



**UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
DOUTORADO ACADÊMICO EM ENGENHARIA ELÉTRICA**

ANDERSON JHONES PASSOS NASCIMENTO

**INTEGRAÇÃO AVANÇADA DE ANÁLISE DE SÉRIES TEMPORAIS,
CLUSTERIZAÇÃO, PREVISÃO E CRIAÇÃO DE APLICAÇÃO DESKTOP PARA
OTIMIZAÇÃO DA EFICIÊNCIA ENERGÉTICA E GESTÃO DE TARIFAS**

**FORTALEZA
2025**

ANDERSON JHONES PASSOS NASCIMENTO

INTEGRAÇÃO AVANÇADA DE ANÁLISE DE SÉRIES TEMPORAIS, CLUSTERIZAÇÃO,
PREVISÃO E CRIAÇÃO DE APLICAÇÃO DESKTOP PARA OTIMIZAÇÃO DA
EFICIÊNCIA ENERGÉTICA E GESTÃO DE TARIFAS

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências e Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Orientador: Prof. Ph.D. Fernando Luiz Marcelo Antunes

Coorientador: Prof. Ph.D. José Antônio Fernandes de Macêdo

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

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

N193i Nascimento, Anderson Jhones Passos.

Integração Avançada De Análise De Séries Temporais, Clusterização, Previsão E Criação De Aplicação Desktop Para Otimização Da Eficiência Energética E Gestão De Tarifas / Anderson Jhones Passos Nascimento. – 2025.

199 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2025.

Orientação: Prof. Dr. Fernando Luiz Marcelo Antunes.

Coorientação: Prof. Dr. José Antônio Fernandes de Macêdo.

1. Modalidade tarifária adequada. 2. Detecção de Anomalias. 3. Clusterização de Consumidores de energia. 4. Eficiência Energética. 5. Previsão de Consumo. I. Título.

CDD 621.3

ANDERSON JHONES PASSOS NASCIMENTO

**INTEGRAÇÃO AVANÇADA DE ANÁLISE DE SÉRIES TEMPORAIS, CLUSTERIZAÇÃO,
PREVISÃO E CRIAÇÃO DE APLICAÇÃO DESKTOP PARA OTIMIZAÇÃO DA
EFICIÊNCIA ENERGÉTICA E GESTÃO DE TARIFAS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências e Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Engenharia Elétrica

Aprovada em: 13/06/2025

BANCA EXAMINADORA

Prof. Ph.D. Fernando Luiz Marcelo
Antunes (Orientador)
Departamento de Engenharia Elétrica -
Universidade Federal do Ceará (UFC)-Campus
Fortaleza

Prof. Ph.D. José Antônio Fernandes de
Macêdo (Coorientador)
Departamento de Computação - Universidade
Federal do Ceará (UFC)-Campus Fortaleza

Prof. Dr. Menaouar Berrehil El Kattel
Departamento de Engenharia Elétrica -
Universidade Federal do Ceará (UFC)-Campus
Fortaleza

Pesquisador Dr. Robson Mayer
Universidade Estadual de Campinas - Unicamp
Departamento: Faculdade de Engenharia
Elétrica e de Computação da Universidade
Estadual de Campinas - FEEC/UNICAMP

Prof. Dr. Arthur Plínio de Souza Braga
Departamento de Engenharia Elétrica -
Universidade Federal do Ceará (UFC) -
Campus Fortaleza

Prof. Dr. Dalton de Araújo Honório
Departamento de Engenharia Elétrica -
Universidade Federal do Ceará (UFC) -
Campus Fortaleza

A Deus, a minha mãe Nazaré, minha tia Francisca, meu tio Antônio José, minha avó Luiza, Meu pai Neto e minha família em geral, eu dedico este trabalho.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me permitir realizar essa conquista, sempre me bençoar e estar comigo em todos os momentos da minha vida.

Aos meus familiares por torcerem por mim e me incentivarem.

Ao meu orientador, Dr. Fernando Luiz Marcelo Antunes, pela orientação e pelo embasamento para eu poder ser um pesquisador melhor, ao meu coorientador, Dr. José Antônio Fernandes de Macêdo, assim como ao professor Dr. Menaouar Berrehil El Kattel pela orientação de como proceder nas correções da tese.

Aos professores Dr. Fernando Luiz Marcelo Antunes, da Universidade Federal do Ceará (UFC), Dr. José Antônio Fernandes de Macêdo, da Universidade Federal do Ceará (UFC), Dr. Menaouar Berrehil El Kattel, da Universidade Federal do Ceará (UFC), Dr. Robson Mayer, da Universidade Estadual de Campinas (Unicamp), Dr. Arthur Plínio de Souza Braga, da Universidade Federal do Ceará (UFC) e Dr. Dalton de Araújo Honório, da Universidade Federal do Ceará (UFC) por participarem desta banca avaliadora.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por seu auxílio financeiro.

Agradeço ao Programa de Pós-Graduação do Departamento de Engenharia Elétrica e ao Programa de Pós-Graduação do Departamento de Ciência da Computação, bem como a todos os professores que me proporcionaram conhecimento e embasamento para prosseguir com esta pesquisa e conseguir concluir-la.

Ao Grupo de Processamento de Energia e Controle (GPEC) pelo suporte ao projeto.

À Secretaria da Infraestrutura do estado do Ceará, que cedeu senhas e logins de unidades consumidoras públicas para coleta de dados de grandezas elétricas através do sistema de telemedição da Enel Ceará.

Por fim, agradeço a todos aqueles que de forma direta ou indireta contribuíram para minha formação profissional e social.

“Quando eu iniciei minha jornada, eu era apenas um menino no meio dos leões. Hoje, eu sou um leão entre os leões.”

(Charles Oliveira (Do Bronx))

RESUMO

Esta tese de doutorado investiga a análise avançada de demanda elétrica e consumo de energia, com foco na detecção de anomalias e na identificação de padrões de consumo em unidades consumidoras. Utilizando técnicas de análise de séries temporais e algoritmos especializados, identificaram-se comportamentos anômalos tanto nas demandas quanto nos registros de consumo. Adicionalmente, a pesquisa englobou a identificação de clientes com perfis de consumo anômalos, utilizando-se para tal a técnica de clusterização, baseada nos consumos médios mensais e na demanda contratada. A abordagem de clusterização proporciona uma visão mais abrangente dos grupos de consumidores, revelando características distintas em termos de padrões de consumo, sejam eles normais ou irregulares, e comportamentos de tendências e sazonalidades. A pesquisa também incorpora a previsão de consumo. Séries temporais altamente correlacionadas dentro do mesmo grupo são utilizadas para prever o comportamento de novas séries temporais ou aquelas com escassez de dados históricos. Esse enfoque oferece uma compreensão aprofundada do padrão de comportamento das séries mais antigas e estáveis, sendo fundamental para determinar o nível de consumo de novas unidades consumidoras ao longo do ano e prever seu padrão de comportamento. A previsão também contribui para a definição da demanda contratada mais adequada, otimizando a eficiência no consumo de energia. Para aprimorar a utilidade prática dessas análises, foi desenvolvida uma aplicação desktop especializada. Esta ferramenta permite a análise de dados de demanda e consumo de energia, facilitando a escolha da tarifação mais adequada para o Grupo A de consumidores de energia. A aplicação destaca estatísticas relevantes, como média e desvio padrão, e compara os custos atuais com diferentes opções tarifárias. A aplicação inclui ainda uma aba de detecção de anomalias, que permite a visualização gráfica e textual dos valores identificados como anomalias. Ademais, dispõe de uma aba dedicada à observação de tendências e sazonalidades de uma série temporal decomposta. Os resultados desta pesquisa não somente aprimoram a compreensão dos padrões de consumo de energia e demanda elétrica, mas também introduzem ferramentas práticas e inovadoras para profissionais do setor. A pesquisa demonstrou que os custos de energia das unidades públicas analisadas poderiam ser reduzidos em aproximadamente 2,7 milhões de reais em um ano. Esta tese representa uma contribuição significativa para a gestão inteligente da demanda de energia, integrando técnicas avançadas de análise de séries temporais, clusterização e previsão, com o objetivo de otimizar a eficiência operacional e econômica no setor elétrico.

Palavras-chave: modalidade tarifária adequada; detecção de anomalias; análise de séries temporais; previsão de consumo; clusterização de consumidores de energia; eficiência energética; aplicação desktop; aprendizado de máquina.

ABSTRACT

This doctoral thesis investigates advanced analysis of electrical demand and energy consumption, with a focus on anomaly detection and the identification of consumption patterns in consumer units. By employing time series analysis techniques and specialized algorithms, anomalous behaviors were identified in both demand and consumption records. Additionally, the research encompassed the identification of customers with anomalous consumption profiles using clustering techniques based on average monthly consumption and contracted demand. The clustering approach provides a broader perspective on consumer groups, revealing distinct characteristics in terms of consumption patterns—whether normal or irregular—as well as trend and seasonality behaviors. The research also incorporates consumption forecasting. Highly correlated time series within the same group are used to predict the behavior of new time series or those with limited historical data. This approach offers a deeper understanding of the behavioral patterns of older and more stable series, which is essential for estimating the annual consumption levels of new consumer units and forecasting their behavioral trends. Forecasting also contributes to the determination of the most suitable contracted demand, optimizing energy consumption efficiency. To enhance the practical utility of these analyses, a specialized desktop application was developed. This tool enables the analysis of demand and energy consumption data, supporting the selection of the most appropriate tariff option for Group A energy consumers. The application highlights relevant statistics such as mean and standard deviation and compares current costs with different tariff alternatives. It also includes an anomaly detection tab that allows both graphical and textual visualization of values identified as anomalies. Furthermore, it features a dedicated tab for observing trends and seasonality in decomposed time series. The results of this research not only improve the understanding of energy consumption and electrical demand patterns but also introduce practical and innovative tools for professionals in the sector. The study demonstrated that energy costs for the analyzed public units could be reduced by approximately BRL 2.7 million in a single year. This thesis represents a significant contribution to the intelligent management of energy demand, integrating advanced time series analysis, clustering, and forecasting techniques to optimize operational and economic efficiency in the This doctoral thesis investigates advanced analysis of electrical demand and energy consumption, with a focus on anomaly detection and the identification of consumption patterns in consumer units. By employing time series analysis techniques and specialized algorithms, anomalous behaviors were identified in both demand and consumption records. Additionally, the research encompassed the identification of customers

with anomalous consumption profiles using clustering techniques based on average monthly consumption and contracted demand. The clustering approach provides a broader perspective on consumer groups, revealing distinct characteristics in terms of consumption patterns—whether normal or irregular—as well as trend and seasonality behaviors. The research also incorporates consumption forecasting. Highly correlated time series within the same group are used to predict the behavior of new time series or those with limited historical data. This approach offers a deeper understanding of the behavioral patterns of older and more stable series, which is essential for estimating the annual consumption levels of new consumer units and forecasting their behavioral trends. Forecasting also contributes to the determination of the most suitable contracted demand, optimizing energy consumption efficiency. To enhance the practical utility of these analyses, a specialized desktop application was developed. This tool enables the analysis of demand and energy consumption data, supporting the selection of the most appropriate tariff option for Group A energy consumers. The application highlights relevant statistics such as mean and standard deviation and compares current costs with different tariff alternatives. It also includes an anomaly detection tab that allows both graphical and textual visualization of values identified as anomalies. Furthermore, it features a dedicated tab for observing trends and seasonality in decomposed time series. The results of this research not only improve the understanding of energy consumption and electrical demand patterns but also introduce practical and innovative tools for professionals in the sector. The study demonstrated that energy costs for the analyzed public units could be reduced by approximately BRL 2.7 million in a single year. This thesis represents a significant contribution to the intelligent management of energy demand, integrating advanced time series analysis, clustering, and forecasting techniques to optimize operational and economic efficiency in the power sector.

Keywords: appropriate tariff modality; anomaly detection; time series analysis; consumption forecasting; energy consumer clustering; energy efficiency; desktop application; machine learning.

LISTA DE FIGURAS

Figura 1 – Infraestrutura de rede inteligente no âmbito do Projeto Piloto Latvenergo.	33
Figura 2 – Fontes de produção de energia elétrica.	35
Figura 3 – Demanda Média Anual de Carga elétrica.	38
Figura 4 – O modelo exponencial de consumo de kWh.	38
Figura 5 – Representação de um autoencoder convolucional.	50
Figura 6 – Tarifas de aplicação e base econômica para o grupo A (Enel CE).	79
Figura 7 – Diagrama de Blocos desde o Processo de geração do código para raspagem de dados e acesso ao sistema de telemedição até a análise de dados.	79
Figura 8 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada na cidade de Canindé.	81
Figura 9 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada na cidade de Canindé.	82
Figura 10 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada na cidade de Canindé.	83
Figura 11 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada na cidade de Canindé.	85
Figura 12 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada em Maranguape.	86
Figura 13 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Maranguape.	88
Figura 14 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2023, em kW, na unidade consumidora localizada em Maranguape.	89
Figura 15 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Maranguape.	89
Figura 16 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em Aquiraz.	91
Figura 17 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Aquiraz.	92

Figura 18 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Aquiraz.	93
Figura 19 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Aquiraz.	94
Figura 20 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Pacatuba.	96
Figura 21 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Pacatuba.	96
Figura 22 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Pacatuba.	97
Figura 23 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Pacatuba.	98
Figura 24 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em São Gonçalo do Amarante.	100
Figura 25 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em São Gonçalo do Amarante.	101
Figura 26 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em São Gonçalo do Amarante.	102
Figura 27 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em São Gonçalo do Amarante.	103
Figura 28 – Diagrama de Blocos dos estudos realizados no capítulo 4.	107
Figura 29 – Dendrograma para a escolha do número de grupos utilizando Agrupamento Hierárquico.	108
Figura 30 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do Agrupamento Hierárquico.	109
Figura 31 – Quantidade de unidades consumidoras separadas pelo Agrupamento Hierárquico em cada um dos cinco grupos escolhidos.	109
Figura 32 – Escolha do número de clusters de acordo com o método do cotovelo.	110
Figura 33 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do K-Médias.	111

Figura 34 – Quantidade de unidades consumidoras separadas pelo K-Médias em cada um dos cinco grupos escolhidos.	111
Figura 35 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do BIRCH.	112
Figura 36 – Quantidade de unidades consumidoras separadas pelo BIRCH em cada um dos cinco grupos escolhidos.	113
Figura 37 – Gráfico dos valores do Índice de Davies Bouldin variando de 2 a 10 grupos.	114
Figura 38 – Gráfico dos valores do Índice de Calinski-Harabasz variando de 2 a 10 grupos.	115
Figura 39 – Gráfico dos valores do Coeficiente de Silhueta variando de 2 a 10 grupos.	116
Figura 40 – Gráfico dos valores do Método do Cotovelo variando de 2 a 10 grupos.	117
Figura 41 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do Mini Batch K-Médias.	117
Figura 42 – Quantidade de unidades consumidoras separadas pelo Mini Batch K-Médias em cada um dos cinco grupos escolhidos.	118
Figura 43 – Agrupamento 1 das séries temporais do consumo de energia de unidades públicas.	121
Figura 44 – Agrupamento 2 das séries temporais do consumo de energia de unidades públicas.	122
Figura 45 – Agrupamento 1 das séries temporais do consumo de energia de unidades públicas, utilizando o algoritmo BIRCH com PCA e Autoencoders, com 134 unidades consumidoras.	126
Figura 46 – Agrupamento 2 das séries temporais do consumo de energia de unidades públicas, utilizando o algoritmo BIRCH com PCA e Autoencoders, com 49 unidades consumidoras.	127
Figura 47 – Séries temporais do consumo de energia de clientes pertencentes ao grupo 1.	128
Figura 48 – Séries temporais do consumo de energia de clientes pertencentes ao grupo 2.	129
Figura 49 – Correlações de Pearson entre 20 séries temporais do consumo de energia de unidades consumidoras da CAGECE.	131
Figura 50 – Correlações de Pearson entre 20 séries temporais do consumo de energia de unidades consumidoras de órgãos da Justiça.	132
Figura 51 – Correlações de Spearman entre 20 séries temporais do consumo de energia de unidades consumidoras da CAGECE.	133

Figura 52 – Correlações de Spearman entre 20 séries temporais do consumo de energia de unidades consumidoras de órgãos da Justiça.	134
Figura 53 – Agrupamento 1 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 13 unidades consumidoras.	135
Figura 54 – Agrupamento 2 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 60 unidades consumidoras.	137
Figura 55 – Agrupamento 3 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 46 unidades consumidoras.	137
Figura 56 – Agrupamento 4 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 64 unidades consumidoras.	138
Figura 57 – Série temporal de uma unidade consumidora da Justiça, decomposta de forma mensal, do ano de 2019 ao ano de 2023 em kWh.	140
Figura 58 – Série temporal de uma unidade consumidora da Justiça, decomposta de forma anual, do ano de 2019 ao ano de 2023 em kWh.	141
Figura 59 – Dados históricos originais de consumo medido de janeiro de 2019 a dezembro de 2023, a média móvel e o desvio padrão dos dados em kWh.	142
Figura 60 – Previsão de consumo, em kWh, até 2025 com o modelo Prophet.	143
Figura 61 – Previsão de consumo, em kWh, até 2025 com o modelo SARIMA.	145
Figura 62 – Previsão de consumo, em kWh, até 2025 com o modelo Prophet utilizando variáveis exógenas.	146
Figura 63 – Previsão de consumo, em kWh, até 2025 com o modelo SARIMA utilizando variáveis exógenas.	147
Figura 64 – Tela de carregamento de dados para a aplicação.	151
Figura 65 – Tela de visualização dos dados que a aplicação irá consumir.	152
Figura 66 – Tela de visualização de um dashboard de comparação de valores de faturas e gráficos de consumo e demanda.	153
Figura 67 – Tela de visualização da comparação entre as tarifas e demanda escolhida na ponta e fora de ponta.	154
Figura 68 – Tela de visualização de demandas escolhidas, médias móveis, desvio padrão e demanda medida original, nos horários de ponta e fora de ponta.	155
Figura 69 – Tela de visualização de detecção de anomalias nas demandas dos horários de ponta e fora de ponta.	156

Figura 70 – Tela de visualização da demanda no horário fora de ponta, com sua respectiva tendência, sazonalidade e resíduos. 156

Figura 71 – Tela de visualização da demanda no horário de ponta, com sua respectiva tendência, sazonalidade e resíduos. 157

LISTA DE TABELAS

Tabela 1 – Economia Potencial com Sugestão de Demanda e Mudanças de Métodos Tarifários	104
Tabela 2 – BIRCH	119
Tabela 3 – BIRCH com PCA	123
Tabela 4 – BIRCH com PCA e t-NSE	124
Tabela 5 – BIRCH com PCA e Autoencoders	125
Tabela 6 – Métricas de avaliação para as previsões do modelo Prophet	144
Tabela 7 – Métricas de avaliação para as previsões do modelo SARIMA	145
Tabela 8 – Métricas de avaliação para as previsões do modelo Prophet utilizando variáveis exógenas	147
Tabela 9 – Métricas de avaliação para as previsões do modelo SARIMA com variáveis exógenas	148

LISTA DE ABREVIATURAS E SIGLAS

LSTM	<i>Memória Longa de Curto Prazo (Long Short Term Memory)</i>
RNN	<i>Rede Neural Recorrente (Recurrent Neural Network)</i>
CO2	<i>Dióxido de Carbono</i>
AI	<i>Inteligência Artificial (Artificial intelligence)</i>
ML	<i>Aprendizado de Máquina (Machine Learning)</i>
LR	<i>Regressão Linear (Linear Regression)</i>
SVM	<i>Máquina de Vetores de Suporte (Support Vector Machine)</i>
NB	<i>Naive Bayes</i>
KNN	<i>K-ésimo Vizinho mais Próximo (K Nearest Neighbor)</i>
RN	<i>Redes Neurais</i>
MAE	<i>Erro Médio Absoluto (Mean Absolute Error)</i>
MAPE	<i>Erro Percentual Médio Absoluto (Mean Absolute Percentage Error)</i>
RMSE	<i>Raiz Do Erro Quadrático Médio (Root Mean Squared Error)</i>
ARMA	<i>Auto-Regressivo de Médias Móveis (Autoregressive Moving Average)</i>
ARIMA	<i>Auto-Regressivo Integrado de Médias Móveis(Autoregressive Integrated Moving Average)</i>
SARIMA	<i>Sazonal Auto-Regressivo Integrado de Médias Móveis (Seazonal Autoregressive Integrated Moving Average)</i>
AR	<i>Regressão Automática (Automatic Regression)</i>
MA	<i>Média Móvel (Moving Average)</i>
HESCOM	<i>Empresa de Fornecimento de Eletricidade Hubli Limitada (HUBLI ELECTRICITY SUPPLY COMPANY LIMITED)</i>
MOM	<i>Modelos Ocultos de Markov</i>
MSE	<i>Erro Quadrático Médio (Mean Squared Error)</i>
HWSM	<i>Método Sazonal de Inverno de Holt (Holt-Winters' Seasonal Method)</i>
IF	<i>Floresta Isolada (Isolation Forest)</i>
RAEs	<i>Autoencoders Recorrentes (Recurrent Autoencoders)</i>
CAEs	<i>Autoencoders Convolucionais (Convolutional Autoencoders)</i>
VAE	<i>Autoencoder Variacional (Variational Autoencoder)</i>
CNNs	<i>Redes Neurais Convolucionais (Convolutional Neural Networks)</i>

CAE	<i>Engenharia Assistida por Computador (Computer-Aided Engineering)</i>
PCM	<i>Modulação por Código de Pulso (Pulse-Code Modulation)</i>
WCSS	<i>Soma dos Quadrados dentro do Cluster (Within-Cluster Sum of Squares)</i>
BIRCH	<i>Equilibrado Iterativo Redutor e Agrupador usando Hierarquias (Balanced Iterative Reducing and Clustering using Hierarchies)</i>
PCA	<i>Análise de Componentes Principais (Principal Component Analysis)</i>
CF	<i>Característica de Agrupamento (Clustering Feature)</i>
CMs	<i>Componentes Menores (Minor Components)</i>
MCA	<i>Análise de Componentes Menores (Minor Component Analysis)</i>
t-SNE	<i>t-Distribuição de Proximidade Estocástica (t-Distributed Stochastic Neighbor Embedding)</i>
KL	<i>Divergência de Kullback-Leibler (Kullback-Leibler Divergence)</i>
DNN	<i>Rede Neural Profunda (Deep Neural Network)</i>
ANEEL	<i>Agência Nacional de Energia Elétrica</i>
TUSD	<i>Tarifa de Uso do Sistema</i>
TE	<i>Tarifa de Energia</i>

SUMÁRIO

1	INTRODUÇÃO	24
1.1	Proposta da tese	28
1.2	Objetivo	29
2	FUNDAMENTAÇÃO E DEFINIÇÕES	30
2.1	Introdução	30
2.2	Big data	30
2.3	Telemedição	32
2.4	Análise de dados e predição do consumo de energia e da demanda de potência elétrica	34
2.5	Modelos de machine learning utilizados para previsão e métricas de avaliação de performance para previsões de séries temporais	39
2.5.1	<i>Modelos autoregressivos de médias móveis integradas</i>	39
2.5.2	<i>Modelo Prophet</i>	41
2.5.3	<i>Redes neurais de memória longa de curto prazo</i>	43
2.5.4	<i>DeepAR</i>	44
2.5.5	<i>Métricas de avaliação de performance para previsões de séries temporais</i>	46
2.6	Detecção de anomalias	47
2.7	Autoencoders e embeddings para séries temporais.	49
2.8	Algoritmos de agrupamento e métricas de avaliação	52
2.8.1	<i>Algoritmo K-Médias</i>	52
2.8.1.1	<i>MINI-BATCH K-Médias</i>	54
2.8.2	<i>Agrupamento Hierárquico</i>	56
2.8.3	<i>Algoritmo BIRCH</i>	57
2.8.4	<i>Métricas de avaliação de agrupamentos</i>	59
2.8.4.1	<i>Coeficiente de Silhueta</i>	59
2.8.4.2	<i>índice de Calinski-Harabasz</i>	60
2.8.4.3	<i>índice de Davies-Bouldin</i>	61
2.9	Algoritmos de redução de dimensionalidade	62
2.9.1	<i>Análise de Componentes Principais (PCA)</i>	62
2.9.2	<i>t-Distribuição de Proximidade Estocástica (t-SNE)</i>	64

2.10	Padronização e normalização de dados	68
<i>2.10.1</i>	<i>Padronização Z-score</i>	68
<i>2.10.2</i>	<i>Normalização de máximo e mínimo</i>	69
2.11	Coeficientes de correlação de Pearson e de Spearman	69
<i>2.11.1</i>	<i>Coeficiente de correlação de Pearson</i>	69
<i>2.11.2</i>	<i>Coeficiente de correlação de Spearman</i>	71
2.12	Demanda elétrica	72
2.13	Posto tarifário	72
2.14	Modalidade tarifária e tarifação	73
<i>2.14.1</i>	<i>Tipos de modalidade tarifária</i>	73
<i>2.14.1.1</i>	<i>Modalidade tarifária convencional</i>	73
<i>2.14.1.2</i>	<i>Modalidade tarifária horária branca</i>	73
<i>2.14.1.3</i>	<i>Modalidade tarifária horária verde</i>	74
<i>2.14.1.4</i>	<i>Modalidade tarifária horária azul</i>	74
<i>2.14.1.5</i>	<i>Grupo B de unidades consumidoras de energia elétrica</i>	75
<i>2.14.1.6</i>	<i>Grupo A de unidades consumidoras de energia elétrica</i>	75
2.15	Considerações finais	76
3	IDENTIFICAÇÃO DE ANOMALIAS E PADRÕES DE DEMANDA IRREGULARES EM UNIDADES CONSUMIDORAS DE ENERGIA ELÉTRICA DO GRUPO A	78
3.1	Introdução	78
3.2	Análise de séries temporais e detecção de comportamentos anormais na demanda elétrica de unidades consumidoras de energia elétrica	79
3.3	Considerações finais	104
4	AGRUPAMENTO DE UNIDADES CONSUMIDORAS DE ENERGIA ELÉTRICA PELA DEMANDA E PELO CONSUMO DE ENERGIA E PREVISÃO DO CONSUMO ELÉTRICO	106
4.1	Introdução	106
4.2	Agrupamento de unidades consumidoras pela demanda contratada e pelo consumo médio mensal	107
<i>4.2.1</i>	<i>Agrupamento hierárquico</i>	107
<i>4.2.2</i>	<i>Agrupamento com K-Médias</i>	109

4.2.3	<i>Agrupamento com BIRCH</i>	112
4.2.4	<i>Agrupamento com Mini Batch K-Médias</i>	113
4.3	Agrupamento de séries temporais do consumo de energia de unidades consumidoras	118
4.4	Previsão de séries temporais do consumo de energia de unidades consumidoras	139
4.4.1	<i>Previsões univariadas</i>	143
4.4.2	<i>Previsões univariadas com variáveis exógenas</i>	146
4.5	Recomendações práticas para gestores de energia e formuladores de políticas públicas	148
4.6	Considerações finais	149
5	CRIAÇÃO DE APLICAÇÃO DESKTOP PARA CÁLCULO DE COMPARAÇÃO DE FATURAS E DETECÇÃO DE ANOMALIAS	150
5.1	Introdução	150
5.2	Construção da aplicação desktop	150
5.2.1	<i>Apresentação das telas da aplicação desktop</i>	150
5.2.1.1	<i>Tela de carregamento de dados</i>	150
5.3	Considerações finais	157
6	CONCLUSÕES, TRABALHOS FUTUROS E CRONOGRAMA DE CONTINUAÇÃO DO TRABALHO	158
6.1	Conclusões	158
6.2	Trabalhos futuros	159
	REFERÊNCIAS	160
	APÊNDICES	171
	APÊNDICE A–PARTE DO CÓDIGO DA APLICAÇÃO DESKTOP QUE MOSTRA A CRIAÇÃO DO ALGORITMO POR REGRAS (CRIADO COM A LINGUAGEM DE PROGRAMAÇÃO PYTHON)	171
	APÊNDICE B–SUGESTÕES DE DEMANDAS CONTRATADAS E DE MODALIDADE TARIFÁRIA ADEQUADAS PARA AS UNIDADES CONSUMIDORAS ESTUDADAS NESTA TESE	177

APÊNDICE C-DIVISÃO DAS UNIDADES CONSUMIDORAS EM GRUPOS PELOS PADRÕES QUE APRESENTAM, COMO COMPORTAMENTOS SEMELHANTES DO CONSUMO DE ENERGIA AO LONGO DO ANO E/OU ANOMALIAS	183
APÊNDICE D-RELAÇÃO DAS UNIDADES CONSUMIDORAS PELO <i>VALOR QUE PAGARAM NO ANO ESTUDADO, MULTA POR ULTRAPASSAGEM DE DEMANDA, O VALOR QUE A FATURA FICARIA SE NÃO EXISTISSE A MULTA, O VALOR DA MULTA POR ULTRAPASSA- GEM DE DEMANDA CONTRATADA, O VALOR DA FATURA COM A MODALIDADE TARIFÁRIA E A DEMANDA CONTRATADA SUGERIDAS E A MULTA POR EXCEDENTE DE ENERGIA REATIVA</i>	186

1 INTRODUÇÃO

Segundo Zainal *et al.* (2022), à medida que a população mundial cresce, a demanda por energia aumenta drasticamente. Unidades consumidoras industriais e comerciais estão envolvidas nessa demanda por energia. Muitas vezes o consumo excede a real necessidade, resultando em muito desperdício. O uso ineficiente da energia pode levar a elevados custos operacionais. Assim, um problema comumente conhecido hoje em dia é a eficiência da energia. Muitos edifícios têm baixa eficiência operacional e baixa gestão do uso de energia, levando a desperdícios desnecessários. Estatisticamente, o consumo de eletricidade per capita aumentou de 3.900 kWh per capita em 2010 para 4.750 kWh per capita em 2019. As outras razões para os elevados custos de energia incluem sobretaxas cobradas por picos de demanda e fator de potência. A sobretaxa de demanda é uma multa cobrada pela ultrapassagem da demanda máxima de potência de um edifício comercial ou industrial, mesmo que num curto período. O consumo de eletricidade é representado em mais da metade por unidades consumidoras comerciais e industriais.

Como relata Buddhahai *et al.* (2019), a eficiência energética é uma das principais medidas para reduzir o consumo de energia, mantendo um serviço constante ou um nível aceitável de conforto para unidades consumidoras de energia. Os consumidores devem ter a percepção correta e o controle de realmente quanta energia necessitam a fim de evitar custos adicionais. Assim, um plano eficaz para a economia de energia, seria o controle adequado de aparelhos de alta potência. Com o esquema de gestão da energia, sabendo realmente quando ligar equipamentos de alta potência e evitar picos de demanda nos horários fora de ponta e no horário de ponta, pode-se reduzir os custos da tarifa de energia.

Conforme Numbi *et al.* (2017), o processo de auditoria energética, também conhecido como levantamento energético ou avaliação energética, é o primeiro passo em qualquer projeto de gestão de energia. Tanto as nações desenvolvidas como as em desenvolvimento vem realizando exercícios de auditoria energética. Além disso, vários autores ao redor do mundo relataram os processos de auditoria de energia, experiências e resultados. Esse processo consiste na aplicação de métodos de análise energética para avaliar tendências e padrões de consumo de energia em instalações de edifícios , processos industriais, etc. e identificar alternativas econômicas para reduzir custos de energia, Capehart *et al.* (2013).

Segundo Dang *et al.* (2023), ao empregar técnicas estatísticas e inteligência artificial, os gestores de energia podem prontamente identificar o uso anômalo de energia e determinar suas

causas subjacentes. Existem vários algoritmos de aprendizado de máquina robustos o bastante para atuar como detectores de anomalias; contudo, é crucial que os algoritmos candidatos sejam suficientemente precisos e apresentem uma resposta rápida para serem aplicados na indústria. Graças ao desempenho adequado em diferentes tipos de detecção de anomalias não supervisionadas, a abordagem do Algoritmo de Fator de Excentricidade Local (Local Outlier Factor Algorithm) foi selecionada. No estudo conduzido por Dang *et al.* (2023), foi possível identificar padrões anormais de consumo de energia visando a prevenção de perdas energéticas e a promoção de manutenção preditiva em uma fábrica de processamento de bebidas no Vietnã. O escore de anomalia foi avaliado para detectar anomalias multivariadas e de subsequência. Por fim, séries temporais de consumo de energia com pontos anômalos destacados foram disponibilizadas para que os gestores pudessem tomar medidas em relação às anomalias no consumo de energia.

O estudo de Nam *et al.* (2020) propõe um esquema de detecção de anomalias baseado em autoencoder *Memória Longa de Curto Prazo (Long Short Term Memory)* (LSTM) para gestão de energia, que visa prevenir estados anômalos antes que realmente ocorram. Quando o prognóstico de um estado anômalo é detectado, o estado anômalo pode ser prevenido por meio de medidas apropriadas. No entanto, é difícil determinar dados normais e anômalos, uma vez que o consumo de energia varia consideravelmente dependendo do clima, hora, dia da semana e estação. Assim, este artigo propõe um esquema de detecção de anomalias usando autoencoder LSTM para detectar um padrão de dados que se desvia do padrão de dados normal e determiná-lo como um estado anômalo. Os resultados experimentais mostram que este esquema pode discriminar anomalias dos dados multivariados observados e pode ser utilizado para prevenir falhas e operações incorretas antecipadamente.

O artigo de Çetinkaya *et al.* (2020) trata da importância da análise de dados nos sistemas de energia, destacando o uso da análise de clustering de dados de consumo para atividades de operação de rede. O estudo desenvolveu um programa usando a linguagem MATLAB para analisar séries temporais de consumo de diferentes redes de distribuição, apresentando visualmente os resultados anuais, mensais e por hora. A análise de clustering revelou que várias regiões de distribuição podem ser agrupadas com base na similaridade de consumo, facilitando o gerenciamento correspondente à resolução temporal. Em resumo, o estudo demonstrou a utilidade da análise de clustering para agrupar redes de distribuição e sugeriu a aplicação de diferentes métodos de clustering e dados reais de rede para diversos fins, como geração, mercado e falhas, visando melhorar a operação do sistema de energia. A clusterização no estudo é feita

em séries temporais de consumo de energia. Essas séries temporais representam os padrões de consumo de energia ao longo do tempo em diferentes redes de distribuição. A análise de clustering busca agrupar essas séries temporais com base na similaridade de seus padrões de consumo, permitindo uma melhor compreensão e gerenciamento das redes de distribuição de energia elétrica.

O estudo de Lukács *et al.* (2023) apresenta uma análise do consumo de energia e da produção fotovoltaica de uma pequena empresa industrial, explorando a aplicação de métodos de aprendizado de máquina para previsões. Os dados foram coletados ao longo de quatro meses, com medições realizadas a cada 15 minutos usando um analisador de energia e acesso online aos dados do inversor para a produção fotovoltaica. O estudo compara dois casos de previsão: no primeiro, os modelos são aplicados diretamente ao balanço de eletricidade, enquanto no segundo, os modelos são aplicados separadamente à produção fotovoltaica e ao consumo, sendo posteriormente somados. Foram utilizados algoritmos de regressão linear e redes neurais, como Multilayer Perceptron e *Rede Neural Recorrente (Recurrent Neural Network)* (RNN), incluindo uma variação chamada Unidade Recorrente com Portões (Gated Recurrent Unit) (GRU). Os dados meteorológicos foram obtidos de uma API de clima. A implementação foi realizada usando a plataforma Tensorflow e as bibliotecas Keras, com Scikit-learn, Numpy e Seaborn para processamento e visualização de dados. Os resultados mostraram que, ao prever separadamente a produção fotovoltaica e o consumo, melhores resultados foram obtidos do que ao prever diretamente o balanço de eletricidade. O modelo GRU apresentou os menores erros de previsão e foi mais adequado para a aquisição de energia. A análise também destacou a importância do monitoramento, automação e digitalização para reduzir os erros de previsão e otimizar o fluxo de energia com mínimas perdas financeiras. A previsão desempenha um papel crucial neste artigo, pois permite antecipar o comportamento do consumo de energia e da produção fotovoltaica em uma empresa industrial. Isso é fundamental para garantir a estabilidade e a eficiência do sistema elétrico, especialmente considerando a crescente integração de fontes de energia renovável, como a energia solar fotovoltaica. Ao prever o consumo de energia e a produção fotovoltaica, a empresa pode tomar medidas proativas para otimizar o uso de energia, reduzir custos, minimizar perdas e melhorar a eficiência operacional. Isso é especialmente importante em um contexto onde as flutuações na produção de energia solar são frequentes e imprevisíveis devido às variações nas condições climáticas. Além disso, a previsão é essencial para ajudar os fornecedores de energia a planejar e gerenciar suas operações de forma mais eficaz. Ao ter uma visão antecipada da

demandas e da oferta de energia, eles podem tomar decisões informadas sobre o fornecimento de energia, evitar picos de demanda e garantir o equilíbrio entre oferta e demanda no mercado de energia. Portanto, a previsão desempenha um papel fundamental na maximização da eficiência energética, na redução dos custos operacionais e na garantia da confiabilidade do sistema elétrico, tornando-se uma ferramenta essencial para empresas industriais e fornecedores de energia.

A análise de dados de consumo de energia, demanda, análise de séries temporais do consumo de energia, clusterização de consumo e demanda, clusterização de séries temporais do consumo de energia e previsão do consumo de energia desempenham papéis fundamentais na gestão eficiente e eficaz dos sistemas elétricos contemporâneos. Essas práticas analíticas proporcionam insights valiosos e ferramentas poderosas para os operadores de rede, planejadores energéticos e consumidores, promovendo uma operação mais confiável, econômica e sustentável dos sistemas de energia. A análise de dados de consumo de energia e demanda elétrica permite uma compreensão detalhada dos padrões de consumo ao longo do tempo, identificando tendências, sazonalidades, anomalias e variações significativas. Essa compreensão é essencial para a otimização do planejamento energético, a previsão da demanda futura e a identificação de oportunidades de eficiência energética. Além disso, a análise de séries temporais de energia permite a detecção precoce de anomalias e falhas no sistema, contribuindo para uma resposta mais rápida e eficaz a eventos inesperados. A análise de dados de séries temporais fornece insights detalhados sobre o comportamento do consumo ao longo do tempo. Por meio da detecção de padrões incomuns, flutuações anômalas ou eventos atípicos, como picos de consumo repentinos ou quedas significativas na demanda, essa análise permite identificar potenciais problemas. A clusterização de consumo e demanda agrupa consumidores ou padrões de consumo semelhantes, permitindo uma abordagem mais segmentada e personalizada para a gestão da demanda. Isso possibilita a implementação de estratégias de resposta à demanda mais eficientes e a concepção de tarifas de energia mais adequadas às necessidades específicas dos diferentes grupos de consumidores. Da mesma forma, a clusterização de séries temporais do consumo de energia agrupa padrões de consumo semelhantes ao longo do tempo, facilitando a identificação de tendências, sazonalidades específicas e padrões anormais, isto é, anomalias no consumo de energia. Essa abordagem é fundamental para o desenvolvimento de modelos de previsão mais precisos e confiáveis, permitindo uma melhor gestão dos recursos energéticos e uma operação mais eficiente do sistema elétrico. Em suma, a aplicação dessas técnicas analíticas proporciona uma visão abrangente e detalhada do comportamento do consumo de energia e demanda elétrica,

capacitando os atores do setor elétrico a tomar decisões informadas e estratégicas para garantir a estabilidade, confiabilidade e sustentabilidade dos sistemas de energia.

1.1 Proposta da tese

A presente proposta de tese de doutorado visa explorar métodos avançados para a gestão eficiente da demanda de energia elétrica em unidades consumidoras. O foco principal será na análise de dados de unidades consumidoras de energia elétrica, detecção de anomalias, clusterização de consumidores e previsão de consumo por meio de séries temporais. Inicialmente a pesquisa está concentrada na aplicação de técnicas de análise de séries temporais e algoritmos especializados para a detecção de anomalias nas demandas medidas de unidades consumidoras. Esse primeiro passo visa identificar comportamentos atípicos que podem influenciar negativamente na eficiência operacional e econômica. Além disso, é proposta a identificação de clientes anômalos por meio da clusterização de consumos médios mensais e demanda contratada. Essa abordagem permitirá agrupar consumidores com padrões semelhantes, proporcionando insights valiosos sobre as características distintas desses grupos em termos de padrões de consumo, comportamentos de tendências e sazonalidades. Depois disso, as séries temporais do consumo elétrico serão agrupadas para se observar padrões específicos de cada grupo e detectar picos de consumo, que podem também mostrar outliers na demanda de energia medida. Outro aspecto crucial desta pesquisa é a utilização de séries temporais altamente correlacionadas para prever o consumo de novas unidades consumidoras ou aquelas com histórico limitado. Essa abordagem, apoiada pelos coeficientes de Pearson e Spearman, proporcionará uma visão mais precisa do comportamento de consumo ao longo do ano, auxiliando na determinação do nível de consumo necessário e na definição da demanda contratada mais adequada. A pesquisa avançará para a criação de uma aplicação desktop especializada, capaz de analisar dados de demanda e consumo elétrico. Essa ferramenta integrará funcionalidades para a escolha da melhor tarifação, distinguindo entre tarifas verde e azul, especialmente direcionadas ao Grupo A de consumidores de energia. A aplicação também destacará estatísticas essenciais, como média e desvio padrão, além de permitir a comparação de custos atuais com diferentes opções tarifárias. A aplicação contará com abas de detecção de anomalias e observação da tendência e da sazonalidade de determinada série temporal de uma unidade consumidora de energia.

1.2 Objetivo

O objetivo desta tese é contribuir significativamente para a gestão inteligente da demanda de energia elétrica, integrando metodologias avançadas de detecção de anomalias, clusterização, correlação e previsão. Proporcionar uma ferramenta prática para profissionais do setor elétrico. A aplicabilidade prática desses métodos visa otimizar a eficiência operacional e econômica, proporcionando uma abordagem abrangente e inovadora para o setor elétrico. Embora que os métodos individuais de clusterização, previsão, detecção de anomalias, etc., já existam. O que torna a pesquisa inovadora é a combinação e aplicação específica desses métodos para resolver um problema ou desafio específico no contexto da gestão de demanda de energia elétrica. A forma como esses métodos são integrados, da maneira como estão sendo utilizados juntos para atender às necessidades do setor elétrico, mostra a inovação da pesquisa. Além disso, o desenvolvimento da aplicação desktop personalizada para análise de dados e tomada de decisões tarifárias também contribui para a inovação, pois representa uma ferramenta prática e específica para o setor. Portanto, a inovação reside na forma como esses métodos são combinados, adaptados e aplicados para resolver desafios específicos no contexto da gestão de demanda de energia elétrica.

2 FUNDAMENTAÇÃO E DEFINIÇÕES

2.1 Introdução

Neste capítulo serão abordados assuntos referentes à análise de dados de energia e demanda elétrica, anomalias encontradas na demanda e no consumo elétrico, modalidades tarifárias para o grupo A e outros tópicos em relação a aspectos normativos sobre o sistema de tarifação brasileiro para o grupo A e outros conceitos referentes à aplicação de algoritmos de machine learning para detecção de anomalias, previsão de séries temporais e agrupamento de clientes de energia.

2.2 Big data

De acordo com Sagiroglu e Sinanc (2013), big data é um termo para conjuntos massivos de dados que têm estrutura grande, variada e complexa com as dificuldades de armazenar, analisar e visualizar processos ou resultados. É o processo de pesquisa de grandes quantidades de dados para revelar padrões ocultos e correlações secretas. Estas informações são úteis para empresas ou organizações e visam ajudar a obter insights mais ricos e profundos e obter vantagem sobre a concorrência. Por esta razão, implementações de big data precisam ser analisadas e executadas com a maior precisão possível. Segundo Schneider (2012), big data e suas análises estão no centro da ciência moderna e dos negócios. Esses dados são gerados on-line transações, e-mails, vídeos, áudios, imagens, fluxos de cliques, registros, postagens, consultas de pesquisa, registros de saúde, redes interações em redes sociais, dados científicos, sensores e telefones celulares e seus aplicativos. Eles são armazenados em bancos de dados crescentes massivamente e tornam-se difíceis de capturar, formar, armazenar, gerenciar.

Conforme relatado por Zhou *et al.* (2017), a mineração de dados consiste na exploração de conhecimentos ou leis de valor significativo para indivíduos, a partir de um vasto conjunto de informações que são, em sua maior parte, incompletas e irregulares. Objetos de mineração de dados visam principalmente dados em grandes bancos de dados. O processo que engloba a limpeza de dados, integração, conversão, análise, avaliação de modelo e representação do conhecimento derivado de dados empresariais fornece aos usuários informações preciosas, auxiliando assim na tomada de decisões no âmbito dos negócios.

De acordo com Qu *et al.* (2015) e Wen *et al.* (2018), uma vasta quantidade de

dados sobre o consumo de energia é coletada dos consumidores de energia e armazenada no lado dos fornecedores de energia elétrica (ou fornecedores de energia). Esses dados estão se acumulando de forma massiva devido à implementações de redes inteligentes, com a utilização de instrumentos inteligentes abrangentes. Informações implícitas nos dados podem ser descobertas, por exemplo, o comportamento dos clientes em relação ao consumo de energia, beneficiará a companhia elétrica para otimizar a energia oferecendo eficiência e atualizando o nível de atendimento ao cliente. Os resultados podem incluir a detecção de anomalias e a correção desses problemas, a análise das características comportamentais dos clientes, a correlação entre diferentes setores e a potencial aplicação comercial dos dados provenientes de redes inteligentes. Com o desenvolvimento de redes inteligentes e o alto grau de integração entre a indústria de energia e a tecnologia da informação, foram produzidos, coletados e armazenados grandes quantidades de dados relacionados à geração de energia, transmissão, consumo, monitoramento de status em tempo real, além de dados climáticos e geográficos.

Em concordância com Aiello e Pagani (2014) e Alahakoon e Yu (2013), a análise do cliente é um dos domínios mais atraentes para empresas de serviços públicos porque podem gerar grande valor a partir de dados de redes inteligentes. Os dados de consumo de energia do lado do cliente implicam a característica do comportamento do cliente, o que pode ser útil para definir o perfil de consumo de eletricidade de unidades consumidoras de setores comerciais, residenciais e industriais, apoio à decisão sobre preços de eletricidade e outros serviços de valor agregado. Por isso, como descobrir a informação implícita nos dados de consumo e demanda de energia por técnicas estatísticas, ciência de dados e aprendizado de máquina com o auxílio do big data, é muito importante para apoiar empresas elétricas na otimização do consumo de energia oferecendo eficiência e melhorando o nível de atendimento ao cliente. Além disso, pode ajudar o cliente a conhecer melhor sua real necessidade de consumo e demanda elétrica.

Segundo (Liu *et al.* (2020) e Correa *et al.* (2018)), com o desenvolvimento e aplicação de sistemas avançados de medição e distribuição de energia, juntamente com sistemas de coleta de informações, os dados provenientes do lado do usuário aumentaram geometricamente. Diante de dados massivos, a mineração e a análise das características de uso desses dados tornam-se uns dos principais desafios da atual análise de big data. Características do comportamento e da demanda de potência elétrica estão escondidas na grande quantidade de dados coletados pelas telemedições. Entender o comportamento da demanda e do consumo dos usuários residenciais, comerciais e industriais é chave para compreender as necessidades individuais dos usuários,

melhorando o nível de serviço das empresas de energia e a estabilidade da rede elétrica. Isso pode ser feito através de uma análise aprofundada de comportamento do consumo de energia do usuário, pesquisas sobre tipos de usuários e avaliação do uso do sistema de energia. Organizar racionalmente a operação otimizada de equipamentos elétricos pode reduzir o pico de carga da rede elétrica e evitar multas por ultrapassagem de demanda e fator de potência abaixo do estabelecido em norma.

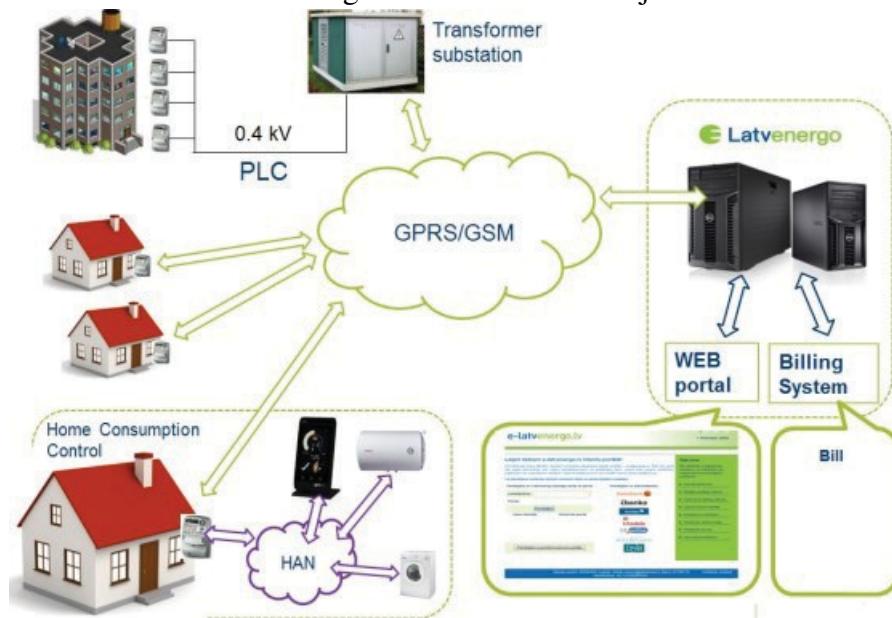
2.3 Telemedição

Como explicam Sauhats *et al.* (2015), é cada vez mais importante para os comercializadores de energia conhecer o comportamento e o perfil de consumo de seus clientes. Da mesma forma, para as unidades consumidoras, ter controle sobre sua demanda e consumo energia é crucial. A utilização de dados de telemetria permite que os fornecedores de eletricidade estejam melhor preparados para atender às necessidades de seus consumidores. Além disso, soluções tecnológicas inteligentes oferecem a capacidade não apenas de obter perfis detalhados de consumo de energia, mas também de influenciar as decisões de consumo dos clientes e gerenciar a resposta à demanda de forma eficaz.

Em Sauhats *et al.* (2015) está sendo feita a aplicação de dados de medidores inteligentes para prever o consumo de eletricidade dos consumidores residenciais. A disponibilidade e quantidade de dados são adequadas para a análise estatística aprofundada dos perfis de consumo de energia elétrica e para o estudo do comportamento do consumidor. A previsão do consumo de eletricidade é muito importante para que os comercializadores de eletricidade possam equilibrar a sua carteira de compras e vendas de eletricidade, bem como para ter preços acessíveis para os seus clientes. Foram analisados dados de consumo de energia elétrica de 500 consumidores divididos em 6 grupos de consumidores. Os dados de consumo foram derivados de medidores inteligentes. Como próximo passo, seriam aplicados métodos modernos de previsão do consumo de energia para prever o consumo das famílias. O Projeto Piloto, que visa a promoção da eficiência energética nos agregados familiares, foi implementado pela empresa de energia Latvenergo em 2013, através da instalação de medidores inteligentes em 500 agregados familiares, selecionados e segmentados em 6 grupos por consumo médio mensal de energia elétrica. Os clientes receberam dados de consumo de energia elétrica no portal do cliente Latvenergo (www.e-latvenergo.lv). O Portal disponibiliza aos clientes informações detalhadas sobre seu perfil de carga com intervalo de tempo a cada 5 minutos. Também é possível observar dados

de consumo de energia, carga elétrica e emissão de *Dióxido de Carbono* (CO₂) para diferentes períodos de tempo. Com o Projeto Piloto foi desenvolvida a aplicação para smartphone para visualização dos dados de consumo de energia do portal do Cliente. Na Figura 1 pode-se observar a infraestrutura de rede inteligente no âmbito do Projeto Piloto Latvenergo.

Figura 1 – Infraestrutura de rede inteligente no âmbito do Projeto Piloto Latvenergo.



Fonte: Sauhats et al. (2015).

Para fazer previsões de cargas elétricas diárias, é necessário analisar dados históricos e determinar os fatores que causam alterações na carga. Levando em consideração que a carga é uma variável aleatória, uma teoria de probabilidade e métodos estatísticos devem ser utilizados para esta análise.

Segundo Amin *et al.* (2019), as empresas têm substituído os obsoletos medidores analógicos pelas novas versões de medidores inteligentes para capturar automaticamente informações sobre o consumo de eletricidade com uma granularidade de tempo precisa e transmiti-las de volta ao fornecedor de serviços públicos. A previsão de demanda energética é essencial para as operações de redes inteligentes. A capacidade de realizar análises de dados nas medições coletadas do medidor inteligente e então prever as demandas de eletricidade desempenha um papel importante na tomada de decisão das empresas de serviços públicos para o seu sistema de planejamento e operações e para os consumidores analisarem seu consumo e demanda. A iniciativa de redes inteligentes representa uma oportunidade sem precedentes para modernizar a indústria energética e a sua infraestrutura para geração mais eficiente e confiável e transmissão de eletricidade, reduzindo ao mesmo tempo a operação e custo de gerenciamento. Um dos

componentes facilitadores das redes inteligentes é a Infraestrutura de Medição Avançada. A Infraestrutura de Medição Avançada é um sistema integrado de medidores inteligentes, redes de comunicação e sistemas de gerenciamento de dados, que suporta comunicação bidirecional entre concessionárias e clientes.

Conforme Zhang *et al.* (2018), com o desenvolvimento das tecnologias de medição inteligente de eletricidade, enormes quantidades de dados de consumo podem ser recuperadas diariamente, de hora em hora e até medições de 15 em 15 minutos. A previsão de consumo de energia facilita o gerenciamento da demanda de eletricidade e o planejamento da carga das concessionárias. O acelerado desenvolvimento de tecnologias de medição inteligente tornou possível medir, coletar e apresentar informações de consumo de energia elétrica. A modelagem e previsão de eletricidade usando dados de medidores inteligentes ajuda concessionárias a implementar uma gestão de carga eficaz do lado da demanda e fornecer serviços residenciais personalizados.

Como consta em Liu *et al.* (2017), Wijaya *et al.* (2015), e em Shvedov *et al.* (2022), o número de estudos de pesquisa sobre consumo de energia, incluindo consumo anual para diversos usos, características impactando o uso de energia e a previsão de consumo, está aumentando dramaticamente com a implantação de medidores inteligentes e outros métodos de coleta de dados. Muitos estudos exploraram abordagens de aprendizado de máquina para modelagem de consumo de energia, aplicadas nos setores comercial e residencial.

2.4 Análise de dados e predição do consumo de energia e da demanda de potência elétrica

Segundo Sias *et al.* (2023), é impossível evitar a implementação de *Inteligência Artificial (Artificial intelligence)* (AI) em todas as áreas da vida, inclusive para análise a grande quantidade de dados digitais. Quanto maior o volume de dados armazenados, mais complexa será a análise e será necessária a tecnologia mais atualizada. A habilidade de previsão é necessária em diversas áreas, como prever a localização das rotas de transporte e necessidades logísticas, previsão de estacionamentos em cidades inteligentes e assim por diante, como pode ser visto em Tsolaki *et al.* (2022) e em Jin *et al.* (2022). Hoje, à medida que a rede elétrica se torna cada vez mais complexa e interativa, é claramente necessária uma boa gestão para melhorar a segurança, a eficiência e os custos. Uma das importantes atividades em gestão de energia é prever a demanda de energia com precisão. A diferença entre a procura e a oferta de energia torna-se elevada devido ao aumento dos tipos de equipamentos elétricos.

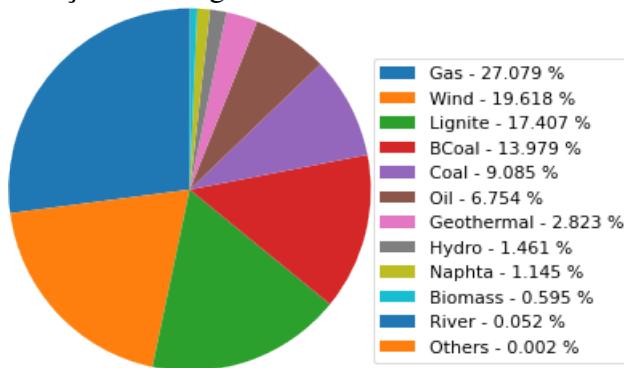
Conforme Patel *et al.* (2022), para efeitos de gestão de energia, vários estudos têm implemento *Aprendizado de Máquina (Machine Learning)* (ML), métodos utilizados como a *Regressão Linear (Linear Regression)* (LR), *Máquina de Vetores de Suporte (Support Vector Machine)* (SVM), *Naive Bayes* (NB), árvore de decisão, *K-ésimo Vizinho mais Próximo (K Nearest Neighbor)* (KNN) e *Redes Neurais* (RN).

Em Sias *et al.* (2023), pode-se ver a implementação de uma LR simples e de uma LR múltipla para previsão do consumo de energia com base em dados anteriores de produção de energia. Na equação 2.1 é mostrada uma LR simples com uma variável de saída dependente e uma variável de entrada independente. Na equação 2.2 é descrita uma variável de saída dependente e múltiplas variáveis independentes de entrada. Se não houver perda de energia, a correlação entre energia consumida e a produção de energia será perfeita. A utilização do modelo de LR foi escolhida porque está em conformidade com a lei do balanço energético nos dados analisados nesse artigo citado. A variável de saída utilizada como objeto deste trabalho é a demanda real de energia ou o consumo de energia diário. A variável de entrada usada são dados da produção de energia elétrica a partir de várias as fontes de eletricidade como mostrado na Figura 2.

$$y = \beta_0 + \beta_1 x \quad (2.1)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \dots \quad (2.2)$$

Figura 2 – Fontes de produção de energia elétrica.



Fonte: Sias et al. (2023).

Os dados usados para construir o modelo são de um ano de dados de consumo de energia elétrica e produção de energia de vários fontes de energia (gás, carvão, geotérmica,

hídrica, eólica, biomassa e petróleo) na Turquia de 2021 a 2022. São detalhados em dados diários de energia que podem ser usados como referência para previsões anuais. Os dados registrados são de hora em hora, para que sejam somados antecipadamente por 24 horas para obter dados diários tanto do lado da produção quanto do lado do consumo de eletricidade. O modelo pode ser avaliado pelo *Erro Médio Absoluto (Mean Absolute Error)* (MAE), *Erro Percentual Médio Absoluto (Mean Absolute Percentage Error)* (MAPE) e a *Raiz Do Erro Quadrático Médio (Root Mean Squared Error)* (RMSE). A avaliação do modelo neste artigo mencionado usa apenas MAE e RMSE porque MAPE corresponde ao MAE em termos percentuais Alquthami *et al.* (2022).

De acordo com Vijayan (2022), a previsão de carga é uma das etapas mais importantes para manter o equilíbrio entre a oferta e a demanda e a estabilidade num sistema de potência. Com o advento da inteligência artificial e das ferramentas de aprendizagem de máquina, a previsão de carga/consumo de energia é conduzida com maior precisão. O ML é um subconjunto da AI que faz o sistema aprender consigo mesmo sem a necessidade de intervenção humana. Todo ML vem sob a AI, mas nem toda AI é ML. A aprendizagem ML é uma parte da AI que cria sistemas que aprendem automaticamente. Sistema esse que aprende a partir de um algoritmo que analisa os dados históricos e é capaz de prever o comportamento futuro. Atualmente o mundo está enfrentando uma enorme demanda por eletricidade. Portanto, sua produção, consumo e armazenamento tornam-se vitais. A previsão precisa da demanda de energia ajuda a evitar o excesso de produção, isso auxilia os sistemas de gestão de energia.

Como consta em Hu (2017), a previsão do consumo de energia em residências e edifícios comerciais tem sido uma área crescente de pesquisa nos últimos anos. Os métodos utilizados para prever a demanda e o consumo de energia podem ser categorizados em três principais áreas: engenharia, abordagens estatísticas e AI.

Como relata Nichiforov *et al.* (2017), modelos projetados usando métodos estatísticos como modelos *Auto-Regressivo de Médias Móveis (Autoregressive Moving Average)* (ARMA) e *Auto-Regressivo Integrado de Médias Móveis (Autoregressive Integrated Moving Average)* (ARIMA) produzem bons resultados para previsão. Métodos que envolvem AI como pode-se ver em Sulaiman *et al.* (2016), métodos baseados em RN, SVM, e lógica fuzzy são aplicados para capturar problemas não lineares, relações complexas entre entradas e saídas. Compreender os padrões e tendências de consumo de energia no setor residencial e industrial é crucial para que as empresas de serviços públicos possam apoiar e fornecer adequadamente os seus serviços atuais e futuros. Além disso, permite que os consumidores de energia evitem multas por ultrapassagem

de demanda e por baixo fator de potência, por exemplo. A precisão da previsão da demanda depende da capacidade de caracterizar padrões de demanda de energia e reconhecer tendências para mudanças esperadas nas demandas futuras.

Em conformidade com Sahagun *et al.* (2018), a gestão cuidadosa do consumo de energia é de fato vital. O consumo de energia pode ser gerido de forma eficaz, se for quantificado com precisão; isso permite o desenvolvimento da consciência sobre quanta energia está sendo consumida dentro de instituições, residências ou instalações industriais.

Como mostra Chou e Ngo (2016), a previsão é importante porque a demanda de carga futura é incerta, então a previsão ajuda no planejamento de recursos e auxilia em conhecer o comportamento dos sistemas de energia.

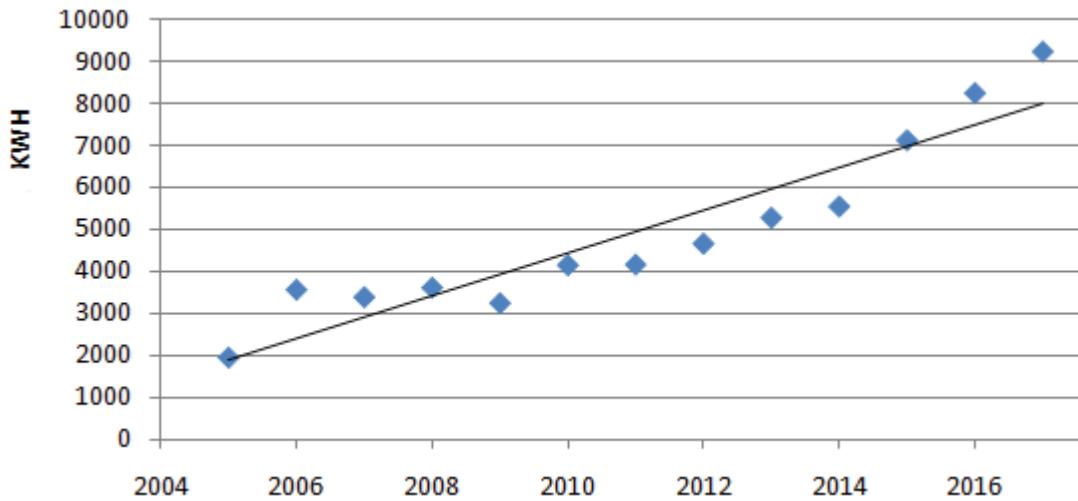
Em um estudo realizado por Sahagun *et al.* (2018), foi utilizada a técnica de análises de séries temporais e um modelo não linear para avaliar o consumo de energia. O objetivo do estudo foi avaliar a situação elétrica atual e futura da demanda de carga da Universidade Estadual Tecnológica Don Honorio - Campus Principal. Especificamente, para avaliar sua alocação de cargas e de demanda de carga; analisar a tendência de carga pelo histórico elétrico e prever a demanda de carga de eletricidade para cinco anos à frente.

Na Figura 3 é mostrada a média do consumo da potência elétrica anual de 2005 a 2017 na unidade consumidora. Um aumento de 45,11% ocorreu entre 2005 e 2006, o que se deve à mudança de administração. Entre 2009 e 2010, a demanda de carga aumentou em 21,7%, esse aumento ocorreu no processo de transformação da instituição em universidade. O consumo histórico de energia do sistema existente foi usado para realizar previsões de carga de médio prazo. A previsão de cinco anos à frente usando um modelo de regressão exponencial pode ser vista na Figura 4.

Consoante Yoo e Lee (2013), padrões de informação de consumo e demanda de unidades consumidoras, assim como a análise dos dados coletados para identificar esses padrões, são de extrema importância. Dados de consumo e demanda coletados do sistema de monitoramento de energia podem mostrar como o sistema de determinado cliente de energia funciona e pode ajudar a reduzir custos e melhorar a eficiência energética.

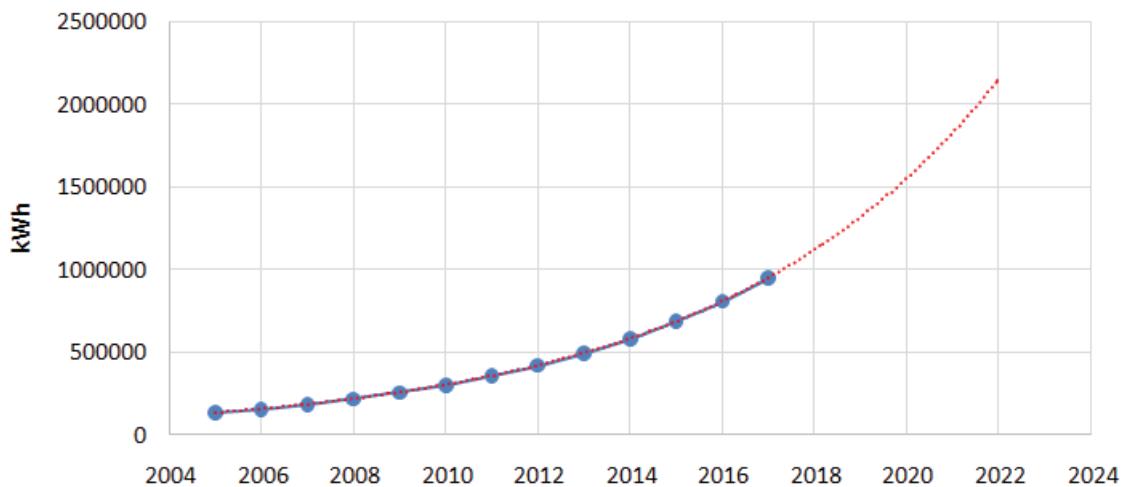
A estratégia de prever o consumo anual de energia é essencial para o planejamento de recursos da concessionária de energia elétrica. O estudo adota uma abordagem para compreender os fatores que influenciam a demanda anual e prever o consumo futuro de energia. O processo de estudo consiste em desenvolver um modelo de previsão usando dados históricos coletados.

Figura 3 – Demanda Média Anual de Carga elétrica.



Fonte: Sahagun et al. (2018).

Figura 4 – O modelo exponencial de consumo de kWh.



Fonte: Sahagun et al. (2018).

Depois de obter um modelo confiável através do treinamento, utilizando dados históricos, é possível prever futuros valores da série temporal em estudo.

Segundo Han *et al.* (2022b), o consumo de energia dos edifícios é responsável por aproximadamente 40% do consumo total de energia. Uma análise precisa do consumo de energia dos edifícios pode não só trazer economias significativas de energia, mas também ajuda a estimar a demanda potencial de unidades consumidoras com mais precisão e, consequentemente, traz benefícios à rede elétrica.

Em Hajjaji *et al.* (2022), é feita uma análise do consumo de energia elétrica na microrrede de um campus universitário durante um ano. Esta pesquisa foi conduzida para compreender os dados e interpretar o consumo diário de energia e suas flutuações para os

diferentes perfis. No estudo foi analisado o consumo de energia de cinco edifícios diferentes dentro de um campus universitário: escritórios e laboratórios dos professores, salas de aula, restaurante, iluminação exterior e sala de estudantes. A análise forneceu interpretações que podem ajudar a classificar outros perfis que possuem características semelhantes.

Conforme Tao *et al.* (2021), com o rápido desenvolvimento da internet e da tecnologia da informação, o nível de informatização da indústria de energia continua a melhorar. Com base nas plataformas de gerenciamento de dados, as empresas da rede elétrica acumulam enormes quantidades de dados de clientes, que tem grande potencial de aplicação. Além disso, com o desenvolvimento da tecnologia da informação, é possível controlar os recursos flexíveis do lado do cliente. Ao usar esses dados para minerar e utilizar o relacionamento e as regras profundas, pode-se realizar análises e a previsão do comportamento do cliente da rede elétrica e ajudar na tomada de decisões. Através da adoção da tecnologia apropriada de análise e processamento de dados, analisar e minerar os dados de forma pertinente, pode-se transformá-los em informações de tomada de decisão para fornecer uma base que auxilie no desenvolvimento empresarial, que pode apoiar a área de marketing empresarial da rede elétrica e melhorar o nível de serviço ao cliente, por exemplo.

Segundo Chuang *et al.* (2021) e Fan *et al.* (2022), existem muitas potenciais informações sobre o comportamento do usuário, ocultas no big data do cliente, isso é essencial para identificar com precisão o comportamento de consumo de energia dos usuários. O comportamento de consumo de energia dos usuários em diferentes indústrias tem certos padrões. Se os padrões de características intrínsecas dos usuários em diferentes indústrias são ignorados, a previsão do consumo de energia produzirá erros. Além disso, minerando as informações precisas no big data do cliente, pode-se analisar efetivamente o comportamento de consumo de energia dos usuários, tornar as características das unidades consumidoras de energia mais representativas, melhorar a eficiência de utilização do equipamento e reduzir o consumo de energia.

2.5 Modelos de machine learning utilizados para previsão e métricas de avaliação de performance para previsões de séries temporais

2.5.1 Modelos autoregressivos de médias móveis integradas

Um modelo estatístico é autoregressivo se prever valores futuros com base em valores passados. Os modelos ARIMA, iniciados por Box-Jenkins (Box *et al.*, 1994) são modelos

estatísticos. O ARIMA utiliza dados passados para prever o futuro, usando autocorrelação e médias móveis. Além disso, o ARIMA possui derivações como modelos que permitem identificar e considerar a sazonalidade, que é o caso do modelo *Sazonal Auto-Regressivo Integrado de Médias Móveis (Seazonal Autoregressive Integrated Moving Average)* (SARIMA), modelos *Regressão Automática (Automatic Regression)* (AR), *Média Móvel (Moving Average)* (MA), ARMA. O ARIMA possui parâmetros com o intuito de melhorar o modelo, os três parâmetros principais do modelo ARIMA são corretamente identificados como: p, d, e q, com as respectivas definições: p é número de defasagens do modelo auto-regressivo; d é grau de diferenciação, ou seja, o número de vezes que os dados originais são diferenciados para alcançar estacionariedade, q: ordem do modelo de média móvel. O ARIMA faz uso de médias móveis defasadas para suavizar dados de séries temporais. Os modelos autorregressivos assumem implicitamente que o futuro será semelhante ao passado. A parte de AR refere-se a um modelo que mostra uma variável variável que regride em seus próprios valores defasados, ou anteriores, Integrado (Integrated)(I): representa a diferenciação de observações brutas para permitir que a série temporal se torne estacionária, isto é, os valores dos dados são substituídos pela diferença entre os valores dos dados atuais de cada linha de um conjunto de dados e os valores anteriores (lags), a MA incorpora a dependência entre uma observação e um erro residual de um modelo de média móvel aplicado a observações defasadas. O modelo SARIMA ou ARIMA Sazonal, é uma ampliação do modelo ARIMA. O SARIMA trabalha com dados de séries temporais univariadas que apresentam um componente sazonal. Esse modelo adiciona três novos hiperparâmetros para especificar a parte AR, a diferenciação I e a MA para o componente sazonal da série, além de um parâmetro adicional para o período da sazonalidade. O SARIMA traz mais 4 parâmetros principais P (sazonal autorregressivo) , D (diferenciação sazonal), Q (média móvel sazonal) e S (parâmetro que especifica o período da sazonalidade, ou seja, a frequência com que o padrão sazonal se repete, seja anualmente, mensalmente, semanalmente, etc). Essas informações podem ser encontradas em trabalhos como (Ho e Xie (1998); Hillmer e Tiao (1982); Newbold (1983); Benvenuto *et al.* (2020); Fattah *et al.* (2018); Ariyo *et al.* (2014); Tseng *et al.* (2002); Kavasseri e Seetharaman (2009); Sowell (1992) e Faruk (2010)), por exemplo. Os modelos ARMA(p, q) e ARIMA(p, d, q) possuem muitas semelhanças, como os componentes AR e MA, são da mesma forma, combinando um modelo autorregressivo geral AR(p) e modelo de média móvel geral MA(q). AR(p) usa valores anteriores da variável dependente para prever a informação futura. Por outro lado, MA(q) usa a média da série e erros anteriores para completar as previsões. Abaixo

pode-se ver a definição do modelo ARMA na equação 2.3. Onde φ representa os parâmetros do modelo autorregressivo, θ representa os parâmetros do modelo de média móvel, c é uma constante e ε trata dos termos de erro (ruído branco).

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.3)$$

Conforme Elsaraiti *et al.* (2021), a previsão do consumo de energia é o primeiro passo para lidar com o gerenciamento de carga. Para previsão de séries temporais, os modelos ARIMA são um dos modelos amplamente utilizados que mostram resultados encorajadores. O estudo realizado pelos autores, teve como objetivo prever o consumo de energia no sul de Trípoli, Líbia, por duas semanas, com base em dados do dia 1 de janeiro de 2016 a 24 de março de 2016 (12 semanas) usando o sistema autoregressivo integrado de média móvel (ARIMA).

De acordo com Mahia *et al.* (2019), o ARIMA é uma técnica ótima para previsão futura da produção de energia elétrica que vai ao encontro do planejamento da demanda energética futura. O valor da previsão ajuda a determinar o orçamento e quanta energia deve ser produzida para abastecer vários setores, incluindo agricultura, transporte, setor residencial, comercial e industrial. Em Mahia *et al.* (2019) foram utilizados conjunto de dados sintéticos e dados de consumo de energia de indústrias de Guangdong, província na China.

2.5.2 *Modelo Prophet*

Segundo Facebook (2023), o Prophet é um procedimento para previsão de dados de séries temporais com base em um modelo aditivo onde tendências não lineares são ajustadas à sazonalidade anual, semanal e diária, além dos efeitos dos feriados. Funciona melhor com séries temporais que apresentam fortes efeitos sazonais e várias temporadas de dados históricos. O Prophet é robusto em relação à falta de dados e às mudanças na tendência e normalmente lida bem com valores discrepantes. O Prophet é usado em muitos aplicativos do Facebook para produzir previsões confiáveis para planejamento e definição de metas. O Prophet inclui funcionalidade para validação cruzada de séries temporais para medir erros de previsão usando dados históricos. Isso é feito selecionando pontos de corte no histórico, e para cada um deles ajustando o modelo utilizando dados apenas até aquele ponto de corte. Podemos então comparar os valores previstos com os valores reais. No modelo Prophet a coluna da variável a ser prevista deve se chamar Y, e a coluna de data deve se chamar DS, a coluna de dados previstos é YHAT,

o limite inferior previsto é YHAT LOWER e o limite superior previsto é YHAT UPPER. Este modelo foi introduzido por Taylor e Letham (2018). Para a construção do modelo Prophet foi usado um modelo de série temporal decomponível baseado em Harvey e Peters (1990), com três componentes principais do modelo: tendência, sazonalidade e feriados. Esses componentes são combinados na seguinte equação 2.4. No modelo, $g(t)$ é a função de tendência que modela mudanças não periódicas no valor da série temporal, $s(t)$ representa mudanças periódicas (por exemplo, sazonalidade semanal e anual) e $h(t)$ representa os efeitos de feriados que ocorrem em horários potencialmente irregulares durante um ou mais dias. O termo de erro representa quaisquer mudanças idiossincráticas que não são acomodadas pelo modelo.

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (2.4)$$

Como mostra Gong *et al.* (2020), existem muitos fatores que influenciam o consumo de eletricidade, como clima, estação, horário, economia e preço da energia elétrica, que possuem características de certas mudanças lineares e periódicas, e têm fortes mudanças. Neste estudo foi utilizado um modelo Prophet para fazer uma análise de tendências do consumo de energia de edifícios. Ao comparar os resultados de previsão do algoritmo Prophet e um algoritmo ARIMA, o algoritmo Prophet obteve melhor previsão dos resultados. Os resultados da simulação mostram que o consumo abrangente de energia dos shopping centers analisados é afetado até certo ponto por feriados, mas também por altas temperaturas. O abrangente consumo de energia dos edifícios de escritórios é relativamente menos afetado por feriados e clima de alta temperatura até certo ponto.

Em concordância com Kindalkar *et al.* (2022), uma das ameaças ao fornecimento confiável de energia de sistemas de potência é uma demanda de carga imprevisível. Assim, a previsão de carga precisa é essencial. O ML e a análise de dados são métodos recomendados. Uma abordagem de previsão de série temporal é usada em Kindalkar *et al.* (2022), para prever os níveis futuros de demanda de carga com um alto grau de confiança. A ferramenta Prophet desenvolvida pelo Facebook é usada no processo. O modelo de previsão é desenvolvido usando dados horários em tempo real da *Empresa de Fornecimento de Eletricidade Hubli Limitada (HUBLI ELECTRICITY SUPPLY COMPANY LIMITED)* (HESCOM) por um intervalo de tempo estipulado. O efeito de várias sazonalidades, parâmetros climáticos como temperatura, umidade e precipitação também são considerados. A HESCOM é uma empresa de distribuição de energia que atende sete distritos no estado de Karnataka na Índia.

2.5.3 Redes neurais de memória longa de curto prazo

Segundo Graves e Graves (2012) e Hochreiter e Schmidhuber (1997), um benefício importante das redes neurais recorrentes é a sua capacidade de usar informações contextuais ao mapear entre sequências de entrada e saída. Infelizmente, para arquiteturas de RNN padrão, a gama de contextos que podem ser acessados na prática é bastante limitada. O problema é que a influência de um determinado input no valor da camada oculta e, portanto, na saída da rede, decai exponencialmente à medida que circula pelas conexões recorrentes da rede. A arquitetura LSTM consiste em um conjunto de sub-redes conectadas recorrentemente, conhecidos como blocos de memória. Esses blocos podem ser considerados como uma versão de bloco diferenciável dos chips de memória em um computador digital. Cada bloco contém um ou mais células de memória autoconectadas e três unidades multiplicativas. Uma rede LSTM é igual a uma RNN padrão, exceto porque as unidades de soma na camada oculta são substituídas por blocos de memória. As mesmas camadas de saída podem ser usadas para redes LSTM como para RNNs padrão. As portas multiplicativas permitem que as células de memória LSTM armazenem e acessem informações durante longos períodos de tempo, mitigando assim o problema do gradiente evanescente. Por exemplo, enquanto a porta de entrada permanecer fechada (ou seja, tem ativação próxima a 0), a ativação da célula não será sobreescrita pelas novas entradas que chegam na rede, podendo estar disponível para a rede muito tempo depois na sequência, abrindo a porta de saída.

A LSTM é uma arquitetura de RNN que “lembra” valores em intervalos arbitrários. A LSTM é bem adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. A insensibilidade relativa ao comprimento do gap dá uma vantagem à LSTM em relação a RNNs tradicionais (também chamadas “vanilla”), *Modelos Ocultos de Markov* (MOM) e outros métodos de aprendizado de sequências, Data Science Academy (2022).

De acordo com Asri *et al.* (2021), a demanda de eletricidade está aumentando de forma muito rápida devido ao crescimento e desenvolvimento da população mundial e de equipamentos que necessitam de energia elétrica. Com base nesta tendência, é importante planejar o uso eficiente de energia para eliminar o desperdício de energia e, assim, reduzir as emissões de carbono. Visando previsões mais precisas do consumo de energia, o estudo de Asri *et al.* (2021) foca na análise de séries temporais e no uso do modelo LSTM para prever o consumo de energia. Os conjuntos de dados utilizados no estudo foram obtidos de um terceiro, onde os

dados de consumo de energia foram retirados de quatro locais diferentes que são denominados no trabalho de SSB1E, SSB1N, SSBGE e SSBGN. Cada conjunto de dados contém um total de 34.944 dados que são de 12 meses de uso do consumo de energia. Os dados foram coletados de janeiro a dezembro de 2017 a cada 15 minutos. O valor do *Erro Quadrático Médio (Mean Squared Error)* (MSE) foi de 10,23%, provando assim que o modelo LSTM é altamente preciso em fazer previsões. O modelo LSTM do estudo foi capaz de gerar uma previsão precisa do uso da energia que poderá ajudar em um planejamento energético eficaz.

Em concordância com Dubey *et al.* (2021), a previsão do consumo de energia é essencial para as operações de redes inteligentes, pois facilita a gestão da demanda de eletricidade e o planejamento da carga dos serviços públicos. No artigo proposto por Dubey *et al.* (2021), a análise de dados apresentada foi possível pela coleta de dados em medidores inteligentes e, em seguida, foi feita a previsão do consumo de energia diária usando os modelos ARIMA, SARIMA e o modelo LSTM. A análise tende a compreender os diferentes fatores que influenciam o consumo de energia e auxiliar os operadores na tomada de decisões. É útil para reduzir a interrupção de energia e melhorar a consciência situacional do consumo de energia diariamente, proveniente dos medidores inteligentes. Os fatores relacionados são capazes de diminuir o consumo de energia, ou melhor, contribuir para o consumo efetivo de unidades consumidoras de energia. Os parâmetros utilizados para a avaliação dos resultados são várias características relacionadas ao clima, como temperatura, umidade, cobertura de nuvens, visibilidade, velocidade do vento, índice UV e ponto de orvalho. Os resultados indicaram que o consumo de energia tem alta correlação positiva com a umidade e alta correlação negativa com a temperatura. No geral, o modelo LSTM foi considerado proeminente em comparação com ARIMA e SARIMA com erro MAE de 0,23.

2.5.4 DeepAR

Segundo Salinas *et al.* (2020), a previsão probabilística, ou seja, estimar a distribuição de probabilidade futura de uma série temporal dado o seu passado, é um facilitador essencial para a otimização dos processos de negócios. Nas empresas de varejo, por exemplo, as previsões probabilísticas de demanda são cruciais para ter o estoque certo disponível na hora certa e no lugar certo. Em Salinas *et al.* (2020), é proposto o modelo de Previsão probabilística com redes recorrentes autorregressivas (DeepAR), uma metodologia para produzir previsões probabilísticas precisas, com base no treinamento de um modelo de rede neural recorrente autorregressivo

em um grande número de séries temporais relacionadas. Demonstra-se como a aplicação de técnicas de aprendizagem profunda à previsão pode superar muitos dos desafios enfrentados pelas abordagens clássicas amplamente utilizadas para o problema. Por meio de extensas avaliações empíricas sobre vários conjuntos de dados, mostra-se que a metodologia produz previsões precisas. O DeepAR aprende um modelo global a partir de dados históricos de todas as séries temporais no conjunto de dados. O método se baseia em trabalhos anteriores sobre aprendizagem profunda para dados de séries temporais (Graves (2013); Oord *et al.* (2016); Sutskever *et al.* (2014)) e adapta uma rede de memória de longo prazo semelhante a (Hochreiter e Schmidhuber (1997)), baseada em uma arquitetura de rede neural recorrente para o problema de previsão probabilística. Um desafio frequentemente encontrado ao tentar aprender em conjunto com problemas de previsão com múltiplas séries temporais do mundo real é que as magnitudes das séries temporais diferem amplamente e a distribuição de magnitudes é fortemente distorcida em aplicações práticas. As principais contribuições no artigo são: proposição de uma arquitetura de RNN para previsão probabilística, que incorpora uma probabilidade binomial negativa para dados de contagem, bem como tratamento especial para o caso em que as magnitudes das séries temporais variam amplamente; e demonstra-se empiricamente, em vários conjuntos de dados do mundo real, que este modelo produz previsões probabilísticas precisas em uma faixa de características de entrada, mostrando assim que abordagens baseadas na aprendizagem profunda podem ser eficazes para abordar o problema da previsão probabilística. Isto fornece mais evidências de que as RN são uma técnica de previsão útil e de uso geral.

O modelo DeepAR proposto é eficaz no aprendizado global de várias séries temporais relacionadas, pode lidar com grandes variações de escala por meio de reescalonamento e amostragem, gera previsões probabilísticas calibradas com alta precisão e é capaz de aprender padrões complexos, como sazonalidade e crescimento da incerteza ao longo do tempo a partir de dados. Curiosamente, o método funciona em uma ampla variedade de conjuntos de dados com pouco ou nenhum ajuste de hiperparâmetros e é aplicável a conjuntos de dados de tamanho médio que contêm apenas algumas centenas de séries temporais, Salinas *et al.* (2020).

Como explica Amazon Web Services (2023a), durante o treinamento, o DeepAR aceita um conjunto de dados de treinamento e um conjunto de dados de teste opcional. Ele usa o conjunto de dados de teste para avaliar o modelo treinado. Em geral, os conjuntos de dados não precisam conter o mesmo conjunto de séries temporais. Pode-se usar um modelo treinado em um determinado conjunto de treinamento para gerar previsões para o futuro da

série temporal no conjunto de treinamento e para outras séries temporais. Tanto os conjuntos de dados de treinamento quanto os de teste consistem em uma ou, preferencialmente, mais séries temporais alvo. Cada série temporal de destino pode opcionalmente ser associada a um vetor de características de série temporal e a um vetor de recursos categóricos.

Em Yan (2023), foi feita uma análise de previsão de mudança de série temporal de imagens biológicas nos campos da medicina e da biologia, o artigo propõe uma abordagem de um método de análise de previsão de mudança de série temporal de imagens biológicas com base no algoritmo DeepAR. Primeiro, de acordo com as características das imagens biológicas, os dados da série temporal são adquiridos e pré-processados para obter informações como valores alvo, recursos dinâmicos e recursos estáticos. Em uma segunda etapa, para melhorar a precisão e estabilidade de previsão, um modelo de aprendizagem profunda baseado em uma rede neural recorrente, o DeepAR, é usado para ajustar e prever a tendência de mudança da série temporal. Em outra etapa, um índice de avaliação e uma estratégia de otimização que considera de forma abrangente a influência da periodicidade de tempo da série, sazonalidade, outliers, etc., são construídos com base em diferentes cenários de aplicação para avaliar a qualidade dos resultados da previsão com mais precisão. Finalmente, um sistema de análise de previsão de mudança de série temporal de imagens com base no algoritmo DeepAR foi construído.

2.5.5 *Métricas de avaliação de performance para previsões de séries temporais*

Os modelos de previsão precisam ser avaliados, a fim de identificar se o modelo está apto para ser utilizado para previsões de valores futuros. Para isso é feito o uso de métricas de avaliação como o MSE, RMSE, MAE e o MAPE. O MSE é uma métrica que mede a média dos quadrados dos erros entre valores observados e valores previstos. A equação para o MSE é mostrada em 2.5. Onde n é o número total de observações, y_i é o valor original para a i -ésima observação e \hat{y}_i é o valor previsto para a i -ésima observação. O RMSE é a raiz quadrada do MSE e fornece uma medida do erro na mesma unidade dos dados originais. A equação para o RMSE é mostrada em 2.6. O MAE é uma métrica que calcula a média dos valores absolutos dos erros entre valores observados e valores previstos. Em 2.7 é mostrada a equação para o erro MAE. O MAPE é uma métrica que expressa o erro como uma porcentagem da média dos valores observados. A equação para o MAPE é expressa em 2.8. Essas informações estão de acordo com (Wang e Bovik (2009); Chai e Draxler (2014); Myttenaere *et al.* (2016); Chicco *et al.* (2021); Ostertagova e Ostertag (2012) e Tian *et al.* (2018)).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.7)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|y_i - \hat{y}_i|}{|y_i|} \right) \cdot 100\% \quad (2.8)$$

Várias pesquisas relacionadas ao estudo de dados de séries temporais utilizam as métricas comentadas para avaliar modelos e fazer a escolha do melhor algoritmo para determinados tipos de dados. Em Basha *et al.* (2022), foram utilizados modelos como o SARIMA e o *Método Sazonal de Inverno de Holt (Holt-Winters' Seasonal Method)* (HWSM) para previsão da água da chuva na Índia. Foi realizada uma análise comparativa para inspecionar o melhor modelo de previsão de séries temporais. Os parâmetros de avaliação utilizados para realizar uma análise comparativa dos diferentes modelos de previsão de séries temporais são MSE, RMSE e MAE. Observou-se que o modelo HWSM registrou a menor taxa de erro, com 5,767 e 5,343 como RMSE, 2,143 e 2,432 como MAE, 31,65 e 26,75 como MSE para dois conjuntos de dados, denominados no trabalho como conjunto de dados 1 e conjunto de dados 2, respectivamente, quando comparado aos demais modelos.

2.6 Detecção de anomalias

Como relata Amazon Web Services (2023b), a detecção de anomalias examina pontos de dados específicos e detecta ocorrências raras que parecem suspeitas porque são diferentes do padrão de comportamento estabelecido. A detecção de anomalias não é nova, mas à medida que os dados aumentam, o rastreamento manual torna-se impraticável. A detecção de anomalias é especialmente importante em setores como finanças, varejo e segurança cibernética, mas todas as empresas devem considerar uma solução de detecção de anomalias. Esta tecnologia fornece um meio automatizado de detectar valores discrepantes prejudiciais e proteger os dados das

organizações. Por exemplo, o setor bancário é um setor que se beneficia da detecção de anomalias. Ao utilizá-la, os bancos podem identificar atividades fraudulentas e padrões inconsistentes e proteger os dados. Examinar manualmente os pontos de dados, buscando pistas e insights sobre o desempenho de seus sistemas nem sempre é um método eficaz para encontrar descobertas. Uma organização pode ter notado uma mudança no comportamento, mas não necessariamente conseguir descobrir as causas básicas. Com a detecção de anomalias depende mais do ML. O ML desempenha um papel crucial ao identificar pontos discrepantes difíceis de detectar manualmente, mitigar essas ameaças e, consequentemente, proteger o sistema. A detecção de anomalias oferece vários benefícios. Pode-se localizar e resolver um problema antes que ele atinja outras partes de um sistema. Isso resulta em economia de custos.

De acordo com Patiño *et al.* (2021), a diminuição dos preços da tecnologia disponível para autogeração a partir da energia solar e o alto custo ambiental dos sistemas tradicionais de geração de eletricidade, levaram as pessoas no contexto das alterações climáticas gerar a sua própria energia para satisfazer suas necessidades de consumo. Para o sistema elétrico em um contexto estratégico, isso trouxe uma série de desafios em termos de planejamento e projeção da demanda e sua evolução decrescente ao longo do tempo, o que sugere um desafio tecnológico, especialmente quando coexistem grandes cidades ou comunidades remotas. No artigo de Patiño *et al.* (2021), é apresentada uma metodologia baseada em técnicas de detecção de anomalias para a caracterização de mudanças atípicas no comportamento de uma série temporal de consumo de energia, a fim de identificar a instalação de dispositivos de autogeração por painéis solares em uma área de estudo. A metodologia analisada baseia-se principalmente em duas tendências de desenvolvimentos: a primeira faz uso dos algoritmos de detecção de anomalias disponíveis na biblioteca Prophet do Facebook, enquanto a segunda usa uma série de algoritmos de buscas exaustivas para determinar mudanças nos dados. Os resultados obtidos mostraram as mudanças no comportamento da série temporal como resultado da integração dessas tecnologias na geração de eletricidade, e onde o intervalo de tempo de análise desempenha um papel determinante neste processo.

No artigo apresentado por Zihan *et al.* (2021), é relatado que para resolver o problema que os tradicionais métodos não conseguem fazer o pleno uso das características da série temporal de dados de consumo de eletricidade e melhorar a eficiência e precisão da detecção de valores discrepantes no consumo de eletricidade, foi proposto no artigo um algoritmo de detecção de valores discrepantes de consumo de eletricidade baseado no modelo LSTM, que pode extrair

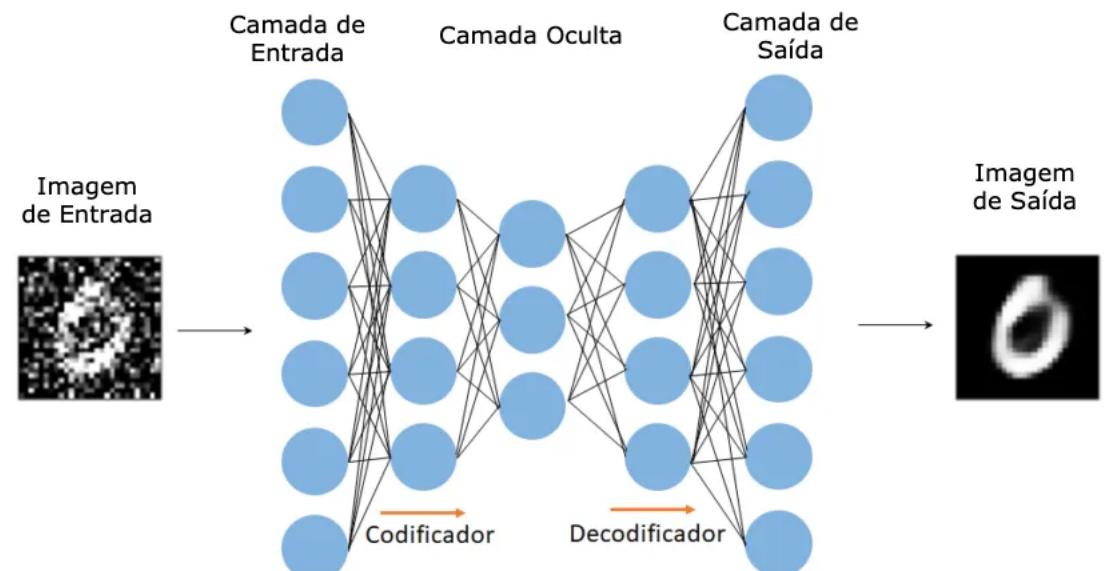
características da sequência de consumo de eletricidade. Primeiro, a LSTM é usada para analisar séries temporais de dados de eletricidade, que são usados como a entrada do modelo de detecção de outliers. Em um segundo momento, calculou-se a densidade de pico como centro de agrupamento inicial para otimizar o algoritmo de detecção de outlier baseado em K-médias para alcançar a eficiência do algoritmo . Finalmente, fez-se um experimento em 200 dias de dados de consumo de eletricidade de uma determinada área.

O artigo proposto por Mao *et al.* (2018), apresenta um modelo de detecção de anomalias de dados de energia não supervisionado baseado principalmente no algoritmo de *Floresta Isolada (Isolation Forest)* (IF). O modelo inclui módulos para extração de recursos, redução de recursos e o módulo computacional de IF. Os resultados da pesquisa mostram que o uso deste modelo para detectar dados anormais de uso de energia pode processar grandes quantidades de dados em um curto espaço de tempo.

2.7 Autoencoders e embeddings para séries temporais.

Em conformidade com (Zhang e Chen (2019), Salinas *et al.* (2020), Song *et al.* (2018)), os autoencoders são uma classe de algoritmos de aprendizado profundo usados para aprendizado não supervisionado de representações eficientes de dados. Além disso, consistem em uma arquitetura de rede neural que mapeia os dados de entrada para uma representação interna e, em seguida, tenta reconstruir os dados de entrada a partir dessa representação. O treinamento de autoencoders é realizado minimizando a diferença entre os dados de entrada e a reconstrução gerada pelo modelo. Para aplicar autoencoders a séries temporais, é possível usar arquiteturas específicas, como os *Autoencoders Recorrentes (Recurrent Autoencoders)* (RAEs) ou *Autoencoders Convolucionais (Convolutional Autoencoders)* (CAEs), dependendo da natureza dos dados temporais. Esses modelos são projetados para capturar padrões temporais nas séries. A técnica de embeddings refere-se à representação vetorial de dados em um espaço vetorial de dimensão inferior. No contexto de séries temporais, embeddings podem ser obtidos usando autoencoders para aprender uma representação latente compacta que capture as características mais importantes da série como tendências, sazonalidades, anomalias, etc. Na Figura 5 é mostrado um autoencoder convolucional retirado de Esteves (2020). O autoencoder utilizado extrai da imagem original as principais características para formar o dígito zero, retirando os ruídos e diminuindo a dimensionalidade da imagem para características que de fato constituem o dígito zero e depois reconstrói a imagem na saída.

Figura 5 – Representação de um autoencoder convolucional.



Fonte: Toni Esteves (2020).

ARĞUN e ALPTEKİN (2023) utilizaram o *Autoencoder Variacional (Variational Autoencoder)* (VAE), um método de aprendizagem não supervisionado, no setor varejista para monitorar e gerenciar os níveis de estoque baseando-se nas vendas previstas, visando sustentar sua posição no mercado. A precisão do estoque é fundamental para evitar a escassez, sendo definida como a diferença entre os registros de armazém e a quantidade real em estoque. Segundo o autor, no contexto desse trabalho, as causas básicas da imprecisão do estoque são roubo por funcionários ou clientes, dano ou deterioração do produto e remessas erradas. O estudo visa detectar imprecisões nos estoques de uma das maiores cadeias de supermercados da Turquia. Com base nos resultados, mostrou-se que o VAE é capaz de modelar a probabilidade subjacente da distribuição de dados, regenerar o padrão a partir de dados de séries temporais e detectar anomalias. Consequentemente, reduz tempo e esforço para rotular manualmente a imprecisão nos dados. O estudo relata que os resultados experimentais mostraram que as abordagens propostas podem detectar anomalias tanto em produtos com quantidades baixas de estoque como nas altas quantidades de estoque.

Como explica Provotor *et al.* (2019), a detecção automática de anomalias na mineração de dados tem uma ampla gama de aplicações, como detecção de fraudes, monitoramento da saúde do sistema, detecção de falhas, sistemas de detecção de eventos em redes de sensores, entre outros. O principal desafio relacionado a esse problema é a natureza desconhecida da anomalia. Portanto, segundo o autor, é impossível usar técnicas clássicas de aprendizado de máquina para treinar o modelo, uma vez que não se têm rótulos de séries temporais com anomalias. Um dos

métodos mais inovadores do ML é a detecção de anomalias baseada em autoencoders. Um autoencoder é um tipo de rede neural artificial usado para aprender codificações eficientes de dados de maneira não supervisionada. O objetivo de um autoencoder é aprender uma representação (codificação) para um conjunto de dados, geralmente para redução de dimensionalidade, treinando a rede para ignorar o ruído do sinal.

Em Mehra *et al.* (2023), é proposto um sistema de detecção de anomalias baseado em aprendizado de máquina multidimensional. O setup experimental é projetado para mapear a redução multidimensional dos dados de séries temporais na área industrial. Segundo o autor o sistema descentralizado proposto melhora o tempo de cálculo e a detecção eficaz de anomalias pode ser empregada para processar dados industriais em tempo real. A etapa de redução de dimensionalidade utiliza autoencoders, que podem ser eficazmente combinados com outras formas de RN para a detecção de anomalias. Os detectores de monitoramento baseados em aprendizado de máquina descentralizado estão equipados para capturar pequenas mudanças no cronograma de produção industrial. Em resumo, o trabalho abordou uma estrutura multidimensional e eficiente, utilizando ML descentralizado, para identificar anomalias em séries temporais industriais, oferecendo insights valiosos para a otimização da produção e manutenção industrial.

Segundo Zhao *et al.* (2019), muitos dados de séries temporais são caracterizados por forte aleatoriedade e alto ruído. Os modelos preditivos tradicionais têm dificuldade em extrair as características dos dados, e o efeito da previsão não é muito bom. *Redes Neurais Convolucionais (Convolutional Neural Networks)* (CNNs) e autoencoders são eficazes na extração de características dos dados. Neste estudo, o autor propõe um modelo preditivo de uma combinação de *Engenharia Assistida por Computador (Computer-Aided Engineering)* (CAE) e LSTM para prever dados de séries temporais com alto ruído. Primeiramente, uma convolução unidimensional é usada na rede de codificação e decodificação do autoencoder para extrair as características dos dados e, em seguida, utiliza-se LSTM para previsão. De acordo com o trabalho, os resultados experimentais mostraram que o erro de previsão do modelo CAE-LSTM é significativamente menor do que em outros modelos. O modelo tem um melhor efeito de ajuste em dados de séries temporais com grandes mutações e ruído do que o modelo LSTM tradicional. Os experimentos foram conduzidos em conjunto de dados públicos de fluxo de tráfego e conjunto de dados de falhas em equipamentos de fábricas, provando, conforme o autor, que o modelo proposto é melhor que a LSTM tradicional.

2.8 Algoritmos de agrupamento e métricas de avaliação

2.8.1 Algoritmo K-Médias

O algoritmo K-Médias foi introduzido por Lloyd (1982), o artigo descreve o algoritmo básico e a abordagem de quantização por mínimos quadrados, que é a base do algoritmo K-Médias. O trabalho introduz o algoritmo K-Médias para a quantização de sinais em sistemas de *Modulação por Código de Pulso (Pulse-Code Modulation)* (PCM). O artigo aborda o problema de quantizar sinais em sistemas PCM com o objetivo de minimizar o erro quadrático médio entre os valores quantizados e os originais. O algoritmo tem o objetivo de encontrar K centroides μ_k (onde $k = 1, 2, \dots, k=1,2,\dots,K$), de um conjunto de N amostras x_i (onde $i = 1, 2, \dots, Ni=1,2,\dots,N$), de modo a minimizar a soma dos quadrados das diferenças entre cada amostra e o centroide mais próximo. A função objetivo é definida na equação 2.9.

$$J = \sum_{i=1}^N \sum_{k=1}^K r_{ik} \|x_i - \mu_k\|^2 \quad (2.9)$$

Onde r_{ik} é uma variável indicadora que é 1 se a amostra x_i pertence ao cluster k e 0 caso contrário. As amostras são atribuídas ao cluster cujo centróide é o mais próximo. Os centroides são recalculados como a média das amostras atribuídas a cada cluster como visto na equação 2.10. Os passos de atribuição do cluster e atualização dos centroides do algoritmo são repetidos iterativamente até que a convergência seja alcançada.

$$\mu_k = \frac{\sum_{i=1}^N r_{ik} x_i}{\sum_{i=1}^N r_{ik}} \quad (2.10)$$

Segundo Ketchen e Shook (1996) e Marutho *et al.* (2018), o Método do Cotovelo é uma técnica usada para determinar o número ideal de clusters K em algoritmos de agrupamento. O conceito principal é observar como a variância no interior do cluster decresce à medida que o número de clusters aumenta, identificando um ponto de inflexão, conhecido como cotovelo, onde o ganho na redução da variância começa a diminuir significativamente. Este ponto é considerado uma indicação do número ótimo de clusters para o conjunto de dados. A *Soma dos Quadrados dentro do Cluster (Within-Cluster Sum of Squares)* (WCSS) é uma métrica que mede a variabilidade dos pontos de dados dentro de cada cluster. A fórmula geral para o cálculo do WCSS é mostrada na equação 2.11.

$$WCSS = \sum_{i=1}^K \sum_{j=1}^{n_i} d(x_{ij}, c_i)^2 \quad (2.11)$$

Onde K é o número de clusters, n_i é o número de pontos no cluster i, x_{ij} é o j-ésimo ponto no cluster i, c_i é o centroide (ou centro) do cluster i, $d(x_{ij}, c_i)$ é a distância entre o ponto x_{ij} e o centro c_i . Este valor é calculado para diferentes valores de K, e o ponto onde a redução na variância intra-cluster começa a diminuir é geralmente identificado como o cotovelo. Esse é o valor ótimo de K para o conjunto de dados específico.

Em Liu *et al.* (2016), foi analisado o comportamento de consumo de energia de clientes de energia com base em dados massivos. As curvas de características de carga dos clientes foram agrupadas utilizando o algoritmo K-Médias. Sob diferentes agrupamentos de datas, as características de carga elétrica dos clientes são analisadas. Pode-se reconhecer diferentes padrões de uso de energia, comparando as curvas características de carga da rede e dos clientes. O autor relata que ao implementar diferentes estratégias considerando o comportamento de consumo de eletricidade dos clientes, o nível de gerenciamento do lado da demanda da rede elétrica principal pode ser aprimorado, promovendo a operação estável da rede elétrica principal.

Segundo Wang *et al.* (2022), com o contínuo desenvolvimento da internet das coisas e tecnologias de redes inteligentes, o valor potencial dos grandes conjuntos de dados de energia está sendo constantemente explorado. O comportamento do usuário no consumo de energia é de grande importância para empresas de energia, consumidores e para o sistema de energia. Nesse artigo, por meio da mineração e análise de dados no lado do consumo de energia, o método de agrupamento K-Médias foi usado para buscar a similaridade das amostras, e os usuários são classificados de acordo com as características do comportamento de consumo de energia, com base nos dados coletados de um período de um ano. São obtidos quatro tipos diferentes de usuários, a composição da estrutura familiar e a situação econômica dos usuários relacionados são analisadas. O padrão de comportamento de consumo de energia dos usuários foi analisado, fornecendo uma base para a tomada de decisões no lado da gestão de rede e melhorando a qualidade do serviço dos vendedores de energia elétrica para os usuários. A classificação adequada dos usuários de energia pode ajudar as distribuidoras de energia a prever com precisão a carga, permite que as empresas de energia forneçam serviços mais direcionados de acordo com as diferentes classificações de usuários e ajuda a alcançar a alocação ótima de recursos na indústria de energia.

No estudo de Tang *et al.* (2022), com o objetivo de analisar as características do consumo elétrico, procedeu-se à coleta de dados relativos ao consumo de energia de um consumidor no período compreendido entre 1º de janeiro de 2022 e 27 de julho de 2022. Para tal análise, foram implementados modelos de agrupamento, especificamente os métodos K-Médias e Hierárquico. As entradas definidas do modelo foram as temperaturas mais altas e mais baixas medidas e o consumo. Os resultados mostram que, quando o agrupamento K-Médias é realizado com 3 clusters, embora possam refletir a demanda por aquecimento, não conseguem refletir a demanda por refrigeração. Por outro lado, os resultados do agrupamento hierárquico conseguem refletir tanto a demanda por aquecimento quanto por refrigeração. Assim, os resultados do agrupamento hierárquico são mais confiáveis em comparação com os do K-Médias neste estudo.

Em Wang *et al.* (2019), foi utilizado algoritmo de agrupamento K-Médias para encontrar usuários que realizam furto de energia. Usuários com flutuação anormal nos dados normalizados de consumo de eletricidade formaram clusters isolados ou agregaram-se em classes distantes de outras classes de agrupamento. Usando o algoritmo K-Médias, foram encontrados 125 usuários anômalos suspeitos de furtar energia, dos quais 103 usuários estavam na lista de ladrões de eletricidade dos conjuntos de dados originais.

Em Jangid *et al.* (2021) foi feita uma segmentação de carga utilizando o método de agrupamento K-Médias baseado em partições sobre um conjunto de dados de consumo de energia para diferentes categorias de carga como hospitais, residências, supermercados, grandes hotéis, armazéns, etc. A abordagem proposta identifica padrões dominantes para cada categoria de carga e também inspeciona os impactos sazonais no consumo. A análise revela que, para representar de forma ótima as características de consumo de energia das diversas categorias de carga no conjunto de dados, o número ideal de clusters é três. As descobertas demonstram categorias distintas de consumo de energia normalizado e identificam qual categoria tem picos de consumo e consumos mais altos. Os dados resultantes do agrupamento podem ser utilizados para elaborar previsões de consumo e têm um papel importante em programas voltados à resposta de demanda e à estratégia de definição de preços de energia.

2.8.1.1 MINI-BATCH K-Médias

O artigo Sculley (2010) discute a aplicação de técnicas de mini lotes ao algoritmo K-Médias para torná-lo escalável para grandes conjuntos de dados. O trabalho apresenta uma abordagem escalável para o algoritmo K-Médias, focada em lidar com grandes conjuntos de

dados, especialmente aqueles encontrados na web. A principal contribuição do artigo é a introdução do método mini-batch para tornar o K-Médias mais eficiente em ambientes de larga escala. O método mini-batch envolve o processamento do algoritmo K-Médias em subconjuntos menores de dados em vez de o conjunto completo. Isso proporciona uma melhoria significativa na eficiência computacional, permitindo que o algoritmo seja aplicado de maneira mais rápida em grandes volumes de dados. O artigo também destaca a importância da escalabilidade e eficiência em ambientes web, onde conjuntos de dados massivos são comuns. A abordagem em mini-batch é formulada utilizando equações específicas que ajustam os cálculos do K-Médias para operar em lotes menores de dados, facilitando a aplicação em larga escala. Segundo o autor o algoritmo K-Médias clássico de Lloyd continua sendo uma escolha popular para tarefas de clusterização. No entanto, o algoritmo em lote padrão é lento para conjuntos de dados grandes. De acordo com o autor o problema de otimização do K-Médias é encontrar o conjunto C de centros de cluster $c \in \mathbb{R}^m$, com $|C| = k$, para minimizar sobre um conjunto X de exemplos $x \in \mathbb{R}^m$ a seguinte função objetivo. Aqui, $f(C, x)$ retorna o centro de cluster mais próximo $c \in C$ para x usando a distância euclidiana. O clássico algoritmo K-Médias em lote é caro para conjuntos de dados grandes, exigindo um tempo de computação $O(kns)$, onde n é o número de exemplos e s é o número máximo de elementos não nulos em qualquer vetor de exemplo. Como explica o autor, a motivação por trás desse método é que os mini-lotes tendem a ter menor ruído estocástico e no trabalho o método por mini-lotes convergiu para um valor quase ótimo várias ordens de magnitude mais rápido do que o método em lote completo. De acordo com o artigo, experimentos adicionais (omitidos por questões de espaço) mostraram que o K-Médias por mini-lotes é várias vezes mais rápido em grandes conjuntos de dados do que o K-Médias em lote. Para valores pequenos de k , os métodos por mini-lotes conseguiram produzir centros de clusters quase ótimos para quase um milhão de documentos em uma fração de segundo de CPU em uma única máquina comum de 2,4 GHz.

Conforme explica Alonso (2013), o Mini Batch K-Médias foi proposto como uma alternativa ao algoritmo K-Médias para o agrupamento de conjuntos de dados massivos. A vantagem desse algoritmo é reduzir o custo computacional ao não usar todo o conjunto de dados a cada iteração, mas uma subamostra de tamanho fixo. Essa estratégia reduz o número de cálculos de distância por iteração, mas ao custo de uma qualidade de cluster inferior.

Em Feizollah *et al.* (2014), é avaliado o desempenho dos algoritmos de agrupamento K-Médias e Mini Batch K-Médias, na detecção de malware para Android. O tráfego de rede

gerado por aplicativos Android, tanto normais quanto maliciosos, é analisado para fins de detecção. Utilizou-se uma amostra de dados do MalGenome para construir o conjunto de dados, escolhendo 800 amostras dentre 1260 de malwares para Android. Além disso, foram coletados dados de numerosos aplicativos normais do mercado oficial do Android. Os resultados no artigo mostraram que o algoritmo Mini Batch K-Médias tem um desempenho superior ao algoritmo K-Médias na detecção de malware para Android.

Em Chang *et al.* (2022), foi proposto um método de agrupamento baseado no Mini Batch K-Médias com análise de componentes principais para segmentação de clientes em big data de comércio eletrônico. Usando o conjunto de dados do Kaggle: Análise de Personalidade do Cliente como exemplo, o método Mini Batch K-Médias foi nitidamente superior a outros algoritmos, segundo o autor. Comparado com os métodos K-Médias, Aglomerativo, *Equilibrado Iterativo Redutor e Agrupador usando Hierarquias (Balanced Iterative Reducing and Clustering using Hierarchies)* (BIRCH) e Espectral, o método Mini-Batch K-Médias possui a menor soma dos quadrados dos erros SSE, nesse artigo. Através do método de agrupamento Mini-Batch K-Médias com *Análise de Componentes Principais (Principal Component Analysis)* (PCA), dividiu-se os clientes de comércio eletrônico em cinco clusters, compreendeu-se o nível de educação e estado civil dos clientes por meio de pré-processamento de dados e visualização de dados, e o método do cotovelo foi utilizado para determinar o número de clusters e o melhor algoritmo. Após explorar as características desses cinco clusters, foram propostas estratégias correspondentes de marketing para os perfis de clientes.

2.8.2 Agrupamento Hierárquico

Um dos primeiros métodos de agrupamento hierárquico foi proposto por Jr (1963), conhecido como método de ligação de Ward. O artigo aborda a questão de agrupamento hierárquico com o objetivo de otimizar uma função objetivo. O trabalho propõe um método que utiliza uma abordagem hierárquica para agrupar elementos de modo a maximizar ou minimizar uma função objetivo específica. Ele introduz um algoritmo que ajusta dinamicamente a estrutura de agrupamento para otimizar o valor da função objetivo. O método conta com uma função objetivo que pode representar, por exemplo, a similaridade ou dissimilaridade entre grupos de elementos. A abordagem hierárquica implica na formação iterativa de grupos a partir de elementos individuais. O algoritmo ajusta dinamicamente a estrutura de agrupamento para otimizar a função objetivo. A equação fundamental pode ser expressa conforme mostrado em

2.12.

$$F(C) = \sum_i \sum_j s_{ij} \delta(C_i C_j) \quad (2.12)$$

Na equação 2.12 $F(C)$ é a função objetivo a ser otimizada, s_{ij} é uma medida de similaridade ou dissimilaridade entre os elementos i e j , (C_i e C_j são os clusters que contêm os elementos i e j , respectivamente, $\delta(C_i C_j)$ é uma função delta que assume 1 se C_i e C_j estão no mesmo cluster e 0 caso contrário. O algoritmo itera até que a estrutura de agrupamento alcance a configuração que optimiza a função objetivo.

2.8.3 Algoritmo BIRCH

O algoritmo BIRCH (Balanced Iterative Reducing and Clustering using Hierarchies) foi proposto por Zhang *et al.* (1996). O artigo propõe um método eficiente para agrupamento de dados em grandes conjuntos. O algoritmo BIRCH é projetado para lidar com grandes bases de dados, minimizando a necessidade de varreduras múltiplas dos dados, ou seja, é projetado para ser eficiente em termos de processamento de grandes conjuntos de dados, reduzindo a quantidade de vezes que os dados precisam ser percorridos durante o processo de agrupamento. A ideia central do BIRCH é criar uma estrutura hierárquica em forma de árvore, onde os pontos de dados são agregados em clusters folha e, em seguida, esses clusters folha são agrupados para formar clusters mais amplos. O algoritmo utiliza um esquema de resumo baseado em uma estrutura de árvore chamada *Característica de Agrupamento (Clustering Feature)* (CF), que armazena informações compactas sobre os clusters, permitindo uma atualização eficiente à medida que novos pontos de dados são incorporados, e as informações compactas no formato CF ajudam a manter um resumo eficiente dos clusters durante todo o processo de agrupamento. Essa eficiência é particularmente valiosa ao lidar com grandes volumes de dados. A equação 2.13 ilustra como um ponto de dado é inserido em um cluster CF, onde "1" representa o número de pontos no subcluster, "n" é o número total de pontos no subcluster e em seus descendentes. Descendentes são definidos como qualquer subcluster posicionado hierarquicamente abaixo do subcluster em análise na estrutura de árvore de clusters, significando que um subcluster pode originar outros subclusters, os quais são considerados seus descendentes. "LS" corresponde à soma linear dos pontos no subcluster, enquanto "SS" indica a soma dos quadrados dos pontos no subcluster. No algoritmo BIRCH, clusters e subclusters são usados para representar a estrutura

hierárquica. Quando um novo ponto de dados é adicionado ao conjunto, ele é associado a um subcluster existente ou usado para criar um novo subcluster. A equação mencionada é uma forma de atualizar o CF de um subcluster. A equação 2.13 significa que o vetor CF é atualizado adicionando informações do novo ponto ou subcluster ao vetor existente. Isso é feito levando em consideração o número total de pontos, a soma linear e a soma dos quadrados. Essa fórmula é usada durante a fase de construção da estrutura hierárquica do BIRCH, onde os subclusters são atualizados à medida que novos pontos são adicionados ao conjunto de dados. Essa atualização é feita de maneira eficiente para minimizar a necessidade de múltiplas varreduras dos dados. A equação 2.14 mostra a criação de um cluster de subárvore. A junção de dois clusters é feita simplesmente adicionando as informações do segundo ao primeiro como visto na equação 2.15

$$CF = CF + (1, n, LS, SS) \quad (2.13)$$

$$CF = (1, n, LS, SS) \quad (2.14)$$

$$CF_1 = CF_1 + CF_2 \quad (2.15)$$

De acordo com Fontanini e Abreu (2018), em análises típicas de padrões de carga, muitos métodos de agrupamento diferentes têm sido utilizados para segmentar clientes de energia, interpretar comportamentos e informar estratégias de alcance de marketing. Devido aos requisitos de memória e eficiência computacional, muitos algoritmos de agrupamento não têm a capacidade de realizar análises em grande escala urbana. Nesse artigo, um algoritmo de agrupamento BIRCH orientado a dados de forma escalável foi utilizado para extrair os padrões de carga típicos de um bairro. O método desenvolvido permite analisar rapidamente grandes conjuntos de dados de séries temporais em escala urbana. Um conjunto de funções de custo baseadas na compacidade e separação dos clusters foi utilizado para agrupar padrões de carga de consumo alto, intermediário e baixo. As funções de custo foram avaliadas quanto à adequação para produzir clusters maiores e menores para contextualização e interpretabilidade. O autor cita que usando esse algoritmo, a análise de carga típica pode ser realizada em escala urbana e potencialmente para aprendizado e classificação contínuos em tempo real por empresas de serviços públicos.

O artigo He *et al.* (2020), relata o desenvolvimento de um sistema inteligente para identificar padrões dentro dos dados de eletricidade industrial. Nesse trabalho são utilizados 5 algoritmos, dentre eles o BIRCH para, para uma base de 15 conjuntos de dados de referência e dados de consumo de eletricidade. Padrões de eletricidade hierárquicos diários e anuais são determinados analisando dados de eletricidade industrial. Segundo o autor, o sistema proposto de identificação de padrões de eletricidade possui um potencial considerável de aplicação para empresas e companhias de energia, pois podem fornecer orientações úteis.

2.8.4 *Métricas de avaliação de agrupamentos*

2.8.4.1 *Coeficiente de Silhueta*

Em Rousseeuw (1987), o autor aborda a necessidade de métodos objetivos e visuais para avaliar a qualidade de soluções de agrupamento. O artigo propõe a métrica de silhueta como uma medida que combina aspectos de compacidade e separação dos clusters. A silhueta varia de -1 a 1, indicando o quanto bem um objeto se encaixa no seu próprio cluster em comparação com outros clusters. A métrica é visualizada graficamente, fornecendo uma representação intuitiva da qualidade do agrupamento. A métrica de silhueta é calculada para cada ponto no conjunto de dados, resultando em uma medida global da qualidade do agrupamento. Valores próximos de 1 indicam que o objeto está bem enquadrado em seu cluster, valores próximos de -1 indicam que o objeto pode estar melhor em um cluster diferente, e valores próximos de 0 indicam sobreposição de clusters ou objetos na fronteira entre clusters. A representação gráfica desses coeficientes ajuda a identificar padrões e avaliar a coesão e separação dos clusters. Cada cluster é representado por uma chamada silhueta, que se baseia na comparação de sua coesão e separação. Essa silhueta mostra quais objetos estão bem ajustados ao seu cluster e quais estão apenas em algum lugar entre clusters. Todo o agrupamento é exibido combinando as siluetas em um único gráfico, permitindo uma apreciação da qualidade relativa dos clusters e uma visão geral da configuração dos dados. A largura média da silhueta fornece uma avaliação da validade do agrupamento e pode ser usada para selecionar um número apropriado de clusters. A distância média intra-cluster é mostrada na equação 2.16, a distância mínima inter-cluster é vista na equação 2.17, o Coeficiente de Silhueta pode ser observado na equação 2.18.

$$a(i) = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} dist(i, j) \quad (2.16)$$

A distância média intra-cluster ($a(i)$) para um objeto i em um conjunto de dados agrupado é calculada como a média das dissimilaridades entre o objeto i e todos os outros objetos no mesmo cluster ao qual i pertence. Onde $a(i)$ é a distância média intra-cluster para o objeto i , A é o cluster ao qual o objeto i pertence, $|A|$ é o número de objetos no cluster A , j é um objeto em A diferente de i , $dist(i,j)$ é a dissimilaridade (ou distância) entre os objetos i e j . Essencialmente, $a(i)$ representa quanto bem o objeto i está compactamente agrupado com outros objetos em um cluster, calculando a média das dissimilaridades entre i e todos os outros objetos no mesmo cluster. Quanto menor o valor de $a(i)$, melhor é a coesão do cluster ao qual i pertence.

$$b(i) = \min_{C \neq A} \left\{ \frac{(\sum j \in C) d(i, j)}{|C|} \right\} \quad (2.17)$$

A distância mínima inter-cluster ($b(i)$) é uma medida que representa a menor distância média entre um ponto i em um cluster específico (A) e os pontos em qualquer outro cluster (C) ao qual i não pertence. Onde C representa um cluster diferente de A , $d(i,j)$ é a dissimilaridade (ou distância) entre os pontos i e j , $(\sum j \in C) d(i, j)$ é a soma das dissimilaridades de i para todos os pontos j no cluster C , $|C|$ é o número de pontos no cluster C , $\min_{C \neq A}$ denota a escolha da menor média de dissimilaridade entre i e os pontos em qualquer cluster C diferente de A . Em termos mais simples, $b(i)$ é a menor média das distâncias entre o ponto i e os pontos em um cluster diferente de A . Essa métrica é usada no cálculo do coeficiente de silhueta para avaliar a qualidade dos clusters em uma análise de agrupamento.

$$s(i) = \frac{b(i) - a(i)}{\max \{a(i), b(i)\}} \quad (2.18)$$

Na equação 2.18, $\max \{a(i), b(i)\}$ é o máximo entre $a(i)$ e $b(i)$, garantindo que $s(i)$ esteja no intervalo de $[-1, 1]$.

2.8.4.2 Índice de Calinski-Harabasz

O Índice de Calinski-Harabasz, também conhecido como critério de razão de dispersão, foi introduzido por Calinski e Harabasz (1974). Neste artigo, os autores propõem um método de dendrograma para análise de cluster, centrado no conceito de dendritos (Um dendrograma é uma representação gráfica de dados em forma de árvore, onde objetos semelhantes são agrupados em clusters), e o índice de Calinski-Harabasz é apresentado como uma medida de validação

interna para avaliar a qualidade dos agrupamentos obtidos. O índice é calculado com base na razão entre a dispersão média entre os clusters e a dispersão média dentro dos clusters. É usado para avaliar a coesão intra-cluster e a separação inter-cluster. Na equação 2.19 é mostrada a dispersão intra-cluster, na equação 2.20 é expressa a dispersão inter-cluster, na equação 2.21 observa-se o Índice de Calinski-Harabasz.

$$SSW = \sum_{i=1}^k \sum_{x \in C_i} d^2(x, c_i) \quad (2.19)$$

SSW representa a soma dos quadrados das distâncias entre cada ponto no cluster e o centro desse cluster. É uma medida de coesão intra-cluster. Onde k é o número de clusters, C_i é o conjunto de pontos no cluster i , $d(x, c_i)$ é a distância entre o ponto x e o centro do cluster c_i .

$$SSB = \sum_{i=1}^k n_i \cdot d^2(c_i, c_{total}) \quad (2.20)$$

SSB representa a soma dos quadrados das distâncias ponderadas entre os centros dos clusters e o centro global de todos os dados. servindo como uma medida de separação entre os clusters. Aqui, n_i é o número de pontos no cluster i , c_i é o centro do cluster i , c_{total} é o centro global de todos os dados.

$$CH = \frac{SSB}{(k-1)} \times \frac{(N-k)}{SSW} \quad (2.21)$$

O Índice de Calinski-Harabasz (CH) é calculado como a razão entre a dispersão inter-cluster e a dispersão intra-cluster, ajustada pelo número de clusters e o tamanho dos dados. O objetivo é maximizar esse índice, indicando clusters bem separados e coesos. O Índice de Calinski-Harabasz é usado como uma medida de validação interna, onde valores mais altos indicam agrupamentos mais robustos e distintos.

2.8.4.3 índice de Davies-Bouldin

Em Davies e Bouldin (1979), é introduzido o Índice de Davies-Bouldin como uma métrica para avaliação da separação entre clusters em técnicas de agrupamento. O artigo aborda a necessidade de métricas objetivas para avaliar a qualidade de técnicas de agrupamento. Propõe uma medida que avalia a separação entre clusters, considerando tanto a compacidade quanto a

dissimilaridade entre eles. A métrica é baseada na comparação dos clusters dois a dois. Para cada par de clusters, calcula-se a soma de dois termos: a dissimilaridade média entre os pontos do cluster e a distância entre os centros dos clusters. A métrica global é obtida considerando o máximo dessas somas sobre todos os pares de clusters. Seja C_i um cluster e d_{ij} a distância média entre os pontos de C_i e C_j . A dissimilaridade média dentro do cluster C_i é d_{ii} . A métrica para o par de clusters C_i e C_j é definida na equação 2.22. A métrica global é obtida considerando o máximo desses valores sobre todos os pares de clusters, e é mostrada na equação 2.23

$$R_{ij} = \frac{d_{ii} + d_{jj}}{d_{ij}} \quad (2.22)$$

$$DB = \max_{i \neq j} R_{ij} \quad (2.23)$$

Quanto menor o valor de DB, melhor é a separação entre os clusters. A métrica considera tanto a compacidade (baixo d_{ii}) quanto a dissimilaridade entre clusters (alto d_{ij}).

2.9 Algoritmos de redução de dimensionalidade

2.9.1 Análise de Componentes Principais (PCA)

Em Pearson (1901), foram introduzidos conceitos fundamentais como covariância, que mede como variáveis mudam juntas. Se a covariância é positiva, isso indica que quando uma variável aumenta, a outra também tende a aumentar. Se a covariância é negativa, indica que quando uma variável aumenta, a outra tende a diminuir. Uma covariância próxima a zero indica que as variáveis são pouco relacionadas, e variância, que é uma medida de quão dispersos os valores de um conjunto de dados estão em relação à média. Esses conceitos foram essenciais para a introdução do método de PCA. O artigo de Hotelling (1933), foi um dos principais para o desenvolvimento do PCA, na compreensão teórica e na aplicação prática do PCA. O autor foi um dos estatísticos que formalizou o PCA usando a matriz de covariância e apresentou a teoria em termos de autovalores e autovetores. O PCA é uma técnica estatística usada para reduzir a dimensionalidade dos dados, mantendo o máximo possível de variância original. A matriz de covariância quantifica as relações entre todas as variáveis do conjunto de dados e é fundamental para o cálculo das componentes principais. Componentes principais são combinações lineares das variáveis originais, são ordenados por importância, com o primeiro componente principal

capturando a maior variação nos dados. Os componentes principais são ortogonais entre si, isto é, não têm correlação mútua. A soma das variâncias dos componentes principais é igual à variância total dos dados originais. matriz de covariância S é mostrada na equação 2.24.

$$S = \frac{1}{n-1} (X - \bar{X})^T (X - \bar{X}) \quad (2.24)$$

Onde X representa um conjunto de dados com n observações e p variáveis, \bar{X} é o vetor médio das observações.

A obtenção dos autovalores (λ) e autovetores (v) da matriz de covariância são obtidos a partir da equação característica vista em 2.25. Através da equação 2.25 pode-se achar os autovalores e de posse deles, encontrar os autovetores associados a cada autovalor.

$$\det(S - \lambda I) = 0 \quad (2.25)$$

Os autovalores representam a quantidade de variância explicada por cada componente principal, e os autovetores indicam a direção dessas componentes. Os autovetores da matriz de covariância são os próprios componentes principais. As componentes principais são selecionadas com base nos autovalores. Os dados originais podem ser transformados para o espaço das componentes principais usando os autovetores. Se V é a matriz de autovetores, a transformação é dada por $W = X \cdot V$, sendo W a matriz de dados transformada.

Segundo Kong *et al.* (2017), na análise de dados, uma técnica linear muito importante para extrair informações dos dados é a Análise de Componentes Principais. Os Componentes Principais (CPs) são as direções nas quais os dados têm as maiores variâncias e capturam a maior parte do conteúdo informativo dos dados. Eles correspondem aos autovetores associados aos maiores autovalores da matriz de autocorrelação dos vetores de dados. Ao contrário, os autovetores que correspondem aos menores autovalores da matriz de autocorrelação dos vetores de dados são definidos como os *Componentes Menores (Minor Components)* (CMs) e são as direções nas quais os dados têm as menores variâncias (representam o ruído nos dados). Expressar vetores de dados em termos dos Componentes Menores é chamado de *Análise de Componentes Menores (Minor Component Analysis)* (MCA). Através do PCA, muitas variáveis podem ser representadas por poucos componentes, então o PCA pode ser considerado tanto uma tecnologia de extração de características quanto de compressão de dados. Atualmente, o PCA tem sido aplicado com sucesso a muitos problemas de processamento de dados, como estimação

espectral de alta resolução, identificação de sistemas, compressão de imagem e reconhecimento de padrões. A MCA é principalmente usada para resolver o problema de mínimos quadrados totais, que é uma tecnologia amplamente utilizada para compensar erros de dados na estimação de parâmetros ou identificação de sistemas. O PCA é uma ferramenta útil em extração de características, compressão de dados, reconhecimento de padrões e previsão de séries temporais (Zhang e Leung (2000), Washizawa (2009)).

Em Perner (2012), é reforçada a ideia que a PCA, foi desenvolvida pela primeira vez por Pearson (1901) e por Hotelling (1933). O autor ressalta que o PCA é uma das técnicas de redução de dimensionalidade mais amplamente utilizadas em problemas como compressão de dados e agrupamento, reconhecimento de padrões e visualização. O autor ainda cita que a ideia principal é reduzir a dimensionalidade de uma população de dados tentando preservar suas características espaciais. Isso é alcançado com uma transformação linear para o espaço de componentes principais, que são ordenados de tal forma que os primeiros retêm a maior parte da variação dos dados. Os componentes principais são obtidos realizando a eigenanálise da matriz de covariância dos dados, ou seja análise de autovalores e autovetores.

Conforme Naik (2017), PCA é uma das técnicas amplamente utilizadas de fatoração de matrizes para redução de dimensionalidade e revelação de fatores ocultos subjacentes a conjuntos de variáveis aleatórias, sinais ou medições. O PCA é essencialmente um método para extrair sinais individuais de misturas de sinais. Seu poder reside nas suposições físicas de que diferentes processos físicos geram sinais não relacionados.

2.9.2 *t-Distribuição de Proximidade Estocástica (t-SNE)*

Em Maaten e Hinton (2008), foi proposta uma técnica chamada *t-Distribuição de Proximidade Estocástica (t-Distributed Stochastic Neighbor Embedding)* (t-SNE), que visualiza dados de alta dimensão atribuindo a cada ponto de dados uma localização em um mapa bidimensional ou tridimensional.

A técnica é uma variação do trabalho de Hinton e Roweis (2002) que, segundo o autor, é muito mais fácil de otimizar e produz visualizações significativamente melhores, reduzindo a tendência de agrupar pontos no centro do mapa. Ainda de acordo com Maaten e Hinton (2008), o t-SNE é superior a técnicas existentes na criação de um único mapa que revela estruturas em diversas escalas, em outras palavras, o t-SNE é capaz de representar padrões e relações nos dados, independentemente de sua complexidade ou escala, de uma maneira que

outras técnicas de visualização não conseguem fazer com tanta precisão. Isso é especialmente importante para dados de alta dimensão que estão em várias estruturas de baixa dimensão diferentes, mas relacionadas, como imagens de objetos de várias classes vistos de múltiplos pontos de vista. Para visualizar a estrutura de conjuntos de dados muito grandes, o t-SNE pode utilizar uma abordagem em que a estrutura implícita de todos os dados influencia a exibição de um subconjunto específico, utilizando informações de conectividade entre os pontos. No trabalho o desempenho do t-SNE foi ilustrado em uma variedade de conjuntos de dados e o comparado com muitas outras técnicas de visualização não paramétricas, incluindo o mapeamento de Sammon, Isomap e Locally Linear Embedding. Conforme o autor, as visualizações produzidas pelo t-SNE são significativamente melhores do que aquelas produzidas pelas outras técnicas em quase todos os conjuntos de dados. Dado um conjunto de pontos de dados de alta dimensão x_1, x_2, \dots, x_n no espaço de entrada, o t-SNE cria representações correspondentes de baixa dimensão y_1, y_2, \dots, y_n no espaço de saída. A similaridade entre pares de pontos no espaço original é representada por distribuições de probabilidade condicional. A probabilidade $p_{j|i}$ mede a semelhança entre x_i e x_j e a sua equação é mostrada em 2.26. Onde σ representa a largura da distribuição t-Student, vista em Student (1908), ao redor de um ponto específico x_i no espaço de alta dimensão, ele controla a largura da distribuição t-Student. O parâmetro σ afeta a dispersão da distribuição t-Student. Valores maiores de σ causam uma distribuição mais ampla, enquanto valores menores levam a uma distribuição mais estreita. O σ pode variar de ponto para ponto, ajustando-se às características locais da densidade dos dados. Em regiões densas, σ pode ser menor para capturar detalhes finos, enquanto em regiões mais esparsas, σ pode ser maior para uma visão mais abrangente. A similaridade no espaço de menor dimensão entre pares de pontos é representada pela probabilidade $q_{j|i}$ que mede a semelhança entre os pontos y_i e y_j e é mostrada na equação 2.27.

$$p_{j|i} = \frac{\exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_i^2}\right)}{\sum_{k \neq i} \exp\left(-\frac{\|x_i - x_k\|^2}{2\sigma_i^2}\right)} \quad (2.26)$$

$$q_{j|i} = \frac{\exp\left(-\frac{\|y_i - y_j\|^2}{2}\right)}{\sum_{k \neq i} \exp\left(-\frac{\|y_i - y_k\|^2}{2}\right)} \quad (2.27)$$

A *Divergência de Kullback-Leibler (Kullback-Leibler Divergence)* (KL), relatada em Kullback e Leibler (1951), é uma medida na teoria da informação que quantifica a diferença

entre duas distribuições de probabilidade. Tem um papel importante na teoria estatística e na comparação de distribuições. A KL representa a média ponderada dos logaritmos das razões entre as probabilidades das duas distribuições. Essa medida é amplamente utilizada em diversas áreas, incluindo estatística, aprendizado de máquina e processamento de sinais. A medida KL é capaz de quantificar a perda de eficiência ao utilizar uma distribuição para modelar outra, é uma ferramenta essencial na teoria da informação, fornecendo uma medida quantitativa para comparar distribuições de probabilidade.

De acordo com Maaten e Hinton (2008), a função custo do t-SNE é definida como a divergência Kullback-Leibler entre as distribuições de probabilidade no espaço original e no espaço de menor dimensão. O objetivo é minimizar essa divergência. Onde P_i é a distribuição de probabilidade condicional no espaço original e representa a distribuição de probabilidade condicional sobre todos os outros pontos de dados, dado o ponto de dados x_i , Q_i é a distribuição de probabilidade condicional no espaço de menor dimensão e representa a distribuição de probabilidade condicional sobre todos os outros pontos do mapa, dado o ponto do mapa y_i e KL trata-se da divergência Kullback-Leibler. A função custo do t-SNE é mostrada na equação 2.28.

$$C = \sum_i KL(P_i || Q_i) = \sum_i \sum_j p_{j|i} \log\left(\frac{p_{j|i}}{q_{j|i}}\right) \quad (2.28)$$

Em Khan *et al.* (2023), foi proposto um framework para investigar as capacidades de técnicas de redução de dimensionalidade como o t-SNE aplicadas a dados em escala urbana para identificar características-chave de áreas com alto consumo e geração com base em características de edifícios. A análise foi realizada em dados medidos de 2735 códigos postais, consistindo de 72000 residências/edifícios de uma cidade nos Países Baixos. Os resultados da avaliação mostraram que o t-SNE é significativamente mais sensível ao parâmetro de perplexidade. O framework proposto foi criado para auxiliar operadores de rede e planejadores de energia na extração de informações dos dados de consumo de energia no nível de bairros, utilizando técnicas de redução de dimensionalidade de alto desempenho.

Segundo Rosenlund *et al.* (2020), o sistema de energia está mudando rapidamente, e novas ferramentas para prever eventos indesejados são necessárias para manter um alto nível de segurança de fornecimento. Grandes volumes de dados da rede elétrica norueguesa foram coletados ao longo de vários anos, registrando eventos indesejados como interrupções, falhas à terra, quedas de tensão e mudanças rápidas de tensão. Nesse artigo é demonstrada a aplicação de técnicas de agrupamento e redução de dimensionalidade como o t-SNE, com o objetivo de prever

eventos indesejados. Diversas técnicas foram aplicadas para reduzir a dimensionalidade dos conjuntos de dados e agrupar eventos com base em características analíticas, separando eventos contendo falhas de situações normais. O artigo mostra que o modelo preditivo desenvolvido possui alguma capacidade de previsão ao usar conjuntos de dados平衡ados contendo um número semelhante de eventos com falhas e eventos sem falhas. No entanto, uma das principais descobertas é que essa capacidade preditiva é significativamente reduzida ao usar conjuntos de dados desbalanceados.

Conforme Khan *et al.* (2020), a previsão de carga elétrica constitui um elemento crucial da rede elétrica inteligente. Esta assegura a sustentabilidade e auxilia as concessionárias na adoção de estratégias eficazes do ponto de vista econômico, tanto para o planejamento quanto para a operação do sistema energético. Segundo o autor, métodos convencionais de previsão de carga não conseguem lidar com grandes volumes de dados que têm uma relação não linear com a potência de carga. Portanto, é necessária uma abordagem integrada que adote um procedimento de coordenação entre diferentes módulos de previsão de carga de eletricidade. Nesse artigo foi desenvolvido uma nova arquitetura de previsão de carga elétrica que integra três módulos, que são, seleção, extração e classificação de dados, em um único modelo. Primeiro, características essenciais são selecionadas com a ajuda de métodos de eliminação recursiva de características e floresta aleatória. Isso ajuda a reduzir a redundância de características e, portanto, a sobrecarga computacional para os dois módulos seguintes. Em segundo lugar, a redução de dimensionalidade é realizada com a ajuda do t-SNE para a melhor extração de características. Por fim, a carga elétrica é prevista com a ajuda de uma *Rede Neural Profunda (Deep Neural Network)* (DNN). Para melhorar a tendência de aprendizado e a eficiência computacional, foi utilizado um algoritmo de busca em rede para ajustar os parâmetros críticos da DNN. O autor ressalta que os resultados da simulação confirmam que o modelo proposto alcança maior precisão em comparação com a DNN padrão.

Segundo Li *et al.* (2021), a relação de conexão da topologia da rede de distribuição é de grande importância para a manutenção, diagnóstico de falhas e otimização de desligamentos programados da rede de distribuição. O autor propõe um método para a verificação topológica de áreas de subestação de baixa tensão. O artigo apresenta um modelo para correção de erros e identificação de fase de acesso do usuário em estações de baixa tensão com base em dados de tensões multidimensionais coletados por medidores inteligentes. O modelo pode fornecer uma referência para a identificação topológica e solução de problemas de linha de subestações de baixa

tensão. Primeiramente, os algoritmos t-SNE e PCA realizam a redução de dimensionalidade nos dados originais de carga para resolver o problema de redundância causado pela alta dimensão do conjunto original de dados de tensão. Em segundo momento, o algoritmo de Fator Local de Excentricidade é usado para identificar amostras anômalas no conjunto de dados de tensão. Em seguida, o método de agrupamento espectral é utilizado para agrupar os dados de carga com dimensionalidade reduzida para realizar a identificação de fase de usuários monofásicos na área da estação de baixa tensão. Por fim, dados reais de uma determinada área em Haining, província de Zhejiang, China, são utilizados como casos de simulação para demonstração. Os resultados dos estudos de caso, segundo o artigo, mostraram que o modelo proposto é viável e eficaz.

2.10 Padronização e normalização de dados

2.10.1 Padronização Z-score

De acordo com Cheadle *et al.* (2003) e Gal e Rubinfeld (2019), a padronização Z-score, também conhecida como normalização Z-score, é um método de transformação de dados que ajusta a distribuição de uma variável para que ela tenha uma média de zero e um desvio padrão de um. Essa técnica é amplamente utilizada em estatística e análise de dados para tornar as variáveis comparáveis, especialmente quando diferentes variáveis têm escalas diferentes. Na equação 2.29 é mostrada a padronização Z-score. Onde z é o valor padronizado, x é o valor original, μ é a média dos dados, δ é o desvio padrão dos dados. A padronização Z-score garante que a média dos dados padronizados seja zero. O desvio padrão dos dados padronizados é igual a um. Isso significa que os dados padronizados estão em unidades de desvio padrão em relação à média. A forma da distribuição dos dados é preservada após a padronização. Ou seja, se os dados originalmente seguem uma distribuição normal, os dados padronizados também seguirão uma distribuição normal. Os dados padronizados tornam-se comparáveis entre diferentes variáveis, pois estão na mesma escala. A padronização Z-score elimina o viés introduzido por diferentes escalas nas variáveis, permitindo uma comparação mais justa entre elas. Com a padronização os coeficientes em modelos estatísticos ou de aprendizado de máquina se tornam mais facilmente interpretáveis, pois estão todos na mesma escala.

$$z = \frac{x - \mu}{\delta} \quad (2.29)$$

2.10.2 Normalização de máximo e mínimo

Segundo Han *et al.* (2022a) e Raschka e Mirjalili (2017), a normalização de máximo e mínimo é uma técnica comum para colocar os valores de uma variável em uma escala específica, geralmente entre 0 e 1. Essa normalização é útil quando os dados originais têm escalas diferentes ou quando se deseja colocar todos os valores em uma escala padronizada. A normalização de máximo e mínimo é especialmente útil em algoritmos sensíveis à escala, como redes neurais e algoritmos de aprendizado de máquina, onde diferentes escalas podem afetar o desempenho do modelo. Na equação 2.30 é mostrada a normalização de máximo e mínimo. A normalização dos dados tenta atribuir a todos os atributos um peso igual. A normalização é particularmente útil para algoritmos de classificação que envolvem redes neurais ou medições de distância, como classificação por vizinho mais próximo e agrupamento. Se estiver usando o algoritmo de retropropagação da rede neural para classificação, normalizar os valores de entrada para cada atributo medido nas tuplas de treinamento ajudará a acelerar a fase de aprendizado. Para métodos baseados em distância, a normalização ajuda a evitar que atributos com faixas inicialmente grandes (por exemplo, renda) ponderem mais do que atributos com faixas inicialmente menores (por exemplo, atributos binários). Também é útil quando não há conhecimento prévio dos dados. A normalização realiza uma transformação linear nos dados originais.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.30)$$

Onde X_{norm} é o valor normalizado, X é o valor original, X_{min} é o valor mínimo na variável, X_{max} é o valor máximo na variável. A equação 2.30 justa todos os valores para que fiquem dentro da faixa [0, 1]. Se X for igual a X_{min} , então X_{norm} será 0, se X for igual a X_{max} , então X_{norm} será 1. A normalização pelo máximo e mínimo preserva as relações entre os valores originais dos dados. Esta abordagem identificará um erro fora dos limites caso uma entrada futura, destinada à normalização, esteja fora da faixa original dos dados.

2.11 Coeficientes de correlação de Pearson e de Spearman

2.11.1 Coeficiente de correlação de Pearson

No artigo Pearson (1909), Pearson aborda a questão da relação entre duas variáveis, A e B, quando os dados são expressos em termos de porcentagens ou outra escala. A ideia

fundamental por trás do coeficiente de correlação de Pearson é medir a força e a direção da relação linear entre duas variáveis. A fórmula original do coeficiente de correlação de Pearson está expressa na equação. Onde X_i e Y_i são valores individuais das variáveis X e Y. Já \bar{X} e \bar{Y} são as médias de X e Y, respectivamente. O coeficiente de correlação não é afetado pela escala ou unidade em que os dados são expressos, contanto que a relação linear entre as variáveis seja preservada. O coeficiente de correlação de Pearson varia entre -1 e 1, onde -1 indica uma correlação negativa perfeita, 1 indica uma correlação positiva perfeita e 0 indica ausência de correlação linear. A equação é o padrão para correlação linear, e ela assume que os dados seguem uma distribuição bivariada normal. Se os dados não atenderem a essas condições, outras medidas de associação podem ser mais apropriadas.

$$r = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2 \cdot \sum(Y_i - \bar{Y})^2}} \quad (2.31)$$

De acordo com Iwanowski (2018), o coeficiente de correlação entre a geração de energia renovável com base em vento ou solar e o consumo de eletricidade em todo o sistema elétrico polonês, clientes industriais e residências típicas na Polônia, permite estimar o volume de eletricidade que pode ser transferido diretamente para os clientes para atender às necessidades de consumo de energia e o volume de eletricidade que deve ser armazenado para garantir um fornecimento contínuo. Conforme indicado no artigo, esse volume oferece uma perspectiva sobre a capacidade de armazenamento de energia requerida para diferentes perfis de clientes. O trabalho relata que o coeficiente de correlação entre vento, sol e consumo de energia deve permitir estimar o volume de eletricidade que pode ser transferido diretamente para os clientes para cobrir as necessidades de consumo de energia e a quantidade de energia que deve ser armazenada para garantir o fornecimento contínuo de eletricidade aos clientes durante períodos sem vento e sem sol. Os clientes são divididos em 4 grupos, de acordo com o nível de tensão de conexão e a classificação de potência requerida. Cada grupo é tarifado com um preço diferente pelos serviços de distribuição de eletricidade. No artigo um coeficiente de correlação positivo entre a geração e o consumo de eletricidade, direcionado para 1, significa que é necessária uma capacidade de armazenamento de energia pequena para fornecer aos clientes durante todo o ano, porque quase todo o consumo é coberto pela geração, que ocorre ao mesmo tempo. Da mesma forma, um coeficiente de correlação negativo entre a geração e o consumo de eletricidade, direcionado para -1, significa que é necessária uma grande capacidade de armazenamento de energia, pois quase toda a energia gerada deve ser armazenada para cobrir o consumo, que não

ocorre ao mesmo tempo. Um coeficiente de correlação neutro, direcionado para 0, significa que a capacidade de armazenamento de energia necessária está entre a capacidade necessária para correlação positiva e a necessária para correlação negativa.

2.11.2 Coeficiente de correlação de Spearman

Charles Spearman introduziu o coeficiente de correlação de postos em 1904, tem-se a publicação do artigo em Spearman (1961). O coeficiente de correlação de Spearman avalia a força e a direção de uma relação monotônica entre duas variáveis. A monotonicidade refere-se à consistência na direção da relação, mas não necessariamente à taxa constante de mudança. O processo geral pode ser descrito como: ordenação de dados, onde para cada uma das duas variáveis, os dados são ordenados do menor para o maior, atribuindo um posto para cada valor, cálculo dos diferenciais de postos, que consiste no fato de que para cada par de valores, a diferença entre os postos correspondentes é calculada e por fim, o cálculo do Coeficiente de Correlação de Spearman, que é calculado como o coeficiente de correlação de Pearson entre os diferenciais de postos. Em 2.32 tem-se a equação geral para o coeficiente de correlação de postos de Spearman. Onde d_i são os diferenciais de postos e n é o número de pares de observações. A equação normaliza os diferenciais de postos e fornece um valor entre -1 e 1. Um valor de 1 indica uma relação perfeita positiva monotônica, -1 indica uma relação perfeita negativa monotônica, e 0 indica nenhuma correlação.

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (2.32)$$

Conforme relata Nascimento *et al.* (2019), Os mercados de energia elétrica são ambientes complexos com características muito dinâmicas. A penetração em larga escala de fontes de energia renovável trouxe uma maior incerteza à geração, refletida consequentemente nos preços do mercado de energia elétrica. Dessa forma, de acordo com o autor, são necessários novos métodos avançados de previsão capazes de prever os preços do mercado de eletricidade levando em consideração as novas variáveis que influenciam a variação de preços. Este artigo propõe um novo modelo para previsão de preços de mercado de energia para o dia seguinte com base na aplicação de uma rede neural artificial. Na fase de pré-processamento, são analisados os dados relevantes das diversas variáveis que exercem influência direta nos preços de mercado, tais como geração, temperatura, consumo, entre outros. A associação entre essas variáveis é realizada

usando a correlação de Spearman, resultando na identificação de quais dados têm uma influência maior na variação dos preços de mercado. Essa pré-análise é então utilizada no trabalho para adaptar o processo de treinamento da rede neural artificial, com a finalidade de se conseguir resultados aprimorados na previsão, ao utilizar os dados mais relevantes de maneira apropriada. O Coeficiente de Correlação de Spearman permitiu compreender a tendência da variação de preços de energia. Usando o método de Correlação de Spearman, é possível analisar o valor da correlação entre variáveis com precisão. A análise é realizada em relação ao preço e ao consumo de carga.

2.12 Demanda elétrica

Segundo MME/ANEEL (2021), a demanda representa a média das potências elétricas ativas ou reativas, que são inseridas ou solicitadas ao sistema elétrico de distribuição em um período de tempo específico. A demanda contratada é a potência ativa que deve ser obrigatória e continuamente fornecida pela distribuidora no ponto de conexão, conforme os termos estabelecidos em contrato, expressa em quilowatts (kW). A demanda medida refere-se à maior potência ativa inserida ou solicitada ao sistema elétrico de distribuição pela carga ou geração, sendo verificada por meio de medição e agregada em intervalos de 15 minutos durante o período de faturamento, também expressa em quilowatts (kW). No caso de posto tarifário, a demanda contratada deve permanecer constante ao longo do contrato, exceto para unidades consumidoras da classe rural e aquelas com sazonalidade reconhecida, para as quais a demanda pode ser contratada conforme um cronograma mensal.

2.13 Posto tarifário

De acordo com (MME/ANEEL (2021), ANEEL (2022b), MME/ANEEL (2022)), posto tarifário refere-se ao intervalo de horas em que as tarifas são aplicadas de maneira distinta ao longo do dia, seguindo a seguinte segmentação:

1. posto tarifário de ponta refere-se a um intervalo de 3 horas consecutivas diárias, estabelecido pela distribuidora de energia com base na curva de carga do seu sistema elétrico. Essa definição é aprovada pela *Agência Nacional de Energia Elétrica* (ANEEL) e abrange toda a área de concessão ou permissão, excluindo os sábados, domingos, terça-feira de carnaval, sexta-feira da Paixão, Corpus Christi e feriados nacionais, tais como 1º de janeiro, 21 de

- abril, 1º de maio, 7 de setembro, 12 de outubro, 2 de novembro, 15 de novembro e 25 de dezembro;
2. posto tarifário intermediário designa um intervalo de duas horas, compreendendo uma hora imediatamente anterior e outra imediatamente posterior ao período de pico. Essa categorização é exclusiva para o grupo B;
 3. posto tarifário fora de ponta abrange o conjunto de horas diárias consecutivas que complementam aquelas definidas nos postos de ponta e, no caso do grupo B, intermediário.

2.14 Modalidade tarifária e tarifação

De acordo com MME/ANEEL (2021), ANEEL (2022a) e CEPEL (2015), a modalidade tarifária comprehende o conjunto de tarifas atribuídas às componentes de consumo de energia elétrica e demanda. A aplicação das tarifas deve considerar variáveis como o perfil do usuário, o grupo e subgrupo, a classe e subclasse, assim como a modalidade tarifária da unidade consumidora. A distribuidora é responsável por disponibilizar em sua página na internet as tarifas atualmente em vigor, devidamente homologadas pela ANEEL, fornecendo informações sobre o número e a data da resolução que as certificou.

2.14.1 Tipos de modalidade tarifária

2.14.1.1 Modalidade tarifária convencional

Como consta em MME/ANEEL (2021) e CEPEL (2015), a modalidade tarifária convencional se distingue pela aplicação de uma única tarifa para o consumo de energia, sem distinção de horários ao longo do dia. Nesse modelo tarifário convencional, não ocorre a contratação de demanda. Abaixo pode-se ver na equação 2.33 o equacionamento para a tarifação convencional.

$$\text{Tarifa Convencional (R\$)} = \text{Tarifa de consumo (R\$/kWh)} \cdot \text{Consumo (kWh) Medido} \quad (2.33)$$

2.14.1.2 Modalidade tarifária horária branca

De acordo com MME/ANEEL (2021) e ANEEL (2022c), a opção tarifária horária branca apresenta distinções nas tarifas de consumo de energia elétrica conforme os diferentes

horários de utilização ao longo do dia, dividindo-se em 3 (três) postos tarifários:

1. 1 (uma) tarifa para o posto tarifário ponta;
2. 1 (uma) tarifa para o posto tarifário intermediário;
3. 1 (uma) tarifa para o posto tarifário fora de ponta.

2.14.1.3 Modalidade tarifária horária verde

Conforme MME/ANEEL (2021), ANEEL (2022a) e ME (2019), a modalidade tarifária horária verde é caracterizada por:

1. 1 (uma) tarifa para a demanda, sem segmentação horária;
2. 1 (uma) tarifa para o consumo de energia elétrica para o posto tarifário ponta;
3. 1 (uma) tarifa para o consumo de energia elétrica para o posto tarifário fora de ponta.

Abaixo pode-se ver o equacionamento para o consumo faturado nos horários de ponta e fora de ponta 2.34, a equação para a demanda faturada 2.35, além da equação para a multa por ultrapassagem de demanda 2.36 para a tarifação horosazonal verde.

$$\begin{aligned} \text{Consumo Faturado} = & (\text{Tarifa}_{\text{Consumo horário ponta}} \cdot \text{Consumo}(kW)_{\text{Medido horário ponta}}) + \\ & (\text{Tarifa}_{\text{Consumo horário fora ponta}} \cdot \text{Consumo}(kW)_{\text{Medido horário fora ponta}}) \end{aligned} \quad (2.34)$$

$$\text{Demanda Faturada (R\$)} = \text{Tarifa}_{\text{Demanda}}(\text{R\$/kW}) \cdot \text{Demanda}_{\text{Contratada}}(\text{kW}) \quad (2.35)$$

$$\begin{aligned} \text{Demanda Ultrapassada (R\$)} = & 2 \cdot \text{Tarifa}_{\text{Demanda}}(\text{R\$/kW}) \cdot (\text{Demanda}_{\text{Medida}} \\ & (\text{kW}) - \text{Demanda}_{\text{Contratada}}(\text{kW})) \end{aligned} \quad (2.36)$$

2.14.1.4 Modalidade tarifária horária azul

Conforme MME/ANEEL (2021), ANEEL (2022a) e ME (2019), a modalidade tarifária horária azul é caracterizada por:

1. 1 (uma) tarifa para a demanda para o posto tarifário ponta;
2. 1 (uma) tarifa para a demanda para o posto tarifário fora de ponta;
3. 1 (uma) tarifa para o consumo de energia elétrica para o posto tarifário ponta;
4. 1 (uma) tarifa para o consumo de energia elétrica para o posto tarifário fora de ponta.

Abaixo pode-se ver o equacionamento para a demanda faturada 2.37, além da equação para a multa por ultrapassagem de demanda 2.38 para a tarifação horosazonal azul. Ressalta-se que a tarifação do consumo na tarifação horodazonal azul é o mesmo mostrado na equação 2.34.

$$\begin{aligned}
 \text{Demanda Faturada (R\$)} &= (\text{Tarifa}_{\text{Demanda horário ponta}} (\text{R\$}/\text{kW}) \\
 &\quad \cdot \text{Demanda}_{\text{Contratada horário ponta}} (\text{kW})) \quad (2.37) \\
 &+ (\text{Tarifa}_{\text{Demanda horário fora ponta}} (\text{R\$}/\text{kW}) \cdot \text{Demanda}_{\text{Contratada horário fora ponta}} (\text{kW})) \\
 \\
 \text{Demanda Ultrapassada (R\$)} &= 2 \cdot \text{Tarifa}_{\text{Demanda horário ponta}} (\text{R\$}/\text{kW}) \\
 &\cdot (\text{Demanda}_{\text{Medida horário ponta}} (\text{kW}) - \text{Demanda}_{\text{Contratada horário ponta}} (\text{kW})) \quad (2.38) \\
 &+ 2 \cdot \text{Tarifa}_{\text{Demanda horário fora ponta}} (\text{R\$}/\text{kW}) \\
 &\cdot (\text{Demanda}_{\text{Medida horário fora ponta}} (\text{kW}) - \text{Demanda}_{\text{Contratada horário fora ponta}} (\text{kW}))
 \end{aligned}$$

2.14.1.5 Grupo B de unidades consumidoras de energia elétrica

O Grupo B refere-se a uma categoria formada por unidades consumidoras conectadas a uma tensão inferior a 2,3 kV, sendo subdividido nos seguintes subgrupos:

1. subgrupo B1: residencial;
2. subgrupo B2: rural;
3. subgrupo B3: demais classes;
4. subgrupo B4: Iluminação Pública.

Unidade consumidora do Grupo B, com tensão inferior a 2,3 kV em rede aérea, será categorizada como tal se a carga e a potência de geração instalada na unidade consumidora forem iguais ou inferiores a 75 kW. Para unidades consumidoras do Grupo B, com tensão inferior a 2,3 kV em sistema subterrâneo, a classificação é válida até o limite de potência instalada, conforme o padrão de atendimento da distribuidora, com a consideração do direito de opção para o subgrupo AS do Grupo A.

2.14.1.6 Grupo A de unidades consumidoras de energia elétrica

Este trabalho tem como foco a análise de unidades consumidoras de energia elétrica do grupo A.

De acordo com MME/ANEEL (2021) e ANEEL (2022a), o Grupo A é a categorização formada por unidades consumidoras conectadas a uma tensão igual ou superior a 2,3 kV, ou aquelas atendidas por meio de um sistema subterrâneo de distribuição com tensão inferior a 2,3 kV, sendo subdividido nos seguintes subgrupos:

1. subgrupo A1: tensão de conexão maior ou igual a 230 kV;
2. subgrupo A2: tensão de conexão maior ou igual a 88 kV e menor ou igual a 138 kV;
3. subgrupo A3: tensão de conexão igual a 69 kV;
4. subgrupo A3a: tensão de conexão maior ou igual a 30 kV e menor ou igual a 44 kV;
5. subgrupo A4: tensão de conexão maior ou igual a 2,3 kV e menor ou igual a 25 kV;
6. subgrupo AS: tensão de conexão menor que 2,3 kV, a partir de sistema subterrâneo de distribuição.

Segundo MME/ANEEL (2021), integram o Grupo A as unidades consumidoras com tensão igual ou superior a 2,3 kV e inferior a 69 kV, considerando que a carga ou potência instalada de geração na unidade consumidora ultrapasse 75 kW e a maior demanda a ser contratada seja igual ou inferior a 2500 kW. As unidades consumidoras com tensão igual ou superior a 69 kV são enquadradas no Grupo A se a maior demanda a ser contratada exceder 2500 kW. De acordo com MME/ANEEL (2021), a classificação tarifária para unidades consumidoras do Grupo A deve ocorrer de acordo com as seguintes modalidades:

1. no caso de tensão de conexão maior ou igual a 69 kV: horária azul;
2. no caso de tensão de conexão menor que 69 kV: horária azul ou verde, de acordo com a opção do consumidor.

2.15 Considerações finais

Este capítulo abordou diferentes assuntos relacionados à big data, telemetria, análise de dados de séries temporais, técnicas de detecção de anomalias, clusterização e previsão, dentre outros assuntos relacionados a essas áreas como análise de correlação, e métricas de avaliação dos resultados proporcionados por essas áreas do aprendizado de máquina e por consequência da inteligência artificial. Mostrando desde aplicações mais convencionais até trabalhos mais atuais e avançados. Abordando suas características peculiares, formas de aplicação e resultados que podem gerar. A revisão bibliográfica foi realizada com o intuito de mostrar trabalhos relacionados às áreas citadas desde os primórdios, ressaltando trabalhos originais e pioneiros nesses campos de pesquisa, como também trabalhos atuais, e relacioná-los com estudos feitos no âmbito de

gestão da demanda elétrica, com a intenção de embasar esta pesquisa.

3 IDENTIFICAÇÃO DE ANOMALIAS E PADRÕES DE DEMANDA IRREGULARES EM UNIDADES CONSUMIDORAS DE ENERGIA ELÉTRICA DO GRUPO A

3.1 Introdução

Este capítulo abordará um estudo realizado em unidades consumidoras de energia no estado do Ceará, onde serão apresentados os padrões de consumo e de demanda de energia elétrica dos clientes. Serão sugeridos valores adequados de demanda contratada para o consumo de energia dos clientes, além de serem apresentados os custos com os valores de demandas contratadas atuais, bem como a redução estimada da tarifa de energia caso a demanda contratada esteja alinhada com o consumo da respectiva unidade consumidora de energia.

Na Figura 6 são mostradas as tarifas de aplicação e base econômica que foram aplicadas neste trabalho para o grupo A. As tarifas são em relação à ENEL Ceará. Além das tarifas considerou-se um adicional de 20% de impostos federais e estaduais sobre a tarifa de energia. Em relação ao posto tarifário a sigla P significa "posto tarifário ponta", FP é "posto tarifário fora de ponta" e NA significa "não se aplica (não há distinção dentro da classe, subclasse, acessante ou posto tarifário)". A maioria das unidades consumidoras públicas do estado do Ceará pertencem ao subgrupo A4. Desse modo, os valores adotados para o cálculo da tarifa de energia foram em relação à modalidade tarifária horosazonal verde: *Tarifa de Uso do Sistema* (TUSD) de 23,43 ($R\$/kW$) para a demanda, 1.520,02 ($R\$/MWh$) para o consumo no horário de ponta e 80,32 ($R\$/MWh$) para o consumo no horário fora de ponta e a *Tarifa de Energia* (TE) de 467,27 ($R\$/MWh$) para o consumo no horário de ponta e 290,02 ($R\$/MWh$) para o consumo no horário fora de ponta. Já para a modalidade tarifária horosazonal azul: TUSD de 59,34 ($R\$/kW$) para a demanda na ponta, 23,43 ($R\$/kW$) para a demanda fora de ponta, 80,32 ($R\$/MWh$) para o consumo no horário de ponta e 80,32 ($R\$/MWh$) para o consumo no horário fora de ponta e a TE de 467,27 ($R\$/MWh$) para o consumo no horário de ponta e 290,02 ($R\$/MWh$) para o consumo no horário fora de ponta.

Na Figura 7 é apresentado o diagrama de passos realizados até a análise de dados. Primeiramente foi criado um script na linguagem Python para raspagem dos dados, ou seja, para coletar os dados e para acessar o sistema de telemedição. Em seguida foi feito o acesso ao sistema de telemedição pelo código automatizado para essa ação, depois disso foram coletados dados de consumos de energia e de demandas de potência medidos nos horários de ponta e fora de ponta. Além disso os dados foram tratados, deixados no formato numérico, criadas colunas

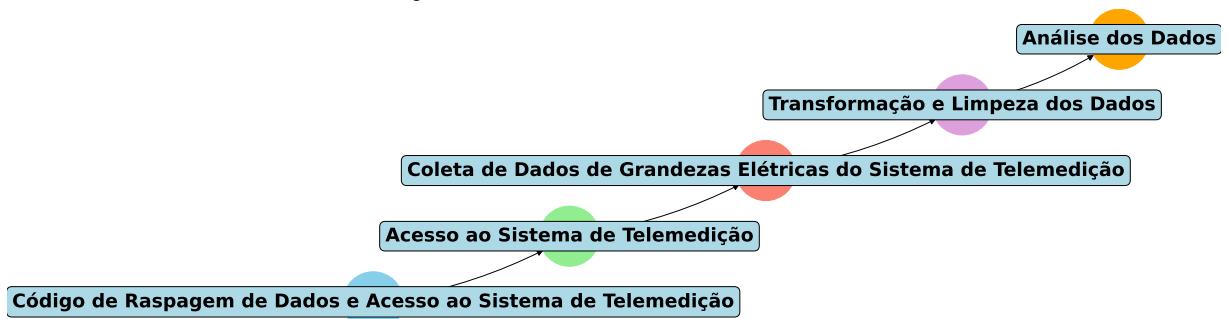
Figura 6 – Tarifas de aplicação e base econômica para o grupo A (Enel CE).

SUBGRUPO	MODALIDADE	ACESSANTE	POSTO	TARIFAS DE APLICAÇÃO				BASE ECONÔMICA		
				TUSD		TE	TUSD		TE	
				R\$/kW	R\$/MWh		R\$/MWh	R\$/kW	R\$/MWh	R\$/MWh
A3 (69kV)	AZUL	NA	P	18,20	53,19	467,27	16,89	52,93	473,08	
			FP	8,76	53,19	290,02	7,56	52,93	291,78	
	AZUL APE	NA	P	18,20	11,32	0,00	16,89	11,58	0,00	
			FP	8,76	11,32	0,00	7,56	11,58	0,00	
	VERDE	NA	NA	19,28	0,00	0,00	19,40	0,00	0,00	
			P	59,34	80,32	467,27	58,21	80,57	473,08	
	VERDE APE	NA	FP	23,43	80,32	290,02	22,23	80,57	291,78	
			P	59,34	28,97	0,00	58,21	29,66	0,00	
	DISTRIBUIÇÃO	Cepisa	FP	23,43	28,97	0,00	22,23	29,66	0,00	
			NA	23,43	0,00	0,00	22,23	0,00	0,00	
	EPB	NA	P	0,00	1.520,02	467,27	0,00	1.493,41	473,08	
			FP	0,00	80,32	290,02	0,00	80,57	291,78	
	GERAÇÃO	NA	NA	23,43	0,00	0,00	22,23	0,00	0,00	
			P	0,00	1.468,67	0,00	0,00	1.442,49	0,00	
			FP	0,00	28,97	0,00	0,00	29,66	0,00	

Fonte: ANEEL (2022).

de data e adicionais limpezas nos dados como remoção de valores nulos para deixá-los prontos para a etapa posterior de análises de dados.

Figura 7 – Diagrama de Blocos desde o Processo de geração do código para raspagem de dados e acesso ao sistema de telemedição até a análise de dados.



Fonte: Próprio autor (2024).

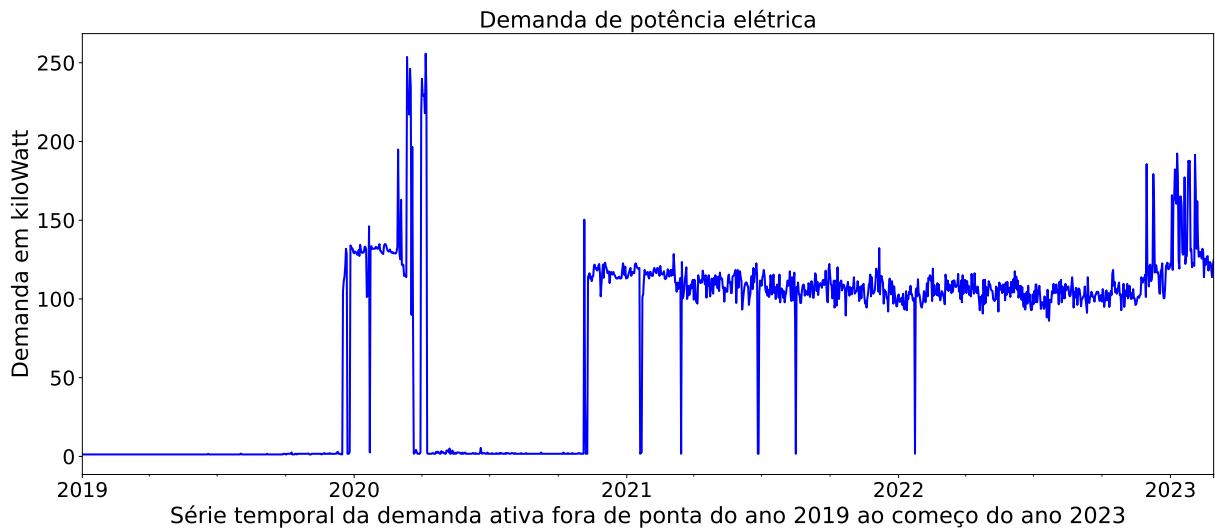
3.2 Análise de séries temporais e detecção de comportamentos anormais na demanda elétrica de unidades consumidoras de energia elétrica

Na Figura 8, pode-se observar a série temporal da demanda medida fora de ponta em uma unidade consumidora de energia elétrica responsável pelo gerenciamento da água acumulada nos reservatórios públicos do Ceará, localizada na cidade de Canindé. Cabe destacar

que a tarifa desse cliente é horosazonal verde. A demanda contratada para essa unidade é de 368 kW, no entanto, é visível que a unidade consumidora não necessita de toda essa demanda contratada. Durante o ano de 2019, praticamente não houve consumo de energia nessa unidade, resultando em uma demanda quase nula. No ano de 2020, a demanda variou entre 146 kW e 256 kW nos primeiros quatro meses do ano, enquanto de maio a outubro a demanda registrada foi praticamente zero, com um aumento para cerca de 151 kW nos dois últimos meses do ano. No ano de 2021, a demanda permaneceu mais constante, atingindo um pico máximo de aproximadamente 135 kW no horário fora de ponta. Em 2022, a demanda também foi relativamente estável, variando de cerca de 113 kW a 186 kW ao longo do ano. No início de 2023, observaram-se picos de demanda que não ultrapassaram 189 kW. Percebe-se que o pico máximo registrado de demanda em quatro anos e dois meses para essa unidade consumidora foi de aproximadamente 256 kW no ano de 2020, e a demanda média, calculada somando todos os anos e dividindo por ano, fica abaixo desse valor. Analisando o ano de 2022, um dos anos mais recentes da análise desse cliente, constata-se que 80% das medições de demandas máximas diárias, ou seja, demandas máximas de cada dia, em torno de 30 por mês, estão abaixo de 111 kW, com apenas dois registros acima de 179 kW. Em geral, foi possível perceber que a demanda medida ao longo dos anos está bem abaixo do valor contratado, pois, considerando todas as medições máximas diárias de quatro anos e dois meses de registros, em 75% delas a demanda registrada está abaixo de 112 kW. Portanto, mesmo que haja estudos meteorológicos que tentem justificar o valor de 368 kW para esse cliente, ou que se tenha a preocupação com a diminuição da demanda, pois esta pode eventualmente aumentar posteriormente, primeiramente, antes de qualquer aumento, será realizado um levantamento de carga para determinar quanta demanda a unidade realmente necessita, visto que o histórico de dados de telemedição demonstra claramente que a unidade não precisa do valor contratado atualmente. Pelo contrário, o valor está muito acima do que está sendo realmente utilizado. Um valor adequado estaria entre 140 e 200 kW, sendo que o valor contratado atual é praticamente o dobro de 200 kW, cerca de 84% a mais. Analisando a série temporal apresentada na Figura 8, é possível observar uma variação significativa nas demandas ao longo dos anos. Em particular, os anos de 2019 e 2020 mostram períodos de baixa demanda quase nula, com algumas flutuações nos meses finais de 2020. Em contrapartida, os anos de 2021 e 2022 demonstram uma maior estabilidade na demanda, com valores que raramente ultrapassam 186 kW. Esta estabilidade pode indicar uma mudança nos padrões de consumo ou uma adaptação das operações da unidade. Além disso, os dados iniciais

de 2023 também indicam a presença de picos de demanda que, apesar de presentes, ainda se mantêm abaixo da capacidade contratada de 368 kW.

Figura 8 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada na cidade de Canindé.

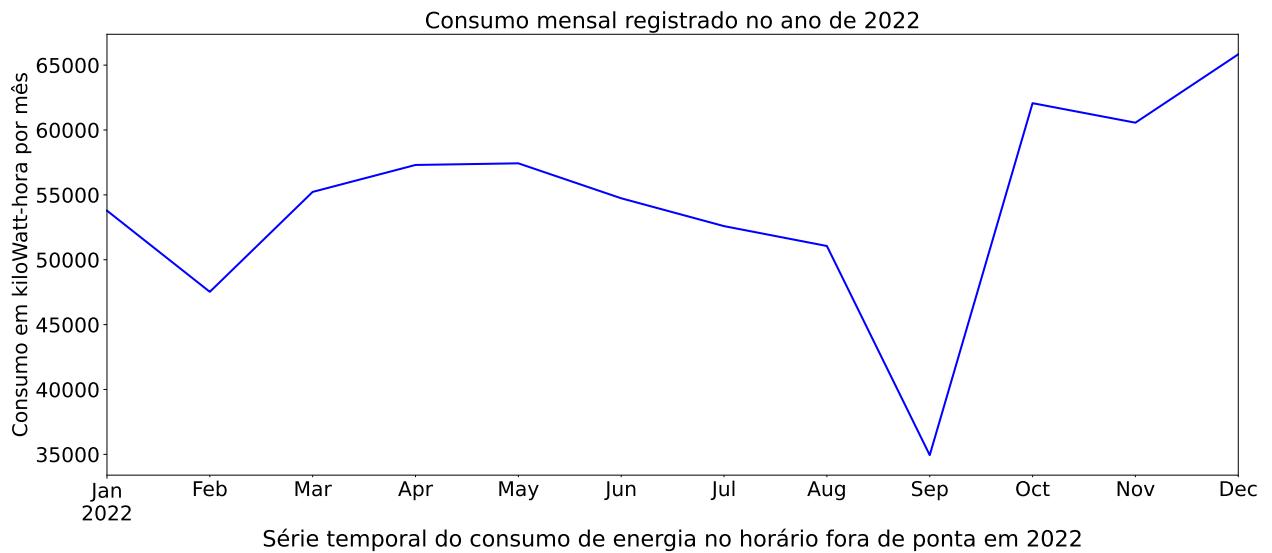


Fonte: Próprio autor (2024).

Na Figura 9 observa-se a série temporal do consumo de energia no horário fora de ponta para o ano de 2022. A análise dos dados mensais indica uma variação significativa no consumo ao longo do ano. Em janeiro de 2022, o consumo registrado foi de aproximadamente 55.000 kWh. Em fevereiro o consumo decaiu para em torno de 47.000 kWh. Nos meses seguintes, até maio, o consumo manteve-se relativamente estável, com pequenos aumentos e diminuições, variando entre 55.000 kWh e 60.000 kWh. Nos meses de junho a setembro houve uma tendência de queda do consumo de energia, com destaque para o mês de setembro, onde observou-se uma queda brusca no consumo para cerca de 35.000 kWh. Após essa queda, nos meses de outubro a dezembro, o consumo voltou a subir, o maior valor de consumo desta unidade no ano de 2022 foi alcançado em dezembro, onde foram registrados 65.000 kWh. Esta flutuação pode ser atribuída a diversos fatores, incluindo variações sazonais na demanda por energia, alterações operacionais na unidade consumidora e etc.

Na Figura 10 é apresentada a série temporal da demanda medida no horário de ponta na unidade consumidora localizada em Canindé. Observa-se uma considerável irregularidade na demanda medida, com valores frequentemente próximos de zero e picos isolados de alta magnitude. Durante os períodos em que a demanda foi regular e constante, manteve-se consistentemente abaixo de 150 kW ao longo dos quatro anos e dois meses de registro. Este

Figura 9 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada na cidade de Canindé.

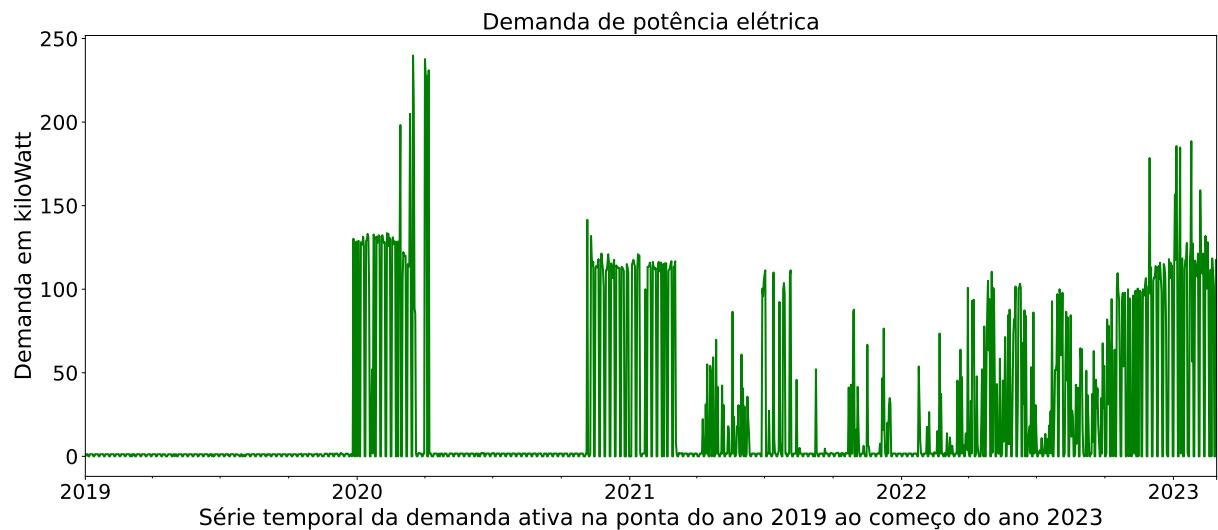


Fonte: Próprio autor (2024).

comportamento evidencia que a demanda contratada de 368 kW é excessiva e desnecessária para as necessidades reais da unidade. A demanda apresenta valores extremamente baixos em diversos períodos, indicando uma baixa utilização da energia elétrica durante o horário de ponta na maior parte do tempo. Há picos isolados que atingem valores significativos, próximos a 200 kW e em alguns casos ultrapassando este valor, embora estes picos sejam esporádicos e não representem o comportamento regular da demanda. Nos momentos em que a demanda se mantém constante, ela raramente ultrapassa os 150 kW. Isso sugere que, mesmo durante os horários de ponta, a necessidade de energia elétrica da unidade é significativamente menor do que a demanda contratada de 368 kW. Durante 2019, a demanda é praticamente nula, sugerindo uma inatividade ou uma operação mínima da unidade consumidora. No ano de 2020, observa-se um aumento na demanda no primeiro semestre, com picos significativos, mas a partir do meio do ano, a demanda retorna a valores próximos de zero. Em 2021, a demanda mostra maior estabilidade comparada aos anos anteriores, mantendo-se ainda abaixo de 150 kW na maioria dos registros. Em 2022 essa estabilidade continua, com poucos picos isolados e a maioria dos valores de demanda permanecendo baixos. No início de 2023, há um aumento na frequência e na magnitude dos picos de demanda, ainda que os valores permaneçam abaixo da capacidade contratada de 368 kW. A análise do gráfico reforça a necessidade de reavaliar a demanda contratada para esta unidade. Os dados históricos de quatro anos e dois meses mostram claramente que a demanda raramente se aproxima do valor contratado de 368 kW, sendo a maior parte do tempo significativamente

inferior a este valor. A presença de picos esporádicos e de alta magnitude pode justificar a manutenção de uma margem de segurança, mas esta deveria ser baseada em uma análise mais detalhada das operações da unidade e em possíveis medidas de mitigação para esses picos. Reduzir a demanda contratada para um valor mais próximo do realmente necessário pode resultar em uma economia significativa nos custos de energia para a unidade consumidora. Uma demanda contratada entre 140 e 200 kW, como sugerido, poderia ser mais adequada, considerando que a demanda constante raramente ultrapassa 150 kW e levando em conta os picos isolados. A unidade consumidora poderia considerar ajustes operacionais ou investimentos em tecnologias que ajudem a gerenciar e reduzir os picos de demanda, como sistemas de gerenciamento de energia ou ajuste de cargas. A ausência de um sistema controlador de demanda pode levar a picos que ultrapassam a capacidade contratada, resultando em penalidades financeiras. Implementar um sistema de controle de demanda poderia ajudar a suavizar esses picos, distribuindo a carga de forma mais uniforme ao longo do dia e evitando excedentes desnecessários.

Figura 10 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada na cidade de Canindé.



Fonte: Próprio autor (2024).

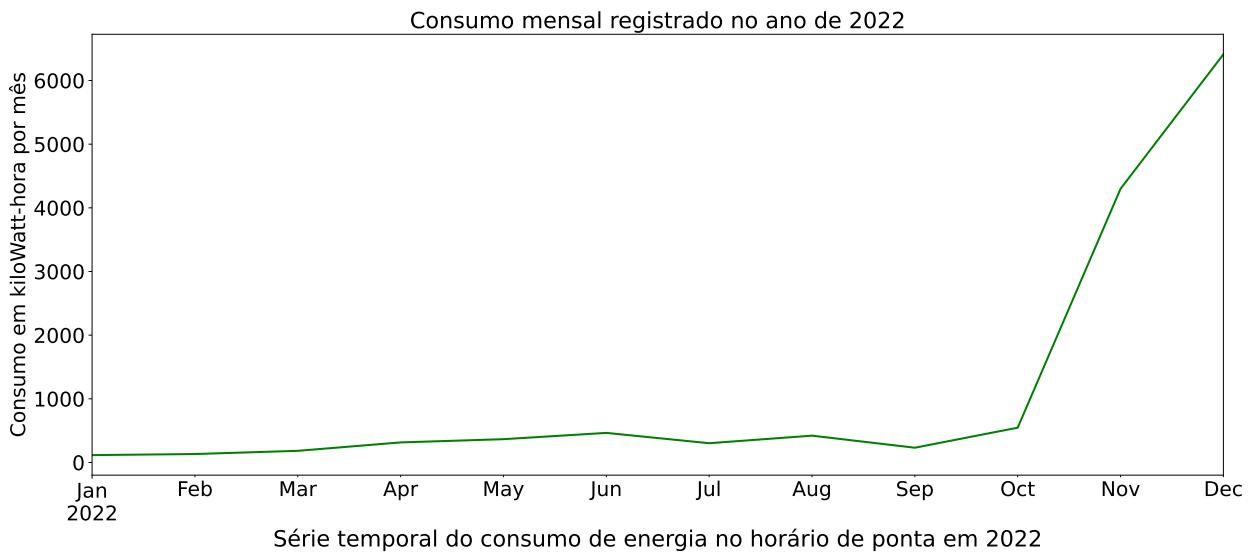
Na Figura 11 é mostrado o consumo no horário de ponta no ano de 2022 da unidade consumidora localizada em Canindé. Observa-se que, apesar dos picos de demanda acima de 100 kW no horário de ponta, o consumo real de energia foi significativamente inferior ao do horário fora de ponta. Esses picos de demanda podem resultar do acionamento ineficiente de equipamentos, como a ligação simultânea de vários dispositivos, o que aumenta a corrente elétrica dos circuitos e, consequentemente, a demanda registrada em determinado momento. A demanda

é medida em intervalos de 15 minutos, e a ausência de um sistema controlador de demanda pode elevá-la, podendo até ultrapassar o valor contratado e o limite máximo aceitável para evitar multas, que é de 5% acima da demanda contratada, conforme indicado em MME/ANEEL (2021). Nos primeiros nove meses de 2022 (janeiro a setembro), o consumo de energia no horário de ponta é bastante baixo, com valores mensais próximos de zero. Isso indica uma utilização mínima de energia durante o horário de ponta nesse período. A partir de outubro, observa-se um aumento gradual no consumo de energia, que se torna mais acentuado nos meses de novembro e dezembro. Este aumento pode ser associado a mudanças sazonais ou a um aumento na atividade da unidade consumidora durante esses meses. O consumo atinge um pico significativo em dezembro, ultrapassando 6000 kWh. Este valor é substancialmente maior em comparação com os meses anteriores, indicando um aumento expressivo na utilização de energia no horário de ponta. Isto também pode ser uma falha de medição ou de inserção dos dados do cliente na plataforma de telemedição. O aumento acentuado no consumo nos últimos meses de 2022 pode estar relacionado a fatores sazonais, a uma intensificação das atividades operacionais ou a falhas de equipamentos de medição. Analisar esses fatores pode fornecer insights sobre como gerenciar melhor a demanda ao longo do ano. Com base nos dados de consumo, reavaliar a demanda contratada para garantir que esteja alinhada com as necessidades reais da unidade pode resultar em uma significativa redução de custos. Fornecer educação e treinamento para o pessoal sobre práticas de uso eficiente de energia e a importância de gerenciar a demanda pode contribuir para uma operação mais eficiente. Esses pontos destacam a importância de uma gestão energética eficiente e a necessidade de revisar continuamente os padrões de consumo para garantir que as necessidades da unidade sejam atendidas de maneira econômica e sustentável.

A unidade consumidora comentada e localizada em Canindé está tendo um custo de em torno de 466 mil reais anuais com a tarifa de energia atual, não está pagando multa por ultrapassagem de demanda, porém, pelo alto valor de demanda contratada (368 kW), está tendo um custo elevado com a tarifa de energia. Com a adoção de uma demanda contratada de 200 kW o custo tarifário seria cerca de 407 mil reais anuais.

Na Figura 12 é mostrada a demanda fora de ponta de uma unidade consumidora responsável pelo gerenciamento da água acumulada nos reservatórios públicos do Ceará, localizada em Maranguape. A demanda contratada para esse cliente de energia é 423 kW, com tarifa horosazonal verde. No entanto, é perceptível que a demanda medida desde o início de janeiro de 2020 até o registro de fevereiro de 2024, está praticamente zero, muito menor até que o mínimo

Figura 11 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada na cidade de Canindé.

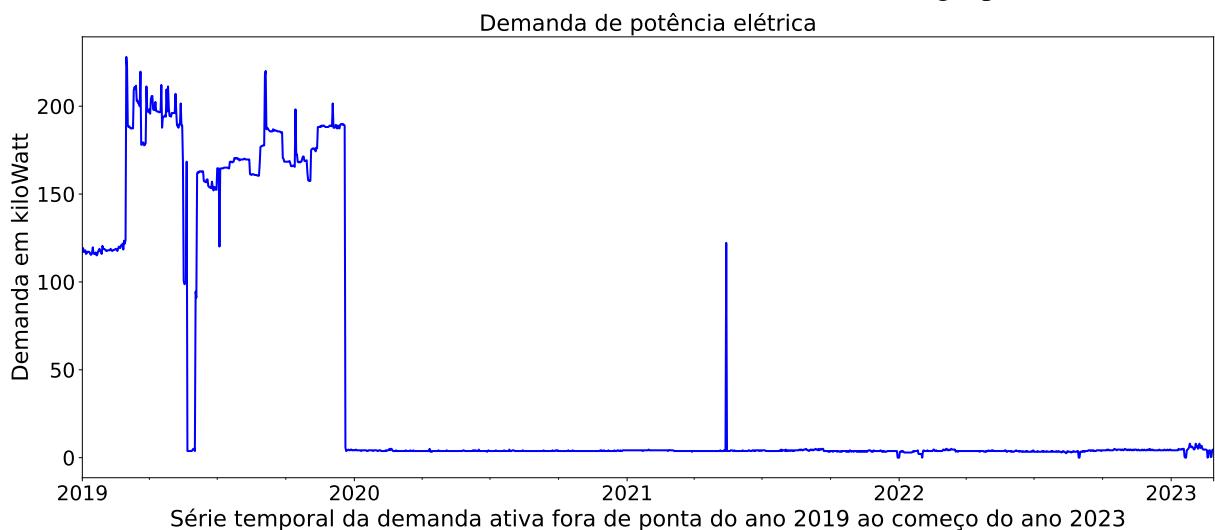


Fonte: Próprio autor (2024).

que deve ser contratado para consumidores do grupo A, que são 30 kW de demanda, como consta em MME/ANEEL (2021). Ressalta-se que até mesmo em 2019, ano com maiores demandas dentre esses 4 anos e 2 meses registrados, a demanda maior registrada foi cerca de 228 kW, com média de 157 kW, cerca de 75% dos registros abaixo de 189 kW e com mediana de 169 kW, aproximadamente, valores muito abaixo do contratado, que é 423 kW de demanda. O ideal para esse cliente seria reduzir drasticamente a demanda contratada, pois mesmo que posteriormente seja preciso aumentar a demanda da unidade consumidora, a concessionária de energia terá que informar por escrito se terá a necessidade de execução de obras e se no caso existir a necessidade de obras, quanto maior for a demanda contratada, menores são os custos do cliente com as obras de reforço de rede, por exemplo, pois será calculado o encargo de responsabilidade da distribuidora, assim como a eventual participação financeira do consumidor, como mostrado na equação 3.1. Em que ERD representa o encargo de responsabilidade da distribuidora, DEMANDAERD é a demanda a ser atendida ou acrescida para o cálculo do ERD, em kW, K é o fator de cálculo do ERD, calculado pela equação 3.2. TUSD Fio B_{FP} é a parcela da TUSD no posto tarifário fora de ponta, composta pelos custos regulatórios decorrentes do uso dos ativos da distribuidora, que remunera o investimento, o custo de operação e manutenção e a depreciação dos ativos, em Reais por kilowatt ($R\$/kW$), α é a relação entre os custos de operação e manutenção, vinculados à prestação do serviço de distribuição de energia elétrica, como pessoal, material, serviços de terceiros e outras despesas, e os custos gerenciáveis totais da distribuidora

- Parcela B, definidos na última revisão tarifária, FRC é o fator de recuperação do capital que traz a valor presente a receita uniforme prevista, sendo obtido pela equação 3.3, WACC é o custo médio ponderado do capital definido na última revisão tarifária da distribuidora, antes dos impostos, n é o período de vida útil, em anos, associado à taxa de depreciação percentual anual "d" definida na última revisão tarifária, sendo obtido pela equação 3.4, MME/ANEEL (2021). A Figura 12 evidencia que a demanda fora de ponta medida de forma diária, entre janeiro de 2019 e fevereiro de 2024, apresenta uma queda acentuada desde o início de 2020, permanecendo praticamente nula ao longo dos anos seguintes. Essa análise reforça a necessidade de revisar a demanda contratada para essa unidade consumidora, visando otimizar os custos e adequar a demanda contratada à demanda real medida, garantindo eficiência e economia para a unidade consumidora.

Figura 12 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2024, em kW, na unidade consumidora localizada em Maranguape.



Fonte: Próprio autor (2024).

$$ERDB = DEMANDA_{ERD} \cdot K \quad (3.1)$$

$$K = 12 \cdot (TUSD \text{ Fio } BFP) \cdot (1 - \alpha) \cdot \frac{1}{FRC} \quad (3.2)$$

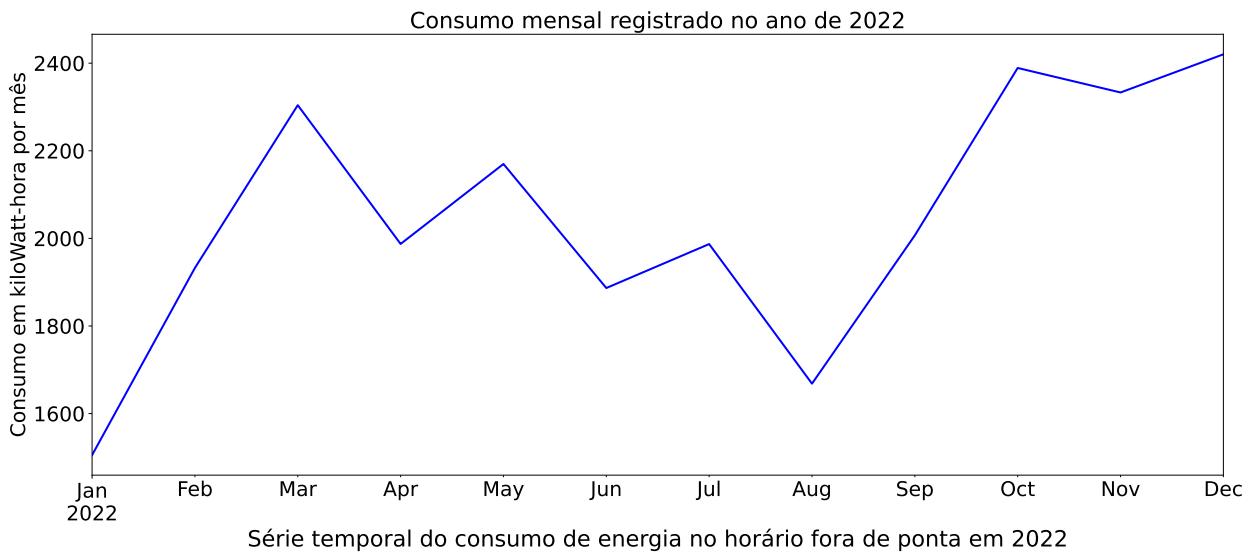
$$FRC = \frac{WACC \cdot (1 + WACC)^n}{(1 + WACC)^n - 1} \quad (3.3)$$

$$n = \frac{100}{d} \quad (3.4)$$

Na Figura 13 é apresentado o consumo de energia fora de ponta no ano de 2022 da unidade consumidora localizada em Maranguape, previamente discutida em relação à demanda ilustrada na Figura 12. Observa-se que o consumo mensal é significativamente baixo quando comparado ao nível de demanda contratada. O consumo de energia variou entre aproximadamente 1600 kWh e 2400 kWh por mês. Este nível de consumo é relativamente baixo, especialmente quando comparado com a demanda contratada de 423 kW. O consumo apresenta um padrão cíclico ao longo do ano. Nota-se um aumento significativo nos meses de fevereiro e março, seguido por uma ligeira queda até julho, em agosto a queda foi mais acentuada, com um aumento gradual a partir de setembro até alcançar um pico em outubro, estabilizando-se novamente em novembro e dezembro. A média de consumo mensal está consideravelmente abaixo do que seria esperado para a demanda contratada de 423 kW. Mesmo no mês de maior consumo (março), o valor é muito inferior ao nível de demanda contratada, indicando um potencial desperdício de recursos financeiros devido à contratação de uma demanda muito superior à necessidade real da unidade. A análise sugere que a unidade consumidora pode beneficiar-se de uma reavaliação da demanda contratada. Reduzir a demanda contratada para um nível mais próximo do consumo real pode resultar em economias significativas, evitando custos desnecessários associados a uma demanda superestimada. O consumo de energia, apesar das variações mensais, não apresenta flutuações extremas, o que pode facilitar a previsão e planejamento do consumo futuro, tornando mais eficiente a gestão da energia para esta unidade. A combinação da análise de demanda na Figura 12 e do consumo na Figura 13 fornece uma visão abrangente sobre o perfil de consumo desta unidade, evidenciando a necessidade de ajustes na demanda contratada para otimizar custos e melhorar a eficiência energética.

Na Figura 14 é apresentada a série temporal da demanda medida no horário de ponta na unidade consumidora localizada em Maranguape. Observa-se que, durante o horário de ponta, a demanda foi significativamente registrada apenas no ano de 2019. Neste ano, o valor máximo medido foi aproximadamente metade da demanda contratada, com uma média em 2019 de cerca de 106 kW, mediana em torno de 153 kW, indicando que metade das medições diárias superaram este valor, e um valor máximo registrado de 220 kW. Nos anos subsequentes, a demanda medida permaneceu consistentemente abaixo dos 30 kW especificados pela norma como valor mínimo contratado. Em 2022, o valor máximo registrado foi de apenas 5 kW, indicando uma redução

Figura 13 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Maranguape.

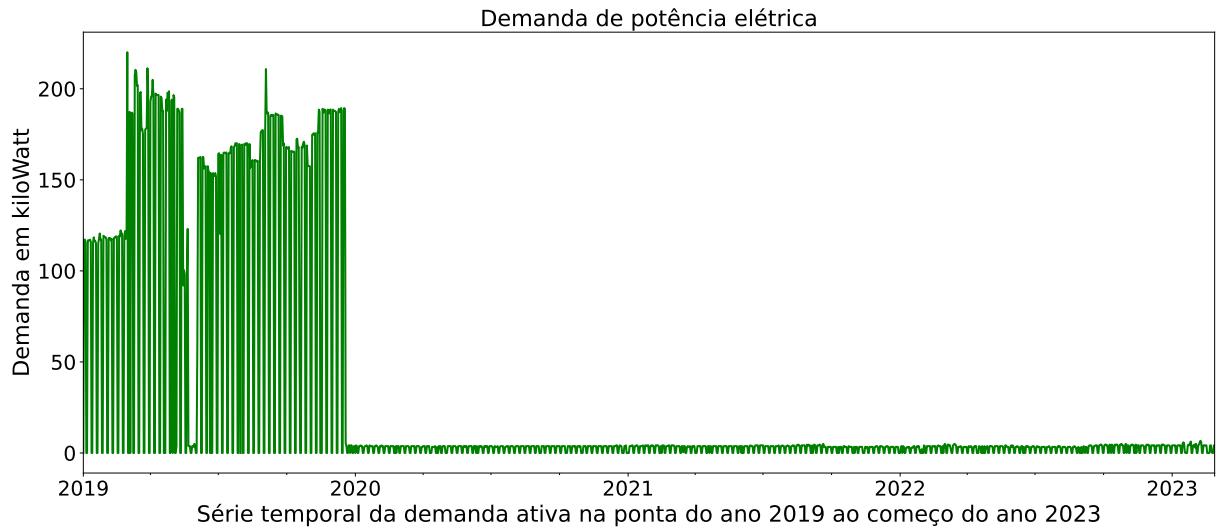


Fonte: Próprio autor (2024).

substancial na utilização de potência durante o horário de ponta. A queda abrupta e sustentada na demanda de potência a partir de 2020 sugere mudanças operacionais na unidade consumidora, potencialmente devido a alterações na atividade. A redução constante pode também indicar uma reavaliação da necessidade de demanda contratada, refletindo um ajuste para valores mais alinhados com o consumo real. Essas observações ressaltam a importância de um monitoramento contínuo e detalhado da demanda de potência para garantir que os valores contratados estejam alinhados com o consumo real, evitando custos desnecessários e promovendo uma utilização mais eficiente da energia elétrica.

Na Figura 15 é mostrado o consumo no horário de ponta no ano de 2022 da unidade consumidora que está localizada em Maranguape. Os dados revelam que os baixos valores de demanda de potência refletidos na Figura 14 são acompanhados por baixos consumos de energia no horário de ponta. O consumo mensal variou, mas manteve-se em níveis baixos, reforçando a análise de que não há justificativa para manter um nível de demanda contratada tão alto. O gráfico de consumo mensal para 2022 mostra valores relativamente baixos e variáveis, com picos ocasionais, mas nenhum deles suficiente para justificar a manutenção de um contrato de demanda alta. Este padrão de consumo corrobora a necessidade de reavaliar o contrato de demanda, pois a unidade está pagando por uma capacidade não utilizada, resultando em custos desnecessários. A análise da demanda de potência e do consumo de energia no horário de ponta para a unidade consumidora em Maranguape demonstra claramente que a demanda contratada é excessiva em

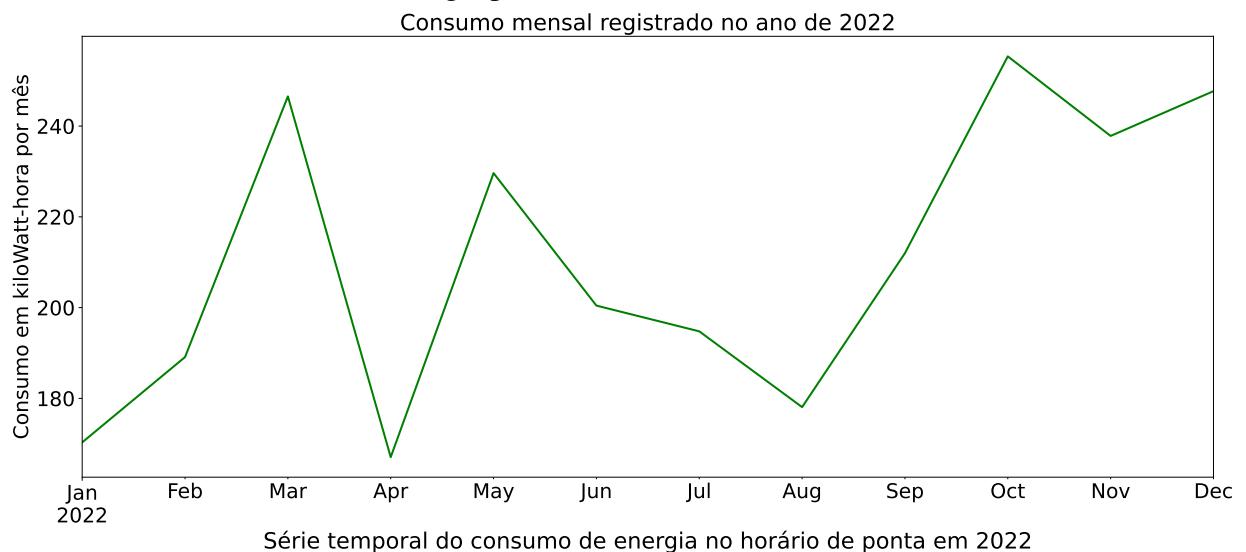
Figura 14 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e fevereiro de 2023, em kW, na unidade consumidora localizada em Maranguape.



Fonte: Próprio autor (2024).

relação às necessidades reais da unidade. A manutenção de um contrato de demanda elevado, frente aos dados apresentados, não se justifica economicamente. Recomenda-se a reavaliação e possível redução do nível de demanda contratada para alinhar os custos com o perfil de consumo atual.

Figura 15 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Maranguape.



Fonte: Próprio autor (2024).

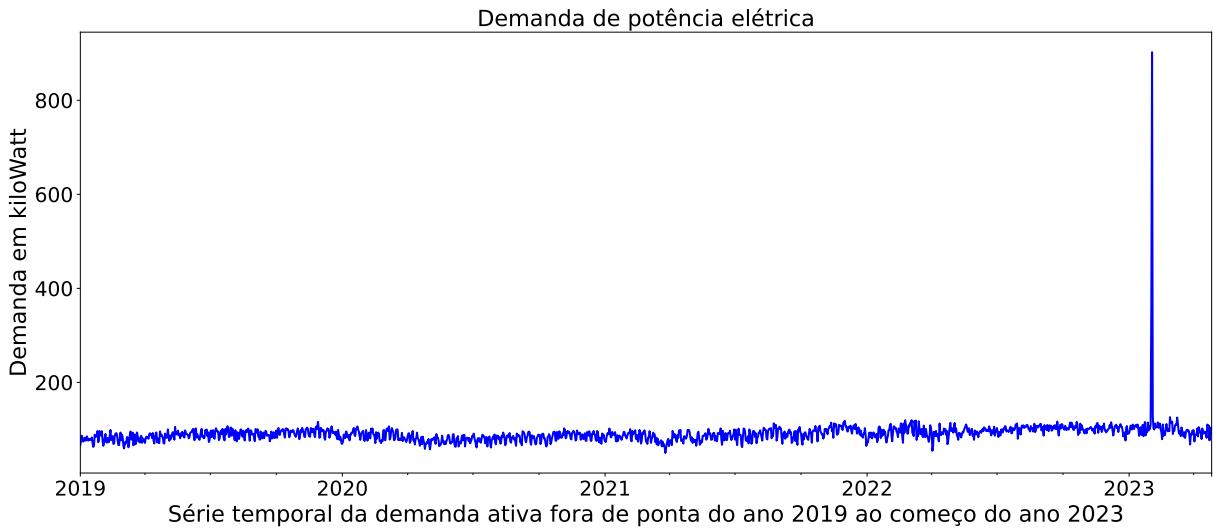
A unidade consumidora comentada e localizada em Maranguape está tendo um custo de em torno de 166,330 mil reais anuais com a tarifa de energia atual, não está pagando multa

por ultrapassagem de demanda, porém, pelo alto valor de demanda contratada (423 kW), está tendo um custo elevado com a tarifa de energia. Com a adoção de uma demanda contratada de 30 kW o custo tarifário seria cerca de 28,209 mil reais anuais.

Na Figura 16 é apresentada a série temporal da demanda fora de ponta de uma unidade consumidora pertencente à Secretaria de Justiça, localizada em Aquiraz. A demanda contratada para este cliente de energia é de 30 kW, com tarifa horosazonal verde. Contudo, ao observar a série temporal da demanda desta unidade, com medições diárias ao longo de 4 anos e 4 meses, constatou-se que a demanda mais adequada para este cliente seria em torno de 120 kW contratados no horário de ponta e 120 kW contratados no horário fora de ponta, com tarifação horosazonal azul. Ao analisar os dados de 1577 dias de medição, verificou-se que em 75% das medições, a demanda de potência registrada foi de até aproximadamente 91 kW, com uma média de cerca de 62 kW e mediana de 81 kW. No ano de 2022, a média foi em torno de 98 kW, a mediana de 99 kW, e 80% das medições desse ano estavam com valores de até aproximadamente 107 kW, com o valor máximo registrado de quase 120 kW. Isso indica uma baixa variância nos valores registrados ao longo dos 4 anos e 4 meses, com um desvio padrão em 2022 de apenas 10 kW. Em fevereiro de 2024, ocorreu um pico anômalo no comportamento habitual da série temporal deste cliente, com um registro de 902 kW, aumentando ainda mais o valor da multa por ultrapassagem de demanda dessa unidade, que já estava sendo significativamente ultrapassada nos anos anteriores, considerando que o valor da demanda contratada é de apenas 30 kW. A análise detalhada da demanda fora de ponta da unidade consumidora em Aquiraz revela que a demanda contratada de 30 kW é insuficiente e não representa adequadamente o perfil de consumo dessa unidade. Os dados sugerem que uma demanda contratada de 120 kW para ambos os períodos de ponta e fora de ponta, com tarifação horosazonal azul, seria mais apropriada. A inadequação da demanda contratada atual não só resulta em frequentes ultrapassagens de demanda, mas também implica em multas significativas e custos desnecessários. Portanto, recomenda-se fortemente a revisão e ajuste do contrato de demanda para melhor refletir o perfil de consumo real desta unidade consumidora.

Na Figura 17 é mostrado o consumo fora de ponta no ano de 2022 da unidade consumidora localizada em Aquiraz, comentada acima com demanda fora de ponta vista na Figura 16. Nota-se que o consumo dessa unidade no horário fora de ponta de junho a dezembro é maior do que nos primeiros meses do ano. O consumo varia entre cerca de 41.000 kWh e 52.000 kWh. Esses valores representam os níveis máximos e mínimos de consumo mensal. O gráfico

Figura 16 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em Aquiraz.

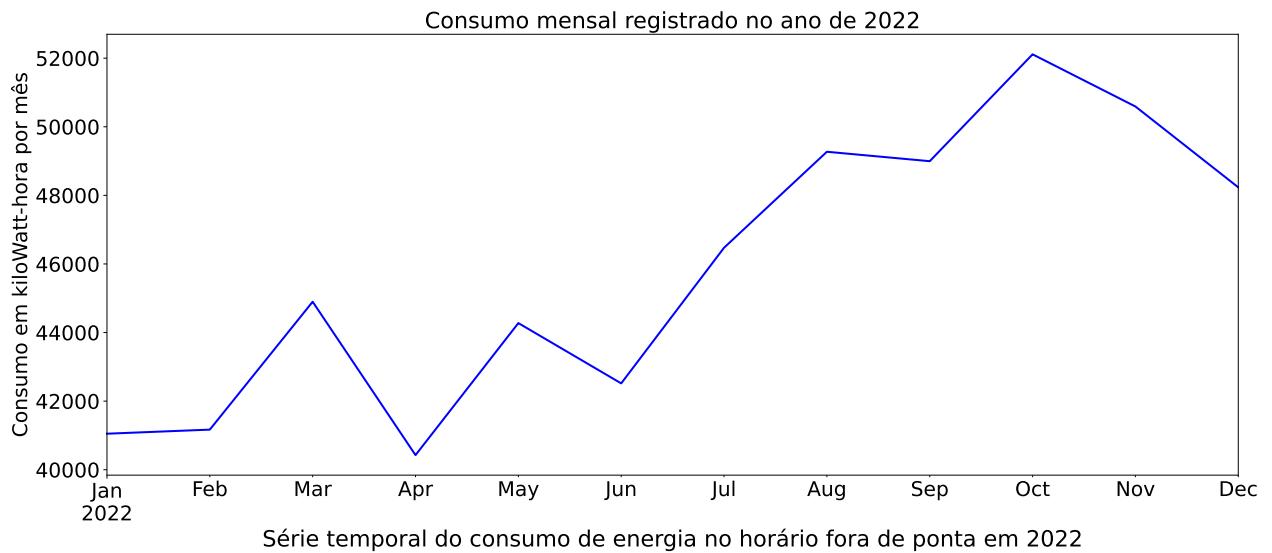


Fonte: Próprio autor (2024).

revela flutuações significativas no consumo ao longo do ano. Os meses de junho a dezembro apresentam um aumento notável no consumo em comparação com os primeiros meses do ano. Essa tendência sugere uma sazonalidade no uso de energia. Em resumo, o consumo fora de ponta na unidade consumidora em Aquiraz segue um padrão sazonal, com maior demanda nos meses mais quentes e uma tendência ascendente no segundo semestre. Essas informações são valiosas para o planejamento energético e a promoção da eficiência. É importante ressaltar que Falhas ou mau funcionamento de equipamentos elétricos podem levar a picos de consumo como o mostrado na Figura 16, que mostra a demanda medida. Mudanças inesperadas nas condições ambientais ou operacionais também podem causar anomalias. Problemas na rede elétrica, como flutuações de tensão, podem afetar o consumo. Para identificar anomalias, é importante monitorar o consumo regularmente. Isso permite detectar padrões incomuns e tomar medidas corretivas.

Na Figura 18 é apresentada a série temporal da demanda medida no horário de ponta para a unidade consumidora localizada em Aquiraz. Observa-se que, durante os quatro anos e quatro meses de medições, a demanda manteve-se relativamente estável, com uma média de aproximadamente 61 kW, uma mediana de 81 kW, e 75% das medições registradas até 91 kW. De maneira geral, a demanda no horário de ponta mostrou-se estável ao longo do período analisado. A estabilidade da demanda é indicada pela consistência nos valores de potência elétrica, sem variações significativas na maior parte do tempo. No ano de 2022, a média da demanda foi de cerca de 68 kW, com a mediana próxima a 92 kW, e 80% dos registros situando-se até aproximadamente 105 kW. O valor máximo registrado nesse ano foi de cerca de 117

Figura 17 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Aquiraz.

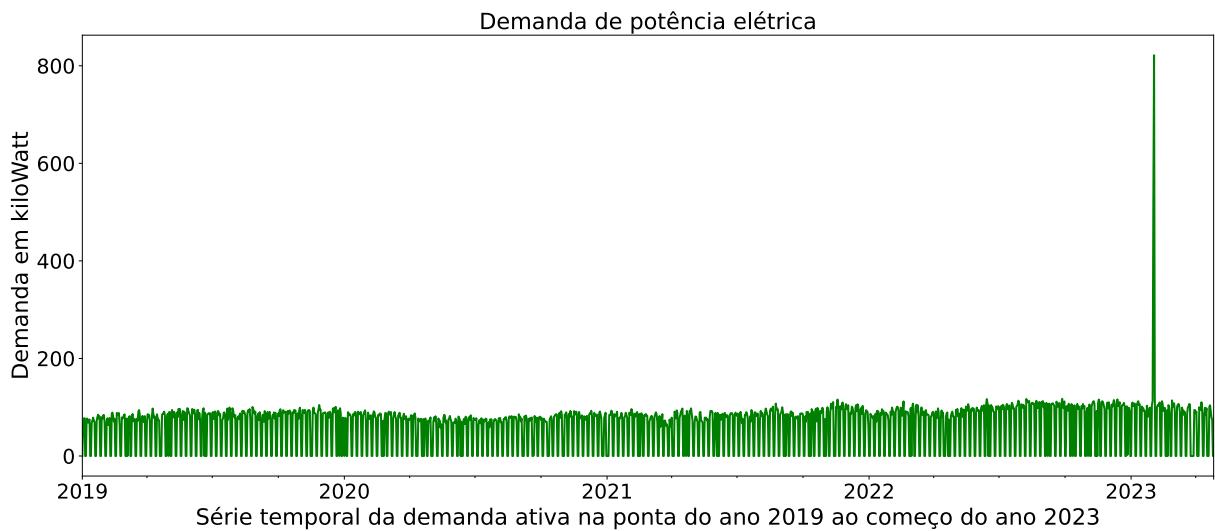


Fonte: Próprio autor (2024).

kW, o que indica que, mesmo em períodos de maior demanda, os valores não ultrapassaram os níveis significativamente altos. A figura destaca uma elevação abrupta na demanda registrada em fevereiro de 2024, atingindo um pico de 822 kW. Essa anomalia merece uma investigação detalhada para determinar se a unidade consumidora realmente apresentou uma requisição de demanda tão alta em um curto período de tempo ou se houve um erro no sistema de medição. Tal discrepância pode resultar em custos indesejados na fatura de energia, o que justifica a necessidade de uma análise mais aprofundada. Ressalta-se que a demanda contratada para esta unidade é de apenas 30 kW, um valor significativamente inferior à demanda efetivamente utilizada. Esta discrepança entre a demanda contratada e a utilizada pode indicar a necessidade de reavaliar o contrato de demanda para refletir melhor o consumo real, evitando custos adicionais e otimizando a alocação de recursos.

Na Figura 19 é apresentado o consumo no horário de ponta durante o ano de 2022 para a unidade consumidora localizada em Aquiraz. Observa-se que, embora o consumo no horário de ponta seja de menor escala em kW, aproximadamente na casa das dezenas, a adoção da tarifa horosazonal azul poderia ser mais vantajosa economicamente. A tarifa horosazonal azul oferece valores de 120 kW tanto para o horário de ponta quanto para o horário fora de ponta, o que se mostra adequado dado o consumo significativo desta unidade durante o horário de ponta. A série temporal do consumo de energia no horário de ponta ao longo do ano de 2022 apresenta variações mensais. Observa-se que o consumo atinge picos notáveis em determinados meses,

Figura 18 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Aquiraz.



Fonte: Próprio autor (2024).

como agosto, e apresenta quedas significativas em outros, como abril. Esta variação sugere que a unidade possui um consumo de energia flutuante no horário de ponta. Comparando as modalidades tarifárias, a tarifa de uso do sistema de distribuição (TUSD) no horário de ponta para a modalidade azul é significativamente mais baixa ($0,08032 \text{ R\$/kWh}$) em comparação com a tarifação horosazonal verde ($1,52002 \text{ R\$/kWh}$). Este fator torna a tarifa azul economicamente mais atraente para a unidade, dado o seu consumo considerável no horário de ponta. Embora a tarifa de demanda no horário de ponta para a modalidade azul ($59,34 \text{ R\$/kW}$) seja mais alta em comparação com a única tarifa de demanda da tarifação verde ($23,43 \text{ R\$/kW}$), a separação dos contratos de demanda para os horários de ponta e fora de ponta na modalidade azul pode resultar em uma fatura de energia mais equilibrada e ajustada ao perfil de consumo desta unidade. Apesar da complexidade adicional de gerenciar dois contratos distintos de demanda na modalidade tarifária azul, esta opção pode proporcionar benefícios econômicos significativos para a unidade consumidora. A análise dos dados de consumo justifica a recomendação de migração para a tarifa horosazonal azul, considerando a diferença nos custos das TUSDs e as demandas contratuais mais alinhadas ao perfil de consumo da unidade. Os cálculos para determinar as tarifas horosazonal verde e horosazonal azul foram realizados com base na AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL (2022), garantindo que as recomendações estejam fundamentadas em dados tarifários atuais e precisos. Em conclusão a análise da Figura 19 evidencia a necessidade de ajustes na gestão tarifária e na contratação de demanda da unidade consumidora em Aquiraz. A estabilidade histórica da demanda contrasta com o pico anômalo registrado, sugerindo uma

necessidade de investigação e possível revisão de sistemas de medição. Além disso, a variação no consumo mensal destaca a importância de escolher uma modalidade tarifária que melhor se alinhe com os padrões de uso da unidade. A adoção da tarifa horosazonal azul, apesar de mais complexa, pode proporcionar benefícios econômicos substanciais, otimizando a relação custo-benefício para a unidade consumidora.

Figura 19 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Aquiraz.



Fonte: Próprio autor (2024).

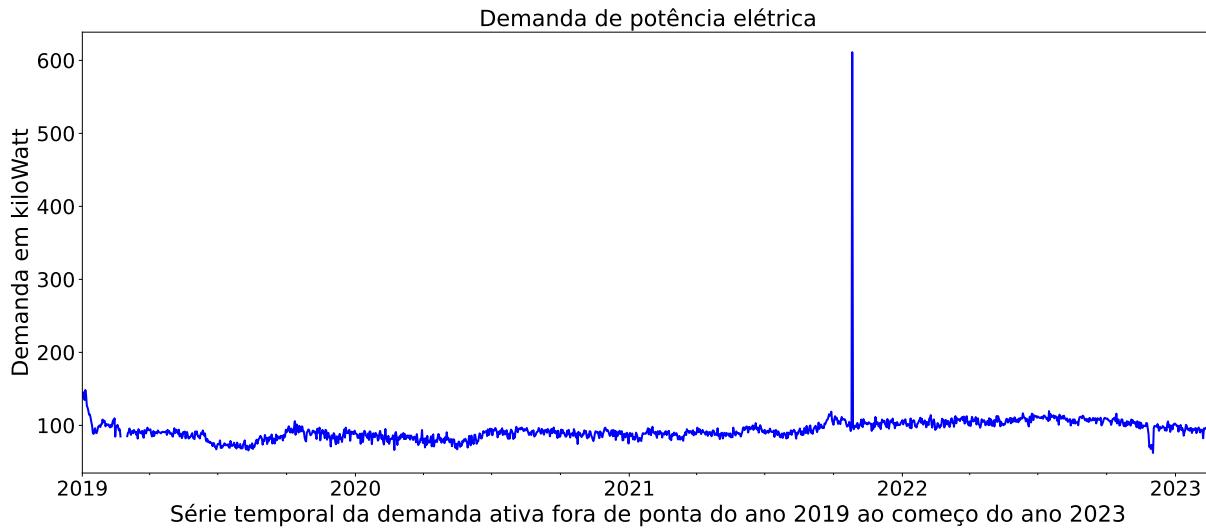
A unidade consumidora comentada e localizada em Aquiraz está tendo um custo de em torno de 496,450 mil reais anuais com a tarifa de energia atual e está pagando multa por ultrapassagem de demanda com valor por volta de 60 mil reais. Além disso, pelo baixo valor de demanda contratada (30 kW), está tendo um custo elevado com a tarifa de energia. Com a adoção de uma demanda contratada de 120 kW, tanto no horário de ponta, quanto no horário fora de ponta, o custo tarifário seria cerca de 450,780 mil reais anuais. Ressalta-se que a modalidade tarifária atual para essa unidade consumidora é a Horosazonal verde, mas a modalidade mais adequada segundo as análises e os cálculos realizados é a Horosazonal azul.

Na Figura 20, é apresentada a demanda fora de ponta de uma unidade consumidora pertencente à Secretaria de Justiça, localizada em Pacatuba. A demanda contratada para essa unidade é de 85 kW, com tarifa horosazonal verde. Após a observação da série temporal da demanda dessa unidade, com medições diárias durante 4 anos e 2 meses, constatou-se que a demanda mais adequada para este cliente de energia seria em torno de 120 a 134 kW contratados

no horário de ponta e 120 a 132 kW contratados no horário fora de ponta, com tarifação horosazonal azul. Em 1513 dias de medição, 75% das medições da demanda elétrica fora de ponta registraram valores até aproximadamente 101 kW, com média de cerca de 93 kW e mediana de 92 kW. No ano de 2022, a média foi de aproximadamente 105 kW, mediana de 106 kW, com 80% das medições apresentando valores até aproximadamente 110 kW e um valor máximo registrado de quase 120 kW. O desvio padrão em 2022 foi de apenas cerca de 7 kW, o que sugere um padrão de consumo consistente. Este comportamento demonstra que a demanda desta unidade é constante e não varia drasticamente. Contudo, é necessário alterar o valor contratado, conforme já mencionado. Em outubro de 2021, ocorreu um pico anômalo ao comportamento habitual da série temporal desta unidade, registrando 601 kW no horário fora de ponta, um valor significativamente maior do que a média e os valores típicos de demanda. Este pico anômalo é um ponto crítico que merece investigação para determinar se foi ocasionado pelo cliente ou por um erro no sistema de medição. A demanda contratada de apenas 85 kW é frequentemente excedida pela unidade, alcançando até 120 kW. Recomenda-se a revisão do contrato de demanda para refletir mais precisamente o consumo real, evitando penalidades e otimizando os custos de energia. Em suma, a análise da Figura 20 destaca a necessidade de ajustes na gestão tarifária e na contratação de demanda para a unidade consumidora em Pacatuba. A constância da demanda, combinada com picos anômalos, sugere que a revisão do contrato e a mudança para uma tarifação mais adequada poderiam otimizar os custos e prevenir surpresas na fatura de energia. Além disso, a investigação de picos anômalos é essencial para garantir a precisão dos dados de medição e evitar cobranças indevidas.

A Figura 21 ilustra a série temporal do consumo de energia mensal fora de ponta, em kWh, para uma unidade consumidora localizada em Pacatuba ao longo do ano de 2022. A análise detalhada dos dados apresentados na figura revela algumas observações importantes que merecem destaque. O consumo de energia fora de ponta atinge seu pico nos meses de julho e agosto, com um consumo mensal aproximado de 50000 kWh. Apesar desse pico, observa-se uma variação perceptível ao longo do ano, com oscilações notáveis entre os meses. O consumo mais baixo registrado ocorre em fevereiro, com aproximadamente 40000 kWh, indicando uma queda significativa em comparação aos meses de pico. Comparando-se os valores mensais, nota-se que a maioria dos meses mantém o consumo acima de 40000 kWh, com exceção de fevereiro. Esta consistência relativa sugere um comportamento estável na maior parte do ano, excetuando-se os períodos de variação mencionados. É importante considerar fatores como variações climáticas,

Figura 20 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Pacatuba.



Fonte: Próprio autor (2024).

atividades sazonais e possíveis mudanças no uso de equipamentos elétricos que podem estar influenciando o padrão de consumo observado. Essas variáveis devem ser levadas em conta para uma análise mais precisa e detalhada do comportamento de consumo de energia da unidade em questão.

Figura 21 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Pacatuba.

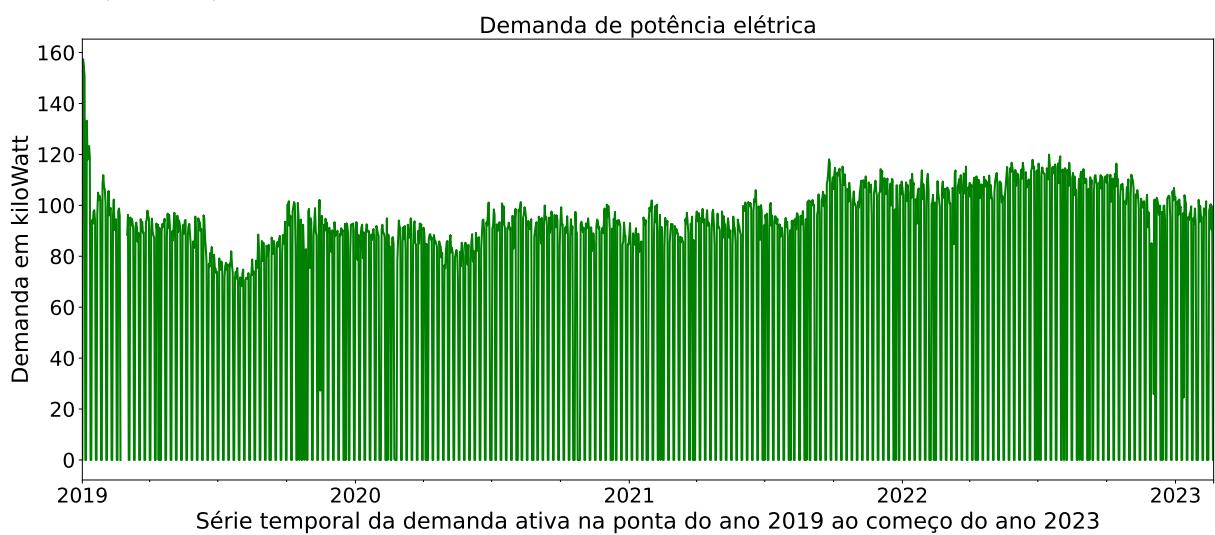


Fonte: Próprio autor (2024).

Na Figura 22 é apresentada a série temporal da demanda medida no horário de ponta na unidade consumidora localizada em Pacatuba. Ao longo dos quatro anos e dois

meses de medições, a demanda no horário de ponta mostrou-se relativamente estável, com uma média de aproximadamente 66 kW e uma mediana de 90 kW, sendo que 75% das medições não ultrapassaram 100 kW. No ano de 2022, a demanda média foi de cerca de 74 kW, com uma mediana em torno de 104 kW. Além disso, 80% dos registros permaneceram abaixo de aproximadamente 111 kW, com o valor máximo atingindo cerca de 120 kW. Observa-se um pico de demanda significativo no início do período analisado, em 2019, com valores chegando a aproximadamente 160 kW. Após esse pico inicial, a demanda se estabilizou, indicando um comportamento consistente no consumo de energia. A partir de 2021, há uma leve tendência de aumento na demanda, o que pode refletir um crescimento no consumo de energia devido a fatores como aumento da atividade econômica ou expansão das operações na unidade consumidora. Essas observações destacam a importância de considerar tanto fatores sazonais quanto mudanças no perfil de consumo ao analisar a demanda de potência na ponta. Embora haja algumas flutuações sazonais, a demanda se mantém relativamente estável ao longo do tempo, sem variações extremas. Este padrão sugere que os fatores sazonais têm um impacto moderado na demanda de potência durante o horário de ponta.

Figura 22 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2024, em kW, na unidade consumidora localizada em Pacatuba.

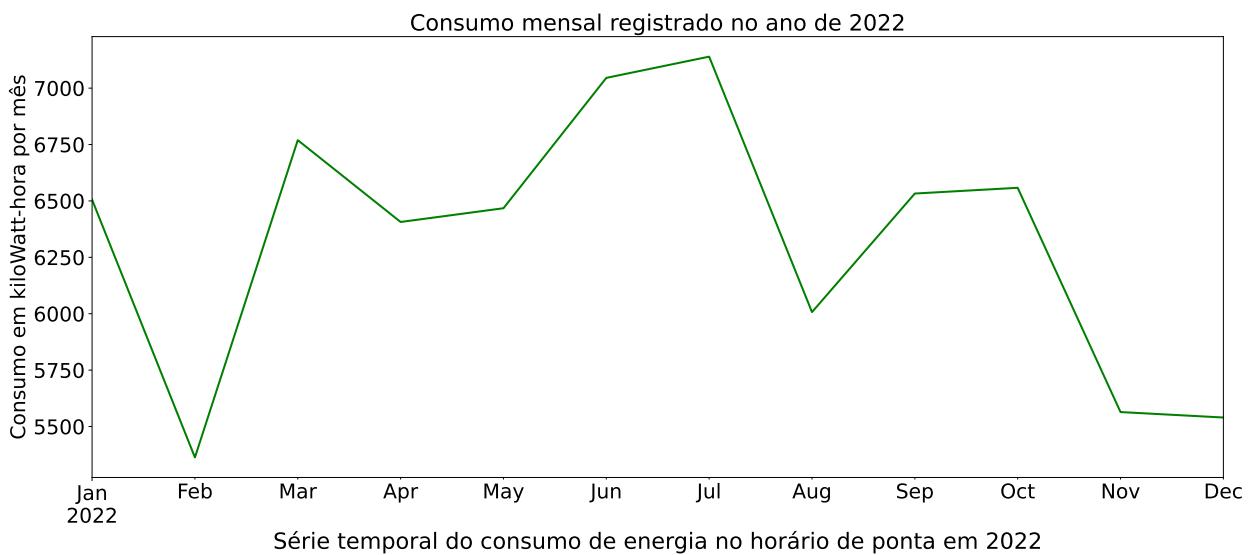


Fonte: Próprio autor (2024).

Na Figura 23 é mostrado o consumo no horário de ponta no ano de 2022 da unidade consumidora localizada em Pacatuba. O consumo de energia no horário de ponta apresenta variações significativas ao longo do ano, com um consumo mais baixo registrado em fevereiro, em torno de 5300 kWh, e um pico em julho, com aproximadamente 7250 kWh. Após o pico de

julho, o consumo diminui novamente, com outra queda significativa em novembro, atingindo valores similares aos de fevereiro. Exceto pelos picos e vales observados, o consumo mensal se mantém relativamente estável entre 6000 kWh e 7000 kWh nos outros meses, indicando um comportamento consistente no uso de energia durante a maior parte do ano. A quantidade de consumo dessa unidade no horário de ponta sugere a necessidade de alteração da modalidade tarifária para horosazonal azul, pois os custos de tarifação são menores com esse modelo tarifário para este cliente de energia elétrica. Esta mudança pode ser vantajosa considerando o padrão de consumo observado e as possíveis influências de fatores sazonais. A análise técnica reforça a importância de considerar esses fatores ao planejar a estratégia de tarifação para a unidade consumidora.

Figura 23 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em Pacatuba.



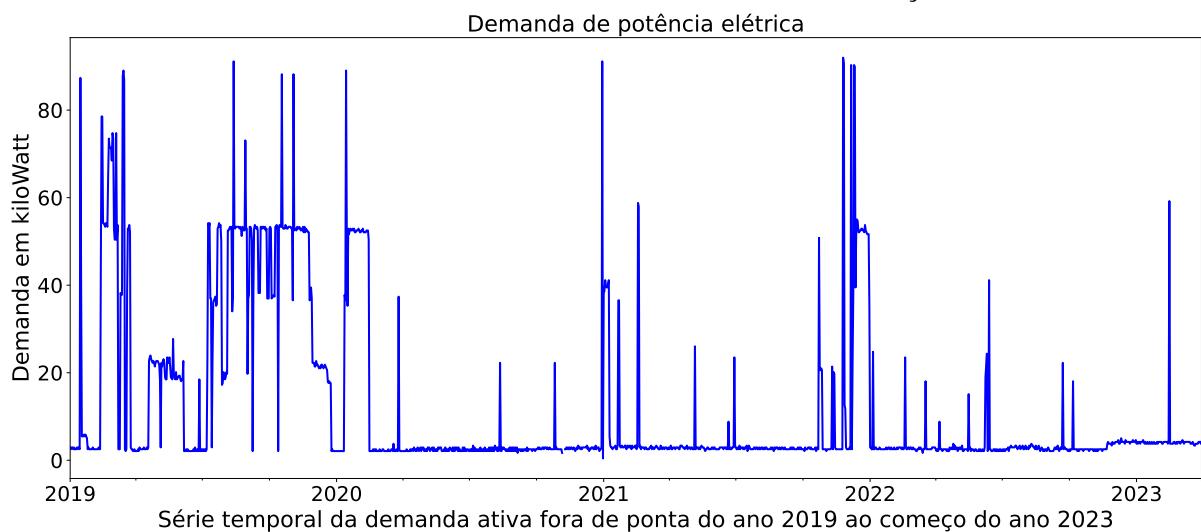
Fonte: Próprio autor (2024).

A unidade consumidora comentada e localizada em Pacatuba está tendo um custo de em torno de 485,370 mil reais anuais com a tarifa de energia atual e está pagando multa por ultrapassagem de demanda com valor por volta de 20,70 mil reais. Além disso, pelo baixo valor de demanda contratada (85 kW), está tendo um custo elevado com a tarifa de energia. Com a adoção de uma demanda contratada de 120 kW, tanto no horário de ponta, quanto no horário fora de ponta o custo tarifário seria cerca de 447,190 mil reais anuais. Ressalta-se que a modalidade tarifária atual para essa unidade consumidora é a Horosazonal verde, mas a modalidade mais adequada segundo as análises e os cálculos realizados é a Horosazonal azul.

Na Figura 24, é apresentada a demanda fora de ponta de uma unidade consumidora responsável pelo gerenciamento da água acumulada nos reservatórios públicos do Ceará, localizada em São Gonçalo do Amarante. A demanda contratada para esta unidade é de 136 kW, com tarifa horosazonal verde. Entretanto, apenas parcialmente se justifica este valor de demanda contratada, observando-se uma demanda significativamente maior apenas em 2019, em comparação com os outros anos registrados pelo sistema de telemedição. No ano de 2019, a demanda média foi de 30 kW, com mediana de 23 kW, 75% dos dados situados até 53 kW, e um valor máximo registrado de 91 kW no horário fora de ponta. Nos anos subsequentes até março de 2024, período abrangido pelos dados coletados, a unidade consumidora apresentou um consumo de energia praticamente insignificante. Nesse intervalo, a demanda média foi de cerca de 6 kW, com mediana de 2,5 kW, e 75% dos dados registrando valores até 3 kW. Os picos de demanda registrados durante esses anos são aleatórios e não representam a energia requerida consistentemente. No ano de 2022, a demanda fora de ponta teve uma média de 3 kW, com mediana de 2,5 kW, e 80% dos dados registrando valores até aproximadamente 3 kW. Esses dados sugerem que a unidade deveria ser desligada, ou seja, interromper o fornecimento de energia para essa unidade consumidora. Caso o desligamento não seja viável, é necessária uma redução da demanda contratada para 30 kW, que é o valor mínimo permitido para clientes do grupo A. A análise da série temporal da demanda fora de ponta na unidade consumidora mencionada revela uma discrepância significativa entre a demanda contratada e o consumo real de energia, especialmente após 2019. A figura demonstra que, a partir de 2020, a demanda reduziu drasticamente, permanecendo em níveis extremamente baixos. Essa redução acentuada pode indicar mudanças operacionais na unidade consumidora ou a desativação parcial das atividades. A persistência de picos aleatórios, mesmo em períodos de baixa demanda, levanta questões sobre a precisão e a consistência do sistema de medição. Esses picos anômalos, embora esporádicos, sugerem a necessidade de uma investigação detalhada para identificar se são resultantes de atividades operacionais irregulares ou falhas no sistema de medição. A manutenção de uma demanda contratada de 136 kW, apesar da redução drástica no consumo, resulta em custos desnecessários para a unidade consumidora. A revisão do contrato de demanda para refletir o consumo real atual é essencial para otimizar os custos de energia. Caso a unidade retome suas atividades normais, ajustes futuros poderão ser feitos, mas, no cenário atual, a manutenção de uma demanda contratada tão alta é economicamente inviável. Além disso, a análise sugere que, se a unidade continuar a operar com uma demanda tão baixa, a modalidade tarifária verde

pode não ser a mais adequada. Uma revisão completa das necessidades energéticas e das tarifas aplicáveis poderia resultar em economias significativas e melhor gestão dos recursos energéticos.

Figura 24 – Demanda de potência fora de ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em São Gonçalo do Amarante.

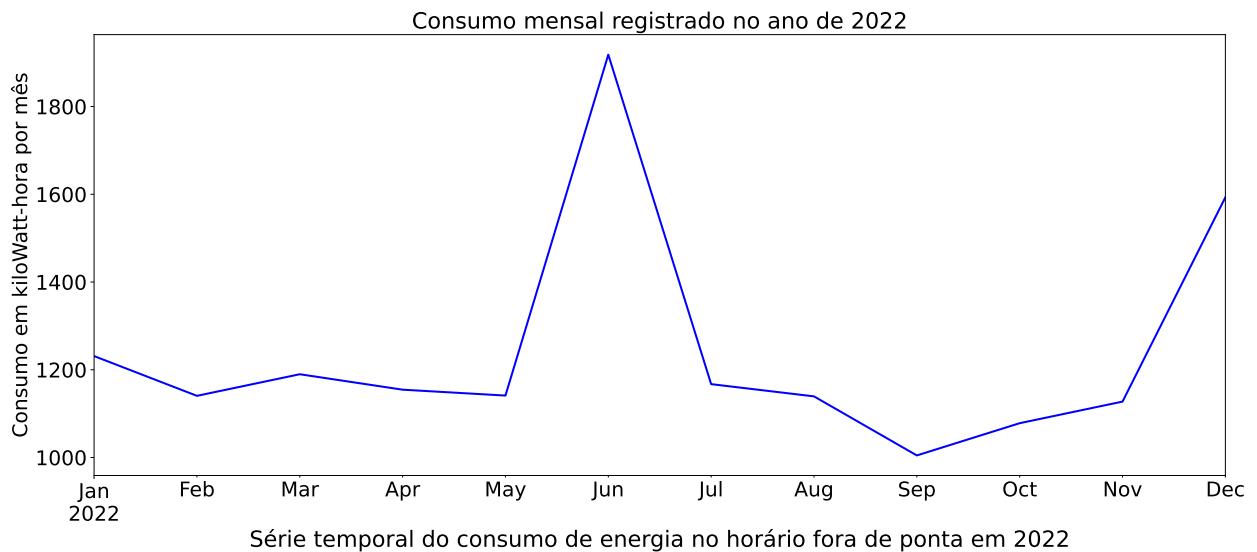


Fonte: Próprio autor (2024).

Na Figura 25, apresenta-se o consumo fora de ponta no ano de 2022 da unidade consumidora localizada em São Gonçalo do Amarante, anteriormente discutida quanto à demanda fora de ponta na Figura 24. Observa-se que o consumo desta unidade no horário fora de ponta em 2022 é significativamente baixo em relação à demanda contratada, corroborando com as medições de demanda ilustradas na Figura 24. Este fato evidencia a necessidade imperativa de reduzir a demanda contratada. O gráfico indica que, ao longo de 2022, o consumo de energia fora de ponta manteve-se em níveis baixos e relativamente constantes, com exceção de um pico acentuado em junho, onde o consumo ultrapassou 1800 kWh. A maior parte dos meses apresentou um consumo entre 1000 e 1300 kWh, reforçando a inadequação da demanda contratada, que é muito superior ao consumo efetivo da unidade. A observação do consumo mensal fora de ponta em 2022 corrobora com os dados de demanda apresentados anteriormente. Há uma clara discrepância entre a demanda contratada e o consumo real da unidade. Esse descompasso sugere que a demanda contratada de 136 kW é excessiva, resultando em custos desnecessários para a unidade consumidora. O pico observado em junho de 2022 é um ponto que merece atenção. Este aumento súbito no consumo pode indicar uma atividade incomum ou um possível erro na medição que deve ser investigado. Tal investigação é essencial para garantir a precisão dos dados e evitar cobranças indevidas. Considerando os dados apresentados, recomenda-se fortemente

uma revisão do contrato de demanda para refletir de forma mais precisa o consumo real da unidade. A redução da demanda contratada para cerca de 30 kW, que é o valor mínimo permitido para clientes do grupo A, parece ser uma solução viável e econômica e otimizando os custos de energia. Além disso, a análise destaca a necessidade de avaliar a modalidade tarifária mais adequada para esta unidade. Com o consumo consistentemente baixo, a tarifação horosazonal verde pode não ser a opção mais econômica. Uma revisão completa das necessidades energéticas e das tarifas aplicáveis poderia resultar em economias significativas e melhor gestão dos recursos energéticos. A análise do consumo fora de ponta em 2022 para a unidade consumidora em São Gonçalo do Amarante, juntamente com os dados de demanda, demonstra a necessidade urgente de ajustar a demanda contratada. Este ajuste evitaria custos desnecessários e proporcionaria uma gestão mais eficiente dos recursos energéticos. A investigação de picos anômalos, como o observado em junho de 2022, também é crucial para assegurar a precisão dos dados de consumo e garantir que a unidade não seja indevidamente onerada.

Figura 25 – Consumo de energia mensal fora de ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em São Gonçalo do Amarante.

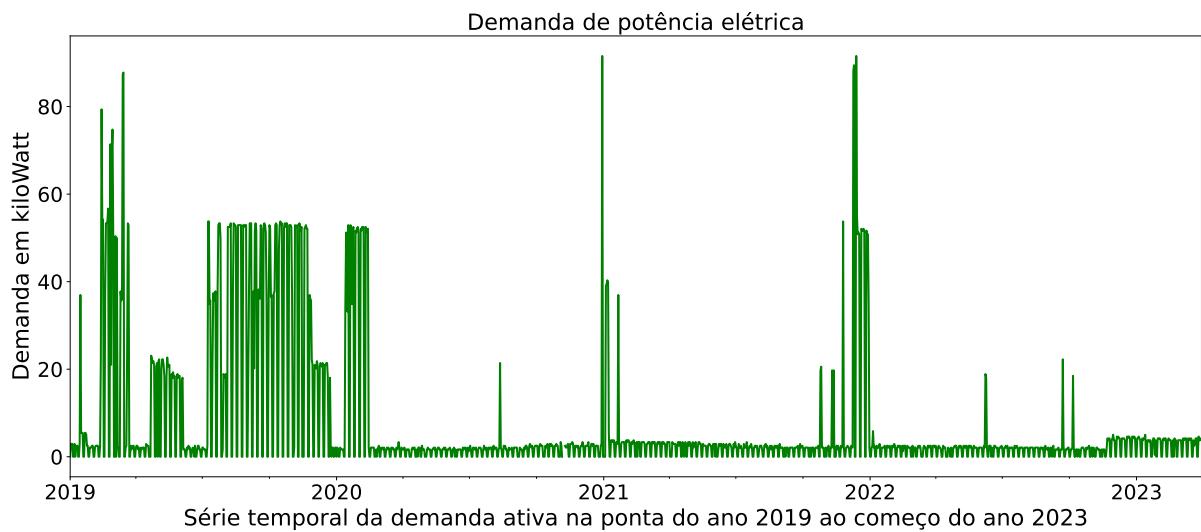


Fonte: Próprio autor (2024).

Na Figura 26, apresenta-se a série temporal da demanda medida no horário de ponta na unidade consumidora mencionada. A demanda no horário de ponta segue um perfil semelhante ao registrado no horário fora de ponta, conforme mostrado na Figura 24. Em 2019, a demanda teve uma média de aproximadamente 20 kW, com uma mediana de 3 kW, e 75% das medições registraram valores até 38 kW, com um valor máximo de 87 kW. Nos anos seguintes, a média de

demanda reduziu-se para cerca de 4 kW, com uma mediana de 2 kW, e 75% dos dados registraram valores até 2,5 kW. Durante esses anos, observaram-se picos anômalos de demanda. Em 2022, a média de demanda foi de 2 kW, com uma mediana de 2 kW, e 80% dos dados registraram valores até 2,5 kW, com uma demanda máxima medida de 22 kW. A análise dos dados indica que, após 2019, houve uma queda significativa na demanda da unidade consumidora, com valores médios e medianos muito inferiores aos do primeiro ano analisado. Os picos anômalos observados ao longo dos anos seguintes sugerem a necessidade de uma investigação detalhada para determinar as causas, sejam elas falhas no sistema de medição ou eventos de consumo atípicos. A persistência de uma demanda contratada alta, que não corresponde aos padrões de consumo atuais, reforça a necessidade de uma revisão dos contratos de demanda para alinhar melhor a capacidade contratada com o consumo real. Esta medida evitará custos desnecessários e permitirá uma gestão mais eficiente da energia. A redução da demanda contratada é crucial para otimizar os custos e evitar penalidades por excesso de demanda contratada não utilizada. Em resumo, a Figura 26 destaca a necessidade de ajustes significativos na gestão tarifária da unidade consumidora localizada em São Gonçalo do Amarante, tanto para adequar a demanda contratada às reais necessidades de consumo quanto para investigar picos anômalos de demanda.

Figura 26 – Demanda de potência na ponta medida de forma diária entre janeiro de 2019 e abril de 2023, em kW, na unidade consumidora localizada em São Gonçalo do Amarante.

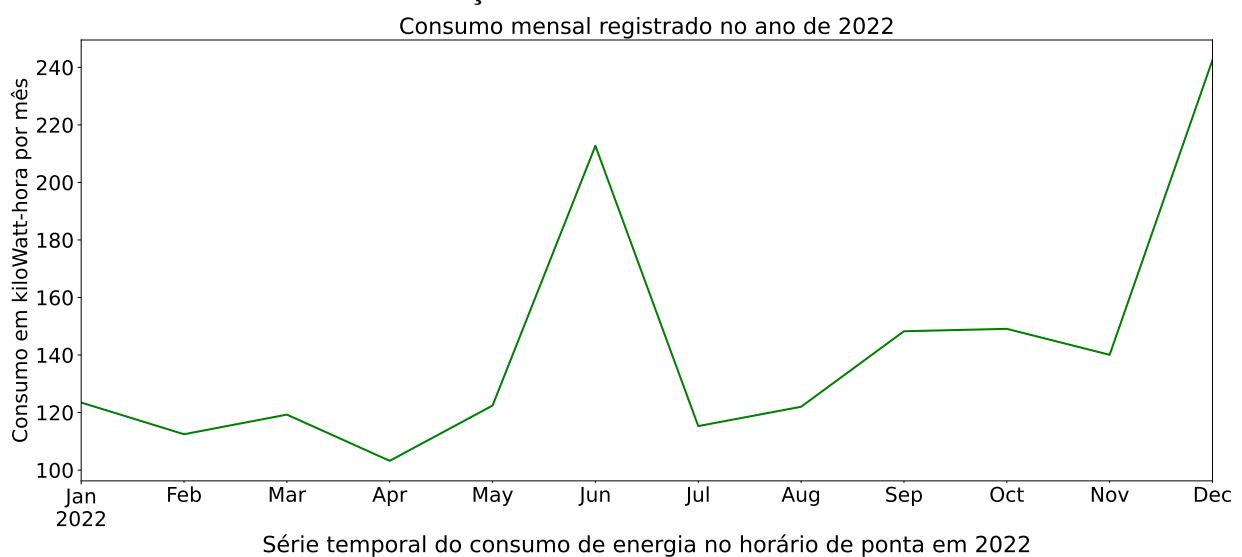


Fonte: Próprio autor (2024).

Na Figura 27 é mostrado o consumo no horário de ponta no ano de 2022 para a unidade consumidora localizada em São Gonçalo do Amarante. A análise da série temporal do consumo no horário de ponta ao longo de 2022 revela um padrão de variação significativa.

Inicialmente, nos primeiros meses do ano, o consumo mantém-se relativamente estável, oscilando entre aproximadamente 105 kWh e 125 kWh por mês. A partir de junho, observa-se um aumento acentuado, com o consumo atingindo um pico de aproximadamente 220 kWh. No entanto, este pico é seguido por uma queda abrupta em julho, retornando a valores próximos de 120 kWh. Após essa queda, o consumo volta a apresentar uma tendência de crescimento gradual, com uma pequena queda em novembro e em dezembro atinge cerca de 240 kWh. A série temporal evidencia uma variabilidade sazonal, com flutuações significativas no consumo ao longo do ano. Os picos de consumo em junho e dezembro podem estar associados a eventos específicos ou aumentos temporários na demanda de energia. É essencial investigar as causas subjacentes a esses aumentos para entender melhor o perfil de consumo da unidade e, possivelmente, implementar medidas de gestão de demanda.

Figura 27 – Consumo de energia mensal na ponta registrado no ano de 2022, em kWh, na unidade consumidora localizada em São Gonçalo do Amarante.



Fonte: Próprio autor (2024).

A unidade consumidora comentada e localizada em São Gonçalo do Amarante está tendo um custo de em torno de 58,938 mil reais anuais com a tarifa de energia atual, não está pagando multa por ultrapassagem de demanda, porém, pelo alto valor de demanda contratada (136 kW), está tendo um custo elevado com a tarifa de energia. Com a adoção de uma demanda contratada de 30 kW o custo tarifário seria cerca de 22,338 mil reais anuais.

Após a análise de 185 unidades consumidoras de energia foram estimados e calculados cobranças por multas de ultrapassagem de demanda, valores de multas por excedentes

de energia reativa e como ficariam os custos do Governo do Ceará com energia da unidades mencionadas se as sugestões de demanda e/ou mudanças de métodos tarifários fossem acatadas, isso é mostrado na Tabela 1. O Estado possui mais de 1200 unidades consumidoras do grupos A, há um potencial de exploração em busca da redução de custos e da eficiência energética enorme nessas unidades. O estudo realizado nesta tese mostra que o Ceará pode economizar bastante no setor de energia elétrica se buscar conseguir a eficiência energética por meio de auditorias, por exemplo. O valor gasto nesse setor poderia ser transferido para setores estratégicos como educação, saúde e segurança.

Tabela 1 – Economia Potencial com Sugestão de Demanda e Mudanças de Métodos Tarifários

Valor com demandas e método tarifário atual (R\$)	Cobrança por ultrapassagem (R\$)	Valor com sugestões de demandas e/ou mudança de método tarifário (R\$)	Valor de multas por excedente reativo (R\$)
18.648.681,30	114.381,09	15.927.126,96	303.183,85

2,722 Milhões
Total Economizado (R\$)

Fonte: Próprio autor (2025).

3.3 Considerações finais

Este capítulo apresentou a análise de séries temporais e detecção de comportamentos anormais na demanda e no consumo de energia medido de unidades consumidoras. Foram observados os dados coletados e a partir disso gerou-se informações e análises estatísticas de média, mediana, quartis e valores discrepantes, a fim de mostrar que certas unidades estão com demandas contratadas muito acima do valor que realmente necessitam, pois isso é refletido em seus consumos de energia. Graficamente também pode-se perceber essas informações irregularidades na demanda medida, que são refletidas no consumo, nos horários tanto fora de ponta como de ponta. O método de análise de séries temporais e encontrar pontos de dados anômalos e sugerir valores de demanda contratada adequada para as unidades consumidoras de

energia, é apenas um dos métodos que são utilizados nesse trabalho a fim de se obter a gestão da demanda, incluindo a eficiência energética e a redução de custos.

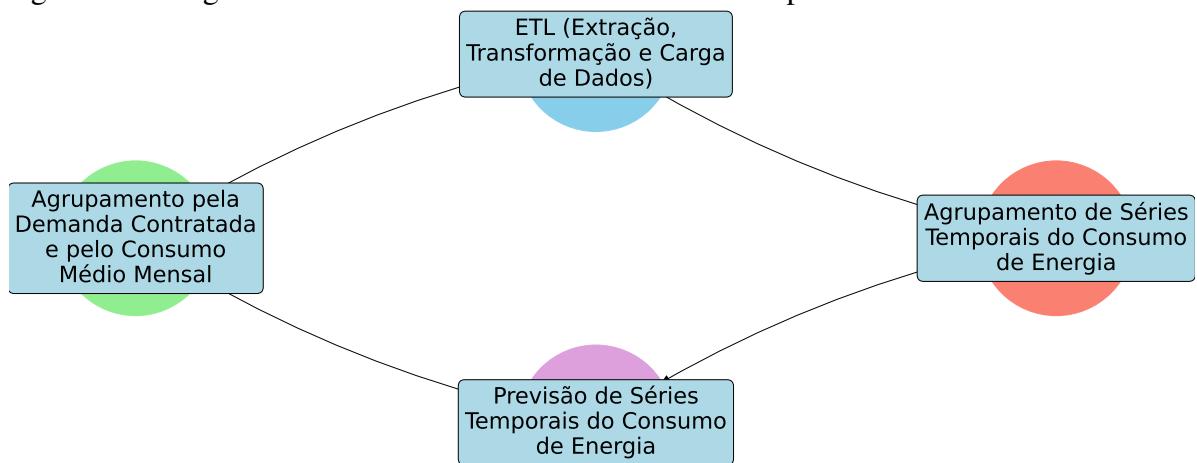
4 AGRUPAMENTO DE UNIDADES CONSUMIDORAS DE ENERGIA ELÉTRICA PELA DEMANDA E PELO CONSUMO DE ENERGIA E PREVISÃO DO CONSUMO ELÉTRICO

4.1 Introdução

Este capítulo, além da seção de introdução, compreende mais três seções: o agrupamento de unidades consumidoras de energia conforme a demanda contratada e o consumo médio mensal (sendo este último calculado pela soma do consumo total anual dividido por doze); o agrupamento das séries temporais do consumo medido das unidades consumidoras; e a previsão do consumo elétrico futuro, tanto por métodos univariados quanto pela inclusão de variáveis exógenas para aprimorar a previsão. As variáveis exógenas empregadas correspondem a outras unidades consumidoras de energia que apresentam um padrão de consumo similar à unidade em análise, abrangendo tendência e sazonalidade. Os agrupamentos serão realizados com séries temporais de demanda e consumo de 185 unidades consumidoras públicas do estado do Ceará. O agrupamento de unidades consumidoras de energia conforme a demanda contratada e o consumo médio mensal é fundamental para identificar diferentes perfis de consumo, detectar anomalias e necessidades energéticas. Ao agrupar as séries temporais do consumo medido das unidades consumidoras, pode-se identificar padrões de consumo dos clientes ao longo do tempo, incluindo tendências e sazonalidades, e descobrir em qual grupo um determinado cliente se encaixa. Isso é crucial para entender melhor as demandas de energia em diferentes períodos e para aprimorar a previsão do consumo futuro. Além de contribuir para que clientes com consumos que tenham perfis diferentes dos demais clientes do grupo de origem possam ser identificados e a gestão de energia possa ser aplicada. A inclusão de variáveis exógenas, como o consumo de outras unidades consumidoras com padrões semelhantes, permite melhorar a precisão das previsões ao considerar influências externas que podem afetar o consumo de energia. Essas variáveis abrangem tendências e sazonalidades observadas em outros consumidores, fornecendo insights valiosos para a previsão do consumo de energia futuro. O uso de técnicas de aprendizado de máquina é essencial nesse contexto, pois permite automatizar e aprimorar esses processos de análise, identificação de padrões e previsão, tornando-os mais eficientes, precisos e escaláveis do que se fossem feitos manualmente. Dessa forma, pode-se obter uma visão mais abrangente e detalhada do consumo de energia, contribuindo para uma gestão mais eficiente e sustentável dos recursos energéticos. A Figura 28 apresenta o que foi realizado nas seções do capítulo 4. Além

da etapa de ETL (Extração, Transformação e Carga de Dados), foram executados os estudos comentados acima sobre as seções deste capítulo, que incluem o agrupamento das unidades consumidoras de energia de acordo com a demanda contratada e o consumo médio mensal (este último calculado pela divisão do consumo anual total por doze), a clusterização das séries temporais de consumo medido das unidades consumidoras e a previsão do consumo futuro de energia elétrica, tanto por meio de métodos univariados quanto com a incorporação de variáveis exógenas para aprimorar a previsão.

Figura 28 – Diagrama de Blocos dos estudos realizados no capítulo 4.



Fonte: Próprio autor (2024).

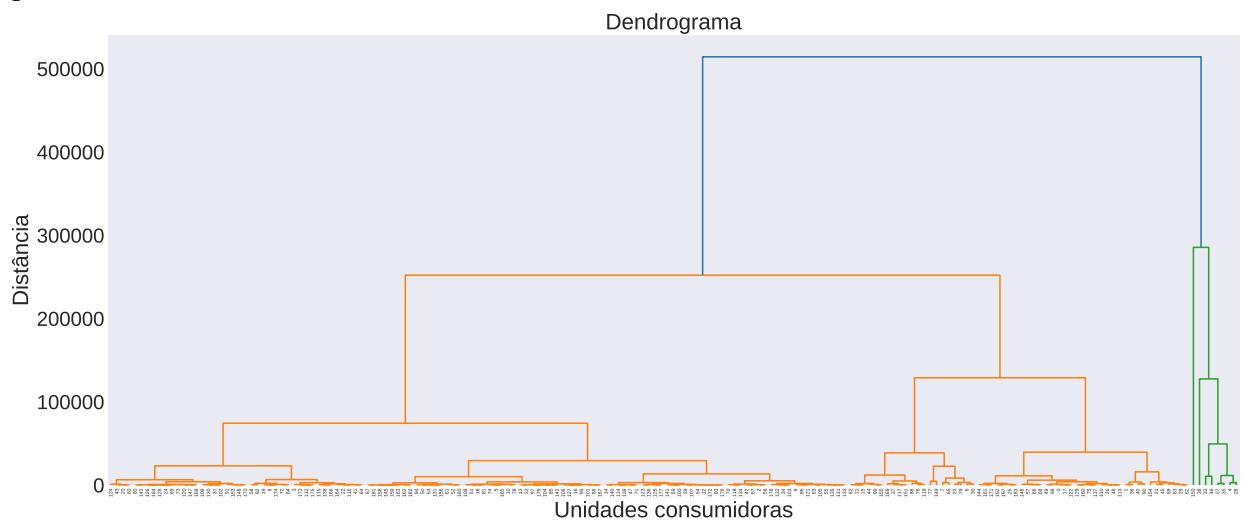
4.2 Agrupamento de unidades consumidoras pela demanda contratada e pelo consumo médio mensal

4.2.1 Agrupamento hierárquico

Para a determinação do número de grupos no Agrupamento Hierárquico, foi realizado uma análise do dendrograma. O dendrograma sugere a presença de dois grandes grupos; no entanto, o objetivo da clusterização nesta seção é identificar clientes cuja demanda contratada excede significativamente sua necessidade real de energia, com base no consumo observado. Dado que a escala dos valores não apresenta discrepâncias extremas, como no caso de compras fraudulentas em cartões de crédito, onde o valor pode ser muito maior em comparação com uma compra legítima, tornando a discrepância mais facilmente identificável, optou-se por adotar não apenas dois, mas cinco clusters. Isso se deve ao fato de que os valores não são tão distintamente separáveis. Dessa forma, pode haver informações essenciais e específicas sobre o comportamento

dos clientes em subgrupos dentro dos dois grandes grupos, por isso a adoção de cinco clusters. A Figura 29 apresenta o dendrograma utilizado para determinar o número de clusters para a aplicação do algoritmo de Agrupamento Hierárquico. A Figura 30 ilustra o agrupamento de 185 unidades consumidoras de energia por meio do método de agrupamento hierárquico. O objetivo é agrupar os clientes com base em seu nível de consumo e verificar se estão no grupo adequado, considerando também o valor da demanda contratada. Ou seja, unidades consumidoras com uma demanda contratada maior deveriam, teoricamente, consumir mais energia. No entanto, se uma unidade apresentar uma demanda contratada muito alta e um consumo baixo de energia, a clusterização identificará esses clientes, sugerindo a necessidade de ajustar sua demanda contratada para um valor mais adequado ao seu consumo médio mensal de energia.

Figura 29 – Dendrograma para a escolha do número de grupos utilizando Agrupamento Hierárquico.

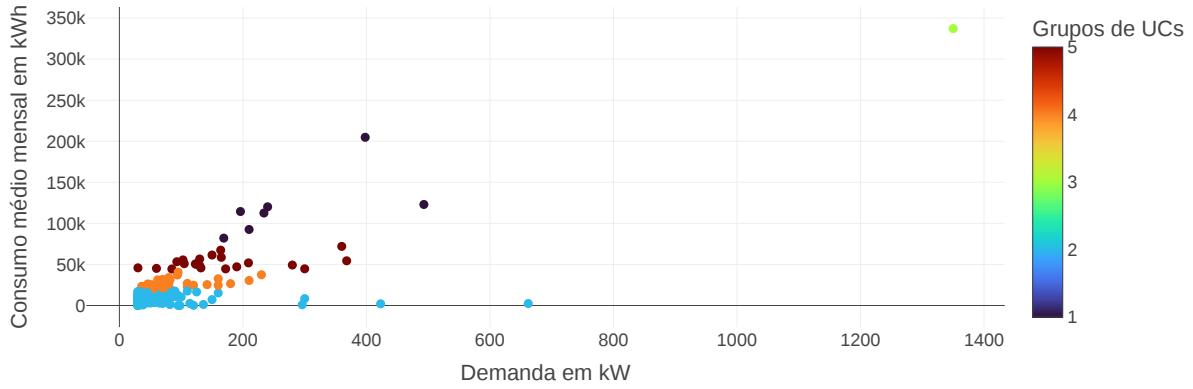


Fonte: Próprio autor (2024).

Na Figura 31 é mostrada a quantidade de clientes separados em cinco grupos, conforme a separação feita pelo Agrupamento Hierárquico. Observa-se que o agrupamento hierárquico não apresentou elevada sensibilidade na separação dos grupos com base nos níveis de consumo e na demanda contratada. Embora várias unidades apresentem demandas contratadas que correspondem ao valor de consumo observado, há clientes com consumos muito baixos e demandas contratadas muito altas que foram agrupados juntos. Especificamente, os grupos de 1 a 5 contêm 7, 121, 1, 35 e 21 unidades consumidoras, respectivamente, totalizando as 185 unidades agrupadas.

Figura 30 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do Agrupamento Hierárquico.

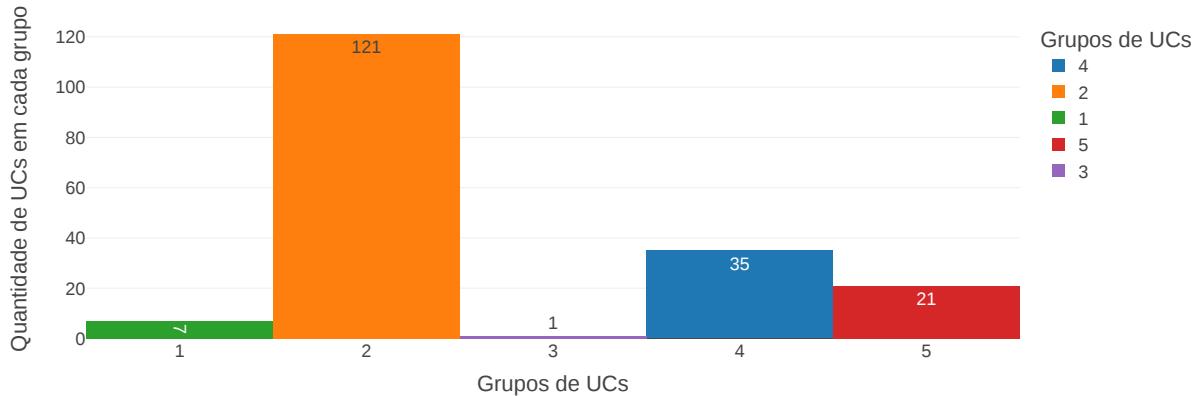
Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo (kWh) usando AH



Fonte: Próprio autor (2024).

Figura 31 – Quantidade de unidades consumidoras separadas pelo Agrupamento Hierárquico em cada um dos cinco grupos escolhidos.

Distribuição das UCs em grupos segundo o agrupamento hierárquico



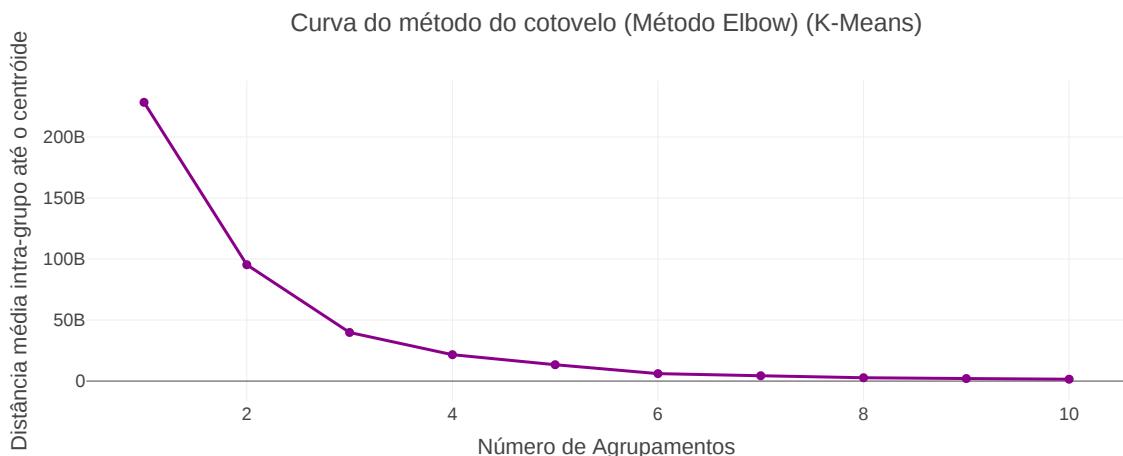
Fonte: Próprio autor (2024).

4.2.2 Agrupamento com K-Médias

Outro método utilizado na escolha do número de clusters foi o método do cotovelo. Basicamente, escolhe-se o número de grupos no ponto do gráfico onde a inclinação tende a diminuir. Isso indica que, quando se chega ao ponto do cotovelo, a adição de mais clusters não proporcionará uma redução significativa da soma dos quadrados das distâncias. De acordo com o gráfico, a escolha deveria ser em torno de 3 a 4 clusters; porém, como já mencionado, esses métodos de avaliação não são tão eficazes quando os clusters não são bem separados e não há

uma grande esparsidade. Consequentemente, foi novamente adotado o número de 5 grupos no algoritmo K-Médias. Na Figura 32 é mostrado o gráfico do método do cotovelo para o algoritmo K-Médias. Já na Figura 33, é apresentada a divisão feita pelo K-Médias ao longo dos 5 grupos.

Figura 32 – Escolha do número de clusters de acordo com o método do cotovelo.



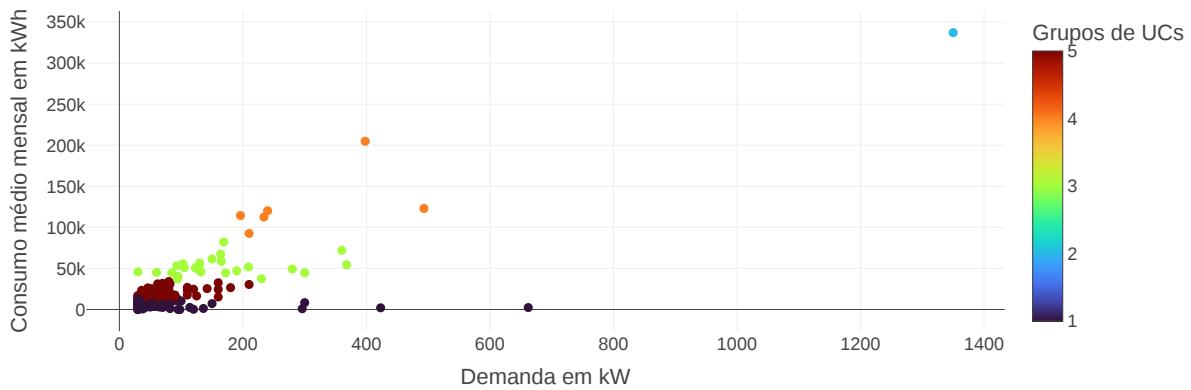
Fonte: Próprio autor (2024).

Observa-se que unidades com baixo consumo foram agrupadas juntas, mesmo que algumas possuam uma demanda contratada bem alta. Isso sugere que essas unidades com baixo consumo e alta demanda contratada devem reconsiderar o valor de demanda contratado, adequando-o ao seu consumo real. Foram agrupadas com unidades que possuem tanto consumo quanto demanda contratada baixos, o que pode indicar uma utilização mais adequada da demanda contratada. O algoritmo K-Médias fez essa identificação com base no consumo médio e na demanda contratada em todos os 5 clusters. Espera-se que os métodos de agrupamento utilizados no contexto abordado sejam capazes de separar bem os clientes considerados anômalos, ou seja, aqueles que estejam consumindo muito pouco e possuam demandas contratadas muito altas, por exemplo. O K-Médias se saiu bem, porém ainda agrupou clientes com consumos e demandas bem adequadas com clientes cujas demandas contratadas são muito discrepantes.

É possível observar também que um elemento foi classificado sozinho no grupo dois, o que indica um cliente discrepante dos demais em termos de valor de consumo e demanda contratada. No entanto, isso não necessariamente significa que ele está com uma demanda contratada errada. Esta situação pode ser analisada conforme foi feito no capítulo 3, que abordou a análise das séries temporais de consumo e demanda de algumas unidades consumidoras. O agrupamento realizado é outra forma de análise e detecção de clientes anômalos, oferecendo

Figura 33 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do K-Médias.

Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo (kWh) usando K-Means



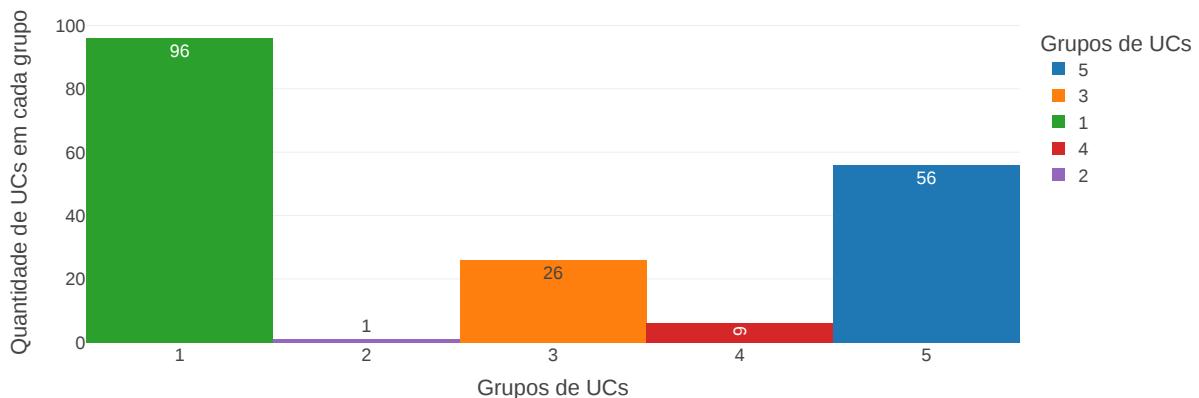
Fonte: Próprio autor (2024).

mais um método para a avaliação das unidades consumidoras em termos de eficiência no uso dos recursos energéticos contratados e na busca por redução de custos. Os grupos de 1 a 5 contêm 96, 1, 26, 6 e 56 unidades consumidoras, respectivamente, totalizando as 185 unidades agrupadas.

Na Figura 34 é mostrada a quantidade de clientes separados entre cinco grupos, conforme a separação feita pelo K-Médias.

Figura 34 – Quantidade de unidades consumidoras separadas pelo K-Médias em cada um dos cinco grupos escolhidos.

Distribuição das UCs em grupos segundo o algoritmo K-Means

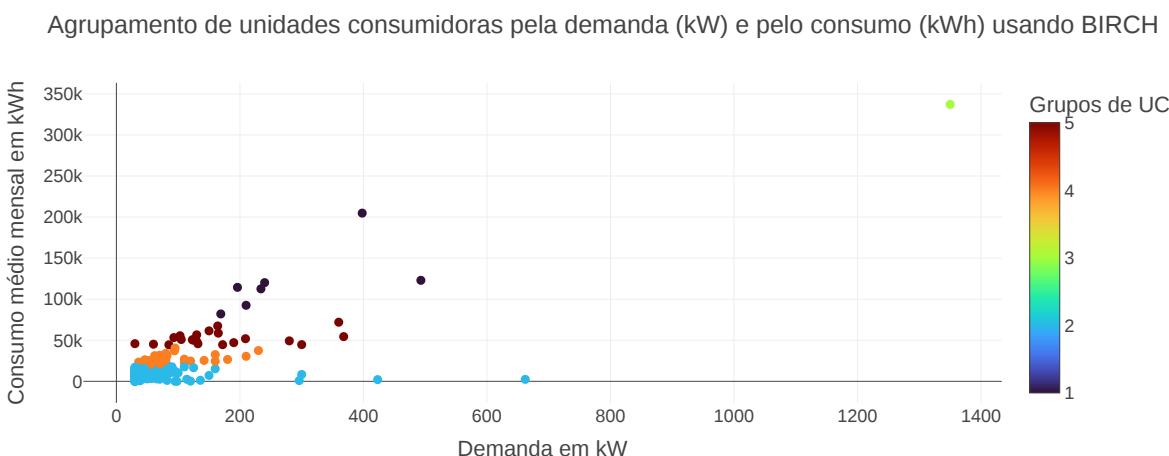


Fonte: Próprio autor (2024).

4.2.3 Agrupamento com BIRCH

Na Figura 35, observa-se o agrupamento das unidades consumidoras pela demanda e pelo consumo médio mensal. Cada cor representa um dos cinco clusters identificados pelo algoritmo BIRCH. A intenção principal é identificar unidades consumidoras com demandas contratadas muito altas e consumos muito baixos.

Figura 35 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do BIRCH.



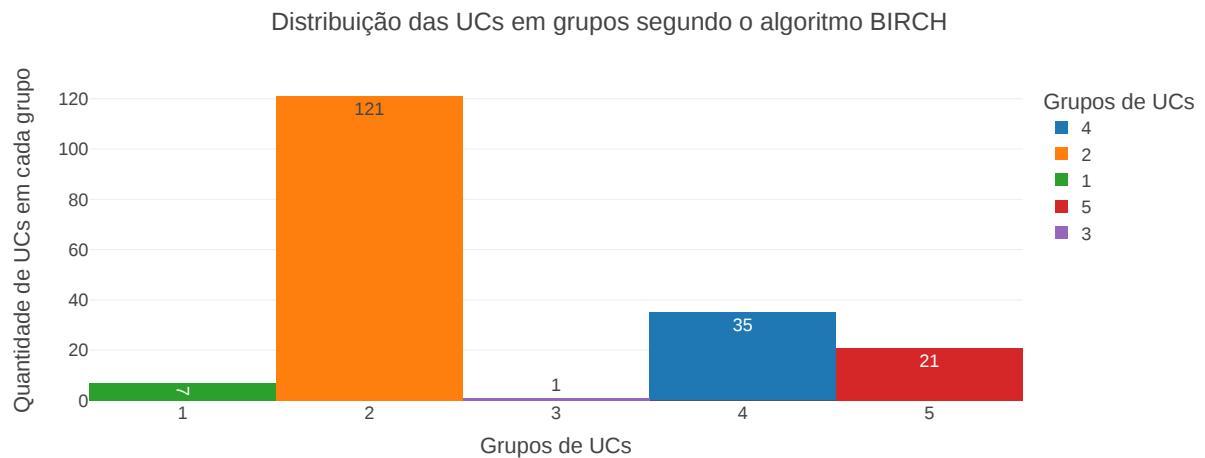
Fonte: Próprio autor (2024).

O BIRCH é um algoritmo de clustering projetado para lidar eficientemente com grandes conjuntos de dados. No caso aplicado, embora o conjunto de dados não seja grande, o BIRCH ainda é uma opção eficaz devido à sua estrutura de árvore hierárquica. O resultado foi semelhante ao obtido com o algoritmo de Agrupamento Hierárquico discutido no início da seção. No entanto, o BIRCH agrupou unidades com demandas e consumos baixos junto com unidades que apresentam consumos baixos e demandas contratadas altas. Isso sugere que o algoritmo, embora eficiente, não conseguiu separar completamente os clientes anômalos que possuem uma discrepância significativa entre demanda contratada e consumo real. Por exemplo, clientes com consumo baixo e demandas contratadas de valor alto deveriam ser analisados em grupos separados para identificar se há necessidade de ajuste na demanda contratada.

Na Figura 36 é mostrada a quantidade de clientes separados entre cinco grupos, conforme a separação feita pelo BIRCH. O uso do BIRCH, apesar de o conjunto de dados não ser extenso, mostrou-se vantajoso pela sua capacidade de lidar com a variação e dispersão dos dados de consumo e demanda. No entanto, a análise visual do gráfico confirma que, embora

o algoritmo tenha conseguido segmentar as unidades consumidoras em grupos que refletem suas características de consumo e demanda contratada, ainda há a necessidade de uma análise complementar para identificar melhor as anomalias. Identificar essas unidades é crucial para promover uma gestão mais eficiente dos recursos energéticos, ajustando as demandas contratadas conforme o consumo real.

Figura 36 – Quantidade de unidades consumidoras separadas pelo BIRCH em cada um dos cinco grupos escolhidos.



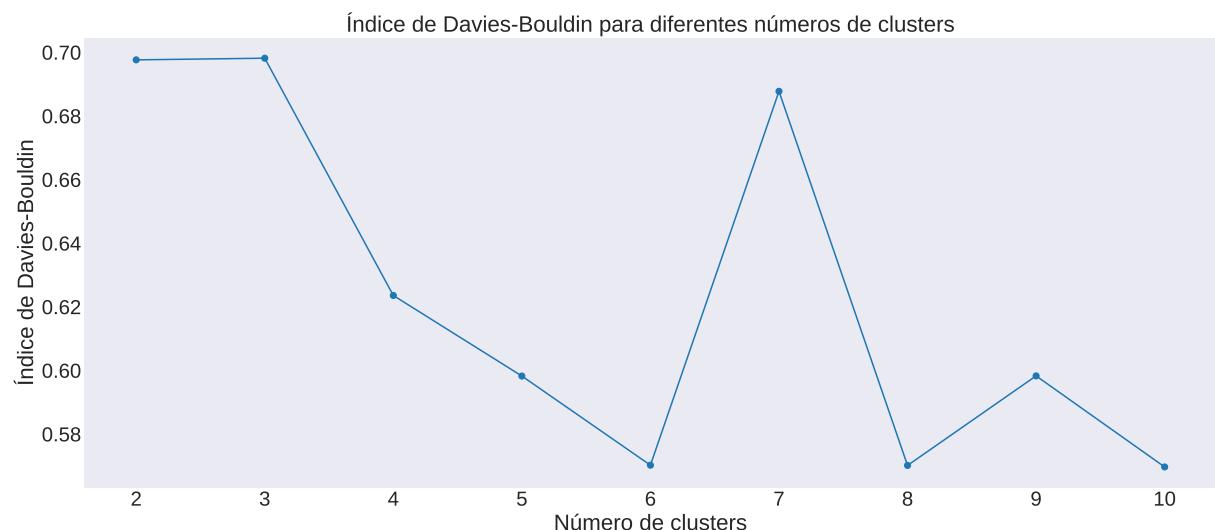
Fonte: Próprio autor (2024).

4.2.4 Agrupamento com Mini Batch K-Médias

Diferentemente do K-Médias tradicional, o Mini Batch K-Médias, em vez de usar o conjunto de dados completo a cada iteração, faz atualizações utilizando mini-batches aleatórios, ou seja, amostras menores do conjunto de dados. Isso torna o algoritmo mais rápido e mais escalável para grandes conjuntos de dados. Em cada iteração, o Mini-Batch K-Médias seleciona aleatoriamente um pequeno conjunto de dados para atualizar os centroides. A abordagem de mini lotes torna o algoritmo mais eficiente em termos computacionais. Foram utilizadas algumas métricas para a escolha do número de clusters, dentre elas o Índice de Davies Bouldin, o Índice de Calinski-Harabasz, o Coeficiente de Silhueta e o método do cotovelo. Novamente, ressalta-se que essas métricas de escolha do número de grupos funcionam melhor quando os grupos são bem definidos, bem separados e não há uma clara esparsidão entre eles. Quando os clusters estão próximos, sobrepostos ou têm densidades variáveis, essas métricas podem não refletir adequadamente a qualidade do agrupamento. Assim, em alguns casos, a escolha do número de

clusters pode ser obtida, por exemplo, por validação visual através da observação de gráficos, índices que utilizam os rótulos originais dos dados, se tiverem, ou também pode-se considerar os critérios específicos do projeto ao se avaliar os resultados de um algoritmo de clustering, pois a avaliação de clusters depende fortemente dos objetivos e do contexto do problema em questão. Na Figura 37 é mostrado o gráfico para o Índice de Davies Bouldin variando de 2 a 10 grupos. O Índice de Davies Bouldin é uma métrica de avaliação de clusterização que considera a dispersão intra-cluster e a dispersão inter-cluster. Um valor mais baixo do índice indica uma clusterização mais eficaz, onde os clusters estão mais compactos e separados uns dos outros. Essa métrica é útil porque não requer conhecimento prévio sobre o verdadeiro número de clusters nos dados. No entanto, é importante lembrar que o Índice de Davies Bouldin assume que os clusters têm uma forma esférica e têm tamanhos aproximadamente iguais, o que nem sempre é o caso na prática. Por isso, é recomendável usar essa métrica juntamente com outras métricas e técnicas de avaliação para obter uma visão mais completa da qualidade da clusterização. O gráfico da Figura 37 sugere um número adequado de 6 clusters, não valeria a pena colocar 8 ou 10 clusters, pois os valores do índice não seriam menor do que com 6 grupos.

Figura 37 – Gráfico dos valores do Índice de Davies Bouldin variando de 2 a 10 grupos.

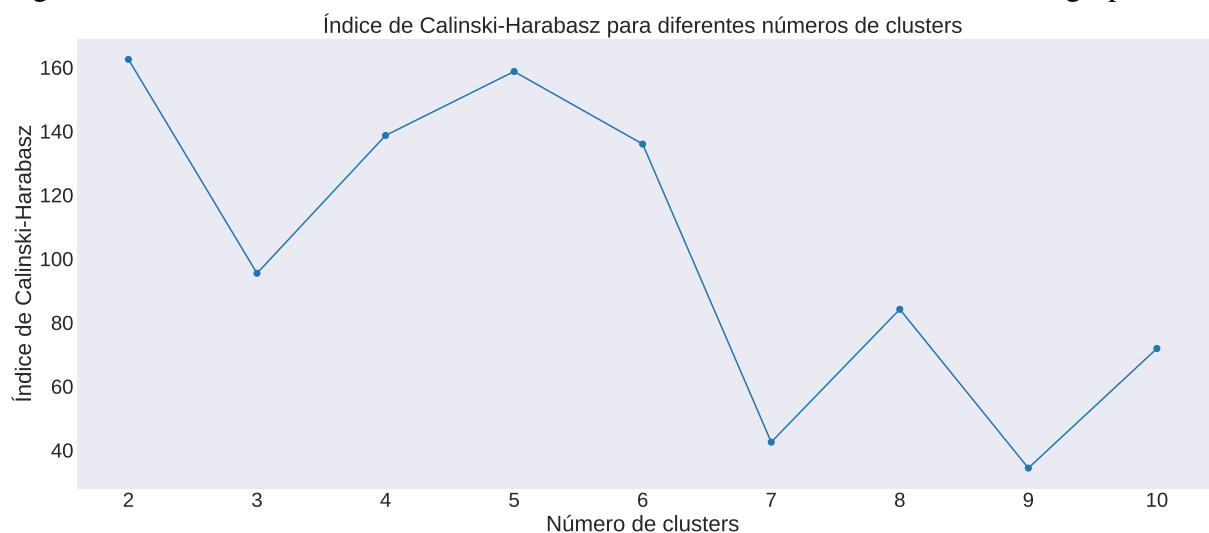


Fonte: Próprio autor (2024).

Na Figura 38 é mostrado o gráfico para o Índice de Calinski-Harabasz. Este índice avalia a qualidade da clusterização com base na coesão intra-cluster e na separação inter-cluster. Em teoria, valores maiores do Índice de Calinski-Harabasz indicam uma clusterização mais coesa e bem definida, sugerindo que os clusters são mais compactos internamente e bem separados

entre si. No entanto, é importante destacar que, assim como outras métricas de avaliação de clusters, o Índice de Calinski-Harabasz funciona melhor quando os clusters são bem separados e têm formas e tamanhos aproximadamente iguais. Em situações onde os clusters estão próximos, sobrepostos ou apresentam densidades variáveis, essa métrica pode não refletir adequadamente a qualidade da clusterização. Portanto, recomenda-se usar o Índice de Calinski-Harabasz em conjunto com outras métricas e técnicas de avaliação para uma análise mais robusta e precisa da qualidade dos clusters. Observando o gráfico da Figura 38, o Índice de Calinski-Harabasz sugere que 2 grupos seriam a quantidade mais adequada. No entanto, pode-se notar que, com 5 grupos, o valor obtido pela métrica é bastante próximo ao obtido com 2 grupos.

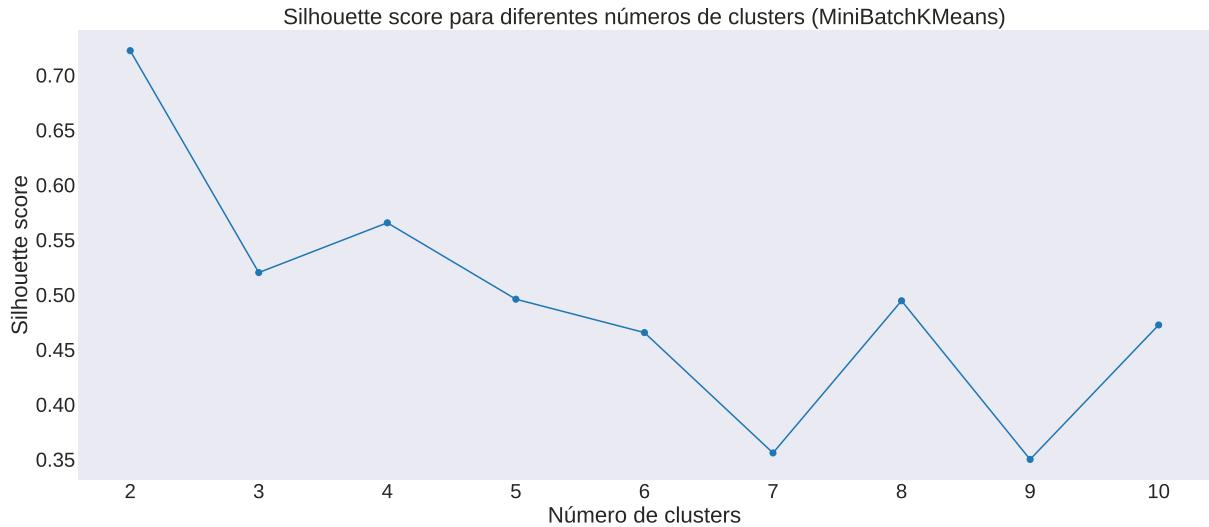
Figura 38 – Gráfico dos valores do Índice de Calinski-Harabasz variando de 2 a 10 grupos.



Fonte: Próprio autor (2024).

Na Figura 39 é mostrado o gráfico para o Coeficiente de Silhueta. Este índice mede a qualidade da clusterização com base na proximidade de cada ponto ao seu próprio cluster em comparação com os pontos dos clusters vizinhos. Um valor mais elevado do Coeficiente de Silhueta indica uma maior clareza na distinção entre os clusters, ou seja, maior é a separação entre os clusters. Quando o valor do Coeficiente de Silhueta é igual a zero, sugere que a amostra está na fronteira de decisão entre dois clusters vizinhos. Em contrapartida, um valor negativo indica a possibilidade de que essas amostras tenham sido atribuídas ao cluster errado. Dessa forma, o Coeficiente de Silhueta é uma ferramenta útil para avaliar a consistência dos clusters e identificar possíveis problemas na alocação de amostras. O gráfico da Figura 39, com base na métrica do Coeficiente de Silhueta, sugere a formação de 2 grupos.

Figura 39 – Gráfico dos valores do Coeficiente de Silhueta variando de 2 a 10 grupos.

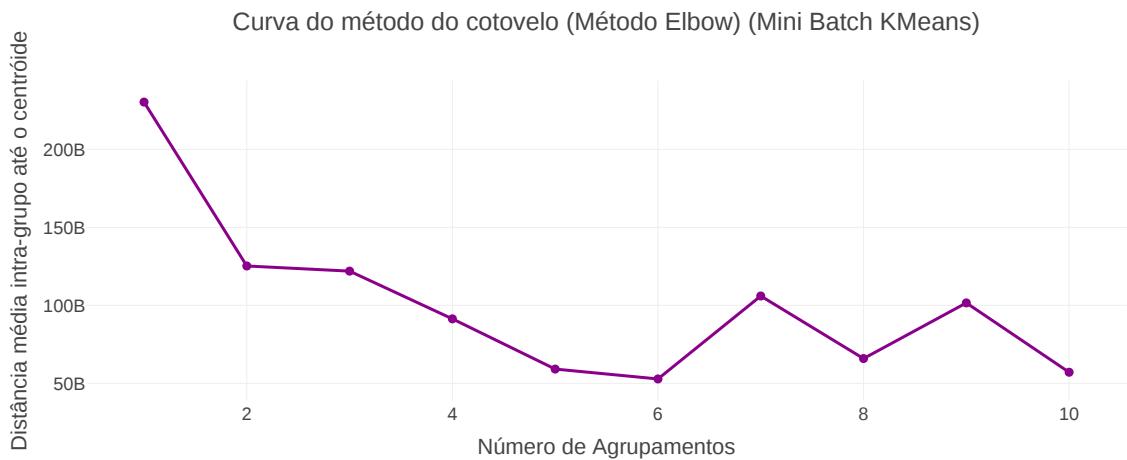


Fonte: Próprio autor (2024).

Na Figura 40 é mostrado o gráfico do Método do Cotovelo. Observando o gráfico da curva do Método do Cotovelo, percebe-se que a curva se nivelou inicialmente no ponto onde se indica 2 grupos. Este ponto é bastante relevante e pode ser apontado pelo método como o número de grupos escolhido. No entanto, há uma curva secundária que pode indicar um ponto onde o ganho adicional, em termos da métrica de avaliação, é novamente significativo. Isso pode sugerir uma estrutura mais fina ou detalhada nos dados que não foi capturada pelo número inicial de clusters. Esse segundo ponto pode ser apontado com o número de 5 grupos. O Método do Cotovelo é uma técnica visual que ajuda a identificar o número ideal de clusters ao buscar o ponto onde a diminuição da soma dos erros quadráticos internos começa a desacelerar. Assim, este método fornece uma forma intuitiva de escolher o número adequado de clusters ao analisar a relação entre o número de clusters e a soma dos erros quadráticos internos. Inicialmente a inclinação da curva no gráfico da Figura 40 sugere a formação de 2 grupos. No entanto, percebe-se que há uma nova inclinação significativa, sugerindo a geração de 5 grupos.

Na Figura 41 são mostrados os grupos formados pelo algoritmo Mini Batch K-Médias. Do ponto de vista do autor, essa foi a melhor divisão obtida entre os algoritmos de agrupamento utilizados. O motivo é que o Mini Batch K-Médias conseguiu separar as unidades consumidoras por níveis de consumo médio de maneira eficiente. Esta escolha é particularmente apropriada devido à capacidade do Mini Batch K-Médias de lidar com grandes conjuntos de dados, tornando o processo de clusterização mais rápido e escalável. Além disso, o uso de mini-batches aleatórios permite que o algoritmo faça atualizações frequentes e precisas dos centroides,

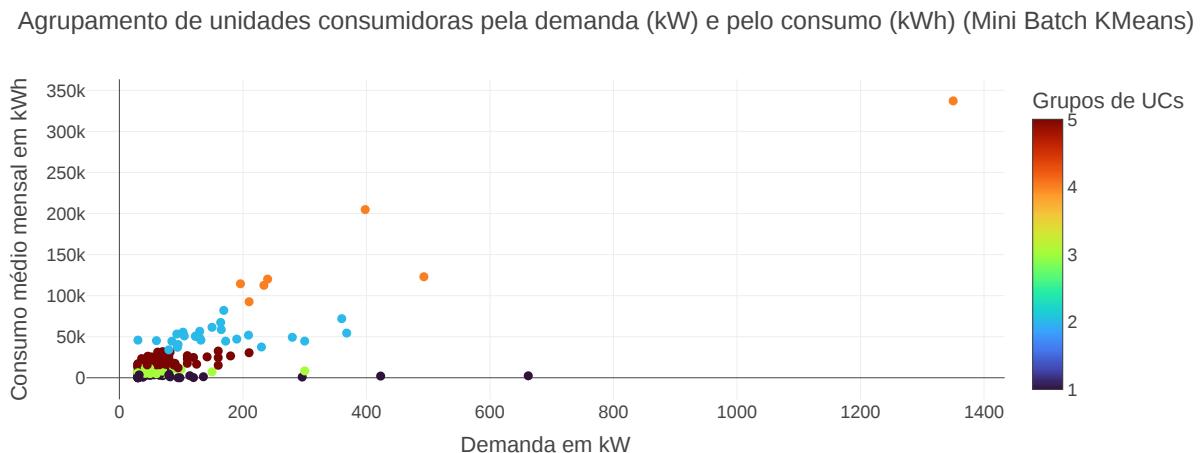
Figura 40 – Gráfico dos valores do Método do Cotovelo variando de 2 a 10 grupos.



Fonte: Próprio autor (2024).

garantindo uma melhor definição dos clusters. Como resultado, clientes de energia que estão consumindo um valor médio mensal que não condiz com suas demandas contratadas podem ser identificados, e os seus valores de demanda contratada podem ser ajustados de forma mais precisa. Pode-se observar que o algoritmo conseguiu agrupar clientes com consumo baixíssimo e demandas contratadas muito altas em um mesmo grupo, assim como separar clientes cujas demandas já estão ajustadas de acordo com seus níveis de consumo. Dessa forma, o Mini Batch K-Médias se mostra uma ferramenta eficaz para a análise de consumo de energia, proporcionando uma separação clara e eficiente dos grupos com base nos níveis de consumo médio e de demanda contratada.

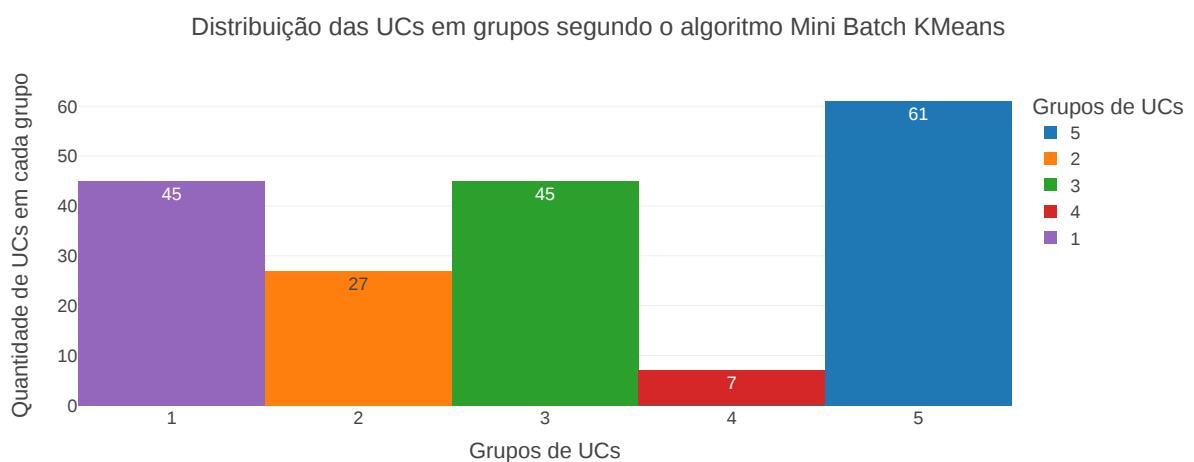
Figura 41 – Agrupamento de unidades consumidoras pela demanda (kW) e pelo consumo médio (kWh) com a utilização do Mini Batch K-Médias.



Fonte: Próprio autor (2024).

Na Figura 42 é mostrada a quantidade de clientes distribuídos entre cinco grupos, conforme a separação feita pelo Mini Batch K-Médias. Os grupos de 1 a 5 contêm 45, 27, 45, 7 e 61 unidades consumidoras, respectivamente, totalizando 185 unidades agrupadas.

Figura 42 – Quantidade de unidades consumidoras separadas pelo Mini Batch K-Médias em cada um dos cinco grupos escolhidos.



Fonte: Próprio autor (2024).

4.3 Agrupamento de séries temporais do consumo de energia de unidades consumidoras

Nesta seção, será empregada a abordagem de agrupamento das séries temporais do consumo de energia de unidades consumidoras públicas do estado do Ceará com o intuito de encontrar padrões, como tendência e sazonalidade. Além da possibilidade de identificar anomalias, agrupar unidades conforme o comportamento de suas curvas de consumo, identificar comportamentos atípicos em relação ao comportamento regular de unidades de um determinado grupo e a possibilidade de agrupar unidades com comportamento regular, ou seja, unidades cuja curva de consumo mantém um padrão de repetição anual, pois podem servir de base para unidades consumidoras implantadas mais recentemente e novas unidades. O motivo é que, conhecendo-se a demanda contratada ideal dos clientes já estabilizados e com demandas bem definidas para seus respectivos níveis de consumo, pode-se adotar uma demanda contratada mais condizente com o perfil de consumo dos clientes mais novos, baseada em como se comporta o consumo de energia dos clientes mais antigos e o nível real de demanda contratada que necessitam com base em seus consumos a fim de evitar custos desnecessários e demandas contratadas muito além do que os clientes realmente necessitam. Dentre as séries temporais analisadas, a predominância é

de unidades consumidoras da CAGECE e, em segundo lugar, órgãos da Justiça, como tribunais. Ressalta-se que as séries temporais foram normalizadas para terem magnitudes em uma mesma escala, pois em suas escalas reais, há séries com consumo bem baixo, por exemplo, 30 kW, e outros com consumo mais alto, com 500 kW contratados, a título de exemplo. Logo, as escalas não coincidiriam, mesmo que tenham o mesmo comportamento, e como nessa técnica o intuito é encontrar os padrões nas séries temporais, ou seja, o algoritmo irá observar como é a curva de consumo, verificando pontos de subida e descida, picos de consumo, etc., a normalização das séries temporais é adequada.

Foram testados os mesmos algoritmos da seção anterior: Agrupamento Hierárquico, BIRCH, K-Médias e Mini Batch K-Médias. O algoritmo que obteve melhores resultados foi o BIRCH. Ele conseguiu separar melhor as séries temporais de acordo com os seus respectivos grupos pertencentes e identificar unidades que deveriam apresentar um comportamento semelhante ao grupo ao qual pertencem, mas fogem do padrão, por algum motivo, como anomalias no consumo. Na Tabela 2, são mostrados os resultados das métricas Coeficiente de Silhueta, Calinski-Harabasz e Davies-Bouldin para o algoritmo BIRCH aplicado de 2 a 10 clusters. As métricas forneceram valores diferentes quando aplicados os algoritmos sem técnicas de redução de dimensionalidade, como PCA e t-NSE, ou Autoencoders, mas os resultados não diferiram significativamente. Na Tabela 2 são mostrados os resultados das métricas para o algoritmo BIRCH sem utilização das técnicas mencionadas.

Tabela 2 – BIRCH

Número de Clusters	Coeficiente de Silhueta	Calinski-Harabasz	Davies-Bouldin
2	0.187640	47.082328	1.487384
3	0.160117	30.768028	2.979967
4	0.159580	23.948689	3.081799
5	0.142426	19.784455	3.038526
6	0.141425	17.251193	2.847763
7	0.142475	15.446779	2.791187
8	0.139062	14.059773	2.762656
9	0.143186	12.981095	2.718379
10	0.068455	12.105286	2.713521

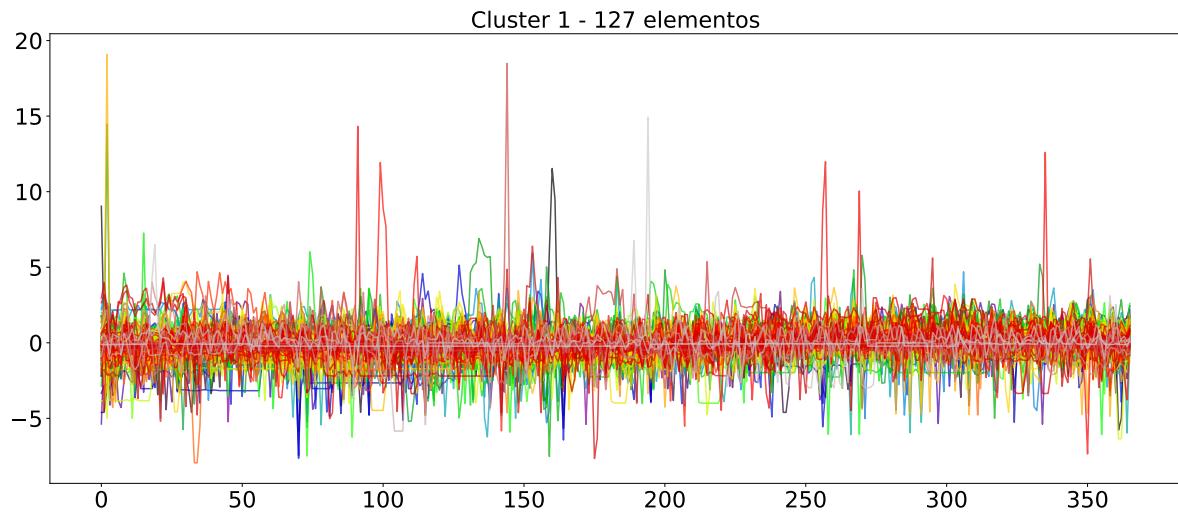
Fonte: Próprio autor (2025).

Na Figura 43 é mostrado o agrupamento 1, que contém 127 unidades consumidoras de um total de 183 séries temporais agrupadas. A maioria das unidades pertencem à CAGECE, com algumas unidades da COGERH e outras da Secretaria de Saúde. Neste agrupamento,

observou-se uma boa precisão, mas como foram escolhidos apenas dois grupos, não houve um detalhamento maior. Por exemplo, unidades que apresentam picos aleatórios de consumo não foram separadas em um grupo específico. As séries temporais do Cluster 1 foram normalizadas, o que significa que os valores foram ajustados para uma mesma escala, permitindo a comparação direta entre diferentes unidades consumidoras, independentemente de suas quantidades absolutas de consumo. No eixo x, é representada a quantidade de dias, já no eixo y é mostrado o consumo diário normalizado. A figura revela uma grande variabilidade no consumo ao longo do tempo. Muitas séries apresentam flutuações frequentes e picos de consumo, indicando uma natureza bastante imprevisível. Há picos de consumo bastante altos em intervalos irregulares, mesmo após a normalização. Isso sugere que algumas unidades consumidoras têm eventos esporádicos que causam aumentos significativos no consumo de energia, indicativos de atividades ou eventos não regulares. A sobreposição de várias séries temporais, cada uma com padrões distintos de consumo, sugere que as unidades consumidoras no cluster têm perfis de uso de energia muito variados. Algumas unidades podem ter consumo constante com picos ocasionais, enquanto outras podem ter um padrão mais caótico. A variabilidade observada ao longo dos dias indica que o consumo não segue um padrão diário consistente, mas é afetado por fatores que variam com o tempo. Este comportamento torna a previsão do consumo energético um desafio. A alta variabilidade e os picos aleatórios dificultam a previsão precisa do consumo de energia para essas unidades, complicando o planejamento e a otimização do fornecimento de energia. Em resumo, o Cluster 1 é caracterizado por um consumo de energia altamente variável e imprevisível ao longo dos dias, com picos frequentes apesar da normalização das séries temporais. É crucial identificar e tratar as unidades com consumo irregular para contribuir efetivamente na gestão de energia. A clusterização de séries temporais é uma ferramenta importante para encontrar essas unidades anômalas. Conhecer os padrões de consumo ajuda no planejamento de demandas futuras e na alocação de recursos de maneira mais eficaz. Unidades com consumo irregular podem ser previstas e monitoradas mais de perto para evitar surpresas. Reduzir picos de consumo pode resultar em custos operacionais mais baixos, já que muitas vezes os picos são mais caros devido à necessidade de capacidade adicional de fornecimento. A clusterização de séries temporais permite encontrar essas unidades anômalas, facilitando a aplicação de estratégias específicas para melhorar a eficiência e reduzir custos.

Na Figura 44 é mostrado o agrupamento 2 com 56 unidades consumidoras. Os clientes agrupados no Cluster 2 são predominantemente órgãos da Justiça, como tribunais e

Figura 43 – Agrupamento 1 das séries temporais do consumo de energia de unidades públicas.



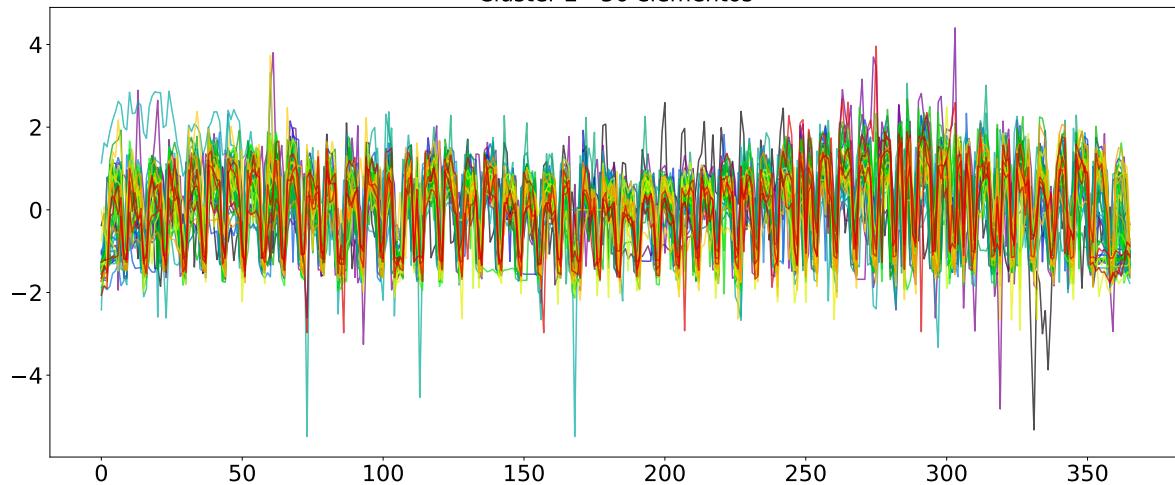
Fonte: Próprio autor (2024).

secretarias de justiça, além de unidades da Secretaria de Saúde. Pode-se observar um padrão de comportamento das séries temporais agrupadas, caracterizado por um comportamento relativamente constante de consumo ao longo do ano, com uma redução de consumo no terceiro trimestre e, posteriormente, um aumento para o nível de consumo anterior. As séries temporais no Cluster 2 exibem um comportamento de consumo de energia relativamente constante ao longo do tempo, com menos variabilidade e picos aleatórios comparados ao Cluster 1. Este padrão sugere uma rotina operacional estável para a maioria das unidades consumidoras nesse agrupamento. Observa-se uma redução no consumo de energia durante o terceiro trimestre do ano. Esse comportamento pode ser atribuído a fatores sazonais, como férias judiciais ou redução de atividades em determinados períodos do ano. Após a redução observada no terceiro trimestre, há um retorno ao nível de consumo anterior, indicando que a redução é temporária e seguida pela retomada das atividades normais. A maioria das unidades consumidoras neste cluster pertence a órgãos da Justiça e unidades da Secretaria de Saúde. Estes órgãos, por sua natureza, podem ter horários de funcionamento e demandas energéticas mais previsíveis e regimentadas, o que se reflete na constância do consumo de energia. Identificar e analisar os padrões de consumo de energia em diferentes clusters é essencial para a gestão eficiente da energia. A clusterização de séries temporais permite encontrar unidades anômalas e padrões específicos de consumo que podem ser tratados de maneira direcionada. Conhecer os padrões de consumo ajuda a implementar medidas que aumentem a eficiência energética, reduzindo desperdícios e melhorando o uso dos recursos. Compreender os comportamentos sazonais e padrões constantes permite um melhor planejamento das demandas energéticas e a alocação de recursos. A identificação de períodos de

consumo reduzido pode ser aproveitada para realizar manutenções ou implementar estratégias de economia de energia. Em resumo, o Cluster 2 é caracterizado por um consumo de energia constante ao longo do tempo, com uma redução sazonal no terceiro trimestre, seguida por um retorno ao consumo anterior. A predominância de órgãos da Justiça e unidades da Secretaria de Saúde reflete padrões de uso energético mais previsíveis. A identificação e análise desses padrões são cruciais para uma gestão energética eficiente.

Figura 44 – Agrupamento 2 das séries temporais do consumo de energia de unidades públicas.

Cluster 2 - 56 elementos



Fonte: Próprio autor (2024).

A Tabela 3 mostra os resultados do algoritmo BIRCH aplicado juntamente com o PCA para redução de dimensionalidade. O PCA assume relações lineares entre as variáveis, sendo eficiente para grandes conjuntos de dados e para redução de dimensionalidade em dados onde relações lineares são uma boa aproximação, ou seja, onde as relações entre as variáveis podem ser adequadamente modeladas como lineares. Observando as métricas, pode-se ver que se forem citados os dois melhores valores das métricas da Tabela 3, o Coeficiente de Silhueta sugere entre 3 ou 4 clusters, o índice de Calinski-Harabasz sugere 9 ou 10 clusters, e o índice de Davies-Bouldin sugere 6 ou 10 clusters. Os melhores valores para o Coeficiente de Silhueta são encontrados para 3 clusters (0.607549) e 4 clusters (0.600266). Isso sugere que, do ponto de vista da coesão e separação, 3 ou 4 clusters formam agrupamentos bem definidos. Os melhores valores para o índice de Calinski-Harabasz são encontrados para 9 clusters (2261.681404) e 10 clusters (2172.358623). Isso sugere que, do ponto de vista da dispersão, 9 ou 10 clusters são mais adequados. Os melhores valores para o índice de Davies-Bouldin são encontrados para 10 clusters (0.442303) e 6 clusters (0.477002). Isso sugere que, do ponto de vista da relação entre

dispersão e separação, 6 ou 10 clusters são mais apropriados. Para uma decisão mais informada, é importante considerar o contexto específico da aplicação e os objetivos da análise. Além disso, a escolha pode ser influenciada pela interpretação prática dos resultados e pela facilidade de gerenciamento dos clusters identificados.

Tabela 3 – BIRCH com PCA

Número de Clusters	Coeficiente de Silhueta	Calinski-Harabasz	Davies-Bouldin
2	0.380810	175.811074	0.694424
3	0.607549	977.791181	0.489098
4	0.600266	1192.216334	0.505780
5	0.582791	1273.062210	0.479397
6	0.532916	1207.073037	0.477002
7	0.532417	1251.740203	0.482947
8	0.540401	1621.586450	0.487784
9	0.569276	2261.681404	0.485056
10	0.567210	2172.358623	0.442303

Fonte: Próprio autor (2025).

O PCA e o t-SNE podem ser utilizados de forma complementar. O t-SNE, uma técnica de redução de dimensionalidade não linear, revela estruturas mais complexas e detalhadas, bem como agrupamentos que podem não ser perceptíveis em dimensões mais elevadas. Portanto, a combinação do PCA com o t-SNE aproveita as vantagens de ambas as técnicas para obter uma representação eficaz dos dados. Enquanto o PCA é mais rápido e capaz de capturar padrões lineares, o t-SNE observa relações não lineares. Essa combinação é útil quando se dispõe de conjuntos de dados de alta dimensionalidade e busca-se visualizar as relações entre os dados de maneira mais interpretável, ou seja, quando se procura mais clareza nas relações entre os pontos de dados. Na Tabela 4, , são apresentados os resultados das métricas utilizadas com a aplicação de PCA e t-SNE. O t-SNE visa preservar as relações de similaridade locais, ou seja, pontos que são semelhantes entre si nos dados originais permanecerão próximos no espaço de menor dimensão. Isso é particularmente útil para a visualização e identificação de agrupamentos em dados que possam ter uma estrutura não linear ou que não são facilmente separados em dimensões mais globais. Na Tabela 4, os índices fornecem insights sobre o número ideal de clusters. O Coeficiente de Silhueta sugere que 2 ou 3 clusters podem ser apropriados, enquanto o índice de Calinski-Harabasz indica preferência por um maior número de clusters, especialmente 9 ou 10. Por outro lado, o índice de Davies-Bouldin sugere que 2 ou 10 clusters podem ser mais adequados.

Tabela 4 – BIRCH com PCA e t-NSE

Número de Clusters	Coeficiente de Silhueta	Calinski-Harabasz	Davies-Bouldin
2	0.741682	774.341743	0.274779
3	0.635834	1207.277522	0.422042
4	0.619548	1575.157586	0.490978
5	0.585608	1365.546347	0.404420
6	0.616791	1788.045735	0.406392
7	0.581036	1945.790813	0.468761
8	0.567094	2554.044482	0.458473
9	0.588326	3161.197123	0.452568
10	0.579684	3268.435303	0.397833

Fonte: Próprio autor (2025).

Os Autoencoders desempenham um papel crucial na extração de características e na identificação de representações latentes de dados. Em essência, eles oferecem uma descrição das características fundamentais e abstratas presentes nos dados originais, como padrões e relações entre os dados. Essa representação latente é uma versão simplificada e compacta que mantém as informações essenciais dos dados originais. A utilização da representação latente gerada pelos Autoencoders é aplicável em diversas tarefas, tais como agrupamento, detecção de padrões, análise de tendências, sazonalidade e detecção de anomalias em séries temporais. Na Tabela 5 são mostrados os resultados das métricas obtidas ao empregar o algoritmo BIRCH em conjunto com as técnicas de PCA e Autoencoders. Ao analisar os resultados obtidos ao empregar PCA em conjunto com Autoencoders no algoritmo BIRCH, observa-se um desempenho aprimorado em comparação com as aplicações anteriores. Isso pode ser atribuído à combinação das capacidades de redução de dimensionalidade oferecidas pelo PCA e à capacidade dos Autoencoders de extrair características e representações latentes dos dados. Ao utilizar apenas o algoritmo de cluster sem técnicas adicionais, a análise pode ser limitada pela alta dimensionalidade dos dados, o que pode dificultar a identificação de padrões e relações significativas. A introdução do PCA permite uma redução eficiente da dimensionalidade, simplificando a complexidade dos dados e facilitando a identificação de agrupamentos. No entanto, ao adicionar o t-SNE à análise, embora essa técnica seja eficaz na preservação de estruturas não lineares e na visualização de agrupamentos em espaços de menor dimensão, ela pode não capturar completamente as relações complexas presentes nos dados originais. Por outro lado, a inclusão dos Autoencoders oferece uma abordagem mais holística, pois não só reduz a dimensionalidade dos dados, como também extrai características importantes e abstratas por meio da representação latente. Essas representações latentes podem conter informações mais ricas e significativas sobre os dados.

originais, contribuindo para uma melhor separação dos clusters e uma interpretação mais precisa dos resultados. Portanto, a combinação de PCA com Autoencoders demonstra ser uma estratégia eficaz na análise de dados de alta dimensionalidade, proporcionando uma representação mais informativa e facilitando a identificação de padrões e relações intrínsecas nos dados.

Em resumo, os resultados indicam que o algoritmo BIRCH com PCA e Autoencoders é capaz de gerar agrupamentos bem definidos e separados. Isso sugere que essa combinação de técnicas é eficaz na análise e interpretação de conjuntos de dados complexos.

Tabela 5 – BIRCH com PCA e Autoencoders

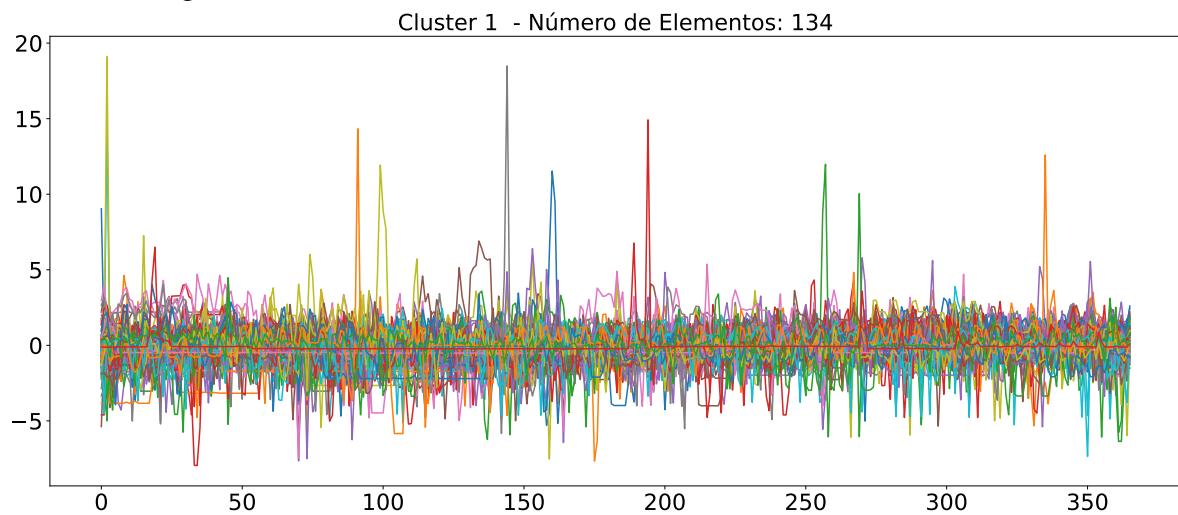
Número de Clusters	Coeficiente de Silhueta	Calinski-Harabasz	Davies-Bouldin
2	0.844872	1981.132244	0.181829
3	0.714235	2032.085225	0.331411
4	0.668226	1653.172040	0.474404
5	0.626381	3024.639541	0.512553
6	0.608150	2701.368835	0.531902
7	0.582965	2469.032070	0.465158
8	0.539459	2567.657588	0.467951
9	0.551788	3612.923941	0.471712
10	0.547103	3385.955072	0.443839

Fonte: Próprio autor (2025).

Na Figura 45, observa-se o agrupamento 1, que inclui 134 unidades consumidoras dentre as 183 séries temporais analisadas. Este agrupamento foi realizado utilizando o algoritmo BIRCH, em combinação com PCA e Autoencoders. A maioria das unidades agrupadas pertence à CAGECE, com algumas unidades da COGERH e algumas pertencentes à Secretaria de Saúde. O perfil de consumo de energia dentro deste grupo apresenta uma natureza aleatória, com variações significativas ao longo do tempo. Este comportamento indica que os padrões de consumo das unidades consumidoras são bastante diversificados, misturando séries que possuem grandes flutuações com aquelas que mantêm um perfil mais constante e estável. A diversidade nas séries temporais dentro deste agrupamento sugere que, apesar de estarem no mesmo cluster, as unidades consumidoras possuem características de consumo distintas. As séries temporais com variações acentuadas podem estar associadas a unidades consumidoras com atividades intermitentes ou sazonais, enquanto as séries mais constantes refletem unidades com consumo de energia mais previsível e regular.

Na Figura 46, observa-se o agrupamento 2, que inclui 49 unidades consumidoras. Este agrupamento foi realizado utilizando o algoritmo BIRCH, em combinação com PCA e

Figura 45 – Agrupamento 1 das séries temporais do consumo de energia de unidades públicas, utilizando o algoritmo BIRCH com PCA e Autoencoders, com 134 unidades consumidoras.

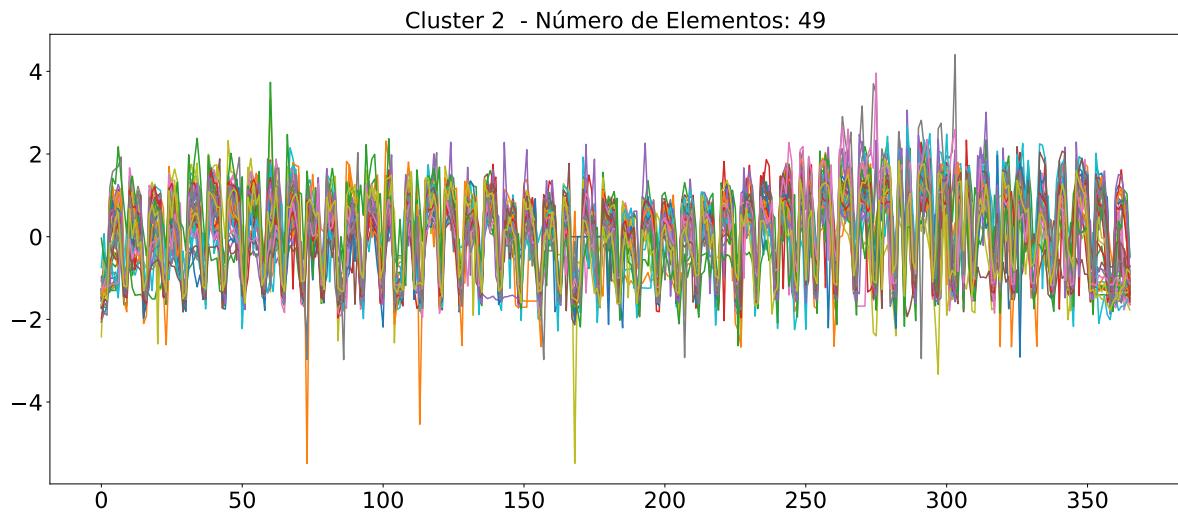


Fonte: Próprio autor (2024).

Autoencoders. Os clientes agrupados no cluster 2 são predominantemente órgãos da Justiça, como tribunais e secretarias de justiça, além de unidades da Secretaria de Saúde e algumas unidades do Corpo de Bombeiros. O perfil de consumo de energia dentro deste grupo mostra um comportamento relativamente mais estável comparado ao cluster 1, mas ainda apresenta variações significativas. A presença de órgãos da Justiça e unidades de saúde indica que essas unidades possuem um padrão de consumo energético que, embora variado, tende a ser mais previsível devido à natureza de suas operações. As séries temporais neste agrupamento mostram variações cíclicas e uma certa regularidade, refletindo as operações contínuas e rotineiras dessas instituições. No entanto, algumas séries apresentam flutuações que podem estar associadas a eventos específicos ou variações na demanda operacional. Essa análise é importante para identificar e entender os diferentes perfis de consumo de energia, permitindo o desenvolvimento de estratégias de gerenciamento de demanda mais precisas e eficientes, especialmente para órgãos públicos com diferentes necessidades energéticas.

A análise dos clusters 1 e 2 destaca a necessidade de formar mais grupos além desses dois. A criação de outros clusters pode revelar padrões específicos de subgrupos que ainda não foram identificados, permitindo uma compreensão mais detalhada dos perfis de consumo energético. Essa abordagem pode identificar padrões anômalos e fornecer insights importantes que seriam mascarados em uma análise menos granular. Por exemplo, ao dividir os dados em mais clusters, pode-se descobrir que certas unidades da saúde têm padrões de consumo significativamente diferentes em relação a outros hospitais ou clínicas, devido a diferenças nas

Figura 46 – Agrupamento 2 das séries temporais do consumo de energia de unidades públicas, utilizando o algoritmo BIRCH com PCA e Autoencoders, com 49 unidades consumidoras.



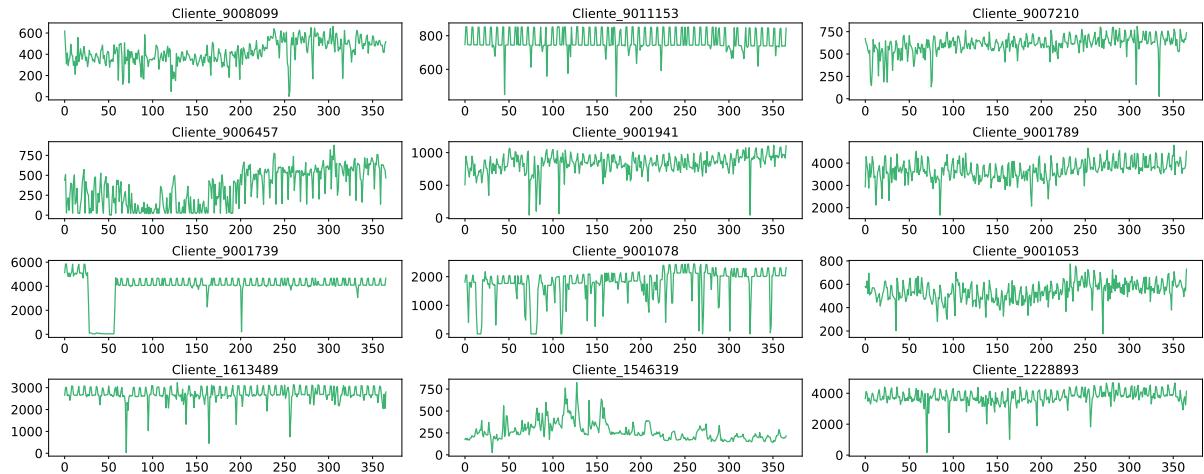
Fonte: Próprio autor (2024).

operações ou na demanda de energia em certos períodos. Da mesma forma, outros órgãos da Justiça podem apresentar padrões específicos que variam de acordo com suas atividades judiciais ou administrativas. Além disso, a criação de mais clusters pode facilitar a identificação de anomalias no consumo de energia. Padrões anômalos, que podem indicar problemas como desperdício de energia, falhas no equipamento, ou comportamentos operacionais incomuns, são mais facilmente detectados quando os dados são divididos em grupos mais homogêneos. Detectar essas anomalias é crucial para a manutenção preventiva e para a implementação de estratégias de eficiência energética.

Na Figura 47 são mostradas 12 séries temporais de consumo de clientes do grupo 1. As séries estão na escala de valores reais. Observa-se que as séries temporais apresentadas exibem um padrão de consumo bastante variado e, em muitos casos, irregular. Existem flutuações significativas no consumo ao longo do tempo para diferentes clientes. Alguns clientes, como os identificados pelos códigos 9001739 e 1546319, mostram picos e quedas acentuadas, indicando períodos de alta demanda seguidos por reduções bruscas. As séries temporais demonstram que o consumo de energia neste grupo é altamente variável e, em muitos casos, aleatório. Essa variabilidade pode ser resultado de diferentes fatores, como atividades sazonais, operações intermitentes, ou mudanças na demanda operacional. A identificação de padrões de consumo permite a implementação de medidas para melhorar a eficiência energética, reduzindo desperdícios. Compreender a variabilidade do consumo ajuda no planejamento adequado dos recursos e na previsão de demandas futuras. Unidades com consumo irregular podem ser alvo de intervenções

específicas para estabilizar e otimizar o uso de energia, resultando em economia de custos. Em resumo, a análise das séries temporais do grupo 1 revela um consumo de energia altamente variável e, em muitos casos, aleatório. Essa variabilidade destaca a importância da clusterização como ferramenta para identificar padrões e anomalias, possibilitando a implementação de estratégias de gestão energética mais eficientes e sustentáveis.

Figura 47 – Séries temporais do consumo de energia de clientes pertencentes ao grupo 1.

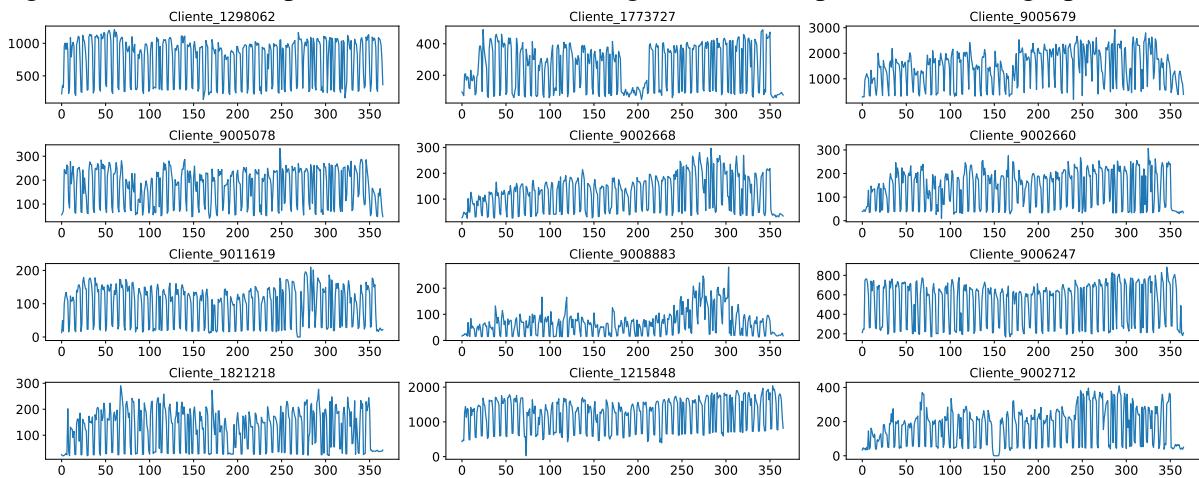


Fonte: Próprio autor (2024).

Na Figura 48 são mostradas 12 séries temporais de consumo de clientes do grupo 2. As séries estão na escala de valores reais. As séries temporais apresentadas exibem um padrão de consumo mais constante e regular ao longo do tempo, comparado com o grupo 1. Observa-se uma menor variabilidade nos dados, com picos de consumo ocorrendo em intervalos regulares. A maioria dos clientes apresenta um consumo cíclico diário, típico de operações que seguem uma rotina fixa. Um comportamento notável nas séries temporais do grupo 2 é a redução de consumo observada durante o terceiro trimestre do ano, seguida por uma recuperação para níveis anteriores. Conhecer os padrões de consumo permite a implementação de estratégias de otimização, como a negociação de contratos de energia que refletem o perfil de consumo dos clientes. Com padrões de consumo claramente identificados, é possível introduzir medidas de eficiência energética mais eficazes, como a instalação de sistemas de automação que ajustem o consumo com base nas necessidades reais.

Padrões distintos de consumo podem ser observados em ambos os agrupamentos, evidenciando a eficácia da técnica de agrupamento da série temporal completa de uma unidade consumidora. Esta abordagem, que considera não apenas uma representação singular da unidade,

Figura 48 – Sériess temporais do consumo de energia de clientes pertencentes ao grupo 2.



Fonte: Próprio autor (2024).

mas a totalidade de seus dados ao longo do tempo, permite a identificação não apenas de pontos anômalos, mas também de padrões distintivos, como tendências e sazonalidades. Ademais, oferece informações abrangentes sobre os níveis de consumo das unidades ao longo do ano, o que pode ser instrumental na gestão da demanda, especialmente ao se basear no consumo de unidades com séries temporais consolidadas e padrões recorrentes dentro de um determinado grupo. As unidades caracterizadas por um consumo estável e previsível podem servir como um modelo representativo do comportamento do grupo em questão. Portanto, compreender a dinâmica de consumo de clientes específicos ao longo do ano possibilita a definição precisa da demanda necessária.

O coeficiente de correlação de Pearson desempenha um papel crucial na análise dos padrões de consumo de energia das unidades consumidoras. Por meio deste coeficiente, é possível determinar se existe uma relação linear entre as séries temporais de consumo de energia, permitindo a identificação de tendências comuns ou padrões de comportamento relacionados ao consumo de energia. Um coeficiente próximo de 1 sugere uma forte correlação positiva, indicando padrões de consumo de energia semelhantes entre as unidades consumidoras. Por outro lado, um valor próximo de -1 denota uma forte correlação negativa, sugerindo padrões opostos de consumo. Valores próximos de zero indicam uma correlação fraca. A análise da correlação entre as séries temporais permite identificar unidades que compartilham características similares em termos de consumo de energia, o que pode ser fundamental para o desenvolvimento e implementação de estratégias eficazes de gerenciamento de energia. Além disso, essa análise pode revelar padrões temporais nas séries, indicando se as variáveis têm tendências similares,

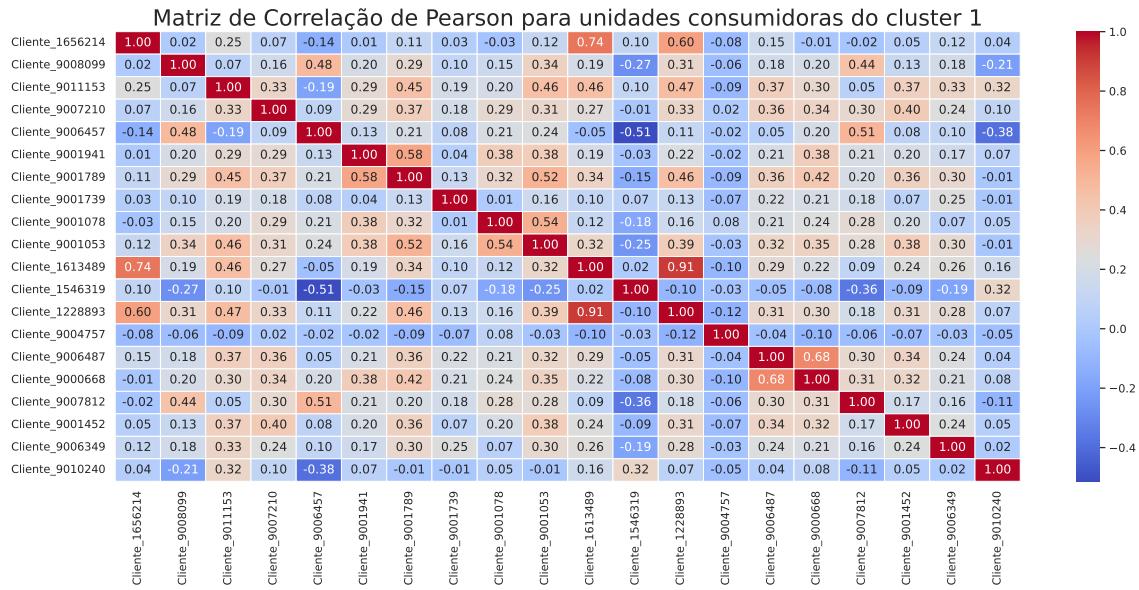
inversas ou independentes ao longo do tempo. As correlações também podem auxiliar na detecção de padrões sazonais nas séries temporais, como ciclos recorrentes ao longo do tempo. Na Figura 49 é apresentada a correlação de Pearson para 20 séries temporais do grupo 1, composto por 20 unidades da CAGECE.

Algumas séries temporais apresentam fortes correlações positivas, como é o caso entre os clientes 1656214 e 1613489 (correlação de 0.74). Isso sugere que essas unidades consumidoras possuem padrões de consumo de energia bastante similares ao longo do tempo. Outra correlação notável é entre os clientes 1613489 e 1228893 (correlação de 0.91), indicando uma forte semelhança nos seus comportamentos de consumo. Existem também várias correlações fracas ou até negativas entre algumas séries temporais. Por exemplo, a correlação entre os clientes 1546319 e 9009141 é de -0.27, sugerindo que os padrões de consumo dessas unidades são relativamente desassociados.

A matriz de correlação ajuda a identificar subgrupos de unidades consumidoras com padrões de consumo similares. Por exemplo, cliente 900668, cliente 900647, e cliente 900812 formam um subgrupo com correlações positivas significativas entre si. Esses subgrupos podem ser úteis para a segmentação de estratégias de gestão de energia, permitindo intervenções mais direcionadas e eficientes. Compreender as correlações entre as séries temporais permite identificar padrões comuns de consumo, o que é crucial para a previsão de demanda e planejamento energético. Correlações anômalas (extremamente altas ou baixas) podem indicar problemas ou oportunidades para otimização. Agrupar unidades com padrões de consumo similares permite implementar medidas de eficiência energética mais precisas. Unidades com fortes correlações positivas podem compartilhar estratégias de gerenciamento de energia com maior eficácia. Em resumo, a análise da matriz de correlação de Pearson para o cluster 1 revela importantes insights sobre os padrões de consumo de energia das unidades consumidoras, destacando tanto similaridades quanto divergências que podem ser exploradas, detectando unidades anômalas e realizando a gestão de demanda adequada.

Na Figura 50 é mostrada a matriz de coeficientes de correlação de Pearson para o grupo 2, que inclui unidades da Justiça, como tribunais, além de algumas secretarias de justiça. As correlações positivas no grupo 2 são significativamente maiores em comparação com os valores obtidos de correlação para o grupo 1. Se os dados exibem uma relação linear forte, o coeficiente de Pearson pode capturar essa relação de forma mais eficaz, resultando em uma correlação maior. O coeficiente de Pearson é sensível a outliers; mesmo com os dados

Figura 49 – Correlações de Pearson entre 20 séries temporais do consumo de energia de unidades consumidoras da CAGECE.

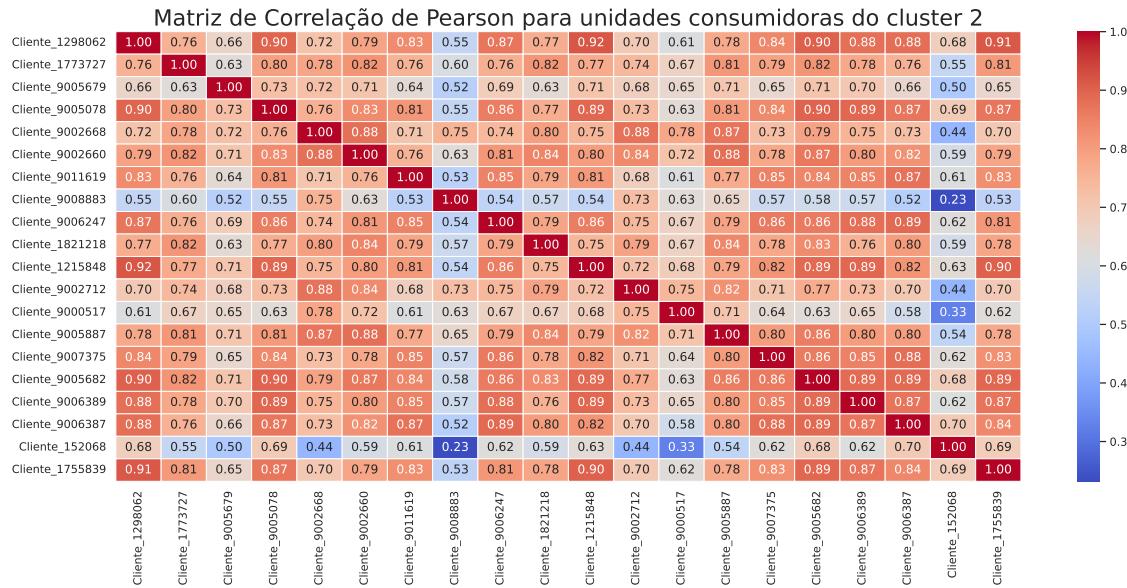


Fonte: Próprio autor (2024).

normalizados, podem existir valores extremos nas séries temporais, o que pode influenciar a estimativa da correlação. Isso acontece porque o coeficiente de Pearson é baseado na covariância e no desvio padrão das variáveis, que são sensíveis a valores extremos. Observa-se na matriz que a maioria das correlações entre as séries temporais das unidades consumidoras do grupo 2 é positiva e alta, indicando um padrão de consumo energético mais uniforme e sincronizado entre essas unidades. Essa consistência pode ser atribuída à natureza das operações judiciais, que seguem rotinas similares e, portanto, apresentam padrões de consumo mais alinhados. No entanto, a presença de algumas correlações mais baixas ou negativas sugere a existência de variações operacionais específicas ou outliers que afetam certos períodos de consumo. A análise dessas anomalias pode ser crucial para identificar comportamentos energéticos atípicos, possibilitando a implementação de medidas corretivas ou de eficiência energética mais eficazes. Para complementar esta análise e obter uma visão mais robusta das correlações, será utilizado também o coeficiente de Spearman. Este coeficiente é menos sensível a distribuições não lineares e a outliers, podendo fornecer insights adicionais sobre as relações entre as séries temporais que o coeficiente de Pearson pode não capturar completamente.

Na Figura 51 ,é mostrada a matriz de correlação de Spearman para as mesmas 20 séries temporais do grupo 1 usadas para calcular os coeficientes de Pearson. O coeficiente de Spearman é mais robusto em relação a outliers e não requer a suposição de uma distribuição normal nos dados, além de não assumir uma relação linear entre as variáveis. A diferença

Figura 50 – Correlações de Pearson entre 20 séries temporais do consumo de energia de unidades consumidoras de órgãos da Justiça.

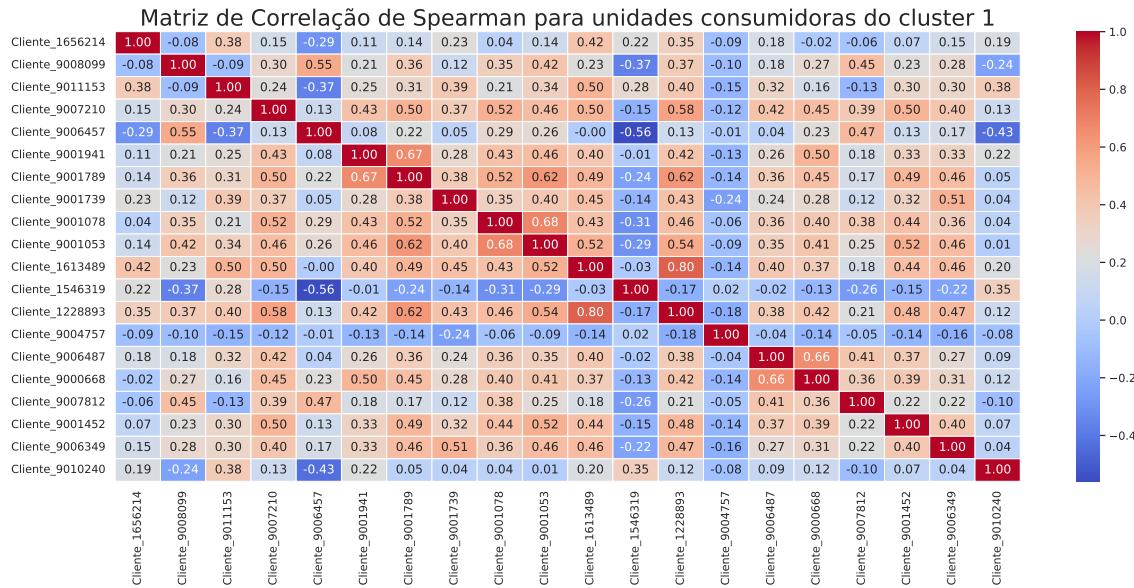


Fonte: Próprio autor (2024).

nos resultados entre o coeficiente de Spearman e o coeficiente de Pearson pode ocorrer devido às características dos dados, como relações lineares fortes ou fracas, presença de outliers, e forte ordem nos dados, com relações lineares ou não. A matriz de correlação de Spearman mostra que, embora existam algumas correlações positivas significativas entre certas séries temporais, muitas correlações são mais moderadas ou baixas. Isso sugere que, enquanto algumas unidades consumidoras da CAGECE podem ter padrões de consumo semelhantes, outras exibem variações que não são capturadas completamente por uma relação linear. A correlação de Spearman também revela a presença de relações não lineares e a influência de outliers menos pronunciada. Isso é importante para entender a complexidade dos padrões de consumo energético, especialmente em um contexto onde diferentes unidades podem operar de maneiras bastante distintas. O coeficiente de Spearman proporciona uma visão mais robusta e menos sensível a outliers das relações entre as séries temporais. As diferenças entre as matrizes destacam a importância de considerar múltiplas métricas de correlação para uma compreensão completa dos padrões de consumo. A utilização de Spearman, juntamente com Pearson, permite identificar tanto relações lineares fortes quanto padrões de ordens mais gerais, oferecendo uma análise mais completa e detalhada dos dados.

Na Figura 52 é mostrada a matriz de correlações de Spearman para 20 séries temporais de consumo de energia de unidades consumidoras de órgãos da Justiça. Se a relação entre as variáveis em uma série temporal for verdadeiramente linear, a correlação de Spearman

Figura 51 – Correlações de Spearman entre 20 séries temporais do consumo de energia de unidades consumidoras da CAGECE.



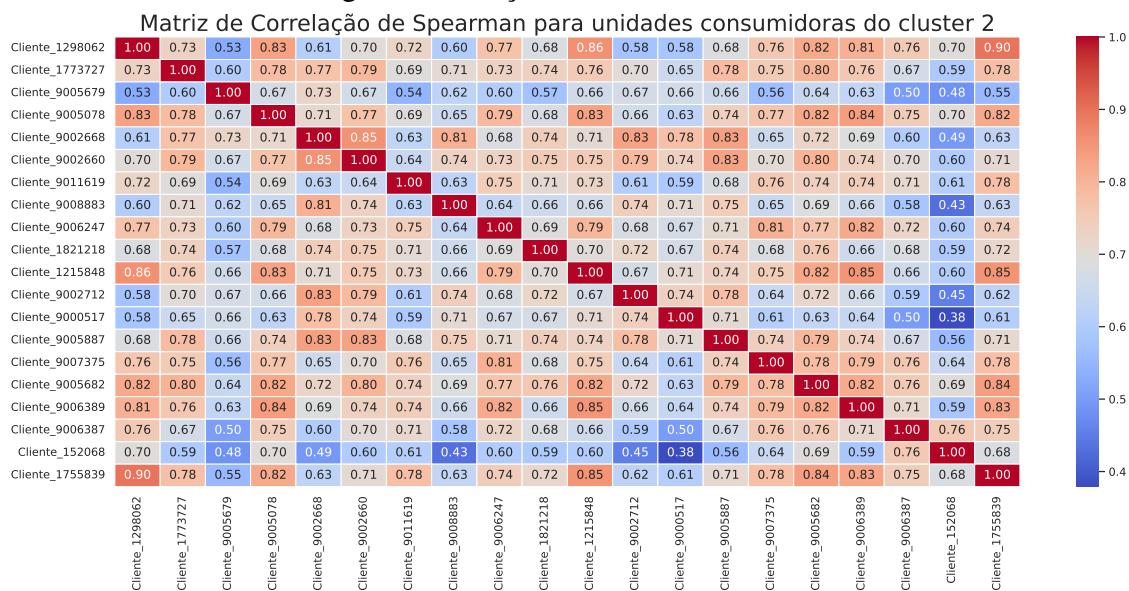
Fonte: Próprio autor (2024).

pode não ser tão sensível quanto a correlação de Pearson. A correlação de Spearman perde parte da informação original dos dados, especialmente em situações onde a relação é linear. Por outro lado, se a relação não for estritamente linear, a correlação de Pearson pode não capturar completamente a dependência entre as séries temporais. A correlação de Spearman avalia relações monotônicas, não necessariamente lineares. Portanto, é capaz de identificar padrões mais complexos nas séries temporais. A correlação de Spearman é mais robusta em relação a outliers. Isso é evidente na matriz, onde pode-se ver menos extremos comparados à matriz de Pearson, sugerindo que os outliers presentes nas séries temporais tiveram menos impacto. A análise das correlações de Spearman para o grupo 2 revela uma visão complementar à fornecida pelas correlações de Pearson. Enquanto Pearson é sensível a outliers e captura melhor relações lineares, Spearman é mais robusto e pode identificar relações monotônicas complexas. A matriz de Spearman mostra menos correlações extremas. Por exemplo, a correlação entre os clientes 1773727 e 1298062 é de 0,73, ligeiramente menor do que a obtida com Pearson. A matriz de Spearman revela correlações mais moderadas, indicando que os outliers têm menos impacto na análise. Spearman captura melhor as relações monotônicas. Observa-se várias correlações moderadas, como a entre os clientes 9002686 e 9002688 de 0,85, sugerindo uma ordem nas séries temporais que não é necessariamente linear. Há menos variação extrema em comparação com Pearson, o que sugere uma distribuição mais uniforme das correlações. Correlações que são muito altas em Pearson, como entre os clientes 1773727 e 1298062 de 0,76 em Pearson, são

mais moderadas em Spearman 0,73. Isso indica que, embora exista uma forte relação linear, a relação monotônica não é tão extrema. As correlações negativas significativas em Pearson, como entre os clientes 9006883 e 9005682 de -0,43, não aparecem em Spearman, onde a correlação é positiva 0,48. Isso demonstra que Spearman é menos sensível a outliers, suavizando essas relações extremas.

Através da análise das matrizes de correlação de Pearson e Spearman, pode-se obter informações sobre padrões anormais, como outliers, e relações fortes entre padrões de sazonalidade, tendência e comportamento semelhante da curva de consumo dos clientes. A divergência nos coeficientes de correlação pode indicar a presença de outliers nos dados, que são pontos discrepantes que se afastam do padrão geral dos dados. Por outro lado, a presença de relações lineares fortes nos coeficientes de correlação sugere uma forte associação entre os dados, indicando padrões de comportamento semelhantes entre os clientes. Além disso, a análise das correlações pode revelar relações de comportamento semelhante entre os clientes, destacando padrões de sazonalidade e tendência que podem ser úteis para prever o consumo futuro de energia elétrica e identificar segmentos de clientes com comportamentos similares, o que pode ajudar a prever a demanda de energia de novos clientes pertencentes a determinado grupo.

Figura 52 – Correlações de Spearman entre 20 séries temporais do consumo de energia de unidades consumidoras de órgãos da Justiça.

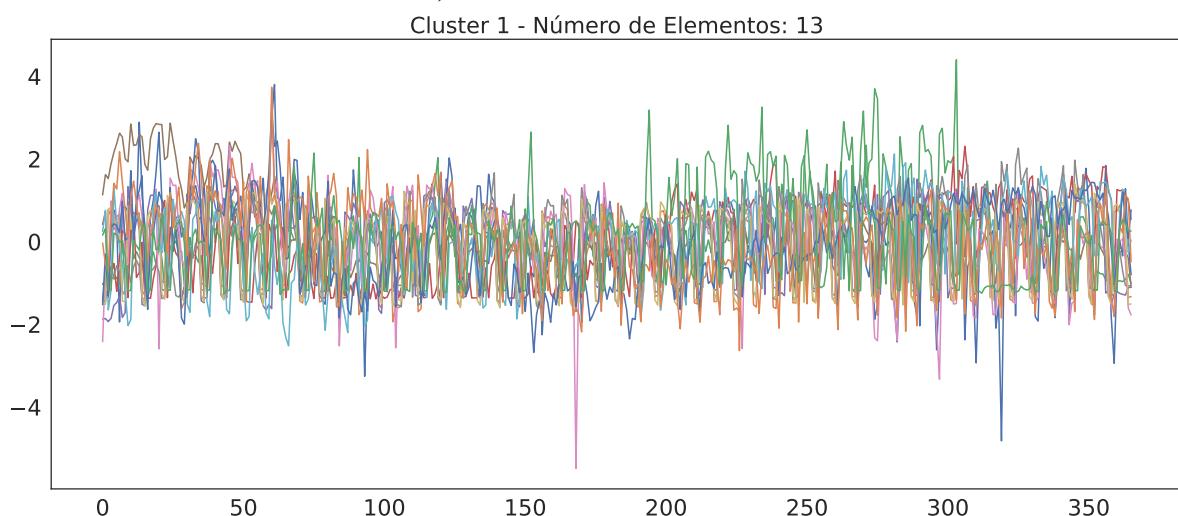


Fonte: Próprio autor (2024).

Como mencionado anteriormente, a clusterização pode auxiliar na identificação de padrões de consumo de energia semelhantes entre diferentes unidades consumidoras. Além disso,

permite a identificação de outliers, ou seja, padrões incomuns nas séries temporais, que podem indicar situações que requerem uma atenção mais específica e refinada. Para não apenas agrupar as séries temporais por padrões normalmente apresentados, mas também por características anômalas, as séries temporais estudadas foram separadas em quatro grupos. Na Figura 53, é apresentado o agrupamento 1, que contém 13 unidades consumidoras. A clusterização com um número maior de grupos pode revelar mais detalhes comparados a um número menor de grupos, em determinados casos. Séries temporais de diferentes secretarias, como Infraestrutura, Justiça, Saúde, Cidades, entre outras, podem ser agrupadas juntas dependendo do tipo de comportamento que apresentam. Isso ocorre porque é possível que suas curvas de consumo em estados normais funcionem de forma semelhante. Entretanto, também é possível que sejam agrupadas devido a anomalias encontradas de forma semelhante em seus consumos de energia. As séries temporais no Cluster 1 apresentam padrões de consumo bastante consistentes, com variações relativamente pequenas ao longo do ano. Isso sugere que as unidades consumidoras agrupadas têm um comportamento de consumo de energia estável. Embora existam picos esporádicos em algumas das séries temporais, a maioria das unidades mantém um nível de consumo uniforme. Esses picos podem indicar eventos específicos que demandaram um aumento temporário no uso de energia. A presença de unidades de diferentes secretarias no mesmo cluster indica que, apesar das diferenças funcionais, seus padrões de consumo de energia podem ser influenciados por fatores comuns, como políticas de eficiência energética, horários de funcionamento, e estrutura organizacional.

Figura 53 – Agrupamento 1 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 13 unidades consumidoras.

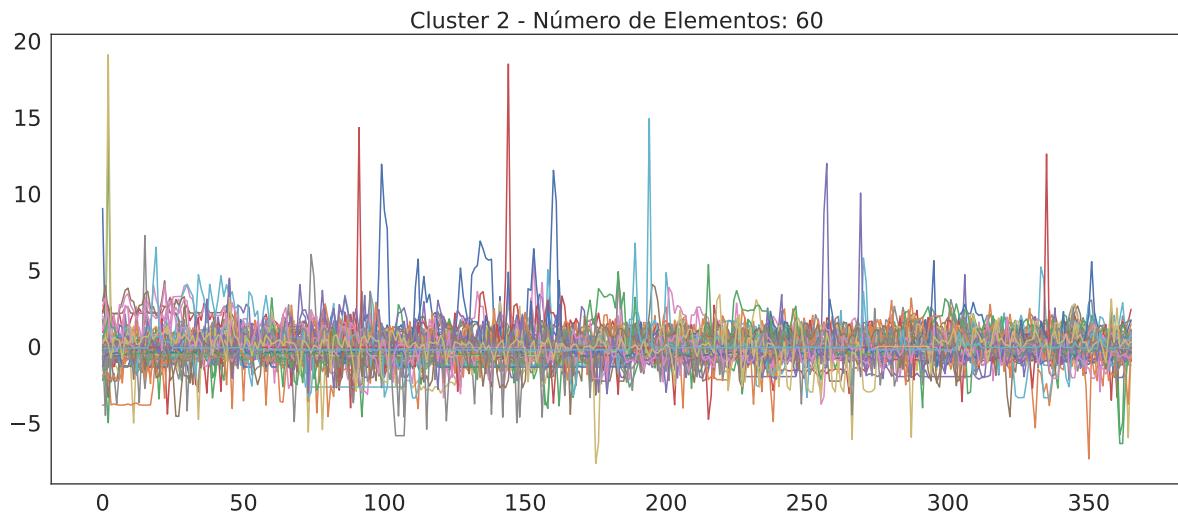


Fonte: Próprio autor (2024).

Na Figura 54 foram separadas 60 séries temporais no grupo 2. Observando o gráfico pode-se ver elevações súbitas de consumo nas séries temporais. São variações bruscas que não representam a curva de consumo padrão das unidades consumidoras. Os picos de consumo podem indicar problemas operacionais, por exemplo uma falha em um equipamento, mau funcionamento de sistemas, ou até mesmo interrupções no fornecimento de energia. O mau funcionamento de aparelhos ou equipamentos pode se manifestar como padrões incomuns nas séries temporais. A clusterização pode ajudar a isolar esses comportamentos anômalos para uma análise mais detalhada e identificação da causa. Outra possibilidade é que se uma unidade consumidora estiver envolvida em atividades fraudulentas, como manipulação de medidores ou desvio de eletricidade, isso pode se refletir em padrões de consumo atípicos. A clusterização pode destacar esses padrões fora do comum para uma investigação mais aprofundada. Além disso, o acionamento de várias cargas ao mesmo tempo pode gerar esses picos de consumo e por sua vez, picos de demanda, que podem influenciar no valor final da tarifa de energia por multas causadas através da ultrapassagem do valor permitido de ultrapassagem de demanda, que é 5% a mais do valor contratado. No grupo 2 dois também foram separadas séries temporais que estão com o consumo de energia bem baixo, próximo a zero. Esse método de clusterização de séries temporais é mais uma das metodologias utilizadas nesse trabalho, que combinadas podem fornecer informações relevantes e auxiliar na otimização da eficiência energética, escolha de demandas e modelos de tarifação adequados e identificação de irregularidades no consumo e na demanda elétrica. Em conclusão, a clusterização do Cluster 2 revela padrões de consumo com elevações súbitas, picos de demanda e períodos de baixo consumo. Identificar e isolar esses padrões anômalos é crucial para uma gestão mais eficiente do consumo de energia e para a implementação de medidas corretivas. A análise detalhada pode levar à identificação de causas específicas, como problemas operacionais, atividades fraudulentas, ou ineficiências no sistema.

Na Figura 55 é mostrado o agrupamento 3, que contém 46 unidades consumidoras. Este grupo demonstra uma notável linearidade, com um consumo de energia bastante constante ao longo do ano. Observa-se uma redução no consumo aproximadamente do final do segundo trimestre até o início do quarto trimestre. Posteriormente, o consumo retorna ao nível observado nos primeiros cinco meses do ano e, em alguns momentos, até supera ligeiramente esse patamar. A análise do gráfico revela que o comportamento de consumo das unidades do Cluster 3 é caracterizado por uma estabilidade relativa, intercalada por um período específico de redução. Essa consistência pode indicar operações regulares e bem geridas, com poucas variações ou anomalias

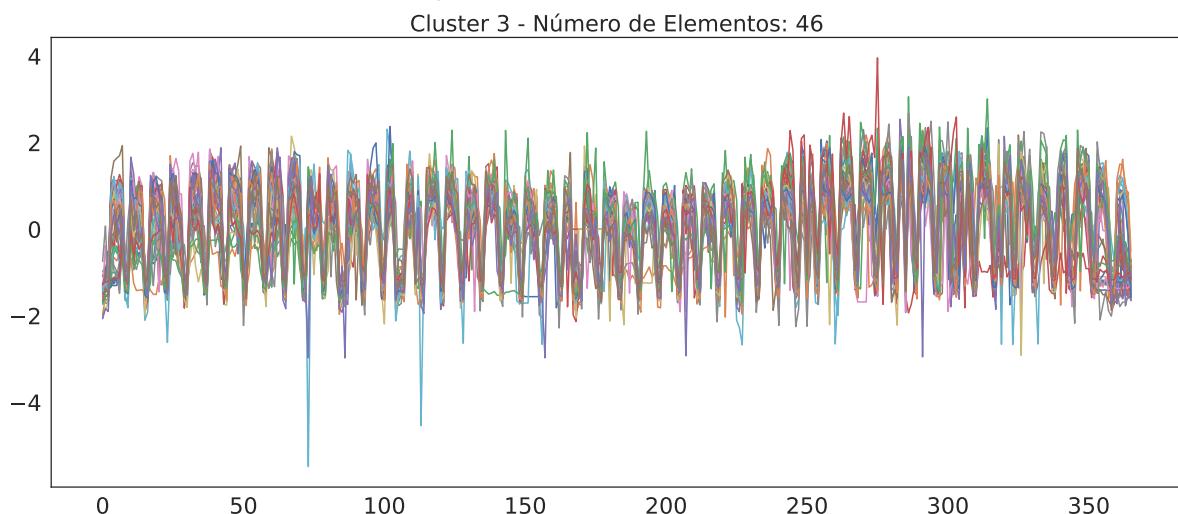
Figura 54 – Agrupamento 2 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 60 unidades consumidoras.



Fonte: Próprio autor (2024).

significativas no consumo de energia. A redução observada durante o período mencionado pode estar relacionada a fatores sazonais ou operacionais, como a implementação de medidas de eficiência energética, períodos de férias, ou manutenção programada de equipamentos. Além disso, o retorno ao nível de consumo anterior sugere que qualquer redução no uso de energia foi temporária e controlada, evidenciando uma recuperação planejada ou esperada do consumo energético. Esse tipo de padrão pode ser útil para a gestão de demandas energéticas e para a previsão de consumo futuro, auxiliando na elaboração de estratégias de otimização e na identificação de períodos críticos para intervenções específicas.

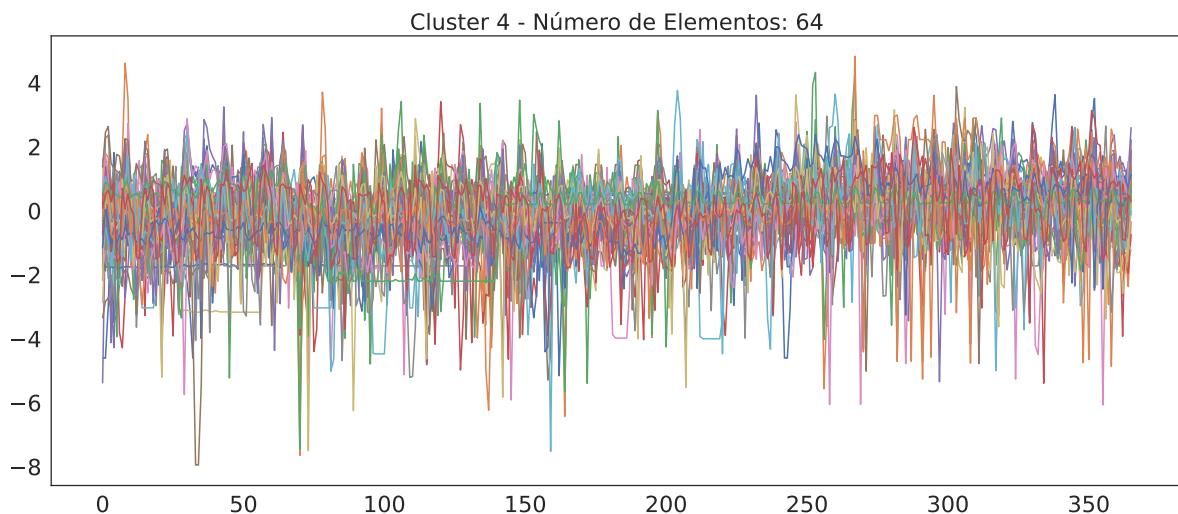
Figura 55 – Agrupamento 3 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 46 unidades consumidoras.



Fonte: Próprio autor (2024).

Na Figura 56 é visto o agrupamento 4 de clientes de energia elétrica. O grupo 4 é o que mais apresenta variações em relação à média de consumo, tanto para mais como para menos. Embora algumas dessas unidades consumidoras tenham baixo consumo de energia e outras tenham consumos significativamente maiores, esse método permite identificar o perfil das séries temporais. Através da análise de dados feita anteriormente sobre o consumo e a demanda desses clientes, já tinham sido identificados esses picos de consumo e demanda, positivos ou negativos em relação à média. No entanto, a clusterização desses clientes reforça a necessidade de ajuste na demanda contratada dessas unidades, seja para aumento ou diminuição. Além disso, este método agiliza o processo de identificação de padrões de grupos de clientes e pontos de dados anômalos no consumo e na demanda elétrica. A análise gráfica do Cluster 4 revela uma alta variabilidade no consumo, indicando a presença de comportamentos distintos entre as unidades consumidoras. Esta variação pode ser resultado de diferentes fatores, como flutuações operacionais, variações sazonais, ou até mesmo irregularidades no uso de energia. Identificar e entender esses padrões é crucial para otimizar a eficiência energética, ajustar corretamente a demanda contratada, e implementar estratégias específicas para mitigar picos de consumo inesperados ou desperdícios de energia. A clusterização, portanto, não apenas confirma as observações anteriores, mas também proporciona uma ferramenta eficiente para a gestão e monitoramento contínuo do consumo de energia, permitindo intervenções mais precisas e fundamentadas na análise de dados.

Figura 56 – Agrupamento 4 do consumo de energia de unidades públicas, através do algoritmo BIRCH com PCA e Autoencoders, com 64 unidades consumidoras.



Fonte: Próprio autor (2024).

Clusterizar as séries temporais permite agrupar consumidores com comportamentos

de consumo semelhantes, o que é essencial para compreender e modelar diferentes perfis de consumo. A otimização dos recursos energéticos beneficia não apenas as unidades consumidoras, mas também as concessionárias de energia, pois a compreensão dos diferentes perfis de consumo pode levar a uma melhor alocação de recursos, como dimensionamento adequado da infraestrutura elétrica, planejamento de capacidade e gestão da demanda. Isso pode resultar em eficiência operacional e redução de custos. A identificação de clusters permite a adaptação de estratégias específicas de eficiência energética para diferentes grupos de consumidores. Além disso, a clusterização pode contribuir para modelos mais precisos de previsão de demanda, ao ajustar os modelos para diferentes grupos de consumidores com comportamentos distintos. À medida que as condições de consumo mudam ao longo do tempo, a clusterização de séries temporais possibilita a compreensão das tendências e sazonalidades dos clientes. A clusterização proporciona uma compreensão mais profunda das necessidades e comportamentos específicos de cada grupo de unidades consumidoras. Além disso, a clusterização auxilia na detecção de comportamentos anômalos nas séries temporais de consumo, sendo útil para identificar problemas operacionais, falhas em equipamentos ou até mesmo fraudes.

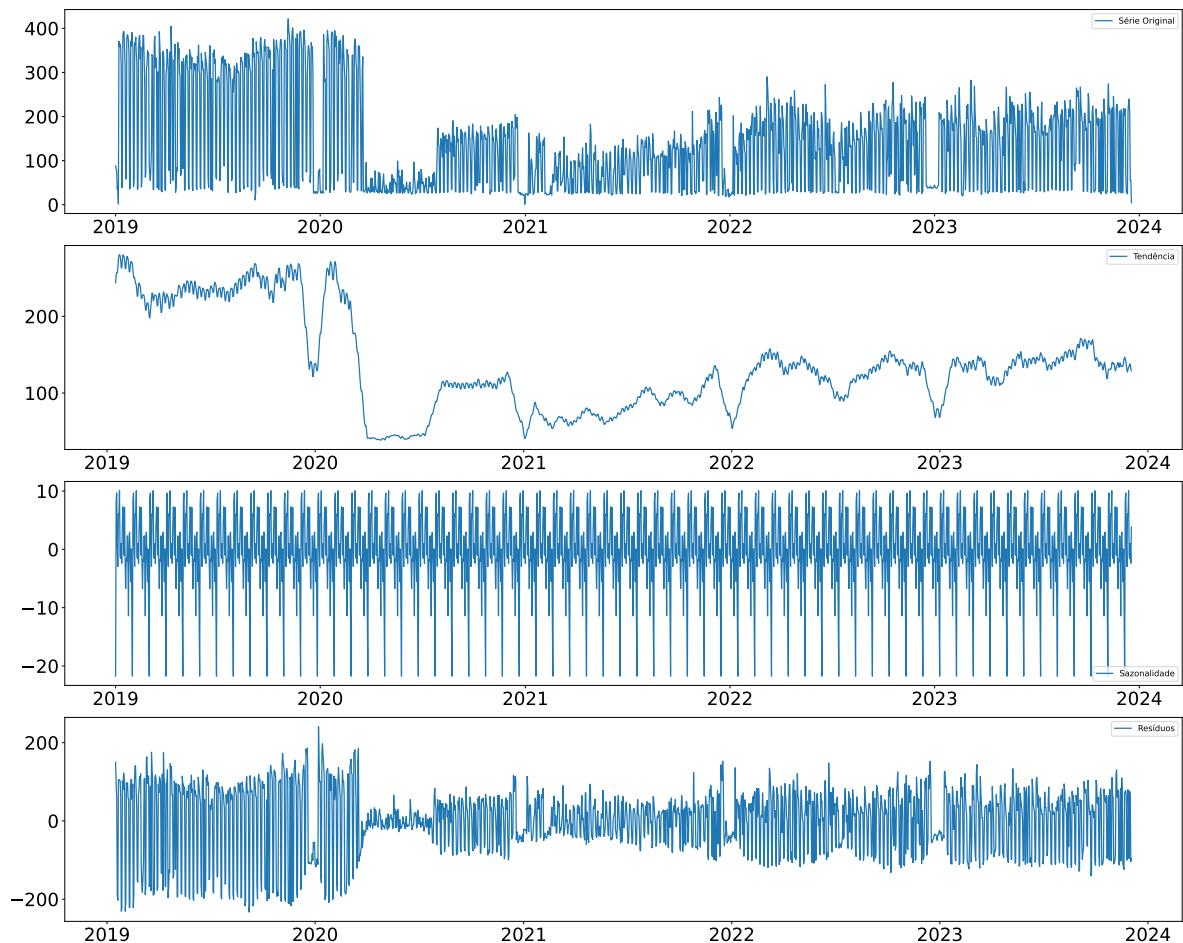
4.4 Previsão de séries temporais do consumo de energia de unidades consumidoras

Após a identificação de séries temporais que apresentam padrões de comportamento semelhantes, como tendência e sazonalidade, é possível utilizar essas séries temporais representativas dos respectivos grupos para prever o consumo de energia de unidades cuja demanda contratada não corresponde ao consumo de energia medido, ou para prever o consumo de novas unidades a serem implantadas. Séries temporais podem ser utilizadas como variáveis exógenas para auxiliar na previsão do consumo de energia de novos clientes. O consumo de energia frequentemente exibe padrões sazonais e tendências ao longo de vários meses, sendo a previsão desses padrões crucial para otimizar o planejamento e gerenciamento de energia de um consumidor.

Na Figura 57 é apresentada a decomposição da série temporal de forma mensal de uma unidade consumidora pertencente aos órgãos da Justiça. É possível observar a série temporal original, a tendência, a sazonalidade e os resíduos do consumo de energia. Os dados históricos abrangem o período de janeiro de 2019 a dezembro de 2023. A unidade consumidora apresentou uma queda no consumo de energia nos últimos anos em comparação com 2019 e o início de 2020, mas o consumo mostra uma estabilidade nos anos mais recentes, principalmente em 2022

e 2023. Portanto, a unidade está demonstrando constância em relação ao consumo de energia, embora seja evidente uma sazonalidade mensal, com maior consumo de energia na primeira metade de cada mês.

Figura 57 – Série temporal de uma unidade consumidora da Justiça, decomposta de forma mensal, do ano de 2019 ao ano de 2023 em kWh.



Fonte: Próprio autor (2024).

Na Figura 58, é apresentada a decomposição anual da série temporal em discussão. Observa-se uma tendência de queda a partir da metade de 2019 até a metade de 2020, seguida por uma estabilização entre meados de 2020 e meados de 2021. A partir do segundo semestre de 2021, há uma tendência de aumento no consumo, com uma subsequente estabilização desde o início de 2022 até o final de 2023. Além disso, é perceptível uma sazonalidade anual no consumo de energia, evidenciada por um padrão de diminuição no segundo trimestre do ano seguido por um aumento até atingir os níveis de consumo do primeiro trimestre. Vale ressaltar que a abordagem aditiva para decomposição da série temporal considera a série como a soma de suas componentes individuais de tendência, sazonalidade e resíduos.

Figura 58 – Série temporal de uma unidade consumidora da Justiça, decomposta de forma anual, do ano de 2019 ao ano de 2023 em kWh.



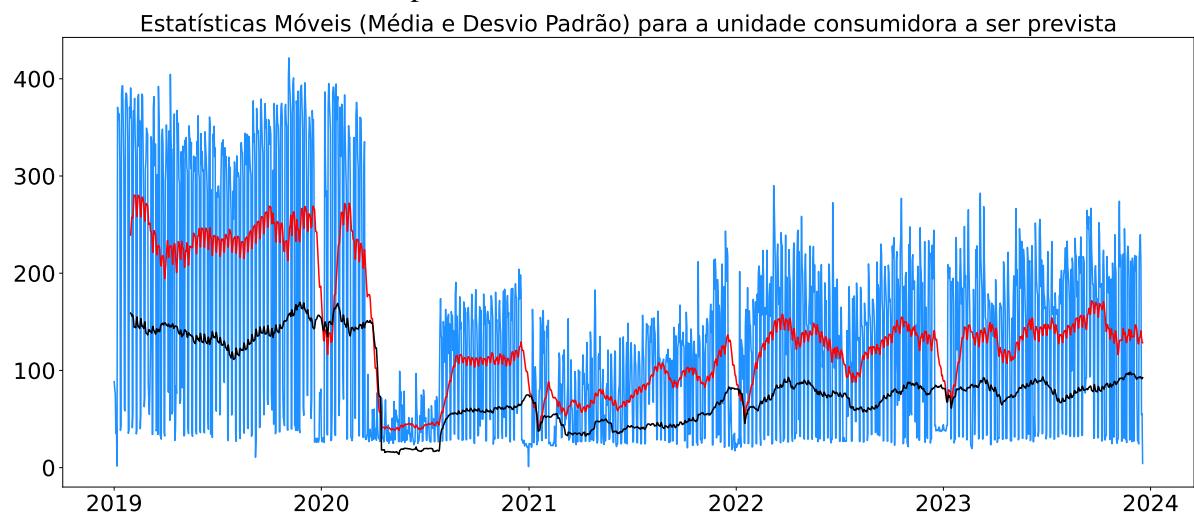
Fonte: Próprio autor (2024).

Observa-se que tanto a sazonalidade quanto os resíduos apresentam valores positivos e negativos, mesmo que a série temporal em si não contenha valores negativos. Tal fenômeno é comum, uma vez que a soma das componentes constitui a série original. A sazonalidade oscila em torno de valores de aproximadamente 100, 0 e -100, indicando que em diferentes períodos ao longo do ano, a série temporal apresenta variações positivas de cerca de 100 unidades em relação à média, variações próximas a zero e variações negativas próximas de 100 unidades. Quanto aos resíduos, estes representam as variações na série temporal que não são explicadas pelas componentes de tendência e sazonalidade. Essas variações sugerem a presença de padrões não capturados ou ruídos na série temporal, os quais podem ser modelados e incorporados por meio de modelos de previsão.

Na Figura 59, são apresentadas as curvas referentes à série temporal original de consumo do cliente afiliado à Justiça, destacada em azul, juntamente com a média móvel em vermelho e o desvio padrão em preto. Ao observar a média móvel e o desvio padrão, é possível

inferir que a série temporal atualmente demonstra um comportamento praticamente estacionário. Durante os últimos dois anos, especificamente em 2022 e 2023, o consumo não apresenta variações significativas.

Figura 59 – Dados históricos originais de consumo medido de janeiro de 2019 a dezembro de 2023, a média móvel e o desvio padrão dos dados em kWh.



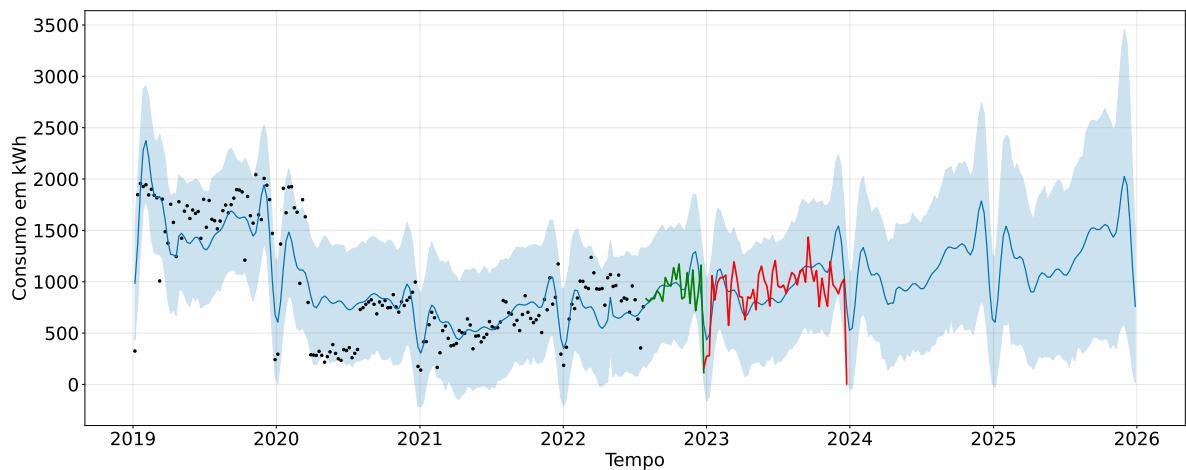
Fonte: Próprio autor (2024).

Nesta seção, os algoritmos Prophet e SARIMA serão empregados para realizar previsões em uma unidade consumidora. Inicialmente, essas previsões serão fundamentadas nos dados históricos da série temporal em questão. Posteriormente, serão exploradas abordagens que incorporam outras séries temporais como variáveis exógenas nos modelos. A previsão de horizontes mais amplos desempenha um papel crucial no planejamento de recursos para as empresas de energia, permitindo a alocação eficiente de recursos, como geração e distribuição de energia, para atender à demanda futura. Além disso, auxilia as unidades consumidoras na compreensão dos níveis de consumo necessários e na determinação da demanda contratada adequada. O conhecimento das previsões de consumo de energia também facilita a operação eficiente da rede elétrica, possibilitando ajustes operacionais para evitar picos de demanda ou períodos de ociosidade excessiva. Antecipar a demanda futura pode ainda influenciar estratégias relacionadas à compra e contratação de energia, especialmente no caso de unidades consumidoras participantes do mercado livre de energia.

4.4.1 Previsões univariadas

Na Figura 60, são apresentadas as previsões geradas pelo modelo Prophet para a série temporal analisada nesta seção. Os pontos pretos representam os dados de treinamento, enquanto as previsões do modelo são representadas em azul. Os pontos em verde correspondem às medições originais realizadas entre meados do ano de 2021 e os dois primeiros terços do mês de dezembro de 2022, enquanto os pontos em vermelho representam medições originais realizadas do último terço do mês de dezembro de 2022 até dezembro de 2023. O sombreado em azul claro indica o intervalo de confiança das previsões do modelo. A utilização de previsões univariadas, como as geradas pelo modelo Prophet, é vantajosa em muitos cenários devido à sua simplicidade e eficácia. Ao se concentrar exclusivamente na série temporal de consumo de energia, o modelo pode capturar padrões sazonais e tendências específicas dessa variável sem ser influenciado por outras séries que possam introduzir ruídos ou complexidades adicionais.

Figura 60 – Previsão de consumo, em kWh, até 2025 com o modelo Prophet.



Fonte: Próprio autor (2024).

Na Tabela 6, são apresentadas as métricas de avaliação MSE, RMSE, MAE e MAPE para as previsões geradas pelo modelo Prophet. O MSE calcula a média dos quadrados das diferenças entre os valores previstos e os valores reais, proporcionando uma medida do erro quadrático médio entre as previsões e os dados observados. Uma pontuação elevada de MSE indica um desempenho insatisfatório do modelo em relação às previsões, especialmente quando há valores discrepantes entre as previsões e os dados reais. O RMSE, por sua vez, penaliza grandes discrepâncias entre os valores previstos e os valores reais, apresentando a raiz quadrada do MSE para expressar o erro na mesma escala dos dados originais. Dessa forma, ao observar o valor de RMSE, é possível inferir que o modelo pode estar errando, em média, uma

determinada quantidade em relação aos valores originais, considerando-se a média quadrática dos erros. Por sua vez, o MAE não é influenciado por valores discrepantes e expressa a média das diferenças absolutas entre os valores previstos e os valores reais. Assim como o RMSE, o MAE também expressa o erro na mesma escala dos dados originais. O MAPE, por fim, representa a porcentagem média de erro em relação aos valores originais, permitindo uma avaliação da precisão das previsões em termos percentuais. Os resultados obtidos para as métricas indicam que as previsões do modelo Prophet são razoavelmente precisas, conforme apresentado na Tabela 6. É importante ressaltar que, embora as medições de consumo tenham sido coletadas diariamente, os dados foram reorganizados em intervalos semanais para melhorar a precisão das previsões, considerando a sazonalidade anual. Essa reorganização dos dados, realizada pela soma do consumo a cada sete dias, contribuiu para a obtenção de resultados mais confiáveis por parte do modelo.

Tabela 6 – Métricas de avaliação para as previsões do modelo Prophet

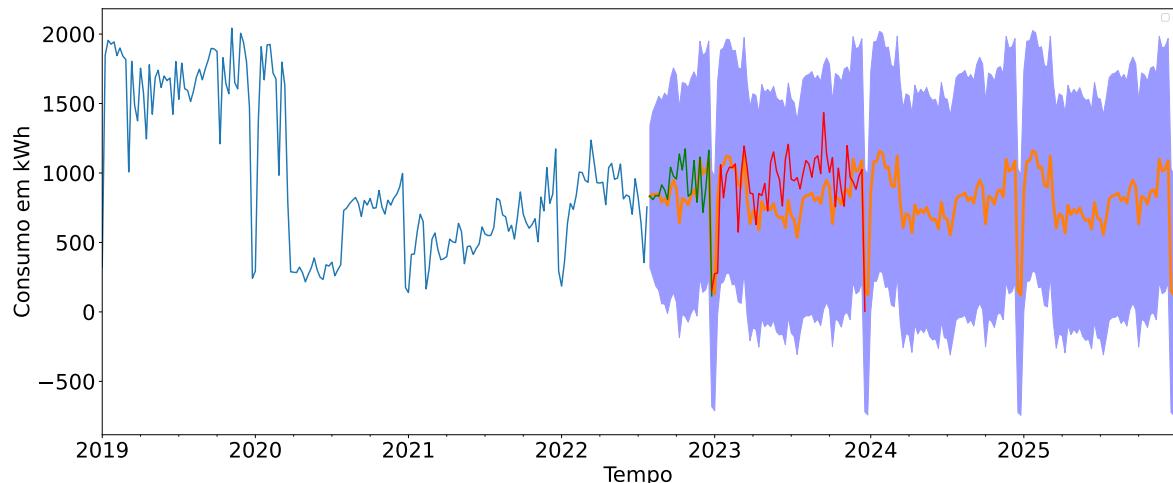
Base de dados	MSE	RMSE	MAE	MAPE
Base de treinamento (2019/2021)	84173,51	290	222,72	0,38
Base de teste (2021/2022)	48715,05	220,71	149,45	0,35

Fonte: Próprio autor (2025).

Na Figura 61, é apresentado o gráfico com as previsões geradas pelo modelo SARIMA. Os dados originais de treinamento do modelo são destacados em azul, enquanto os dados de teste, abrangendo o período entre o meio do ano de 2021 e os dois primeiros terços do mês de dezembro de 2022, são representados em verde. Os pontos em vermelho correspondem às medições originais realizadas no final do mês de dezembro de 2022, aproximadamente nos últimos 10 dias do mês, até dezembro de 2023, e as previsões do modelo são destacadas em laranja. O sombreado em roxo representa o intervalo de confiança das previsões do modelo SARIMA. A utilização do modelo SARIMA é vantajosa no contexto desta tese de doutorado por várias razões. Em primeiro lugar, o SARIMA é uma extensão do modelo ARIMA (Autoregressive Integrated Moving Average), que é amplamente utilizado em análise de séries temporais. Essa extensão permite que o SARIMA modele efetivamente séries temporais com sazonalidade, o que é crucial para prever o consumo de energia, já que muitos padrões de consumo seguem padrões sazonais anuais, mensais ou semanais. Além disso, o SARIMA também leva em conta a autoregressão, a diferenciação e a média móvel, o que o torna adequado para capturar tendências e padrões de comportamento complexos presentes nos dados de consumo de energia. Dessa forma, o uso do

SARIMA neste contexto permite a construção de previsões mais precisas e robustas, fornecendo insights valiosos para o planejamento e a gestão eficiente de recursos energéticos.

Figura 61 – Previsão de consumo, em kWh, até 2025 com o modelo SARIMA.



Fonte: Próprio autor (2024).

Na Tabela 7, são apresentadas as métricas de avaliação MSE, RMSE, MAE e MAPE para as previsões geradas pelo modelo SARIMA. O modelo SARIMA demonstrou um desempenho superior ao modelo Prophet, conforme evidenciado pela análise dos erros dos modelos. A utilização do modelo SARIMA resultou em valores significativamente menores de MSE, RMSE, MAE e MAPE em comparação com o modelo Prophet, indicando uma maior precisão nas previsões. Esses resultados sugerem que o SARIMA foi capaz de capturar de forma mais eficaz os padrões e a variabilidade presentes na série temporal de consumo de energia, contribuindo assim para uma melhor capacidade de previsão. Essa maior precisão do SARIMA pode ser atribuída à sua capacidade de modelar adequadamente a sazonalidade, tendências e padrões autoregressivos presentes nos dados de consumo de energia. Portanto, o uso do SARIMA neste contexto se mostra promissor para aprimorar o planejamento e a gestão eficiente de recursos energéticos, fornecendo previsões mais confiáveis e precisas para os tomadores de decisão no setor energético.

Tabela 7 – Métricas de avaliação para as previsões do modelo SARIMA

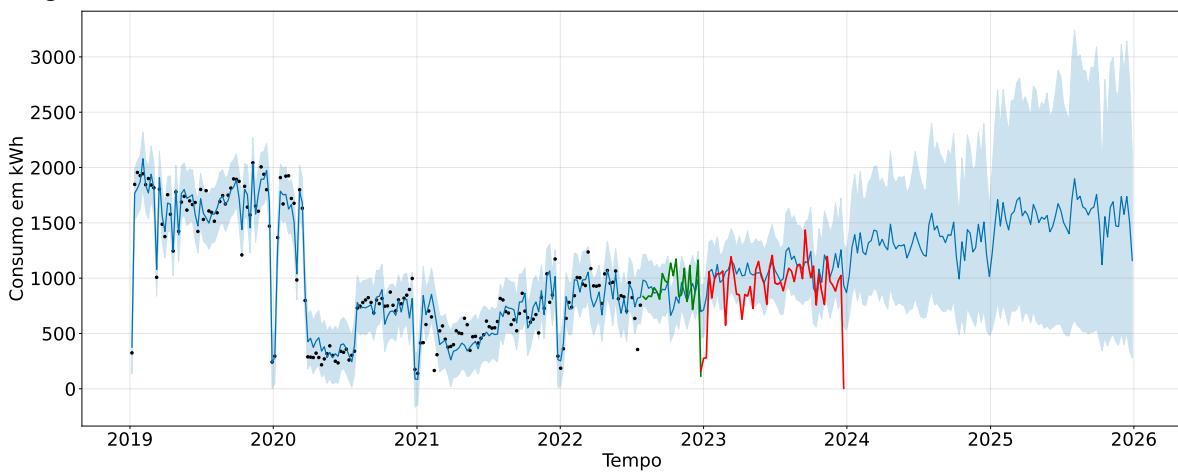
Base de dados	MSE	RMSE	MAE	MAPE
Base de teste (2021/2022)	28400,16	168,52	112,42	13,3

Fonte: Próprio autor (2025).

4.4.2 Previsões univariadas com variáveis exógenas

Na Figura 62, são apresentadas as previsões geradas pelo modelo Prophet utilizando variáveis exógenas. Os pontos pretos representam os dados de treinamento, conforme mencionado anteriormente. As previsões do modelo são destacadas em azul e abrangem até o ano de 2025. Os pontos em verde correspondem às medições reais realizadas entre o meio do ano de 2021 e aproximadamente o dia 20 do mês de dezembro de 2022. Já os pontos em vermelho representam as medições originais realizadas no final do mês de dezembro de 2022, especificamente nos últimos 10 dias do mês, até dezembro de 2023. O sombreado em azul claro indica o intervalo de confiança das previsões do modelo. A inclusão de variáveis exógenas nas previsões do modelo Prophet permite incorporar informações adicionais que podem influenciar o consumo de energia, como padrões de consumo de outras unidades consumidoras do mesmo grupo com curvas de consumo bem definidas. Essa abordagem tem o potencial de melhorar a precisão das previsões ao capturar mais detalhadamente os padrões de consumo e as influências externas que podem afetar a demanda de energia. Portanto, ao utilizar variáveis exógenas, o modelo Prophet pode oferecer previsões mais robustas e confiáveis, auxiliando assim no planejamento e na gestão eficiente dos recursos energéticos.

Figura 62 – Previsão de consumo, em kWh, até 2025 com o modelo Prophet utilizando variáveis exógenas.



Fonte: Próprio autor (2024).

Na Tabela 8 são mostradas as métricas de avaliação para o modelo Prophet utilizando variáveis exógenas.

Na Figura 63, é apresentado o gráfico com as previsões geradas pelo modelo SARIMA utilizando variáveis exógenas. Os dados reais de treinamento estão representados em

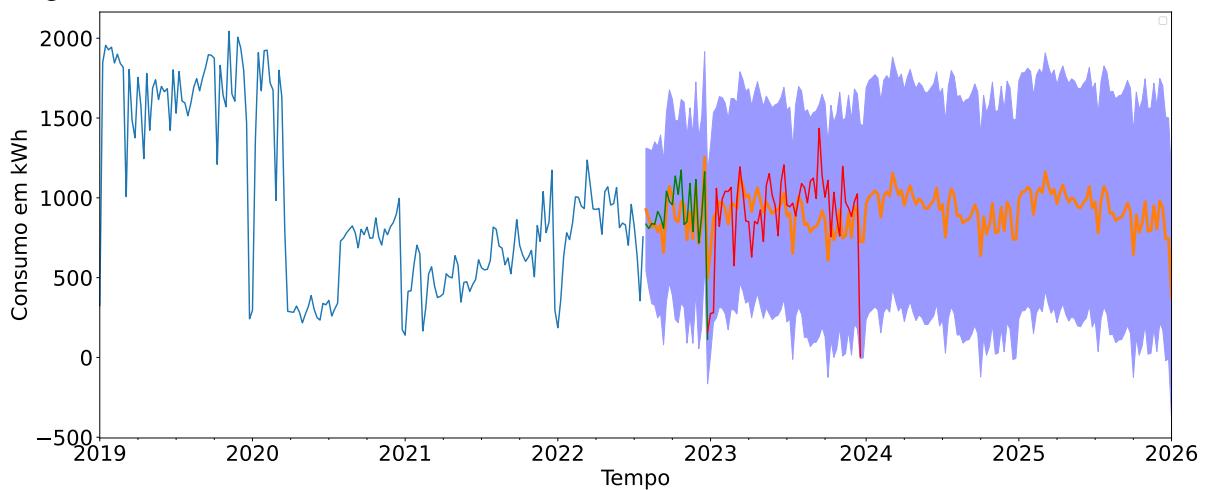
Tabela 8 – Métricas de avaliação para as previsões do modelo Prophet utilizando variáveis exógenas

Base de dados	MSE	RMSE	MAE	MAPE
Base de treinamento (2019/2021)	15094,56	122,86	91,82	0,15
Base de teste (2021/2022)	48574,92	220,39	160,86	0,36

Fonte: Próprio autor (2025).

azul, enquanto os dados de teste, abrangendo o período entre o meio do ano de 2021 e aproximadamente os dois primeiros terços do mês de dezembro de 2022, são destacados em verde. As medições reais coletadas no final do mês de dezembro de 2022, aproximadamente nos últimos 10 dias do mês, até dezembro de 2023, são mostradas em vermelho, e as previsões do modelo até o final de 2025 são exibidas em laranja. O sombreado em roxo indica o intervalo de confiança das previsões do modelo SARIMA com variáveis exógenas.

Figura 63 – Previsão de consumo, em kWh, até 2025 com o modelo SARIMA utilizando variáveis exógenas.



Fonte: Próprio autor (2024).

Na Tabela 9, são apresentadas as métricas de avaliação MSE, RMSE, MAE e MAPE para o modelo SARIMA com variáveis exógenas. O modelo SARIMA com variáveis exógenas demonstrou um desempenho superior em comparação com o modelo Prophet sem variáveis exógenas e também em relação ao modelo SARIMA aplicado sem variáveis exógenas, conforme evidenciado pela análise dos erros dos modelos. Como observado anteriormente, o modelo Prophet com variáveis exógenas apresentou um desempenho ligeiramente inferior ao modelo Prophet sem variáveis exógenas. Por outro lado, o modelo SARIMA com as variáveis exógenas, que neste contexto são outras séries temporais de unidades consumidoras com padrões de

consumo bem definidos e correlação elevada com a série temporal em análise, obteve um desempenho melhor do que o modelo SARIMA sem as variáveis exógenas. Esses resultados indicam que as séries temporais inseridas no modelo SARIMA, como variáveis exógenas, desempenharam um papel crucial na melhoria das previsões do consumo de energia da unidade consumidora analisada. A inclusão dessas variáveis adicionais permitiu que o modelo capturasse mais eficientemente os padrões e influências externas relevantes, resultando em previsões mais precisas e confiáveis.

Tabela 9 – Métricas de avaliação para as previsões do modelo SARIMA com variáveis exógenas

Base de dados	MSE	RMSE	MAE	MAPE
Base de teste (2021/2022)	15954,70	126,31	103,36	19,06

Fonte: Próprio autor (2025).

4.5 Recomendações práticas para gestores de energia e formuladores de políticas públicas

Os resultados desta pesquisa oferecem subsídios aplicáveis para gestores de energia e formuladores de políticas públicas, favorecendo a otimização da demanda contratada e a implementação de estratégias de eficiência energética por meio de técnicas de clusterização, análise de correlação e modelos de previsão. Unidades consumidoras com baixo consumo, porém com elevada demanda contratada devem ser reavaliadas imediatamente, a fim de alinhar a demanda contratada ao perfil real de utilização, reduzindo penalidades e os custos globais com energia.

Unidades com padrões de consumo estáveis, porém cíclicos podem se beneficiar da adoção de programas automatizados de resposta à demanda, visando à mitigação de picos de carga sem comprometer a eficiência operacional.

Os resultados da clusterização possibilitam o delineamento de estratégias específicas conforme o perfil de consumo das unidades. O Cluster 1 das séries temporais, por exemplo, demanda ajustes imediatos na demanda contratada e auditorias energéticas para identificação de ineficiências. Já o Cluster 2, caracterizado por comportamento de consumo irregular, exige uma investigação aprofundada sobre possíveis causas operacionais, como falhas em equipamentos, furtos de energia ou simplesmente contratação de demanda excessiva em relação ao uso efetivo, refletindo práticas de gestão energética inefficientes. Por sua vez, as unidades agrupadas nos Clusters 3 e 4 — que apresentam perfis estáveis ou cíclicos — podem servir como referência

para definição da demanda contratada em novas unidades ou naquelas recentemente conectadas.

A integração de modelos de previsão aos sistemas de gestão de energia pode ser realizada com a utilização de perfis consolidados de consumidores como variáveis exógenas em previsões de séries temporais, especialmente voltadas à estimativa de consumo de novas unidades consumidoras ou daquelas com histórico de dados limitado. Os resultados dessas previsões devem ser incorporados às plataformas existentes, permitindo o monitoramento em tempo real da demanda e a aplicação de análises preditivas, com alertas automatizados para notificação de desvios relevantes em relação aos padrões esperados.

Adicionalmente, o monitoramento contínuo com base em técnicas de análise de correlação — como os coeficientes de Pearson e Spearman — permite identificar padrões comportamentais semelhantes e detectar anomalias, estabelecendo um ciclo de retroalimentação no qual os insights provenientes da detecção de anomalias refinam progressivamente os modelos de clusterização e previsão.

A metodologia proposta, se aplicada de forma ampliada a todas as unidades consumidoras do Grupo A sob gestão do Estado, possui o potencial de gerar economias significativas, ultrapassando os R\$ 2,7 milhões estimados para as 185 unidades analisadas, permitindo a relocação desses recursos para serviços públicos essenciais, como educação, saúde e segurança pública.

Em síntese, estas recomendações práticas traçam um caminho claro para o aprimoramento da eficiência na gestão energética, redução de custos e aumento da precisão nas previsões de demanda, ao mesmo tempo em que estabelecem bases sólidas para práticas sustentáveis e orientadas por dados no setor elétrico.

4.6 Considerações finais

Este capítulo apresentou os métodos de clusterização pelo consumo médio e pela demanda contratada, clusterização das séries temporais do consumo de energia de unidades consumidoras, correlação entre as séries temporais utilizando os coeficientes de correlação de Pearson e Spearman e previsões de séries temporais utilizando outros consumidores de mesmo grupo para ajudar na previsão de consumo de unidades consumidoras. Estes métodos combinados contribuem para o conhecimento de como a energia está sendo utilizada por determinado cliente e visa a eficiência energética, assim como a gestão da demanda de energia elétrica.

5 CRIAÇÃO DE APLICAÇÃO DESKTOP PARA CÁLCULO DE COMPARAÇÃO DE FATURAS E DETECÇÃO DE ANOMALIAS

5.1 Introdução

Este capítulo abordará a criação de um aplicativo destinado à comparação do valor da tarifa de energia aplicada a um cliente do grupo A, considerando as modalidades horosazonal verde ou azul. Essa comparação será baseada no consumo e na demanda elétrica. O aplicativo também será capaz de detectar anomalias, fornecer dados estatísticos como média móvel e desvio padrão, apresentar a modalidade tarifária mais adequada para o cliente e a nova demanda a ser contratada para se adequar ao valor de consumo do cliente nos horários de ponta e fora de ponta. Adicionalmente, serão analisadas a tendência e a sazonalidade da série temporal de demanda elétrica ao longo do ano, bem como serão identificadas possíveis anomalias.

5.2 Construção da aplicação desktop

Para o desenvolvimento do aplicativo desktop, foi empregada a linguagem Python, juntamente com bibliotecas como Pandas, Matplotlib, Numpy, Os, Math, Statsmodels e Scikit-learn, entre outras. Ademais, foi utilizado o Tkinter, que constitui a interface padrão em Python para o kit de ferramentas GUI Tcl/Tk. Tanto o Tk quanto o Tkinter são amplamente disponíveis em diversas plataformas Unix, incluindo macOS, bem como em sistemas Windows (Python Software Foundation, 2023). Tkinter é uma das ferramentas fornecidas pela linguagem Python para o desenvolvimento de interfaces gráficas, e sua documentação é extensa (Grupo Python - UNESP, 2005). O código elaborado para esta aplicação possibilita a geração de executáveis tanto para sistemas Windows quanto para Linux, por exemplo.

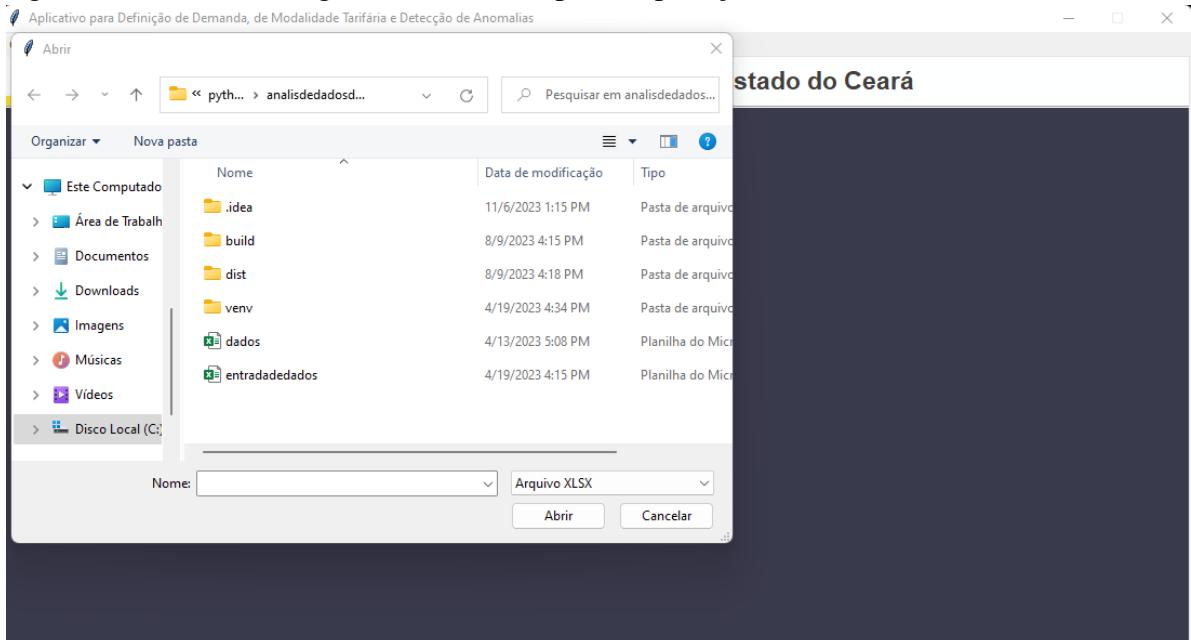
5.2.1 Apresentação das telas da aplicação desktop

5.2.1.1 Tela de carregamento de dados

Na Figura 64 é mostrada a tela 1 da aplicação desktop. Nessa tela os dados são carregados. A aplicação requer dois arquivos: o primeiro contendo dados de potência e consumo de energia; o segundo, detalhando preços de tarifas, incluindo a TUSD, demandas contratadas, datas de início e fim da série temporal (ano, mês, dia) e o tipo da tarifa atual do cliente. Não é necessário nomear os arquivos de forma específica. Contudo, deve-se carregar primeiramente

o arquivo de dados de potência e consumo de energia, seguido pelo arquivo com informações sobre tarifas, demandas contratadas, entre outros detalhes.

Figura 64 – Tela de carregamento de dados para a aplicação.



Fonte: Próprio autor (2024).

Na Figura 65, é apresentada a tela com os dados já carregados. Conforme mencionado, podem ser observados os dados de demanda nos horários de ponta e fora de ponta, além do consumo em horário de ponta e fora de ponta, eventual consumo reservado e a data correspondente. A data é exibida no formato de dias, que é o padrão fornecido pelo site de telemedição da Enel, plataforma na qual os dados foram coletados. No site, as medidas diárias são representadas nesse formato, o que justifica a solicitação, na aplicação, das datas de início e fim dos dados coletados (ano, mês e dia). Internamente, o algoritmo desenvolvido analisa os dados de data de início e fim, verificando se estão de acordo com o número total de dias no conjunto de dados, e então gera as datas no formato de ano, mês e dia. Entretanto, esse formato de ano, mês e dia não é exibido nessa tela específica, mas sim nas telas subsequentes. O algoritmo já realiza esse processamento internamente.

Na Figura 66 é mostrado um dashboard referente a uma unidade consumidora exemplar. Neste contexto, a demanda contratada é de 423 kW, com a modalidade tarifária horosazonal verde. Nesta tela, são exibidos os valores da tarifação anual e mensal totais para esse cliente, bem como o consumo mensal nos horários de ponta e fora de ponta, medido ao longo de um ano e expresso em MWh. Adicionalmente, são apresentadas a demanda contratada

Figura 65 – Tela de visualização dos dados que a aplicação irá consumir.

The screenshot shows a Windows application window titled 'Dashboard Energético - Unidade Consumidora do Estado do Ceará'. The window has a menu bar with items like 'Carregamento de Dados', 'Dashboard Energético', 'Definição de Demanda', 'Demandas escolhidas', 'Detecção de Anomalias', 'Anomalias detectadas FP', and 'Anomalias detectadas P'. Below the menu is a table with columns: Data, Demandaforaponta, Demandaponta, Demandareservado, Consumoforaponta, Consumoponta, and Consumoreservado. The table contains 22 rows of data, each with numerical values corresponding to the columns.

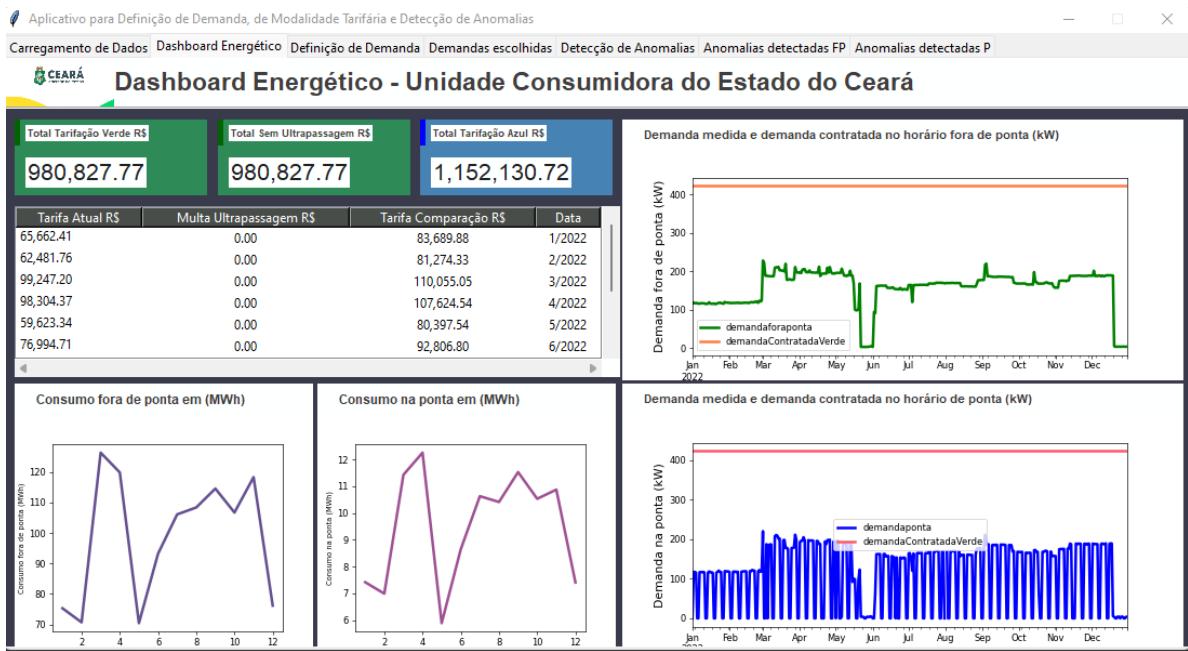
Data	Demandafóraponta	Demandaponta	Demandareservado	Consumofóraponta	Consumoponta	Consumoreservado
1.0	117.18	0.0	0.0	2802.165	0.0	0.0
2.0	119.28	117.18	0.0	2378.355	349.86	0.0
3.0	117.18	117.18	0.0	2449.44	350.175	0.0
4.0	117.18	115.5	0.0	2428.755	345.765	0.0
5.0	118.02	0.0	0.0	2472.12	0.0	0.0
6.0	115.92	0.0	0.0	2761.815	0.0	0.0
7.0	116.34	116.76	0.0	2416.785	347.655	0.0
8.0	117.18	116.76	0.0	2429.91	350.07	0.0
9.0	117.18	116.76	0.0	2365.44	349.335	0.0
10.0	117.18	117.18	0.0	2431.065	349.125	0.0
11.0	116.76	115.92	0.0	2420.985	344.82	0.0
12.0	115.5	0.0	0.0	1867.005	0.0	0.0
13.0	115.5	0.0	0.0	2754.15	0.0	0.0
14.0	116.34	115.5	0.0	2410.59	330.12	0.0
15.0	119.7	118.44	0.0	2046.24	339.99	0.0
16.0	116.34	116.34	0.0	2416.26	347.76	0.0
17.0	115.92	116.34	0.0	2413.635	347.13	0.0
18.0	115.92	115.08	0.0	2407.23	343.35	0.0
19.0	116.76	0.0	0.0	2762.13	0.0	0.0
20.0	115.08	0.0	0.0	2739.66	0.0	0.0
21.0	115.5	115.08	0.0	2406.285	344.505	0.0
22.0	117.18	117.6	0.0	2389.485	350.7	0.0

Fonte: Próprio autor (2024).

nos horários de ponta e fora de ponta. Destaca-se que a demanda contratada para um cliente de energia com modalidade tarifária horosazonal verde é um valor único, independentemente da diferenciação entre horários de ponta e fora de ponta. Assim, os gráficos exibidos representam a demanda medida nos horários de ponta e fora de ponta, juntamente com a demanda contratada, que aparece nos dois gráficos com um único valor e contrato, independente do posto horário. Além disso, é verificado se há multa por ultrapassagem da demanda contratada, lembrando que o limite máximo para ultrapassagem de clientes do grupo A é de 5% do valor da demanda contratada. O campo denominado "tarifa de comparação" refere-se ao modelo tarifário que está sendo comparado com o atual. Por exemplo, no caso deste cliente, a tarifação na qual ele está atualmente inscrito é a horosazonal verde, portanto, a tarifa de comparação é a horosazonal azul.

Na Figura 67 são apresentados os valores totais anuais referentes ao modelo tarifário atual, juntamente com a demanda contratada atual, assim como os valores da tarifação verde e azul com a demanda contratada selecionada, tanto nos horários de ponta quanto fora de ponta. Além disso, são exibidos os valores mensais da tarifação e gráficos ilustrativos da nova demanda contratada, seja nos horários de ponta ou fora de ponta, juntamente com o tipo de modalidade tarifária escolhida e as demandas medidas nos horários de ponta e fora de ponta. Para esta unidade consumidora, a modalidade tarifária que resultou em menores custos durante o ano, e consequentemente foi selecionada, foi a tarifação horosazonal azul. O algoritmo utilizado para a definição da demanda baseia-se em conceitos estatísticos. Através da análise de diversas

Figura 66 – Tela de visualização de um dashboard de comparação de valores de faturas e gráficos de consumo e demanda.

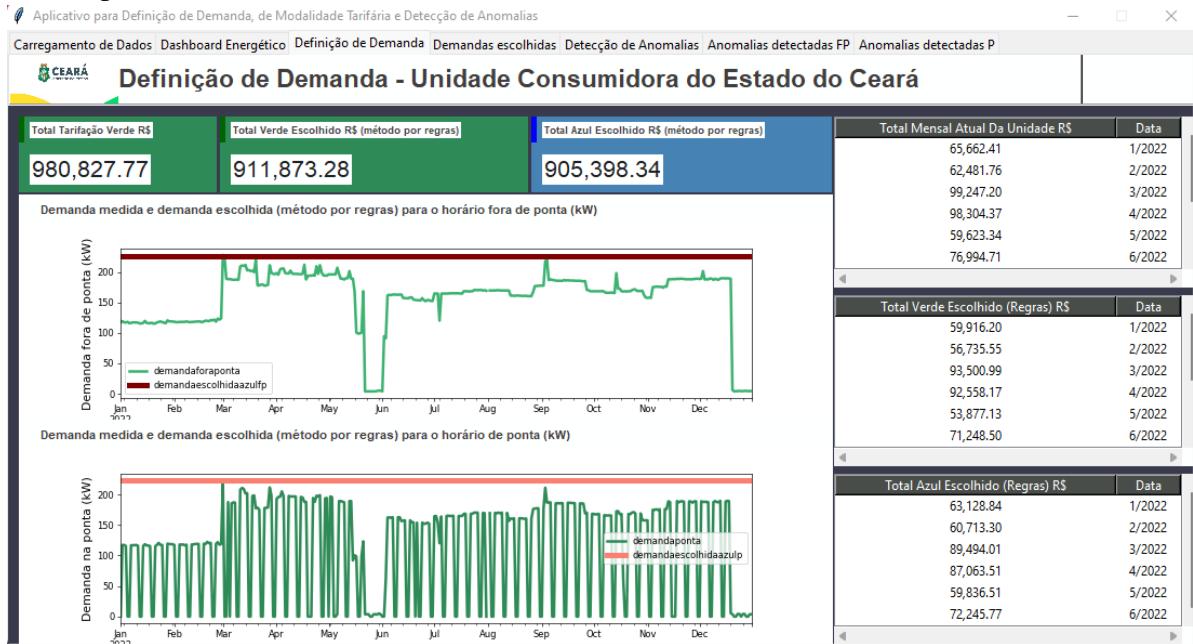


Fonte: Próprio autor (2024).

bases de dados, identificou-se que o percentil 80, representando 80% dos dados medidos de demanda ao longo do ano, proporciona uma boa visão e um indicativo confiável para determinar o valor da demanda a ser contratada para um cliente de energia. Valores de demanda mais baixos ou mais altos em relação ao percentil 80 podem não refletir totalmente o comportamento das solicitações de demanda ao longo do ano, o que poderia resultar em custos adicionais por multa de ultrapassagem da demanda ou por contratação excessiva de demanda. Se 80% da demanda registrada for menor que 30 kW, o valor mínimo a ser contratado para clientes do grupo A, a demanda escolhida é 30 kW, ou recomenda-se o desligamento da unidade. Se a demanda contratada for maior que a demanda medida definida pelo percentil 80 e menor ou igual a 1,2 vezes a demanda média definida pelo percentil 80, então a demanda escolhida é a própria demanda já contratada. Se a demanda contratada for maior que 1,2 vezes a medida definida pelo percentil 80, a demanda escolhida é 1,2 vezes a medida; se a demanda contratada for menor que a definida pelo percentil 80, a demanda escolhida é a demanda definida pelo percentil 80 multiplicada por 1,2. Para maior esclarecimento, a demanda mencionada no texto como definida pelo percentil 80 é a demanda utilizada como base de cálculo. Por exemplo, se, em uma base de dados, o percentil 80 for 10 kW, essa demanda será a referência para o cálculo da escolha da demanda do cliente. Após esses procedimentos, o algoritmo compara o custo das tarificações horosazonal azul e verde para o cliente em questão, com base no consumo e nas novas demandas

selecionadas, e sugere a modalidade tarifária com menor custo.

Figura 67 – Tela de visualização da comparação entre as tarifas e demanda escolhida na ponta e fora de ponta.



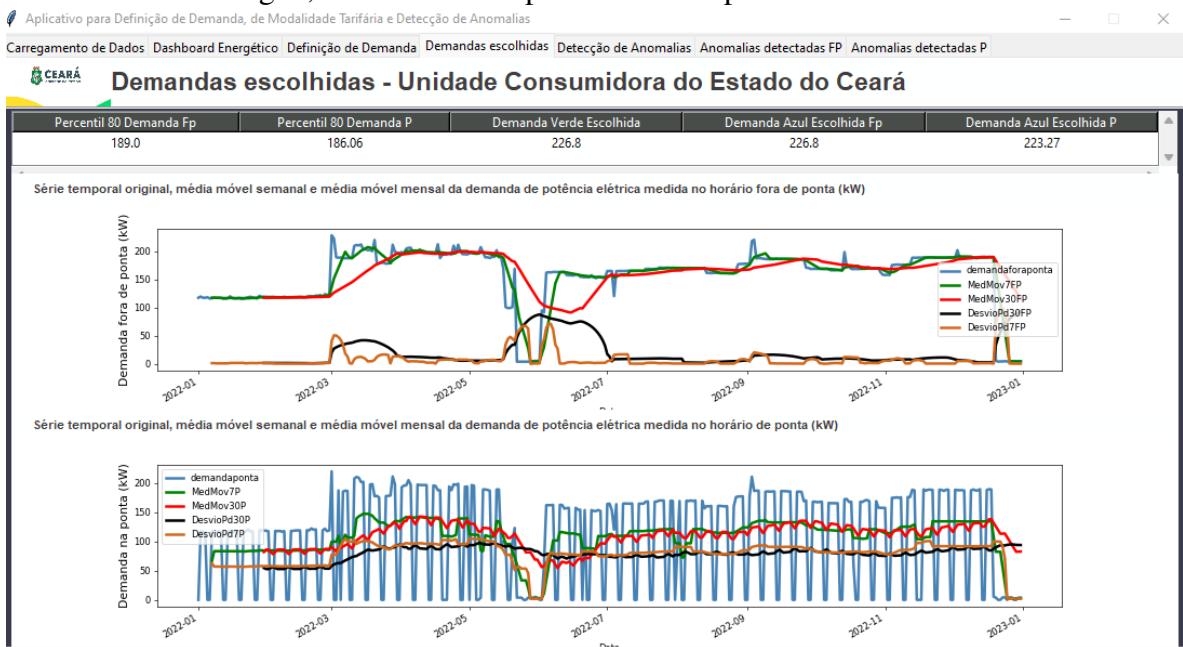
Fonte: Próprio autor (2024).

Na Figura 68, são exibidas as demandas selecionadas nas modalidades tarifárias verde e azul, os percentis 80 das demandas e gráficos contendo médias móveis e desvios padrão, tanto semanais quanto mensais. Além disso, são apresentadas as séries temporais originais de demanda, tanto para os horários de ponta quanto para os horários fora de ponta.

Na Figura 69 são mostradas as séries temporais de demanda nos horários de ponta e fora de ponta e foi aplicado o algoritmo de floresta isolada para a detecção não supervisionada de anomalias. O algoritmo é usado principalmente para detectar anormalidades nos pontos de dados. Em outras palavras, ele descobre os pontos de dados, em um grande número de dados, que não são consistentes com a maioria dos dados analisados, e sim são pontos discrepantes. O algoritmo de floresta isolada pode lidar com dados em grande escala de forma bastante rápida. O algoritmo de floresta isolada consiste em diversas árvores. A árvore no algoritmo é chamada de árvore isolada. O estabelecimento da árvore isolada é o seguinte, Liu *et al.* (2008) e Mao *et al.* (2018):

1. Extrai aleatoriamente subamostras dos pontos de dados de treinamento como nós raiz em árvores;
2. Uma dimensão é atribuída aleatoriamente para gerar um ponto de corte P nos dados do nó atual que são gerados aleatoriamente entre os valores máximo e o mínimo da dimensão

Figura 68 – Tela de visualização de demandas escolhidas, médias móveis, desvio padrão e demanda medida original, nos horários de ponta e fora de ponta.



Fonte: Próprio autor (2024).

especificada do nó atual;

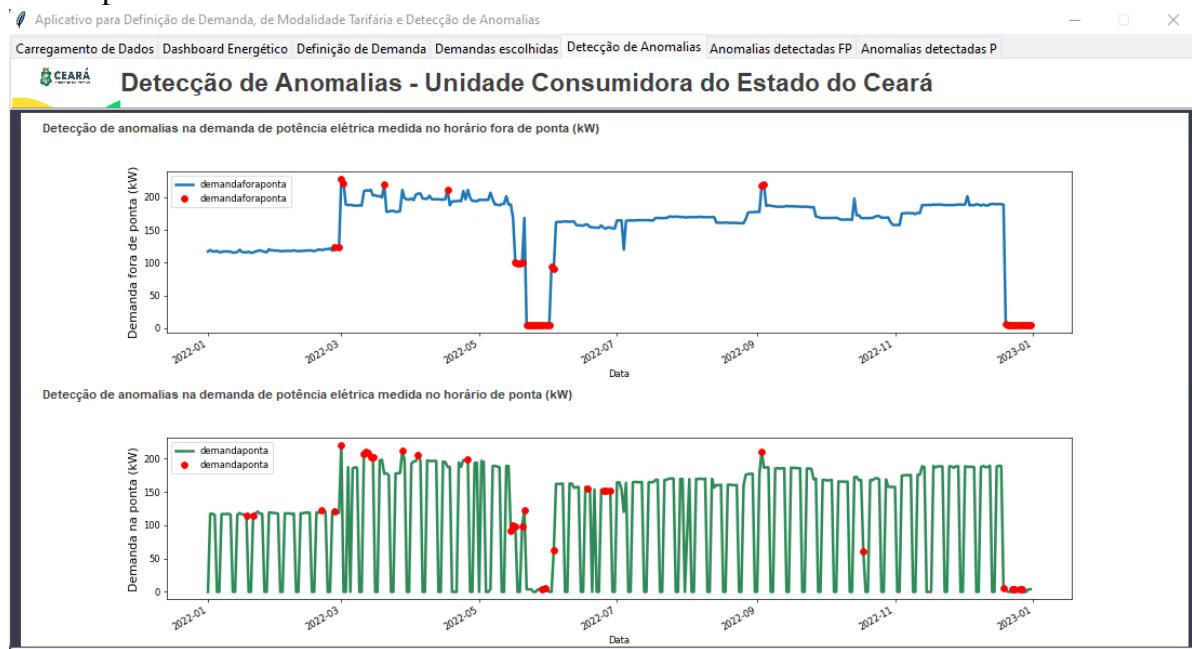
3. O espaço de dados do nó atual é dividido em 2 subespaços pelo ponto de corte P: o dado com a dimensão especificada menor que p é colocado à esquerda da subárvore do nó atual e o dado maior que ou igual a P é colocado na subárvore direita do nó atual;
4. Nos nós filhos, repete-se as etapas 2 e 3 para construir novos sub-nós até que apenas um nó de dados ou nó filho no nó filho atinge a altura definida.

Depois de obter várias árvores isoladas, o treinamento do algoritmo é finalizado. Em seguida, os dados de treinamento são detectados pela floresta isolada gerada. Para um conjunto de dados de treinamento x , ele percorre cada árvore isolada de acordo com as regras acima. A altura do nó filho final em que X é calculado. Pode-se calcular a média altura de X em cada árvore, como $E(H(x))$, e $h(x)$ é o número total de arestas do nó raiz da árvore isolada até nó x isolado. O grau de anormalidade pode ser expresso como 5.1. Na equação 5.2 tem-se o comprimento do caminho médio da árvore de pesquisa. $H(k) = \ln(k) + \xi$ em que ξ é a constante de Euler, Liu *et al.* (2008) e Mao *et al.* (2018).

$$S(X, n) = 2^{-E(h(X))C(n)} \quad (5.1)$$

$$C(n) = 2H(n-1) - (2(n-1)/n) \quad (5.2)$$

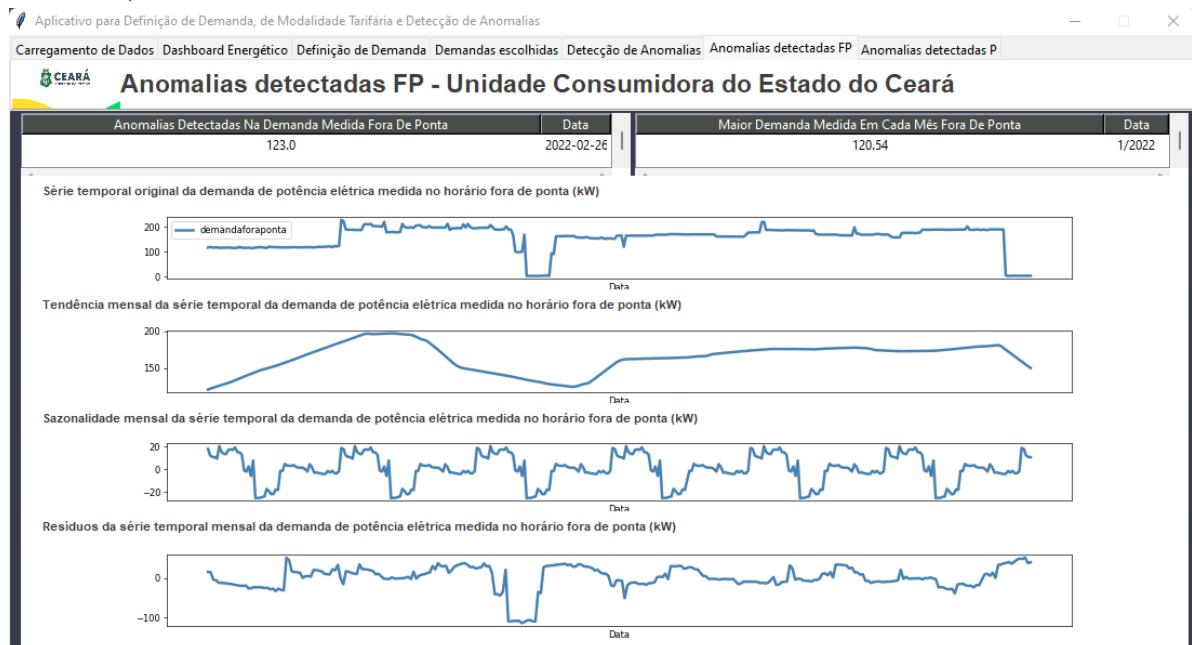
Figura 69 – Tela de visualização de detecção de anomalias nas demandas dos horários de ponta e fora de ponta.



Fonte: Próprio autor (2024).

Na Figura 70 é mostrada uma tela da aplicação que apresenta a série temporal da demanda elétrica fora de ponta, com a tendência, a sazonalidade e os resíduos da série temporal.

Figura 70 – Tela de visualização da demanda no horário fora de ponta, com sua respectiva tendência, sazonalidade e resíduos.

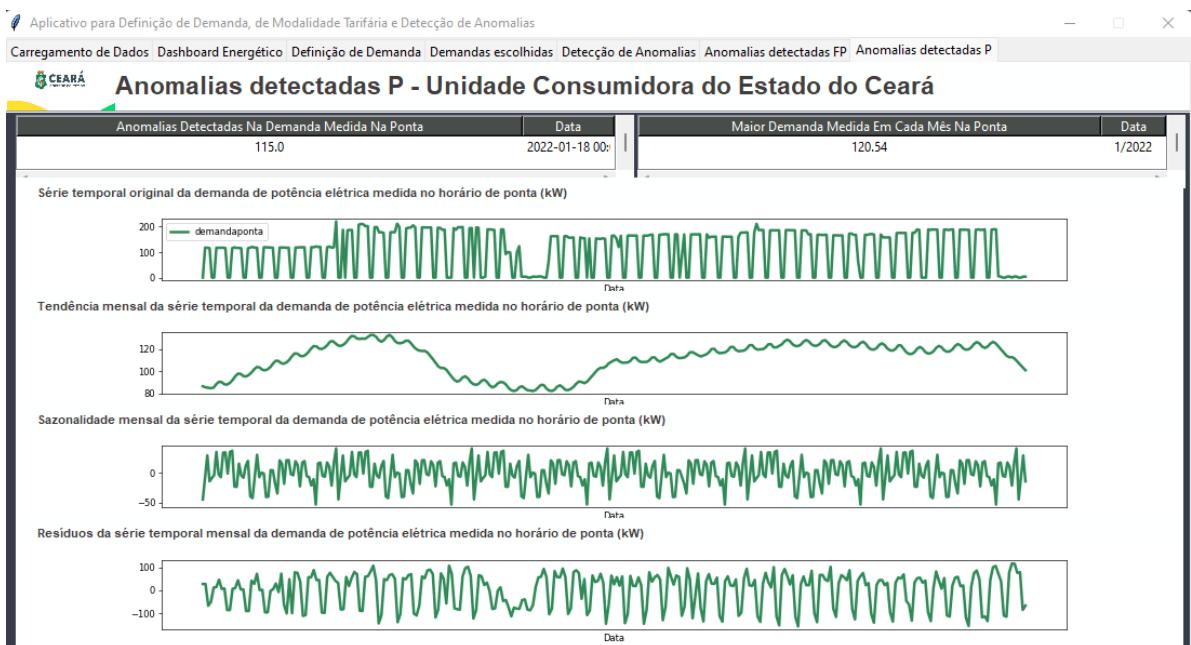


Fonte: Próprio autor (2024).

Na Figura 71 é mostrada uma tela da aplicação que apresenta a série temporal da

demandas elétricas fora de ponta, com a tendência, a sazonalidade e os resíduos da série temporal. Os resíduos podem indicar padrões irregulares, anômalos que não são capturados pela tendência e pela sazonalidade da série temporal, pois podem ser pontos aleatórios, que não se repetem da mesma forma no decorrer do tempo.

Figura 71 – Tela de visualização da demanda no horário de ponta, com sua respectiva tendência, sazonalidade e resíduos.



Fonte: Próprio autor (2024).

5.3 Considerações finais

Este capítulo descreve a criação da aplicação desktop proposta, a qual se destina ao carregamento de dados, análise de demanda e consumo de energia, bem como à proposição de uma demanda contratada mais adequada para determinado cliente. Além disso, a aplicação sugere a modalidade tarifária que resulta em menor custo para o consumidor. Entre as funcionalidades disponíveis na aplicação, destacam-se abas destinadas a análises estatísticas, decomposição da série temporal e detecção de anomalias. Dessa forma, a aplicação pode se mostrar altamente útil para a gestão da demanda de energia elétrica.

6 CONCLUSÕES, TRABALHOS FUTUROS E CRONOGRAMA DE CONTINUAÇÃO DO TRABALHO

Neste capítulo apresentam-se as conclusões desta tese, sugestões de trabalhos futuros e o cronograma de continuação do trabalho.

6.1 Conclusões

A pesquisa desenvolvida neste doutorado proporcionou uma análise abrangente e inovadora no contexto da gestão de demanda de energia elétrica. A detecção de anomalias nas demandas, a identificação de clientes anômalos por meio de clusterização, e a previsão de consumo utilizando séries temporais trouxeram contribuições significativas. A aplicação desktop desenvolvida demonstra a viabilidade prática desses métodos, permitindo a escolha da melhor modalidade tarifária, análise estatística detalhada, valor adequado de demanda contratada e detecção eficaz de anomalias. A utilização de séries temporais para prever o consumo de novas unidades e a análise da correlação através dos coeficientes de Pearson e Spearman entre essas séries ampliam a compreensão do comportamento energético, proporcionando insights valiosos para a gestão eficiente da demanda. Esses resultados evidenciam a relevância e o potencial inovador dessa abordagem no contexto da auditoria energética e gestão de energia elétrica.

Os objetivos do trabalho foram alcançados, pois os métodos de análise de séries temporais, correlação, clusterização e previsão, combinados, contribuem significativamente para a gestão inteligente da demanda de energia elétrica. Detectando irregularidades no consumo e na demanda de clientes de energia, agrupando clientes anômalos, separando grupos de acordo com padrões de comportamento de tendência e sazonalidade. As métricas de avaliações dos erros de previsões dos modelos também mostram que a utilização de séries temporais de unidades consumidoras consolidadas e com padrões bem definidos e repetitivos de um determinado grupo como variáveis exógenas para prever o consumo de outras unidades do mesmo grupo, podem melhorar os resultados das previsões. Além disso, a metodologia aplicada, com aplicação de vários métodos, permite a escolha adequada do valor de demanda contratada que se encaixa com o perfil de consumo de determinado cliente.

O estudo evidenciou que os gastos com energia elétrica das unidades públicas avaliadas poderiam ser diminuídos em cerca de 2,7 milhões de reais ao longo de um ano. Esta tese oferece uma contribuição relevante para o aprimoramento da gestão eficiente da demanda energética, ao empregar métodos avançados de análise de séries temporais, agrupamento de

dados e técnicas de previsão, com foco na maximização da eficiência operacional e econômica no contexto do setor elétrico.

Em síntese, este trabalho não apenas apresenta resultados concretos e aplicáveis, mas também estabelece a união de métodos e inovação que combinados podem contribuir para a gestão de energia elétrica. As contribuições dessa pesquisa não apenas respondem aos desafios contemporâneos do setor, mas também abrem caminhos para futuras investigações e melhorias na eficiência operacional e econômica do sistema elétrico.

6.2 Trabalhos futuros

Com a intenção de possibilitar o seguimento dos estudos relacionados ao trabalho desenvolvido, são sugeridos alguns temas para trabalhos futuros:

1. Criar um modelo de previsão de demanda;
2. Estudo da energia reativa e do fator de potência das unidades consumidoras. Buscar coletar além dos dados de consumo ativo e reativo, dados de equipamentos das instalações, visando otimizar a eficiência do consumo de energia;
3. Sugerir a migração das unidades consumidoras para o mercado livre de energia. Tendo em vista que já se conhece os padrões de consumo dos clientes e os níveis adequados de demanda contratada. Assim pode-se negociar os preços de energia de acordo com o consumo requerido pela unidade e receber descontos nos valores de demanda contratada, nos casos de consumidor livre com energia de fonte incentivada;
4. Desenvolvimento de modelos híbridos. Modelos híbridos que combinem diferentes abordagens de previsão, como técnicas estatísticas tradicionais e métodos baseados em aprendizado de máquina;
5. Criação de um sistema baseado em visão computacional para análise e detecção de anomalias em imagens de gráficos de demanda ativa, demanda reativa, consumo e fator de potência, advindas da telemedição da concessionária de energia;
6. Aprimoramento da interface de usuário e mais funcionalidades da aplicação desktop.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução homologatoria 3.026**, de 19 de abril de 2022. Disponível em: <https://www2.aneel.gov.br/cedoc/reh20223026ti.pdf>. Acesso em: 27 de outubro 2023.

AIELLO, M.; PAGANI, G. A. The smart grid's data generating potentials. In: IEEE. **2014 FEDERATED CONFERENCE ON COMPUTER SCIENCE AND INFORMATION SYSTEMS**. [S. l.], 2014. p. 9–16.

ALAHAKOON, D.; YU, X. Advanced analytics for harnessing the power of smart meter big data. In: IEEE. 2013. **IEEE INTERNATIONAL WORKSHOP ON INTELLIGENT ENERGY SYSTEMS (IWIES)**. [S. l.], 2013. p. 40–45.

ALONSO, J. B. **K-Means vs mini batch k-means**: a comparison. Barcelona, 2013.

ALQUTHAMI, T.; ZULFIQAR, M.; KAMRAN, M.; MILYANI, A. H.; RASHEED, M. B. A. Performance comparison of machine learning algorithms for load forecasting in smart grid. **IEEE Access**, IEEE, v. 10, p. 48419–48433, 2022.

Amazon Web Services. **"How the DeepAR Algorithm Works"**. 2023. Disponível em: https://docs.aws.amazon.com/sagemaker/latest/dg/deepar_how-it-works.html. Acesso em: 20 de outubro 2023.

Amazon Web Services. **What is Anomaly Detection?**. 2023. Disponível em: <https://aws.amazon.com/what-is/anomaly-detection/#:~:text=Anomaly%20detection%20is%20examining%20specific,increases%20manual%20tracking%20is%20impractical..> Acesso em: 20 de outubro 2023.

AMIN, P.; CHERKASOVA, L.;AITKEN, R.; KACHE, V. Analysis and demand forecasting of residential energy consumption at multiple time scales. In: IEEE. **2019 IFIP/IEEE SYMPOSIUM ON INTEGRATED NETWORK AND SERVICE MANAGEMENT (IM)**. [S. l.], 2019. p. 494–499.

ANEEL. **Modalidades Tarifárias**. 2022. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/tarifas/entenda-a-tarifa/modalidades-tarifarias>. Acesso em: 9 de dezembro 2023.

ANEEL. **Módulo 7: Estrutura Tarifária das Concessionárias de Distribuição**. 2022. Disponível em: https://www2.aneel.gov.br/cedoc/aren20221003_Proret_Submod_7_1_V2_5C.pdf. Acesso em: 9 de dezembro 2023.

ANEEL. **Tarifa Branca**. 2022. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/tarifas/tarifa-branca>. Acesso em: 10 de dezembro 2023.

ARGUN, H.; ALPTEKİN, S. E. Variational autoencoder-based anomaly detection in time series data for inventory record inaccuracy. **Turkish Journal of Electrical Engineering and Computer Sciences**, v. 31, n. 1, p. 163–179, 2023.

ARIYO, A. A.; ADEWUMI, A. O.; AYO, C. K. Stock price prediction using the arima model. In: IEEE. **2014 UKSIM-AMSS 16TH INTERNATIONAL CONFERENCE ON COMPUTER MODELLING AND SIMULATION**. [S. l.], 2014, p. 106–112.

- ASRI, M. A. N. M.; ZAINI, N.; LATIP, M. F. A. Development of an lstm-based model for energy consumption prediction with data pre-analysis. In: IEEE. **2021 11TH IEEE INTERNATIONAL CONFERENCE ON CONTROL SYSTEM, COMPUTING AND ENGINEERING (ICCSCE)**. [S. l.], 2021, p. 228–233.
- BASHA, S. J.; AMMANNAMMA, T.; VIVEK, K.; VEESAM, V. S. Comparative analysis of time series forecasting models to predict amount of rainfall in telangana. In: IEEE. **2022 8TH INTERNATIONAL CONFERENCE ON ADVANCED COMPUTING AND COMMUNICATION SYSTEMS (ICACCS)**. [S. l.], v. 1, 2022, p. 1918–1922.
- BENVENUTO, D.; GIOVANETTI, M.; VASSALLO, L.; ANGELETTI, S.; CICCOZZI, M. Application of the arima model on the covid-2019 epidemic dataset. **Data in brief**, Elsevier, v. 29, p. 105340, 2020.
- BUDDHAHAI, B.; WONGSEREE, W.; RAKKWAMSUK, P. An energy prediction approach for a nonintrusive load monitoring in home appliances. **IEEE Transactions on Consumer Electronics**, IEEE, v. 66, n. 1, p. 96–105, 2019.
- CALIŃSKI, T.; HARABASZ, J. A dendrite method for cluster analysis. **Communications in Statistics-theory and Methods**, Taylor & Francis, v. 3, n. 1, p. 1–27, 1974.
- CAPEHART, B. L.; TURNER, W. C.; KENNEDY, W. J. *et al.* **Guide to Energy Management 7th Edition**. [S. l.]: Lulu Press, Inc, 2013.
- CEPEL. **gui a para eficiênc a energética nas edificações públicas. 2015. Disponível em:** <https://www.gov.br/mme/pt-br/arquivos/guia-para-eficiencia-energetica-nas-edificacoes-publicas.pdf>. **Acesso em:** 9 de dezembro 2023.
- ÇETINKAYA, Ü.; AVCI, E.; BAYINDIR, R. Time series clustering analysis of energy consumption data. In: IEEE. **2020 9TH INTERNATIONAL CONFERENCE ON RENEWABLE ENERGY RESEARCH AND APPLICATION (ICRERA)**. [S. l.], 2020. p. 409–413.
- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae). **Geoscientific model development discussions**, v. 7, n. 1, p. 1525–1534, 2014.
- CHANG, Y.-C.; YANG, H.; KONG, S. Based on mini batch k-means clustering for customer segmentation in e-commerce. In: IEEE. **2022 INTERNATIONAL CONFERENCE ON CLOUD COMPUTING, BIG DATA AND INTERNET OF THINGS (3CBIT)**. [S. l.], 2022. p. 60–66.
- CHEADLE, C.; VAWTER, M. P.; FREED, W. J.; BECKER, K. G. Analysis of microarray data using z score transformation. **The Journal of molecular diagnostics**, Elsevier, v. 5, n. 2, p. 73–81, 2003.
- CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. **PeerJ Computer Science**, PeerJ Inc., v. 7, p. e623, 2021.
- CHOU, J.-S.; NGO, N.-T. Smart grid data analytics framework for increasing energy savings in residential buildings. **Automation in construction**, Elsevier, v. 72, p. 247–257, 2016.

- CHUANG, M.; YIKUAI, W.; JUNDA, Z.; KE, C.; FEIXIANG, G.; TAO, C.; SONGSONG, C. Research on user electricity consumption behavior and energy consumption modeling in big data environment. In: IEEE. **2021 IEEE 2ND INTERNATIONAL CONFERENCE ON BIG DATA, ARTIFICIAL INTELLIGENCE AND INTERNET OF THINGS ENGINEERING (ICBAIE)**. [S. l.], 2021, p. 220–224.
- CORREA, E.; INGA, E.; INGA, J.; HINCAPIE, R. Patrón de consumo eléctrico basado en el sistema de gestión de datos medidos usando técnicas de big data. In: **PROCEEDINGS-2017 INTERNATIONAL CONFERENCE ON INFORMATION SYSTEMS AND COMPUTER SCIENCE, INCISCOS 2017**. [S. l.: s. n.], 2018.
- DANG, H.-A.; DAO, V.-D.; DANG, C.-D.; NGUYEN, N. H.; HOANG, A. Identifying abnormal energy consumption patterns in industrial settings: Application of local outlier factor algorithm for a processing factory in vietnam. In: IEEE. **2023 ASIA MEETING ON ENVIRONMENT AND ELECTRICAL ENGINEERING (EEE-AM)**. [S. l.], 2023, p. 1–5.
- Data Science Academy. "**Deep Learning Book**". 2022. Disponível em: <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/#:~:text=A%20LSTM%20Ãl'%20uma%20arquitetura,de%20tempo%20de%20duraÃgÃcÃo%20desconhecida..> Acesso em: 19 de outubro 2023.
- DAVIES, D. L.; BOULDIN, D. W. A cluster separation measure. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, n. 2, p. 224–227, 1979.
- DUBEY, A. K.; KUMAR, A.; GARCÍA-DÍAZ, V.; SHARMA, A. K.; KANHAIYA, K. Study and analysis of sarima and lstm in forecasting time series data. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 47, p. 101474, 2021.
- ELSARAITI, M.; ALI, G.; MUSBAH, H.; MERABET, A.; LITTLE, T. Time series analysis of electricity consumption forecasting using arima model. In: IEEE. **2021 IEEE GREEN TECHNOLOGIES CONFERENCE (GREENTECH)**. 2021, [S. l.], p. 259–262.
- ESTEVES, T. **Extraindo representações com autoencoders convolucionais**. 2020. Disponível em: <https://estevestoni.medium.com/extraindo-representaÃgÃues-com-autoencoders-convolucionais-405ab73afa05>. Acesso em: 5 de dezembro, 2023.
- Facebook. "**Forecasting at Scale**". 2023. Disponível em: <https://facebook.github.io/prophet/>. Acesso em: 19 de outubro 2023.
- FAN, L.; FU, C.; GUO, Y.; WANG, Y.; WU, M.; SUN, L. Prediction and analysis of power user energy consumption based on demand side management. In: IEEE. **2022 4TH INTERNATIONAL CONFERENCE ON POWER AND ENERGY TECHNOLOGY (ICPET)**. [S. l.], 2022 p. 932–937.
- FARUK, D. Ö. A hybrid neural network and arima model for water quality time series prediction. **Engineering applications of artificial intelligence**, Elsevier, v. 23, n. 4, p. 586–594, 2010.
- FATTAH, J.; EZZINE, L.; AMAN, Z.; MOUSSAMI, H. E.; LACHHAB, A. Forecasting of demand using arima model. **International Journal of Engineering Business Management**, SAGE Publications Sage UK: London, England, v. 10, p. 184, 2018.

FEIZOLLAH, A.; ANUAR, N. B.; SALLEH, R.; AMALINA, F. Comparative study of k-means and mini batch k-means clustering algorithms in android malware detection using network traffic analysis. In: IEEE. **2014 INTERNATIONAL SYMPOSIUM ON BIOMETRICS AND SECURITY TECHNOLOGIES (ISBAST)**. [S. l.], 2014, p. 193–197.

FONTANINI, A. D.; ABREU, J. A data-driven birch clustering method for extracting typical load profiles for big data. In: IEEE. **2018 IEEE POWER & ENERGY SOCIETY GENERAL MEETING (PESGM)**. [S. l.], 2018. p. 1–5.

GAL, M. S.; RUBINFELD, D. L. Data standardization. **NYUL Rev.**, HeinOnline, v. 94, p. 737, 2019.

GONG, F.; HAN, N.; LI, D.; TIAN, S. Trend analysis of building power consumption based on prophet algorithm. In: IEEE. **2020 ASIA ENERGY AND ELECTRICAL ENGINEERING SYMPOSIUM (AEEES)**. [S. l.], 2020, p. 1002–1006.

GRAVES, A. **Generating sequences with recurrent neural networks**. Springer, 2013.

GRAVES, A.; GRAVES, A. Long short-term memory. **Supervised sequence labelling with recurrent neural networks**, Springer, p. 37–45, 2012.

Grupo Python - UNESP. "Introdução a Python - Módulo C". 2005. Disponível em: <https://www.dcc.ufrj.br/~fabiom/mab225/tutorialkinter.pdf>. Acesso em: 6 de novembro 2023.

HAJJAJI, I.; ALAMI, H. E.; ALAMI, R. E.; DAHMOUNI, H. Energy consumption characterization in university campus microgrid based on power data analysis. In: IEEE. **2022 9TH INTERNATIONAL CONFERENCE ON FUTURE INTERNET OF THINGS AND CLOUD (FICLOUD)**. [S. l.], 2022, p. 107–112.

HAN, J.; PEI, J.; TONG, H. **Data mining: concepts and techniques**. [S. l.]: Morgan kaufmann, 2022.

HAN, X.; ZHANG, C.; TANG, Y.; YE, Y. Physical-data fusion modeling method for energy consumption analysis of smart building. **Journal of Modern Power Systems and Clean Energy**, SGPRI, v. 10, n. 2, p. 482–491, 2022.

HARVEY, A. C.; PETERS, S. Estimation procedures for structural time series models. **Journal of forecasting**, Wiley Online Library, v. 9, n. 2, p. 89–108, 1990.

HE, Y.-L.; QIN, H.-L.; HUANG, J. Z.; JIN, Y. Novel electricity pattern identification system based on improved i-nice algorithm. **Computers & Industrial Engineering**, Elsevier, v. 150, p. 106908, 2020.

HILLMER, S. C.; TIAO, G. C. An arima-model-based approach to seasonal adjustment. **Journal of the American Statistical Association**, Taylor & Francis, v. 77, n. 377, p. 63–70, 1982.

HINTON, G. E.; ROWEIS, S. Stochastic neighbor embedding. **Advances in neural information processing systems**, v. 15, 2002.

HO, S. L.; XIE, M. The use of arima models for reliability forecasting and analysis. **Computers & industrial engineering**, Elsevier, v. 35, n. 1-2, p. 213–216, 1998.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT press, v. 9, n. 8, p. 1735–1780, 1997.

- HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of educational psychology**, Warwick & York, v. 24, n. 6, p. 417, 1933.
- HU, Y.-C. Electricity consumption prediction using a neural-network-based grey forecasting approach. **Journal of the Operational Research Society**, Springer, v. 68, p. 1259–1264, 2017.
- IWANOWSKI, D. Correlation between wind and solar renewable energy generation and electricity consumption in poland, derived to estimate the energy storage needs. In: IEEE. **2018 14TH SELECTED ISSUES OF ELECTRICAL ENGINEERING AND ELECTRONICS (WZEE)**. [S. l.], 2018. p. 1–4.
- JANGID, B.; MATHRURIA, P.; GUPTA, V. Load profile segmentation of various load categories using clustering. In: IEEE. **2021 IEEE 2ND INTERNATIONAL CONFERENCE ON ELECTRICAL POWER AND ENERGY SYSTEMS (ICEPES)**. [S. l.], 2021, p. 1–6.
- JIN, B.; ZHAO, Y.; NI, J. Sustainable transport in a smart city: Prediction of short-term parking space through improvement of lstm algorithm. **Applied Sciences**, MDPI, v. 12, n. 21, p. 11046, 2022.
- JR, J. H. W. Hierarchical grouping to optimize an objective function. **Journal of the American statistical association**, Taylor & Francis, v. 58, n. 301, p. 236–244, 1963.
- KAVASSERI, R. G.; SEETHARAMAN, K. Day-ahead wind speed forecasting using f-arima models. **Renewable Energy**, Elsevier, v. 34, n. 5, p. 1388–1393, 2009.
- KETCHEN, D. J.; SHOOK, C. L. The application of cluster analysis in strategic management research: an analysis and critique. **Strategic management journal**, Wiley Online Library, v. 17, n. 6, p. 441–458, 1996.
- KHAN, I. U.; JAVAID, N.; TAYLOR, C. J.; GAMAGE, K. A.; MA, X. Big data analytics based short term load forecasting model for residential buildings in smart grids. In: IEEE. **IEEE INFOCOM 2020-IEEE CONFERENCE ON COMPUTER COMMUNICATIONS WORKSHOPS (INFOCOM WKSHPS)**. [S. l.], 2020 p. 544–549.
- KHAN, W.; WALKER, S.; ZEILER, W. A bottom-up framework for analysing city-scale energy data using high dimension reduction techniques. **Sustainable Cities and Society**, Elsevier, v. 89, p. 104323, 2023.
- KINDALKAR, S. S.; ITAGI, A. R.; KAPPALI, M.; KARAJGI, S. Time series based short term load forecasting using prophet for distribution system. In: IEEE. **2022 INTERNATIONAL CONFERENCE ON SMART GENERATION COMPUTING, COMMUNICATION AND NETWORKING (SMART GENCON)**. [S. l.], 2022, p. 1–6.
- KONG, X.; HU, C.; DUAN, Z. **Principal component analysis networks and algorithms**. [S. l.]: Springer, 2017.
- KULLBACK, S.; LEIBLER, R. A. On information and sufficiency. **The annals of mathematical statistics**, JSTOR, v. 22, n. 1, p. 79–86, 1951.
- LI, J.; WU, D.; JIN, W.; CHU, Z.; LIU, S.; MA, J.; LIN, Z.; YANG, L. Identification of distribution network topology parameters based on multidimensional operation data. **Energy Reports**, Elsevier, v. 7, p. 304–311, 2021.

- LIU, F. T.; TING, K. M.; ZHOU, Z.-H. Isolation forest. In: IEEE. **2008 EIGHTH IEEE INTERNATIONAL CONFERENCE ON DATA MINING**. [S. l.], 2008. p. 413–422.
- LIU, J.; ZHAO, J.; CHEN, Y.; LI, H.; HUANG, Q.; OUYANG, H.; HAO, Q.; LU, Y. Analysis of customers' electricity consumption behavior based on massive data. In: IEEE. **2016 12th INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY (ICNC-FSKD)**. [S. l.], 2016, p. 1433–1438.
- LIU, S.; YAN, L.; WU, Y. Multi-dimensional energy efficiency assessment of residential users based on big data analysis of differentiated electricity consumption behavior. In: IEEE. **2020 IEEE 9TH JOINT INTERNATIONAL INFORMATION TECHNOLOGY AND ARTIFICIAL INTELLIGENCE CONFERENCE (ITAIC)**. [S. l.], v. 9, 2020, p. 1295–1300.
- LIU, Y.; WANG, W.; GHADIMI, N. Electricity load forecasting by an improved forecast engine for building level consumers. **Energy**, Elsevier, v. 139, p. 18–30, 2017.
- LLOYD, S. Least squares quantization in pcm. **IEEE transactions on information theory**, IEEE, v. 28, n. 2, p. 129–137, 1982.
- LUKÁCS, A. K.; UNGUREANU, S.; CZIKER, A. C.; MIRON, A. Forecasting the electricity balance of a small manufacturer with photovoltaic production using machine learning. In: IEEE. **2023 10TH INTERNATIONAL CONFERENCE ON MODERN POWER SYSTEMS (MPS)**. [S. l.], 2023, p. 1–6.
- MAATEN, L. Van der; HINTON, G. Visualizing data using t-sne. **Journal of machine learning research**, v. 9, n. 11, 2008.
- MAHIA, F.; DEY, A. R.; MASUD, M. A.; MAHMUD, M. S. Forecasting electricity consumption using arima model. In: IEEE. **2019 INTERNATIONAL CONFERENCE ON SUSTAINABLE TECHNOLOGIES FOR INDUSTRY 4.0 (STI)**. [S. l.], 2019, p. 1–6.
- MAO, W.; CAO, X.; YAN, T.; ZHANG, Y. *et al.* Anomaly detection for power consumption data based on isolated forest. In: IEEE. **2018 INTERNATIONAL CONFERENCE ON POWER SYSTEM TECHNOLOGY (POWERCON)**. [S. l.], 2018, p. 4169–4174.
- MARUTHO, D.; HANDAKA, S. H.; WIJAYA, E. *et al.* The determination of cluster number at k-mean using elbow method and purity evaluation on headline news. In: IEEE. **2018 INTERNATIONAL SEMINAR ON APPLICATION FOR TECHNOLOGY OF INFORMATION AND COMMUNICATION**. [S. l.], 2018, p. 533–538.
- MINISTÉRIO DA EDUCAÇÃO. **Como analisar gastos com energia elétrica**. 2019. Disponível em:
https://antigo.comprasgovernamentais.gov.br/images/delog/files/cartilha_energia_web2110.pdf. Acesso em: 10 de dezembro 2023.
- MEHRA, P.; AHUJA, M. S.; AERI, M. Time series anomaly detection system with linear neural network and autoencoder. In: IEEE. **2023 INTERNATIONAL CONFERENCE ON DEVICE INTELLIGENCE, COMPUTING AND COMMUNICATION TECHNOLOGIES (DICCT)**. [S. l.], 2023, p. 659–662.

MME/ANEEL. "RESOLUÇÃO NORMATIVA ANEEL Nº 1.000, DE 7 DE DEZEMBRO DE 2021". 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-1.000-de-7-de-dezembro-de-2021-368359651>. Acesso em: 18 de outubro 2023.

MME/ANEEL. **Postos Tarifários**. 2022. Disponível em: <https://www.gov.br/aneel/pt-br/assuntos/tarifas/entenda-a-tarifa/postos-tarifarios>. Acesso em: 9 de dezembro 2023.

MYTTENAERE, A. D.; GOLDEN, B.; GRAND, B. L.; ROSSI, F. Mean absolute percentage error for regression models. **Neurocomputing**, Elsevier, v. 192, p. 38–48, 2016.

NAIK, G. R. **Advances in principal component analysis: research and development**. [S. l.]: Springer, 2017.

NAM, H.-S.; JEONG, Y.-K.; PARK, J. W. An anomaly detection scheme based on lstm autoencoder for energy management. In: IEEE. **2020 INTERNATIONAL CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGY CONVERGENCE (ICTC)**. [S. l.], 2020, p. 1445–1447.

NASCIMENTO, J.; PINTO, T.; VALE, Z. Day-ahead electricity market price forecasting using artificial neural network with spearman data correlation. In: IEEE. **2019 IEEE MILAN POWERTECH**. [S. l.], 2019, p. 1–6.

NEWBOLD, P. Arima model building and the time series analysis approach to forecasting. **Journal of forecasting**, Wiley Online Library, v. 2, n. 1, p. 23–35, 1983.

NICHIFOROV, C.; STAMATESCU, I.; FĂRĂAŞAN, I.; STAMATESCU, G. Energy consumption forecasting using arima and neural network models. In: IEEE. **2017 5TH INTERNATIONAL SYMPOSIUM ON ELECTRICAL AND ELECTRONICS ENGINEERING (ISEEE)**. [S. l.], 2017, p. 1–4.

NUMBI, B.; MALINGA, S.; CHIDZONGA, R.; MULANGU, T. Energy cost saving potential in educational buildings-case study of mut campus. In: IEEE. **2017 INTERNATIONAL CONFERENCE ON THE INDUSTRIAL AND COMMERCIAL USE OF ENERGY (ICUE)**. [S. l.], 2017, p. 1–5.

OORD, A. v. d.; DIELEMAN, S.; ZEN, H.; SIMONYAN, K.; VINYALS, O.; GRAVES, A.; KALCHBRENNER, N.; SENIOR, A.; KAVUKCUOGLU, K. Wavenet: A generative model for raw audio. **arXiv preprint arXiv:1609.03499**, 2016.

OSTERTAGOVA, E.; OSTERTAG, O. Forecasting using simple exponential smoothing method. **Acta Electrotechnica et Informatica**, De Gruyter Open Sp. z oo, v. 12, n. 3, p. 62, 2012.

PATEL, R. K.; KUMARI, A.; TANWAR, S.; HONG, W.-C.; SHARMA, R. Ai-empowered recommender system for renewable energy harvesting in smart grid system. **IEEE Access**, IEEE, v. 10, p. 24316–24326, 2022.

PATIÑO, A.; PEÑA, A.; HOYOS, S.; ESCUDERO, A. C. Automatic identification of self-generation points in time series of electricity consumption: Granular anomaly detection. In: IEEE. **2021 16TH IBERIAN CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES (CISTI)**. [S. l.], 2021, p. 1–5.

PEARSON, K. Liii. on lines and planes of closest fit to systems of points in space. **The London, Edinburgh, and Dublin philosophical magazine and journal of science**, Taylor & Francis, v. 2, n. 11, p. 559–572, 1901.

PEARSON, K. On a new method of determining correlation between a measured character a, and a character b, of which only the percentage of cases wherein b exceeds (or falls short of) a given intensity is recorded for each grade of a. **Biometrika**, JSTOR, v. 7, n. 1/2, p. 96–105, 1909.

PERNER, P. **Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin, Germany, July 13-20, 2012, Proceedings**. [S. l.]: Springer, v. 7376, 2012.

PROVOTAR, O. I.; LINDER, Y. M.; VERES, M. M. Unsupervised anomaly detection in time series using lstm-based autoencoders. In: IEEE. **2019 IEEE INTERNATIONAL CONFERENCE ON ADVANCED TRENDS IN INFORMATION THEORY (ATIT)**. [S. l.], 2019, p. 513–517.

PYTHON SOFTWARE FOUNDATION. "**Python interface to Tcl/Tk**". 2023. Disponível em: <https://docs.python.org/3/library/tkinter.html>. Acesso em: 6 de novembro 2023.

QU, H.; LING, P.; WU, L. Electricity consumption analysis and applications based on smart grid big data. In: IEEE. **2015 IEEE 12TH INTL CONF ON UBIQUITOUS INTELLIGENCE AND COMPUTING AND 2015 IEEE 12TH INTL CONF ON AUTONOMIC AND TRUSTED COMPUTING AND 2015 IEEE 15TH INTL CONF ON SCALABLE COMPUTING AND COMMUNICATIONS AND ITS ASSOCIATED WORKSHOPS (UIC-ATC-SCALCOM)**. [S. l.], 2015, p. 923–928.

RASCHKA, S.; MIRJALILI, V. **Python machine learning second edition**. [S. l.]: Packt Publishing, 2017.

ROSENlund, G. H.; HØIEM, K. W.; TORSÆTER, B. N.; ANDRESEN, C. A. Clustering and dimensionality-reduction techniques applied on power quality measurement data. In: IEEE. **2020 INTERNATIONAL CONFERENCE ON SMART ENERGY SYSTEMS AND TECHNOLOGIES (SEST)**. [S. l.], 2020, p. 1–6.

ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of computational and applied mathematics**, Elsevier, v. 20, p. 53–65, 1987.

SAGIROGLU, S.; SINANC, D. Big data: A review. In: IEEE. **2013 international conference on collaboration technologies and systems (CTS)**. [S. l.], 2013, p. 42–47.

SAHAGUN, M. A. M.; CAPARAS, A. T.; GOMEZ, R. Assessment and forecasting of electric load demand of don honorio ventura technological state university. In: IEEE. **2018 IEEE 10TH INTERNATIONAL CONFERENCE ON HUMANOID, NANOTECHNOLOGY, INFORMATION TECHNOLOGY, COMMUNICATION AND CONTROL, ENVIRONMENT AND MANAGEMENT (HNICEM)**. [S. l.], 2018, p. 1–6.

SALINAS, D.; FLUNKERT, V.; GASTHAUS, J.; JANUSCHOWSKI, T. Deepar: Probabilistic forecasting with autoregressive recurrent networks. **International Journal of Forecasting**, Elsevier, v. 36, n. 3, p. 1181–1191, 2020.

- SAUHATS, A.; VARFOLOMEJEVA, R.; LMKEVICS, O.; PETRECENKO, R.; KUNICKIS, M.; BALODIS, M. Analysis and prediction of electricity consumption using smart meter data. In: **IEEE. 2015 IEEE 5TH INTERNATIONAL CONFERENCE ON POWER ENGINEERING, ENERGY AND ELECTRICAL DRIVES (POWERENG).** [S. l.], 2015, p. 17–22.
- SCHNEIDER, R. D. Hadoop for dummies special edition. **John Wiley&Sons Canada**, p. 978–1, 2012.
- SCULLEY, D. Web-scale k-means clustering. In: **Proceedings of the 19th international conference on World wide web.** [S. l.: s. n.], 2010, p. 1177–1178.
- SHVEDOV, G. V.; MORSIN, I. A.; DEMIDENKO, A. S.; KUDELINA, S. A.; PARFENOV, G. A. Analysis of the maximum electrical load of multi-apartment residential buildings in the power supply systems of cities. In: **IEEE. 2022 4TH INTERNATIONAL YOUTH CONFERENCE ON RADIO ELECTRONICS, ELECTRICAL AND POWER ENGINEERING (REEPE).** [S. l.], 2022, p. 1–5.
- SIAS, Q. A.; LIM, S.; GANTASSI, R.; CHOI, Y. Implementation of single and multi linear regression for prediction of energy consumption based on previous data of energy production. In: **IEEE. 2023 INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE IN INFORMATION AND COMMUNICATION (ICAIIC).** [S. l.], 2023, p. 830–832.
- SONG, D.; XIA, N.; CHENG, W.; CHEN, H.; TAO, D. Deep r-th root of rank supervised joint binary embedding for multivariate time series retrieval. In: **PROCEEDINGS OF THE 24TH ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING.** [S. l.: s. n.], 2018, p. 2229–2238.
- SOWELL, F. Modeling long-run behavior with the fractional arima model. **Journal of monetary economics**, Elsevier, v. 29, n. 2, p. 277–302, 1992.
- SPEARMAN, C. **The proof and measurement of association between two things.** Appleton-Century-Crofts, 1961.
- STUDENT. The probable error of a mean. **Biometrika**, Oxford University Press, v. 6, n. 1, p. 1–25, 1908.
- SULAIMAN, S.; JEYANTHY, P. A.; DEVARAJ, D. Artificial neural network based day ahead load forecasting using smart meter data. In: **IEEE. 2016 BIENNIAL INTERNATIONAL CONFERENCE ON POWER AND ENERGY SYSTEMS: TOWARDS SUSTAINABLE ENERGY (PESTSE).** [S. l.], 2016, p. 1–6.
- SUTSKEVER, I.; VINYALS, O.; LE, Q. V. Sequence to sequence learning with neural networks. **Advances in neural information processing systems**, v. 27, 2014.
- TANG, Z.; CUI, Y.; XING, J.; HUANG, J.; JIN, J.; TANG, Y.; WU, F. Comparison of k-means and hierarchical clustering used in power consumption analysis. In: **IEEE. 2022 IEEE 6TH CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION (EI2).** [S. l.], 2022, p. 1696–1700.

- TAO, X.; GANG, S.; NINGHUI, H.; KE, C.; JINDOU, Y.; JIANYONG, D.; SONGSONG, C. Power consumption behavior analysis for customer side flexible resources based on data mining. In: IEEE. **2021 IEEE 2ND INTERNATIONAL CONFERENCE ON BIG DATA, ARTIFICIAL INTELLIGENCE AND INTERNET OF THINGS ENGINEERING (ICBAIE)**. [S. l.], 2021, p. 1–4.
- TAYLOR, S. J.; LETHAM, B. Forecasting at scale. **The American Statistician**, Taylor & Francis, v. 72, n. 1, p. 37–45, 2018.
- TIAN, C.; MA, J.; ZHANG, C.; ZHAN, P. A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network. **Energies**, MDPI, v. 11, n. 12, p. 3493, 2018.
- TSENG, F.-M.; YU, H.-C.; TZENG, G.-H. Combining neural network model with seasonal time series arima model. **Technological forecasting and social change**, Elsevier, v. 69, n. 1, p. 71–87, 2002.
- TSOLAKI, K.; VAFEIADIS, T.; NIZAMIS, A.; IOANNIDIS, D.; TZOVARAS, D. Utilizing. Machine learning on freight transportation and logistics applications: A review. **ICT Express**, Elsevier, 2022.
- VIJAYAN, P. Energy consumption prediction in low energy buildings using machine learning and artificial intelligence for energy efficiency. In: IEEE. **2022 8TH INTERNATIONAL YOUTH CONFERENCE ON ENERGY (IYCE)**. [S. l.], 2022, p. 1–6.
- WANG, X.; LI, H.; YI, X.; KONG, J.; WANG, X. Analysis of user's power consumption behavior based on k-means. In: IEEE. **2022 4TH INTERNATIONAL CONFERENCE ON MACHINE LEARNING, BIG DATA AND BUSINESS INTELLIGENCE (MLBDBI)**. [S. l.], 2022, p. 39–42.
- WANG, X.; ZHAO, T.; LIU, H.; HE, R. Power consumption predicting and anomaly detection based on long short-term memory neural network. In: IEEE. **2019 IEEE 4TH INTERNATIONAL CONFERENCE ON CLOUD COMPUTING AND BIG DATA ANALYSIS (ICCCBDA)**. [S. l.], 2019, p. 487–491.
- WANG, Z.; BOVIK, A. C. Mean squared error: Love it or leave it? a new look at signal fidelity measures. **IEEE signal processing magazine**, IEEE, v. 26, n. 1, p. 98–117, 2009.
- WASHIZAWA, Y. Feature extraction using constrained approximation and suppression. **IEEE transactions on neural networks**, IEEE, v. 21, n. 2, p. 201–210, 2009.
- WEN, L.; ZHOU, K.; YANG, S.; LI, L. Compression of smart meter big data: A survey. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 91, p. 59–69, 2018.
- WIJAYA, T. K.; VASIRANI, M.; HUMEAU, S.; ABERER, K. Cluster-based aggregate forecasting for residential electricity demand using smart meter data. In: IEEE. **2015 IEEE INTERNATIONAL CONFERENCE ON BIG DATA (Big data)**. [S. l.], 2015, p. 879–887.
- YAN, Y. Research on biological image time series change prediction analysis based on deepar forecasting algorithm. In: IEEE. **2023 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING AND COMPUTER APPLICATIONS (ICIPCA)**. [S. l.], 2023, p. 1511–1515.

- YOO, Y.-S.; LEE, I.-W. Toward preference of energy consumption information in multi-family housing complexes. In: IEEE. **2013 INTERNATIONAL CONFERENCE ON ICT CONVERGENCE (ICTC)**. [S. l.], 2013, p. 789–791.
- ZAINAL, N. H. B.; SAID, D. B. M.; YUNUS, A.-M. F. bin; SARIJARI, M. A. bin; YUNUS, M. S. bin M. Development of power quality analysis using labview. In: IEEE. **2022 IEEE INTERNATIONAL CONFERENCE ON POWER AND ENERGY (PECon)**. [S. l.], 2022, p. 192–196.
- ZHANG, C.; CHEN, Y. Time series anomaly detection with variational autoencoders. **arXiv preprint arXiv:1907.01702**, v. 70, 2019.
- ZHANG, Q.; LEUNG, Y. W. A class of learning algorithms for principal component analysis and minor component analysis. **IEEE Transactions on Neural Networks**, IEEE, v. 11, n. 1, p. 200–204, 2000.
- ZHANG, T.; RAMAKRISHNAN, R.; LIVNY, M. Birch: an efficient data clustering method for very large databases. **ACM sigmod record**, ACM New York, NY, USA, v. 25, n. 2, p. 103–114, 1996.
- ZHANG, X. M.; GROLINGER, K.; CAPRETZ, M. A.; SEEWALD, L. Forecasting residential energy consumption: Single household perspective. In: IEEE. **2018 17th IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS (ICMLA)**. [S. l.], 2018, p. 110–117.
- ZHAO, X.; HAN, X.; SU, W.; YAN, Z. Time series prediction method based on convolutional autoencoder and lstm. In: IEEE. **2019 CHINESE AUTOMATION CONGRESS (CAC)**. [S. l.], 2019, p. 5790–5793.
- ZHOU, J.; XU, X.; JIANG, W. Bigdata technology based power usage behavior analysis platform and algorithm. In: IEEE. **2017 IEEE 7TH ANNUAL INTERNATIONAL CONFERENCE ON CYBER TECHNOLOGY IN AUTOMATION, CONTROL, AND INTELLIGENT SYSTEMS (CYBER)**. [S. l.], 2017, p. 1372–1377.
- ZIHAN, W.; ENZE, S.; CAN, W.; XIAO, X.; XIANBO, D.; CHUNLIN, Z.; LEI, Z.; GUOLIN, C.; CHAO, F. Lstm-based method for electric consumption outlier detection. In: IEEE. **2021 IEEE SUSTAINABLE POWER AND ENERGY CONFERENCE (iSPEC)**. [S. l.], 2021, p. 3955–3959.

**APÊNDICE A – PARTE DO CÓDIGO DA APLICAÇÃO DESKTOP QUE MOSTRA A
CRIAÇÃO DO ALGORITMO POR REGRAS (CRIADO COM A LINGUAGEM DE
PROGRAMAÇÃO PYTHON)**

```

""" Para tarifa verde """
ultimoanofverde = df2[df2['ano'] == df2['ano'].unique()[-1]]['demandaforaponta'].tolist()
dmnotnullfpverde = [x for x in ultimoanofverde if math.isnan(x) == False]
demandamedidafpverde = np.percentile(dmnotnullfpverde, 80)

demandaescolhidaverdefp = 0

if demandamedidafpverde <= 5:
    demandaescolhidaverdefp += 30

elif (demandamedidafpverde > 5) and (demandamedidafpverde <= 30):
    demandaescolhidaverdefp += 30

elif (demandacontratadaverde > demandamedidafpverde) and (demandacontratadaverde <= 1.2 * demandamedidafpverde):
    demandaescolhidaverdefp = demandacontratadaverde

elif (demandacontratadaverde > 1.2 * demandamedidafpverde):
    demandaescolhidaverdefp = 1.2 * demandamedidafpverde

elif (demandacontratadaverde < demandamedidafpverde):
    demandaescolhidaverdefp = 1.2 * demandamedidafpverde

ultimoanopverde = df2[df2['ano'] == df2['ano'].unique()[-1]]['demandaponta'].tolist()
dmnotnullpverde = [x for x in ultimoanopverde if math.isnan(x) == False]
demandamedidapverde = np.percentile(dmnotnullpverde, 80)

demandaescolhidaverdep = 0

if demandamedidapverde <= 5:
    demandaescolhidaverdep += 30

elif (demandamedidapverde > 5) and (demandamedidapverde <= 30):
    demandaescolhidaverdep += 30

elif (demandacontratadaverde > demandamedidapverde) and (demandacontratadaverde <= 1.2 * demandamedidapverde):
    demandaescolhidaverdep = demandacontratadaverde

elif (demandacontratadaverde > 1.2 * demandamedidapverde):
    demandaescolhidaverdep = 1.2 * demandamedidapverde

elif (demandacontratadaverde < demandamedidapverde):
    demandaescolhidaverdep = 1.2 * demandamedidapverde

```

```

verdeescolhida = 0
if demandaescolhidaverdefp > demandaescolhidaverdep:
    verdeescolhida += demandaescolhidaverdefp
else:
    verdeescolhida += demandaescolhidaverdep

""" Para tarifa azul """

ultimoanofpazul = df2[df2['ano'] == df2['ano'].unique()[-1]]['demandaforaponta'].tolist()
dmnotnullfpazul = [x for x in ultimoanofpazul if math.isnan(x) == False]
demandamedidafpazul = np.percentile(dmnotnullfpazul, 80)

demandaescolhidaazulfp = 0

if demandamedidafpazul <= 5:
    demandaescolhidaazulfp += 30

elif (demandamedidafpazul > 5) and (demandamedidafpazul <= 30):
    demandaescolhidaazulfp += 30

elif (demandaContratadaAzulFP > demandamedidafpazul) and (demandaContratadaAzulFP <= 1.2 * demandamedidafpazul):
    demandaescolhidaazulfp = demandaContratadaAzulFP

elif (demandaContratadaAzulFP > 1.2 * demandamedidafpazul):
    demandaescolhidaazulfp = 1.2 * demandamedidafpazul

elif (demandaContratadaAzulFP < demandamedidafpazul):
    demandaescolhidaazulfp = 1.2 * demandamedidafpazul

ultimoanopazul = df2[df2['ano'] == df2['ano'].unique()[-1]]['demandaponta'].tolist()
dmnotnullpazul = [x for x in ultimoanopazul if math.isnan(x) == False]
demandamedidapazul = np.percentile(dmnotnullpazul, 80)

demandaescolhidaazulp = 0

if demandamedidapazul <= 5:
    demandaescolhidaazulp += 30

elif (demandamedidapazul > 5) and (demandamedidapazul <= 30):
    demandaescolhidaazulp += 30

elif (demandaContratadaAzulP > demandamedidapazul) and (demandaContratadaAzulP <= 1.2 * demandamedidapazul):
    demandaescolhidaazulp = demandaContratadaAzulP

```

```

    demandaescolhidaazulp = demandaContratadaAzulP

elif (demandaContratadaAzulP > 1.2 * demandamedidapazul):

    demandaescolhidaazulp = 1.2 * demandamedidapazul

elif (demandaContratadaAzulP < demandamedidapazul):

    demandaescolhidaazulp = 1.2 * demandamedidapazul

# calculando nova tarifação

# tarifação

# tarifação verde

demandacontratadaverdelistanovo = []

demandamaiorverdenovo = []

consumoFPOntaverdenovo = []

consumoPONtaverdenovo = []

demandacontratadaverdenovo = verdeescolhida

for i in range(len(dfagrupadofp)):
    if dfagrupadofp[i] > dfagrupadop[i]:

        demandacontratadaverdelistanovo.append(demandacontratadaverdenovo *
tarifaverdeimpostos)
        consumoFPOntaverdenovo.append((consumofp[i] * tusdFPontaVerde) + (consumofp[i] *
teFPontaVerde))
        consumoPONtaverdenovo.append((consumop[i] * tusdPontaVerde) + (consumop[i] *
tePontaVerde))

        if dfagrupadofp[i] > demandacontratadaverdenovo * 1.05:
            demandamaiorverdenovo.append((dfagrupadofp[i] - demandacontratadaverdenovo) * 2
* tarifaverdeimpostos)
        else:
            demandamaiorverdenovo.append(0)
    else:
        demandacontratadaverdelistanovo.append(demandacontratadaverdenovo *
tarifaverdeimpostos)
        consumoFPOntaverdenovo.append((consumofp[i] * tusdFPontaVerde) + (consumofp[i] *
teFPontaVerde))
        consumoPONtaverdenovo.append((consumop[i] * tusdPontaVerde) + (consumop[i] *
tePontaVerde))

        if dfagrupadop[i] > demandacontratadaverdenovo * 1.05:
            demandamaiorverdenovo.append((dfagrupadop[i] - demandacontratadaverdenovo) * 2
* tarifaverdeimpostos)
        else:
            demandamaiorverdenovo.append(0)

```

```

demandacontratadaverdelistanpovo = np.array(demandacontratadaverdelistanovo)

TotalVerdenovo = demandacontratadaverdelistanpovo + demandamaiorverdenovo +
consumoFPOntaverdenovo + consumoPONtaverdenovo
TotalVerdeSemMultanovo = demandacontratadaverdelistanpovo + consumoFPOntaverdenovo +
consumoPONtaverdenovo
multaverdenovo = TotalVerdenovo - TotalVerdeSemMultanovo

# tarifação azul

demandacontratadaazullistapnovo = []
demandacontratadaazullistafpnovo = []
demandamaiorazulpnovo = []
demandamaiorazulfpnovo = []
consumoFPOntaaazulnovo = []
consumoPONtaazulnovo = []

demandaContratadaAzulPnovo = demandaescolhidaazulp
demandaContratadaAzulFPnovo = demandaescolhidaazulfp

for i in range(len(dfagrupadofp)):

    demandacontratadaazullistafpnovo.append(demandaContratadaAzulFPnovo *
tarifaDemandaAzulFP)
    consumoFPOntaaazulnovo.append((consumofp[i] * tusdFPontaAzul) + (consumofp[i] *
teFPontaAzul))
    demandacontratadaazullistapnovo.append(demandaContratadaAzulPnovo *
tarifaDemandaAzulP)
    consumoPONtaazulnovo.append((consumop[i] * tusdPontaAzul) + (consumop[i] *
tePontaAzul))

    if dfagrupadofp[i] > demandaContratadaAzulFPnovo * 1.05:
        demandamaiorazulfpnovo.append(
            (dfagrupadofp[i] - demandaContratadaAzulFPnovo) * 2 * tarifaDemandaAzulFP)
    else:
        demandamaiorazulfpnovo.append(0)

    if dfagrupadop[i] > demandaContratadaAzulPnovo * 1.05:
        demandamaiorazulpnovo.append(
            (dfagrupadop[i] - demandaContratadaAzulPnovo) * 2 * tarifaDemandaAzulP)
    else:
        demandamaiorazulpnovo.append(0)

# tarifa azul

demandacontratadaazullistafpnovo = np.array(demandacontratadaazullistafpnovo)

TarifaAzulComMultanovo = demandacontratadaazullistafpnovo +
demandacontratadaazullistapnovo + demandamaiorazulpnovo + demandamaiorazulfpnovo +
consumoFPOntaaazulnovo + consumoPONtaazulnovo

```

TarifaAzulSemMultanovo = demandacontratadaazullistafpnov +
demandacontratadaazullistapnovo + consumoFPOntaazulnovo + consumoPOntaazulnovo

multaazulnovo = TarifaAzulComMultanovo - TarifaAzulSemMultanovo

**APÊNDICE B – SUGESTÕES DE DEMANDAS CONTRATADAS E DE
MODALIDADE TARIFÁRIA ADEQUADAS PARA AS UNIDADES CONSUMIDORAS
ESTUDADAS NESTA TESE**

id	unidade consumidora	Tarifa	demandatualkW	sugestao de demandakW	cidade	Sugestao Tarifa
1298062	CONTROLADORIA GERAL DE DISCI	A4_HOROSAZONAL_VERDE	110	118	Fortaleza	A4_HOROSAZONAL_VERDE
1656214	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	94	85	Fortaleza	A4_HOROSAZONAL_VERDE
1773727	TJCE CRECHE DO PODER JUDICIA	A4_HOROSAZONAL_VERDE	60	56	Fortaleza	A4_HOROSAZONAL_VERDE
1773726	TJCE ESC SUPER MAGISTRATURA	A4_HOROSAZONAL_VERDE	80	105	Fortaleza	A4_HOROSAZONAL_VERDE
1710660	COGERH EB GAVIAO ACARAPE	A4_HOROSAZONAL_VERDE	493	493	Pacatuba	A4_HOROSAZONAL_VERDE
9011170	DETTRAN QUIXADA	A4_HOROSAZONAL_VERDE	70	30	Quixada	A4_HOROSAZONAL_VERDE
9009354	COGERH EB SAO PEDRO	A4_HOROSAZONAL_VERDE	368	200	Canide	A4_HOROSAZONAL_VERDE
9008188	METROFOR PATIO DE MANUTENCAO	A4_HOROSAZONAL_VERDE	150	170	Pacatuba	A4_HOROSAZONAL_VERDE
9008099	CAGECE EEAT ITAPEBUSSU	A4_HOROSAZONAL_VERDE	35	35	Maranguape	A4_HOROSAZONAL_VERDE
9007986	SESA UPA CANINDE COGERH	A4_HOROSAZONAL_VERDE	30	30	Canide	A4_HOROSAZONAL_VERDE
9007102	BARRAGEM DO RIO MARAN	A4_HOROSAZONAL_VERDE	423	30	Maranguape	A4_HOROSAZONAL_VERDE
9005679	SSPDS ACADEMIA DE POLICIA	A4_HOROSAZONAL_VERDE	300	275	Fortaleza	A4_HOROSAZONAL_VERDE
9005078	STD'S ESCOLA SABOR VIDA E ART	A4_HOROSAZONAL_VERDE	30	33	Fortaleza	A4_HOROSAZONAL_VERDE
9002668	TJCE FORUM DE CANINDE	A4_HOROSAZONAL_VERDE	50	35	Canide	A4_HOROSAZONAL_VERDE
9002660	TJCE FORUM MARANGUAPE	A4_HOROSAZONAL_VERDE	60	40	Maranguape	A4_HOROSAZONAL_VERDE
9000626	SESA BLOCO E	A4_HOROSAZONAL_VERDE	172	185	Fortaleza	A4_HOROSAZONAL_VERDE
9011619	CONS PUB DE SAUDE DE MICRO R	A4_HOROSAZONAL_VERDE	50	35	Crato	A4_HOROSAZONAL_VERDE
9011153	CAGECE JUAZEIRO DO NORTE CE	A4_HOROSAZONAL_VERDE	36	36 ponta e 36 fora de ponta	Juazeiro do Norte	A4_HOROSAZONAL_AZUL
9008883	TJCE FORUM DA COMARCA DE ASS	A4_HOROSAZONAL_VERDE	40	30	Assare	A4_HOROSAZONAL_VERDE
9007898	CENTRO SOCIOEDU CANINDEZINHO	A4_HOROSAZONAL_VERDE	70	50	Fortaleza	A4_HOROSAZONAL_VERDE
9007210	CAGECE CIA AGUA ESGOTO DO C	A4_HOROSAZONAL_VERDE	60	60	Pereiro	A4_HOROSAZONAL_VERDE
9006863	SSE SEC DE SAUDE DO ESTADO	A4_HOROSAZONAL_VERDE	75	90	Fortaleza	A4_HOROSAZONAL_VERDE
9006457	CAGECE ESTACAO DE BOMBEAMENT	A4_HOROSAZONAL_VERDE	100	109	Aquiraz	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
9006331	SEJUS PFHVA CPSMAR	A4_HOROSAZONAL_VERDE	130	140 ponta e 150 fora de ponta	Pacatuba	A4_HOROSAZONAL_AZUL
9006247	POLICLINICA DR JOSE H CPSMAR	A4_HOROSAZONAL_VERDE	80	80	Aracati	A4_HOROSAZONAL_VERDE
9006152	POLICLINICA DR JOSE H	A4_HOROSAZONAL_VERDE	80	70	Fortaleza	A4_HOROSAZONAL_VERDE
9001941	CAGECE CIA AGUA ESGOTO DO CE	A4_HOROSAZONAL_VERDE	142	90	Russas	A4_HOROSAZONAL_VERDE
9001789	CAGECE CIA AGUA ESGOTO DO CE	A4_HOROSAZONAL_VERDE	234	234 ponta e 234 fora de ponta	Russas	A4_HOROSAZONAL_AZUL
9001739	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	240	193 ponta e 193 fora de ponta	Araripe	A4_HOROSAZONAL_AZUL
9001387	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	82	75 ponta e 82 fora de ponta	Fortaleza	A4_HOROSAZONAL_AZUL
9001078	CAGECE CIA AGUA ESGOTO DO CE	A4_HOROSAZONAL_VERDE	93	100 ponta e 100 fora de ponta	Aquiraz	A4_HOROSAZONAL_AZUL
9001053	CAGECE CIA AGUA ESGOTO DO CE	A4_HOROSAZONAL_VERDE	87	87	Aquiraz	A4_HOROSAZONAL_VERDE
1821218	TJCE FORUM DE ARACATI	A4_HOROSAZONAL_VERDE	55	42	Aracati	A4_HOROSAZONAL_VERDE
1613489	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	169	169 ponta e 169 fora de ponta	Ibiapina	A4_HOROSAZONAL_AZUL
1546319	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	38	38	Russas	A4_HOROSAZONAL_VERDE
1228893	CAGECE	A4_HOROSAZONAL_VERDE	196	200 ponta e 205 fora de ponta	Ubajara	A4_HOROSAZONAL_AZUL
1215848	FUNDACAO NUCLEO TEC INDUSTRI	A4_HOROSAZONAL_VERDE	230	210	Fortaleza	A4_HOROSAZONAL_VERDE
9004757	CAGECE	A4_HOROSAZONAL_VERDE	105	105 ponta e 105 fora de ponta	Frecheirinha	A4_HOROSAZONAL_AZUL
9006487	CAGECE	A4_HOROSAZONAL_VERDE	398	398 ponta e 398 fora de ponta	Quixada	A4_HOROSAZONAL_AZUL
9002712	TJCE	A4_HOROSAZONAL_VERDE	65	60	Quixada	A4_HOROSAZONAL_VERDE

9000668	CAGECE	A4_HOROSAZONAL_VERDE	94	94 ponta e 94 fora de ponta	Quixada	A4_HOROSAZONAL_AZUL A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
9000517	FUNECE	A4_HOROSAZONAL_VERDE	95	85	Quixada	
9005887	TJCE	A4_HOROSAZONAL_VERDE	80	65	Limoeiro do norte	A4_HOROSAZONAL_VERDE
9007375	Consorcio	A4_HOROSAZONAL_VERDE	85	95	Limoeiro do norte	A4_HOROSAZONAL_VERDE
9007812	CAGECE	A4_HOROSAZONAL_VERDE	60	80	Juazeiro do Norte	A4_HOROSAZONAL_AZUL
9005682	Defensoria	A4_HOROSAZONAL_VERDE	210	160	Fortaleza	A4_HOROSAZONAL_VERDE
9005711	SESA	A4_HOROSAZONAL_VERDE	210	175 ponta e 200 fora de ponta	Fortaleza	A4_HOROSAZONAL_AZUL
9005642	Consorcio	A4_HOROSAZONAL_VERDE	76	50	Tiangua	A4_HOROSAZONAL_VERDE
9001452	CAGECE	A4_HOROSAZONAL_VERDE	52	52 ponta e 52 fora de ponta	Potengi	A4_HOROSAZONAL_AZUL
9006349	CAGECE	A4_HOROSAZONAL_VERDE	53	53 ponta e 53 fora de ponta	Itaitinga	A4_HOROSAZONAL_AZUL
9011197	CogeRH	A4_HOROSAZONAL_VERDE	82	65	Sao gonçalo do amarante	A4_HOROSAZONAL_VERDE
9011196	CogeRH	A4_HOROSAZONAL_VERDE	38	30	Sao gonçalo do amarante	A4_HOROSAZONAL_VERDE
9011198	CogeRH	A4_HOROSAZONAL_VERDE	38	30	Sao gonçalo do amarante	A4_HOROSAZONAL_VERDE
9009240	CogeRH	A4_HOROSAZONAL_VERDE	136	30	Sao gonçalo do amarante	A4_HOROSAZONAL_VERDE
9010240	CAGECE	A4_HOROSAZONAL_VERDE	65	35	Caucaia	A4_HOROSAZONAL_VERDE
9006389	SESA	A4_HOROSAZONAL_VERDE	40	45	Caucaia	A4_HOROSAZONAL_VERDE
9006387	Consorcio	A4_HOROSAZONAL_VERDE	42	42	Cascavel	A4_HOROSAZONAL_VERDE
9010726	CAGECE	A4_HOROSAZONAL_VERDE	46	50 ponta e 50 fora de ponta	Beberibe	A4_HOROSAZONAL_AZUL
9009703	SAP	A4_HOROSAZONAL_VERDE	80	45	Juazeiro do Norte	A4_HOROSAZONAL_VERDE
9009155	Sop	A4_HOROSAZONAL_VERDE	70	30	Juazeiro do Norte	A4_HOROSAZONAL_VERDE
9010543	CAGECE	A4_HOROSAZONAL_VERDE	30	30 ponta e 30 fora de ponta	Juazeiro do Norte	A4_HOROSAZONAL_AZUL
9009423	CogeRH	A4_HOROSAZONAL_VERDE	296	30	Ipaporanga	A4_HOROSAZONAL_VERDE
9010482	CAGECE	A4_HOROSAZONAL_VERDE	62	62 ponta e 72 fora de ponta	Independencia	A4_HOROSAZONAL_AZUL
9001036	CAGECE	A4_HOROSAZONAL_VERDE	70	70 ponta e 70 fora de ponta	Jaguaribara	A4_HOROSAZONAL_AZUL
768958	SECRETARIA DE SAUDE NUASF	A4_HOROSAZONAL_VERDE	88	70	Fortaleza	A4_HOROSAZONAL_VERDE
152068	EMPRESA DE TECNOLOGIA DA INF	A4_HOROSAZONAL_VERDE	165	150	Fortaleza	A4_HOROSAZONAL_VERDE
1755839	FUNDACAO CEARENSE DE METEORO	A4_HOROSAZONAL_VERDE	110	100	Fortaleza	A4_HOROSAZONAL_VERDE
9008507	INSTITUTO DE ARTE E CULTURA	A4_HOROSAZONAL_VERDE	150	70	Fortaleza	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
768940	ISSEC INST SAUDE SERVIDORES METROFOR	A4_HOROSAZONAL_VERDE	180	160	Fortaleza	A4_HOROSAZONAL_VERDE
9008304	ESTACAO XICO DA SIL	A4_HOROSAZONAL_VERDE	70	55	Fortaleza	A4_HOROSAZONAL_VERDE
9005572	METROFOR CIA CEARENSE DE TRA	A4_HOROSAZONAL_VERDE	35	30	Fortaleza	A4_HOROSAZONAL_VERDE
900884	TJCE FORUM DA COMARCA DE BOA	A4_HOROSAZONAL_VERDE	80	50	Boa Viagem	A4_HOROSAZONAL_VERDE
9005970	CONS PUBLICO DE SAUDE MICROR	A4_HOROSAZONAL_VERDE	95	70	Camocim	A4_HOROSAZONAL_VERDE
1418976	FUNCAP	A4_HOROSAZONAL_VERDE	160	80	Fortaleza	A4_HOROSAZONAL_VERDE
9010270	SECRETARIA DA CULTURA	A4_HOROSAZONAL_VERDE	114	35	Fortaleza	A4_HOROSAZONAL_VERDE
768968	COGERH SEDE	A4_HOROSAZONAL_VERDE	160	150	Fortaleza	A4_HOROSAZONAL_VERDE
768963	SUPERINTENDENCIA DA POLICIA	A4_HOROSAZONAL_VERDE	280	260	Fortaleza	A4_HOROSAZONAL_VERDE
43017	CAGECE CIA AGUA E ESGOTO CEA	A4_HOROSAZONAL_VERDE	164	164 ponta e 164 fora de ponta	Varjota	A4_HOROSAZONAL_AZUL
9009614	COGERH EB FLORES	A4_HOROSAZONAL_VERDE	662	30	Ipu	A4_HOROSAZONAL_VERDE
9003664	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	103	110 ponta e 110 fora de ponta	Ipu	A4_HOROSAZONAL_AZUL
9006376	CONSORCIO PUB SAUDE MICROREG	A4_HOROSAZONAL_VERDE	80	80	Russas	A4_HOROSAZONAL_VERDE
9009152	DETTRAN RUSSAS	A4_HOROSAZONAL_VERDE	35	30	Russas	A4_HOROSAZONAL_VERDE

9005136	SEJUS CPPL II	A4_HOROSAZONAL_VERDE	85	120 ponta e 120 fora de ponta	Pacatuba	A4_HOROSAZONAL_AZUL
9007262	METROFOR ESTACAO MARACANAU METROFOR	A4_HOROSAZONAL_VERDE	50	50	Maracanau	A4_HOROSAZONAL_VERDE
9007111	ESTACAO VILA DAS FL	A4_HOROSAZONAL_VERDE	30	35 ponta e 35 fora de ponta	Maracanau	A4_HOROSAZONAL_AZUL
9010829	DETRAN DEPTO ESTADUAL DE TRA	A4_HOROSAZONAL_VERDE	57	40	Aracati	A4_HOROSAZONAL_VERDE
9008953	SESA UPA ARACATI	A4_HOROSAZONAL_VERDE	45	40	Aracati	A4_HOROSAZONAL_VERDE
9009109	COGERH ACUDE SITIOS NOVOS	A4_HOROSAZONAL_VERDE	98	30	Caucaia	A4_HOROSAZONAL_VERDE
9011757	SECRETARIA DA JUSTICA E CIDA	A4_HOROSAZONAL_VERDE	190	120 ponta e 120 fora de ponta	Itaitinga	A4_HOROSAZONAL_AZUL
9005331	SEJUS CPPL III	A4_HOROSAZONAL_VERDE	160	100	Itaitinga	A4_HOROSAZONAL_VERDE
9000899	SEJUS PRESIDIO FEMININO FORT	A4_HOROSAZONAL_VERDE	95	108	Itaitinga	A4_HOROSAZONAL_VERDE
9005577	SEJUS IPPS	A4_HOROSAZONAL_VERDE	30	45	Aquiraz	A4_HOROSAZONAL_VERDE
9008599	CONS PUB DE SAUDE IBIAPABA P	A4_HOROSAZONAL_VERDE	30	80	Tiangua	A4_HOROSAZONAL_VERDE
9006303	DETAN DEP ESTADUAL DE TRANS	A4_HOROSAZONAL_VERDE	46	40	Tiangua	A4_HOROSAZONAL_VERDE
9009154	DETAN TIANGUA	A4_HOROSAZONAL_VERDE	30	80	Tiangua	A4_HOROSAZONAL_VERDE
9011538	CAGECE ETE VICOSA	A4_HOROSAZONAL_VERDE	65	30 ou desligar	Viçosa do Ceará	A4_HOROSAZONAL_VERDE
430035	CAGECE CIA AGUA E ESGOTO CEA	A4_HOROSAZONAL_VERDE	38	47	Pacoti	A4_HOROSAZONAL_VERDE
9000987	TJCE FORUM DA COMARCA DE GRA	A4_HOROSAZONAL_VERDE	40	30	Granja	A4_HOROSAZONAL_VERDE
9003645	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	63	63	Groairas	A4_HOROSAZONAL_VERDE
272044	SEJUS PRESIDO MILITAR	A4_HOROSAZONAL_VERDE	30	120 ponta e 120 fora de ponta	AQUIRAZ	A4_HOROSAZONAL_AZUL
9005168	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	60	50	MONSENHOR TABOSA	A4_HOROSAZONAL_VERDE
9001856	TJCE FORUM DE PARACURU	A4_HOROSAZONAL_VERDE	40	35	PARACURU	A4_HOROSAZONAL_VERDE
9008806	CAGECE EEP ARATUBA	A4_HOROSAZONAL_VERDE	30	35 ponta e 35 fora de ponta	ARATUBA	A4_HOROSAZONAL_AZUL
9009792	DETAN DE BATURITE	A4_HOROSAZONAL_VERDE	70	50	BATURITE	A4_HOROSAZONAL_VERDE
9002842	TJCE FORUM DE BATURITE	A4_HOROSAZONAL_VERDE	80	40	BATURITE	A4_HOROSAZONAL_VERDE
9001783	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	49	35	PORTEIRAS	A4_HOROSAZONAL_VERDE
9001614	CAGECE CIA AGUA E ESGOTO CEA	A4_HOROSAZONAL_VERDE	42	30	PENAFORTE	A4_HOROSAZONAL_VERDE
9008276	SETUR CTRO CONVENCOES DO CAR	A4_HOROSAZONAL_VERDE	300	120	CRATO	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
9009600	COGERH EB URUCARA	A4_HOROSAZONAL_VERDE	95	30 ou 0	MARANGUAPE	A4_HOROSAZONAL_VERDE ou desligamento da unidade ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
1768833	COGERH EB MARANGUAPE EB ACAR	A4_HOROSAZONAL_VERDE	120	30 ou 0	MARANGUAPE	A4_HOROSAZONAL_VERDE ou desligamento da unidade ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA
1810903	CAGECE CIA DE AGUA E ESG DO	A4_HOROSAZONAL_VERDE	71	65	IBICUITINGA	A4_HOROSAZONAL_VERDE
9007292	SESA UPA PECEM	A4_HOROSAZONAL_VERDE	45	50 ponta e 55 fora de ponta	São GONçALO do AMARANTe	A4_HOROSAZONAL_AZUL

id	unidade consumidora	Tarifa	demandaAtualkW	sugestaodeDemandakW	cidade	SugestaoTarifa
9005483	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	70	70	Araripe	A4_HOROSAZONAL_VERDE
9001735	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30 ou 0	Pereiro	A4_HOROSAZONAL_VERDE ou desligamento da unidade ou B optante se a potênci nominal total dos transformadores for igual ou inferior a 112,5 kVA
9002537	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	71	71	Quixere	A4_HOROSAZONAL_VERDE
1404033	CAGECE CIA AGUA ESGOTO DO CE SEJUS	A4_HOROSAZONAL_VERDE	42	42	Fortaleza	A4_HOROSAZONAL_VERDE, mas talvez vallhe a pena mudar a4 azul
1020515	SECRETARIA DA JUSTICA CASA CIVIL	A4_HOROSAZONAL_VERDE	90	90	Fortaleza	A4_HOROSAZONAL_VERDE
768945	PALACIO DA ABOLIC	A4_HOROSAZONAL_VERDE	360	360	Fortaleza	A4_HOROSAZONAL_VERDE
521899	FUNECE	A4_HOROSAZONAL_VERDE	1350	1350	Fortaleza	A4_HOROSAZONAL_VERDE
275981	Cagece	A4_HOROSAZONAL_VERDE	124	124	Quixada	A4_HOROSAZONAL_VERDE
9001777	Cagece	A4_HOROSAZONAL_VERDE	55	55	Farias Brito	A4_HOROSAZONAL_VERDE
9001411	CAGECE CIA AGUA E ESGOTO DO SSE SEC DE SAUDE DO ESTADO	A4_HOROSAZONAL_VERDE	42	42	MAURITI	A4_HOROSAZONAL_VERDE
9006930	COGERH EB BROTA	A4_HOROSAZONAL_VERDE	80	80	Fortaleza	A4_HOROSAZONAL_VERDE
9009397	COGERH EB POCOS DO CUMBUCO	A4_HOROSAZONAL_VERDE	132	132	IRAU CUBA	A4_HOROSAZONAL_VERDE
9011426	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30 ou 0	Caucaia	A4_HOROSAZONAL_VERDE ou B optante se a potênci nominal total dos transformadores for igual ou inferior a 112,5 kVA
9005346	CAGECE EEAT PARACURU	A4_HOROSAZONAL_VERDE	30	30 ou 0	Paracuru	A4_HOROSAZONAL_VERDE
9009045	CAGECE EEE DE MARANGUAPE	A4_HOROSAZONAL_VERDE	30	30 ou 0	MARANGUAPE	A4_HOROSAZONAL_VERDE ou desligamento da unidade ou B optante se a potênci nominal total dos transformadores for igual ou inferior a 112,5 kVA
9000632	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	60	60	TAMBORIL	A4_HOROSAZONAL_VERDE
1725914	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	55	55	PORANGA	A4_HOROSAZONAL_VERDE
9011334	CAGECE EEAB NOVA RUSSAS TAMB	A4_HOROSAZONAL_VERDE	30	30	NOVA RUSSAS	A4_HOROSAZONAL_VERDE
9011452	CAGECE EEAB DE APUIARES ACUD	A4_HOROSAZONAL_VERDE	30	30 ou 0	GENERAL SAMPAIO	A4_HOROSAZONAL_VERDE
9004621	CAGECE SE CAPISTRANO	A4_HOROSAZONAL_VERDE	36	36	CAPISTRANO	A4_HOROSAZONAL_VERDE
9001692	TJCE FORUM DE CAPISTRANO	A4_HOROSAZONAL_VERDE	30	30	CAPISTRANO	A4_HOROSAZONAL_VERDE
9007713	SESA UPA ARACOIABA	A4_HOROSAZONAL_VERDE	30	30	ARACOIABA	A4_HOROSAZONAL_VERDE
9001018	TJCE FORUM DE ARACOIABA	A4_HOROSAZONAL_VERDE	30	30	ARACOIABA	A4_HOROSAZONAL_VERDE
9001831	CAGECE ARACOIABA EE3	A4_HOROSAZONAL_VERDE	88	88	ARACOIABA	A4_HOROSAZONAL_VERDE
9001829	CAGECE ARACOIABA EE2	A4_HOROSAZONAL_VERDE	209	209	ARACOIABA	A4_HOROSAZONAL_VERDE
9006246	CONSORCIO PUBLICO SAUDE MACI	A4_HOROSAZONAL_VERDE	110	110	BATURITE	A4_HOROSAZONAL_VERDE
9003649	CAGECE ESTACAO ELEVATORIA FL CPSMBS CEO	A4_HOROSAZONAL_VERDE	46	46	Lavras DA MANGABEIRA	A4_HOROSAZONAL_VERDE
9006386	DE BREJO SANTO	A4_HOROSAZONAL_VERDE	42	42	BREJO SANTO	A4_HOROSAZONAL_VERDE
9009821	DETTRAN CRATO	A4_HOROSAZONAL_VERDE	30	30	CRATO	A4_HOROSAZONAL_VERDE

id	unidade consumidora	Tarifa	demandAtual	sugestaodeDemanda	cidade
1725904	CAGECE ADUTORA SAO DOMINGOS	A4_HOROSAZONAL_VERDE	58	58	Caridade
9008289	CAGECE EEE 01 QUIXADA	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA	30	30	Quixada
9006388	SEC DE SAUDE DO ESTADO CEO C	A4_HOROSAZONAL_VERDE	50	50	Canide
9006057	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA	30	30	Quixada
9009288	POLICIA CIVIL 2 DP E DEPROTU	A4_HOROSAZONAL_VERDE	75	75	Fortaleza
9006451	SSE SEC DE SAUDE DO ESTADO	A4_HOROSAZONAL_VERDE	80	80	Fortaleza
9005645	CPSMR CONSORCIO PUB SAUDE RU	A4_HOROSAZONAL_VERDE	47	47	Russas
9008858	SESA UPA QUIXADA	A4_HOROSAZONAL_VERDE	45	45	Quixada
9008076	SESA	A4_HOROSAZONAL_VERDE	68	68	Fortaleza
49572	Cagece	A4_HOROSAZONAL_VERDE	30	30	Iracema
1235856	Cagece	A4_HOROSAZONAL_VERDE	30	30	Iracema
1389771	Cagece	A4_HOROSAZONAL_VERDE	49	49	Quixada
9003442	COGERH	A4_HOROSAZONAL_VERDE	123	123	QUIXERAMOBIM
9006420	Consortio	A4_HOROSAZONAL_VERDE	50	50	Limoeiro do norte
9001645	SAP	A4_HOROSAZONAL_VERDE	130	130	Itaitinga
9003581	SESA	A4_HOROSAZONAL_VERDE	51	51	Eusebio
9011121	COGERH	A4_HOROSAZONAL_VERDE	40	40	Beberibe
9011122	COGERH	A4_HOROSAZONAL_VERDE	67	67	Beberibe
9006440	Consortio	A4_HOROSAZONAL_VERDE	50	50	Crateus
9009567	Cagece	A4_HOROSAZONAL_VERDE	44	44	Potiretama
9001780	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30	MAURITI
9001453	CAGECE CAPTACAO DE AGUA DE A	A4_HOROSAZONAL_VERDE	60	60	AURORA
9010058	CAGECE ETA JARDIM DE SAO JOS	A4_HOROSAZONAL_VERDE	30	30	RUSSAS
9001041	TJCE CORREGEDORIA GERAL	A4_HOROSAZONAL_VERDE	90	90	Fortaleza
9008521	SSPDC DIVISAO DE COMBATE AO	A4_HOROSAZONAL_VERDE	120	120	Fortaleza
1333387	CORPO DE BOMBEIROS M SST DO COGERH	A4_HOROSAZONAL_VERDE	125	125	Fortaleza
9003275	ACAMPAMENTO TRECHO 2	A4_HOROSAZONAL_VERDE	30	30	Limoeiro do norte
9006489	METROFOR ESTACAO VIRGILIO TA	A4_HOROSAZONAL_VERDE	30	30	Maracanau
9006503	METROFOR ESTACAO DE RAQUEL D	A4_HOROSAZONAL_VERDE	30	30	Maracanau
9007094	METROFOR ESTACAO JEREISSATI	A4_HOROSAZONAL_VERDE	30	30	Maracanau
9007260	METROFOR ESTACAO ALTO ALEGRE	A4_HOROSAZONAL_VERDE	30	30	Maracanau
9009115	CAGECE ETA MARCO	A4_HOROSAZONAL_VERDE	30	30	Marco
1780598	CAGECE CIA AGUA E ESGOTO DO	A4_HOROSAZONAL_VERDE	55	55	Moraujo
9004919	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30	ITAPIUNA
9010967	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30	Capistrano
9005626	METROFOR CARIRI	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA	35	35	Crato
9006204	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	32	32	ARARENDA
9004343	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30	MONSENHOR TABOSA
9000478	CAGECE CIA AGUA ESGOTO DO CE	A4_HOROSAZONAL_VERDE	65	65	PARACURU
9009457	CAGECE ETA BAIXIO	A4_HOROSAZONAL_VERDE	30	30	Baixio
9001781	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	30	30	PORTEIRAS
9007221	CAGECE CIA DE AGUA E ESGOTO	A4_HOROSAZONAL_VERDE	32	32	MARANGUAPE
9009280	CAGECE ETE MARANGUAPE	A4_HOROSAZONAL_VERDE ou B optante se a potência nominal total dos transformadores for igual ou inferior a 112,5 kVA	30	30	MARANGUAPE

APÊNDICE C – DIVISÃO DAS UNIDADES CONSUMIDORAS EM GRUPOS PELOS PADRÕES QUE APRESENTAM, COMO COMPORTAMENTOS SEMELHANTES DO CONSUMO DE ENERGIA AO LONGO DO ANO E/OU ANOMALIAS

Clientes	Cluster	Clientes	Cluster	Clientes	Cluster	Clientes	Cluster
Cliente_9008188	1	Cliente_9009240	2	Cliente_1298062	3	Cliente_9007102	4
Cliente_9000626	1	Cliente_9005136	2	Cliente_1773727	3	Cliente_1656214	4
Cliente_9008883	1	Cliente_272044	2	Cliente_9005679	3	Cliente_9011153	4
Cliente_9006457	1	Cliente_9009354	2	Cliente_9005078	3	Cliente_9007210	4
Cliente_9005642	1	Cliente_1773726	2	Cliente_9002668	3	Cliente_9006863	4
Cliente_768958	1	Cliente_1710660	2	Cliente_9002660	3	Cliente_9006331	4
Cliente_152068	1	Cliente_9008099	2	Cliente_9011619	3	Cliente_9001941	4
Cliente_9008507	1	Cliente_9007986	2	Cliente_9006247	3	Cliente_9001789	4
Cliente_768963	1	Cliente_9007898	2	Cliente_1821218	3	Cliente_9001739	4
Cliente_9009288	1	Cliente_9006152	2	Cliente_1215848	3	Cliente_9001078	4
Cliente_9003581	1	Cliente_1546319	2	Cliente_9002712	3	Cliente_9001053	4
Cliente_9005626	1	Cliente_9004757	2	Cliente_9000517	3	Cliente_1613489	4
Cliente_9001692	1	Cliente_9005711	2	Cliente_9005887	3	Cliente_1228893	4
		Cliente_9011197	2	Cliente_9007375	3	Cliente_9006487	4
		Cliente_9011196	2	Cliente_9005682	3	Cliente_9000668	4
		Cliente_9011198	2	Cliente_9006389	3	Cliente_9007812	4
		Cliente_9010240	2	Cliente_9006387	3	Cliente_9001452	4
		Cliente_9001036	2	Cliente_1755839	3	Cliente_9006349	4
		Cliente_9008304	2	Cliente_768940	3	Cliente_9010726	4
		Cliente_9009152	2	Cliente_9005572	3	Cliente_9009703	4
		Cliente_9007262	2	Cliente_9008884	3	Cliente_9009155	4
		Cliente_9007111	2	Cliente_9005970	3	Cliente_9010543	4
		Cliente_9000899	2	Cliente_9010270	3	Cliente_9009423	4
		Cliente_9011538	2	Cliente_768968	3	Cliente_9010482	4
		Cliente_9003645	2	Cliente_9006376	3	Cliente_1418976	4
		Cliente_9005168	2	Cliente_9010829	3	Cliente_43017	4
		Cliente_9008289	2	Cliente_9008953	3	Cliente_9009614	4
		Cliente_9006057	2	Cliente_9008599	3	Cliente_9003664	4
		Cliente_9001645	2	Cliente_9006303	3	Cliente_9011757	4
		Cliente_9011121	2	Cliente_9000987	3	Cliente_9005331	4
		Cliente_9011122	2	Cliente_9001856	3	Cliente_9005577	4
		Cliente_9009567	2	Cliente_9009792	3	Cliente_9009154	4
		Cliente_9001780	2	Cliente_9002842	3	Cliente_430035	4
		Cliente_9001453	2	Cliente_9006388	3	Cliente_9008806	4
		Cliente_9003275	2	Cliente_9005645	3	Cliente_9006451	4
		Cliente_9004919	2	Cliente_9006420	3	Cliente_9008858	4
		Cliente_9010967	2	Cliente_9006440	3	Cliente_9008076	4
		Cliente_9006204	2	Cliente_9001041	3	Cliente_49572	4
		Cliente_9001735	2	Cliente_9008521	3	Cliente_1235856	4
		Cliente_9011426	2	Cliente_1333387	3	Cliente_1389771	4
		Cliente_9008685	2	Cliente_1020515	3	Cliente_9003442	4
		Cliente_9000632	2	Cliente_768945	3	Cliente_9010058	4
		Cliente_1725914	2	Cliente_521899	3	Cliente_9006489	4
		Cliente_9011334	2	Cliente_9001018	3	Cliente_9006503	4
		Cliente_9011452	2	Cliente_9006246	3	Cliente_9007094	4
		Cliente_9001831	2	Cliente_9006386	3	Cliente_9007260	4
		Cliente_9001829	2			Cliente_9009115	4
		Cliente_9009457	2			Cliente_1780598	4
		Cliente_9001781	2			Cliente_9004343	4
		Cliente_9001614	2			Cliente_9000478	4
		Cliente_9008276	2			Cliente_9005483	4

Cliente_9007221	2	Cliente_9002537	4
Cliente_9009280	2	Cliente_1404033	4
Cliente_9009600	2	Cliente_275981	4
Cliente_1768833	2	Cliente_9001777	4
Cliente_1810903	2	Cliente_9001411	4
Cliente_9011170	2	Cliente_9006930	4
Cliente_9001387	2	Cliente_9009397	4
Cliente_1725904	2	Cliente_9005346	4
Cliente_9009045	2	Cliente_9004621	4
		Cliente_9007713	4
		Cliente_9003649	4
		Cliente_9001783	4
		Cliente_9009821	4

APÊNDICE D – RELAÇÃO DAS UNIDADES CONSUMIDORAS PELO VALOR QUE PAGARAM NO ANO ESTUDADO, MULTA POR ULTRAPASSAGEM DE DEMANDA, O VALOR QUE A FATURA FICARIA SE NÃO EXISTISSE A MULTA, O VALOR DA MULTA POR ULTRAPASSAGEM DE DEMANDA CONTRATADA, O VALOR DA FATURA COM A MODALIDADE TARIFÁRIA E A DEMANDA CONTRATADA SUGERIDAS E A MULTA POR EXCEDENTE DE ENERGIA REATIVA

clientes_meses_2022	janeiro	fevereiro	março	abril	maio	junho	julho	agosto	setembro	outubro	novembro	
cliente_1298062_com_multaD110TVerde	17008,21461853	17934,18587319	17561,10696407	15212,79644871	17648,9092965	14747,55182747	15055,80167267	16526,94733624	16964,05452454	17182,82160703	16172,88954591	17183,54656401
cliente_1298062_sem_multaD110TVerde	16214,40621853	17095,39187319	17087,82096407	15212,79644871	17248,7248965	14747,55182747	15055,80167267	16526,94733624	16541,37732454	16737,65160703	15840,18354591	17183,54656401
cliente_1298062_multa_ultrapassagem_D110TVerde	793,8084	838,794	473,286	0	400,1844	0	0	0	422,6772	445,17	332,706	0
cliente_1298062_sugestDemanda118MaiorTVerde	16448,70621853	17698,85857819	17322,12096407	15447,09644871	17483,0248965	14981,85182747	15290,10167267	16761,24733624	16775,67732454	16971,95160703	16074,48354591	17147,84656401
EnergiaReativaExcedente1298062	23,7303448	12,4644956	17,2804856	9,5820364	17,124794	3,4318388	1,4947406	10,7664132	14,3302458	12,735618	18,0189374	14,3694872
cliente_1656214_D94TVerdeClioOk	27661,4560095	25251,83727075	27058,67095894	25239,780972	23951,89734037	27093,59990812	27146,37490575	28350,05055525	25221,49879875	27297,98485594	25429,1695905	27042,92759025
cliente_1656214_sugestDemanda85MenorTVerde	27397,86865095	24988,24977075	26795,08345894	24976,193472	23688,30984038	26830,01240812	26882,78740575	28086,46305525	24957,91129875	27034,40095594	25165,5820905	26779,34009025
EnergiaReativaExcedente1656214	782,4984878	737,8417746	759,4709208	738,9476686	889,1423434	764,6828922	134,348284	635,8854826	499,9318686	835,1069356	836,9441466	462,1281308
cliente_1773727_D60TVerdeClioOk	5492,68631146	6503,70572631	5888,01876143	5603,12096778	6438,93601581	5833,34860303	3730,2832663	6683,66667737	6624,95741416	6740,51023683	6477,09442611	5443,8431052
cliente_1773727_sugestDemanda56MenorTVerde	5375,53631146	6386,55572631	5770,86876143	5485,97096778	6321,78601581	5716,19860303	3613,13323663	6566,51667737	6507,80741416	6623,36023683	6359,94442611	5575,6134252
EnergiaReativaExcedente1773727	3,7671744	2,4151298	2,871757	4,3771998	5,065708	7,31317	1,765863	3,0715314	2,0013114	1,6731106	3,7065286	3,174986
cliente_1773726_com_multaD80TVerde	12316,80630943	13491,51394981	11952,20524769	11481,19538338	9364,58356373	11844,81657275	10096,41033676	12288,95970755	8910,04295505	11416,82389147	10620,78600199	11408,27721479
cliente_1773726_sem_multaD80TVerde	10516,44510943	11872,50094981	10244,62684769	9929,66078338	9364,58356373	10305,93417275	10096,41033676	10897,68630755	8910,04295505	10784,68249147	10620,78600199	10291,13481479
cliente_1773726_multa_ultrapassagem_D80TVerde	1800,3612	1619,013	1707,5784	1551,5346	0	1538,8824	0	1391,2734	0	632,1414	0	1117,1424
cliente_1773726_sugestDemanda105MaiorTVerde	11584,61880943	12604,68844981	10976,81434769	10661,84828338	10096,77106373	11038,12167275	10828,59783676	11629,87380755	9642,23045505	11516,86999147	11352,97350199	11023,323213479
EnergiaReativaExcedente1773726	2,3687536	1,9335308	5,0906798	4,2345038	0,8704456	0,1855048	5,056708	3,2534688	0	0	0	0
cliente_1710660_com_multaD493TVerde	37664,91866349	39482,79443674	47678,46065417	178407,92432657	205448,11972063	165704,19773126	47464,6172208	48013,752252	50135,75769891	208799,8277808	164520,7249632	35856,5495676
cliente_1710660_sem_multaD493TVerde	37664,91866349	39482,79443674	47678,46065417	178407,92432657	199844,13232063	165704,19773126	47464,6172208	44299,160052	50135,75769891	205625,0627808	164520,7249632	35856,5495676
cliente_1710660_multa_ultrapassagem_D493TVerde	0	0	0	0	5603,9874	0	0	3714,5922	0	3174,765	0	0
EnergiaReativaExcedente1710660	5951,3079152	5057,3353122	5477,6927564	269,6918726	1,7801326	352,5911138	5536,5619912	6396,6300246	5613,8069034	252,6575376	137,6017528	4653,7339458
cliente_9011170_com_multaD70TVerde	5019,73565057	4380,43879329	4745,46721431	3272,82030327	2271,10651881	3575,44285406	3788,74565486	3707,71274001	3872,58617927	3731,99001827	3733,8126312	2883,7722153
cliente_9011170_sem_multaD70TVerde	5019,73565057	4380,43879329	4745,46721431	3272,82030327	2271,10651881	3575,44285406	3788,74565486	3707,71274001	3872,58617927	3731,99001827	3733,8126312	2883,7722153
cliente_9011170_multa_ultrapassagem_D70TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9011170_sugestDemanda30MenorTVerde	3848,23565057	3208,93879329	3573,96721431	2556,32030327	1099,60651881	2403,94285406	2617,24565486	2536,21274001	2701,08617927	2560,49001827	2562,3126312	1712,2722153
EnergiaReativaExcedente9011170	834,5290168	890,316018	1014,5899644	1051,9620468	868,2552164	865,1515784	650,4832834	374,345119	0	0	0	0
cliente_9009354_com_multaD368TVerde	35963,23955606	33107,852154	36798,926538	38088,35606925	38272,9272165	37271,30555306	35874,87105881	35460,6096855	27528,89320444	40867,381089	49492,84801219	57180,61568362
cliente_9009354_sem_multaD368TVerde	35963,23955606	33107,852154	36798,926538	38088,35606925	38272,9272165	37271,30555306	35874,87105881	35460,6096855	27528,89320444	40867,381089	49492,84801219	57180,61568362
cliente_9009354_multa_ultrapassagem_D368TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009354_sugestDemanda200MenorTVerde	31042,93955606	28187,552154	31878,626538	33168,05606925	33352,6272165	32351,00555306	30954,57105881	30540,3096855	22608,59320444	35947,081089	44572,54801219	52260,31568362
EnergiaReativaExcedente9009354	3288,5327746	3199,1337306	3514,1529876	3231,4258354	1289,454567	1096,3042888	161,6531636	164,4143312	41,3854074	28,503526	0	0
cliente_9008188_com_multaD150TVerde	52416,1916295	48894,04627575	52603,12688175	47273,161062	5117,953363	46117,93000275	47734,6449	49551,2443365	47681,804817	47991,21189825	46764,06666325	49270,1495355
cliente_9008188_sem_multaD150TVerde	49885,7516295	47052,44827575	50564,71688175	44939,533062	49727,979363	45260,39200275	46286,6709	48890,5183365	45938,612817	45067,14789825	44233,62866325	47034,9275355
cliente_9008188_multa_ultrapassagem_D150TVerde	2530,44	1841,598	2038,41	2333,628	1447,974	857,538	1447,974	660,726	1743,192	2924,064	2530,44	223,222
cliente_9008188_sugestDemanda170MaiorTVerde	51830,4416295	48308,29627575	52017,37688175	46687,411062	50313,729363	45846,14200275	46872,4209	49476,263365	47096,054817	47405,46189825	46178,31866325	48684,3995355
EnergiaReativaExcedente9008188	16,4778206	19,103427	9,3323184	28,18246	19,3959538	5,5722788	1,0131416	11,2979558	0,035674	0,6706712	37,1330662	24,1477306
cliente_9008099_com_multaD35TVerde	8896,94635758	8007,6959928	8971,09860507	8540,25025952	7975,90530125	8367,37837671	9292,54342404	11806,14170436	10640,68938224	12336,00315236	11053,44092094	11819,78377407
cliente_9008099_sem_multaD35TVerde	8896,94635758	7856,3381928	8971,09860507	8540,25025952	7975,90530125	8237,95105671	9292,54342404	11678,40134436	10640,68938224	12336,00315236	11053,44092094	11819,78377407
cliente_9008099_multa_ultrapassagem_D35TVerde	0	151,3578	0	0	0	129,42732	0	127,74036	0	0	0	0
EnergiaReativaExcedente9008099	15,8642278	14,9260016	20,4697412	32,962776	9,899535	15,7893124	5,5366048	2,9145658	2,0833616	1,2200508	3,4032996	0
cliente_9007986_com_multaD30TVerde	7051,51920345	5966,23601565	7144,37289037	6161,9672751	6625,14100755	6012,75895612	6142,6239666	6863,00438805	7712,2477098	9253,03556888	8675,01029257	8854,9244124
cliente_9007986_sem_multaD30TVerde	7051,51920345	5966,23601565	7144,37289037	6161,9672751	6625,14100755	6012,75895612	6142,6239666	6863,00438805	7511,2183098	8992,96256888	8533,02449257	8693,2574124
cliente_9007986_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	201,0294	260,073	141,9858	161,667
EnergiaReativaExcedente9007986	4,9515512	2,5613932	0,9489284	8,5581926	0,0285392	0	1,0737874	1,872885	0	0	0	0

cliente_9007102_com_multaD423TVerde	13508,48566838	13752,99861769	14067,67340287	13723,56213694	13963,52485594	13759,92019594	13792,28980181	13603,30186312	13844,29462894	14128,88560762	14059,44687281	14124,28120144
cliente_9007102_sem_multaD423TVerde	13508,48566838	13752,99861769	14067,67340287	13723,56213694	13963,52485594	13759,92019594	13792,28980181	13603,30186312	13844,29462894	14128,88560762	14059,44687281	14124,28120144
cliente_9007102_multa_ultrapassagem_D423TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9007102_sugestDemandada30MenorTVerde	1998,49816837	2243,01111769	2557,68590287	2213,57463694	2453,53735594	2249,93269594	2282,30230181	2093,31436312	2334,30712894	2618,89810762	2549,45937281	2614,29370144
EnergiaReativaExcedente9007102	2465,0805348	958,471195	222,4523616	161,3642042	288,1353306	2653,360772	3945,4480802	3132,3591374	0	0	0	0
cliente_9005679_com_multaD300TVerde	27362,63385188	31273,58888662	30975,51592613	33596,99114381	32870,28350606	30962,76481781	40878,65720794	42192,25982775	42000,90049556	39025,63821506	43402,0042875	30045,75671794
cliente_9005679_sem_multaD300TVerde	27362,63385188	31273,58888662	30975,51592613	33596,99114381	32870,28350606	30962,76481781	40878,65720794	42192,25982775	42000,90049556	39025,63821506	43402,0042875	30045,75671794
cliente_9005679_multa_ultrapassagem_D300TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005679_sugestDemandada275MenorTVerde	26630,44635187	30541,40138662	32043,32842613	32864,80364381	32138,0960606	30230,57731781	40146,46970794	41460,07232775	41268,71299556	38293,45071506	42669,8167875	29313,56921794
EnergiaReativaExcedente9005679	10,6807956	2,593498	0,1641004	3,4568106	0,2176114	4,9301468	0	0,4387902	0	0	0	0
cliente_9005078_com_multaD30TVerde	3919,68838297	4088,09583045	3794,96000198	3557,41529602	4232,83687852	3663,86504685	3927,51831487	4003,723263	4302,39785227	3969,34701412	4031,7031743	3734,11794765
cliente_9005078_sem_multaD30TVerde	3807,22438298	3965,79123045	3662,81480198	3366,22649602	4002,28567852	3663,86504685	3927,51831487	4003,723263	4170,25625227	3969,34701412	4031,7031743	3572,45094765
cliente_9005078_multa_ultrapassagem_D30TVerde	112,464	122,3046	132,1452	191,1888	230,5512	0	0	0	132,1452	0	0	161,667
cliente_9005078_sugestDemandada33MaiorTVerde	3895,08668298	4053,65373045	3750,67730198	3454,08899603	4090,14817852	3751,72754685	4015,38081487	4091,585763	4258,11515227	4057,20951412	4119,5656743	3660,31344765
EnergiaReativaExcedente9005078	115,869152	148,7284734	156,7301516	153,433874	135,828755	151,5645564	130,709536	160,033564	0	0	0	0
cliente_9002668_com_multaD50TVerde	3035,6131346	3448,41815412	3871,14109499	3782,37023568	4193,53158985	4110,83894919	4170,89812692	4610,68346626	5018,10592072	4993,61956342	4605,3162083	3610,70181281
cliente_9002668_sem_multaD50TVerde	3035,6131346	3448,41815412	3871,14109499	3782,37023568	4193,53158985	4110,83894919	4170,89812692	4610,68346626	5018,10592072	4993,61956342	4605,3162083	3610,70181281
cliente_9002668_multa_ultrapassagem_D50TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9002668_sugestDemandada35MenorTVerde	2596,3006346	3009,10565412	3431,82859499	3343,05773568	3754,21908985	3671,52644919	3731,58562692	4171,37096626	4578,79342072	4554,30706342	4166,0037083	3171,38931281
EnergiaReativaExcedente9002668	0,963198	1,533982	2,5364214	1,0060068	0,0749154	0,053511	0,2211788	0,1926396	0,1997744	0,1819374	0,695643	1,302101
cliente_9002660_com_multaD60TVerde	3342,439428	3999,37509094	3908,18713713	3835,35338747	4280,48642454	4161,85234433	3952,32926561	4379,22070685	4333,92032318	4204,08994846	4217,06495434	3529,7731371
cliente_9002660_sem_multaD60TVerde	3342,439428	3999,37509094	3908,18713713	3835,35338747	4280,48642454	4161,85234433	3952,32926561	4379,22070685	4333,92032318	4204,08994846	4217,06495434	3529,7731371
cliente_9002660_multa_ultrapassagem_D60TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9002660_sugestDemandada40MenorTVerde	2756,689428	3413,62509094	3322,43713713	3249,60338747	3694,73642454	3576,10234433	3366,57926561	3793,47070685	3748,17032318	3618,33994846	3631,31495434	2944,0231371
EnergiaReativaExcedente9002660	14,3302458	12,771292	11,1445576	8,2264244	6,3785112	4,566272	1,3520446	0,8597434	1,6160322	4,4164412	4,5020588	1,6695432
cliente_900626_com_multaD172TVerde	35341,15983694	37011,53307862	33939,09802744	30340,128738	34952,45411081	32073,13003331	31745,67833344	32833,92005381	30919,41453262	31945,76125594	31919,50669444	33249,237498
cliente_900626_sem_multaD172TVerde	34173,17433694	35425,32207862	33287,74402744	29196,744738	34301,10011081	31520,18203331	31745,67833344	32833,92005381	30919,41453262	31945,76125594	31919,50669444	33249,237498
cliente_900626_multa_ultrapassagem_D172TVerde	1167,9855	1586,211	651,354	1143,384	651,354	552,948	0	0	0	0	0	0
cliente_900626_sugestDemandada40MenorTVerde	34553,91183694	36630,79557862	33668,48152744	2957,482238	34681,83761081	31900,91953331	32126,41583344	33214,65755381	31300,15203262	32326,49875594	32300,24419444	33629,974998
EnergiaReativaExcedente900626	260,491548	317,0919164	342,131497	336,280961	307,1138986	293,8841706	293,7076094	287,7928602	0	0	0	0
cliente_9011619_com_multaD50TVerde	3165,81805507	3294,56400588	3384,58037263	2871,3043503	3147,14047727	2734,07092881	2833,26357233	3135,39318654	2893,63045677	3444,22401034	3126,83654807	2901,70531281
cliente_9011619_sem_multaD50TVerde	3165,81805507	3294,56400588	3384,58037263	2871,3043503	3147,14047727	2734,07092881	2833,26357233	3135,39318654	2893,63045677	3444,22401034	3126,83654807	2901,70531281
cliente_9011619_multa_ultrapassagem_D50TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9011619_sugestDemandada35MenorTVerde	2726,5055507	2855,25150588	2945,26787263	2431,9918503	2707,82797727	2294,75842881	2393,95107233	2696,08068654	2454,31795677	30043,11151034	2687,52404807	2462,39281281
EnergiaReativaExcedente9011619	3,2962776	4,5627046	5,297589	8,4226314	3,8278202	3,2320644	5,8719404	2,4151298	3,317682	1,8229414	1,3484772	1,9272722
cliente_9011153_com_multaD36TVerde	17769,66816554	16194,97721388	17840,14652487	16644,49726062	17989,38257436	17163,92791669	17656,7759798	18107,38006671	17323,62536831	17269,2941864	16792,90309371	17815,57716738
cliente_9011153_sem_multaD36TVerde	17769,66816554	16194,97721388	17840,14652487	16644,49726062	17989,38257436	17163,92791669	17656,7759798	18107,38006671	17323,62536831	17269,2941864	16792,90309371	17815,57716738
cliente_9011153_multa_ultrapassagem_D36TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9011153_sugestD36Ponta36FPontaMudarParaTAzul	16430,25393674	15048,22507878	16314,45815127	15690,16103052	16449,18204276	15823,24387249	16311,9067259	16390,31237211	16013,41689371	16148,3789075	15677,31326511	16323,77213328
EnergiaReativaExcedente9011153	10,4275102	34,8499306	4,4735196	0	29,8627054	52,0162594	495,8935718	0	0	0	0	0
cliente_9008883_com_multaD40TVerde	1856,97363066	2033,79022018	2158,43568094	2129,78214212	2169,65251258	1986,7238253	2013,15957369	2410,11628615	3345,61806515	3601,12158365	2171,32509736	1902,23643405
cliente_9008883_sem_multaD40TVerde	1856,97363066	2033,79022018	2158,43568094	2129,78214212	2169,65251258	1986,7238253	2013,15957369	2410,11628615	3345,61806515	3601,12158365	2171,32509736	1902,23643405
cliente_9008883_multa_ultrapassagem_D40TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9008883_sugestDemandada30MenorTVerde	1564,09863066	1740,91522018	1865,56068094	1836,90714212	1876,77752158	1693,8488253	1720,28457369	2117,24128615	3052,74306515	3308,24658365	1878,45009736	1609,36143405

EnergiaReativaExcedente9008883	0,1034546	0,0321066	valor_nao_econtrado	0,0035674	0,0214044	0,0071348	valor_nao_econtrado	0,017837	0,1926396	valor_nao_econtrado	0,0749154	0,071348
cliente_9007898_com_multaD70TVerde	11697,78405219	10548,05379356	11339,63084803	8759,28591853	10823,83192007	10026,0392713	10409,09521569	11267,71600226	10873,559484	11587,29455584	11773,11726883	12064,2657831
cliente_9007898_sem_multaD70TVerde	11697,78405219	10548,05379356	11339,63084803	8759,28591853	10823,83192007	10026,0392713	10409,09521569	11267,71600226	10873,559484	11587,29455584	11773,11726883	12064,2657831
cliente_9007898_multa_ultrapassagem_D70TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9007898_sugestDemandaN50MenorTVerde	11112,03405219	9962,30379356	10753,88084803	8173,53591853	10238,08192007	9440,28992713	9823,34521569	10681,96600226	10287,809484	11001,54455584	11187,36726883	11478,5157831
EnergiaReativaExcedente9007898	0,017837	0,1212916	valor_nao_econtrado	valor_nao_econtrado	4,1631558	valor_nao_econtrado	0,6028906	valor_nao_econtrado	0,3282008	0,0570784	0,0392414	
cliente_9007210_com_multaD60TVerde	11841,30751626	12485,72530533	14004,74861604	14557,49683092	15523,61981796	14352,12843693	15741,50991108	15718,06497183	16009,97420326	16144,35205902	14289,68851974	16691,08724828
cliente_9007210_sem_multaD60TVerde	11841,30751626	12485,72530533	14004,74861604	14557,49683092	15523,61981796	14352,12843693	15741,50991108	15718,06497183	16009,97420326	16144,35205902	14289,68851974	16362,69236828
cliente_9007210_multa_ultrapassagem_D60TVerde	0	0	0	0	0	0	0	0	0	0	0	328,39488
EnergiaReativaExcedente9007210	240,460597	227,5608786	254,6909556	254,3877266	207,5085232	164,2002872	169,6048982	185,5262044	0	0	0	0
cliente_9006863_com_multaD75TVerde	17927,52821862	20343,85861728	19099,8701766	18417,27394854	19254,45316908	17504,742063	18219,0485394	18805,24538232	18458,10077508	18683,52343554	23268,5380356	23296,5972714
cliente_9006863_sem_multaD75TVerde	17230,25141862	19678,07173728	18733,2375366	17901,06418854	19053,14260908	17287,686543	18219,0485394	18805,24538232	18458,10077508	17655,60247554	22098,9124356	22922,09280714
cliente_9006863_multa_ultrapassagem_D75TVerde	697,2768	665,78688	366,63264	516,20976	201,31056	217,0552	0	0	0	1027,92096	1169,6256	374,50512
cliente_9006863_sugestDemandaN50MaiorTVerde	17581,70141862	20029,52173728	19084,6875366	18252,51418854	19040,59269098	17639,136543	18570,4985394	19156,69538232	18809,50577508	18332,07343554	22917,0880356	23273,54280714
EnergiaReativaExcedente9006863	22,9704886	0	0	13,9806406	0	0	4,387902	31,2646936	0	0	0	0
cliente_9006457_com_multaD100TVerde	6841,1888019	6696,56385862	5314,32802905	4456,79406383	5181,1807431	6168,779433497	8861,1013044	12125,75117033	13079,71760895	14631,20593927	14805,74576708	14848,02604747
cliente_9006457_sem_multaD100TVerde	6841,1888019	6354,48585863	5314,32802905	4456,79406383	5181,1807431	6168,779433497	8528,8639044	11754,15137033	12757,32080895	13865,98213928	14178,29036708	14220,57064748
cliente_9006457_multa_ultrapassagem_D100TVerde	0	342,078	0	0	0	0	332,2374	371,5998	322,3968	765,2238	627,4554	627,4554
cliente_9006457_sugestDemandaN15MaiorTVerde	7280,5013019	6793,79838562	5753,64052905	4896,10656382	5620,4932431	6608,10683497	8968,1764044	12193,46387033	13196,63330895	14305,29463928	14617,60286708	14659,88314748
EnergiaReativaExcedente9006457	1232,9219792	1679,250954	1362,8787938	1288,027607	599,4052502	288,0604152	345,698897	31,000029	23,4948964	86,4131302	391,2117862	348,7026478
cliente_9006331_com_multaD130TVerde	27897,0966444	32423,714975	40799,1361713	38439,4154157	42514,3201749	38934,8085417	39635,8577316	42295,8423663	40131,2910846	40649,325165	40143,7886517	42064,4798202
cliente_9006331_sem_multaD130TVerde	27897,0966444	31509,0642975	40238,6905713	38036,4194157	41953,8745749	38610,5373417	39232,8617316	41341,7727663	39767,6574846	40649,325165	39819,5174517	40952,9606202
cliente_9006331_multa_ultrapassagem_D130TVerde	0	914,7072	560,4456	402,996	560,4456	324,2712	402,996	954,0696	363,6336	0	324,2712	1111,5192
cliente_9006331_sugestD140Ponta150FariaLima	31031,0835504	33232,6490985	37634,6235543	37657,55227187	38747,5522539	36996,3216627	37429,6854276	38600,4447513	37596,2347146	39023,318343	38094,0417567	39069,9673482
EnergiaReativaExcedente9006331	1200,3516172	670,3786732	1183,3529562	1199,520413	1125,3220604	1114,3380358	1289,8541158	1060,748553	964,7355494	948,6929516	1032,690952	792,6477408
cliente_9006247_com_multaD80TVerde	11739,53326628	11265,03075367	11495,51388713	10887,81585255	11811,12809955	10828,64400052	11080,2663231	12056,09993153	12025,89340725	12626,5619193	12120,31349445	12239,2446081
cliente_9006247_sem_multaD80TVerde	11739,53326628	11265,03075367	11495,51388713	10887,81585255	11811,12809955	10828,64400052	11080,2663231	12056,09993153	12025,89340725	12626,5619193	12120,31349445	11867,1762081
cliente_9006247_multa_ultrapassagem_D80TVerde	0	0	0	0	0	0	0	0	0	0	0	372,0684
EnergiaReativaExcedente9006247	150,5942236	137,8015272	157,3187726	193,2781646	149,0887808	177,0036858	151,9141616	99,6339146	114,317333	126,0469442	139,2677286	140,6304754
cliente_9006152_com_multaD80TVerde	14970,07546512	14482,48266186	7125,00404802	8283,47966832	16067,5968993	13582,34480766	15168,84085554	14466,3527409	14862,65232702	15401,2260714	15752,5872069	16676,845602
cliente_9006152_sem_multaD80TVerde	14970,07546512	14482,48266186	7125,00404802	8283,47966832	16067,5968993	13582,34480766	15168,84085554	14466,3527409	14862,65232702	15401,2260714	15752,5872069	16676,845602
cliente_9006152_multa_ultrapassagem_D80TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9006152_sugestDemandaN70MenorTVerde	14735,77546512	14248,18266186	6890,70404802	8049,17966832	15833,2968993	13348,04480766	14934,54085554	14232,0527409	14628,35232702	15166,9260714	15158,2872069	16442,545602
EnergiaReativaExcedente9006152	7,384518	valor_nao_econtrado	3,8741964	3,03229	15,1507478	3,2534688	valor_nao_econtrado	96,6158942	valor_nao_econtrado	0,4601946	valor_nao_econtrado	valor_nao_econtrado
cliente_9001941_com_multaD142TVerde	20608,1759478	21510,10591215	20248,06755375	22171,97495947	23068,69746915	21862,23326985	21776,0254914	22960,69122968	21563,93207663	22867,72974975	23538,22687845	25406,18056365
cliente_9001941_sem_multaD142TVerde	20608,1759478	21510,10591215	20248,06755375	22171,97495947	23068,69746915	21862,23326985	21776,0254914	22960,69122968	21563,93207663	22867,72974975	23538,22687845	25406,18056365
cliente_9001941_multa_ultrapassagem_D142TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001941_sugestDemandaN50MenorTVerde	19085,2259478	19987,15591215	18725,11755375	20649,02495947	21545,74764915	20339,28326985	20253,0754914	21437,74122968	20771,99807663	22380,85434975	22015,27687845	23883,23056365
EnergiaReativaExcedente9001941	171,8630624	291,6385174	375,9896904	558,940232	492,4474634	536,3728596	444,0628172	14,1304714	0	0	0	0
cliente_9001789_com_multaD234TVerde	84658,90904923	83601,13351269	85778,83797519	84882,85550434	84721,06647681	81394,3571175	83386,91357936	90585,46749471	90842,70536524	93070,58754729	91064,00190484	94867,89478791
cliente_9001789_sem_multaD234TVerde	84658,90904923	83601,13351269	85778,83797519	84882,85550434	84721,06647681	81394,3571175	83386,91357936	90585,46749471	90842,70536524	93070,58754729	91064,00190484	94867,89478791
cliente_9001789_multa_ultrapassagem_D234TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001789_sugestD234Ponta234FPontaMudarParaTAzul	82301,84539123	80106,41891469	82552,20991419	83606,68981234	81756,69416781	79687,8794925	81304,93340036	85640,83102671	86545,54517824	89333,83058529	87364,43239384	89705,83482591
EnergiaReativaExcedente9001789	67,3953208	12,5536806	99,9121718	42,0632134	valor_nao_econtrado	10,5630714	45,234632	2,0762268	16,9166108	1,7979696	5,0514384	17,8940784

cliente_9001739_com_multaD240TVerde	98356,18078671	14590,86018139	99451,91969711	94227,18874875	99921,61713954	94947,34807029	95349,36310457	101148,3004725	95117,81425104	96045,95738154	94526,58352532	100122,36843054
cliente_9001739_sem_multaD240TVerde	98356,18078671	14590,86018139	99451,91969711	94227,18874875	99921,61713954	94947,34807029	95349,36310457	101148,3004725	95117,81425104	96045,95738154	94526,58352532	100122,36843054
cliente_9001739_multa_ultrapassagem_D240TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001739_sogestD193Ponta193FPontaMudarParaTAzul	102759,56458671	26155,02921889	89426,63547461	87130,90219125	89608,68085704	85692,69926529	87187,01468957	89792,6254725	86853,42709854	88753,36772904	86444,89430282	89817,20652804
EnergiaReativaExcedente9001739	795,0985446	1332,1317372	90,736819	71,5370722	130,763047	184,8376962	914,5136922	47,6319248	980,222335	2035,861669	532,719842	608,9694496
cliente_9001387_com_multaD82TVerde	24759,17974807	25361,30315973	28818,77630576	19053,78045311	13880,78222302	29287,95088872	29396,92512162	29300,35499336	28635,51190017	29176,10686284	28310,7252389	30116,23576135
cliente_9001387_sem_multaD82TVerde	24759,17974807	25361,30315973	28818,77630576	19053,78045311	13880,78222302	29287,95088872	29396,92512162	29300,35499336	28635,51190017	29176,10686284	28310,7252389	30116,23576135
cliente_9001387_multa_ultrapassagem_D82TVerde	3118,533	0	0	0	0	0	0	0	0	0	0	0
cliente_9001387_sugestD75Ponta82FPontaMudarParaTAzul	24359,34233077	24430,61811873	26989,99488716	20291,11084811	15932,85468472	27302,73598722	27083,21675052	27328,38245246	26773,09333077	27573,09343944	26656,2713345	27556,98655525
EnergiaReativaExcedente9001387	31,74986	16,3315572	5,7506488	16,7097016	3,9455444	valor_nao_econtrado	8,3084746	19,0927248	0,0142696	valor_nao_econtrado	13,306402	25,0324458
cliente_9001078_com_multaD93TVerde	33342,90494402	37735,3163097	31003,38709556	36138,16884253	42995,87330021	44737,33117502	43041,67085788	44937,44223902	44507,08095671	45273,44322761	44413,57266941	46232,74561367
cliente_9001078_sem_multaD93TVerde	33342,90494402	37735,3163097	31003,38709556	35849,97984253	42547,42310021	44187,66337502	42390,78545788	44415,89043902	43929,29715671	44749,07982761	44413,57266941	46232,74561367
cliente_9001078_multa_ultrapassagem_D93TVerde	0	0	0	288,189	448,4502	549,6678	650,8854	521,5518	577,7838	524,3634	0	0
cliente_9001078_sugestD100Ponta100FPontaMudarParaTAzul	33476,07644852	36104,8481157	31086,65139956	35221,54284853	39266,82115571	40377,58296152	39587,91916438	40774,25492552	41689,25278421	42397,08438311	41728,92014291	42998,29325267
EnergiaReativaExcedente9001078	639,6383874	919,426002	955,7528362	1127,405422	665,569818	115,8548824	279,4059028	205,4394312	55,401722	159,1381466	115,1164306	62,3831238
cliente_9001053_com_multaD87TVerde	14529,19752274	13597,19446684	14439,9880755	13695,63459189	14489,6473728	14112,76099333	14782,11540296	16212,15320119	14893,49719738	14873,08909607	14727,89812097	15927,42802457
cliente_9001053_sem_multaD87TVerde	14529,19752274	13597,19446684	14439,9880755	13401,82239189	14176,1539728	13717,73119333	14367,40440298	15786,19580119	14893,49719738	14873,08909607	14727,89812097	15927,42802457
cliente_9001053_multa_ultrapassagem_D87TVerde	0	0	0	293,8122	313,4934	395,0298	414,711	425,9574	0	0	0	0
EnergiaReativaExcedente9001053	45,2274972	21,8467576	63,160817	135,1723534	64,6270184	40,989426	30,0089688	30,5262418	26,3916252	51,4847168	255,7861474	278,899332
cliente_1821218_com_multaD55TVerde	3083,04182801	3654,25542029	4063,34458653	3700,3489894	3834,63804093	3592,34887829	3118,75248526	3668,66554763	3735,88792173	3830,04496295	3800,63556348	3268,6438744
cliente_1821218_sem_multaD55TVerde	3083,04182801	3654,25542029	4063,34458653	3700,3489894	3834,63804093	3592,34887829	3118,75248526	3668,66554763	3735,88792173	3830,04496295	3800,63556348	3268,6438744
cliente_1821218_multa_ultrapassagem_D55TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1821218_sugestDemandad42MenorTVerde	2702,30432801	3273,51792029	3682,60708653	3319,6114894	3453,90054093	3211,61137829	2738,01498526	3287,92084763	3355,15042173	3449,30746295	3419,8906348	2887,9063744
EnergiaReativaExcedente1821218	52,9972944	34,9391156	40,0476324	49,6011296	32,0816282	30,6154268	36,8405398	32,4954466	32,3456158	32,3170766	24,133461	30,536944
cliente_1613489_com_multaD169TVerde	65128,77983865	59902,31276985	62541,10000297	59698,9784475	64497,14061517	61655,16158865	63694,34184645	67339,09233382	61443,5208834	63170,24704111	61797,84737617	64812,63748822
cliente_1613489_sem_multaD169TVerde	65128,77983865	59902,31276985	62541,10000297	59698,9784475	64497,14061517	61655,16158865	63694,34184645	67339,09233382	61443,5208834	63170,24704111	61797,84737617	64812,63748822
cliente_1613489_multa_ultrapassagem_D169TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1613489_sugestD169Ponta169FPontaMudarParaTAzul	62856,94675815	58220,18800785	60075,24215272	59504,6540625	61352,68736843	59591,48753265	61898,68950495	63117,86586158	60118,0026129	62390,1447186	60564,31513792	62099,61914047
EnergiaReativaExcedente1613489	valor_nao_econtrado	valor_nao_econtrado	100,3616642	30,0803168	19,2247186	72,828471	valor_nao_econtrado	valor_nao_econtrado	38,4494372	6,7887622	valor_nao_econtrado	57,1461806
cliente_1546319_com_multaD38TVerde	6551,21737956	6719,9340219	9135,61026086	10818,71682517	9633,23292546	8538,36465193	7542,88079457	6156,59334537	6151,39520112	5275,08360895	5347,46263518	5628,27479168
cliente_1546319_sem_multaD38TVerde	6551,21737956	6535,1181819	9135,61026086	10008,96186517	9633,23292546	8297,87913193	7368,18671457	6156,59334537	6151,39520112	5275,08360895	5347,46263518	5628,27479168
cliente_1546319_multa_ultrapassagem_D38TVerde	0	184,81584	0	179,75496	0	240,48552	174,69408	0	0	0	0	0
EnergiaReativaExcedente1546319	69,9638488	227,8070292	172,2055328	38,510083	29,60942	37,4648348	52,6155826	42,2879596	0	0	0	0
cliente_1228893_com_multaD196TVerde	88914,07288596	81833,37908106	89731,61627391	82976,93815971	87316,13842324	82146,3040338	86306,52554809	93420,23818046	87900,43195796	91163,72192537	89006,70068301	91666,37870809
cliente_1228893_sem_multaD196TVerde	88914,07288596	81833,37908106	87649,15787391	82976,93815971	87316,13842324	82146,3040338	86306,52554809	93420,23818046	87900,43195796	91163,72192537	89006,70068301	91666,37870809
cliente_1228893_multa_ultrapassagem_D196TVerde	0	0	208,4584	0	0	0	0	0	0	0	0	0
cliente_1228893_sugestDemandad210MenorTVerde	82995,20713446	76883,58979656	85502,40065991	78989,03404071	80110,02970324	77318,3781558	81431,37031159	84776,25787946	82482,04191896	86385,16336037	84020,17745301	84784,65599359
EnergiaReativaExcedente1228893	valor_nao_econtrado	212,4600744	27,5688672	valor_nao_econtrado	97,9750736	valor_nao_econtrado	valor_nao_econtrado	83,0241002	0	0	0	0
cliente_1215848_com_multaD230TVerde	26689,62996737	28208,85934389	27500,92085331	26223,93798909	29073,07459714	26222,532186	27510,16724554	30095,12752731	29966,66063451	30989,29630029	31159,61497766	33618,93411669
cliente_1215848_sem_multaD230TVerde	26689,62996737	28208,85934389	27500,92085331	26223,93798909	29073,07459714	26222,532186	27510,16724554	30095,12752731	29966,66063451	30989,29630029	31159,61497766	33618,93411669
cliente_1215848_multa_ultrapassagem_D230TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1215848_sugestDemandad210MenorTVerde	26103,87996737	27623,10934389	26915,17085331	25638,18798909	28487,32459714	25636,782186	26924,41724554	29509,37752731	29380,91063451	30403,54630029	30573,86497766	33033,18411669
EnergiaReativaExcedente1215848	335,5781832	377,96603	291,420906	541,0532884	224,710526	158,2998076	190,4492164	216,1166594	114,959465	167,9068158	144,6616374	121,2916
cliente_9004757_com_multaD105TVerde	38450,99259465	34813,776354	38308,97176515	38749,86975105	39135,71992755	38614,89442995	40106,94022312	37161,89076563	41849,74667437	40129,4819115	37252,4574066	39349,7183472

cliente_9004757_sem_multaD105TVerde	38450,99259465	34813,776354	38308,97176515	38749,86975105	39135,71992755	38614,89442995	40106,94022312	37161,89076563	41849,74667437	40129,4819115	37252,4574066	39349,7183472
cliente_9004757_multa_ultrapassagem_D105TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9004757_sugestD105Ponta105PontaMudarParaTAzul	37587,84317115	35410,6123035	37014,99211665	37996,1962705	38104,16879505	38353,54680495	38229,52574887	37351,10085487	39810,27956812	38647,448649	36818,6265231	37599,7548502
cliente_9006487_com_multaD398TVerde	148559,27744287	136526,46858713	154904,12334188	146892,75384825	152754,41287425	164679,40522275	174876,70421363	185457,38850637	170255,25776362	177740,58602887	142414,7936595	129681,228342
cliente_9006487_sem_multaD398TVerde	148559,27744287	136526,46858713	154904,12334188	146892,75384825	152754,41287425	164679,40522275	174876,70421363	185457,38850637	170255,25776362	177740,58602887	142414,7936595	129681,228342
cliente_9006487_multa_ultrapassagem_D398TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9006487_sugestD398Ponta398FPontaMudarParaTAzul	142602,81425662	133746,05558588	146600,76919313	144050,73968325	147495,21439425	155380,98442275	163695,10182488	168920,64200513	160440,97445737	167055,57216263	139780,636182	129415,125417
EnergiaReativaExcedente9006487	214,9572544	315,6328498	351,5637026	339,4060034	358,2418754	123,538956	227,189869	143,2453796	315,465182	412,355766	492,2405542	471,9384808
cliente_9002712_com_multaD65TVerde	3671,96192777	4442,2794858	5357,67849475	4930,72110901	4751,30609031	4616,46107989	5272,97989162	5750,75784804	6816,51552729	6214,68707313	5489,36871302	4618,29885065
cliente_9002712_sem_multaD65TVerde	3671,96192777	4442,2794858	5357,67849475	4930,72110901	4751,30609031	4616,46107989	5272,97989162	5750,75784804	6816,51552729	6214,68707313	5489,36871302	4618,29885065
cliente_9002712_multa_ultrapassagem_D65TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9002712_sugestDemandadoMenorTVerde	3525,52442777	4295,8419858	5211,24099475	4784,28360901	4604,86859031	4470,02357989	5126,54239162	5604,32034804	6670,07802729	6068,24957313	5342,93121302	4471,86135065
cliente_9000668_com_multaD94TVerde	29169,90877393	26890,21720232	29000,47576886	28593,22042123	31889,33487662	29189,73156384	32103,48420358	35264,14683409	30942,30098914	31415,01578256	32217,12793646	34397,37043594
cliente_9000668_sem_multaD94TVerde	29169,90877393	26890,21720232	29000,47576886	28593,22042123	31889,33487662	29189,73156384	32103,48420358	35264,14683409	30942,30098914	31415,01578256	31537,65793646	34397,37043594
cliente_9000668_multa_ultrapassagem_D94TVerde	0	0	0	0	0	0	0	0	0	0	679,47	0
cliente_900668_sugestD94Ponta94FPontaMudarParaTAzul	29375,19289393	27603,75141482	29618,30626286	29436,09008323	31537,26073712	29360,57086134	31630,04335408	33355,55543659	30664,45058314	31096,97615106	31803,48502646	33035,12359294
EnergiaReativaExcedente9000668	2,1297378	0,3531726	4,2345038	2,2082206	10,2170336	4,601946	2,3402144	3,0465596	5,7149748	1,3306402	4,2130994	1,5553864
cliente_9000517_com_multaD95TVerde	6532,77155991	7187,76366184	11945,77531196	14867,92029696	16494,90120332	13497,36304069	10112,50601908	12852,60043384	18524,60949146	17096,8133175	16199,96988686	13147,64713708
cliente_9000517_sem_multaD95TVerde	6532,77155991	7187,76366184	11945,77531196	14867,92029696	16494,90120332	13497,36304069	10112,50601908	12852,60043384	18524,60949146	17096,8133175	16199,96988686	13147,64713708
cliente_9000517_multa_ultrapassagem_D95TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_99000517_sugestDemandado85MenorTVerde	6239,89655991	6894,88866184	11652,90031196	14575,04529696	16202,02620332	13204,48804069	9819,63101908	12559,72543384	18684,87069146	17335,7993175	16613,27508686	13268,54593708
EnergiaReativaExcedente9000517	317,6270264	255,176122	198,52581	16,4528488	17,0022284	18,4898342	12,4537934	6,7209816	6,9243234	2,6184716	8,5403556	8,9862806
cliente_9005887_com_multaD80TVerde	5761,093783	6453,7690161	6526,26095595	6475,11235575	7191,24170378	6248,4330486	6717,77771505	7576,71286597	7364,04047543	7958,98954072	7359,82779097	6024,56434267
cliente_9005887_sem_multaD80TVerde	5761,093783	6453,7690161	6526,26095595	6475,11235575	7191,24170378	6248,4330486	6717,77771505	7576,71286597	7364,04047543	7958,98954072	7359,82779097	6024,56434267
cliente_9005887_multa_ultrapassagem_D80TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005887_sugestDemandado55MenorTVerde	5321,7812835	6014,4565161	6086,94845595	6035,79985575	6751,92920378	5809,1205486	6278,46521505	7137,40036597	6924,72797542	7519,67704072	6920,51529097	5585,25184267
EnergiaReativaExcedente90005887	222,2097786	180,3998506	203,966095	221,7424492	216,808735	166,4049404	169,3730172	154,1437866	141,2369334	143,10266386	144,7971986	170,7857076
cliente_9007375_com_multaD85TVerde	14928,22768819	14740,18723163	15283,13271262	13784,226078	13483,64718956	12236,72979188	11695,82382056	14391,78788869	14608,20191812	15243,06634013	14168,59700644	13288,02552244
cliente_9007375_sem_multaD85TVerde	14224,15618819	14232,92773163	14529,85821263	13129,357578	13483,64718956	12236,72979188	11695,82382056	13909,12988869	13953,33341812	14440,58884013	13218,51050644	12731,56302244
cliente_9007375_multa_ultrapassagem_D85TVerde	704,0715	507,2595	753,2745	654,8685	0	0	482,658	654,8685	802,4775	950,0865	556,4625	
cliente_9007375_sugestDemandado55MenorTVerde	14517,03118819	14525,80273163	14822,2322578	13776,52218956	12529,60479188	11988,69882056	14202,00488869	14246,20841812	14733,46384013	13875,72200644	13024,43802244	
EnergiaReativaExcedente9007375	1013,7908666	565,1617776	756,9951452	561,112778	913,9964192	768,025546	796,4149152	551,305996	628,308325	812,8178204	983,7141174	1245,7396474
cliente_9007812_com_multaD60TVerde	30058,37238497	27093,64545621	30375,23625767	28821,40584141	31629,52022674	34932,67541901	41653,0637877	41843,45159426	36301,6974993	29752,06985721	40739,40888463	40208,0670553
cliente_9007812_sem_multaD60TVerde	30058,37238497	27093,64545621	30375,23625767	28821,40584141	31370,85302674	33448,15619101	40331,6117877	40538,69194242	35013,9846993	28475,60345721	39474,18884643	38931,60066553
cliente_9007812_multa_ultrapassagem_D60TVerde	0	0	0	0	258,6672	1484,5248	1321,452	1304,5824	1287,7128	1276,4664	1265,22	1276,4664
cliente_9007812_sugestD80Ponta80FPontaMudarParaTAzul	29551,11944897	27521,95277121	29787,51848867	29153,31084441	30297,02055274	33032,05031601	3759,5930087	37390,83213262	33642,8685723	28582,39696821	36398,02165063	36429,22586653
EnergiaReativaExcedente9007812	0	53,164962	0	0	34,9319808	0	0,1819374	74,879726	282,2098792	0	343,308739	29,3382976
cliente_9005682_com_multaD210TVerde	23708,81383125	24934,75420444	24878,68246913	23155,83646519	24342,73040006	22080,44559844	23317,39657913	25189,50788362	24197,29694642	24262,37464556	24099,50622225	24094,409637
cliente_9005682_sem_multaD210TVerde	23708,81383125	24934,75420444	24878,68246913	23155,83646519	24342,73040006	22080,44559844	23317,39657913	25189,50788362	24197,29694642	24262,37464556	24099,50622225	24094,409637
cliente_9005682_multa_ultrapassagem_D210TVerde	0	0	0	0	0	0	108,4632296	146,3026414	155,859706	98,6992558	117,0142874	98,1819828
cliente_9005682_sugestDemandado160MenorTVerde	2244,43883125	23470,37920444	23414,30746913	21691,46146519	22878,35540006	20616,07059844	21853,02157913	23725,13288362	22732,92196462	22797,99964556	22635,13122225	22630,034637
EnergiaReativaExcedente9005682	0	154,2508086	0	0	108,4632296	146,3026414	155,859706	98,6992558	117,0142874	98,1819828	100,5364668	
cliente_9005711_com_multaD210TVerde	71845,83149906	69551,70050006	71391,98580656	68681,614068	73601,16816188	67773,37361269	68475,34933444	71420,32678388	69721,59464888	70059,20712469	72461,62514625	75180,58796569
cliente_9005711_sem_multaD210TVerde	71845,83149906	69551,70050006	71391,98580656	68681,614068	73601,16816188	67773,37361269	68475,34933444	71420,32678388	69721,59464888	70059,20712469	72461,62514625	75180,58796569

cliente_9005711_multa_ultrapassagem_D210TVerde	0	0	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005711_sugestD175Ponta200FPontaMudarParaTAzul	68788,05949969	66535,87775944	67622,21017219	66925,9697355	69486,16146563	65187,62525456	66193,82758256	67193,83331887	66665,90121638	67921,29544781	69406,68755625	70651,94646131		
EnergiaReativaExcedente9005711	0	411,8670322	0	0	0	572,218048	717,5718078	668,851826	716,9724846	735,6620932	609,8006538	623,7170812		
cliente_9005642_com_multaD76TVerde	4726,57255545	4743,86204377	4983,15570855	4721,03032597	5093,64640072	4832,15731957	4891,9721538	5131,01160053	5057,31072022	5249,60279063	4998,48826822	4768,36691813		
cliente_9005642_sem_multaD76TVerde	4726,57255545	4743,86204377	4983,15570855	4721,03032597	5093,64640072	4832,15731957	4891,9721538	5131,01160053	5057,31072022	5249,60279063	4998,48826822	4768,36691813		
cliente_9005642_multa_ultrapassagem_D76TVerde	0	0	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005642_sugestDemandaa50MenorTVerde	3965,09755545	3982,38704377	4221,68070855	3959,55532598	4332,17140073	4070,68231957	4130,4971538	4369,53660052	4295,83572022	4488,12779062	4237,01326822	4006,89191812		
EnergiaReativaExcedente9005642	1,3270728	0,0463762	0,2568528	0,820502	0,9560632	0,196207	0,0285392	0	0	0,0285392	0,0214044	0,5137056		
cliente_9001452_com_multaD52TVerde	19971,11447103	19387,60365251	20147,40198403	19234,99014049	20858,81079773	19987,06150463	20913,26663473	20879,13147845	22555,45091761	21853,79116123	19341,19311649	21306,59321689		
cliente_9001452_sem_multaD52TVerde	19971,11447103	19387,60365251	20147,40198403	19234,99014049	20858,81079773	19987,06150463	20913,26663473	20879,13147845	22555,45091761	21466,72756123	19341,19311649	21306,59321689		
cliente_9001452_multa_ultrapassagem_D52TVerde	0	0	0	0	0	0	0	0	0	387,0636	0	0		
cliente_9001452_sugestD52Ponta52FPontaMudarParaTAzul	18731,87514963	18191,69354231	18206,17737109	19084,64230313	18453,47119913	19531,12125163	19325,01680975	20781,29538031	20556,51609313	18259,39794739	20287,83531229			
EnergiaReativaExcedente9001452	21,261704	25,4212924	24,6007904	18,158066	11,2087708	11,1695294	12,468063	11,861605	14,4808274	87,2693062	5,0050622	4,6590244		
cliente_9006349_com_multaD53TVerde	19821,27743839	15823,16180347	17781,4113594	16557,69259099	17991,38997915	18295,19096062	17991,29895941	19810,75473634	19097,45469979	19155,7366071	18162,89631143	20551,85478855		
cliente_9006349_sem_multaD53TVerde	19821,27743839	15823,16180347	17781,4113594	16557,69259099	17991,38997915	18295,19096062	17991,29895941	19810,75473634	19097,45469979	19155,7366071	18162,89631143	20551,85478855		
cliente_9006349multa_ultrapassagem_D53Verde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9006349_sugestD53Ponta53FPontaMudarParaTAzul	19395,68730776	16066,00098772	17521,46411265	16933,97576861	17744,06530215	18058,90158413	17793,89767954	18910,7978271	18683,35337516	18901,0046736	18183,89572193	19719,05451105		
EnergiaReativaExcedente9006349	47,0397364	50,6249734	39,6124096	6,6068248	60,7456872	9,4429078	60,9811356	21,4507762	0	287,4269854	584,8645278	647,7720594		
cliente_9011197_com_multaD82TVerde	5030,40120588	4598,92644336	3871,59714007	2689,99134441	2824,88255583	2750,49791664	2721,84710675	2762,07200263	2821,67590969	2789,11724857	2913,02879823	2852,50286316		
cliente_9011197_sem_multaD82TVerde	5030,40120588	4598,92644336	3871,59714007	2689,99134441	2824,88255583	2750,49791664	2721,84710675	2762,07200263	2821,67590969	2789,11724857	2913,02879823	2852,50286316		
cliente_9011197_multa_ultrapassagem_D82TVerde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9011197_sugestDemandaa55MenorTVerde	4532,51370588	4101,03894336	3373,70964007	2192,10384441	2326,99505583	2252,61041664	2223,95960675	2264,18450263	2323,78840969	2291,22974857	2415,14129823	2354,61536316		
EnergiaReativaExcedente9011197	3,1072054	4,2309364	4,1239144	10,202764	2,5934998	2,7861394	2,7718698	2,9680768	2,6291738	2,3794558	2,5649606	2,6184716		
cliente_9011196_com_multaD38TVerde	2697,30008507	2426,17485897	3204,62266679	1894,566981	2589,46073068	2490,70179203	2421,92591846	2614,89715472	2877,256505	2527,84283843	5141,33054876	2791,87708916		
cliente_9011196_sem_multaD38TVerde	2697,30008507	2426,17485897	3204,62266679	1894,566981	2589,46073068	2490,70179203	2421,92591846	2614,89715472	2877,256505	2527,84283843	5230,66622877	2791,87708916		
cliente_9011196_multa_ultrapassagem_D38TVerde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9011196_sugestDemandaa30MenorTVerde	2463,00008507	2191,87485897	2970,32266679	1660,266981	2355,16073068	2256,40179203	2187,62591846	2380,59715472	2642,956505	2293,54283843	5375,63054877	2557,57708916		
EnergiaReativaExcedente9011196	0	0,838339	0	0	0	4,0275946	21,9002686	4,2202342	0	11,8223636	129,050695	3,620911		
cliente_9011198_com_multaD38TVerde	3250,81660242	2252,42212491	2422,9290031	1311,09963892	1206,32571263	1206,33550641	1207,3356188	1189,84166257	1204,60349596	1205,51129759	1218,60169839	1207,29091113		
cliente_9011198_sem_multaD38TVerde	3250,81660242	2252,42212491	2422,9290031	1311,09963892	1206,32571263	1206,33550641	1207,3356188	1189,84166257	1204,60349596	1205,51129759	1218,60169839	1207,29091113		
cliente_9011198_multa_ultrapassagem_D38TVerde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9011198_sugestDemandaa30MenorTVerde	3016,51660242	2018,12212491	2188,6290031	1076,79963892	972,02571263	972,03550641	973,0356188	955,54166257	970,30349596	971,21129759	984,30169839	972,99091113		
EnergiaReativaExcedente9011198	0	2,8824592	0	0	0	25,9385654	25,0538502	14,0698256	19,6171326	20,5517914	19,9167942	20,5624936		
cliente_9009240_com_multaD136TVerde	4859,79841538	4790,44229456	4830,193104	4773,98856206	4815,5129595	5399,56965038	4809,83096325	4813,60859175	4816,48832287	4852,61385262	4852,96517062	5323,10267513		
cliente_9009240_sem_multaD136TVerde	4859,79841538	4790,44229456	4830,193104	4773,98856206	4815,5129595	5399,56965038	4809,83096325	4813,60859175	4816,48832287	4852,61385262	4852,96517062	5323,10267513		
cliente_9009240_multa_ultrapassagem_D136TVerde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9009240_sugestDemandaa30MenorTVerde	1755,32341537	1685,96729456	1725,718104	1669,51356206	1711,0379595	2948,79165037	1705,35596325	1709,13359175	1712,01332288	1748,13885262	1748,49017062	2218,62767512		
EnergiaReativaExcedente9009240	158,3961274	140,2023874	145,5356504	96,7336184	140,5840992	197,2486808	138,9288256	120,7707596	57,684858	60,4210538	61,3093364	87,5011872		
cliente_9010240_com_multaD65TVerde	5404,58434267	5852,90552103	6566,30413109	5081,02356778	7298,17049463	6453,4706781	5822,55736992	6034,91378313	5386,4796044	5434,172244	5641,83153783	5863,72307066		
cliente_9010240_sem_multaD65TVerde	5404,58434267	5852,90552103	6566,30413109	5081,02356778	7298,17049463	6453,4706781	5822,55736992	6034,91378313	5386,4796044	5434,172244	5641,83153783	5863,72307066		
cliente_9010240_multa_ultrapassagem_D65TVerde	0	0	0	0	0	0	0	0	0	0	0	0		
cliente_9010240_sugestDemandaa35MenorTVerde	4525,95934267	4974,28052103	5687,67913109	4202,39856778	6419,54549463	5574,8456781	4943,93236992	5156,28878313	4507,8546044	4555,547244	4763,20653783	4985,09807066		
EnergiaReativaExcedente9010240	0	37,653907	0	0	0	53,707207	71,472859	59,1046832	50,6249734	48,7092796	66,9529632	67,1955464		
cliente_9006389_com_multaD40TVerde	6825,00661245	7454,47447478	6927,33002902	6403,1766183	6765,31151948	6373,45365937	6914,6300325	7318,92266235	7013,42234332	7898,39647942	8334,84370777	7577,8180308		

cliente_9006389_sem_multaD40TVerde	6540,56641245	6815,77267478	6564,16502902	5990,8086183	6372,62471947	5842,99845937	6364,4936325	6936,07646235	6581,37314332	7417,14427942	7568,21410777	6870,2320308
cliente_9006389_multa_ultrapassagem_D40TVerde	284,4402	638,7018	363,165	412,368	392,6868	530,4552	550,1364	382,8462	432,0492	481,2522	766,6296	707,586
cliente_9006389_sugestDemanda45MaiorTVerde	6687,00391245	7308,03697478	6710,60252902	6137,2461183	6519,60221947	6227,01615937	6768,1925325	7082,51396235	6866,98484332	7751,59897942	8188,40620777	7431,3805308
EnergiaReativaExcedente9006389	0	3,0608292	0	0	0	4,7196702	12,3895802	5,333263	1,9906092	1,1308658	0,5065708	1,1487028
cliente_9006387_com_multaD42TVerde	5946,56713845	6035,5370667	6211,47167407	5208,75608677	5810,17844992	5309,11849905	5366,24709712	5631,18064912	5622,68476005	5526,74223015	5686,13135865	4959,71799922
cliente_9006387_sem_multaD42TVerde	5946,56713845	5779,6814667	6044,18147407	5208,75608677	5810,17844992	5309,11849905	5366,24709712	5631,18064912	5622,68476005	5526,74223015	5686,13135865	4959,71799922
cliente_9006387_multa_ultrapassagem_D42TVerde	0	255,8556	167,2902	0	0	0	0	0	0	0	0	0
EnergiaReativaExcedente9006387	0	11,0446704	0	0	0	19,3424428	29,3347302	12,931825	9,1396788	17,3446988	21,5792026	24,2904266
cliente_9010726_com_multaD46TVerde	19786,32395385	17803,19377065	18705,39612143	16861,2779727	18349,79172968	18164,13567263	2105,2875119	22335,45732307	22336,65384127	22221,59863103	19439,22903833	19616,56574662
cliente_9010726_sem_multaD46TVerde	19786,32395385	17803,19377065	18705,39612143	16861,2779727	18349,79172968	18164,13567263	2105,2875119	22335,45732307	22177,32984128	22221,59863103	19439,22903833	19616,56574662
cliente_9010726_multa_ultrapassagem_D46TVerde	0	0	0	0	0	0	0	0	159,324	0	0	0
cliente_9010726_sugestD50Ponta50FPontaMudarParaTAzul	19166,96304285	17531,82274665	18137,05457918	17085,8907972	17876,53517392	17881,65376387	20126,3931654	20783,31118283	20873,55354652	21190,68147878	18972,47272808	18846,26308837
EnergiaReativaExcedente9010726	0	657,222102	0	0	0	33,3480552	47,5962508	56,5825314	63,214328	74,6086036	77,1307554	117,3103816
cliente_9009703_com_multaD80TVerde	13768,93358228	13140,96272513	13466,19150742	11647,40546185	12964,7359362	11656,6448193	12165,09540339	13037,11025609	12906,62212536	15168,5624545	15151,30914248	15303,24736069
cliente_9009703_sem_multaD80TVerde	13768,93358228	13140,96272513	13466,19150742	11647,40546185	12964,7359362	11656,6448193	12165,09540339	13037,11025609	12906,62212536	15168,5624545	15151,30914248	15303,24736069
cliente_9009703_multa_ultrapassagem_D80TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009703_sugestDemand45MenorTVerde	14919,20600228	12115,90022513	12441,12900742	10622,34296185	11939,6734362	10631,5823193	11140,03290339	12012,04775609	11881,55962536	14143,4999545	14126,24664248	14278,18486069
EnergiaReativaExcedente9009703	159,2344664	0	0	0	0	0	0	0	0	0	0	0
cliente_9009155_com_multaD70TVerde	5065,34997629	4856,65648706	5437,45059075	5383,51695942	5867,68633599	4926,07001594	4830,98919271	5090,97928953	5519,60352322	6624,09013942	9580,24138962	9575,49230935
cliente_9009155_sem_multaD70TVerde	5065,34997629	4856,65648706	5437,45059075	5383,51695942	5867,68633599	4926,07001594	4830,98919271	5090,97928953	5519,60352322	6624,09013942	9580,24138962	9575,49230935
cliente_9009155_multa_ultrapassagem_D70TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009155_sugestDemand30MenorTVerde	3893,84997629	3685,15648706	4265,95059075	4212,01695942	4696,18633599	3754,57001594	3659,48919271	3919,47928953	4348,10352322	5645,46589942	8497,02562962	8403,99230935
EnergiaReativaExcedente9009155	0	0,9239566	0	0	0	2,0655246	2,1333052	8,6794842	0,7027778	78,0582794	871,2161584	874,1949374
cliente_9010543_com_multaD30TVerde	12545,83117013	11670,42824082	12826,80333959	12035,68380307	12057,35059713	11867,30176767	12070,25981121	12116,66819706	12004,69827015	11327,05861421	11090,07720404	11530,10153924
cliente_9010543_sem_multaD30TVerde	12545,83117013	11670,42824082	12826,80333959	12035,68380307	12057,35059713	11867,30176767	12070,25981121	12116,66819706	12004,69827015	11327,05861421	11090,07720404	11530,10153924
cliente_9010543_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9010543_sugestDemand30Ponta50FPontaMudarParaTAzul	12009,77688173	11207,32355142	12086,49017399	11710,87237657	11524,04325633	11415,46992927	11588,15972001	11460,47382306	11350,90099665	11105,19293621	10891,45692224	11102,49985184
EnergiaReativaExcedente9010543	14,9045972	7,1740414	8,8043432	11,0446704	34,7500434	32,4740422	34,4753536	23,8052602	0	26,2096878	0	5,500308
cliente_9009423_com_multaD296TVerde	9310,5547215	9242,871618	9318,04508044	9262,65418106	9313,10274731	9271,51522275	9284,18733806	9299,74614356	9270,19618256	9280,17552431	9264,36465712	9291,6906315
cliente_9009423_sem_multaD296TVerde	9310,5547215	9242,871618	9318,04508044	9262,65418106	9313,10274731	9271,51522275	9284,18733806	9299,74614356	9270,19618256	9280,17552431	9264,36465712	9291,6906315
cliente_9009423_multa_ultrapassagem_D296TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009423_sugestDemand30MenorTVerde	1520,0797215	1452,396618	1527,57008044	1472,17918106	1522,62774731	1481,04022275	1493,71233806	1509,27114356	1479,72118256	1489,70052431	1473,88965712	1501,2156315
EnergiaReativaExcedente9009423	1026,9902468	910,3148624	1021,9459432	999,0039938	869,8783834	338,8173824	283,2230208	322,2717812	304,4133768	297,1251786	320,6807208	268,1222166
cliente_9010482_com_multaD62TVerde	25630,45323568	23316,17473316	24517,54351521	24305,66323175	23232,97859334	2119,22799641	22694,14402581	24195,98059854	23760,78123126	25193,56125218	27561,97197704	28354,78447022
cliente_9010482_sem_multaD62TVerde	25630,45323568	23316,17473316	24166,28095521	23851,4961175	22753,5070334	20693,73919641	2204,55074581	23692,89163854	23121,04851126	24278,85405218	26181,66381704	27023,39815022
cliente_9010482_multa_ultrapassagem_D62TVerde	0	0	351,26256	454,16712	479,47152	425,4888	489,59328	503,08996	639,73272	914,7072	1380,30816	1331,38632
cliente_9010482_sugestD62Ponta70FPontaMudarParaTAzul	24635,39673838	22647,39600716	23319,31343961	23628,13753055	22312,90640034	20769,33144081	21847,39508481	24026,28344814	22169,08799376	24213,79512338	26066,12954654	26264,87574932
EnergiaReativaExcedente9010482	483,186493	446,0070502	131,8118626	0,0107022	80,9657104	388,2508442	541,6276398	534,3216046	516,0636514	548,0560946	676,8570716	920,3214194
cliente_9001035_com_multaD60TVerde	27447,62831786	24591,05594994	26326,74744054	25158,29679131	24845,54978661	24728,58877532	24485,33354796	26682,69994099	25575,60709127	24326,18303756	25517,15839333	26371,85505171
cliente_9001035_sem_multaD60TVerde	27447,62831786	24591,05594994	26326,74744054	25158,29679131	24845,54978661	24728,58877532	24485,33354796	26682,69994099	25575,60709127	24326,18303756	25517,15839333	26371,85505171
cliente_9001035_multa_ultrapassagem_D60TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001035_sugestD60Ponta60FPontaMudarParaTAzul	25718,05770086	23155,16253744	24666,64954704	24256,24413881	23336,81475261	23602,37483282	23521,86329346	24750,19641049	24222,96433127	23543,61828656	24435,02086633	24760,28224671
EnergiaReativaExcedente9001035	0	274,0548028	0	0	0	617,1673348	8,115835	154,3542632	0,0142696	0	5,2761846	1,8514806
cliente_9001036_com_multaD70TVerde	26290,7209373	22109,65335858	21926,57051526	22594,00375738	22171,14606457	24882,65528482	27957,77300536	28714,77633588	27476,04258758	28579,92402693	27493,81299151	28954,61961964

cliente_9001036_sem_multaD70TVerde	26290,07209373	22109,65335858	21926,57051526	22594,00375738	22171,14606457	24882,65528482	27957,77300536	28714,77633588	27476,04258758	28579,92402693	27493,81299151	28954,61961964
cliente_9001036_multa_ultrapassagem_D70TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001036_sugestD70Ponta70FPontaMudarParaAzul	24484,58969843	21825,2841028	21994,20836526	21928,40095768	21735,67787017	24097,01605792	25805,04792736	26984,12234808	26046,2706308	27008,82623133	25861,02549061	27001,51470544
EnergiaReativaExcedente9001036	408,3567106	292,4233454	373,667313	289,0200458	249,4254732	14,1590106	35,3065578	21,564933	5,921884	0	10,2348706	9,4821492
cliente_768958_com_multaD88TVerde	15741,29887342	12965,81726377	8367,10025498	7777,7658558	8308,46215282	7932,87923302	8423,68223182	9010,33013805	8455,03811002	8181,48159225	7862,15516017	7984,71154905
cliente_768958_sem_multaD88TVerde	15741,29887342	12965,81726377	8367,10025498	7777,7658558	8308,46215282	7932,87923302	8423,68223182	9010,33013805	8455,03811002	8181,48159225	7862,15516017	7984,71154905
cliente_768958_multa_ultrapassagem_D88TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_768958_sugestDemand70MenorTVerde	15214,12387343	12436,64226378	7839,92525497	7250,5908558	7781,28715282	7405,07423303	7896,50723183	8483,15513805	7927,86311003	7654,30659225	7334,98016018	7457,53654905
cliente_152068_com_multaD165TVerde	45874,86794743	43949,1138444	46107,17734963	43553,93059286	46029,32564811	43828,40794474	45079,26687926	46887,15893143	44480,98081131	42546,86549229	41901,27472491	43920,56668114
cliente_152068_sem_multaD165TVerde	45874,86794743	43949,1138444	46107,17734963	43553,93059286	46029,32564811	43828,40794474	45079,26687926	46887,15893143	44480,98081131	42546,86549229	41901,27472491	43920,56668114
cliente_152068_multa_ultrapassagem_D165TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_152068_sugestDemand150MenorTVerde	45435,55544743	43509,8013444	45667,86484963	43114,61809286	45590,01314811	43389,09544474	44639,95439726	46447,84643143	44041,66831131	42107,55299229	41461,96222491	43481,25418114
cliente_755839_com_multaD110TVerde	20012,61776391	2115,58726295	21644,25558699	19427,25731323	21230,64297079	18293,57297906	18307,89708287	19987,88242406	20118,85300406	20817,26015216	20232,46558579	20742,07606862
cliente_755839_sem_multaD110TVerde	20012,61776391	2115,58726295	21644,25558699	19427,25731323	21230,64297079	18293,57297906	18307,89708287	19987,88242406	20118,85300406	20817,26015216	20232,46558579	20742,07606862
cliente_1755839_multa_ultrapassagem_D110TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1755839_sugestDemand100MenorTVerde	19719,74276391	20822,71226295	21351,38058699	19134,38231323	20937,76797079	18000,69797096	18015,02208287	19694,70742406	19825,97800406	20524,38515216	19939,59058579	20449,20106862
cliente_9008507_com_multa150TVerde	6955,94165447	8367,92571896	8943,47962723	9016,2849423	9839,16474797	9704,71208709	9128,9133273	9906,5853546	9823,46576421	10130,46607517	10878,40601297	9086,51045666
cliente_9008507_multa_ultrapassagem_D150TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9008507_sugestDemand70MenorTVerde	4612,94165447	6024,92571896	6600,47962723	6673,2849423	7496,16474797	7361,71208709	6785,9133273	7563,5853546	7480,46576421	7787,46607517	8535,40612097	6743,51045666
cliente_768940_com_multa180TVerde	20974,18466419	20896,13791781	21041,28712613	18586,6203405	20568,70620394	19527,93395606	19414,37893219	21071,86809037	19462,92884044	19991,63402756	21049,496682	22554,01528013
cliente_768940_sem_multaD180TVerde	20974,18466419	20896,13791781	21041,28712613	18586,6203405	20568,70620394	19527,93395606	19414,37893219	21071,86809037	19462,92884044	19991,63402756	21049,496682	22554,01528013
cliente_768940_multa_ultrapassagem_D180TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_768940_sugestDemand160MenorTVerde	20388,43466419	20310,38791781	20455,53712613	18000,8703405	19982,95602394	18942,18395606	18828,62893219	20486,11809037	18877,17884044	19405,88402756	20463,746682	21968,26528013
cliente_9008304_com_multa70TVerde	13734,34017694	12236,11997062	13156,93871906	12717,10747669	15065,08096781	14538,94274544	14548,38071681	14332,0361175	13514,60390194	13719,16679719	14539,81287844	14255,47368487
cliente_9008304_sem_multa70TVerde	13734,34017694	12236,11997062	13156,93871906	12717,10747669	15065,08096781	14538,94274544	14548,38071681	14332,0361175	13514,60390194	13719,16679719	14539,81287844	14255,47368487
cliente_9008304_multa_ultrapassagem_D70TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9008304_sugestDemand55MenorTVerde	13295,02767694	11796,80747062	12717,62621906	12277,79479669	14625,76846781	14099,62975444	14109,06821681	13892,7236175	13075,29140194	13279,85429719	14100,50037844	13816,16118487
cliente_9005572_com_multa35TVerde	5058,82033102	5201,86664032	5738,33888888	5676,83298817	6061,94762843	5180,35338773	5323,88509417	5476,31242785	5241,69209745	5741,76763177	5565,30360682	5931,69145102
cliente_9005572_sem_multaD35TVerde	5058,82033102	5201,86664032	5738,33888888	5676,83298817	6061,94762843	5180,35338773	5323,88509417	5476,31242785	5241,69209745	5741,76763177	5565,30360682	5931,69145102
cliente_9005572_multa_ultrapassagem_D35TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005572_sugestDemand30MenorTVerde	4912,38283102	5055,42914032	5591,9013888	5530,39548817	5915,51012842	5033,91588773	5177,44759417	5329,87492785	5095,25459745	5595,33013177	5418,86610683	5785,25395102
cliente_900884_com_multa80TVerde	4887,88681743	5047,95145342	5669,51297777	5140,72344427	5196,99157883	4824,15259129	4853,404865	5219,19515308	5786,21708655	5714,64683493	5458,68185403	4811,10349867
cliente_900884_sem_multa80TVerde	4887,88681743	5047,95145342	5669,51297777	5140,72344427	5196,99157883	4824,15259129	4853,404865	5219,19515308	5786,21708655	5714,64683493	5458,68185403	4811,10349867
cliente_900884_multa_ultrapassagem_D80TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_900884_sugestDemand50MenorTVerde	4009,26181743	4169,32645342	4790,88797777	4262,09844427	4318,36657883	3945,52759129	3974,779865	4340,57015308	4907,59208655	4836,02183493	4580,05685403	3932,47849867
cliente_9005970_com_multa95TVerde	10019,0116065	10070,3806575	10018,86440025	9023,28047794	10549,91112319	10392,34674244	9802,44764344	11429,91565594	10865,325501	10753,40090288	10805,58241219	10261,243206
cliente_9005970_multa_ultrapassagem_D95TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005970_sugestDemand75MenorTVerde	9286,8241065	9338,1931575	9286,67690025	8291,09297794	9817,72362319	9660,15924244	9070,26014344	10697,72815594	10133,138001	10021,21340288	10073,3941219	9529,055706
cliente_1418976_com_multa160TVerde	14297,93877643	13987,30858659	13166,82846317	14026,25352154	13583,27745883	12766,55675854	13653,48517466	13720,83084017	13978,94702199	14762,14371763	13905,82098347	14156,66122513
cliente_1418976_sem_multa160TVerde	14297,93877643	13987,30858659	13166,82846317	14026,25352154	13583,27745883	12766,55675854	13653,48517466	13720,83084017	13978,94702199	14762,14371763	13905,82098347	14156,66122513
cliente_1418976_multa_ultrapassagem_D160TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1418976_sugestDemand80MenorTVerde	11954,93877643	11644,30858659	10823,82846317	11683,25352154	11240,27745883	10423,55675854	11310,48517466	11377,83084017	11635,94702199	12419,14371763	11562,82098347	11813,66122513

cliente_9010270_com_multa114TVerde	4433,98248157	4282,85082833	4460,24882063	4624,212207	5200,18308217	5258,1456189	4914,97699785	5165,7522774	4914,48506437	4911,97149053	5181,83317012	4887,3914427
cliente_9010270_sem_multaD114TVerde	4433,98248157	4282,85082833	4460,24882063	4624,212207	5200,18308217	5258,1456189	4914,97699785	5165,7522774	4914,48506437	4911,97149053	5181,83317012	4887,3914427
cliente_9010270_sugestDemand35MenorTVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_768968_com_multa160TVerde	2120,26998157	1969,13832832	2146,53632062	2310,499707	2886,47058217	2944,4331189	2601,26449785	2852,0397774	2600,77256438	2598,25899053	2868,12067012	2573,6789427
cliente_768968_com_multa160TVerde	20789,41657236	21603,10185861	21455,03905016	19544,02452321	21079,69724383	11570,86526104	19839,84855276	21775,12156262	21260,73393077	20394,88729551	13936,49059631	13966,42369637
cliente_768968_sem_multaD160TVerde	20789,41657236	21603,10185861	21455,03905016	19544,02452321	21079,69724383	11570,86526104	19839,84855276	21775,12156262	21260,73393077	20394,88729551	13936,49059631	13966,42369637
cliente_768968_multa_ultrapassagem_D160TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_768968_sugestDemand35MenorTVerde	20496,54157236	21310,2685861	21162,16405016	19251,14952321	20786,82224383	11277,99026104	19546,97355276	21482,24656262	20967,85893077	20102,01229551	13643,61559631	13673,54869637
cliente_768963_com_multa280TVerde	37659,13024046	37692,79612903	37721,74973949	33295,38316569	36717,83374071	34578,2077944	36248,70170631	38495,18171451	36007,77031491	37028,82706466	36260,77936354	38005,15799374
cliente_768963_sem_multaD280TVerde	37659,13024046	37692,79612903	37721,74973949	33295,38316569	36717,83374071	34578,2077944	36248,70170631	38495,18171451	36007,77031491	37028,82706466	36260,77936354	38005,15799374
cliente_768963_multa_ultrapassagem_D280TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_768963_sugestDemand260MenorTVerde	37073,38024046	37107,04612903	37135,99973949	32709,63316569	36132,08374071	33992,4577944	35662,95170631	37909,43171451	35422,02031491	36443,07706466	35675,02936354	37419,40799374
cliente_43017_com_multaD164TVerde	51473,02076674	51594,41327451	52784,58457796	48345,46211944	51284,49190307	53995,18483191	56064,50989029	56121,0931953	55599,2914476	54649,10633117	55682,2119771	55604,81584419
cliente_43017_sem_multaD164TVerde	51473,02076674	51594,41327451	52784,58457796	48345,46211944	51284,49190307	53995,18483191	56064,50989029	56121,0931953	55599,2914476	54649,10633117	55682,2119771	55604,81584419
cliente_43017_multa_ultrapassagem_D164TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_43017_sugestDemand164Ponta164FPontaMudarParaTAzul	51604,27625674	51016,90445451	52494,33909896	49668,83240044	50816,21312207	52731,19825791	54926,46827229	53970,3522003	54674,0086956	54765,93602717	55336,3364901	54115,32905919
cliente_9009614_com_multa662TVerde	20850,17286375	20803,8868995	20881,21496512	20770,22592375	20840,17209825	20899,66313512	20930,47140262	21234,232107	21270,388824	21210,30711637	21191,66535075	21249,2045265
cliente_9009614_sem_multaD662TVerde	20850,17286375	20803,8868995	20881,21496512	20770,22592375	20840,17209825	20899,66313512	20930,47140262	21234,232107	21270,388824	21210,30711637	21191,66535075	21249,2045265
cliente_9009614_multa_ultrapassagem_D662TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009614_sugestDemand30MenorTVerde	2340,47286375	2294,1868995	2371,51496512	2260,52592375	2330,47209825	2389,63135135	2420,77140263	2724,532107	2760,688824	2700,60711638	2681,96535075	2739,5042565
cliente_9003664_com_multaD103TVerde	43767,6753279	38814,694149	45550,62805462	33529,04650117	44712,67335292	43497,18036157	42401,74615155	42313,31354467	40779,1019535	40793,68041735	41205,69609053	44020,8215676
cliente_9003664_sem_multaD103TVerde	43767,6753279	38814,694149	45550,62805462	33529,04650117	44712,67335292	43497,18036157	42401,74615155	42313,31354467	40779,1019535	40793,68041735	43224,6701676	
cliente_9003664_multa_ultrapassagem_D103TVerde	0	0	0	0	0	0	0	0	0	0	412,368	796,1514
cliente_9003664_sugestDemand110Ponta110FPontaMudarParaTAzul	42936,3579729	37710,971157	43451,83841137	35462,22308992	42337,85002867	42113,56889183	40932,95123205	40695,23973142	39821,1053955	40531,05895935	40198,06034828	41971,3324116
cliente_9006376_com_multa80TVerde	14086,39254585	15006,28877295	15030,27919185	13349,94554362	14019,85483987	12546,97884982	12520,03108013	13780,1107943	14238,1107943	14223,94569353	14845,3833277	14415,12815572
cliente_9009614_com_multa80TVerde	14086,39254585	14279,95877295	14422,03639185	13349,94554362	14019,85483987	12546,97884982	12520,03108013	13780,1107943	14238,1107943	13576,34049353	13954,49435572	
cliente_9009614_multa_ultrapassagem_D80TVerde	0	726,33	608,2428	0	0	0	0	0	0	647,6052	696,8082	460,6338
cliente_9009152_com_multa35TVerde	2696,05464748	2380,15135948	2671,33701049	2768,60113616	2513,29338693	2656,2151388	3040,88152233	2829,09668498	3097,79686821	2965,38538477	3492,83523432	3998,52315062
cliente_9009152_sem_multaD35TVerde	2696,05464748	2380,15135948	2671,33701049	2768,60113616	2513,29338693	2656,2151388	3040,88152233	2829,09668498	3097,79686821	2965,38538477	3492,83523432	3998,52315062
cliente_9009152_multa_ultrapassagem_D35TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009152_sugestDemand30MenorTVerde	2549,61714748	2233,71385948	2524,89950149	2622,16363616	2366,85586893	2509,77763888	2894,44402233	2682,65918498	2951,35936821	2818,94788477	3346,39773432	3852,08565062
cliente_9005136_com_multaD85TVerde	40534,76746402	36034,04572305	41848,5475455	39724,73187112	41657,10769282	42613,72421438	44231,6727819	41846,37249412	41088,01067227	41827,2222936	36858,50617005	37105,50762435
cliente_9005136_sem_multaD85TVerde	38851,55626402	34331,15332305	40076,7709455	38159,60787113	39796,76569282	40684,49801437	42184,3593819	39986,03049412	39513,04607227	39986,5614936	35273,70097005	35825,76102435
cliente_9005136_multa_ultrapassagem_D85TVerde	1683,2112	1702,8924	1771,7766	1565,124	1860,342	1929,2262	2047,3134	1860,342	1574,9646	1840,6606	1584,8052	1279,7466
cliente_9005136_sugestDemand120Ponta120FPontaMudarParaTAzul	37070,14752877	34605,86294055	37820,4663675	36555,97329188	38083,53393087	37931,37816113	39261,8552244	39101,35330087	37682,50757452	38110,2945246	35186,51319855	35781,95861235
cliente_9007262_com_multa50TVerde	8207,13955335	7844,35475325	8529,36676875	8751,01270762	12078,52459492	8245,18338007	8510,9774253	8764,43334795	8038,51231785	8719,060578	8587,52372272	
cliente_9007262_sem_multaD50TVerde	8207,13955335	7844,35475325	8529,36676875	8176,50910762	12015,93379493	8245,18338007	8510,9774253	8764,43334795	8038,51231785	8719,060578	8587,52372272	
cliente_9007262_multa_ultrapassagem_D50TVerde	0	0	0	574,5036	692,5908	0	0	0	0	0	0	0
cliente_9007111_com_multaD30TVerde	10124,47941982	9536,13158535	9873,18782002	8993,00460863	10157,91540142	10944,25568235	11745,73702673	12456,08359995	11733,66673012	12786,82411748	11933,40656467	10994,75124975
cliente_9007111_sem_multaD30TVerde	10124,47941982	9536,13158535	9873,18782002	8993,00460863	10157,91540142	10812,11048235	11613,59182672	12314,09779995	11601,52153012	12585,79471748	11732,37716467	10994,75124975
cliente_9007111_multa_ultrapassagem_D30TVerde	0	0	0	0	0	132,1452	132,1452	141,9858	132,1452	201,0294	201,0294	0
cliente_9007111_sugestD35Ponta35FPontaMudarParaTAzul	9965,58931507	9670,73512335	9613,77066277	9349,14558338	9828,35606017	10434,40397385	1129,53827847	11407,60387845	11230,08851438	11894,03656022	11357,46727342	10838,20425675
cliente_9010829_com_multa57TVerde	3967,52803016	4004,25498782	3953,75168611	3384,44766681	3528,57940847	3241,49206425	3280,2868233	3513,14172456	3569,87796477	3560,59016594	3668,23462343	3799,62269689
cliente_9010829_sem_multaD57TVerde	3967,52803016	4004,25498782	3953,75168611	3384,44766681	3528,57940847	3241,49206425	3280,2868233	3513,14172456	3569,87796477	3560,59016594	3668,23462343	3799,62269689

cliente_9010829_multa_ultrapassagem_D57TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9010829_sugestDemandada40MenorTVerde	3469,64053016	3506,36748782	3455,86418611	2886,56016681	3030,69190847	2743,60456425	2782,3993233	3015,25422456	3071,99046477	3062,70266594	3170,34712343	3301,73519689
cliente_9008953_com_multa45TVerde	3143,45439418	3237,84774913	3444,21370689	3024,15368938	3250,3043634	2934,37228637	2888,01086666	3107,86578069	3058,10065301	2906,80703788	3153,95721319	2796,1965225
cliente_9008953_sem_multa45TVerde	3143,45439418	3237,84774913	3444,21370689	3024,15368938	3250,3043634	2934,37228637	2888,01086666	3107,86578069	3058,10065301	2906,80703788	3153,95721319	2796,1965225
cliente_9008953_multa_ultrapassagem_D45TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9008953_sugestDemandada40MenorTVerde	2997,01689418	3091,41024913	3297,77620689	2877,71618938	3103,8668634	2787,93478637	2741,57336666	2961,42828069	2911,66315301	2760,36953788	3007,51971319	2649,7590225
cliente_9009109_com_multa98TVerde	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175
cliente_9009109_sem_multa98TVerde	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175	2870,175
cliente_9009109_multa_ultrapassagem_D98TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009109_sugestDemandada30MenorTVerde	878,625	878,625	878,625	878,625	878,625	878,625	878,625	878,625	878,625	878,625	878,625	878,625
cliente_9011757_com_multaD190TVerde	39754,92700868	38718,23953372	43172,4400317	40587,33497385	45008,6460948	42027,5805111	40388,07411157	42125,542335	42685,0615092	43552,428237	42225,13809675	41233,6099986
cliente_9011757_sem_multaD190TVerde	39754,92700868	38718,23953372	43172,4400317	40587,33497385	45008,6460948	42027,5805111	40388,07411157	42125,542335	42685,0615092	43552,428237	42225,13809675	41233,6099986
cliente_9011757_multa_ultrapassagem_D190TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9011757_sugestDemandada120FPonta120FPontaMudarParaTAzul	36525,35733893	35691,99149647	38944,7803407	37801,52043585	40071,0991278	38082,7570836	37310,42878432	38071,121745	38987,2474107	39958,466898	38973,42224175	37749,0946536
cliente_9005331_com_multaD160TVerde	25550,12370137	27321,73676674	30474,3569682	28363,94640206	31355,40239147	28367,29916044	29611,24667049	32682,8513832	32227,00028057	30962,49411849	29984,01602481	30790,69210929
cliente_9005331_sem_multaD160TVerde	25550,12370137	27321,73676674	30474,3569682	28363,94640206	31355,40239147	28367,29916044	29611,24667049	32682,8513832	32227,00028057	30962,49411849	29984,01602481	30790,69210929
cliente_9005331_multa_ultrapassagem_D160TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9005331_sugestDemandada100MenorTVerde	23792,87370137	25564,48676674	28717,1069682	26606,69640206	29598,15239147	26610,04916044	27853,99667049	30925,6013832	30469,75028057	29205,24411849	28226,76602481	29033,44210929
cliente_9000899_com_multaD95TVerde	90483,41241433	33016,472024223	35443,89812619	32064,61692257	35137,0098051	31768,8836889	33662,229501466	31690,81976121	32312,33098749	33107,17419223	32002,93433601	33811,6102683
cliente_9000899_sem_multaD95TVerde	33816,08301433	32221,25604223	34648,68392619	32064,61692257	34392,4044051	31768,8836889	32900,75041466	31690,81976121	32006,33518749	33107,17419223	32002,93433601	33235,7006863
cliente_9000899_multa_ultrapassagem_D95TVerde	56667,3294	795,2142	0	744,6054	0	761,475	0	305,9958	0	0	57,5094	
cliente_9000899_sugestDemandada108MenorTVerde	90102,67491433	32601,99354223	35029,42142619	32445,35442257	34773,1419051	32149,6211889	33281,49151466	32071,55726121	32387,07268749	33487,91169223	32383,67183601	33616,4383683
cliente_9005577_com_multaD30TVerde	13484,7012909	13918,8329394	14543,18165572	14094,51200707	14938,1646933	13171,15241438	14588,36611717	15437,95489702	15347,31931875	16413,7043268	16462,29034785	16597,70513137
cliente_9005577_sem_multaD30TVerde	12988,4538909	13215,9329394	13840,28165572	13273,52480707	14254,945893	12586,33961437	13846,10371717	14666,17069702	14437,76671875	15632,0795268	15483,85354785	15776,71793137
cliente_9005577_multa_ultrapassagem_D30TVerde	496,2474	702,9	702,9	802,9872	683,2188	584,8128	742,2624	771,7842	905,5526	781,6248	978,4368	820,9872
cliente_9005577_sugestDemandada5MenorTVerde	13427,7663909	13655,2454394	14279,59415572	13712,83730707	14694,2583933	13025,65211437	14285,41621717	15105,48319702	14877,07921875	16071,3920268	15923,16604785	16216,03043137
cliente_9008599_com_multaD30TVerde	11116,62052331	10785,79663125	10832,21506594	10924,95398887	11150,02923094	9374,76988519	9815,21284144	12272,25633244	14898,75856612	16955,62719319	15884,72620012	14042,19316781
cliente_9008599_sem_multaD30TVerde	9380,45752331	9689,27263125	9342,06706594	9164,18948887	9659,88123094	8081,43388519	8521,87684144	10462,28883244	13039,58806612	13767,97569319	13164,50320012	12109,21816781
cliente_9008599_multa_ultrapassagem_D30TVerde	1736,163	1096,524	1490,148	1760,7645	1490,148	1293,336	1293,336	1809,9675	1859,1705	3187,6515	2720,223	1932,975
cliente_9008599_sugestDemandada80MenorTVerde	10844,83252331	11153,64763125	10806,442026594	10628,56448887	11124,25623094	9545,880888519	9986,25184144	11926,66383244	14503,96306612	15491,25219319	14628,87820012	13573,59136781
cliente_9006303_com_multaD46TVerde	4416,99961822	3946,17151665	4268,78398687	4299,36032138	4892,18730337	4443,812631	4462,21865407	5102,04321487	4735,21150447	4966,81007783	4758,63418627	4838,4211059
cliente_9006303_sem_multaD46TVerde	4416,99961822	3946,17151665	4268,78398687	4299,36032138	4892,18730337	4443,812631	4462,21865407	5102,04321487	4735,21150447	4966,81007783	4758,63418627	4838,4211059
cliente_9006303_multa_ultrapassagem_D46TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9006303_sugestDemandada40MenorTVerde	4241,27461822	3770,44651665	4093,05898687	4123,63532137	4716,46230337	4268,087631	4286,49365407	4926,31821488	4559,48650448	4791,08507782	4582,90918628	4662,6961059
cliente_9009154_com_multaD35TVerde	2092,99902876	1907,90688355	1857,3406604	1938,88204409	2006,25675718	1828,50675619	1991,23743325	2265,04585786	2173,44065799	2103,26656899	1866,64942395	2011,48029555
cliente_9009154_sem_multaD35TVerde	2092,99902876	1907,90688355	1857,3406604	1938,88204409	2006,25675718	1828,50675619	1991,23743325	2265,04585786	2173,44065799	2103,26656899	1866,64942395	2011,48029555
cliente_9009154_multa_ultrapassagem_D35TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009154_sugestDemandada30MenorTVerde	1946,56152876	1761,46938355	1710,9031604	1792,44454409	1859,81925718	1682,06925619	1844,79993325	2118,60835786	2027,00315799	1956,82906899	1720,21192395	1865,04279555
cliente_9011538_com_multaD65TVerde	5426,73361243	4256,77380351	5335,91891793	4196,42208826	5447,44674237	5843,04248477	5165,76097458	3218,99095732	2823,78201419	2761,76061166	2761,67848688	2790,55444457
cliente_9011538_sem_multaD65TVerde	4427,95957243	4256,77380351	5335,91891793	4196,42208826	5447,44674237	5843,04248477	5165,76097458	3218,99095732	2823,78201419	2761,76061166	2761,67848688	2790,55444457
cliente_9011538_multa_ultrapassagem_D65TVerde	998,77404	0	0	0	0	0	0	0	0	0	0	0
cliente_9011538_sugestDemandada30MenorTVerde	6451,7961243	3231,71130351	4310,85641793	3171,35958826	4422,38424237	5005,79486477	4140,69847458	2193,92845732	1798,71951419	1736,69811166	1736,61598688	1765,49194457
cliente_430035_com_multaD38TVerde	7135,68283773	6542,37005866	6597,31910866	5408,66114113	8090,70781489	8132,01699759	7286,16797899	7674,50216767	9157,78810919	9197,48515059	9675,12484347	8793,05323735
cliente_430035_sem_multaD38TVerde	6659,02291773	6050,52749866	6378,76406866	5408,66114113	7745,63077489	7970,81859759	7143,5261389	7674,50216767	8743,54570919	8614,54675059	9243,16936347	8415,92395735

cliente_9009457_sugestDemandado30TVerde	9975,38709671	9004,18969313	10055,59841616	9692,02310496	9799,35932994	9514,76935437	10127,24888833	9964,18446907	9811,35257448	9796,56407232	10028,11229816	10316,45426561
cliente_9001783_com_multaD49TVerde	11889,10528839	11755,12199302	7875,01962105	1556,32422444	4884,42599538	10538,06890543	11024,04099781	11098,18198287	10632,84060288	10767,49890846	10480,08577613	11238,15240844
cliente_9001783_sem_multaD49TVerde	11889,10528839	11755,12199302	7875,01962105	1556,32422444	4884,42599538	10538,06890543	11024,04099781	11098,18198287	10632,84060288	10767,49890846	10480,08577613	11238,15240844
cliente_9001783_multa_ultrapassagem_D49TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001783_sugestDemandado35MenorTVerde	11479,08028839	11345,09699302	7464,99462105	1146,29922444	4474,40099538	10128,04390543	10614,01599781	10688,15698287	10222,8160288	10357,47390846	10070,06077613	10828,12740844
cliente_9001781_com_multaD30TVerde	9975,38709671	9004,18969313	10055,59841616	9692,02310496	9799,35932994	9514,76935437	10127,24888833	9964,18446907	9811,35257448	9796,56407232	10028,11229816	10316,45426561
cliente_9001781_sem_multaD30TVerde	9975,38709671	9004,18969313	10055,59841616	9692,02310496	9799,35932994	9514,76935437	10127,24888833	9964,18446907	9811,35257448	9796,56407232	10028,11229816	10316,45426561
cliente_9001781_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001614_com_multaD42TVerde	10884,50416611	9377,2554813	10257,69459173	7618,06689273	9815,86181919	8899,72515069	9551,02776859	8979,47686439	9768,85821383	9834,85233937	7291,72409404	8285,97956562
cliente_9001614_sem_multaD42TVerde	10884,50416611	9377,2554813	10257,69459173	7618,06689273	9815,86181919	8899,72515069	9551,02776859	8979,47686439	9768,85821383	9834,85233937	7291,72409404	8285,97956562
cliente_9001614_multa_ultrapassagem_D42TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9001614_sugestDemandado30MenorTVerde	10533,05416611	9025,8054813	9906,24459173	7266,61689273	9464,41181919	8548,27515069	9199,57776859	8628,02686439	9417,40821383	9483,40233937	6940,27409404	7934,52965562
cliente_9006386_com_multaD42TVerde	4460,11521015	4516,75183702	4956,19808857	4650,62211667	4807,81028385	4139,70557175	3983,08013152	4590,79128735	4973,84559585	5035,85943285	4874,45936985	4283,01408818
cliente_9006386_sem_multaD42TVerde	4460,11521015	4516,75183702	4956,19808857	4650,62211667	4807,81028385	4139,70557175	3983,08013152	4590,79128735	4973,84559585	5035,85943285	4874,45936985	4283,01408818
cliente_9006386_multa_ultrapassagem_D42TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9006386_sugestDemandado42TVerde	4460,11521015	4516,75183702	4956,19808857	4650,62211667	4807,81028385	4139,70557175	3983,08013152	4590,79128735	4973,84559585	5035,85943285	4874,45936985	4283,01408818
cliente_9009821_com_multaD30TVerde	4969,69130415	5083,01140659	4882,52497357	4761,800839695	5073,35235925	3982,85371718	4685,2179705	4965,10105672	5447,48561166	5908,71225811	5088,04351021	5635,95625233
cliente_9009821_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009821_sugestDemandado30TVerde	4969,69130415	5083,01140659	4882,52497357	4761,800839695	5073,35235925	3982,85371718	4685,2179705	4965,10105672	5447,48561166	5908,71225811	5088,04351021	5635,95625233
cliente_9008276_com_multaD300TVerde	13671,32057325	13610,4335865	13707,03688613	14169,97681969	19698,18581156	18041,54210205	12997,33040625	15280,1912715	15067,17184706	14643,4706115	13679,74930762	17267,09088112
cliente_9008276_sem_multaD300TVerde	13671,32057325	13610,4335865	13707,03688613	14169,97681969	19698,18581156	18041,54210205	12997,33040625	15280,1912715	15067,17184706	14643,4706115	13679,74930762	17267,09088112
cliente_9008276_multa_ultrapassagem_D300TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9008276_sugestDemandado30MenorTVerde	8399,57057325	8338,6835865	8435,26886812	8898,22681969	16376,98331156	14794,14410205	7725,58040625	10008,4412715	9795,42184706	9796,9751115	8407,99930762	11995,34088112
cliente_9007221_com_multaD32TVerde	2451,30026306	2944,14501227	4180,7019063	3658,93959317	3691,14822459	3257,59795144	3510,81612294	2624,38336468	3796,19597627	4597,44993504	2396,49124365	3329,41701523
cliente_9007221_multa_ultrapassagem_D32TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9007221_sugestDemandado32TVerde	2451,30026306	2944,14501227	4180,7019063	3658,93959317	3691,14822459	3257,59795144	3510,81612294	2624,38336468	3796,19597627	4597,44993504	2396,49124365	3329,41701523
cliente_9009280_com_multaD32TVerde	1082,96630262	912,12368554	976,72785939	884,02499	883,97931077	1881,19703243	1425,71487973	2355,84021051	1306,86298244	1084,87921105	1184,69947569	1049,72728848
cliente_9009280_multa_ultrapassagem_D32TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009280_sugestDemandado32TVerde	1082,96630262	912,12368554	976,72785939	884,02499	883,97931077	1881,19703243	1425,71487973	2355,84021051	1306,86298244	1084,87921105	1184,69947569	1049,72728848
cliente_9009280_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009600_com_multaD30TVerde	2797,64798714	2796,13426769	2797,53862059	2796,78379535	2950,26539786	2789,72545835	2791,93269098	2796,41317545	2795,56029432	2793,64270454	2783,66346408	2783,75923038
cliente_9009600_multa_ultrapassagem_D30TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_9009600_sugestDemandado20MenorTVerde	893,96048714	892,44676769	893,85112059	893,09629535	2265,12533786	886,03795835	888,24519098	892,72567545	891,87279432	889,95520454	879,97596408	880,07173038
cliente_1768833_com_multaD42TVerde	4412,85136648	4389,03492804	4457,98788311	4394,55052078	4418,82404036	4383,28375386	4363,84184023	4396,44980638	4385,74607942	4365,93575226	4374,66107809	4384,98777388
cliente_1768833_sem_multaD42TVerde	4412,85136648	4389,03492804	4457,98788311	4394,55052078	4418,82404036	4383,28375386	4363,84184023	4396,44980638	4385,74607942	4365,93575226	4374,66107809	4384,98777388
cliente_1768833_multa_ultrapassagem_D42TVerde	0	0	0	0	0	0	0	0	0	0	0	0
cliente_1768833_sugestDemandado30MenorTVerde	4412,85136648	4389,03492804	4457,98788311	4394,55052078	4418,82404036	4383,28375386	4363,84184023	4396,44980638	4385,74607942	4365,93575226	4374,66107809	4384,98777388
cliente_1810903_com_multaD71TVerde	17114,09484731	15538,98113877	16282,84392246	15903,81934181	15250,11243909	19417,16355177	20237,75903882	20836,39238113	21114,34721738	16289,22951346	12138,29629227	17779,64673123
cliente_1810903_sem_multaD71TVerde	15140,82024731	15538,98113877	16282,84392246	15903,81934181	15250,11243909	19417,16355177	20237,75903882	20836,39238113	21114,34721738	16289,22951346	12138,29629227	17779,64673123
cliente_1810903_multa_ultrapassagem_D71TVerde	1973,2746	0	0	0	0	0	0	0	0	0	0	0
cliente_1810903_sugestDemandado65MenorTVerde	17289,81984731	15363,25613877	16107,11892246	15728,09434181	15074,38743909	19241,43855177	20152,03403882	20660,66738113	20938,62221738	16113,50451346	11962,57129227	17603,92173123

cliente_9007292_com_multaD45TVerde	21342,15770393	19874,4608379	21033,0773076	20739,46314892	19169,12267475	18363,68846362	17445,36397972	9480,13492815	0	0	0	0
cliente_9007292_sem_multaD45TVerde	20917,60610392	19331,8220379	20539,6415076	20344,43334892	18980,74547475	18204,83306362	17445,36397972	9340,96072815	0	0	0	0
cliente_9007292_multa_ultrapassagem_D45TVerde	424,5516	542,6388	493,4358	395,0298	188,3772	158,8554	0	139,1742	0	0	0	0
cliente_9007292_sugestD50Ponta55FPontaMudarParaTAzul	20102,62477268	18677,4572379	19379,4669066	19186,90419668	18572,78532975	17914,55759588	17373,07348897	11543,52940965	0	0	0	0