

PREVISÃO DA DEMANDA DE ENERGIA ELÉTRICA EM UM CAMPUS UNIVERSITÁRIO DA UFMG: UM ESTUDO ABORDANDO REDES NEURAIS RECORRENTES

PREDICTING ELECTRIC POWER DEMAND ON A UFMG UNIVERSITY CAMPUS:
A STUDY USING RECURRENT NEURAL NETWORKS

PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN UN CAMPUS
UNIVERSITARIO DE LA UFMG: UN ESTUDIO MEDIANTE REDES
NEURONALES RECURRENTES

Huggo Rhodrigo Soares Marinho¹

Aderson Rogério Soares Silva²

Islas Batista Guedes³

José Maria Monção Júnior⁴

Marcos de Paulo Ramos⁵

Sócrates Dumont Sobrinho⁶

Suzana Campos do Vale⁷

Renato Dourado Maia⁸

RESUMO: A previsão energética é uma ferramenta amplamente utilizada para gestão e planejamento energético, especialmente diante de cenários de crescimento do consumo e das tarifas de energia no Brasil. O trabalho, em sua essência, teve como objetivo realizar a previsão de demanda da energia elétrica um campus universitário da UFMG, juntamente, buscou-se avaliar o desempenho das três principais arquiteturas de redes neurais recorrentes - RNN Clássica, LSTM e GRU. Foi utilizada uma série temporal com granularidade diária de 48 meses, fornecida pela CEMIG. Os modelos foram implementados em Python e o desempenho foi avaliado pelas métricas MAPE, MAE e RMSE. Os modelos de redes neurais recorrentes propostos apresentaram resultados similares na previsão diária da demanda de energia, com destaque para a GRU, que apresentou um MAPE de 10,51%. Na análise mensal da demanda, a GRU foi ligeiramente superior, apresentando um MAPE de 5,44%, demonstrando maior precisão na identificação dos picos mensais de demanda. Neste conjunto de dados, série temporal de curto período, arquiteturas mais simples demonstraram-se competitivas nas previsões, com a GRU mostrando-se ligeiramente superior.

Palavras-chave: Previsão de demanda de energia. Séries Temporais. Redes Neurais Recorrentes. Long Short-Term Memory (LSTM). Gated Recurrent Unit (GRU).

¹ Mestrando em Modelagem Computacional, UNIMONTES.

² Mestre em Produção Vegetal no Semi-Árido - UNIMONTES.

³ Especialista em Gestão Pública - FAEL.

⁴ Especialista em Engenharia e Segurança do Trabalho - FIP-MOC.

⁵ Professor no CEFET/MG. Doutor em Análise e Modelagem de Sistemas Ambientais - UFMG.

⁶ Especialista em Administração Pública - FACSM.

⁷ Especialista em Direito (Criminologia) - FAVENI.

⁸ Professor na UNIMONTES. Doutor em Engenharia Elétrica - UFMG.

ABSTRACT: Energy forecasting is a widely used tool for energy management and planning, particularly given the scenarios of rising consumption and energy tariffs in Brazil. Fundamentally, this study aimed to forecast the electric energy demand of a UFMG university campus while evaluating the performance of three main recurrent neural network architectures: Classic RNN, LSTM, and GRU. A time series with daily granularity spanning 48 months was used, supplied by CEMIG. The models were implemented in Python, and performance was assessed using MAPE, MAE, and RMSE metrics. The proposed recurrent neural network models yielded similar results for daily energy demand forecasting; the GRU model stood out, achieving a MAPE of 10.51%. In the monthly demand analysis, the GRU model performed slightly better, with a MAPE of 5.44%, demonstrating greater accuracy in identifying monthly demand peaks. For this dataset—a time series spanning a relatively short period—simpler architectures proved competitive, with the GRU model showing slightly superior performance.

Keywords: Energy demand forecasting. Time series. Recurrent neural networks. Long Short-Term Memory (LSTM). Gated Recurrent Unit (GRU).

RESUMEN: La previsión energética es una herramienta ampliamente utilizada para la gestión y planificación energética, especialmente ante escenarios de aumento del consumo y las tarifas energéticas en Brasil. Este trabajo tuvo como objetivo principal predecir la demanda de electricidad de un campus universitario de la UFMG y evaluar el rendimiento de tres arquitecturas principales de redes neuronales recurrentes: RNN clásica, LSTM y GRU. Se utilizó una serie temporal con una granularidad diaria de 48 meses, proporcionada por CEMIG. Los modelos se implementaron en Python y el rendimiento se evaluó mediante las métricas MAPE, MAE y RMSE. Los modelos de redes neuronales recurrentes propuestos mostraron resultados similares en la previsión de la demanda energética diaria, destacando GRU con un MAPE del 10,51 %. En el análisis de la demanda mensual, GRU fue ligeramente superior, presentando un MAPE del 5,44 %, demostrando mayor precisión en la identificación de picos de demanda mensuales. En este conjunto de datos, una serie temporal de corto alcance, las arquitecturas más simples demostraron ser competitivas en la previsión, con GRU mostrando una ligera ventaja.

Palabras clave: Previsión de la demanda energética. Series temporales. Redes neuronales recurrentes. Long Short-Term Memory (LSTM). Gated Recurrent Unit (GRU).

1. INTRODUÇÃO

A energia elétrica tornou-se uma fonte de energia essencial nas sociedades modernas, impactando áreas como: desenvolvimento tecnológico, indústria e bem-estar social. Segundo a Agência Internacional de Energia (IEA), a demanda mundial por eletricidade deve crescer nos próximos 5 anos a uma taxa média de 3,6% ao ano, impulsionada pelo aumento de data centers, expansão da indústria e aumento dos veículos elétricos (IEA, 2026). A eletricidade ocupa a segunda posição em consumo de energia no Brasil, ficando atrás apenas do petróleo e seus derivados (Abrahão e Souza, 2021). De acordo com a Empresa de Pesquisa Energética (EPE), o

consumo de energia elétrica no Brasil cresceu 2,7% em 2025 quando comparado ao ano anterior (EPE, 2026).

Não apenas o crescimento do consumo de energia elétrica merece destaque, mas também o crescimento dos valores da tarifa de energia elétrica. Segundo dados da Associação Brasileira dos Comerciantes de Energia (ABRACEEL), a tarifa de energia elétrica cresceu 177%, entre os anos de 2010 e 2024, superando em 45% o índice oficial da inflação neste mesmo período, que foi de 122% (ABRACEEL, 2025). Dessa forma, buscar entender o comportamento e os padrões de consumo de energia elétrica tornou-se essencial, possibilitando melhorias na gestão e no planejamento do uso desse recurso (Gonçalves, 2025).

A previsão energética é uma importante ferramenta utilizada com frequência atualmente na busca por gestão e planejamento energético de maneira eficaz (Wang et al., 2018), para melhorar a eficiência energética (Chou e Tran, 2018), auxiliando na implementação de pesquisas de mercado (Wang et al., 2020), para determinar o estado operacional ideal dos sistemas (Divina et al., 2018), que permite observar tendências e sazonalidades nos dados observados (Amaral et al., 2022). Este tipo de previsão busca identificar padrões em séries temporais (dados históricos) e, a partir disso, projetar tendências e comportamentos futuros, analisando fatores e variáveis que possam interferir no seu comportamento (Gonçalves, 2025).

3

Diversos métodos e algoritmos são utilizados para previsões, com destaque para as abordagens baseadas em métodos convencionais/estatísticos e em aprendizado de máquina. Os métodos estatísticos mais utilizados neste tipo de estudo são os modelos autorregressivos, com destaque para os modelos Auto-Regressivo Integrado de Média Móvel (ARIMA) (Siarni-Namini et al., 2018), Média Móvel Autorregressiva (ARMA) (Amalou et al., 2022) e Auto-Regressivo Integrado de Média Móvel com Sazonalidade (SARIMA) (Galdelli et al., 2025). Devido a crescente onda da Inteligência Artificial (IA), os modelos baseados em aprendizado de máquina têm se popularizado, ganhado destaque e apresentado bons resultados em previsões de séries temporais, principalmente as - Redes Neurais Artificiais (RNA) (Campos e Figueiredo, 2021). Parte disso se deve ao fato dessas redes possuírem a capacidade de aprendizado para mapeamentos de características não lineares (Wang et al., 2020) e a capacidade de lidar com ruídos (Zeng et al., 2017).

Imerso na seara das RNA, as Redes Neurais Recorrentes (RNN) têm sido amplamente utilizadas na modelagem de dados sequenciais, por exemplo, em problemas de previsões de

séries temporais (Khalidi et al., 2023). No caso das previsões energéticas, que incluem previsão de demanda de energia elétrica e previsão de consumo de energia elétrica, existem diversos estudos utilizando RNN. Por exemplo, Aseeri (2023) utiliza uma *Gated Recurrent Unit* (GRU) na previsão da demanda de energia elétrica para o dia seguinte, Amalou et al. (2022) avaliaram qual arquitetura de RNN (RNN clássica, *Long Short Term Memory* (LSTM) e GRU) foi mais eficaz na previsão de consumo de energia, Wang et al. (2020) utilizam uma rede LSTM para prever o consumo periódico de energia em um sistema de refrigeração, Faiq et al. (2023) utilizaram uma rede LSTM para prever o consumo de energia de um edifício institucional, já Hajjaji et al. (2026) utilizaram uma RNN híbrida (LSTM-RNN) para classificar e prever o consumo de energia elétrica em uma microrrede universitária.

Neste contexto, a aplicação de técnicas de previsão de consumo energético em contextos locais, como em campus universitários, torna-se relevante para a tomada de decisões tanto em aspectos econômicos, quanto em aspectos de planejamento energético. Pois, estes tipos de consumidores possuem características de utilização de energia elétrica bem peculiares. Por conseguinte, uma boa previsão da demanda e do consumo de energia pode contribuir para a melhoria dos contratos com fornecedores de energia elétrica no mercado livre de energia, pode amparar a gestão energética, como na eficiência energética, e também pode auxiliar no planejamento energético, por exemplo, amparando tecnicamente projetos de usinas fotovoltaicas.

Dessa forma, na busca de encontrar uma ferramenta que se adapte bem aos dados estudados, uma série temporal com granularidade diária e de curto período (48 meses), e proporcione uma previsão confiável, este estudo buscou analisar o desempenho das redes neurais recorrentes na previsão da demanda de energia elétrica de um campus universitário da Universidade Federal de Minas Gerais (UFMG). As RNN utilizadas foram: a RNN Clássica, a LSTM e a GRU. Além de um objeto geral, o estudo também buscou discutir alguns aspectos específicos, como: se a utilização de uma RNN mais complexa, isto é, uma rede LSTM ou GRU, melhoraria os resultados da previsão; também abordou a previsão da demanda em um aspecto mensal, analisando se a previsão dos picos dessa variável se assemelhou aos dados reais.

2. METODOLOGIA

A metodologia adotada foi resumida na Figura 1 e descreve as etapas e os procedimentos adotados tanto para realizar a previsão da demanda de energia elétrica, quanto para verificar o desempenho dessa previsão.

Figura 1 – Metodologia.



Fonte: autores, 2026.

2.1. Aquisição dos dados históricos

A pesquisa utiliza dados reais de consumo/demanda de energia elétrica. Os dados são provenientes dos dados históricos das medições realizadas pela Companhia Energética de Minas Gerais (CEMIG) no Instituto de Ciências Agrárias (ICA) da UFMG em Montes Claros/MG. Eles são dispostos diariamente e o intervalo de tempo utilizado para análise foi de 48 meses (janeiro/2022 a dezembro/2025). A variável utilizada nas análises, demanda, é medida em quilowatt (kW) e pode ser entendida como a quantidade de potência que um sistema necessita para atender as cargas elétricas ligadas em um determinado instante.

2.2. Tratamento dos dados

2.2.1. Imputação dos dados ausentes

Os dados da Demanda fornecidos pela CEMIG vieram com algumas lacunas (nulos). Visando aumentar a acurácia do modelo final preencheu-se as lacunas destes dados. O processo

de imputação de dados ausentes em um conjunto de dados é necessário para evitar a remoção de informações que serão importantes no processo de análise das informações da série temporal.

O processo de imputação ou inferência dos dados faltantes da série temporal estudada foi realizado a partir de um algoritmo de imputação de séries temporais univariadas do pacote *imputeTS* da linguagem R, que pode ser encontrado no CRAN. O algoritmo de imputação utilizado foi a Suavização de *Kalman* em modelos ARIMA (Moutinho, 2023).

2.2.2. Normalização dos dados

Para estudos com redes neurais, normalizar os dados é essencial, principalmente se esses apresentarem grandes amplitudes. A função de normalização escolhida foi a Min-Max. A amplitude escolhida foi de 0 a 1, onde o valor mínimo do conjunto torna-se 0 e o valor máximo é 1.

2.3. Previsão da série temporal com rnn

2.3.1. Dados de entrada

Embora a demanda seja medida e precificada mensalmente no contexto real de uma unidade consumidora, optou-se pela modelagem diária devido ao reduzido número de observações mensais disponíveis. Se a modelagem fosse realizada mensalmente, o conjunto de dados teria apenas 48 observações, um volume estatisticamente insuficiente para o treinamento de uma rede neural, o que provavelmente causaria subajuste (*underfitting*). A granularidade diária amplia significativamente a quantidade de amostras para treinamento dos modelos, permitindo capturar padrões temporais mais ricos.

2.3.2. Variáveis de entrada

Na entrada do modelo foram utilizadas além da variável de interesse (demanda), também variáveis exógenas, como: ano, mês, dia da semana, dia do ano e semana do ano.

2.3.3. Hiperparâmetros

A escolha da arquitetura final da rede neural foi baseada em experimentação empírica sistemática e na seleção do conjunto paramétrico que minimizou de forma consistente o MAPE no conjunto de validação. Foram testadas variações, como: número de camadas ocultas (1, 2 e 3),

número de neurônios por camada (50, 70 e 100), função de ativação (*tanh* e *ReLU*), taxa de aprendizagem (0,01 e 0,001), função de perda (MSE e MAE) e *batch size* (32, 64, 98). O número de épocas variou no processamento de cada rede neural. Determinou-se o número máximo de interações como 1000, porém, foram utilizadas técnicas para melhoria do treinamento, como: *dropout*, *early stopping* e *checkpoint*.

2.4. Avaliação do desempenho da previsão

Conforme (Gonçalves, 2025), a capacidade preditiva do modelo pode ser avaliada comparando valores previstos e observados. Dessa forma, o desempenho do modelo será avaliado buscando valores menores para as métricas MAPE, MAE e RMSE.

2.5. Ferramentas e recursos

Na etapa de processamento dos dados, foi utilizado o *software R*, especificamente no tratamento dos dados faltantes. A ferramenta computacional escolhida para a implementação do modelo da rede neural foi o *software Python* versão 3.12.3. As bibliotecas utilizadas foram: a *TensorFlow* e a *Keras* para implementar e treinar a rede neural, a *Scikit-learn* e a *Pandas* para processamento e manipulação dos dados.


3. RESULTADOS E DISCURSÃO

3.1. Pré-processamento dos dados

Os dados foram divididos entre treino (75%) e teste (25%). Os dados de treino compreendem o intervalo de 01/01/2022 a 31/12/2024, 36 meses, e os de teste de 01/01/2025 a 31/12/2025, 12 meses. Essa divisão pode ser observada na Figura 2.

Outro procedimento necessário na preparação dos dados para implementar as redes neurais recorrentes é definir a janela deslizante/deslocável. Essa janela define quantos dias anteriores serão utilizados na predição. Após testes com janelas de 7, 14 e 28 dias, a janela de 14 dias apresentou bons resultados nas simulações, ou seja, 14 dias para prever o próximo dia. Como a periodicidade das medições é semanal, testaram-se janelas com múltiplos de 7.

Figura 2 – Demanda de energia ICA/UFMG.



Fonte: autores, 2026.

3.2. Modelagem e treinamento da rede neural

A RN foi implementada em *Python* utilizando a API *TensorFlow*, por meio do modelo *Sequential()*. Entre as camadas ocultas, utilizou-se a técnica de regularização *Dropout*, esta técnica exclui aleatoriamente os neurônios no processo de treinamento, reduzindo o sobreajuste (*overfitting*) e aumentando a capacidade de generalização do modelo. A função de ativação padrão de uma RNN é a *tanh*, entretanto, após testes, a *ReLU* demonstrou melhores resultados. A função de perda (*loss*) foi determinada após variações entre as funções MAE e a MSE. Os modelos das redes neurais foram treinados de acordo com os hiperparâmetros expostos na Tabela 1.

Posto isso, buscando otimizar o processo de treinamento e prevenir o sobreajuste, utilizou-se a técnica de regularização *Early Stopping*, na qual o treinamento é interrompido a partir do momento em que não há mais melhorias na métrica de desempenho do modelo no conjunto de dados de validação, com o parâmetro paciência (*patience*) configurado em 100 épocas. Outra técnica utilizada com a finalidade de otimização do treinamento foi o checkpoint, em que os parâmetros aprendidos, pesos e vieses, no treinamento são salvos, permitindo, posteriormente, carregar os parâmetros que apresentem o melhor resultado. Deste modo, essas técnicas buscam identificar o momento em que o modelo otimiza a capacidade de generalização,

impedindo que o treinamento continue sem necessidade e que o modelo se especialize nos dados de treino, prejudicando o desempenho nas previsões dos dados não vistos.

Tabela 1 – Hiperparâmetros utilizados.

Hiperparâmetros	Demanda		
	RNN Clássica	LSTM	GRU
Camadas ocultas	2	2	2
Neurônios/Camada	70	70	70
Loss	MAE	MAE	MAE
Batch Size	98	98	98
Épocas	1000	1000	1000
Otimizador	ADAM	ADAM	ADAM
Learning rate	0,001	0,001	0,001
Janela deslizante	14	14	14
Função de ativação	ReLu	ReLu	ReLu

Fonte: autores, 2026.

3.3. Resultados do treinamento e validação

A Tabela 2 apresenta o desempenho das redes neurais treinadas. Neste caso específico, em que a série estudada é relativamente curta no quesito temporal, a rede neural GRU apresenta melhor performance, com um MAPE de 10,51%, frente as redes RNN Clássica e LSTM, entretanto, a margem percentual de diferença é relativamente pequena. Esse comportamento também pode ser observado nas análises do MAE e RMSE em que a diferença ficou na casa de 1 kW, aproximadamente.

Outro fato observado foi o desempenho da RNN Clássica ser melhor que a RNN LSTM. As RNN Clássica são boas em capturar dependências temporais de curto prazo, sendo inadequadas para padrões que se estendem por muitos intervalos de tempo. Por outro lado, as redes LSTM foram desenvolvidas para modelagem de dependências de longo prazo. Por conseguinte, temos que a RNN Clássica, que possui menor complexidade estrutural e menos parâmetros, demonstrou boa capacidade de generalização para este volume específico de dados.

Tabela 2 – Desempenho das redes neurais – Demanda Diária.

	RNN Clássica	LSTM	GRU
MAPE (%)	10,64	10,89	10,51
MAE (kW)	16,37	16,60	15,76
RMSE (kW)	23,63	24,78	23,95
Épocas	196	561	512

Fonte: autores, 2026.

3.4. Análise da demanda mensal

As redes neurais projetadas comparam dados diários das séries temporais. Portanto, as métricas de desempenho também são calculadas nessa mesma lógica, fornecendo amparo para a avaliação das previsões dos resultados diários dessas variáveis. Entretanto, a demanda de energia elétrica mensal mensura a demanda máxima que o estabelecimento registrou no mês mensurado.

Dessa forma, visando chegar aos valores mensais a partir dos valores diários preditos, a demanda foi analisada e agregada em bases mensais. A demanda alvo é a demanda máxima mensal, a qual é identificada isolando o maior valor diário do mês avaliado e determinando esse valor como referência para o mês de análise. O resultado dessa análise foi exposto na Tabela 3.

10

Tabela 3 – Predição – Demanda Mensal.

	Demanda Real	Demanda RNN	Demanda LSTM	Demanda GRU
Fevereiro, 2025	212	217	207	212
Março, 2025	287	263	262	273
Abril, 2026	255	232	232	247
Mai, 2025	213	233	225	232
Junho, 2025	193	189	184	195
Julho, 2025	160	182	160	170
Agosto, 2025	199	195	188	200
Setembro, 2025	254	234	239	239
Outubro, 2025	286	254	269	261
Novembro, 2025	284	260	261	264
Dezembro, 2025	224	187	187	194

Fonte: autores, 2026.

A análise de desempenho das previsões mensais foi refeita, resultando nos valores da Tabela 4. Observa-se, em geral, uma redução considerável do MAPE, identificando uma semelhança mais ajustada aos dados reais. O MAPE reduziu por volta de 50%, ficando na casa dos 5,44% para previsão realizada pela rede GRU. A rede GRU também apresentou valores mais baixos para as métricas MAE e RMSE, demonstrando um desempenho superior frente as outras RNN.

Tabela 4 – Desempenho das redes neurais – Demanda Mensal.


	RNN Clássica	LSTM	GRU
MAPE (%)	7,95	6,62	5,44
MAE (kW)	18,82	16,19	13,09
RMSE (kW)	21,08	18,99	16,17

Fonte: autores, 2026.

Nesta lógica, a rede neural conseguiu alcançar bem seu objetivo, isso fica evidenciado na Figura 3, em que o gráfico em laranja, dados da predição, consegue chegar próximos dos picos do gráfico em azul, dados reais. A Figura 4 representa o gráfico da demanda mensal, após a seleção dos valores de picos mensais. Fica nítido que as previsões seguem o mesmo perfil dos dados originais, evidenciando uma previsão bem ajustada aos dados reais.


11

Figura 3 – Predição RNN GRU – Demanda Diária.



Fonte: autores, 2026.

Figura 4 – Predição RNN GRU – Demanda Mensal



Fonte: autores, 2026.

4. CONCLUSÃO

A previsão de demanda de energia se tornou uma importante ferramenta tanto na gestão, quanto no planejamento energético dos grandes estabelecimentos, como as universidades. Ela cumpre um papel fundamental apoiando projetos de eficiência energética; na redução de custos com energia elétrica; no apoio administrativo, como na melhoria de contratos de compra de energia elétrica; entre outros, como o planejamento energético de um país.

Os resultados indicaram que uma rede neural mais simples, como a RNN Clássica, apresentou desempenho muito próximos aos das arquiteturas mais complexas, como a LSTM e a GRU. Outro ponto interessante, foi que a rede LSTM não desempenhou melhor que a rede RNN Clássica, apresentando métricas de avaliação ligeiramente menores, isso pode ser atribuído a série temporal utilizada no estudo que é relativamente curta, o que pode favorecer modelos menos complexos e com menos parâmetros. Outro ponto de destaque foi o desempenho da rede GRU. Ela despontou-se como a de rede neural de melhor desempenho frente aos dados, principalmente na análise da demanda mensal. A rede além de realizar um bom mapeamento dos picos e vales na previsão diária, mapeando com êxito as características da série temporal da demanda, também identificou os picos da demanda mensal com excelência.

As redes neurais utilizadas no estudo conseguiram capturar o padrão e projetar bem a demanda futura, apresentando resultados semelhantes. Isso nos leva a inferir que diante do

cenário apresentado, séries temporais relativamente curtas, a utilização de arquiteturas mais complexas de redes neurais recorrentes, como a LSTM, não seria um diferencial na previsão.

Como limitações do estudo, podemos citar a extensão curta da série temporal (48 meses), comparação com outras séries temporais de demanda de tamanho semelhante e a ausência de algumas variáveis importantes como: temperatura e ocupação do campus universitário. Além disso, em trabalhos futuros, sugere-se testes com séries temporais de outras unidades consumidoras que possuem séries temporais curtas, avaliação de outras arquiteturas de redes neurais como a MLP, incorporação de outras variáveis exógenas, de modo a verificar a generalização dos resultados obtidos.

REFERÊNCIAS

ABRACEEL. Tarifa de energia elétrica sobe 45% acima da inflação em 15 anos. 2025. Disponível em: <https://abraceel.com.br/press-releases/2025/06/tarifa-de-energia-eletrica-sobe-45-acima-da-inflacao-em-15-anos/>. Acesso em: 8 ago. 2026.

Abrahão, K. C. D. F. J.; Souza, R. G. V. D. Estimativa da evolução do uso final de energia elétrica no setor residencial do Brasil por região geográfica. *Ambiente Construído*, 2021; 21(2): 383-408.

Amalou, I., et al. Multivariate time series prediction by rnn architectures for energy consumption forecasting. *Energy Reports*, 2022; 8:1084-1091. *Technologies and Materials for Renewable Energy, Environment and Sustainability*.

Amaral, L. S., et al. Análise dos fatores que influenciam o desempenho de um modelo de previsão de demanda de energia, 2022; 2:92-102. *Pro-Metrics*.

Aseeri, A. O. Effective rnn-based forecasting methodology design for improving short-term power load forecasts: Application to large-scale power-grid time series. *Journal of Computational Science*, 2023; 68.

Campos, L. M. L. e Figueiredo, Y. F. C. Avaliação de redes neurais profundas para a previsão de preço das ações da Petrobrás. *Revista Gestão Tecnologia*, 2021; 21(3): 27-51.

Chou, J.-S. e Tran, D.-S. Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. *Energy*, 2018; 165: 709-726.

Divina, F., et al. Stacking ensemble learning for short-term electricity consumption forecasting. *Energies*, 2018; 11(4).

EPE. (2026). Balanço Energético Nacional. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-975/topico-850/BEN2026.pdf>. Acesso em: 08 ago. 2026.

Faiq, M., et al. Prediction of energy consumption in campus buildings using long short-term memory. *Alexandria Engineering Journal*, 2023; 67: 65-76.

Galdelli, A., et al. Groundwater level forecasting using data-driven models and vadose zone: A comparative analysis of arima, sarimax, prophet, and neuralprophet. *Applied Computing and Geosciences*, 2025; 28.

Gonçalves, I. G. Previsão do consumo de energia elétrica na região sudeste: aplicação de modelos arima e lstm. *Revista Brasileira de Estudos Regionais e Urbanos*, 2025; 19(3): 310-340.

Hajjaji, I., et al. Ai-driven energy optimization in university microgrid: A hybrid lstm-rnn forecasting consumption patterns approach. *Energy Reports*, 2026; 15.

IEA. 2026. Electricity 2026. Disponível em: <https://www.iea.org/reports/electricity-2026>. Acesso em: 08 ago. 2026.

Khalidi, R., et al. What is the best rnn-cell structure to forecast each time series behavior?. *Expert Systems with Applications*, 2023; 215.

Moutinho, L. C. 2023. Imputação em séries temporais. Disponível em: <https://rpubs.com/fjp/imputts>. Acesso em: 20 abr. 2026.

Siami-Namini, S., et al. A comparison of arima and lstm in forecasting time series. In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), 2018; 1394-1401. Orlando, FL. IEEE.

Wang, J., et al. An improved grey model optimized by multiobjective ant lion optimization algorithm for annual electricity consumption forecasting. *Applied Soft Computing*, 2018; 72: 321-337.

Wang, J. Q., et al. Lstm based long-term energy consumption prediction with periodicity. *Energy*, 2020; 197.

Zeng, Y.-R., et al. Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network. *Energy*, 2017; 127: 381-396.