

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CAMPUS DE ILHA SOLTEIRA

CAMILLA NAYARA SANTOS MOTA

**MODELAGEM HÍBRIDA COM REDES NEURAIS FUZZY ARTMAP E
CLUSTERIZAÇÃO K-MEANS APLICADA À PREVISÃO DE CARGA ELÉTRICA EM
NÍVEL DESAGREGADO**

Ilha Solteira - SP
2025



CAMILLA NAYARA SANTOS MOTA

**MODELAGEM HÍBRIDA COM REDES NEURAIS FUZZY ARTMAP E
CLUSTERIZAÇÃO K-MEANS APLICADA À PREVISÃO DE CARGA ELÉTRICA EM
NÍVEL DESAGREGADO:**

Tese, apresentada à Universidade Estadual Paulista (UNESP), Universidade Estadual Paulista "Júlio de Mesquita Filho", Ilha Solteira, para obtenção do título de Doutora em Engenharia Elétrica.

Área de Concentração: Automação

Orientadora: Prof^o Dra. Mara Lúcia Martins
Lopes

Ilha Solteira - SP

2025

FICHA CATALOGRÁFICA
Desenvolvida pela Diretoria Técnica de Biblioteca e Documentação

M917m Mota, Camilla Nayara Santos.
Modelagem híbrida com redes neurais Fuzzy ARTMAP e clusterização K-means aplicada à previsão de carga elétrica em nível desagregado / Camilla Nayara Santos Mota. -- Ilha Solteira: [s.n.], 2025
64 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2025

Orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Previsão de carga elétrica em nível desagregado. 2. Redes neurais Fuzzy ARTMAP. 3. Clusterização K-means.

IMPACTO POTENCIAL DESTA PESQUISA

Esta pesquisa propõe um modelo híbrido para previsão de carga elétrica em nível desagregado e com alta resolução temporal, combinando interpolação, codificação cíclica, suavização por média móvel ponderada, clusterização K-means e rede neural ARTMAP Fuzzy. A metodologia proposta opera com dados operacionais mínimos e demonstra resultados consistentes mesmo sob variabilidade comportamental significativa, o que favorece sua aplicação em instituições públicas com infraestrutura limitada. O método contribui tecnicamente para a especialização de previsores em contextos não estacionários e, do ponto de vista econômico e social, apoia o uso racional de energia e o planejamento energético de curto prazo. Destaca-se ainda pelo potencial de replicação em ambientes institucionais diversos, inclusive internacionais, e pela aderência aos princípios de sustentabilidade e inovação tecnológica. Os resultados fortalecem a formação de recursos humanos em áreas estratégicas como inteligência artificial e sistemas energéticos, além de alinharem-se às diretrizes dos Objetivos de Desenvolvimento Sustentável, promovendo eficiência energética e digitalização na gestão pública.

POTENTIAL IMPACT OF THIS RESEARCH

This research proposes an hybrid model for short-term electric load forecasting at a disaggregated level and high temporal resolution, combining interpolation, cyclic encoding, weighted moving average smoothing, K-means clustering, and Fuzzy ARTMAP neural networks. The proposed methodology operates with minimal operational data and demonstrates consistent results even under significant behavioral variability, enabling its application in public institutions with limited infrastructure. It contributes technically to the specialization of predictors in non-stationary contexts and, from an economic and social perspective, supports rational energy use and short-term energy planning. It stands out is easily replicable in institutional settings, including international ones, and aligns with principles of sustainability and technological innovation. The outcomes reinforce the training of professionals in strategic areas such as artificial intelligence and energy systems, while supporting the Sustainable Development Goals through energy efficiency and digitalization in public management.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MODELAGEM HÍBRIDA COM REDES NEURAIS ARTMAP FUZZY E CLUSTERIZAÇÃO K-MEANS APLICADA À PREVISÃO DE CARGA ELÉTRICA EM NÍVEL DESAGREGADO

AUTORA: CAMILLA NAYARA SANTOS MOTA

ORIENTADORA: MARA LUCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Doutora em Engenharia Elétrica, área: Automação pela Comissão Examinadora:

Documento assinado digitalmente



MARA LUCIA MARTINS LOPES

Data: 20/08/2025 06:58:22-0300

Verifique em <https://validar.iti.gov.br>

Profa. Dra. MARA LUCIA MARTINS LOPES (Participação Presencial)
Departamento de Matematica / Faculdade de Engenharia de Ilha Solteira - UNESP

Documento assinado digitalmente



ANNA DIVA PLASENCIA LOTUFO

Data: 18/08/2025 10:41:26-0300

Verifique em <https://validar.iti.gov.br>

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO (Participação Presencial)
Departamento de Engenharia Eletrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Documento assinado digitalmente



CARLOS ROBERTO MINUSSI

Data: 18/08/2025 10:10:53-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. CARLOS ROBERTO MINUSSI (Participação Presencial)
Departamento de Engenharia Eletrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Documento assinado digitalmente



CARLOS ROBERTO DOS SANTOS JÚNIOR

Data: 18/08/2025 15:51:07-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. CARLOS ROBERTO DOS SANTOS JÚNIOR (Participação Presencial)
Campus de Três Lagoas / Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul - IFMS



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

Prof. Dr. KENJI NOSE FILHO (Participação Virtual)

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - UFABC



Documento assinado digitalmente

KENJI NOSE FILHO

Data: 08/08/2025 17:42:54-0300

Verifique em <https://validar.iti.gov.br>

Ilha Solteira, 08 de agosto de 2025

Dedico este trabalho à minha mãe Márcia Célia dos Santos

AGRADECIMENTOS

Agradeço a Deus, acima de tudo, por me conceder saúde, forças e coragem para superar os desafios dessa caminhada e alcançar a realização deste sonho.

À minha mãe, Márcia Célia, aos meus avós, Vandolina e Lázaro, e ao meu tio Marcelo, agradeço por todo amor, apoio e dedicação ao longo da minha formação. São exemplos de esforço e generosidade que levo comigo em todos os momentos. Sem vocês, nada disso teria sido possível.

À minha orientadora, Prof^a Dra. Mara Lúcia Martins Lopes, deixo minha sincera gratidão pela orientação, pelos conselhos e pela confiança no meu trabalho. Seu apoio foi fundamental para que eu seguisse em frente, mesmo nas fases mais difíceis. Além de orientadora, se tornou uma grande amiga em toda essa jornada, desde a época do mestrado.

Aos colegas e professores do Laboratório de Sistemas Inteligentes (SINTEL), em especial ao amigo Reginaldo, agradeço pelo suporte técnico e pelas contribuições ao desenvolvimento deste trabalho.

Aos professores da FEIS–UNESP, que fizeram parte da minha formação acadêmica, agradeço pelas aulas, pelas orientações e pelos aprendizados que marcaram minha trajetória.

Por fim, agradeço a todos que, de alguma forma, contribuíram para a construção deste trabalho. Cada gesto, palavra de apoio ou incentivo teve seu valor e será sempre lembrado com carinho.

RESUMO

A previsão de carga elétrica em nível desagregado apresenta desafios relevantes devido à elevada variabilidade dos perfis de consumo, à ausência de variáveis contextuais e à presença de ruídos e padrões atípicos, especialmente em ambientes institucionais, onde o uso coletivo e irregular dos espaços, a sazonalidade acadêmica e a limitação de infraestrutura intensificam a complexidade da modelagem. Desenvolve-se uma metodologia híbrida para previsão horária de curto prazo, baseada na combinação entre redes neurais ARTMAP Fuzzy e o algoritmo de clusterização K-means, aplicada a dados reais de uma microrrede universitária. Utilizam-se séries temporais com resolução de 15 minutos, totalizando 96 registros por dia, no período de abril de 2012 a agosto de 2013. O processo de pré-processamento inclui a filtragem de dias não úteis, interpolação de dados ausentes, codificação cíclica das variáveis temporais e aplicação de suavização por média móvel ponderada. Os dados são segmentados por dia da semana, formando subconjuntos independentes de segunda a sexta-feira. Para cada previsão, calcula-se o perfil médio dos cinco dias úteis anteriores, que é comparado aos centróides obtidos pelo K-means. O cluster mais semelhante define o conjunto de treinamento da rede ARTMAP Fuzzy, com exclusão do dia-alvo. A metodologia é validada por meio da previsão de todos os dias do conjunto amostral, assegurando capacidade de generalização e adaptação a diferentes padrões de carga. Os resultados demonstram reduções significativas nas métricas de erro (MAPE, RMSE e MAE), sobretudo em dias com maior oscilação, mesmo diante de dados incompletos e sem uso de variáveis exógenas. A estrutura modular adotada, aliada à segmentação temporal e à seleção orientada por clusters do conjunto de treinamento, contribui para a robustez da previsão, oferecendo uma solução eficaz e escalável para sistemas elétricos com baixa agregação e restrição de informações auxiliares.

Palavras-Chave: Previsão de Carga Elétrica em Nível Desagregado; Redes Neurais ARTMAP Fuzzy; Clusterização K-means; Suavização; Microrredes Universitárias.

ABSTRACT

Short-term load forecasting at disaggregated levels poses significant challenges due to the high variability of consumption patterns, the absence of contextual variables, and the presence of noise and atypical behaviors, particularly in institutional environments, where collective and irregular use of spaces, academic seasonality, and limited infrastructure intensify the complexity of modeling. This work develops a hybrid methodology for hourly load forecasting, based on the combination of Fuzzy ARTMAP neural networks and the K-means clustering algorithm, using real data from a university microgrid. The time series employed have a 15-minute resolution, totaling 96 records per day, covering the period from April 2012 to August 2013. The preprocessing procedure includes the removal of non-business days, interpolation of missing data, cyclic encoding of temporal variables, and smoothing using a weighted moving average. Data are segmented by weekday, forming independent subsets from Monday to Friday. For each prediction, the average profile of the five most recent weekdays is calculated and compared to the centroids generated by K-means. The most similar cluster defines the training set for the Fuzzy ARTMAP neural network, excluding the target day. The methodology is validated through the prediction of all available days in the dataset, ensuring generalization capacity and adaptability to different load patterns. The results demonstrate significant reductions in forecasting errors (MAPE, RMSE, and MAE), especially on days with higher variability, even under incomplete data conditions and without the use of exogenous variables. The modular structure adopted, combined with temporal segmentation and cluster-driven selection of the training set, contributes to the robustness of the forecasting process, offering an effective and scalable solution for low-aggregation electrical systems with limited auxiliary information.

Keywords: Disaggregated Load Forecasting; Fuzzy ARTMAP Neural Networks; K-means Clustering; Smoothing; University Microgrids.

LISTA DE ILUSTRAÇÕES

Figura 1	Gráfico da Curva de Carga do Subconjunto de Segunda-feira	23
Figura 2	Gráfico da Curva de Carga do Subconjunto de Terça-feira	24
Figura 3	Gráfico da Curva de Carga do Subconjunto de Quarta-feira	24
Figura 4	Gráfico da Curva de Carga do Subconjunto de Quinta-feira	25
Figura 5	Gráfico da Curva de Carga do Subconjunto de Sexta-feira	25
Figura 6	Gráfico da Curva de Carga Interpolada – Segunda-feira	27
Figura 7	Gráfico da Curva de Carga Interpolada – Terça-feira	27
Figura 8	Gráfico da Curva de Carga Interpolada – Quarta-feira	27
Figura 9	Gráfico da Curva de Carga Interpolada – Quinta-feira	28
Figura 10	Gráfico da Curva de Carga Interpolada – Sexta-feira	28
Figura 11	Carga horária suavizada por Média Móvel Simples	29
Figura 12	Carga horária suavizada por Média Móvel Ponderada	30
Figura 13	Carga horária suavizada por Filtro Exponencial	30
Figura 14	Carga horária suavizada por Filtro de Savitzky–Golay	31
Figura 15	Carga horária suavizada por Regressão Local Loess	31
Figura 16	Perfis Médios de Consumo Diário Segmentados por Cluster (K-means) . .	33
Figura 17	Representação gráfica da metodologia de previsão de carga híbrida.	36
Figura 18	Curvas de Carga dos dias Úteis Anteriores	41
Figura 19	Cargas Diárias do Cluster Escolhido	42
Figura 20	Curva de Carga do Dia Teste - Carga Real	42
Figura 21	Curvas de Carga Real Sem Clusterização	45
Figura 22	Curva de Carga Suavizada sem Clusterização	45
Figura 23	Curva de Carga Real com Clusterização	46
Figura 24	Curva de Carga Suavizada com Clusterização	46

LISTA DE TABELAS

Tabela 1 – Resultados das previsões com carga real, sem aplicação da clusterização	
K-means	39
Tabela 2 – Resultados das previsões com carga suavizada, sem aplicação da clusterização	
K-means	40
Tabela 3 – Resultados das previsões com carga real e aplicação da clusterização K-means	43
Tabela 4 – Resultados das previsões com carga suavizada e aplicação da clusterização	
K-means	44

LISTA DE ABREVIATURAS E SIGLAS

RMSE	Raiz do Erro Quadrático Médio
MAE	Erro Absoluto Médio
MAPE	Erro Percentual Absoluto Médio
RMSE R	Raiz do Erro Quadrático Médio - Carga Real
MAE R	Erro Absoluto Médio - Carga Real
MAPE R	Erro Percentual Absoluto Médio - Carga Real
RMSE S	Raiz do Erro Quadrático Médio - Carga Suavizada
MAE S	Erro Absoluto Médio - Carga Suavizada
MAPE S	Erro Percentual Absoluto Médio - Carga Suavizada

LISTA DE SÍMBOLOS

a	Vetor de entrada da rede Fuzzy ARTMAP
b	Vetor de saída desejada da rede Fuzzy ARTMAP
$\bar{I}_a$	Vetor de entrada normalizado
$\bar{I}_b$	Vetor de saída normalizado
I^a	Vetor de entrada com codificação por complemento fuzzy
I^b	Vetor de saída com codificação por complemento fuzzy
w_j^a	Vetor de pesos do neurônio j no módulo de entrada
w_k^b	Vetor de pesos do neurônio k no módulo de saída
$w_{j,k}^{ab}$	Peso de associação entre os neurônios j e k na camada inter-ART
T_j^a	Função de escolha do neurônio j no módulo ART_a
T_k^b	Função de escolha do neurônio k no módulo ART_b
J	Índice do neurônio vencedor no módulo ART_a
K	Índice do neurônio vencedor no módulo ART_b
α	Parâmetro de escolha da rede (fator de regularização)
β	Taxa de aprendizado da rede
ρ_a	Parâmetro de vigilância do módulo de entrada
ρ_b	Parâmetro de vigilância do módulo de saída
ρ_{ab}	Parâmetro de vigilância da conexão cruzada (inter-ART)
n	Número de instantes de medição (tamanho da série)
Y_i	Valor real da carga no instante i
$\hat{Y}_i$	Valor previsto da carga no instante i

SUMÁRIO

1	INTRODUÇÃO	15
1.1	ORGANIZAÇÃO DO TEXTO	16
2	REVISÃO DA LITERATURA	18
3	METODOLOGIA HÍBRIDA PARA PREVISÃO DE CARGAS ELÉTRI- CAS	22
3.1	PRÉ-PROCESSAMENTO DE DADOS	22
3.2	SUAVIZAÇÃO DOS DADOS	28
3.3	CLUSTERIZAÇÃO K-MEANS	32
3.4	REDE NEURAL FUZZY ARTMAP	34
3.5	IMPLEMENTAÇÃO DA ABORDAGEM DE PREVISÃO COM REDES FUZZY ARTMAP E CLUSTERIZAÇÃO K-MEANS	35
4	RESULTADOS	38
4.1	SISTEMA PREVISOR DE CARGA EM NÍVEL DESAGREGADO	38
4.1.1	Resultados sem Clusterização (K-Means)	38
4.1.2	Resultados com Clusterização (K-Means)	40
4.1.3	Análise comparativa entre as abordagens	44
5	DISCUSSÃO	48
6	CONCLUSÃO	50
	REFERÊNCIAS	52
	APÊNDICE A – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO SEGUNDA-FEIRA - SEM CLUS- TERIZAÇÃO	55
	APÊNDICE B – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO SEGUNDA-FEIRA - COM CLUS- TERIZAÇÃO	56
	APÊNDICE C – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO TERÇA-FEIRA - SEM CLUS- TERIZAÇÃO	57

APÊNDICE D – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO TERÇA-FEIRA - COM CLUS- TERIZAÇÃO	58
APÊNDICE E – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO QUARTA-FEIRA - SEM CLUS- TERIZAÇÃO	59
APÊNDICE F – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO QUARTA-FEIRA - COM CLUS- TERIZAÇÃO	60
APÊNDICE G – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO QUINTA-FEIRA - SEM CLUS- TERIZAÇÃO	61
APÊNDICE H – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO QUINTA-FEIRA - COM CLUS- TERIZAÇÃO	62
APÊNDICE I – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO SEXTA-FEIRA - SEM CLUS- TERIZAÇÃO	63
APÊNDICE J – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO SEXTA-FEIRA - COM CLUS- TERIZAÇÃO	64

1 INTRODUÇÃO

A previsão da demanda de energia elétrica em curto prazo é uma atividade essencial para a operação e o gerenciamento eficiente dos sistemas de potência. Com o avanço das tecnologias de medição e a crescente disponibilidade de dados em alta resolução temporal, tornou-se viável monitorar o consumo elétrico em unidades desagregadas, como blocos institucionais, prédios públicos e setores industriais (Heghedus; Chakravorty; Rong, 2018). Essa dificuldade é intensificada pela natureza não linear das curvas de carga e pela influência de fatores exógenos, como condições meteorológicas, sazonalidade e hábitos de uso de energia (Ghelardoni; Ghio; Anguita, 2013; Saber; Alam, 2017).

Sistemas desagregados, como microrredes ou ambientes institucionais, apresentam variações significativas de consumo decorrentes da ocupação irregular, da operação intermitente de equipamentos e da influência de calendários acadêmicos ou administrativos (Hernández *et al.*, 2014). Tais características reduzem a previsibilidade das curvas de carga e inviabilizam a aplicação de modelos que assumem estabilidade estatística ao longo do tempo ou continuidade entre os dias (Panapakidis; Dagoumas, 2016).

Dentre os métodos aplicados à previsão de carga elétrica em curto prazo em ambientes com baixa agregação, destacam-se as Redes Neurais Artificiais (RNAs), que demonstram eficácia na previsão de séries temporais não lineares, especialmente nesse contexto. Quando combinadas com técnicas de agrupamento, como o algoritmo K-means, essas redes podem ser especializadas para subconjuntos de dias com padrões de consumo semelhantes, aumentando a precisão das previsões (Panapakidis; Dagoumas, 2016).

A segmentação prévia por agrupamento também foi explorada em uma arquitetura com três estágios, composta por mapas auto-organizáveis, clusterização K-means e RNA do tipo perceptron multicamadas, validada com sucesso na previsão de curto prazo em microgrids institucionais. O modelo demonstrou capacidade de adaptação a variações operacionais e padrões sazonais característicos de ambientes com uso intermitente (Hernández *et al.*, 2014).

Em outra direção, a aplicação de Redes Neurais com função de base radial em sistemas com alta variabilidade, como mercados de energia real, demonstrou bom desempenho na generalização de séries temporais ruidosas e complexas, o que reforça a viabilidade de arquiteturas alternativas em cenários operacionais desafiadores (Cecati *et al.*, 2015).

Apesar dos avanços encontrados na literatura, ainda persistem lacunas metodológicas importantes. Muitos modelos existentes assumem a disponibilidade dos dados reais do próprio dia de previsão, o que inviabiliza sua aplicação em cenários *ex-ante*, onde apenas informações históricas estão disponíveis. Além disso, os dados coletados nesse tipo de ambiente frequentemente apresentam lacunas, outliers e registros inconsistentes que comprometem a qualidade do modelo preditivo (Müller *et al.*, 2020).

Diante desse cenário, este trabalho propõe uma modelagem híbrida para previsão horária de

carga elétrica em nível desagregado, baseada na integração entre redes neurais Fuzzy ARTMAP e a técnica de clusterização K-means. O modelo é validado com dados reais de consumo de uma universidade brasileira, no período de 24 de abril de 2012 a 22 de agosto de 2013, em um sistema institucional composto por diferentes perfis de uso, caracterizado por elevada granularidade temporal e funcionamento descentralizado.

A metodologia proposta foi concebida para estimar a demanda de qualquer dia útil da semana, utilizando exclusivamente a sequência horária das medições diárias, sem pressupor continuidade temporal entre os dias analisados. Para validar essa abordagem, foram realizadas previsões para todos os dias contidos no banco de dados, garantindo uma avaliação exaustiva da sua robustez. O fluxo metodológico inicia-se com um rigoroso pré-processamento dos dados, incluindo reamostragem temporal para intervalos regulares de 15 minutos, codificação cíclica das horas, preenchimento de lacunas por interpolação e remoção de outliers e dias incompletos.

Na etapa subsequente, é implementada uma estratégia híbrida composta pela integração da técnica de clusterização K-means com a rede neural Fuzzy ARTMAP, complementada pela suavização dos perfis de carga por média móvel ponderada. Tal combinação visa atenuar flutuações de alta frequência e evidenciar padrões estruturais relevantes para o processo de previsão. O treinamento da rede é realizado de forma segmentada por dia da semana, de segunda a sexta-feira, com duas configurações distintas: uma considerando a clusterização e outra sem essa etapa, possibilitando a avaliação comparativa do impacto da segmentação nos resultados obtidos.

Para isso, são adotadas duas estratégias de treinamento da rede Fuzzy ARTMAP, ambas segmentadas por dia da semana, de segunda a sexta-feira. A primeira, sem uso de clusterização, utiliza 15 dias aleatórios de um mesmo dia da semana para treinamento e prevê, iterativamente, as demais ocorrências do subconjunto. A segunda aplica o algoritmo K-means para agrupar os dias do mesmo dia da semana em três clusters segundo a similaridade de seus perfis. A previsão de cada dia é feita com base na curva média dos cinco dias úteis anteriores, que é comparada aos centróides dos clusters para seleção do grupo mais próximo. Caso o dia previsto pertença ao cluster, ele é removido do conjunto de treinamento para evitar vazamento de informação. A rede é então treinada com os demais dias do grupo selecionado.

Para fins de validação, os resultados da previsão são apresentados em duas versões: utilizando a série de carga original e a série suavizada por média móvel ponderada. Ambas as versões são avaliadas sob duas configurações distintas, com e sem a etapa de clusterização, totalizando quatro cenários experimentais. Essa abordagem permite quantificar os efeitos das estratégias de segmentação e suavização sobre as métricas de desempenho, com ênfase na acurácia e robustez preditiva.

1.1 ORGANIZAÇÃO DO TEXTO

Este trabalho está organizado em seis capítulos, incluindo esta introdução.

O Capítulo 2 apresenta a revisão da literatura, na qual são discutidos os principais trabalhos relacionados à previsão de carga elétrica em nível desagregado. São abordadas as redes neurais Fuzzy ARTMAP, técnicas de pré-processamento de dados, métodos de suavização de séries temporais e estratégias de clusterização. O objetivo é estabelecer uma base conceitual sólida para a metodologia desenvolvida.

O Capítulo 3 descreve, de forma detalhada, os métodos e técnicas utilizados na construção do modelo híbrido proposto. São apresentados os procedimentos de interpolação, suavização, segmentação por dia da semana, aplicação do algoritmo K-means para agrupamento de perfis e a estrutura da rede Fuzzy ARTMAP empregada na tarefa de previsão.

No Capítulo 4, são apresentados os resultados obtidos a partir da aplicação do modelo sobre dados reais de consumo elétrico. A avaliação considera diferentes configurações, com e sem clusterização, e contempla todos os dias úteis da semana, utilizando métricas consolidadas de erro para aferição do desempenho.

O Capítulo 5 traz a discussão dos resultados, com base nas hipóteses da pesquisa e na comparação com estudos anteriores. São analisadas as vantagens e limitações da abordagem adotada, bem como sua robustez em cenários com alta variabilidade e ausência de variáveis exógenas.

Por fim, o Capítulo 6 apresenta as conclusões deste trabalho, sintetizando as principais contribuições obtidas e sugerindo direções para investigações futuras, com base nas lacunas identificadas ao longo do desenvolvimento da pesquisa.

2 REVISÃO DA LITERATURA

Neste capítulo, apresentam-se publicações relevantes ao tema desta pesquisa, com ênfase nos estudos sobre previsão de carga elétrica em nível desagregado, uso de redes neurais Fuzzy ARTMAP, técnicas de pré-processamento, suavização de dados e estratégias de clusterização. O objetivo é contextualizar metodologicamente a proposta deste trabalho com base nas contribuições científicas mais representativas da literatura.

A rede ARTMAP Fuzzy, cuja arquitetura favorece o aprendizado incremental com estabilidade categórica e adaptabilidade, conforme descrito por Carpenter *et al.* (1992). Aplicações dessa rede à previsão de cargas foram investigadas por Müller (2018), que avaliou o desempenho da Fuzzy ARTMAP em diferentes níveis de agregação e granularidade temporal. Utilizando a técnica Singular Spectrum Analysis (SSA) para remoção de ruídos, o autor observou que a rede apresenta resultados robustos mesmo em contextos de grande variabilidade, superando modelos estatísticos tradicionais e redes MLP. Essa análise demonstrou a eficácia do modelo em tarefas de previsão multi-horizonte, reforçando sua adequação a séries temporais com estrutura irregular.

Com foco em ambientes de baixa diversidade amostral, Alves (2019) propôs uma abordagem híbrida que integra a rede ARTMAP Fuzzy com o Método dos Mínimos Quadrados (MMQ). Ao aplicar a técnica à previsão de carga de curto prazo em uma universidade brasileira, o autor constatou ganhos significativos de precisão. A integração compensou limitações da rede isolada, notadamente em situações de alta sazonalidade e baixa representatividade estatística, característica comum em ambientes institucionais.

Fernández, Lotufo e Minussi (2023) propuseram uma abordagem híbrida para previsão de carga elétrica de curto prazo em nível desagregado no sistema SEIN (Peru), utilizando uma rede Fuzzy ARTMAP modificada (FAMM) combinada a máquinas de vetores de suporte (SVM). A metodologia empregou dados meteorológicos como variáveis de entrada e pré-processamento por decomposição wavelet com filtro db20, aplicando o modelo em diferentes níveis de agregação. Os resultados experimentais indicaram desempenho superior em relação a modelos tradicionais, com baixos erros de previsão e elevada flexibilidade paramétrica, destacando-se como uma estratégia eficiente para ambientes de alta variabilidade e granularidade temporal.

O avanço das tecnologias de medição e automação possibilitou a previsão de carga em unidades consumidoras menores. Nesse contexto, a previsão da demanda energética em edifícios passou a exercer papel estratégico tanto na otimização operacional quanto na sustentabilidade do sistema elétrico. Chitalia *et al.* (2020) ressaltaram que essa abordagem exige modelos capazes de lidar com elevada variabilidade temporal, influenciada por padrões de ocupação e fatores exógenos.

Modelos baseados em redes neurais profundas vêm sendo aplicados com sucesso nesse contexto. Chitalia *et al.* (2020) utilizaram arquiteturas do tipo LSTM e GRU para previsão de curto prazo em edifícios comerciais, evidenciando sua superioridade frente a técnicas tradicionais

na modelagem de séries não lineares. A robustez dessas arquiteturas decorre da capacidade de retenção de dependências temporais de longo alcance, característica ausente em modelos clássicos.

Na mesma direção, Jeong, Park e Ko (2021) desenvolveram modelos LMVAR, com e sem registro de curva, para previsão horária de consumo. A combinação de modelos autorregressivos demonstrou-se eficaz na captura de padrões sazonais abruptos, ajustando-se às oscilações de uso típicas de edifícios com ocupação variável.

Walker *et al.* (2020) realizaram uma comparação entre diferentes técnicas de aprendizado de máquina, como ANN, SVM e árvores de decisão, aplicadas ao consumo energético em edifícios comerciais. Os resultados evidenciaram que modelos com maior profundidade e estrutura hierárquica tendem a apresentar melhor desempenho, especialmente quando combinados a variáveis ambientais.

A importância das variáveis contextuais foi também destacada por Thokala, Bapna e Chandra (2018), que empregaram redes NARX em conjunto com SVR em previsões com granularidade de 15 minutos. A incorporação de dados climáticos, feriados e ocupação contribuiu significativamente para a melhoria da acurácia preditiva em janelas temporais curtas.

Gu, Cheng e Wang (2011) propuseram um modelo de previsão de carga elétrica de curto prazo com granularidade de 15 minutos, baseado em lógica fuzzy e segmentação diária por similaridade de padrão. A divisão do dia em blocos com características distintas permitiu a modelagem específica de cada faixa horária, resultando em baixos índices de erro preditivo.

Brito e Brito (2022) investigaram diferentes técnicas de previsão em edificações, incluindo MLP, LSTM, SVM e DT. Os autores verificaram que modelos com estrutura recorrente superaram os demais em horizontes de curto prazo, em virtude de sua capacidade de adaptação a oscilações rápidas no perfil de carga.

Khalil *et al.* (2022) conduziram uma revisão sistemática sobre previsão de consumo em edifícios, destacando o crescimento das abordagens híbridas multivariadas. Segundo os autores, a combinação entre modelos supervisionados e dados ambientais oferece maior robustez frente à volatilidade do consumo energético.

A segmentação do consumo por tipo de edificação tem sido apontada como fator determinante para a melhoria do desempenho preditivo. Em ambientes institucionais, essa prática se mostra ainda mais relevante devido à heterogeneidade de usos e horários. Hu, Lo e Hsieh (2025) demonstraram que a integração de redes convolucionais (CNN) e recorrentes (RNN), associada a sensores ambientais, permite identificar padrões distintos de consumo em ambientes como bibliotecas e laboratórios.

Ahmed, Jamil e Khan (2024) reforçaram a importância da inclusão de variáveis como temperatura e umidade, processadas por CNNs, para a detecção de flutuações térmicas e ocupacionais. A abordagem mostrou-se eficiente em antecipar variações súbitas de demanda, especialmente em locais com alta densidade de ocupação.

Gachhadar *et al.* (2023) investigaram um modelo que combina redes neurais profundas com

otimização por enxame de partículas (PSO), aplicado a edificações institucionais. Os resultados indicaram que a segmentação por categoria de uso reduz substancialmente os erros de previsão, mesmo em contextos com variações ocupacionais acentuadas.

Chan *et al.* (2024) propuseram um modelo de previsão de carga de curto prazo aplicado a edifícios de campus universitário, estruturado em séries temporais multivariadas. O estudo incorporou variáveis contextuais provenientes de condições meteorológicas e de características construtivas dos prédios, evidenciando que essa integração aumenta a estabilidade e a precisão das previsões em relação a abordagens que consideram apenas o histórico de carga.

Paralelamente às redes neurais, técnicas de agrupamento têm sido amplamente adotadas como etapa de pré-processamento em modelos de previsão de carga. Kouzelis *et al.* (2014) desenvolveram o método Pattern Sequence-based Forecasting (PSF), o qual associa o algoritmo K-means à identificação de sequências similares em séries históricas. A previsão foi realizada com base na média dos perfis subsequentes, demonstrando desempenho satisfatório em séries com comportamento cíclico.

No trabalho de Mori e Yuihara (2001), o recozimento simulado foi empregado como técnica determinística de agrupamento, voltada ao preparo dos dados de entrada para redes neurais. Essa abordagem favoreceu a separação de padrões heterogêneos, ampliando a aderência dos modelos às características específicas dos perfis analisados.

Panapakidis e Dagoumas (2016) apresentou uma estratégia de segmentação baseada em diferentes algoritmos de agrupamento, como K-means, mapas auto-organizáveis (SOM) e o método de entropia mínima (minCEntropy), com o intuito de identificar padrões típicos de carga e treinar modelos preditivos especializados para cada grupo. Os resultados obtidos indicaram ganhos expressivos de acurácia em horizontes day-ahead e hour-ahead, especialmente em cenários com elevada dinâmica e variações abruptas de consumo.

Em estudo voltado a microgrids institucionais, Hernández *et al.* (2014) estruturaram uma abordagem híbrida composta por mapas auto-organizáveis, clusterização por K-means e redes neurais do tipo Perceptron Multicamadas. A segmentação prévia dos perfis, seguida de um treinamento específico por cluster, contribuiu significativamente para a melhoria da acurácia preditiva em ambientes com elevada variabilidade, como universidades. A arquitetura mostrou ainda capacidade de adaptação a padrões sazonais e comportamentos operacionais intermitentes, evidenciando sua aplicabilidade em cenários reais.

A análise da literatura evidencia que os trabalhos recentes têm avançado na previsão de carga elétrica por meio de redes neurais, modelos híbridos e técnicas de pré-processamento. Contudo, nota-se que a maioria dessas contribuições permanece voltada a cenários de maior agregação ou depende de variáveis contextuais adicionais, o que restringe sua aplicabilidade em ambientes institucionais caracterizados por alta variabilidade e disponibilidade limitada de informações.

Diante desse panorama, este trabalho distingue-se ao propor uma modelagem híbrida que combina a rede Fuzzy ARTMAP com a clusterização K-means, validada com dados reais de uma universidade brasileira. A metodologia foi estruturada para estimar a demanda horária de

qualquer dia útil da semana, mesmo sob a presença de dados incompletos, configurando uma contribuição de caráter técnico-científico relevante para a literatura, especialmente no campo da previsão de carga em nível desagregado.

3 METODOLOGIA HÍBRIDA PARA PREVISÃO DE CARGAS ELÉTRICAS

Neste capítulo, são descritos os métodos e técnicas utilizados na construção do modelo híbrido de previsão de carga elétrica em nível desagregado, incluindo as etapas de pré-processamento, suavização de dados, clusterização e modelagem preditiva.

3.1 PRÉ-PROCESSAMENTO DE DADOS

Em problemas de previsão de carga elétrica, especialmente em contextos com alta granularidade temporal e baixa agregação estatística, a aplicação de técnicas de pré-processamento constitui uma etapa essencial para a melhoria da acurácia e da robustez dos modelos. Operações como regularização da série temporal, remoção de ruídos e tratamento de valores anômalos permitem reduzir inconsistências nos dados e evidenciar padrões relevantes ao processo preditivo (Müller *et al.*, 2020).

No presente trabalho, a base de dados é composta por medições reais de energia ativa, obtidas em um bloco específico de uma universidade brasileira. As medições foram realizadas por meio de instrumentos instalados junto ao transformador que alimenta exclusivamente a edificação analisada, o que assegura o caráter desagregado da carga monitorada, livre da influência de outras unidades consumidoras.

Ambientes institucionais, caracterizados por padrões de consumo dinâmicos e heterogêneos, exigem abordagens preditivas capazes de integrar variáveis de diferentes naturezas e escalas temporais. Em cenários como esse, a adoção de modelos híbridos e adaptativos é fundamental para lidar com incertezas, ruídos e comportamentos sazonais (Gachhadar *et al.*, 2023; Hu; Lo; Hsieh, 2025).

O período analisado inclui eventos operacionais atípicos, como greve acadêmica, feriados e fases de baixa ocupação, que introduzem padrões de consumo irregulares e transições abruptas na série. O conjunto também apresenta ruídos e valores anômalos, atribuídos a falhas de aquisição ou a distúrbios reais na rede elétrica. Essas características conferem à base um elevado grau de complexidade, sendo, portanto, adequada para testar a robustez de modelos de previsão aplicados a ambientes não estacionários e com baixo nível de agregação estatística.

Visando capturar padrões específicos de consumo e compreender com maior clareza os comportamentos atípicos, os dados foram segmentados por dia útil da semana (segunda a sexta-feira), excluindo-se fins de semana e feriados. Essa segmentação permite avaliar a autenticidade do treinamento proposto, ao preservar a variabilidade típica de cada dia e possibilitar o desenvolvimento de modelos especializados, sensíveis às características sazonais e operacionais de cada subconjunto.

As coletas ocorreram de forma contínua entre 24 de abril de 2012 e 22 de agosto de 2013, com registros de alta granularidade temporal, originalmente em intervalos de aproximadamente

15 minutos. Pequenas variações nas marcas temporais foram posteriormente corrigidas durante o processo de regularização do eixo temporal no pré-processamento. O tratamento dos dados foi realizado em três etapas principais: ajuste do eixo temporal com codificação cíclica, exclusão de outliers e observações não representativas, e preenchimento de valores ausentes por meio de técnica de interpolação.


A primeira etapa constituiu no ajuste das amostras para intervalos regulares de 15 minutos, em função de marcações temporais irregulares observadas nas aquisições originais. Para preservar a natureza periódica da variável tempo, adotou-se codificação cíclica baseada na projeção trigonométrica sobre o círculo unitário. Para cada registro, foi calculado o número total de minutos decorridos desde 00:00, a partir da multiplicação da hora por 60 e da soma com os minutos correspondentes. Em seguida, aplicaram-se as equações (1) e (2) para codificar a variável temporal:

$$\text{Hora_seno}_i = \sin \left(\frac{2\pi \cdot \text{Minutos}_i}{1440} \right) \quad (1)$$

$$\text{Hora_cosseno}_i = \cos \left(\frac{2\pi \cdot \text{Minutos}_i}{1440} \right) \quad (2)$$


Considerando o ajuste da série temporal para intervalos regulares de 15 minutos, cada dia completo passou a conter 96 registros de carga, conforme apresentado nas curvas de carga dos subconjuntos ilustrados na Figura 1 a Figura 5, referente ao período entre 24 de abril de 2012 a 22 de agosto de 2013.

Figura 1 – Gráfico da Curva de Carga do Subconjunto de Segunda-feira




Fonte: Elaboração da própria autora

Figura 2 – Gráfico da Curva de Carga do Subconjunto de Terça-feira




Fonte: Elaboração da própria autora

Figura 3 – Gráfico da Curva de Carga do Subconjunto de Quarta-feira




Fonte: Elaboração da própria autora

Figura 4 – Gráfico da Curva de Carga do Subconjunto de Quinta-feira



Fonte: Elaboração da própria autora

Figura 5 – Gráfico da Curva de Carga do Subconjunto de Sexta-feira



Fonte: Elaboração da própria autora

Observa-se na Figura 1 a Figura 5 que, após a aplicação da codificação cíclica, a série temporal resultante passou a ser composta por todas as ocorrências do respectivo dia da semana, com registros uniformes em intervalos de 15 minutos. Ainda assim, nota-se a presença de ruídos, lacunas e variações sazonais significativas, que comprometem a estabilidade da série e justificam a adoção de novas etapas de pré-processamento.

Com o objetivo de mitigar tais inconsistências, procedeu-se à exclusão de todos os dias incompletos, definidos como aqueles que não apresentavam os 96 registros esperados para

um dia integral. Foram também removidas as amostras correspondentes a feriados nacionais e municipais, períodos nos quais não há fluxo regular de pessoas na universidade, gerando padrões de consumo atípicos. Além disso, descartaram-se os dias com consumo total inferior a 5.000 Wh, por não refletirem o comportamento característico da carga elétrica da edificação. Esses registros foram classificados como anômalos, pois poderiam distorcer a aprendizagem do modelo preditivo.

Para o preenchimento de lacunas pontuais na série temporal, optou-se por uma técnica de interpolação linear simples, baseada na média aritmética de valores vizinhos válidos. Essa estratégia considera, para cada ponto ausente ou igual a zero, os valores imediatamente anteriores e posteriores dentro do mesmo dia, desde que diferentes de zero e não nulos.

O procedimento foi implementado de forma adaptativa a cada posição na série diária: nos casos em que o valor ausente ocorre na posição inicial do dia, a interpolação é realizada com base exclusivamente nos valores posteriores válidos; quando o valor ausente está na posição final do dia, utilizam-se apenas os valores anteriores válidos. Para os demais casos intermediários, o preenchimento considera ambos os lados, sendo estimado por meio da média aritmética dos vizinhos adjacentes não nulos e distintos de zero.


Conforme discutido por Pfister (2005), métodos de interpolação local baseados em média entre vizinhos próximos são eficazes para preservar a suavidade da série e mitigar distorções derivadas de dados ausentes pontuais, especialmente em séries com amostragem densa.

Ainda que aplicada em outro domínio, a abordagem metodológica descrita por Cai *et al.* (2018) oferece fundamentos relevantes para o tratamento de séries temporais com alta granularidade. Os autores propuseram um fluxo de pré-processamento de dados experimentais voltado à análise cinética da pirólise de biomassa, contemplando a remoção de ruídos, a suavização de derivadas e a interpolação de pontos críticos. Tais procedimentos reforçam a importância de uma preparação cuidadosa dos dados antes da aplicação de métodos analíticos, especialmente em séries sujeitas a variações rápidas e medições de alta resolução, como ocorre na previsão de carga elétrica.

As Figura 6 a Figura 10 ilustram o efeito da interpolação sobre os subconjuntos semanais da base de dados, evidenciando o preenchimento de lacunas e a recuperação da continuidade das curvas de carga para cada dia útil.


Por fim, observa-se que, mesmo após a aplicação da interpolação, as curvas de carga resultantes permanecem heterogêneas e sujeitas a flutuações abruptas, ainda que segmentadas por subconjuntos homogêneos. Essa variabilidade decorre, em grande parte, da presença de componentes de alta frequência na série temporal, atribuídas a ruídos operacionais ou variações de consumo não sistemáticas. Para atenuar esses efeitos e melhorar a qualidade da informação extraída da série, adota-se, na etapa seguinte, a aplicação de técnicas de suavização de dados.

Figura 6 – Gráfico da Curva de Carga Interpolada – Segunda-feira




Fonte: Elaboração da própria autora

Figura 7 – Gráfico da Curva de Carga Interpolada – Terça-feira




Fonte: Elaboração da própria autora

Figura 8 – Gráfico da Curva de Carga Interpolada – Quarta-feira




Fonte: Elaboração da própria autora

Figura 9 – Gráfico da Curva de Carga Interpolada – Quinta-feira



Fonte: Elaboração da própria autora

Figura 10 – Gráfico da Curva de Carga Interpolada – Sexta-feira



Fonte: Elaboração da própria autora

3.2 SUAVIZAÇÃO DOS DADOS

A presença de ruídos de alta frequência em séries temporais de medição pode distorcer tendências locais e comprometer a estabilidade de algoritmos de previsão. Técnicas de suavização são utilizadas para atenuar essas flutuações espúrias, preservando as características estruturais do sinal e favorecendo a identificação de padrões relevantes por modelos de aprendizado de máquina (Cecati; Citro; Siano, 2011).

Estudos recentes reforçam a importância da suavização em séries de alta resolução voltadas à modelagem preditiva, destacando sua contribuição para a estabilidade dos modelos e a mitigação de desvios induzidos por variações locais de baixa representatividade estatística (Müller *et al.*, 2020). Métodos como Savitzky–Golay e interpolação por spline cúbica têm sido empregados


com sucesso na eliminação de ruídos antes da diferenciação de séries experimentais, preservando a integridade do sinal e aumentando a confiabilidade das análises subsequentes (Cai *et al.*, 2018).

A aplicação de técnicas de suavização, nesse cenário, busca atenuar variações indesejadas sem comprometer a morfologia do sinal, assegurando a continuidade e a coerência do perfil da série temporal. Conforme destacado por Cai *et al.* (2018), essa etapa contribui significativamente para a robustez de procedimentos analíticos como interpolação, diferenciação ou análise espectral.

Com o objetivo de avaliar o desempenho de diferentes técnicas de suavização aplicadas à série de carga horária, foram realizados testes exploratórios com diversos dias representativos do banco de dados real. Esses testes possibilitaram observar o comportamento de cada método frente a características como picos abruptos de demanda, rampas de transição e oscilações de alta frequência. Para fins de apresentação e comparação visual, foi selecionado o dia 17 de junho de 2013, representando um dia útil com perfil variado de carga.


As Figura 11 a Figura 15 apresentam os resultados da aplicação das cinco técnicas de suavização à série de carga horária: média móvel simples, média móvel ponderada, filtro exponencial, filtro de Savitzky-Golay e regressão local Loess. Cada gráfico compara a carga original com a sua versão suavizada e a respectiva margem de erro, possibilitando uma análise visual da adequação de cada método ao perfil observado.

Figura 11 – Carga horária suavizada por Média Móvel Simples




Fonte: Elaboração da própria autora

Figura 12 – Carga horária suavizada por Média Móvel Ponderada




Fonte: Elaboração da própria autora

Figura 13 – Carga horária suavizada por Filtro Exponencial




Fonte: Elaboração da própria autora

Figura 14 – Carga horária suavizada por Filtro de Savitzky–Golay



Fonte: Elaboração da própria autora

Figura 15 – Carga horária suavizada por Regressão Local Loess



Fonte: Elaboração da própria autora

Verifica-se que a suavização por média móvel ponderada (Figura 12) apresentou o melhor equilíbrio entre atenuação de ruído e preservação da estrutura da curva de carga. Essa técnica reduziu oscilações pontuais sem eliminar picos relevantes, mantendo aderência ao comportamento original e apresentando menor atraso em comparação com a média móvel simples (Figura 11) e o filtro exponencial (Figura 13), que apresentaram maior defasagem e perda de eventos característicos.

As abordagens por Savitzky–Golay (Figura 14) e Loess (Figura 15) demonstraram fidelidade superior ao sinal, com baixa margem de erro e excelente preservação dos padrões locais. No entanto, suas maiores complexidades computacionais e sensibilidade à escolha de parâmetros poderiam comprometer a estabilidade da modelagem híbrida proposta.

Nesse sentido, a média móvel ponderada mostrou-se mais adequada ao contexto desta pesquisa, por aliar simplicidade de implementação e desempenho consistente. Sua aplicação considerou uma janela de 5 amostras, com pesos definidos em $[0,1; 0,2; 0,4; 0,2; 0,1]$, atribuindo maior relevância ao ponto central da série. Nas análises preliminares, adotou-se 70% dos dias de cada subconjunto semanal, de modo a preservar a variabilidade estatística e assegurar a consistência do processo de suavização, mantendo plena compatibilidade com as etapas posteriores de clusterização e previsão.

3.3 CLUSTERIZAÇÃO K-MEANS

A elevada variabilidade dos perfis de carga observada em ambientes institucionais representa um desafio para a aplicação de modelos preditivos generalistas, sobretudo em contextos de previsão horária em nível desagregado e com um conjunto limitado de variáveis de entrada. A ausência de informações complementares, como temperatura, ocupação ou contexto operacional, associada à disponibilidade exclusiva de data, hora e carga, intensifica a complexidade do problema e exige estratégias adicionais de segmentação.

Nesse cenário, algoritmos de clusterização não supervisionados têm se mostrado eficazes na organização de séries temporais de carga com alta variabilidade, permitindo a redução da heterogeneidade interna e a especialização de modelos preditivos em subconjuntos mais homogêneos. Entre essas técnicas, o K-means destaca-se por sua simplicidade computacional e ampla aplicação em sistemas com baixa agregação (Hernández *et al.*, 2014; Panapakidis; Dagoumas, 2016).

Segundo Hernández *et al.* (2014) , o K-means pode ser incorporado a arquiteturas híbridas baseadas em redes neurais e mapas auto-organizáveis, segmentando perfis diários com comportamentos semelhantes em microrredes institucionais. Essa abordagem demonstrou ganhos expressivos em termos de precisão e adaptação a padrões sazonais e intermitentes, sendo particularmente relevante para aplicações em ambientes educacionais.

De forma semelhante, Panapakidis e Dagoumas (2016) argumentam que o agrupamento prévio dos perfis diários por similaridade favorece a construção de modelos especializados para diferentes tipos de dias, contribuindo para o aprimoramento da previsão horária em sistemas com elevada variabilidade operacional.

Do ponto de vista técnico, o algoritmo realiza o particionamento com base na minimização da distância euclidiana entre os vetores de entrada e os centróides, ajustando iterativamente os agrupamentos até alcançar convergência. Cada centróide representa um padrão médio de comportamento do grupo, o que favorece a estruturação dos dados em conjuntos mais coesos e

interpretáveis (Hernández *et al.*, 2014).

Estudos recentes também evidenciam a integração do K-means a modelos supervisionados, como o KNN, com o objetivo de capturar influências contextuais, tais como feriados e transições de rotina (Hnin *et al.*, 2024). Aplicações voltadas a edifícios de múltiplos usos demonstraram a eficácia da técnica na diferenciação de regimes operacionais, inclusive em cenários atípicos, como durante a pandemia (Hu; Lo; Hsieh, 2025).


A definição do número ideal de agrupamentos pode ser orientada por métricas de avaliação interna, como o coeficiente de silhueta, que considera simultaneamente a coesão dos grupos formados e sua separabilidade em relação aos demais (Zhou; Gao, 2014).

Além disso, em modelos baseados em padrões históricos, a clusterização K-means pode atuar como etapa preliminar de organização do conjunto, viabilizando a identificação de estruturas sazonais recorrentes e a especialização da previsão em horizontes de curto prazo (Kouzelis *et al.*, 2014).

Diante do exposto, a técnica de clusterização K-means foi aplicada com o objetivo de agrupar curvas de carga com padrões semelhantes, permitindo a formação de subconjuntos mais homogêneos. Essa etapa preliminar favorece a identificação de perfis típicos de consumo e contribui para fundamentar a estratégia posterior de modelagem baseada em dias da semana. Para esta análise preliminar, foram utilizados todos os registros dos dias úteis (segunda a sexta-feira), sem distinção entre os dias da semana, a fim de avaliar a consistência dos agrupamentos formados a partir do comportamento médio diário.

A segmentação resultou em três clusters principais, cujos perfis médios são apresentados na Figura 16. A separação entre os grupos evidencia a existência de variações estruturais nos padrões de carga, possivelmente associadas a diferenças de ocupação, sazonalidade acadêmica ou eventos operacionais pontuais. Essa heterogeneidade reforça a importância de abordagens que considerem a variabilidade intra-semanal e o uso de modelos especializados por perfil.

Figura 16 – Perfis Médios de Consumo Diário Segmentados por Cluster (K-means)



Fonte: Elaboração da própria autora

3.4 REDE NEURAL FUZZY ARTMAP

Dentre os modelos capazes de realizar classificação supervisionada sob incerteza, a rede Fuzzy ARTMAP tem se mostrado particularmente promissora em aplicações de previsão de carga elétrica em nível desagregado. Desenvolvida por Carpenter *et al.* (1992), essa arquitetura integra os princípios da Teoria da Ressonância Adaptativa (ART) com operadores fuzzy, permitindo aprendizado incremental com estabilidade categórica, mesmo em séries ruidosas e não estacionárias.

Sua estrutura é composta por dois módulos do tipo ART Fuzzy, denominados ART_a e ART_b , responsáveis, respectivamente, pelo processamento dos vetores de entrada e das saídas desejadas. A conexão entre os módulos é mediada pela camada intermediária *inter-ART*, que ajusta dinamicamente as associações entre categorias por meio do mecanismo de rastreamento de correspondência, conhecido como *match tracking* (Carpenter; Grossberg, 1992).

O funcionamento da rede é regulado por três parâmetros principais: o parâmetro de escolha $\alpha > 0$, a taxa de aprendizado $\beta \in [0, 1]$ e o parâmetro de vigilância $\rho \in [0, 1]$, que pode ser ajustado separadamente para os módulos ρ_a , ρ_b e para a conexão cruzada ρ_{ab} .

O processo de treinamento inicia-se com a normalização dos vetores de entrada $a = [a_1, a_2, \dots, a_M]$ e de saída $b = [b_1, b_2, \dots, b_M]$, conforme a equação:

$$\bar{I}_a = \frac{a}{|a|}, \quad \bar{I}_b = \frac{b}{|b|} \quad (3)$$

Em seguida, aplica-se a codificação por complemento fuzzy, descrita na Equação (2):

$$I^a = [a, \bar{a}], \quad I^b = [b, \bar{b}] \quad (4)$$

A função de escolha para os neurônios da camada F_2 de cada módulo é dada por:

$$T_j^a = \frac{|I^a \wedge w_j^a|}{\alpha + |w_j^a|}, \quad T_k^b = \frac{|I^b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (5)$$

Os neurônios vencedores são então determinados conforme:

$$J = \arg \max_j T_j^a, \quad K = \arg \max_k T_k^b \quad (6)$$

A condição de ressonância é verificada pelas expressões:

$$\frac{|I^a \wedge w_J^a|}{|I^a|} \geq \rho_a, \quad \frac{|I^b \wedge w_K^b|}{|I^b|} \geq \rho_b \quad (7)$$

Quando satisfeita, os pesos sinápticos são atualizados conforme:

$$w_J^{a(\text{novo})} = \beta(I^a \wedge w_J^{a(\text{velho})}) + (1 - \beta)w_J^{a(\text{velho})} \quad (8)$$

$$w_K^{b(\text{novo})} = \beta(I^b \wedge w_K^{b(\text{velho})}) + (1 - \beta)w_K^{b(\text{velho})} \quad (9)$$

Na camada *inter*-ART, os pesos de associação são definidos por:

$$w_{J,K}^{ab} = 1, \quad w_{j,k}^{ab} = 0 \quad \text{para } j \neq J \text{ ou } k \neq K \quad (10)$$

A rede executa esse processo de forma iterativa para cada par entrada-saída apresentado, promovendo o armazenamento incremental dos padrões aprendidos. Essa característica elimina a necessidade de reprocessamento de toda a base histórica a cada nova entrada, o que favorece a escalabilidade da arquitetura (Carpenter *et al.*, 1992).

A capacidade de aprendizado incremental torna a Fuzzy ARTMAP especialmente adequada para ambientes em que os perfis de carga evoluem ao longo do tempo, como edifícios institucionais monitorados por sistemas de medição inteligente. Sua estrutura possibilita atualizações sem reprocessamento retroativo, o que é vantajoso em cenários com ruído, sazonalidade irregular e baixa agregação. Segundo Fernández, Lotufo e Minussi (2023), redes Fuzzy ARTMAP têm apresentado desempenho robusto na previsão de carga elétrica de curto prazo, sobretudo quando combinadas a técnicas de clusterização aplicadas no pré-processamento.

3.5 IMPLEMENTAÇÃO DA ABORDAGEM DE PREVISÃO COM REDES FUZZY ARTMAP E CLUSTERIZAÇÃO K-MEANS

A estratégia de previsão adotada baseia-se na arquitetura de rede neural Fuzzy ARTMAP, um modelo de aprendizado supervisionado dotado de capacidade de adaptação incremental, projetado para operar em ambientes não estacionários. Essa arquitetura é composta por dois módulos ART Fuzzy, denominados ART_a e ART_b , responsáveis, respectivamente, pelo processamento dos vetores de entrada e de saída. Ambos são interligados por uma estrutura intermediária, denominada *inter*-ART, que executa o mecanismo de rastreamento de correspondência (*match tracking*), responsável por regular a formação de categorias e assegurar a estabilidade do processo de aprendizado (Carpenter *et al.*, 1992; Carpenter; Grossberg, 1992).

O modelo foi configurado para operar com segmentação por dia da semana, de segunda a sexta-feira, tratando cada subconjunto de forma independente. Essa estratégia visa capturar padrões recorrentes de consumo associados a cada dia útil, considerando as particularidades comportamentais inerentes aos perfis diários. Essa separação permite avaliar de forma sistemática o desempenho do previsor, respeitando a estrutura temporal dos dados.


Na primeira abordagem, sem aplicação de clusterização, a rede é treinada com 15 dias aleatórios de um mesmo dia da semana (por exemplo, 15 segundas-feiras), sendo utilizada para prever um dia do mesmo subconjunto. Esse procedimento é repetido iterativamente até que todas as ocorrências daquele dia tenham sido previstas. Essa configuração simula cenários realistas de dados históricos limitados, sem a necessidade de continuidade entre os dias, e possibilita uma

avaliação abrangente da acurácia preditiva.

Na segunda estratégia, com aplicação da clusterização K-means, os dados de um determinado dia da semana (por exemplo, todas as terças-feiras) são inicialmente agrupados em três clusters distintos, com base na similaridade entre os perfis diários de carga. O algoritmo realiza o particionamento por meio da minimização da distância euclidiana entre os vetores de carga e os centróides dos grupos, atualizando iterativamente as associações até atingir estabilidade. Cada centróide representa um padrão médio de comportamento, favorecendo a formação de subconjuntos mais homogêneos e metodologicamente consistentes.

Para a previsão de um determinado dia, calcula-se a curva média de carga dos cinco dias úteis anteriores, considerando todo o banco de dados, e esta é comparada aos centróides previamente obtidos. O cluster mais próximo é selecionado como representativo do comportamento recente. Caso o dia de previsão pertença ao cluster selecionado, ele é removido antes do treinamento, a fim de evitar qualquer vazamento de informação. A rede é então treinada com os demais dias do cluster, e utilizada para estimar os 96 pontos da curva horária daquele dia. O processo é repetido para todas as ocorrências do subconjunto semanal, permitindo reconfiguração dinâmica do conjunto de treinamento e avaliação individualizada de cada previsão. Essa estrutura viabiliza a análise do impacto da clusterização na acurácia do modelo preditivo. A Figura 17, ilustra as etapas de treinamento, seleção e previsão da segunda estratégia proposta.

Figura 17 – Representação gráfica da metodologia de previsão de carga híbrida.



Fonte: Elaboração da própria autora

A entrada da rede é composta por uma janela deslizante contendo três instantes de tempo consecutivos, $[x_{h-3}, x_{h-2}, x_{h-1}]$, utilizada para estimar o valor do instante h . A previsão é realizada de forma recursiva, de modo que os valores estimados em etapas anteriores são realimentados como entrada nas etapas subsequentes. Por exemplo, para prever o instante $h + 1$, utiliza-se o vetor $[\hat{x}_{h-2}, \hat{x}_{h-1}, \hat{x}_h]$, no qual todos os valores $\hat{x}$ foram previamente previstos pelo modelo.

A seleção dos hiperparâmetros da rede Fuzzy ARTMAP é realizada por meio de uma busca exaustiva combinatória sobre uma grade predefinida, composta por:

- **Parâmetro de vigilância do módulo de entrada** (ρ_a): de 0,90 a 0,99, com incremento de 0,01;
- **Parâmetro de vigilância do módulo de saída** (ρ_b): de 0,92 a 0,999, com incremento de 0,001;
- **Parâmetro de vigilância do módulo inter-ART** (ρ_{ab}): valor fixo de 0,8;
- **Taxa de aprendizado** (β): valores discretos $\{0,1; 0,2; 0,5; 0,8; 1,0\}$;
- **Parâmetro de escolha** (α): valor fixo de 0,005.

Cada instância da rede avalia 4.000 combinações distintas desses hiperparâmetros, sendo selecionada aquela que apresenta o menor erro percentual absoluto médio (MAPE) como a configuração ótima para cada experimento.

A avaliação do desempenho do modelo é realizada com base em três métricas estatísticas amplamente utilizadas na literatura para avaliação de acurácia preditiva (Hyndman; Koehler, 2006). Conforme as Equações 11, 12 e 13:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (11)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (12)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100 \quad (13)$$

Nas equações acima, Y_i representa o valor real da carga e $\hat{Y}_i$ o valor previsto no instante i . As métricas são calculadas com base nos 96 pontos de medição da curva diária de carga.

A implementação foi realizada em linguagem *Python*, no ambiente *Jupyter Notebook*, com o suporte das bibliotecas *NumPy*, *Pandas*, *SciPy* e *Scikit-learn*. As simulações foram executadas em um processador Intel® Core™ i7-8700 @3.20GHz (12 núcleos), com 16 GB de memória RAM, apresentando tempo computacional médio por simulação entre 0,03 e 0,04 segundos.

4 RESULTADOS

Neste capítulo, apresentam-se os principais resultados obtidos a partir da aplicação da modelagem híbrida proposta, que combina redes neurais Fuzzy ARTMAP com o algoritmo de clusterização K-means. O modelo foi estruturado para realizar a previsão da carga elétrica para todos os dias úteis da semana, com base na metodologia previamente descrita.

4.1 SISTEMA PREVISOR DE CARGA EM NÍVEL DESAGREGADO

A avaliação do sistema previsor foi realizada com dados reais de consumo de energia elétrica registrados entre 24 de abril de 2012 e 22 de agosto de 2013, em uma universidade brasileira. Cada previsão corresponde a um dia útil completo, com 96 registros de carga a cada 15 minutos, abrangendo de segunda a sexta-feira durante todo o período.

Conforme a estratégia de previsão descrita na Seção 3.5, foram consideradas duas abordagens: uma sem aplicação da clusterização K-means e outra com aplicação da técnica para seleção de dias similares. Ambas as estratégias foram testadas em duas versões dos dados: a carga real e a carga suavizada por média móvel ponderada, permitindo avaliar os efeitos combinados da clusterização e da suavização sobre a qualidade da previsão.

As previsões foram realizadas separadamente para cada dia da semana, com repetições baseadas em diferentes sementes aleatórias, a fim de garantir estabilidade e consistência estatística nos resultados. A avaliação de desempenho foi feita com base em três métricas amplamente utilizadas na literatura de previsão de carga: erro percentual absoluto médio (MAPE), erro absoluto médio (MAE) e raiz do erro quadrático médio (RMSE), todas calculadas sobre os 96 pontos previstos por dia.

4.1.1 Resultados sem Clusterização (K-Means)

Conforme a estratégia metodológica descrita na Seção 3.5, o modelo Fuzzy ARTMAP foi aplicado à previsão de carga elétrica horária em nível desagregado, sem segmentação prévia por similaridade. Cada instância foi prevista de forma independente, com treinamento baseado em subconjuntos aleatórios compostos por dias equivalentes da semana, preservando a estrutura cíclica do padrão de consumo.

As simulações foram realizadas em duas configurações distintas: utilizando as curvas com cargas reais e as suavizadas por média móvel ponderada. As métricas MAPE, RMSE e MAE foram adotadas para quantificação dos erros, permitindo avaliar a robustez do modelo frente à variabilidade dos dados e os efeitos da suavização sobre a estabilidade preditiva.

Os resultados apresentados nas Tabelas 1 e 2 referem-se a amostras representativas extraídas do banco de dados, selecionadas com o objetivo de ilustrar o desempenho do modelo híbrido

proposto. A íntegra das previsões realizadas para todos os dias úteis encontra-se disponível no Apêndice.

Tabela 1 – Resultados das previsões com carga real, sem aplicação da clusterização K-means

Dia da Semana	Data de Teste	MAPE (%)	RMSE (kW)	MAE (kW)
Segunda-feira	2012-09-10	24,65	2363,79	1457,81
	2012-06-04	39,93	2948,06	2246,72
	2013-06-03	33,82	2495,07	1728,23
	2012-07-02	35,74	2828,97	2116,87
	2012-08-27	51,25	4898,25	3362,92
Terça-feira	2012-07-17	33,37	3756,08	2579,58
	2013-03-12	33,88	3960,38	2639,27
	2013-05-14	48,23	4267,93	3050,63
	2012-11-27	27,01	3423,45	2261,71
	2013-02-19	23,28	2460,87	1665,42
Quarta-feira	2012-05-30	38,26	5657,40	3943,84
	2012-06-27	49,60	3581,87	2939,55
	2012-05-23	39,04	4617,05	3301,02
	2013-01-16	26,70	2840,45	1917,83
	2013-08-07	21,83	2181,61	1432,81
Quinta-feira	2013-05-23	23,48	1864,36	1145,37
	2013-01-24	34,26	3311,84	2461,92
	2013-03-21	26,42	3148,23	2288,22
	2012-07-19	24,84	2552,45	1681,48
	2012-08-30	30,18	4707,09	3298,65
Sexta-feira	2012-05-04	31,64	4076,96	2865,26
	2012-07-27	30,87	2828,96	2047,80
	2013-02-01	21,56	3753,42	2446,43
	2013-03-01	33,10	4872,23	3444,79
	2012-06-29	32,49	3545,73	2770,92

Fonte: Elaborada pela autora.

A análise dos resultados apresentados nas Tabelas 1 e 2 revela que o desempenho do modelo Fuzzy ARTMAP, quando aplicado sem segmentação por clusterização, varia significativamente entre os dias da semana. Observam-se valores de MAPE relativamente elevados em algumas amostras, sobretudo nas curvas reais com maior irregularidade. A suavização por média móvel ponderada contribuiu, em diversos casos, para a redução dos erros absolutos e percentuais, evidenciando sua eficácia na atenuação de oscilações abruptas e ruídos de alta frequência.

No entanto, esse efeito não foi sistemático: em certos cenários, a suavização comprometeu a acurácia ao eliminar variações locais relevantes para o modelo. Tal comportamento demonstra que o pré-processamento por suavização, embora útil para estabilizar as séries, não garante, isoladamente, melhora generalizada na performance do previsor. A ausência de segmentação por similaridade impõe limitações à generalização do modelo frente à alta variabilidade estrutural

dos perfis, o que justifica a adoção de estratégias complementares, como a clusterização K-means, explorada na próxima seção.

Tabela 2 – Resultados das previsões com carga suavizada, sem aplicação da clusterização K-means

Dia da Semana	Data de Teste	MAPE (%)	RMSE (kW)	MAE (kW)
Segunda-feira	2012-09-10	36,48	3225,29	2216,69
	2012-06-04	29,59	4158,57	2585,68
	2013-06-03	25,58	2511,00	1593,80
	2012-07-02	28,64	2190,13	1674,98
	2012-08-27	43,89	3921,83	2787,30
Terça-feira	2012-07-17	44,87	5224,77	3270,51
	2013-03-12	24,87	4423,50	2870,65
	2013-05-14	19,53	1337,02	936,31
	2012-11-27	19,17	2787,40	1851,24
	2013-02-19	18,38	2153,24	1434,72
Quarta-feira	2012-05-30	17,64	3121,60	1972,85
	2012-06-27	17,01	1637,21	1119,40
	2012-05-23	42,79	4614,80	3116,83
	2013-01-16	37,45	2789,76	2018,33
	2013-08-07	21,26	2499,56	1585,35
Quinta-feira	2013-05-23	19,07	1333,81	864,84
	2013-01-24	33,97	3593,49	2545,26
	2013-03-21	23,63	2841,08	1920,55
	2012-07-19	49,71	4742,72	3427,46
	2012-08-30	35,15	5133,83	3539,75
Sexta-feira	2012-05-04	42,30	4826,39	3362,47
	2012-07-27	28,06	4386,39	2690,70
	2013-02-01	41,28	6180,11	4381,83
	2013-03-01	32,36	4884,90	3428,21
	2012-06-29	31,59	5673,51	3667,03

Fonte: Elaborada pela autora.

4.1.2 Resultados com Clusterização (K-Means)

Nesta abordagem, a base de dados foi previamente segmentada por dia da semana. Em seguida, cada subconjunto de dias úteis (segunda a sexta-feira) foi particionado em três grupos por meio do algoritmo K-means, com $k = 3$. O objetivo dessa etapa é reduzir a heterogeneidade interna dos perfis de carga, agrupando curvas com padrões semelhantes e favorecendo a especialização do modelo preditivo.

Para cada instância de teste, calcula-se a média das curvas de carga dos cinco dias úteis imediatamente anteriores. Esse perfil médio é utilizado como referência para a identificação do cluster mais semelhante, com base na distância euclidiana aos centróides obtidos na etapa de clusterização. A rede Fuzzy ARTMAP é então treinada com os dias pertencentes ao grupo mais


próximo, removendo-se o próprio dia de teste do conjunto de treinamento, quando aplicável, para preservar a causalidade do processo.

As Figura 18 a Figura 20 ilustram o procedimento adotado tomando como exemplo o dia 27 de agosto de 2012, uma segunda-feira selecionada como instância de teste. Inicialmente, são coletadas as curvas de carga dos cinco dias úteis imediatamente anteriores, independentemente do dia da semana, conforme representado na Figura 18. A partir dessas curvas, calcula-se a média aritmética, que é então utilizada como perfil de referência.

Na etapa seguinte, essa curva média é comparada aos centróides dos três clusters gerados exclusivamente para o subconjunto de segundas-feiras, identificando-se o grupo mais similar com base na menor distância euclidiana (Figura 19). O treinamento da rede Fuzzy ARTMAP é realizado com os dias pertencentes a esse cluster, excluindo-se o próprio dia de teste quando necessário. Por fim, a Figura 20 apresenta o resultado da previsão obtida para o dia 27 de agosto, confrontando a carga prevista com os valores reais, no contexto da abordagem com clusterização.

Esse processo é repetido para cada dia da semana, permitindo que a modelagem se adapte às particularidades de cada perfil diário. A estruturação por cluster contribui para a robustez do modelo diante da variabilidade comportamental presente em ambientes institucionais.

Figura 18 – Curvas de Carga dos dias Úteis Anteriores



Fonte: Elaboração da própria autora

Figura 19 – Cargas Diárias do Cluster Escolhido





Figura 20 – Curva de Carga do Dia Teste - Carga Real



A Tabela 3 apresenta uma amostra dos resultados obtidos com a previsão da carga real utilizando a abordagem com clusterização K-means. Por sua vez, a Tabela 4 exibe os resultados correspondentes ao mesmo procedimento, porém aplicados à carga suavizada por média móvel ponderada. Cabe destacar que o modelo foi executado para todos os dias úteis disponíveis no período analisado, permitindo uma avaliação consistente de sua robustez em cenários de previsão em nível desagregado.

Tabela 3 – Resultados das previsões com carga real e aplicação da clusterização K-means

Dia da Semana	Data de Teste	MAPE (%)	RMSE (kW)	MAE (kW)
Segunda-feira	2012-09-10	15,00	1966,08	1201,25
	2012-06-04	13,38	1224,33	819,13
	2013-06-03	20,37	2346,90	1376,15
	2012-07-02	14,41	2561,90	1485,13
	2012-08-27	12,67	1140,37	764,38
Terça-feira	2012-07-17	11,81	1132,66	768,39
	2013-03-12	15,94	2053,29	1228,61
	2013-05-14	16,44	1335,55	901,25
	2012-11-27	17,12	1775,90	1217,00
	2013-02-19	18,55	1575,47	1026,56
Quarta-feira	2012-05-30	14,70	2859,40	1692,77
	2012-06-27	16,92	1972,91	1330,75
	2012-05-23	19,98	3598,44	2153,60
	2013-01-16	20,27	1884,29	1238,74
	2013-08-07	20,75	2213,70	1486,98
Quinta-feira	2013-05-23	15,93	1774,39	987,11
	2013-01-24	16,38	1804,37	990,95
	2013-03-21	17,01	1944,79	1241,15
	2012-07-19	17,60	2353,28	1435,50
	2012-08-30	18,67	3145,25	1729,06
Sexta-feira	2012-05-04	14,78	2425,45	1439,66
	2012-07-27	14,78	1618,82	1041,61
	2013-02-01	18,86	2534,06	1575,77
	2013-03-01	20,90	2724,67	1600,83
	2012-06-29	17,31	3117,66	1849,57

Fonte: Elaborada pela autora.

Verifica-se, de forma geral, uma redução significativa nas métricas de erro em relação à abordagem sem clusterização, especialmente nos dias com maior variabilidade nos padrões de carga. Esse resultado reforça a contribuição da modelagem híbrida, aumentando a confiabilidade das previsões em ambientes institucionais com elevada oscilação comportamental. A formação de subconjuntos mais homogêneos, obtida por meio do algoritmo K-means, favoreceu a especialização do modelo preditivo e reduziu os impactos negativos da ausência de variáveis exógenas.

Em determinados casos, a combinação entre a suavização por média móvel ponderada e a clusterização K-means resultou em desempenho ainda mais favorável, como podemos observar na Tabela 4, particularmente nos dias em que as curvas apresentavam maior instabilidade ou ruído estrutural. Essa configuração permitiu uma adaptação mais eficiente da rede ao perfil previsto, sem comprometer a integridade das estruturas comportamentais relevantes. Os demais resultados, abrangendo todas as datas previstas ao longo do período analisado, encontram-se organizados no Apêndice deste trabalho, permitindo a consulta completa das métricas de

desempenho por dia da semana e abordagem adotada.

Tabela 4 – Resultados das previsões com carga suavizada e aplicação da clusterização K-means

Dia da Semana	Data de Teste	MAPE (%)	RMSE (kW)	MAE (kW)
Segunda-feira	2012-09-10	15,74	1904,41	1117,76
	2012-06-04	13,07	1400,45	826,30
	2013-06-03	17,82	1431,31	930,94
	2012-07-02	14,32	1507,14	1017,13
	2012-08-27	15,67	1514,37	997,58
Terça-feira	2012-07-17	20,13	2271,58	1481,19
	2013-03-12	17,72	2036,87	1209,44
	2013-05-14	17,66	1165,59	845,71
	2012-11-27	20,36	2519,88	1625,79
	2013-02-19	16,25	1692,14	1093,44
Quarta-feira	2012-05-30	14,05	2225,01	1365,51
	2012-06-27	12,93	1712,81	1055,81
	2012-05-23	15,28	2679,59	1561,81
	2013-01-16	16,79	2273,13	1222,55
	2013-08-07	20,49	1507,66	1015,63
Quinta-feira	2013-05-23	14,62	1182,00	769,27
	2013-01-24	15,65	1521,60	901,85
	2013-03-21	16,30	1868,39	1158,62
	2012-07-19	19,75	1983,28	1342,09
	2012-08-30	12,75	1245,08	843,47
Sexta-feira	2012-05-04	16,03	2406,71	1456,32
	2012-07-27	19,68	1890,35	1298,34
	2013-02-01	18,39	1984,47	1245,23
	2013-03-01	15,43	1835,76	1147,67
	2012-06-29	15,94	1794,13	1237,05


Fonte: Elaborada pela autora.

4.1.3 Análise comparativa entre as abordagens

A avaliação comparativa entre as quatro abordagens testadas permite identificar, com clareza, o impacto isolado e combinado da segmentação por K-means e da suavização da série sobre o desempenho da rede Fuzzy ARTMAP. As tabelas apresentadas anteriormente registram os resultados individuais por data e dia da semana para os seguintes cenários: (i) carga real sem clusterização, (ii) carga suavizada sem clusterização, (iii) carga real com clusterização e (iv) carga suavizada com clusterização.


A Figura 21 a Figura 24 ilustram visualmente a diferença entre as previsões geradas pelas duas estratégias, comparando os perfis reais com as estimativas obtidas com e sem clusterização. Observa-se que, ao agrupar os dados por similaridade, o modelo é capaz de captar com maior fidelidade a estrutura das curvas de carga.

Figura 21 – Curvas de Carga Real Sem Clusterização




Fonte: Elaboração da própria autora

Figura 22 – Curva de Carga Suavizada sem Clusterização




Fonte: Elaboração da própria autora

Figura 23 – Curva de Carga Real com Clusterização



Fonte: Elaboração da própria autora

Figura 24 – Curva de Carga Suavizada com Clusterização



Fonte: Elaboração da própria autora

De forma geral, os dados indicam que a abordagem com carga real e aplicação de clusterização apresentou os melhores desempenhos médios em termos de acurácia, estabilidade e consistência entre os dias da semana. Em praticamente todas as datas avaliadas, a aplicação do K-means foi responsável por uma redução significativa nas métricas MAPE, RMSE e MAE, confirmando o que já havia sido observado em trabalhos anteriores como Hernández *et al.* (2014) e Panapakidis e Dagoumas (2016), que destacam a eficácia da segmentação por similaridade na especialização do modelo preditivo em ambientes com alta variabilidade comportamental.

Nos resultados obtidos com a suavização sem clusterização, observou-se uma resposta inconsistente: embora tenha havido melhorias pontuais em RMSE e MAE, principalmente para quartas e quintas-feiras, o MAPE apresentou variações negativas em diversos casos, inclusive com aumentos expressivos de erro percentual. Isso evidencia que a suavização, por si só, não é suficiente para garantir ganhos de desempenho em séries com elevada flutuação estrutural, como

também indicado por Cai *et al.* (2018), quando alertam para a perda de características dinâmicas relevantes ao se atenuar ruídos indiscriminadamente.

Já a abordagem combinada de suavização e clusterização apresentou desempenho robusto em várias datas, principalmente nos dias em que os perfis de carga demonstravam maior instabilidade ou presença de picos atípicos. Nessas situações, a suavização contribuiu para reforçar a representatividade dos centróides utilizados na classificação dos perfis, o que resultou em ganhos adicionais de acurácia. Contudo, em outros casos — como algumas terças e sextas-feiras — a suavização introduziu pequenas distorções nos padrões típicos de carga, o que reduziu a eficácia do processo de agrupamento e, conseqüentemente, o desempenho da previsão.

A comparação direta entre os cenários com e sem suavização, sob as mesmas condições de clusterização, mostra que não há uma superioridade universal da suavização, sendo seu benefício condicionado à natureza do perfil de carga e ao comportamento histórico dos dados de entrada. Esse resultado está em consonância com os estudos de Müller (2018) e Alves (2019), que utilizaram a rede Fuzzy ARTMAP em contextos com ruído estrutural e também identificaram que a suavização deve ser aplicada com cautela, preferencialmente após a análise espectral ou morfológica das séries.

Dessa forma, conclui-se que a melhor configuração experimental, dentro do conjunto testado, foi a utilização de clusterização K-means com os dados reais de carga. Essa abordagem apresentou os menores valores médios de erro, a maior regularidade entre os dias e a melhor generalização do modelo, mesmo em contextos com elevado ruído e ausência de variáveis meteorológicas ou de ocupação. A abordagem combinada com suavização pode ser vantajosa em cenários específicos, mas não se mostrou superior de forma consistente em relação ao modelo com clusterização e dados originais.

5 DISCUSSÃO

Os resultados obtidos neste estudo confirmam a hipótese de que a aplicação de técnicas de segmentação por similaridade pode aprimorar de forma significativa a acurácia da previsão de carga elétrica em nível desagregado. O modelo híbrido proposto, fundamentado na combinação entre a rede neural Fuzzy ARTMAP e a clusterização via K-means, apresentou ganhos expressivos nas três métricas avaliadas (MAPE, RMSE e MAE) ao longo de diferentes dias da semana, mesmo sob condições operacionais marcadas por alta variabilidade comportamental e ausência de variáveis contextuais.

A estratégia adotada utiliza o algoritmo K-means para segmentar previamente os perfis diários em três grupos homogêneos, baseando-se na forma das curvas de carga. Após a definição do dia a ser previsto, calcula-se a média das curvas dos cinco dias úteis anteriores, e esta é comparada com os centróides previamente obtidos, de modo a identificar o cluster mais representativo. A partir dessa identificação, a rede Fuzzy ARTMAP é treinada apenas com os dados dos demais dias pertencentes ao mesmo cluster, desconsiderando o dia-alvo. Essa filtragem dinâmica permitiu construir subconjuntos de treino mais coesos, favorecendo a estabilidade do processo de aprendizado e a especialização do modelo.

A versão estendida desta pesquisa introduziu ainda uma etapa adicional de pré-processamento baseada em suavização por média móvel ponderada, aplicada diretamente à série temporal de carga. Essa técnica teve como objetivo atenuar oscilações de alta frequência que, embora estruturalmente irrelevantes, poderiam interferir negativamente na etapa de previsão ao gerar ruído nos padrões de entrada. A aplicação da suavização, tanto de forma isolada quanto em conjunto com a clusterização, permitiu avaliar sua influência sobre o desempenho do modelo em cenários reais de previsão com alta granularidade temporal (96 registros diários).

A comparação sistemática entre as quatro abordagens testadas, com e sem clusterização, com e sem suavização, revelou que a configuração com dados reais e aplicação da clusterização apresentou, de modo geral, os melhores resultados médios, demonstrando superioridade em termos de acurácia e regularidade. Essa constatação é consistente com os achados de Hernández *et al.* (2014), que demonstraram a eficácia da segmentação por K-means em ambientes de microgrids institucionais com alta imprevisibilidade comportamental. O presente estudo, no entanto, avança ao utilizar uma arquitetura neural baseada em Fuzzy ARTMAP, capaz de realizar aprendizado incremental com estabilidade, mesmo sob entradas não estacionárias, como também discutido por Müller (2018) e Alves (2019).

A abordagem combinada, com suavização e clusterização, também apresentou bons resultados, especialmente em dias com maior nível de ruído estrutural, como quartas e quintas-feiras. Nesses casos, a suavização contribuiu para reforçar a representatividade dos centróides de cluster, elevando o desempenho preditivo da rede. Por outro lado, em alguns casos, especialmente nas terças e sextas-feiras, a suavização comprometeu a representação de padrões relevantes, dificultando

tando a correta identificação do cluster e, por consequência, a previsão. Essa limitação também é mencionada por Cai *et al.* (2018), que ressaltam a necessidade de aplicação criteriosa de técnicas de suavização para não comprometer a extração de padrões significativos.

Em contrapartida, a suavização isolada, sem o apoio da segmentação, mostrou-se menos eficaz. Apesar de ter reduzido o RMSE e o MAE em algumas datas, o MAPE permaneceu elevado em diversos casos, evidenciando que a eliminação de ruídos de alta frequência, por si só, não é suficiente para garantir acurácia. A estrutura da rede Fuzzy ARTMAP requer padrões recorrentes e coesos para uma categorização eficiente — algo que a clusterização contribui diretamente para oferecer.

A comparação com trabalhos anteriores reforça a pertinência metodológica desta pesquisa. Em Panapakidis e Dagoumas (2016), os autores utilizaram SVR e redes MLP com K-means e observaram melhoria nos erros de previsão após a segmentação, embora tenham destacado a sensibilidade do desempenho ao número de clusters. Já em Hernández *et al.* (2014), o uso da clusterização foi determinante para o sucesso do modelo em ambientes sem dados meteorológicos — contexto análogo ao presente estudo. No entanto, ambos os trabalhos não incluíram estratégias específicas para ruído de alta frequência, lacuna abordada na presente tese por meio da suavização.

Quanto às limitações, destaca-se a ausência de variáveis climáticas, de ocupação ou operacionais, as quais poderiam auxiliar na contextualização dos perfis de carga. Além disso, o conjunto de dados utilizado contém lacunas de medição e períodos afetados por greves acadêmicas, exigindo a aplicação de técnicas de interpolação para reconstrução da série. Tais fatores aumentam a complexidade do problema e, ao mesmo tempo, ressaltam a robustez do modelo proposto frente a condições adversas.

Conclui-se, portanto, que a integração entre clusterização e suavização constitui uma estratégia promissora para a previsão de carga em ambientes desagregados, desde que suas aplicações sejam avaliadas com base nas características específicas da série. O modelo proposto demonstrou desempenho superior ao de abordagens anteriores, validando sua robustez frente a limitações práticas e reforçando sua aplicabilidade em contextos reais, como instituições públicas e sistemas de microrredes. Seus resultados abrem caminho para soluções mais eficazes de gerenciamento energético em ambientes de alta complexidade

6 CONCLUSÃO

A proposta metodológica desenvolvida nesta tese demonstrou alto grau de eficácia na tarefa de previsão de carga elétrica em nível desagregado, utilizando exclusivamente variáveis de carga e informações temporais com granularidade de 15 minutos. A combinação entre a rede neural Fuzzy ARTMAP e o algoritmo de clusterização K-means resultou em previsões consistentes para diferentes dias úteis da semana, mesmo diante de perfis não estacionários e sujeitos a elevada variabilidade.

O modelo foi construído com base em uma sequência estruturada de etapas. Primeiramente, aplicaram-se técnicas de interpolação linear para preenchimento de falhas, seguidas da codificação cíclica das variáveis temporais, de modo a preservar a sazonalidade presente nos dados. Posteriormente, incorporou-se uma etapa de suavização por média móvel ponderada, destinada à atenuação de oscilações de alta frequência. Essa preparação dos dados foi decisiva para a estabilidade do processo de aprendizado e para a formação de categorias mais robustas pela rede.

A etapa de clusterização permitiu a segmentação dos perfis de carga em subconjuntos mais homogêneos, reduzindo a heterogeneidade das curvas utilizadas no treinamento. A seleção dinâmica do cluster mais próximo, realizada com base na curva média dos cinco dias úteis anteriores, favoreceu a especialização do modelo e aumentou sua acurácia, mesmo sem o uso de variáveis externas como temperatura ou ocupação.

Quatro abordagens foram testadas de forma comparativa: com e sem aplicação da clusterização, e com e sem suavização da carga. Os resultados confirmaram que a estratégia baseada em dados reais com clusterização apresentou o melhor desempenho médio nas métricas MAPE, RMSE e MAE. A suavização mostrou-se vantajosa principalmente em situações com maior instabilidade estrutural, reduzindo os erros absolutos em diversos casos. No entanto, sua aplicação isolada não foi suficiente para garantir bons resultados em todos os contextos, o que reforça a importância da clusterização como mecanismo de especialização do modelo.

Além dos testes amostrais apresentados ao longo do capítulo de resultados, o modelo foi aplicado à previsão de todos os dias úteis disponíveis na base de dados, conforme documentado no Apêndice. Essa abrangência valida a proposta não apenas do ponto de vista estatístico, mas também prático, confirmando sua capacidade de generalização para diferentes padrões sazonais e operacionais.

Com base nos resultados obtidos, verifica-se que o método proposto atinge de forma satisfatória o objetivo de produzir previsões robustas e coerentes com a complexidade dos perfis diários de carga, mesmo na ausência de variáveis exógenas ou em condições atípicas, como períodos de greve acadêmica. Sua estrutura modular, combinando preparação criteriosa dos dados, segmentação inteligente e modelagem adaptativa, contribui metodologicamente para o avanço da literatura na área de previsão de carga em ambientes com baixa agregação.

Como sugestões para trabalhos futuros, propõe-se a investigação de técnicas alternativas de

suavização que preservem oscilações estruturais relevantes das séries temporais, aliadas ao desenvolvimento de procedimentos computacionais capazes de identificar, de forma automatizada, o método mais apropriado conforme o perfil da série analisada. Além disso, recomenda-se a implementação de mecanismos estatísticos para seleção e validação de modelos preditivos alternativos aplicados à previsão de carga em nível desagregado, incluindo a análise de arquiteturas neurais distintas e a incorporação de estratégias híbridas baseadas em aprendizado de máquina não supervisionado.

REFERÊNCIAS

- AHMED, Z.; JAMIL, M.; KHAN, A. A. Short-term campus load forecasting using cnn-based encoder–decoder network with attention. **Energies**, MDPI, Basel, v. 17, n. 17, p. 1–19, 2024. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/17/17/4457>. Acesso em: 05 mar. 2025.
- ALVES, M. F. **Previsão de cargas não residenciais mistas por redes neurais ARTMAP Fuzzy**. 2019. 90 f. Tese (Doutorado de Engenharia Elétrica) — Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2019.
- BRITO, T. C.; BRITO, M. A. Forecasting of energy consumption: Artificial intelligence methods. In: IBERIAN CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES, 17th., 2022, Madrid, Espanha. **Anais eletrônicos...** [S.l.]: IEEE, 2022. p. 1–4. DOI:10.23919/CISTI54924.2022.9820078.
- CAI, J. *et al.* Processing thermogravimetric analysis data for isoconversional kinetic analysis of lignocellulosic biomass pyrolysis: Case study of corn stalk. **Renewable and Sustainable Energy Reviews**, Amsterdam, v. 82, p. 2705–2715, 2018. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032117313722>. Acesso em: 20 mar. 2025.
- CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition, and prediction. **IEEE Communications Magazine**, Piscataway, v. 30, n. 9, p. 38–49, 1992. ISSN 0163-6804. Disponível em: <https://doi.org/10.1109/35.156802>. Acesso em: 13 jan. 2025.
- CARPENTER, G. A. *et al.* Fuzzy artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, Piscataway, v. 3, n. 5, p. 698–713, 1992. ISSN 1045-9227. Disponível em: <https://doi.org/10.1109/72.159059>. Acesso em: 03 jan. 2025.
- CECATI, C.; CITRO, C.; SIANO, P. Combined operations of renewable energy systems and responsive demand in a smart grid. **IEEE Transactions on Sustainable Energy**, Piscataway, v. 2, n. 4, p. 468–476, 2011. ISSN 1949-3029. Disponível em: <https://doi.org/10.1109/TSTE.2011.2161624>. Acesso em: 01 fev. 2025.
- CECATI, C. *et al.* A novel rbf training algorithm for short-term electric load forecasting and comparative studies. **IEEE Transactions on Industrial Electronics**, Piscataway, v. 62, n. 10, p. 6519–6529, 2015. ISSN 0278-0046. Disponível em: <https://doi.org/10.1109/TIE.2015.2424399>. Acesso em: 20 fev. 2025.
- CHAN, K. Y. *et al.* Fuzzy clustering-based deep learning for short-term load forecasting in power grid systems using time-varying and time-invariant features. **Sensors**, Basel, v. 24, n. 5, p. 1391, 2024. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/24/5/1391>. Acesso em: 01 jun. 2025.
- CHITALIA, G. *et al.* Robust short-term electrical load forecasting framework for commercial buildings using deep recurrent neural networks. **Applied Energy**, Amsterdam, v. 278, p. 115410,

2020. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261920309223>. Acesso em: 10 fev. 2025.

FERNÁNDEZ, L. B. G.; LOTUFO, A. D. P.; MINUSSI, C. R. Development of a short-term electrical load forecasting in disaggregated levels using a hybrid modified fuzzy-artmap strategy. **Energies**, Basel, v. 16, n. 10, p. 4110, 2023. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/16/10/4110>. Acesso em: 15 jun. 2025.

GACHHADAR, A. *et al.* Power optimization in multi-tier heterogeneous networks using genetic algorithm. **Electronics**, Basel, v. 12, n. 8, p. 1795, 2023. ISSN 2079-9292. Disponível em: <https://www.mdpi.com/2079-9292/12/8/1795>. Acesso em: 15 jun. 2025.

GHELARDONI, L.; GHIO, A.; ANGUITA, D. Energy load forecasting using empirical mode decomposition and support vector regression. **IEEE Transactions on Smart Grid**, Piscataway, v. 4, n. 1, p. 549–556, 2013. ISSN 1949-3053. Disponível em: <https://doi.org/10.1109/TSG.2012.2235089>. Acesso em: 02 fev. 2025.

GU, Y.-D.; CHENG, J.-Z.; WANG, Z.-Y. An fuzzy forecasting algorithm for short-term electricity loads based on partial clustering. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 2011., 2011, Guilin, China. **Anais eletrônicos...** [S.l.]: IEEE, 2011. p. 1560–1565. DOI:<https://doi.org/10.1109/ICMLC.2011.6017031>.

HEGHEDUS, C.; CHAKRAVORTY, A.; RONG, C. Energy load forecasting using deep learning. In: IEEE INTERNATIONAL CONFERENCE ON ENERGY INTERNET, IEEE ICEI., 2018, Beijing, China. **Anais eletrônicos...** [S.l.]: IEEE, 2018. p. 146–151. DOI:<https://doi.org/10.1109/ICEI.2018.00-23>.

HERNÁNDEZ, L. *et al.* Artificial neural networks for short-term load forecasting in microgrids environment. **Energy**, Amsterdam, v. 75, p. 252–264, 2014. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544214008871>. Acesso em: 15 jan. 2025.

HNIN, S. W. *et al.* A hybrid k-means and knn approach for enhanced short-term load forecasting incorporating holiday effects. **Energy Reports**, Amsterdam, v. 12, p. 5942–5959, 2024. ISSN 2352-4847. Disponível em: <https://www.sciencedirect.com/science/article/pii/S235248472400773X>. Acesso em: 15 jan. 2025.

HU, Y.-S.; LO, K.-Y.; HSIEH, I.-Y. L. Ai-driven short-term load forecasting enhanced by clustering in multi-type university buildings: Insights across building types and pandemic phases. **Journal of Building Engineering**, Amsterdam, v. 104, p. 112417, 2025. ISSN 2352-7102. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352710225006540>. Acesso em: 08 jan. 2025.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, Amsterdam, v. 22, p. 679–688, 2006. ISSN 0169-2070. Disponível em: <https://doi.org/10.1016/j.ijforecast.2006.03.001>. Acesso em: 03 mai. 2025.

JEONG, D.; PARK, C.; KO, Y. M. Short-term electric load forecasting for buildings using logistic mixture vector autoregressive model with curve registration. **Applied Energy**, Amsterdam, v. 282, p. 116249, 2021. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261920316408>. Acesso em: 10 mar. 2025.

KHALIL, M. *et al.* Machine learning, deep learning and statistical analysis for forecasting building energy consumption — a systematic review. **Engineering Applications of Artificial Intelligence**, Amsterdam, v. 115, p. 105287, 2022. ISSN 0952-1976. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197622003372>. Acesso em: 01 jun. 2025.

KOUZELIS, K. *et al.* A simplified short-term load forecasting method based on sequential patterns. In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES EUROPE, IEEE ISGT Europe., 2014, Istanbul, Turkey. **Anais eletrônicos...** [S.l.]: IEEE, 2014. p. 1–5. DOI:<https://doi.org/10.1109/ISGTEurope.2014.7028944>.

MORI, H.; YUIHARA, A. Deterministic annealing clustering for ann-based short-term load forecasting. **IEEE Transactions on Power Systems**, Piscataway, v. 16, n. 3, p. 545–551, 2001. ISSN 0885-8950. Disponível em: <https://doi.org/10.1109/59.932293>. Acesso em: 09 mai. 2025.

MÜLLER, M. R. **Análise de desempenho da rede neural artificial ARTMAP fuzzy aplicada para previsão multi-step de cargas elétricas em diferentes níveis de agregação**. 2018. 97 f. Tese (Doutorado em Engenharia Elétrica) — Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, BR, 2018.

MÜLLER, M. R. *et al.* Electrical load forecasting in disaggregated levels using fuzzy artmap artificial neural network and noise removal by singular spectrum analysis. **SN Applied Sciences**, Cham, v. 2, n. 7, p. 1218, 2020. ISSN 2523-3971. Disponível em: <https://link.springer.com/article/10.1007/s42452-020-2988-5>. Acesso em: 30 mai. 2025.

PANAPAKIDIS, I. P.; DAGOUMAS, A. S. Day-ahead electricity price forecasting via the application of artificial neural network based models. **Applied Energy**, Amsterdam, v. 172, p. 132–151, 2016. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261916304160>. Acesso em: 10 jun. 2025.

PFISTER, H. **Hardware-Accelerated Volume Rendering**. 2005.

SABER, A. Y.; ALAM, A. K. M. R. Short term load forecasting using multiple linear regression for big data. In: IEEE SYMPOSIUM SERIES ON COMPUTATIONAL INTELLIGENCE (SSCI), 2017, Honolulu, HI, USA. **Anais eletrônicos...** Piscataway, 2017. p. 1–6. DOI:<https://doi.org/10.1109/SSCI.2017.8285261>.

THOKALA, N. K.; BAPNA, A.; CHANDRA, M. G. A deployable electrical load forecasting solution for commercial buildings. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY, IEEE ICIT., 2018, Lyon, France. **Anais eletrônicos...** [S.l.]: IEEE, 2018. p. 1101–1106. DOI:<https://doi.org/10.1109/ICIT.2018.8352332>.

WALKER, S. *et al.* Accuracy of different machine learning algorithms and added-value of predicting aggregated-level energy performance of commercial buildings. **Energy and Buildings**, Amsterdam, v. 209, p. 109705, 2020. ISSN 0378-7788. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378778819319139>. Acesso em: 25 jun. 2025.

ZHOU, H. B.; GAO, J. T. Automatic method for determining cluster number based on silhouette coefficient. In: ADVANCED RESEARCH ON INTELLIGENT SYSTEM, MECHANICAL DESIGN ENGINEERING AND INFORMATION ENGINEERING III, 3rd., 2014, China. **Anais eletrônicos...** Stafa-Zurich: Trans Tech Publications Ltd, 2014. p. 227–230. DOI:<https://doi.org/10.4028/www.scientific.net/AMR.951.227>.

**APÊNDICE A – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO SEGUNDA-FEIRA - SEM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-14	45,98	4524,15	3677,49	42,60	5080,51	3499,27
2012-05-14	39,35	3617,53	2835,97	37,54	4076,16	2793,47
2012-05-14	37,69	4044,33	3129,49	20,69	2572,26	1699,44
2012-06-04	39,93	2948,06	2246,72	29,59	4158,57	2585,68
2012-06-04	26,65	2682,29	1762,36	15,93	1452,63	1045,64
2012-06-18	41,71	4192,70	2935,13	20,08	2100,67	1466,58
2012-06-25	29,66	1941,96	1572,19	44,40	3796,36	2656,51
2012-07-02	35,74	2828,97	2116,87	28,64	2190,13	1674,98
2012-07-09	23,58	2972,67	1755,02	29,17	3445,06	2115,94
2012-07-16	28,13	2450,08	1620,01	43,93	3831,68	2621,20
2012-07-16	53,61	4602,75	3431,21	49,83	4062,19	3070,64
2012-07-23	39,59	4737,70	3052,11	18,73	2404,07	1378,63
2012-07-23	16,27	2023,09	1248,06	13,52	1586,94	1001,48
2012-08-27	51,25	4898,25	3362,92	43,89	3921,83	2787,30
2012-09-03	32,63	5594,88	3770,42	24,45	4486,46	3003,05
2012-09-03	37,51	5082,27	3630,16	43,72	5962,42	4337,55
2012-09-10	24,65	2363,79	1457,81	36,48	3225,29	2216,69
2012-09-10	29,23	3449,97	2048,75	38,47	3473,80	2474,50
2012-09-24	24,32	2012,90	1302,16	42,06	4183,99	2738,15
2012-10-29	32,35	3232,27	1858,23	22,99	3693,64	2285,84
2012-10-29	41,41	3692,78	2065,52	32,84	2583,88	1504,56
2012-11-05	25,05	3264,75	2070,08	29,23	3253,04	2175,83
2012-11-05	40,79	2938,71	1999,42	22,20	2273,62	1311,57
2012-11-05	28,09	2362,04	1466,51	33,49	3660,43	2440,76
2012-11-12	31,13	4646,19	2721,04	43,53	5123,12	3189,23
2012-11-26	32,05	2933,29	1940,31	29,06	2878,84	2053,05
2012-12-03	36,82	4580,77	3024,21	37,43	4902,49	3169,30
2013-01-07	38,90	3409,69	2376,22	27,95	2553,64	1634,88
2013-02-04	42,18	4996,76	3447,68	43,50	5179,76	3540,30
2013-02-04	23,07	2098,94	1380,99	30,59	4346,79	2829,01
2013-02-04	23,87	2311,83	1441,22	33,37	4119,06	2811,83
2013-02-18	37,96	2883,35	2044,17	43,53	3882,22	2804,18
2013-03-11	23,71	3227,07	1970,21	46,58	4268,95	2832,62
2013-03-25	29,06	3536,22	2289,38	28,94	3193,01	2139,24
2013-04-01	33,38	4004,26	2738,36	26,36	4344,72	2803,06
2013-04-15	43,97	2359,40	1835,55	36,87	2625,60	1914,83
2013-04-15	35,30	2496,07	1825,47	25,77	2257,65	1531,82
2013-04-22	33,65	2990,12	1938,09	27,64	2547,55	1538,15
2013-04-22	44,28	2351,49	1724,80	39,99	3989,40	2586,08
2013-04-29	28,57	2736,71	1713,49	32,02	4095,64	2331,77
2013-05-27	56,41	3640,73	2524,94	18,24	1998,67	1212,41
2013-06-03	33,82	2495,07	1728,23	25,58	2511,00	1593,80
2013-06-03	20,18	2360,26	1508,96	22,14	2781,71	1697,80
2013-07-01	38,76	4354,76	2633,47	33,66	2552,70	1605,86
2013-07-01	42,94	4544,24	2883,76	38,24	3255,32	2148,84
2013-07-08	56,48	3729,76	2607,11	34,73	2585,58	1600,54
2013-07-08	29,79	3234,69	2003,01	29,57	3417,31	2093,04
2013-07-08	28,09	2157,61	1455,83	43,90	4918,29	3122,43
2013-07-22	35,29	2450,70	1607,60	34,31	2236,37	1603,33
2013-07-29	33,84	4024,80	2407,70	40,54	3829,45	2856,94
2013-07-29	35,87	3827,69	2579,68	33,05	3763,01	2572,11
2013-07-29	26,77	2522,91	1801,47	23,03	2021,68	1382,29
2013-07-29	26,62	1963,36	1346,09	31,52	2644,64	1875,98
2013-08-05	47,84	3975,83	2861,96	39,23	2396,47	1664,57
2013-08-19	64,54	5660,24	4133,62	71,34	5966,69	4329,49

Fonte:Elaboração da própria autora.

**APÊNDICE B – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO SEGUNDA-FEIRA - COM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-14	26,69	2715,13	2119,65	17,45	1979,11	1363,35
2012-06-04	13,38	1224,33	819,13	13,07	1400,45	826,30
2012-06-18	26,71	2248,17	1700,87	13,18	1331,03	926,67
2012-06-25	17,22	1914,47	1160,13	16,62	1693,77	1136,44
2012-07-02	14,41	2561,90	1485,13	14,32	1507,14	1017,13
2012-07-09	17,41	2051,48	1240,26	14,76	1648,90	1037,18
2012-07-16	22,83	2279,44	1599,27	13,41	1335,29	876,79
2012-07-23	39,76	4741,79	3057,69	16,24	1594,49	973,57
2012-08-27	12,67	1140,37	764,38	15,67	1514,37	997,58
2012-09-03	27,20	5542,50	3540,60	15,91	2315,82	1424,88
2012-09-10	15,00	1966,08	1201,25	15,74	1904,41	1117,76
2012-09-24	20,57	1104,59	773,94	17,13	1121,96	780,05
2012-10-29	27,30	4968,21	3061,35	21,45	3145,71	1805,77
2012-11-05	20,18	1781,17	1080,91	24,67	2048,04	1300,83
2012-11-12	19,21	2133,55	1083,12	20,76	2206,01	1300,95
2012-11-26	27,68	2623,61	1724,38	21,91	2028,12	1289,67
2012-12-03	23,80	3957,97	2483,31	17,11	2405,98	1478,11
2013-01-07	20,91	1620,33	1080,29	18,32	1530,10	1037,22
2013-02-04	26,48	2304,32	1499,32	24,06	1723,93	1051,89
2013-02-18	26,59	6403,49	3802,40	21,62	4845,39	2634,92
2013-03-11	27,49	2741,53	1792,87	20,55	1885,73	1103,48
2013-03-25	34,20	3516,49	2286,67	19,95	2030,70	1207,16
2013-04-01	28,10	5007,73	3139,21	20,78	2958,75	1810,40
2013-04-15	47,10	2490,92	1841,57	34,44	1975,52	1448,72
2013-04-22	21,37	1916,01	1182,94	20,77	1609,91	1041,44
2013-04-29	27,24	2278,96	1423,09	15,39	1250,67	845,13
2013-05-27	22,03	2726,77	1687,06	19,00	1594,83	1088,68
2013-06-03	20,37	2346,90	1376,15	17,82	1431,31	930,94
2013-07-01	29,86	2794,51	1704,99	24,24	1691,33	1063,81
2013-07-08	28,78	2041,66	1357,19	19,08	1577,96	1027,13
2013-07-22	20,38	1402,41	960,10	19,71	1234,12	890,56
2013-07-29	27,38	2434,30	1714,48	21,19	1267,18	984,16
2013-08-05	28,84	2067,23	1468,37	20,86	1701,80	1126,95
2013-08-19	30,58	2481,07	1756,52	15,70	1276,41	890,27

Fonte:Elaboração da própria autora.

**APÊNDICE C – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO TERÇA-FEIRA - SEM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-15	27,50	1896,88	1695,27	30,56	4022,00	2783,99
2012-05-15	37,83	3723,40	2936,33	45,27	3927,14	3094,08
2012-06-19	36,52	3577,05	2555,13	22,79	2199,26	1585,11
2012-06-19	32,45	3575,17	2477,35	42,67	4216,88	3051,59
2012-06-26	22,68	1753,54	1328,85	29,39	2862,17	2033,62
2012-06-26	30,34	1910,94	1424,01	35,34	3294,89	2157,83
2012-07-03	31,07	2414,15	1694,40	21,01	2332,66	1522,47
2012-07-10	38,58	2339,42	1703,44	38,09	2943,06	2139,25
2012-07-10	28,61	2610,33	1667,87	25,35	2156,69	1384,87
2012-07-17	20,12	2069,16	1420,13	27,20	2328,46	1622,00
2012-07-24	40,19	3994,76	2926,57	47,97	4505,60	3351,66
2012-08-14	41,63	3872,02	2733,52	41,94	3957,45	2805,17
2012-08-14	24,08	2281,18	1523,79	26,69	2425,86	1597,51
2012-08-28	37,89	3260,88	2325,25	37,53	3531,95	2537,88
2012-08-28	33,11	2359,82	1671,42	28,32	1871,22	1285,09
2012-09-04	28,51	2593,15	1676,06	24,60	2782,89	1692,63
2012-09-11	41,40	3790,75	2822,88	42,00	3755,90	2807,73
2012-09-18	34,87	2381,30	1702,02	42,50	3051,17	2156,84
2012-09-25	34,39	2383,40	1584,66	41,35	3049,44	2117,30
2012-10-09	22,77	3867,10	2374,27	27,77	4616,75	2915,60
2012-10-16	25,91	2026,17	1336,79	34,67	2752,56	1794,94
2012-10-16	37,69	3202,59	2409,33	41,83	4054,58	2960,44
2012-10-23	28,93	3123,47	2022,47	36,44	3345,37	2297,48
2012-10-23	30,87	3017,64	1964,70	29,98	2584,52	1631,97
2012-10-30	24,41	2435,09	1610,77	31,53	2957,83	1984,60
2012-10-30	24,06	2502,25	1657,37	32,38	3081,20	2065,67
2012-11-06	36,10	3745,19	2422,00	31,20	2650,50	1687,92
2012-11-06	34,71	3654,70	2403,17	42,13	3740,07	2623,61
2012-11-20	36,35	3051,87	2158,41	29,79	3142,68	2229,15
2012-11-27	28,96	2062,27	1334,33	33,00	2873,48	1873,49
2012-12-04	33,87	2372,47	1612,88	30,93	2600,79	1802,08
2012-12-04	34,86	2229,27	1553,09	42,37	2642,57	1916,21
2013-01-29	25,59	1875,67	1292,23	27,52	2351,85	1593,27
2013-01-29	37,00	2939,83	1923,70	38,18	3140,17	2114,89
2013-02-26	25,14	3574,49	2456,01	27,52	3822,64	2626,82
2013-03-19	35,00	3191,83	2423,19	24,70	2105,15	1639,63

Fonte:Elaboração da própria autora.

**APÊNDICE D – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO TERÇA-FEIRA - COM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-15	28,32	3159,29	2268,04	15,49	1534,75	1164,27
2012-06-19	25,60	3154,93	2166,19	13,98	1956,49	1188,95
2012-06-26	31,37	3235,73	2128,18	15,49	1343,84	947,76
2012-07-03	26,55	2743,75	1931,81	15,96	1591,91	1126,42
2012-07-10	23,96	3850,37	2266,97	16,03	2008,92	1253,24
2012-07-17	11,81	1132,66	768,39	20,13	2271,58	1481,19
2012-07-24	27,10	3613,84	2491,92	18,88	2251,39	1460,66
2012-08-14	25,55	2416,76	1563,59	16,96	1781,12	1156,99
2012-08-28	21,20	2272,27	1542,41	18,30	2059,50	1355,02
2012-09-04	24,58	2267,53	1514,88	20,46	2166,78	1500,12
2012-09-11	27,30	2332,14	1534,04	19,94	1984,77	1401,74
2012-09-18	31,93	2529,66	1848,17	21,67	2130,44	1484,13
2012-09-25	32,60	2409,95	1725,80	25,71	2490,63	1813,65
2012-10-09	28,32	4779,27	3019,38	23,86	2494,64	1741,27
2012-10-16	25,66	2395,94	1705,77	20,49	2273,69	1593,84
2012-10-23	24,89	2493,19	1673,75	16,88	1743,38	988,36
2012-10-30	30,02	3187,58	2251,82	22,01	2341,80	1523,56
2012-11-06	29,25	2840,74	2029,53	19,67	2176,99	1432,52
2012-11-20	24,72	2532,11	1846,66	17,27	1860,39	1262,83
2012-11-27	28,35	2559,91	1747,29	22,90	2144,31	1381,85
2012-12-04	26,55	2464,08	1690,58	18,59	2133,63	1411,37
2013-01-29	29,87	2879,62	2040,76	22,43	2330,17	1625,83
2013-02-26	21,20	2083,20	1326,61	18,48	1645,85	1187,88
2013-03-12	15,94	2053,29	1228,61	17,72	2036,87	1209,44
2013-03-19	23,77	2424,98	1772,97	22,32	2244,80	1643,93

Fonte:Elaboração da própria autora.

**APÊNDICE E – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO QUARTA-FEIRA - SEM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-23	39,04	4617,05	3301,02	42,79	4614,80	3116,83
2012-05-30	32,26	4287,81	2844,38	18,27	3502,86	2232,36
2012-06-27	49,60	3581,87	2939,55	17,01	1637,21	1119,40
2012-07-11	30,47	2907,99	1996,67	33,76	3790,26	2497,35
2012-09-12	40,57	3671,32	2733,33	32,47	2913,90	1881,75
2012-10-03	22,74	2072,59	1312,28	14,08	1523,28	960,51
2012-10-10	16,99	1546,52	999,14	23,07	1959,37	1331,83
2012-10-17	17,97	1412,95	960,53	19,21	1516,36	1126,09
2012-10-24	24,45	2370,63	1583,12	25,15	2111,80	1397,46
2012-10-31	28,27	2574,83	1591,57	31,53	3090,60	1915,50
2012-11-07	32,10	2201,69	1533,95	30,06	2291,82	1654,70
2012-11-14	19,30	2067,88	1322,47	24,30	2299,11	1543,01
2012-11-21	22,38	2400,89	1637,62	20,93	1837,32	1282,74
2012-11-28	21,55	2305,95	1547,99	18,55	1693,64	1121,15
2012-12-05	22,64	2257,27	1472,02	18,82	1774,91	1201,62
2013-02-20	31,56	3385,08	2159,76	21,61	1942,02	1209,89
2013-02-27	27,41	3214,55	2256,79	29,63	2740,18	2040,91
2013-03-06	28,36	2799,12	1933,46	26,89	2370,56	1637,84
2013-03-13	20,08	1850,65	1224,24	17,18	1551,33	1094,44
2013-03-20	25,80	2905,94	1996,42	16,84	1919,94	1300,17
2013-03-27	21,52	2105,28	1357,36	23,46	2075,38	1401,77
2013-04-10	21,55	2164,86	1411,31	25,53	2405,57	1615,69
2013-04-17	26,26	2505,85	1734,72	25,87	2610,56	1746,14
2013-04-24	23,16	2048,30	1423,65	26,42	2452,38	1667,71
2013-05-01	33,32	2862,70	2100,25	29,26	2532,41	1762,88
2013-05-15	22,42	2179,96	1482,71	23,15	2093,36	1485,52
2013-05-22	26,40	2151,92	1542,91	17,72	1476,20	1067,63
2013-06-05	22,65	2367,48	1653,55	15,83	1625,14	1101,71

Fonte:Elaboração da própria autora.

**APÊNDICE F – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO QUARTA-FEIRA - COM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-23	19,98	3598,44	2153,60	15,28	2679,59	1561,81
2012-05-30	14,70	2859,40	1692,77	14,05	2225,01	1365,51
2012-06-27	16,92	1972,91	1330,75	12,93	1712,81	1055,81
2012-07-11	26,18	3552,15	2046,56	17,00	2209,68	1382,76
2012-09-12	22,46	3533,49	2077,92	13,10	1499,57	874,45
2012-10-03	11,98	1324,97	833,95	11,59	1300,47	905,06
2012-10-10	20,39	1686,56	1165,64	12,48	1201,70	856,39
2012-10-17	18,82	1567,77	1152,55	12,94	1238,63	897,87
2012-10-24	16,56	1524,79	1001,47	16,29	1538,83	1087,25
2012-10-31	27,33	2143,11	1457,21	16,84	1527,10	1017,58
2012-11-07	16,38	1634,49	1119,69	14,41	1302,58	937,64
2012-11-14	18,43	1906,91	1181,25	18,34	1956,41	1351,79
2012-11-21	13,74	1431,91	962,90	13,86	1362,29	975,68
2012-11-28	17,64	1812,41	1286,93	13,39	1204,59	812,39
2012-12-05	21,34	1904,30	1239,15	12,47	1246,20	867,80
2013-02-20	14,47	1447,65	975,36	13,10	1163,42	809,28
2013-02-27	25,74	2514,78	1771,19	20,87	1969,57	1382,60
2013-03-06	19,71	1695,77	1085,66	17,11	1536,53	1031,00
2013-03-13	18,26	1705,69	1145,22	14,16	1316,46	925,65
2013-03-20	18,74	1782,44	1250,31	16,03	1660,63	1206,52
2013-03-27	21,66	1947,27	1356,90	17,17	1623,97	1067,09
2013-04-10	21,85	1864,31	1261,44	18,59	1651,08	1166,56
2013-04-17	22,00	2123,56	1453,30	18,08	1922,97	1295,13
2013-04-24	18,85	1650,33	1123,57	15,44	1482,95	1034,33
2013-05-01	26,57	2102,47	1457,10	21,61	1820,13	1266,47
2013-05-15	19,49	1620,83	1091,94	17,09	1567,53	1106,99
2013-05-22	17,08	1655,47	1152,42	12,75	1265,08	849,63
2013-06-05	13,00	1366,78	910,36	11,91	1270,59	886,52

Fonte:Elaboração da própria autora.

**APÊNDICE G – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO QUINTA-FEIRA - SEM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-03	38,28	3760,28	2916,38	37,25	4796,15	3608,38
2012-06-21	31,67	2836,03	2111,76	32,47	4706,76	2955,59
2012-06-28	30,63	4133,52	2776,25	35,77	5853,94	3945,85
2012-07-12	24,84	2552,45	1681,48	49,71	4742,72	3427,46
2012-07-19	28,06	3031,06	2042,11	16,44	1929,50	1197,72
2012-07-26	33,19	4005,64	2699,01	26,19	2983,75	1947,28
2012-08-02	23,40	2662,82	1672,27	29,94	3443,70	2415,29
2012-08-09	31,71	3265,18	2044,06	35,62	3327,85	2252,57
2012-08-16	28,82	3323,83	2352,24	24,97	2612,71	1863,74
2012-08-23	26,49	2241,87	1512,98	22,36	2266,83	1552,10
2012-08-30	27,87	2630,10	1936,91	22,45	1921,65	1352,31
2012-09-13	32,14	2726,50	1891,46	31,89	2503,02	1756,85
2012-10-04	22,91	1839,38	1340,41	16,36	1483,88	1042,86
2012-10-11	21,97	2127,56	1456,57	27,97	2345,43	1658,25
2012-10-18	28,92	2589,26	1879,88	27,79	2140,73	1465,65
2012-10-25	30,48	2977,64	1973,52	32,63	3380,80	2452,90
2012-11-01	24,87	2761,99	1826,96	23,11	2651,68	1840,65
2012-11-08	23,81	2602,50	1883,41	23,68	2631,53	1916,08
2012-11-22	26,18	2465,27	1745,71	26,87	2690,10	1944,13
2012-11-29	22,65	2386,45	1512,29	25,82	2482,79	1707,00
2012-12-06	30,13	3100,35	2151,89	19,67	2427,84	1623,99
2013-01-10	27,77	2886,06	2003,77	24,39	2650,18	1746,63
2013-01-17	25,34	2282,27	1606,50	22,64	2170,31	1544,50
2013-02-07	27,09	2672,49	1880,99	18,73	2128,08	1459,26
2013-02-21	27,35	2703,87	1785,14	29,58	2523,96	1862,11
2013-02-28	23,57	2431,99	1584,74	23,93	2309,99	1679,37
2013-03-07	21,29	2210,70	1449,82	20,84	2033,35	1424,91
2013-03-14	25,42	2473,55	1735,99	21,65	2354,74	1615,76
2013-03-21	24,94	2482,55	1605,37	23,20	2257,18	1531,71
2013-03-28	25,89	2565,51	1806,93	22,38	2130,35	1484,64

Fonte:Elaboração da própria autora.

**APÊNDICE H – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO QUINTA-FEIRA - COM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-24	25,28	3370,11	2354,75	13,09	2596,65	1291,54
2012-06-28	26,10	3365,38	2361,52	19,60	2131,31	1474,96
2012-07-05	23,84	2382,16	1671,37	13,39	1613,34	991,85
2012-07-19	17,60	2353,28	1435,50	19,75	1983,28	1342,09
2012-07-26	26,09	2577,15	1701,50	14,12	1443,73	951,63
2012-08-02	15,23	1607,20	1083,21	13,68	1480,61	1023,13
2012-08-09	20,55	1944,81	1284,33	14,57	1631,32	1089,97
2012-08-16	18,77	1990,77	1413,46	14,03	1657,00	1117,30
2012-08-23	18,83	2085,06	1409,50	15,27	1921,85	1281,99
2012-08-30	19,50	1924,73	1265,49	14,01	1457,37	981,85
2012-09-13	23,59	2063,97	1402,52	17,74	1731,96	1174,47
2012-10-04	17,76	1731,45	1187,99	12,37	1286,85	866,21
2012-10-11	19,97	1831,99	1241,66	13,25	1443,80	975,78
2012-10-18	18,41	1624,95	1163,85	16,63	1435,67	1026,03
2012-10-25	20,57	1776,99	1186,99	16,79	1632,96	1138,83
2012-11-01	18,59	1730,17	1192,83	14,33	1400,26	951,79
2012-11-08	20,23	1793,49	1320,91	15,25	1469,86	1031,73
2012-11-22	19,62	1727,69	1201,46	13,56	1214,92	855,81
2012-11-29	20,38	1767,49	1146,22	17,09	1502,87	1062,41
2012-12-06	18,78	1651,80	1098,07	13,75	1351,44	891,78
2013-01-10	21,60	1800,31	1243,95	17,37	1497,57	1060,19
2013-01-17	19,89	1752,58	1173,71	16,22	1543,84	1114,39
2013-02-07	19,25	1823,20	1238,82	14,51	1362,17	935,84
2013-02-21	23,27	2132,57	1435,15	18,60	1752,56	1194,91
2013-02-28	21,24	1969,14	1296,56	17,20	1497,83	1036,68
2013-03-07	19,28	1683,83	1117,36	13,93	1262,51	880,63
2013-03-14	18,91	1615,91	1066,40	15,48	1505,76	1023,83
2013-03-21	20,82	1831,30	1208,63	15,35	1408,58	976,21
2013-03-28	18,73	1722,31	1183,29	15,01	1401,20	1017,77
2013-05-23	15,93	1774,39	987,11	14,62	1182,00	769,27

Fonte:Elaboração da própria autora.

APÊNDICE I – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO SUBCONJUNTO SEXTA-FEIRA - SEM CLUSTERIZAÇÃO

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-04	31,64	4076,96	2865,26	42,30	4826,39	3362,47
2012-06-29	32,49	3545,73	2770,92	31,59	5673,51	3667,03
2012-07-06	35,07	3854,93	2751,88	33,26	4895,71	2881,60
2012-07-27	25,49	3467,71	2331,35	26,71	3606,83	2145,77
2012-08-17	24,16	2692,71	1791,37	40,19	6170,32	4420,81
2012-09-21	24,67	1802,28	1239,41	32,80	1852,14	1329,55
2012-09-28	58,70	5107,93	3485,45	36,34	3462,20	2164,02
2012-10-19	25,23	3907,23	2584,44	25,82	3927,18	2723,78
2012-10-26	32,50	2167,32	1592,19	39,96	4312,13	2834,19
2012-11-09	34,54	2777,57	2001,62	29,96	3172,03	2280,13
2012-11-23	17,70	2770,97	1557,37	18,95	3261,21	1733,27
2012-11-30	31,05	3821,60	2605,10	36,24	4408,61	3014,10
2012-12-21	24,87	1677,08	1198,44	28,87	3425,78	2258,15
2013-01-11	37,16	2637,29	1842,75	36,23	2291,78	1812,34
2013-01-18	26,36	2212,09	1471,98	31,14	3447,38	2404,50
2013-02-01	21,56	3753,42	2446,43	41,28	6180,11	4381,83
2013-02-15	20,98	2258,37	1371,24	25,01	3360,01	2122,81
2013-02-22	29,85	3050,34	2239,92	22,02	3273,27	2147,71
2013-03-01	33,10	4872,23	3444,79	32,36	4884,90	3428,21
2013-03-08	35,34	5733,92	3947,27	43,77	7043,53	4882,50
2013-03-15	25,35	3156,71	1923,10	31,65	3803,44	2394,62
2013-03-22	30,01	2663,67	1950,83	37,92	4186,86	3021,75
2013-04-12	35,69	3535,64	2383,63	33,65	3142,01	2310,35
2013-04-26	24,78	2673,95	1630,42	30,77	2653,09	1803,91
2013-05-03	20,32	2304,53	1487,48	24,36	2677,25	1950,40
2013-05-10	24,20	2009,22	1314,80	22,33	1650,09	1208,04
2013-05-24	25,42	1824,50	1294,15	47,02	3086,71	2328,33
2013-06-07	24,62	1855,63	1253,46	42,11	3812,37	2506,26
2013-06-21	33,32	1904,75	1387,40	49,86	3918,77	2713,90
2013-07-19	17,48	1222,91	857,50	47,66	3944,53	2797,69
2013-07-26	33,72	2921,58	1982,52	45,36	4979,92	3191,28
2013-08-09	15,21	1206,05	794,38	25,56	2361,41	1670,00

Fonte:Elaboração da própria autora.

**APÊNDICE J – RESULTADO DA PREVISÃO DE CARGA ELÉTRICA DO
SUBCONJUNTO SEXTA-FEIRA - COM CLUSTERIZAÇÃO**

Data	MAPE R	RMSE R	MAE R	MAPE S	RMSE S	MAE S
2012-05-04	14.78	2425.45	1439.66	16.03	2406.71	1456.32
2012-06-29	17.31	3117.66	1849.57	15.94	1794.13	1237.05
2012-07-06	19.84	2623.02	1614.55	17.83	2112.29	1365.46
2012-07-27	14.78	1618.82	1041.61	19.68	1890.35	1298.34
2012-08-17	20.53	3210.90	2090.08	14.84	1787.64	1253.08
2012-09-21	25.23	1872.95	1333.83	15.93	1256.27	861.56
2012-09-28	19.16	1641.96	1143.29	19.51	1369.71	928.10
2012-10-19	35.29	4997.41	3343.38	23.91	2909.12	1947.10
2012-10-26	29.99	2565.11	1820.10	25.02	1776.14	1244.02
2012-11-09	18.32	2215.17	1466.84	20.72	2386.56	1458.41
2012-11-23	33.51	3927.21	2631.98	25.48	3048.29	2035.36
2012-11-30	22.68	1800.50	1355.42	24.30	2318.73	1536.52
2012-12-21	36.75	3392.08	2475.39	24.91	2630.07	1768.85
2013-01-11	28.93	2225.11	1590.03	26.59	1904.76	1383.58
2013-01-18	25.01	2251.81	1520.94	21.83	2003.20	1304.16
2013-02-01	18.86	2534.06	1575.77	18.39	1984.47	1245.23
2013-02-15	21.54	2533.02	1612.37	16.19	2052.16	1177.76
2013-02-22	23.79	2902.43	1938.09	16.73	1773.64	1169.94
2013-03-01	20.90	2724.67	1600.83	15.43	1835.76	1147.67
2013-03-08	23.68	3488.05	1961.27	19.91	2344.37	1520.19
2013-03-15	48.00	4293.00	3222.89	22.49	2585.72	1785.92
2013-03-22	28.42	3442.98	2357.64	23.81	1933.59	1438.94
2013-04-12	29.21	2288.80	1665.28	28.76	1591.72	1283.00
2013-04-26	27.33	2638.39	1682.92	18.78	1315.67	918.80
2013-05-03	30.17	4183.18	3065.20	22.73	1962.54	1437.47
2013-05-10	25.94	2056.18	1432.18	24.21	1245.89	955.06
2013-05-24	24.45	1809.98	1271.77	16.75	1355.99	888.16
2013-06-07	21.17	1666.75	1057.40	15.39	1104.96	736.17
2013-06-21	36.04	2646.92	1862.92	23.23	1743.25	1187.80
2013-07-19	25.31	2669.68	1721.77	17.68	1214.13	836.15
2013-07-26	29.07	2634.64	1877.07	20.53	1425.08	1050.81
2013-08-09	24.22	1805.95	1251.04	18.47	1727.88	1099.65

Fonte:Elaboração da própria autora.