX apresentam resultados muito bons, e o Holt-Winters se comporta melhor de forma geral. Os erros do RMSE são dados em unidades de consumo, devido a níveis de consumo diferentes para cada granularidade, o *heatmap* só pode ser lido por linhas.

Figura 39 – RMSE de todos os modelos para todas granularidades



Fonte: autor

Tabela 4 – Indicação da escolha do melhor modelo por granularidade

Granularidade	Melhor modelo MAPE	Melhor modelo RMSE
Total Brasil	SARIMA	SARIMA
Total Sudeste Centro Oeste	Holt-Winters	Holt-Winters
Total São Paulo	Holt-Winters	Holt-Winters
Comercial Brasil	SARIMA(X)	SARIMA(X)
Comercial Sudeste Centro Oeste	SARIMA(X)	SARIMA(X)
Comercial São Paulo	Holt-Winters	Holt-Winters
Industrial Brasil	Holt-Winters	Holt-Winters
Industrial Sudeste Centro Oeste	Holt-Winters	Holt-Winters
Industrial São Paulo	Holt-Winters	Holt-Winters
Outros Brasil	Prophet	SARIMA
Outros Sudeste Centro Oeste	SARIMA	SARIMA
Outros São Paulo	ingênuo	ingênuo
Residencial Brasil	SARIMAX	SARIMAX
Residencial Sudeste Centro Oeste	SARIMAX	SARIMAX
Residencial São Paulo	SARIMAX	SARIMAX

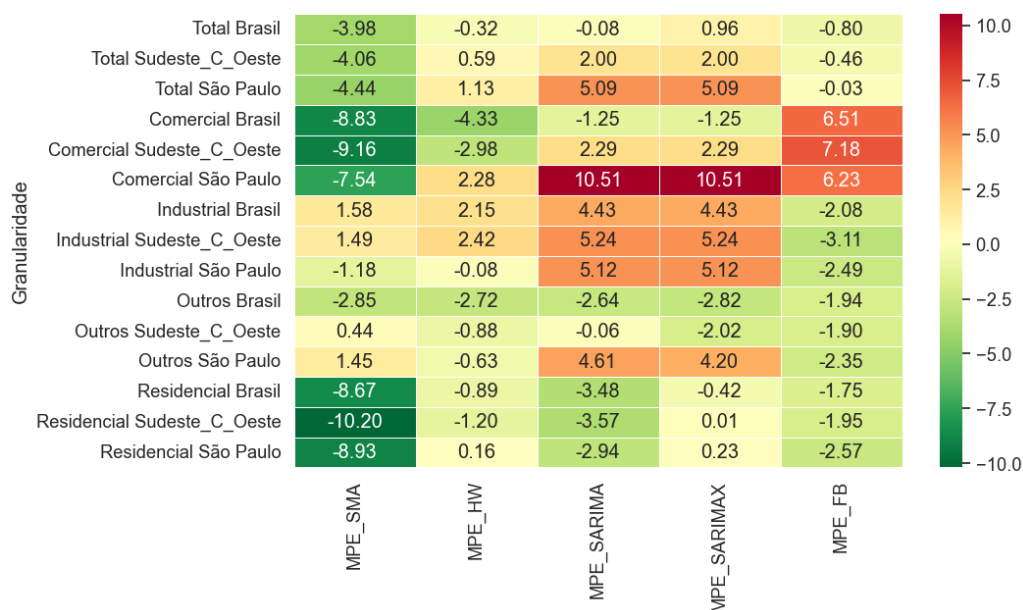
Fonte: autor

A Tabela 4 consolida para cada modelo qual foi o que apresentou os melhores resultados. Tanto para o MAPE quanto para o RMSE, na série “Outros Brasil”, os modelos foram escolhidos diferentemente dependendo da métrica de erro: Prophet para o MAPE e SARIMA para o RMSE. Em todos os outros casos se teve o mesmo modelo escolhidos pela duas métricas.

Os modelos de Holt-Winters e do SARIMA, tanto sem quanto com a variável exógena, apresentam no geral os melhores resultados. Para uma validação final dos modelos, a Figura 40 mostra o MPE dos modelos, que sendo um valor não absoluto, permite identificar se os erros estão sendo categorematicamente positivos ou negativos, indicando que o modelo pode estar enviesado. Para os modelos escolhidos pelas métricas, verificam-se bons MPEs, destacando que se buscam MPEs próximos de 0. Isto, portanto, indica que os erros se balanceiam e não existe viés do modelo.

O melhor modelo então, depende da granularidade e da métrica que se tem mais utilidade em avaliá-lo. Para a escolha de um modelo único para este estudo, convencionou-se escolher o que apresentou o melhor resultado geral. Assim sendo, o modelo ingênuo e o Prophet ganharam em 1 granularidade cada, o SARIMA em 4, o SARIMAX em 6 e o Holt-Winters em 6. Entre o SARIMAX e o Holt-Winters, quando somado os erros de todas as granularidades, Holt-Winters fica com 42% e o SARIMAX com 56%. Logo, o modelo que melhor conseguiu prever, no geral, as séries de consumo de energia elétrica em diversos níveis aqui investigados foi o modelo de Holt-Winters.

Figura 40 – MPE de todos os modelos para todas granularidades



Fonte: autor

4.4 Discussão dos resultados do modelo escolhido

Como discutido anteriormente, não existe um modelo que se melhor adapte a todas granularidades. Cada nível observado foi melhor previsto utilizando um dos modelos investigados, o que reforça a importância desta ferramenta e de se entender o objetivo da sua previsão. Caso opte-se por uma previsão industrial o modelo a ser utilizado pode ser diferente de se analisar uma série de consumo residencial, dada a diferença de comportamento e tendências de cada uma delas.

Dado que o modelo que apresentou os melhores resultados de maneira geral foi o Holt-Winters, esta subseção se dedica à exploração um pouco mais detalhada acerca dos resultados do modelo. Para as granularidades de consumo total, e as quebras deste em industrial, outros e residencial, o modelo providenciou ótimos resultados com erros baixos tanto de MAPE quanto de RMSE. O MPE esteve próximo de 0 em todos os casos, o que indica que o modelo está gerando resultados preditivos bons, sem viés e próximos do real. O destaque negativo esteve relacionado à série comercial, que apresenta erros maiores que a média do modelo. Isto se dá devido ao comportamento destes consumos. Pode-se observar que as séries comerciais são as que tem menor tendência de crescimento, e também as mais afetadas pelo período de isolamento durante a pandemia de COVID 19, que foi discutido na subseção "Limpeza de *Baseline*". Com isso, tem-se um impacto no resultado final, sendo estas séries temporais as que mais se beneficiariam desta etapa em todos os modelos preditivos.

O menor erro do modelo ocorreu nas séries do consumo total Brasil, o que é explicado por alguns fatores. Esta é a série com a menor granularidade, que carrega em

si, todas as variações e comportamentos das quebras analisadas. Essas quebras muitas vezes se balanceiam e resultam em uma série mais previsível. Logo, em algum mês onde o consumo de um subsistema for menor, a interligação entre eles se balancearia nos outros e esse impacto seria mais moderado quando observado para o consumo do Brasil como um todo.

Outro ponto importante é que o horizonte de testes dos modelos foi escolhido com base na granularidade tratada total Brasil. Logo, é evidente que o menor erro seria para esta série. Para obter os menores erros possíveis, então, para cada uma das granularidades que se deseja tratar, poderiam ser realizadas todas etapas tratadas nesse trabalho, individualmente para cada granularidade de dados que se deseja trabalhar, como a decomposição da série, limpeza de *baseline*, escolha de horizonte e teste com os modelos. Logo, garante-se que o modelo seja mais preparado para a granularidade que se deseja tratar.

Deve-se salientar que neste trabalho o objetivo não foi prever para cada granularidade o melhor resultado possível, mas sim criar os passos e uma espécie de ferramenta para auxiliar nesta decisão.

4.5 Estudo de caso e validação final do modelo

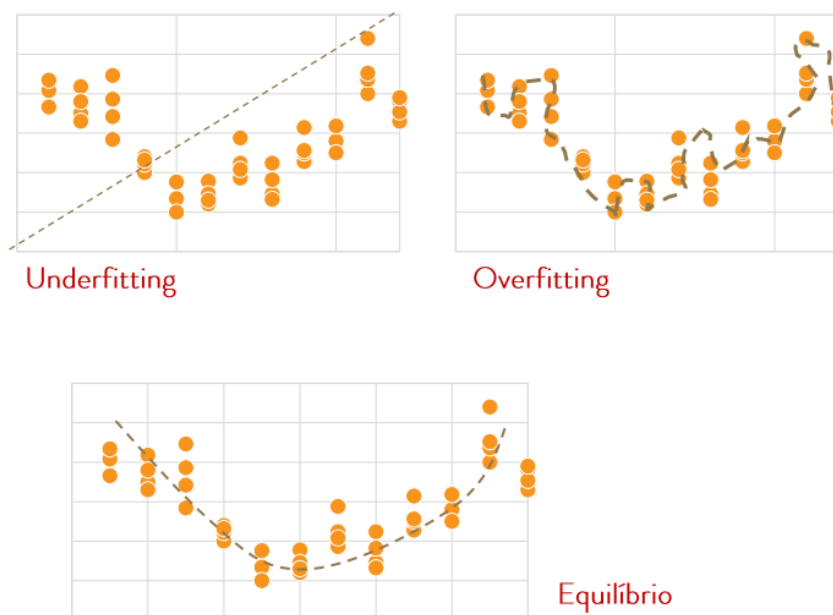
Para uma última validação do modelo escolhido, os valores de consumo obtidos inicialmente, até março de 2023, que foram utilizados para a realização de todos os testes e desenvolvimento deste trabalho serão aplicados como base de treinamento do modelo de Holt-Winters. E o modelo criado a partir destes dados de treino serão utilizados para a previsão de 12 meses futuros, até a conclusão desse trabalho, os dados futuros obtidos pela EPE serão utilizados como dados de teste finais, sendo estes, abril até junho de 2023, totalizando três meses de previsão comparados com o consumo real obtido e 9 meses de previsão futura mas sem a possibilidade de comparação com o consumo efetivo. Este teste será aplicado em três granularidades, quais sejam: consumo total Brasil, subsistema Sudeste/Centro Oeste e São Paulo.

Este estudo de caso busca, como já abordado, uma última validação do modelo, em dois pontos principais:

- *Overfitting*: É a tendência de um modelo de se adaptar de forma excessiva aos dados que tentam prever, de forma a sacrificar a generalização do mesmo para observações inéditas, como ilustrado pela Figura 41.
- *Cross Validation*: É o processo de treinar o modelo utilizando amostras de diferentes tamanhos de treino, garantindo assim que ele tenha a melhor métrica final, e que ele não fique treinado a só funcionar com um certo horizonte de dados de teste e treino.

A validação nos próximos 3 meses, se propõe a responder estes dois pontos, utilizando o modelo para prever dados não utilizados antes, tanto no teste quanto em seu treino. Logo, realiza-se uma *Cross Validation* do modelo, já que utilizou-se dados diferentes para o treino e teste dos usados em suas validações iniciais, e avaliando os

Figura 41 – Exemplo de overfitting em dados




Fonte: ILOS

resultados gerados. Adicionalmente, avalia-se se o modelo sofre de *overfitting*, dado que já se conhece o seu comportamento é esperado um resultado similar para os 3 meses futuros e um resultado muito diferente indicaria algum problema no modelo.


A Figura 42 mostra o resultado final preditivo do modelo Holt-Winters retreinado, aplicado no consumo total Brasil prevendo os 3 meses futuros propostos neste capítulo. A Figura 43, por sua vez, apresenta os resultados para o subsistema Sudeste/Centro Oeste, enquanto a Figura 44 indica os resultados para o estado de São Paulo.

Figura 42 – Consumo total Brasil dado pelo modelo final




Fonte: autor

Figura 43 – Consumo total Sudeste e Centro Oeste dado pelo modelo final



Fonte: autor

Figura 44 – Consumo total São Paulo dado pelo modelo final



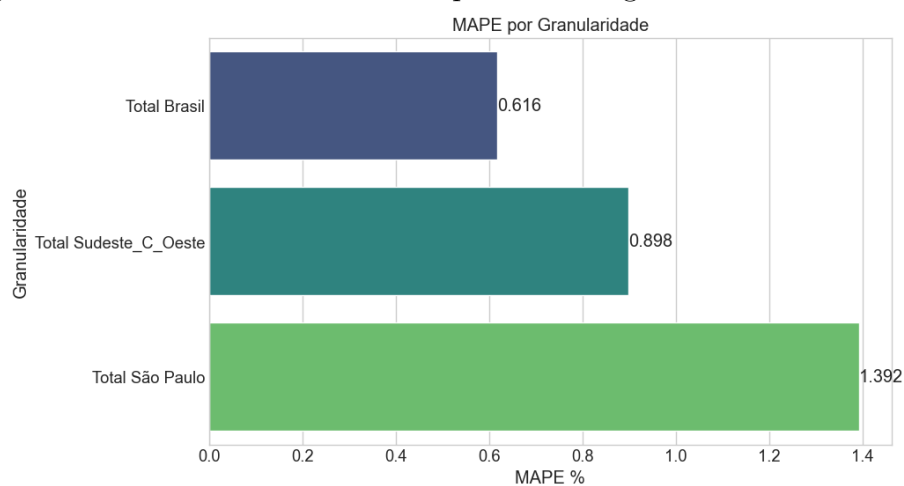
Fonte: autor

Os MAPEs obtidos nas três previsões são consolidados e ilustrados pela Figura 45, onde conclui-se a excelente capacidade preditiva do modelo adotado, com dados previstos extremamente fidedignos aos reais e erros em torno de apenas 1% dos valores reais de consumo para essas granularidades. Os baixos erros também são reflexos da previsão ocorrer apenas para 3 meses, em vez dos 12 realizados nas etapas de validação. Logo, deve-se também pontuar que uma previsão com horizonte menor de tempo tende a apresentar resultados melhores. De todo modo, acredita-se que o modelo adotado respondeu com robustez aos novos dados de treinamento/teste, não tendo indícios de *overfitting*. Adicionalmente, essa nova etapa realizada de treinamento/teste corrobora com a afirmativa

de que o modelo consegue responder bem às projeções de consumo para as granularidades investigadas.

Todos os resultados foram positivos, superando as expectativas médias dadas pela fase de testes do modelo. Logo, conclui-se que a escolha do modelo foi acertada, assim como sua validação final. O modelo final deste estudo é um modelo preditivo preciso, simples, sem viés ou *overfitting*, que conseguiu prever com erros menores que 1% o consumo do Brasil em 3 meses futuros.

Figura 45 – MAPE do modelo final para as três granularidades escolhidas



Fonte: autor

5 CONCLUSÃO

É clara a importância de um planejamento de demanda de energia elétrica para todos os órgãos e empresas relacionadas a sua distribuição e controle. Uma previsão acurada auxilia em decisões estratégicas, planejamento da produção, em manutenções e obras e também na problemática de expansão e investimentos.

O objetivo deste trabalho era entender o processo de planejamento, avaliando cada uma das etapas a ele associada, assim como desenvolver uma ferramenta para, a partir de métricas de análise, escolher o melhor modelo de dados para as séries históricas de consumo utilizadas.

Assim destacam-se 3 conclusões principais. A primeira é que não existe um modelo único que atende todas as séries e granularidades possíveis, onde cada modelo se adequará melhor a um conjunto de dados, destacando a importância do uso de uma ferramenta comparativa como a desenvolvida durante este trabalho. Atualmente, com diversas ferramentas computacionais disponíveis, é possível processar grandes quantidades de informações e testar diversos modelos preditivos em cada uma das séries a serem trabalhadas.

Em segundo lugar, vale pontuar que quando analisado o resultados de algumas séries, fica nítida a importância das etapas do processo de planejamento, como o caso de uma limpeza de dados adequada, retirando padrões que não se quer que o modelo aprenda. Algumas séries são muito mais afetadas por esses padrões que outras, prejudicando fortemente os resultados preditivos dos modelos. Entender exatamente quais são esses dados que não irão se repetir e ajustá-los em sua base é essencial para se garantir uma previsão melhor. Outra etapa essencial para os resultados é a definição dos horizontes de planejamento, assim como definir o tempo de treinamento a ser inserido. Foi verificado neste trabalho que esses dois períodos afetam diretamente o resultado obtido, e que a escolha de um período adequado pode ser a diferença entre usar ou descartar o processo preditivo.

Por fim, cabe fazer uma conclusão geral sobre o processo aqui apresentado. Neste trabalho, foram avaliadas 15 granularidades com o objetivo de gerar resultados e conclusões com o maior número de dados possíveis partindo de perfis e comportamentos distintos no que tange às séries históricas. Mas, em um processo de planejamento, normalmente se concentraria em poucas divisões dos dados. Dessa maneira, os esforços e definições de parâmetros podem ser concentrados em encontrar os melhores resultados para aquela série específica, obtendo um modelo e um processo para cada uma das granularidades a serem abordadas. Todas as etapas abordadas por este trabalho contribuem para o resultado final do planejamento, sendo importante o entendimento pleno do que se quer prever, quando e como, para poder aplicar as melhores ferramentas e tratamentos possíveis ao

modelo desejado. Vale ainda salientar que o modelo de previsão é apenas uma das etapas do processo, e que sem os tratamentos e entendimento adequados, de nada servirá os resultados de um modelo matemático de previsão.

Para trabalhos futuros, sugere-se a implementação de outros modelos de previsão na ferramenta, como de redes neurais, e a inclusão de outras variáveis exógenas, como o PIB aqui utilizado, que podem ter alguma correlação com o consumo de energia elétrica, como temperatura e bandeira de tarifa. Dado que o PIB teve FVA positivo na previsão, outras variáveis podem ter um benefício ainda maior aos resultados alcançados pelos modelos.

REFERÊNCIAS

- ANEEL. **Resolução Normativa N° 666**. 2015. Disponível em: <<https://www2.aneel.gov.br/aplicacoes/audiencia/arquivo/2014/039/resultado/ren2015666.pdf>>. Acesso em: 16.7.2023. Citado na página 13.
- BARBOSA, L. V. **Modelo de Previsão de Consumo de Energia Elétrica em Cenário Pandêmico com uso de Inteligência Artificial**. 213 p. Monografia (Graduação, em Engenharia Elétrica) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2021. Citado na página 26.
- BOTCHKAREV, A. Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology. **Ryerson University**, Toronto, 2019. Citado na página 24.
- CARVALHO, D. J. de. **Métodos de previsão de consumo de energia elétrica residencial em grande volume de dados**. 66 p. Monografia (Graduação, em Sistemas de Informação) — Universidade Federal Rural de Pernambuco, Recife, 2019. Citado na página 26.
- DREBES, F. **Previsão de Demanda de Energia Elétrica Utilizando Inteligência Artificial**. 88 p. Monografia (Graduação, em Engenharia Elétrica) — Universidade do Vale do Taquari, Lajeado, 2020. Citado na página 26.
- FARIA, J. C. **Administração - Introdução ao Estudo**. São Paulo: Livraria Pioneira Editora, 1994. Citado 2 vezes nas páginas 12 e 16.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 2th ed.. ed. Australia: Otexts, 2014. Citado 6 vezes nas páginas 12, 20, 21, 22, 23 e 42.
- KAYTEZ, F. et al. Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. **International Journal of Electrical Power Energy Systems** **67**, 2014. Citado na página 13.
- KLEIN, L. P. **Previsão de demanda de energia elétrica e aplicação de curto prazo**. 113 p. Monografia (Graduação, em Engenharia Elétrica) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014. Citado na página 26.
- KWASNCIKA, E. L. **Introdução à Administração**. **3. ed.** [S.l.]: Atlas, 1986. Citado na página 16.
- MACIEL, D. B.; CARVALHO, P. C. M. de. Impacto da covid-19 sobre o consumo de energia elétrica das regiões do Brasil. **Revista Brasileira de Energia | Vol. 29, N° 1**, 2023. Citado na página 35.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C. **Forecasting Methods for Management**. [S.l.]: John Wiley Sons, 1989. Citado na página 17.
- MONKS, J. G. **Administração da Produção**. [S.l.]: McGraw-Hill, 1987. Citado na página 20.
- MOREIRA, D. A. **Administração da produção e operações**. [S.l.]: Livraria Pioneira Editora, 1993. Citado na página 20.

- NICOLAS, V. **Forecast KPI: How to Assess the Accuracy of a Product Portfolio. Towards data science**. 2023. Disponível em: <<https://towardsdatascience.com/forecast-kpi-how-to-assess-the-accuracy-of-a-product-portfolio-bc38135a6d2a>>. Acesso em: 23.5.2023. Citado na página 24.
- ONS. **O Sistema Interligado Nacional**. 2023. Disponível em: <<https://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>>. Acesso em: 10.7.2023. Citado na página 15.
- ONS. **Previsões de carga para o Planejamento Anual da Carga 2023-2027**. 2023. Disponível em: <https://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Boletim%20T%C3%A9cnico%20PLAN%202027_EPE_ONS_CCEE.pdf>. Acesso em: 23.5.2023. Citado na página 19.
- SANTIAGO, L. A.; JUNIOR, U. F. B. **Métodos Avançados de Previsão de Vendas: Aplicação em Empresa do Segmento de Joias**. 91 p. Monografia (Graduação, em Engenharia de Produção) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2021. Citado na página 26.
- SANTOS, F. R. M. D. **Previsão de Médio Prazo de Demanda de Energia Elétrica do Setor Industrial na Região Sul e Sudeste do Brasil**. 83 p. Monografia (Graduação, em Engenharia de Produção), Paraná, 2019. Citado na página 25.
- SMILL, V. **Energy Transitions: History, Requirements, Prospects**. [S.l.]: Praeger, 2010. Citado na página 15.
- TAYLOR, S. J.; LETHAM, B. Forecasting at scale. **PeerJ Preprints**, California, 2017. Citado na página 22.
- TUBINO, D. F. **Planejamento e controle da Produção**. [S.l.]: Atlas, 2009. Citado na página 18.

Anexos

ANEXO A – Código Fonte

Em função da extensão do código fonte produzido, apresenta-se neste apêndice apenas uma amostra das partes principais do código. Não obstante, todos os códigos desenvolvidos durante este trabalho podem ser acessados em: <https://github.com/ryanzero/Previsao_energia>

Uma amostra dos principais estão anexadas abaixo:

```

1     ## Total Consumo
path_trabalhado = path_atual / 'Dados de Input/Bases Trabalhadas'
3 df1 = pd.read_csv(os.path.join(path_trabalhado, r'Brasil_se.csv'), sep =';')
df1.head(6)
5
## Filtrando apenas BR, subsistema Sudeste e SP
7
df_total_brasil = df1[df1["Regiao"] == "TOTAL BRASIL"]
9 df_total_sudeste = df1[df1["Regiao"] == 'Sudeste/C. Oeste']
df_total_sp = df6[df6["SAO PAULO"] == 'TOTAL']
11
df_comercial_brasil = df2[df2["Regiao"] == "TOTAL COMERCIAL (CATIVO + LIVRE
)"]
13 df_comercial_sudeste = df2[df2["Regiao"] == 'Sudeste/C. Oeste']
df_comercial_sp = df6[df6["SAO PAULO"] == 'COMERCIAL']
15
df_industrial_brasil = df3[df3["Regiao"] == "TOTAL INDUSTRIAL (CATIVO +
LIVRE)"]
17 df_industrial_sudeste = df3[df3["Regiao"] == 'Sudeste/C. Oeste']
df_industrial_sp = df6[df6["SAO PAULO"] == 'INDUSTRIAL']
19
df_outros_brasil = df4[df4["Regiao"] == "TOTAL OUTROS (RURAL + ILUMINACAO
PUB. + SERVIÇO PUB. + PODER PUB. + CONSUMO PRÓPRIO)"]
21 df_outros_sudeste = df4[df4["Regiao"] == 'Sudeste/C. Oeste']
df_outros_sp = df6[df6["SAO PAULO"] == 'OUTROS']
23
df_residencial_brasil = df5[df5["Regiao"] == "TOTAL RESIDENCIAL"]
25 df_residencial_sudeste = df5[df5["Regiao"] == 'Sudeste/C. Oeste']
df_residencial_sp = df6[df6["SAO PAULO"] == 'RESIDENCIAL']
27
## Criando um data frame unico
29
merged_df = pd.concat([df_total_brasil, df_total_sudeste, df_total_sp,
df_comercial_brasil, df_comercial_sudeste, df_comercial_sp,
df_industrial_brasil,
31 df_industrial_sudeste, df_industrial_sp,
df_outros_brasil, df_outros_sudeste, df_outros_sp,

```



```

        df_residencial_brasil, df_residencial_sudeste,
        df_residencial_sp))
merged_df = merged_df[['Data_padrao', 'Granularidade', 'Valor']]
33 merged_df

35 ## Criando uma lista com as series temporais

37 lista_regiao = df_final['Granularidade'].unique()

39 series_temporais = []
for i in lista_regiao:
41     Grupo = df_final[(df_final['Granularidade'].str.contains(i))]
        series_temporais.append(Grupo)
43 series_temporais

```

Listing A.1 – Tratamento dos dados

```

1     #Plotando cada serie temporal para cada granularidade presente na lista

3     fig, axs = plt.subplots(nrows=7, ncols=2, figsize=(15, 30))

5 for serie, grupo, ax in zip(series_temporais[1:], lista_regiao[1:], axs.
    flat):
        plt.figure(figsize=(10,6))
7         ax.plot(serie['Data_padrao'].values, serie['Valor'].values)
            ax.set_title("Serie de " + grupo, fontsize=15)
9             ax.set_xlabel("Data", fontsize=13)
                ax.set_ylabel("Consumo (MWh)", fontsize=13)

11 plt.tight_layout()
13 plt.savefig("series/" + "Series temporais" + ".png", bbox_inches="tight")
plt.show()

```

Listing A.2 – Plot das séries temporais

```

#Plotando a decomposicao das series temporais usando "decompose"
2
serie = primeira_serie.drop(columns=['Granularidade'])
4 serie = serie.set_index('Data_padrao')
rcParams['figure.figsize'] = 8, 6
6 decomposition = sm.tsa.seasonal_decompose(serie, model='additive')
fig = decomposition.plot()

8
plt.show()

10
plt.savefig("Total Brasil decomposicao" + ".png")

```

Listing A.3 – Decomposição das séries

```

1  ## Escolhendo o melhor treinamento para os modelos
3
4  from statsmodels.tsa.holtwinters import ExponentialSmoothing
5
6  primeira_serie = series_temporais[0]
7  test_length = 36
8  mape_values = []
9
10 for i in range(0, len(primeira_serie) - test_length + 1):
11     train = primeira_serie.groupby(['Data_padrao'])['Valor'].sum()
12     test = primeira_serie.groupby(['Data_padrao'])['Valor'].sum()
13     train = train.iloc[i:-12]
14     test = test.iloc[-12:]
15     model = ExponentialSmoothing(train, trend="add", seasonal="add",
16                                 seasonal_periods=12)
17     fit = model.fit()
18     pred = fit.forecast(12)
19     mape = mean_absolute_percentage_error(test, pred)
20     mape_values.append(mape)
21
22 #Plotando todos os pontos de meses de treinamento pelo MAPE correspondente
23
24 fig, ax = plt.subplots(figsize=(12, 6))
25 ax.plot(mape_values, marker='o', linestyle='-', color='red');
26 ax.set_xlabel('Indice de Iteracao')
27 ax.set_ylabel('MAPE')
28 ax.set_title('Valores do MAPE ao longo das iteracoes')
29 plt.savefig("mape_values", bbox_inches="tight")
30 plt.show()

```

Listing A.4 – Escolha do melhor horizonte de treino

```

2  # Criando um teste e treino para cada granularidade
3
4  for serie, grupo in zip(series_temporais, lista_regiao):
5     train = serie.groupby(['Data_padrao'])['Valor'].sum()
6     test = serie.groupby(['Data_padrao'])['Valor'].sum()
7     train = train.iloc[110:-12]
8     test = test.iloc[-12:]
9
10    # Calculo do Holt Winters
11    model = ExponentialSmoothing(train, trend="add", seasonal="add",
12                                seasonal_periods=12)
13    fit = model.fit()
14    pred = fit.forecast(12)

```

```
14
15     #Metricas de erro
16     mape = mean_absolute_percentage_error(test, pred) *100
17     rmse = mean_squared_error(test, pred, squared=False)
18     mpe = mean_percentage_error(test, pred)
19     aic = fit.aic
20
21     fig, ax = plt.subplots(figsize=(12, 6))
22     ax.plot(train);
23     ax.plot(test, label='Dados Real');
24     ax.plot(pred, linestyle='—', color='#ff7823', label="Previsao (AIC
25         ={:0.2f}), (MAPE={:0.3f}%)".format(fit.aic, mape));
26     ax.legend();
27     ax.set_title("Holt-Winter's Seasonal Smoothing - {}".format(grupo));
28     ax.set_ylabel("Consumo (MWh)")
29     ax.set_xlabel("Data")
30
31     # Armazena o MAPE por regioao
32     mape_por_regiao.append({'Granularidade': grupo, 'MAPEHW': mape})
33     rmse_por_regiao.append({'Granularidade': grupo, 'RMSEHW': rmse})
34     mpe_por_regiao.append({'Granularidade': grupo, 'MPEHW': mpe})
35     aic_results = np.append(aic_results, aic)
36
37
38     plt.savefig('hw/'+"previsao_hw_" + grupo + ".png", bbox_inches="tight")
39
40 # Criacao do DataFrame com os valores de MAPE por regioao
41 df_mape = pd.DataFrame(mape_por_regiao)
42 df_rmse = pd.DataFrame(rmse_por_regiao)
43 df_mpe = pd.DataFrame(mpe_por_regiao)
44 df_aic = pd.DataFrame(aic_results)
45
46 df_metricas1 = pd.merge(df_mape, df_mpe, on='Granularidade').merge(df_rmse,
47     on='Granularidade')
48 df_metricas1 = pd.concat([df_metricas1, df_aic], axis=1)
49
50 df_metricas1 = df_metricas1.rename(columns={0: 'AIC_HW'})
51
52 # Configurar estilo Seaborn
53 sns.set(style="whitegrid")
54
55 # Criar o grafico de barras com cores
56 plt.figure(figsize=(10, 6))
57 ax = sns.barplot(x='MAPEHW', y='Granularidade', data=df_mape, palette="
58     viridis", ci=None)
59 plt.xlabel("MAPE %")
```



```
39     index_of_fc = pd.date_range(train.index[-1] + pd.DateOffset(months=1),
40                                 periods = 12, freq='MS')
41
42     fitted_series = pd.Series(fitted , index=index_of_fc)
43
44     mape = mean_absolute_percentage_error(test , fitted_series) *100
45     rmse = mean_squared_error(test , fitted_series , squared=False)
46     mpe = mean_percentage_error(test , fitted_series)
47     aic = fit.aic
48
49     fig , ax = plt.subplots(figsize=(12, 6))
50     ax.plot(train);
51     ax.plot(test , label='Dados Real');
52     ax.plot(fitted_series , linestyle='—', color='#ff7823' , label="Previsão
53             (AIC={:0.2f}) , (MAPE={:0.3f}%)".format(fit.aic , mape));
54     ax.legend();
55     ax.set_title("SARIMAX - {}".format(grupo));
56     ax.set_ylabel("Consumo (MWh)")
57     ax.set_xlabel("Data")
58
59     # Armazena o MAPE por regioao
60     mape_por_regiao.append({'Granularidade': grupo , 'MAPE.SARIMAX': mape})
61     rmse_por_regiao.append({'Granularidade': grupo , 'RMSE.SARIMAX': rmse})
62     mpe_por_regiao.append({'Granularidade': grupo , 'MPE.SARIMAX': mpe})
63     aic_results = np.append(aic_results , aic)
64
65     plt.savefig('sarimax/'+"previsao_sarimax_" + grupo + ".png" ,
66                 bbox_inches="tight")
67
68     # Criacao do DataFrame com os valores de MAPE por regioao
69     df_mape = pd.DataFrame(mape_por_regiao)
70     df_rmse = pd.DataFrame(rmse_por_regiao)
71     df_mpe = pd.DataFrame(mpe_por_regiao)
72     df_aic = pd.DataFrame(aic_results)
73
74     df_metricas3 = pd.merge(df_mape , df_mpe , on='Granularidade').merge(df_rmse ,
75                                 on='Granularidade')
76     df_metricas3 = pd.concat([df_metricas3 , df_aic] , axis=1)
77
78     df_metricas3 = df_metricas3.rename(columns={0: 'AIC.SARIMAX'})
79
80     # Ordenar o DataFrame por MAPE
81     #df_mape = df_mape.sort_values(by='MAPE' , ascending=False)
82
83     # Configurar estilo Seaborn
84     sns.set(style="whitegrid")
```

```

83 # Criar o grafico de barras com cores
plt.figure(figsize=(10, 6))
85 ax = sns.barplot(x='MAPE_SARIMAX', y='Granularidade', data=df_mape, palette
    ="viridis", ci=None)
plt.xlabel("MAPE (%)")
87 plt.ylabel("Granularidade")
plt.title("MAPE por Granularidade")
89 for p in ax.patches:
    ax.text(p.get_width(), p.get_y() + p.get_height() / 2, f'{p.get_width()
        :.3f}', va='center')
91
plt.tight_layout()
93 plt.savefig('sarimax/'+"mape_SARIMAX", bbox_inches="tight")
plt.show()
95
plt.savefig("Total Brasil decomposicao" + ".png")

```

Listing A.6 – SARIMAX

```

2 #Dataframe com o erro de todas as granularidades
4 merged_df_mape = merged_df[['Granularidade', 'MAPE_SMA', 'MAPE_HW', '
    MAPE_SARIMA', 'MAPE_SARIMAX', 'MAPE_FB']]
merged_df_mape.set_index('Granularidade', inplace=True)
6
#Plotando os MAPEs
8 sns.set(font_scale=1.2)
plt.figure(figsize=(10, 6))
10 ax = sns.heatmap(merged_df_mape, cmap='RdYIGn_r', annot=True, fmt=".2f",
    linewidths=.5)
12 # Definir rotulos das linhas
ax.set_yticklabels(merged_df_mape.index, rotation=0)
14
plt.savefig('erros/'+"mape_erros", bbox_inches="tight")
16 plt.show()

```

Listing A.7 – Métricas finais de erro