

# **Previsão de demanda de curto prazo usando aprendizado de máquina com dados por telemetria: Um estudo de caso no Brasil**

**Marcos R. de Souza<sup>1</sup>, Danilo P. Silva<sup>2</sup>, Thiago M. Paixão<sup>3</sup>**

<sup>1</sup>Campus Serra - Instituto Federal do Espírito Santo (IFES)

ortolane@gmail.com, {danilo.silva, thiago.paixao}@ifes.edu.br

**Abstract.** This study evaluates the performance of machine learning models in short-term demand forecasting for a consumer with distributed solar generation. Using a dataset with multi-seasonal patterns and high variability, we compare models such as Ridge, KNN, LGBM, XGBoost, CatBoost, Random Forest, and MLP. Hyperparameter optimization with time-series cross-validation was applied during the tuning phase. The results showed that Random Forest outperformed the others, achieving an MAE of 8.94 kW, surpassing the baseline model by more than 51%. XGBoost, in turn, performed 49% better than the baseline model and had a training time 16 times shorter than Random Forest.

**Resumo.** Este estudo avalia o desempenho de modelos de aprendizado de máquina na previsão de demanda de curto prazo em um consumidor com geração solar distribuída. Utilizando um conjunto de dados com padrões multi-sazonais e alta variabilidade, comparamos modelos como Ridge, KNN, LGBM, XGBoost, CatBoost, Random Forest e MLP. Foi aplicada otimização de hiperparâmetros com validação cruzada temporal durante a fase de ajuste. Os resultados mostraram que o Random Forest superou os demais, alcançando um MAE de 8,94 kW, superando o modelo de base em mais de 51%. O XGBoost, por sua vez, apresentou desempenho 49% superior ao modelo de base e tempo de treinamento 16 vezes menor que o Random Forest.

## **1. Introdução**

A previsão de demanda de energia desempenha um papel central na operação e no planejamento de sistemas elétricos, impactando diretamente a confiabilidade do fornecimento, a estabilidade do sistema e a eficiência econômica das operações. Segundo [Mori and Ogasawara 1993], previsões precisas são essenciais para evitar desperdícios de recursos, otimizar o despacho de energia e reduzir os custos associados à geração e distribuição. Erros de previsão podem resultar em sobrecarga, falhas no fornecimento e custos adicionais para aquisição emergencial de energia no mercado, enquanto cada 1% de aumento na precisão pode economizar milhões de dólares em custos operacionais [Hafeez et al. 2020, Jin et al. 2020].

Além de sua importância operacional, a previsão de demanda tem implicações econômicas e sociais profundas. Ela permite que concessionárias planejem a geração de energia de forma eficiente, garantindo não apenas o fornecimento ininterrupto, mas também a integração de fontes renováveis, como solar e eólica, ao sistema.

Essa integração, indispensável para a transição energética global, depende de modelos de previsão robustos para lidar com a intermitência e variabilidade dessas fontes [Hodge et al. 2013]. Também é fundamental para otimizar o uso de sistemas de armazenamento de energia, como baterias, que ajudam a equilibrar a oferta e a demanda em períodos críticos [Dash et al. 2021].

A previsão de demanda de energia elétrica consiste principalmente em examinar dados passados, levando em conta os diversos fatores que impactam o consumo de eletricidade. A partir dessa análise, são extraídas informações relevantes que serão utilizadas para desenvolver um modelo matemático com o objetivo de prever a trajetória futura do uso e do crescimento da energia elétrica [Dong et al. 2022].

A demanda de energia pode ser caracterizada como uma série temporal, dada sua natureza intrinsecamente dependente do tempo. Segundo [Sousa et al. 2021], esses dados são fundamentais para identificar padrões sazonais, tendências e variações que influenciam o comportamento da demanda. Em sistemas elétricos, as séries temporais incluem variáveis como consumo horário, padrões de dias úteis e finais de semana, que são cruciais para desenvolver modelos preditivos robustos.

Os horizontes de previsão classificam as projeções em curto, médio e longo prazo. As previsões de curto prazo (horas a dias) orientam decisões operacionais como o despatch econômico e o agendamento de unidades geradoras, que são críticos para evitar desperdício de energia e custos adicionais com geração térmica [Saksornchai et al. 2005]. As previsões de médio prazo (semanas a meses) servem para planejamento de manutenção e na alocação de recursos, enquanto no longo prazo (anos) é aplicada ao planejamento de expansão de infraestrutura e políticas públicas de eficiência energética [Kumari and Toshniwal 2021]. Cada horizonte apresenta desafios específicos, exigindo técnicas adaptadas às características e incertezas de cada período.

Diversas abordagens têm sido desenvolvidas para previsão de demanda de energia de curto prazo, variando de métodos tradicionais, técnicas baseadas em aprendizado de máquina, aprendizado profundo ou a combinação desses, os chamados modelos híbridos. [Mohammad et al. 2018] investigaram o uso de Redes Neurais Profundas (*Deep Neural Networks*, DNN) para previsão de carga de curto prazo, aplicando as arquiteturas *Deep Feed-forward Neural Network* (Deep-FNN) e *Deep Recurrent Neural Network* (Deep-RNN). O estudo avalia a precisão das previsões de carga elétrica em diferentes estações do ano, utilizando funções de ativação como Sigmoid, Tanh e ReLU. [Guo et al. 2021] propuseram um modelo de previsão de carga de curto prazo híbrido multietapas com técnica de pré-processamento (EEMD) baseado na fusão dos modelos SVM, RF (Random Forest) e LSTM para melhorar a precisão das previsões. [Anh et al. 2024] abordaram o SARIMA-ONS, uma variante online do SARIMA que atualiza parâmetros via *Online Newton Step*, alcançando um MAPE de 4,57% na previsão de carga horária no Vietnã. [Tziolis et al. 2022] compararam seis modelos de *machine learning* (ML) (ANN, XGBoost (XGB), KNN, RF, RNN e SVR) para previsão de carga líquida em microrredes, fornecendo uma análise prática que evidencia a aplicabilidade dos modelos ML em sistemas com alta penetração de energia fotovoltaica. Em [e Silva et al. 2020], os autores propõem o gerenciamento de uma microrrede, capaz de operar isolada e conectada, através de um modelo de otimização de controle utilizando um sistema preditivo econômico híbrido usando dados meteorológicos e geração renovável reais. Porém os dados de demanda

utilizados nesse estudo são sintéticos.

[Hwang et al. 2022] propõe um método de agendamento de sistemas de armazenamento de energia (ESS) usando LSTM com dados aumentados com possíveis incertezas para reduzir a carga de pico durante horários de alta demanda. Faz uso de dois ESS: o primeiro ESS é programado uma vez por dia com base em uma previsão de carga de um dia, enquanto o segundo ESS é programado a cada 15 minutos durante o período de pico, utilizando previsão de curto prazo por LSTM. [Dong et al. 2022] propõe um método de previsão de carga elétrica de curto prazo baseado em SVM e K-Means, visando capturar o impacto de variáveis como temperatura e feriados sobre as cargas sazonais. A metodologia se concentra em agrupar dias semelhantes com base nas condições de temperatura e em distinguir entre dias úteis e feriados. [Jin et al. 2021] estudaram uma arquitetura Codificador-Decodificador com uma rede neural recorrente com portas (GRU), usando técnica de Atenção Temporal para previsão de carga de energia de curto prazo, usando dados da *American Electric Power* (AEP) em um horizonte de 24 horas com otimização dos hiperparâmetros via otimização *bayesiana*. [Koukaras et al. 2024] analisaram diferentes modelos de aprendizado de máquina para previsão de carga de curto prazo em edifícios, onde são testadas resoluções de 15 minutos, 30 minutos e 1 hora, avaliando o impacto de diferentes horizontes de previsão. Modelos de regressão linear, árvores de decisão e métodos de *boosting* são comparados para determinar a abordagem mais eficaz.

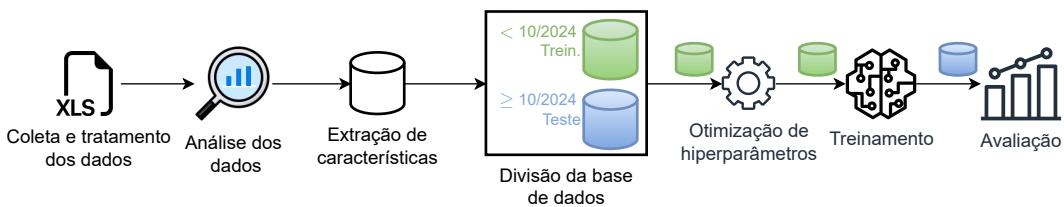
Este trabalho realiza um estudo comparativo de sete algoritmos de aprendizado de máquina para a previsão de demanda de energia de curto prazo em um cenário com alta variabilidade e geração distribuída intermitente, empregando técnicas de extração de características, criação de defasagens temporais e incorporação de variáveis cíclicas. Além disso, aplica otimização de hiperparâmetros por meio de otimização *bayesiana* e apresenta um estudo de caso real com uma base de dados única.

## 2. Materiais e Métodos

A Figura 1 mostra as etapas de construção e avaliação dos modelos preditivos. O processo inicia-se com a coleta e tratamento dos dados. Em seguida, é realizada a análise exploratória dos dados, permitindo a identificação de padrões e tendências relevantes. Após essa etapa, são aplicadas técnicas de extração de características, como a criação de defasagens temporais e a transformação de variáveis temporais em componentes cíclicos. A base de dados é então dividida em conjuntos de treino e teste, possibilitando uma avaliação confiável dos modelos. Na fase seguinte, é realizada a otimização de hiperparâmetros por meio do *framework Optuna*, utilizando otimização bayesiana para selecionar as melhores configurações para cada algoritmo. Por fim, os modelos são treinados e avaliados com métricas estatísticas, permitindo a comparação de desempenho e a identificação da abordagem mais eficaz para a previsão de demanda de energia.

### 2.1. Base de dados

A base de dados utilizada neste estudo foi construída a partir dos registros de demanda de energia elétrica do Instituto Federal do Espírito Santo (Ifes) Campus Serra, uma instituição de ensino brasileira, abrangendo o período de setembro de 2022 a janeiro de 2025. As medições, totalizando mais de 82.000 registros, foram realizadas em intervalos de 15 minutos pelo analisador de energia trifásico ISSO DMI F3000R v2 True



**Figura 1. Visão geral do processo de construção e avaliação dos modelos preditivos.**

RMS. Para mais detalhes sobre a coleta e aquisição dos dados de demanda veja o artigo [Guaitolini et al. 2023].

Uma característica relevante dessa base de dados é a presença de geração distribuída por meio de um sistema fotovoltaico de 119 kWp, o que introduz variabilidade na demanda de energia. Além disso, a série temporal apresenta padrões multisazonais, com sazonalidades mensal, semanal e diária, refletindo oscilações típicas de uma instituição educacional, influenciadas pelo calendário acadêmico.

## 2.2. Pré-processamento

### 2.2.1. Coleta e tratamento dos dados

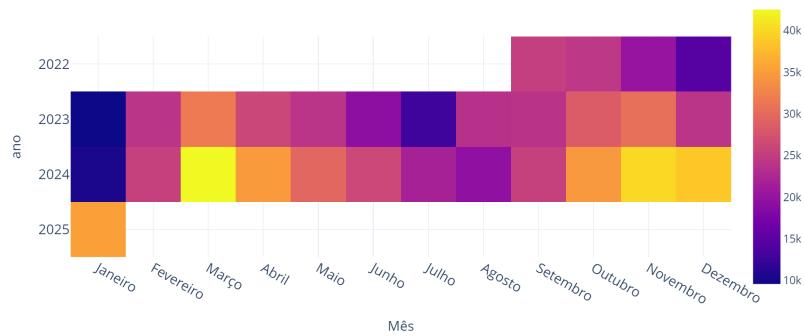
Os dados foram extraídos do analisador ISSO DMI F3000R via telemetria e organizados em planilhas mensais armazenadas em uma pasta compartilhada no Google Drive. Para garantir a integridade temporal dos registros, o formato da data foi padronizado para `yyyy-mm-dd hh:mm`, além da conversão das variáveis para os tipos adequados: `início` para `datetime` e `demand` para `float64`.

O tratamento dos dados incluiu a remoção de registros duplicados e a aplicação de interpolação `nearest` para preenchimento de valores ausentes. Como resultado, foi gerado um arquivo consolidado no formato `.xlsx`, contendo os dados tratados e prontos para as etapas subsequentes de análise e modelagem.

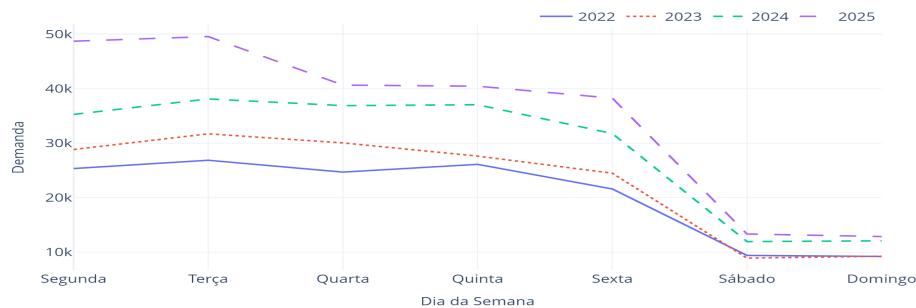
### 2.2.2. Análise exploratória dos dados

No gráfico de calor de demanda (*Anos vs. Meses*) da Figura 2 é possível observar a sazonalidade mensal nos dados. Note que os meses de janeiro e julho, que coincidem com os períodos de férias e recessos, apresentam os menores níveis de demanda. Em contraste, os meses de março, abril e maio demonstram os maiores níveis de demanda, indicando períodos de alta atividade e consumo. Tratam-se de meses historicamente quentes, nos quais o uso de climatizadores é frequente, inclusive durante a noite.

O gráfico de sazonalidade semanal (Figura 3) evidencia que os finais de semana em que não há atividades na instituição apresentam, conforme esperado, uma queda significativa nos níveis de demanda. Essa redução da demanda nos dias de sábado e domingo sugere que a demanda de energia está fortemente relacionada à programação de atividades da instituição, ressaltando a importância de considerar esses padrões ao planejar e prever a demanda.

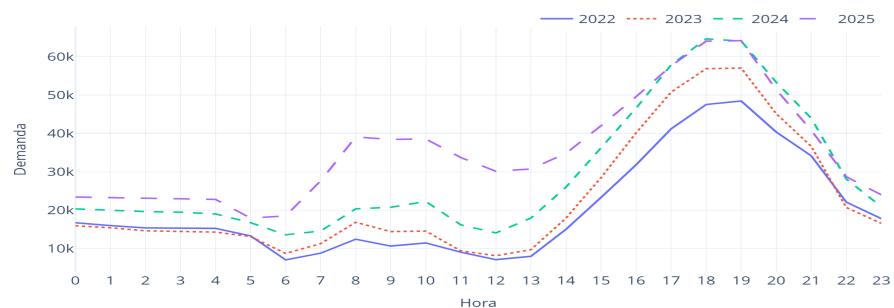


**Figura 2. Gráfico de calor Demanda (kW) - Anos vs Meses**



**Figura 3. Gráfico de sazonalidade semanal média (kW)**

A sazonalidade diária é retratada na Figura 4, que demonstra a ocorrência de horários de pico de demanda entre 16 e 21 horas, coincidentes com os períodos de maior atividade na instituição. Além disso, durante os horários de sol intenso, a demanda tende a ser significativamente reduzida devido à geração da usina fotovoltaica. A energia solar é utilizada para suprir parte das necessidades energéticas da instituição, minimizando a demanda sobre a rede elétrica.



**Figura 4. Gráfico de sazonalidade diária média (kW)**

### 2.2.3. Extração de características

Esta etapa visa transformar a série temporal original em um formato adequado para aprendizado de máquina, focando em capturar tanto padrões temporais quanto relações autorregressivas. Baseado na análise exploratória dos dados, foram criadas variáveis derivadas de informações temporais, autorregressivas e estatísticas. Para representar variações

cíclicas, as horas, dias da semana e meses foram transformados em componentes senoidais e cossenoidais, ajudando o modelo a capturar periodicidades. Além disso, foi aplicada a técnica de *Time-Delay Embedding*, que consiste em introduzir *lags* na variável de interesse, convertendo a série em um conjunto de variáveis com diferentes intervalos de atraso, modelando sua estrutura autorregressiva. Como resultado, padrões históricos podem ser utilizados para prever valores futuros, configurando os dados como séries temporais multivariadas ordenadas. A Tabela 1 sumariza as variáveis utilizadas na construção dos modelos preditivos, detalhando suas características e finalidades.

### 2.3. Divisão dos dados: treinamento e teste

A base de dados foi dividida em conjuntos de treinamento (80%) e teste (20%) para a devida avaliação dos modelos. A separação foi feita de forma cronológica, preservando a sequência temporal dos dados, o que é fundamental para modelos de séries temporais, pois evita o vazamento de informações e assegura que o modelo seja testado com dados futuros em relação ao período de treinamento. O conjunto de treinamento foi usado na otimização de hiperparâmetros e no treinamento propriamente dito dos modelos. Já o conjunto de teste serviu para inferência e cálculo das métricas de desempenho.

## 2.4. Experimentos

Os experimentos conduzidos neste estudo abrangem treinamento, inferência e avaliação métrica dos modelos preditivos propostos. Para estabelecer um protocolo avaliativo robusto, foi implementada uma linha de base comparativa (*baseline*), que serve como referência mínima de desempenho.

**Linha de base** A linha de base, denominada *SeasonalNaive*, prevê a demanda futura assumindo que os valores observados exatamente uma semana antes – 672 pontos para uma taxa de amostragem de 15 minutos – se repetirão no mesmo horário. Dessa forma, captura os padrões cílicos semanais característicos do consumo de energia. A escolha desse parâmetro deve-se à forte sazonalidade semanal presente na série temporal, refletindo variações recorrentes nos hábitos de consumo ao longo dos dias úteis e finais de semana.

### 2.4.1. Otimização de hiperparâmetros

Esta etapa foi realizada empregando-se o *Optuna*, uma biblioteca popular de otimização de hiperparâmetros baseada em busca bayesiana e estratégias adaptativas [Akiba et al. 2019]. Para cada modelo, foram definidos os hiperparâmetros relevantes e seus respectivos domínios de busca. O *Optuna* foi configurado para minimizar o Erro Absoluto Médio (MAE), realizando um total de 100 iterações. Como protocolo de validação cruzada, foi utilizado o *TimeSeriesSplit* da biblioteca *Scikit-Learn*, com 7 *folds*, que divide os dados de forma progressiva, preservando a ordem temporal e evitando o vazamento de informações futuras. Em cada rodada de treino e avaliação, o *fold* mais recente foi utilizado para calcular as métricas de desempenho do modelo, enquanto os anteriores foram empregados no treinamento. Para a padronização dos dados, foi aplicada a normalização por meio do *StandardScaler*, que ajusta os valores das características para

**Tabela 1. Descrição das Variáveis**

Variável	Descrição
demand	Variável alvo do estudo, representando a demanda de energia em kW. O objetivo é prever seu comportamento futuro com base nas demais variáveis explicativas.
dia_semana	Dia da semana em formato numérico, onde 0 = Domingo e 6 = Sábado. Incluída para capturar variações diárias no consumo, como diferenças entre dias úteis e não úteis.
fim_semana	Variável binária (0 = não, 1 = sim) que indica se o dia é um fim de semana, destacando períodos em que a demanda pode ser influenciada por comportamentos distintos.
{sen,cos}_hora	Transformações senoidal e cossenoidal da hora do dia dada por $x_f = f \left( \frac{2\pi x}{x_{max}} \right), \quad (1)$ onde $f$ indica a função seno ou cosseno e $x_{max}$ o valor máximo da variável $x$ (neste caso, 6). Essas variáveis codificam a periodicidade diária de 24 horas, permitindo que o modelo entenda padrões cíclicos.
{sen,cos}_dia_semana	Transformações análogas para o dia da semana, calculadas com base na Equação 1. Elas capturam a sazonalidade semanal, ajudando o modelo a diferenciar padrões entre dias específicos (ex., segunda-feira vs. sexta-feira).
{sen,cos}_mes	Transformações senoidal e cossenoidal do mês, calculadas com base na Equação 1. Essas variáveis refletem a sazonalidade anual, como variações de consumo entre estações (ex., verão com maior demanda por uso mais intenso de ar condicionado).
lag96 e lag672	Representam a demanda defasada em 96 períodos (1 dia) e 672 períodos (1 semana). Essas variáveis são usadas para incorporar dependências temporais de curto e médio prazo, reconhecendo que a demanda atual é influenciada por valores recentes e históricos.
{media,desvio}_{-96,-672}	A média e o desvio padrão das defasagens lag96 e lag672. Essas estatísticas agregadas representam tendências centrais e a variabilidade da demanda nas últimas 24 horas e 7 dias.

que tenham média zero e desvio padrão unitário, garantindo uma escala uniforme e melhorando a estabilidade do treinamento dos modelos.

É importante salientar que a otimização foi restrita ao conjunto de treinamento, de modo que os dados empregados para avaliar o desempenho dos modelos nesse estágio desempenharam o papel de conjunto de validação, sem a necessidade de definição explícita dessa partição. A Tabela 2 exibe a combinação de hiperparâmetros que resultou no valor mínimo da função objetivo.

Modelo	Melhores Hiperparâmetros
<b>Ridge</b>	alpha=0.1, solver='cholesky'
<b>LGBMRegressor</b>	n_estimators=550, max_depth=5, learning_rate=0.01, subsample=0.9, reg_alpha=1e-05
<b>Random Forest</b>	criterion='squared_error', n_estimators=250, max_depth=9, min_samples_split=5, min_samples_leaf=4, bootstrap=True
<b>XGBRegressor</b>	n_estimators=450, max_depth=5, learning_rate=0.01, subsample=0.6, reg_alpha=0.01
<b>CatBoost</b>	depth=7, n_estimators=650, learning_rate=0.01, subsample=0.6, l2_leaf_reg=50
<b>KNeighbors</b>	n_neighbors=73, weights='distance', algorithm='auto'
<b>MLPRegressor</b>	hidden_layer_sizes=(144,), max_iter=1000, learning_rate_init=0.01, alpha=0.001, activation='tanh', solver='adam', shuffle=False

**Tabela 2. Melhores combinações de hiperparâmetros obtidas via Optuna.**

## 2.5. Treinamento e avaliação do modelo

Após a otimização dos hiperparâmetros, cada modelo foi retreinado em todo o conjunto de treinamento (treinamento final), utilizando as combinações de hiperparâmetros apresentadas na Tabela 2. Antes do treinamento, os dados foram normalizados por meio do *StandardScaler*, seguindo o mesmo procedimento adotado na fase de otimização.

Após o treinamento, o modelo foi utilizado para gerar previsões no conjunto de teste. Os valores previstos foram então revertidos para a escala original, assegurando que as métricas de erro fossem calculadas corretamente. Tais métricas incluem: Erro Absoluto Médio (**MAE**), Erro Quadrático Médio (**RMSE**), Erro Percentual Absoluto Médio Ponderado (**WMAPE**) e **R<sup>2</sup>** (coeficiente de determinação).

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|, \quad \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}. \quad (2)$$

$$\text{WMAPE} = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{\sum_{t=1}^n |y_t|}, \quad R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2}. \quad (3)$$

onde  $y_t$  e  $\hat{y}_t$  representam, respectivamente, os valores real e previsto no tempo  $t$ , e  $n$  é o total de observações.

## 2.6. Resultados e discussão

A Tabela 3 apresenta as métricas de desempenho (MAE, RMSE, WMAPE e R<sup>2</sup>), incluindo tempo de processamento para gerar as previsões, resultantes da avaliação dos modelos no conjunto de teste.

O modelo **RF** se destacou com os menores valores de MAE (8,94) e RMSE (15,70), sugerindo precisão adequada nas previsões de demanda de energia, mesmo em cenários com flutuações sazonais ou padrões irregulares. Além disso, o modelo alcançou um WMAPE de 0,27 e um R<sup>2</sup> de 0,76, que são métricas complementares que reforçam sua eficiência. O WMAPE reflete o erro médio ponderado pela escala da demanda, enquanto o R<sup>2</sup> mede a proporção da variabilidade dos dados explicada pelo modelo. Um R<sup>2</sup> de 0,76 indica que o RF consegue capturar cerca de 76% da variabilidade nos dados, o que é adequado para problemas de previsão de demanda de energia. No entanto, o tempo de execução do RF foi de 44,38 segundos, o segundo maior entre os modelos avaliados. Embora esse tempo seja aceitável para aplicações onde a precisão é prioritária, ele pode ser uma limitação em cenários operacionais que exigem respostas rápidas, como sistemas de monitoramento em tempo real. Portanto, o uso do RF deve ser balanceado entre a necessidade de precisão e a tolerância ao tempo de processamento.

Modelo	MAE	RMSE	WMAPE	R <sup>2</sup>	Tempo(s)
RF	<b>8,94</b>	<b>15,70</b>	<b>0,27</b>	<b>0,76</b>	44,38
XGB	9,31	16,12	0,28	0,75	2,71
LGBM	9,41	16,18	0,28	0,74	1,63
MLP	9,48	15,97	0,29	0,75	53,53
CatBoost	9,71	16,57	0,29	0,73	6,01
Ridge	10,93	17,62	0,33	0,70	<b>0,04</b>
KNN	11,27	17,92	0,34	0,68	1,30
SeasonalNaive	18,26	31,87	0,55	-	1,04

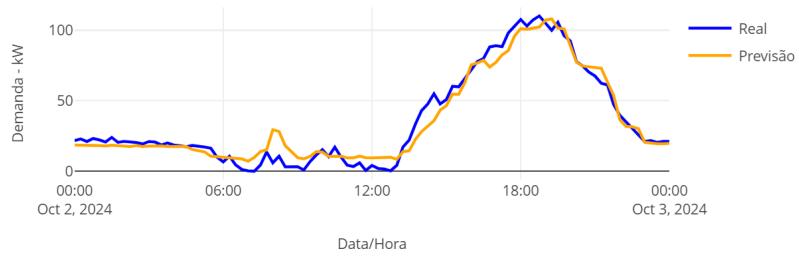
**Tabela 3. Comparação dos modelos de aprendizado de máquina: métricas de erro e tempos de processamento.**

O XGB e o LGBM apresentaram desempenhos próximos ao RF, com pequenas perdas em precisão, mas tempos de execução significativamente menores: 2,71 segundos (-93,90%) e 1,63 segundos (-96,33%), respectivamente. Esses modelos são ideais quando é necessário equilibrar precisão e velocidade.

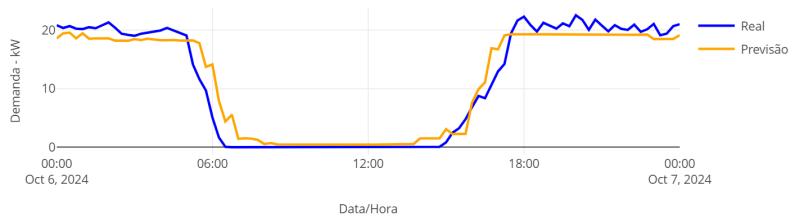
O MLP teve um desempenho intermediário, com MAE de 9,48 e RMSE de 15,97, mas seu tempo de execução foi o maior (53,53 segundos, +20,62% em relação ao RF), tornando-o menos adequado para cenários operacionais rápidos. Já o CatBoost alcançou resultados sólidos, mas inferiores ao RF, com MAE de 9,71 (+8,61%) e RMSE de 16,57 (+5,54%).

Os modelos Ridge e KNN apresentaram desempenhos inferiores, com Ridge sendo o mais rápido (0,04 segundos, -99,91%) e KNN mostrando baixa eficiência (MAE de 11,27, +26,06%; WMAPE de 0,34, +25,93%). O modelo de base SeasonalNaive, obteve resultados muito inferiores: MAE de 18,26 (+104,25%) e WMAPE de 0,55. Comparado a ele, o RF reduziu o MAE em 51,48% e o WMAPE em 50,91% .

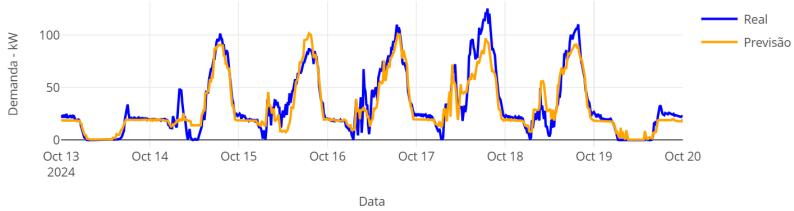
**Análise qualitativa** A Figura 5 ilustra a previsão do RF para o dia 02/10/2024 (quarta-feira). Neste gráfico, observa-se que o modelo acompanha com precisão os dados reais, ajustando-se bem aos horários de pico – especialmente entre 16 e 21 horas – quando a demanda atinge seu ápice durante os dias úteis. A Figura 6 apresenta a previsão para o dia 06/10/2024, um domingo. Apesar de ser um fim de semana, onde geralmente não há atividades na instituição, o modelo demonstra um excelente ajuste aos dados reais, evidenciando sua adaptabilidade mesmo em cenários de menor atividade. Por fim, a Figura 7 expõe a previsão do RF para uma semana completa. Este gráfico comprova a robustez do modelo ao lidar com a diversidade dos dias da semana, contemplando tanto dias úteis quanto fins de semana. Apesar de apresentar certa intermitência em alguns horários – possivelmente devido à influência da usina fotovoltaica – o RF mantém um desempenho consistente, reforçando sua adequação para previsões de curto prazo.



**Figura 5. Previsão RF para o dia 02/10/2024 - Quarta**



**Figura 6. Previsão RF para o dia 06/10/2024 - Domingo**



**Figura 7. Previsão RF para uma semana**

### 3. Conclusão

Este estudo comparou o desempenho de modelos de aprendizado de máquina na previsão de demanda energética de curto prazo em uma instituição de ensino, revelando *insights* relevantes para aplicações práticas. O modelo RF destacou-se como o mais preciso, com um MAE de 8,94 (51% inferior ao modelo de base) e um R<sup>2</sup> de 0,76, indicando boa

capacidade de explicação da variabilidade dos dados. Seu WMAPE de 0,27, o menor entre os modelos testados, reforça sua eficiência preditiva. No entanto, o tempo de execução elevado (44,38 segundos) limita sua aplicação em cenários que exigem resposta imediata, embora seja viável para previsões diárias ou semanais, onde a latência não compromete a operação.

O XGB, por outro lado, apresentou desempenho 49% superior ao modelo de base em precisão, aliado a um tempo de treinamento 16 vezes menor que o RF, configurando-se como uma alternativa equilibrada entre eficiência e rapidez. Modelos como LGBM e CatBoost também demonstraram agilidade, enquanto MLP mostrou-se adequado para contextos em que o tempo de execução não é crítico, mas robustez é necessária. Em contrapartida, Ridge e KNN revelaram-se menos competitivos em cenários que demandam alta precisão.

A seleção do modelo ideal, portanto, deve considerar o equilíbrio entre precisão, velocidade e requisitos operacionais. Para ambientes com integração de renováveis (como energia solar), onde flutuações na demanda são comuns, modelos precisos como o RF são preferíveis. Já em sistemas que exigem atualizações frequentes e rápidas, o XGB ou LGBM podem ser mais adequados.

Pesquisas futuras podem avançar na exploração de modelos híbridos, técnicas de aprendizado profundo e a incorporação de variáveis externas (ex.: condições climáticas) para refinamento das previsões. Além disso, métodos de explicabilidade podem aumentar a transparência dos modelos, facilitando sua adoção em setores regulados. Este trabalho contribui como referência para gestores e pesquisadores, oferecendo um guia estruturado para a otimização da previsão de demanda energética.

## Agradecimentos

Os autores agradecem a FAPES/UnAC (Nº FAPES 1228/2022 P 2022-CD0RQ, Nº SI-AFEM 2022-CD0RQ) pelo apoio financeiro dado por meio do Sistema UniversidaES, o Laboratório Espaço Energia do IFES Serra pela coleta dos dados meteorológicos e de demanda. Este trabalho também foi apoiado pelo projeto FAPES 850/2023 - P:2023-DLP0J.

## Referências

- Akiba, T., Sano, S., Yanase, T., Ohta, T., and Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, pages 2623–2631.
- Anh, N. T. N., Anh, N. N., Thang, T. N., Solanki, V. K., Crespo, R. G., and Dat, N. Q. (2024). Online sarima applied for short-term electricity load forecasting. *Applied Intelligence*, 54:1003–1019.
- Dash, S. K., Roccotelli, M., Khansama, R. R., Fanti, M. P., and Mangini, A. M. (2021). Long term household electricity demand forecasting based on rnn-gbrt model and a novel energy theft detection method. *Applied Sciences*.
- Dong, X., Deng, S., and Wang, D. (2022). A short-term power load forecasting method based on k-means and svm. *Ambient Intelligence and Humanized Computing*, 13:5253–5267.

- e Silva, D. P., Félix Salles, J. L., Fardin, J. F., and Rocha Pereira, M. M. (2020). Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data. *Applied Energy*, 278:115581.
- Guaitolini, T. M., Nascimento, E. B., Breder, R. P., Gobbi, R. E., e Silva, D. P., Silva, F. B. B., and Camargo, R. S. (2023). Load curve based on modeling a photovoltaic system, load and weather data - a case study in brazil. In *2023 15th IEEE International Conference on Industry Applications (INDUSCON)*, pages 248–253. IEEE.
- Guo, W., Che, L., Shahidehpour, M., and Wan, X. (2021). Machine-learning based methods in short-term load forecasting. *The Electricity Journal*, 34:106884.
- Hafeez, G., Alimgeer, K. S., and Khan, I. (2020). Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid. *Applied Energy*, 269:114915.
- Hodge, B.-M., Lew, D., and Milligan, M. (2013). Short-term load forecast error distributions and implications for renewable integration studies. In *IEEE Green Technologies Conference*.
- Hwang, J., Kim, J.-S., and Song, H. (2022). Handling load uncertainty during on-peak time via dual ess and lstm with load data augmentation. *Energies*, 15(9):3001.
- Jin, X.-B., Zheng, W.-Z., Kong, J.-L., Wang, X.-Y., Bai, Y.-T., Su, T.-L., and Lin, S. (2021). Deep-learning forecasting method for electric power load via attention-based encoder-decoder with bayesian optimization. *Energies*, 14(6):1596.
- Jin, Y., Guo, H., Wang, J., and Song, A. (2020). A hybrid system based on lstm for short-term power load forecasting. *Energies*, 13(23):6241.
- Koukaras, P., Mustapha, A., Mystakidis, A., and Tjortjis, C. (2024). Optimizing building short-term load forecasting: A comparative analysis of machine learning models. *Energies*, 17(6).
- Kumari, P. and Toshniwal, D. (2021). Deep learning models for solar irradiance forecasting: A comprehensive review. *Journal of Cleaner Production*, 318:128566.
- Mohammad, F., Lee, K.-B., and Kim, Y.-C. (2018). Short term load forecasting using deep neural networks. *Energies*.
- Mori, H. and Ogasawara, T. (1993). A recurrent neural network for short-term load forecasting. *IEEE Transactions on Power Systems*.
- Saksornchai, T., Lee, W.-J., Methaprayoon, K., Liao, J. R., and Ross, R. J. (2005). Improve the unit commitment scheduling by using the neural-network-based short-term load forecasting. *IEEE Transactions on Industry Applications*, 41(1):169–179.
- Sousa, A. R. S., da Silva, C., da Silva, J. S. F., and Oliveira, R. R. (2021). *Análise de séries temporais*. SAGAH, Porto Alegre.
- Tziolis, G., Koumis, A., Makrides, G., Lopez-Lorente, J., Livera, A., Georghiou, G. E., Baka, M.-I., and Theocharides, S. (2022). Comparative analysis of machine learning models for short-term net load forecasting in renewable integrated microgrids. In *Proceedings of the International Conference on Energy Transmission in the Mediterranean Area (SyNERGY MED)*.