

Previsão de carga elétrica de curto prazo considerando métodos estatísticos tradicionais e de aprendizado profundo

Gabriel Alberto Groehs
Applied Artificial Intelligence Laboratory
Vale do Itajaí University - UNIVALI
São José, Santa Catarina, Brasil
bw.gabrielgroehs@gmail.com

Raimundo C. G. Teive
Applied Artificial Intelligence Laboratory
Vale do Itajaí University - UNIVALI
São José, Santa Catarina, Brasil
rteive@univali.br

ABSTRACT

This work presents a comparative study between SARIMAX and LSTM models for short-term forecasting of intraday industrial electricity consumption using real hourly data from a Brazilian distribution utility. The methodology integrates typological segmentation through K-Means clustering, feature engineering with multi-scale lag structures, and enrichment with macroeconomic exogenous variables obtained from the Brazilian Central Bank (SELIC and exchange rate). The preprocessing pipeline includes STL decomposition, cross-correlation analysis for optimal lag selection, stability-based test-window identification using rolling volatility, and statistical stationarity testing. Experimental results reveal that SARIMAX performs adequately only in typologies characterized by low intraday variance, while failing to capture nonlinear multi-peak consumption patterns. LSTM models consistently outperform SARIMAX across all typologies, particularly in high-volatility regimes, due to their ability to model long-term temporal dependencies and nonlinear dynamics. Exogenous variables, however, exhibit minimal or negative contributions to forecasting accuracy, primarily due to the frequency mismatch between hourly consumption data and monthly economic indicators. The findings provide evidence-based insights to support the design of resilient and sustainable energy forecasting infrastructures, aligning directly with the goals of ODS11 and reinforcing the role of advanced machine learning models in industrial energy management.

KEYWORDS

Time Series; SARIMAX; Long Short-Term Memory); K-Means Clustering; STL Decomposition; Short-Term Forecasting.

1 Introdução

A previsão eficiente do consumo industrial de energia elétrica é um componente essencial para o planejamento e a operação confiável, segura e sustentável dos sistemas de distribuição. Cargas industriais apresentam dinâmicas intradiárias complexas caracterizadas por múltiplas sazonalidades, picos abruptos, ciclos irregulares e elevado grau de não linearidade decorrente da diversidade dos processos produtivos. A melhoria dessa capacidade preditiva contribui diretamente para o Objetivo de Desenvolvimento

Sustentável ODS11, que incentiva o desenvolvimento de infraestrutura urbana resiliente e sustentável.

Modelos estatísticos clássicos tiveram papel central no desenvolvimento da análise de séries temporais desde a formulação da metodologia de Box e Jenkins em 1970 [1]. A estrutura ARIMA e suas extensões sazonais influenciaram amplamente o campo ao possibilitar modelagem paramétrica interpretável e sistemática. Entretanto, quando aplicados a séries de alta resolução temporal com forte volatilidade, irregularidades e múltiplos padrões sazonais, esses modelos apresentam limitações importantes. Isso ocorre principalmente porque dependem de hipóteses de linearidade e estacionaridade que raramente se sustentam no consumo industrial horário.

A evolução das Redes Neurais Recorrentes e do aprendizado profundo ampliou substancialmente a capacidade de modelagem de relações não lineares. A arquitetura Long Short-Term Memory, proposta por Hochreiter e Schmidhuber em 1997 [2], solucionou o problema da dissipação de gradientes e permitiu a captura de dependências de longo prazo com estabilidade. Avanços posteriores reforçaram a eficácia das LSTM em tarefas sequenciais complexas, como demonstrado por Sutskever et al. [3], Goodfellow, Bengio e Courville [4] e Haykin [5].

Além das dinâmicas intradiárias, o consumo industrial é influenciado por características setoriais e operacionais que variam entre consumidores. A identificação de grupos comportamentais homogêneos é fundamental para interpretar padrões específicos. O algoritmo K-Means, introduzido por MacQueen em 1967 [6], permanece um dos métodos mais utilizados na literatura devido à sua simplicidade computacional e capacidade de agrupamento eficaz em espaços normalizados. A segmentação por tipologias permite avaliar o desempenho preditivo de modelos em diferentes regimes de consumo.

O presente estudo realiza uma comparação detalhada entre o modelo SARIMAX, que é uma extensão dos modelos de Box e Jenkins com suporte a variáveis exógenas, e a rede neural recorrente LSTM aplicada a dados reais de consumo industrial horário provenientes de uma distribuidora brasileira de grande porte. A metodologia inclui segmentação tipológica via K-Means, decomposição STL, análise de correlação defasada, enriquecimento com variáveis macroeconômicas mensais obtidas no Banco Central do Brasil e seleção algorítmica de janelas de teste com base na volatilidade móvel.

Os resultados indicam que o modelo SARIMAX apresenta desempenho adequado apenas em tipologias de baixa volatilidade, enquanto apresenta limitações em cenários marcados por múltiplos picos ou mudanças abruptas de regime. Por outro lado, o modelo LSTM apresenta desempenho superior e consistente em todas as tipologias avaliadas, demonstrando maior capacidade de capturar padrões não lineares e estruturas temporais complexas. Observou-se ainda que variáveis exógenas mensais oferecem contribuição limitada ou negativa, o que sugere incompatibilidade entre a frequência desses indicadores e a granularidade horária do consumo industrial.

As evidências apresentadas fortalecem o uso de técnicas avançadas de aprendizado de máquina na construção de sistemas de previsão de demanda de energia elétrica mais robustos e apoiam iniciativas relacionadas ao ODS11 ao promover melhor planejamento e maior eficiência na gestão de redes industriais.

2 Estado da Arte de Previsão de Carga

A literatura recente sobre previsão de carga elétrica apresenta significativa expansão no uso de modelos estatísticos, híbridos e baseados em aprendizado profundo. A revisão sistemática conduzida, composta por 49 artigos publicados entre 2015 e 2024, revela um predomínio de modelos tradicionais aplicados a horizontes de curto prazo, com adoção crescente de arquiteturas neurais capazes de capturar dinâmicas não lineares e multiescalares [7], [8], [9]. Observou-se também que poucos estudos investigam especificamente séries industriais segmentadas por tipologias comportamentais, o que destaca a originalidade da abordagem adotada neste trabalho. Maiores detalhes deste mapeamento sistemático podem ser encontrados em [23]

Modelos estatísticos como ARIMA, SARIMA e suas variantes sazonais permanecem amplamente estudados devido à interpretabilidade e facilidade de ajuste [10], [11]. Trabalhos aplicados a séries residenciais, comerciais e agregadas reportam bom desempenho em ambientes onde a estrutura temporal é predominantemente linear ou apresenta sazonalidades regulares. No entanto, diversos estudos identificam limitações importantes desses modelos em séries com elevada volatilidade ou múltiplas sazonalidades, especialmente quando a carga apresenta comportamentos intradiários irregulares [12]. A literatura também indica que variáveis exógenas de baixa frequência como indicadores macroeconômicos nem sempre melhoram o desempenho preditivo e podem inclusive degradá-lo quando há descompasso entre a periodicidade da série alvo e a das regressoras [13].

Modelos baseados em Redes Neurais Recorrentes aparecem de forma recorrente na revisão, especialmente LSTM e GRU, destacadas pela capacidade de capturar relações não lineares e dependências temporais de longo prazo [7], [8], [14]. Estudos empíricos demonstram que LSTM tende a superar RNA clássica em estabilidade e acurácia, sobretudo em cenários caracterizados por múltiplos picos ou mudanças rápidas de regime. Diversos trabalhos reportam que modelos recorrentes apresentam

desempenho superior a técnicas estatísticas tradicionais quando aplicados a séries com forte variabilidade intradiária [9], [15].

Técnicas híbridas constituem parte relevante da literatura analisada. Combinações entre decomposições de sinais como Wavelet ou Empirical Mode Decomposition e modelos neurais como LSTM ou GRU são frequentemente utilizadas para separar componentes de tendência, ciclo e ruído, facilitando a modelagem [16], [17]. A revisão indica que essas abordagens geralmente aumentam a precisão, principalmente quando a série apresenta estrutura dinâmica complexa. Métodos de otimização como algoritmos genéticos e Particle Swarm Optimization também são comuns para ajuste de hiperparâmetros em modelos híbridos [18], [19].

Outra tendência observada é o uso crescente de modelos baseados em convolução temporal e mecanismos de atenção. Arquiteturas como Temporal Convolutional Networks e Transformers têm apresentado bom desempenho em séries com múltiplas escalas temporais e longas dependências [8], [20]. Além disso, estudos recentes envolvendo modelos N-BEATS e TimesNet sugerem que arquiteturas puramente neurais podem competir com métodos híbridos quando adequadamente configuradas [21].

Um aspecto importante identificado na revisão é que a maioria dos estudos não diferencia adequadamente os tipos de consumidores e frequentemente mistura séries residenciais, comerciais e industriais, o que dificulta análises específicas para o setor industrial. Apenas uma pequena fração dos artigos utiliza segmentação prévia baseada em padrões de consumo, e nenhum deles emprega tipologias industriais derivadas de algoritmos de clusterização não supervisionada como K-Means aplicado diretamente a séries horárias [14], [22]. Essa lacuna metodológica reforça a relevância da abordagem adotada neste estudo, que combina segmentação comportamental com avaliação independente de desempenho por tipologia.

A revisão também indica que variáveis exógenas mais utilizadas na literatura são meteorológicas, como temperatura e umidade, as quais têm maior impacto na previsão do consumo residencial e comercial [7], [12]. Em contraste, poucos trabalhos investigam o uso de indicadores macroeconômicos como taxa de juros ou câmbio, e aqueles que o fazem relatam impacto limitado, reforçando o problema da incompatibilidade temporal entre regressoras e série alvo [13].

De maneira geral, a revisão sistemática revela avanços significativos, porém aponta lacunas claras. Entre elas destacam-se a escassez de estudos dedicados especificamente ao setor industrial, a pouca exploração de segmentações comportamentais (CNAE) e a ausência de investigações que avaliem rigorosamente o impacto de exógenas macroeconômicas em séries industriais horárias. O presente trabalho contribui de forma direta para preencher essas lacunas ao combinar segmentação tipológica, análise de volatilidade e comparação formal entre SARIMAX e LSTM usando dados reais de consumo industrial em alta granularidade temporal.

3. Metodologia

A metodologia adotada integra cinco etapas principais: análise exploratória e pré-processamento, segmentação de tipologias via

Previsão de carga elétrica de curto prazo considerando métodos estatísticos tradicionais e de aprendizado profundo

São José, 01, janeiro, 2025, Santa Catarina, Brazil.

K-Means, incorporação de variáveis exógenas macroeconômicas, decomposição estrutural das séries e modelagem preditiva com SARIMAX e LSTM. Todo o pipeline foi aplicado separadamente para cada tipologia de consumo industrial, conforme recomendado em estudos recentes que destacam a heterogeneidade comportamental entre consumidores [7], [14].

3.1 Análise Exploratória e Pré-processamento

Os dados originais consistem em séries horárias de consumo industrial provenientes de múltiplas unidades consumidoras ao longo de um ano. A primeira etapa envolveu:

- Padronização de datas, horas e valores atípicos
 - Correção de duplicidades por média horária
 - Normalização intraempresa para eliminar viés de escala
 - Conversão da granularidade minuto para granularidade horária
- Para cada empresa foi criada uma curva média diária, permitindo identificar padrões intradiários predominantes. Esta etapa fundamentou a etapa seguinte de agrupamento não supervisionado. A Quadro 1 apresenta uma amostra da base após a consolidação horária.

| empresa | data | hora | potencia_kw |
|---|------------|------|-------------|
| AGS MECANICA E RENOVADORA DE PNEUS LTDA | 2011-01-01 | 0 | 0.321667 |
| AGS MECANICA E RENOVADORA DE PNEUS LTDA | 2011-01-01 | 1 | 0.331667 |
| AGS MECANICA E RENOVADORA DE PNEUS LTDA | 2011-01-01 | 2 | 0.321667 |
| AGS MECANICA E RENOVADORA DE PNEUS LTDA | 2011-01-01 | 3 | 0.325000 |
| AGS MECANICA E RENOVADORA DE PNEUS LTDA | 2011-01-01 | 4 | 0.320000 |
| ... | ... | ... | ... |
| USICAST INDUSTRIA E COMERCIO LTDA | 2011-12-31 | 19 | 0.910000 |
| USICAST INDUSTRIA E COMERCIO LTDA | 2011-12-31 | 20 | 1.067.500 |
| USICAST INDUSTRIA E COMERCIO LTDA | 2011-12-31 | 21 | 2.520.000 |
| USICAST INDUSTRIA E COMERCIO LTDA | 2011-12-31 | 22 | 4.987.500 |

Quadro 1. Amostra da base industrial após padronização e agregação horária.

3.2 Classificação de Tipologias via K-Means

A segmentação em seis tipologias foi realizada com base em curvas médias normalizadas de 24 pontos por empresa (uma média por hora). O K-Means foi escolhido por sua simplicidade e eficiência em padrões contínuos, conforme estabelecido por MacQueen (1967) [6].

Para garantir estabilidade do agrupamento:

- Os dados foram normalizados com MinMax
- A variabilidade intracluster foi analisada
- A silhueta média orientou K=6

Os seis perfis resultantes foram: Contínuo Alto, Pico Duplo, Pico Tarde/Noite, Comercial Estendido, Pico Manhã e Típico/Regular.

A Figura 1 mostra os seis perfis industriais obtidos pelo agrupamento K-means.

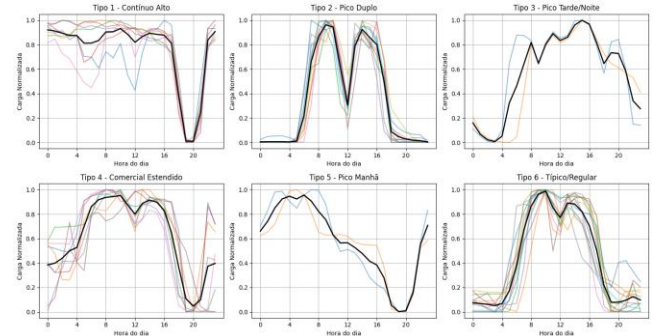


Figura 1. Tipologias industriais derivadas das curvas intradiárias normalizadas.

A Figura 1 evidencia que as seis tipologias apresentam padrões intradiários estruturalmente distintos, justificando a modelagem separada.

3.3 Enriquecimento com Variáveis Exógenas Macroeconômicas

Foram incorporadas séries mensais disponibilizadas pelo Banco Central do Brasil: IPCA, SELIC, câmbio, produção industrial e indicadores de crédito PF, PJ, livre e direcionado. Após alinhamento temporal e reamostragem por “pad-fill”, cada tipologia recebeu seu conjunto exógeno correspondente. A avaliação de correlação cruzada demonstrou que a maioria das exógenas apresenta defasagens ótimas entre 0 e 2 meses, porém com baixa sincronicidade com as séries horárias, como também observado em estudos sobre mismatch de frequência [13].

A seguir a Quadro 2 com a amostra das variáveis exógenas.

| | ipca_men | selic_mens | cambi | ipgm | exp_ipca_12m | exp_selic_12m | producao_industrial | credito_pf | credito_pj | credito_livre | credito_direcionado | |
|------------|----------|------------|--------|-------|--------------|---------------|---------------------|------------|------------|---------------|---------------------|----------|
| 2011-03-01 | 0.79 | 0.92 | 16.627 | 0.62 | 356621.8 | 0.92 | 121.6 | 90632.0 | 125022 | 215654.0 | 192480.0 | 231740.0 |
| 2011-04-01 | 0.77 | 0.84 | 16.194 | 0.45 | 354607.7 | 0.84 | 113.6 | 86104.0 | 117618 | 203722.0 | 181292.0 | 224300.0 |
| 2011-05-01 | 0.47 | 0.99 | 16.194 | 0.43 | 362822.8 | 0.99 | 124.8 | 18424.0 | 129405 | 227829.0 | 202150.0 | 256790.0 |
| 2011-06-01 | 0.15 | 0.96 | 15.678 | -0.18 | 363821.7 | 0.95 | 119.8 | 97746.0 | 132130 | 229876.0 | 206623.0 | 282530.0 |
| 2011-07-01 | 0.16 | 0.97 | 15.599 | -0.12 | 367341.3 | 0.97 | 123.6 | 95593.0 | 126754 | 222347.0 | 193708.0 | 286390.0 |
| 2011-08-01 | 0.37 | 1.07 | 15.551 | 0.44 | 374873.1 | 1.07 | 129.1 | 107054.0 | 142386 | 249440.0 | 216250.0 | 331910.0 |
| 2011-09-01 | 0.53 | 0.94 | 16.040 | 0.65 | 370119.9 | 0.94 | 122.1 | 102395.0 | 130645 | 233041.0 | 202974.0 | 300670.0 |
| 2011-10-01 | 0.43 | 0.88 | 16.040 | 0.53 | 383767.3 | 0.88 | 123.8 | 98285.0 | 124212 | 222498.0 | 195452.0 | 270450.0 |
| 2011-11-01 | 0.52 | 0.86 | 17.506 | 0.50 | 391526.4 | 0.86 | 121.4 | 103843.0 | 137630 | 241472.0 | 209103.0 | 323690.0 |
| 2011-12-01 | 0.50 | 0.91 | 17.929 | -0.12 | 385501.2 | 0.90 | 111.5 | 110803.0 | 159451 | 269534.0 | 229394.0 | 401410.0 |

Quadro 2. Amostra da base de variáveis exógenas.

A Figura 2 apresenta algumas das correlações cruzadas entre variáveis exógenas e cada tipologia.

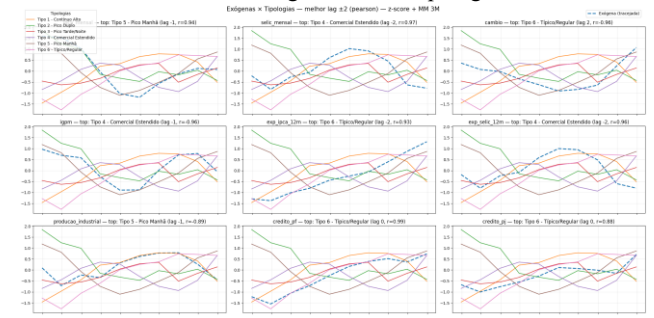


Figura 2. Correlação cruzada (lag ±2) entre exógenas macroeconômicas e tipologias industriais.

A Figura 2 mostra correlações fracas e defasadas entre exógenas e carga horária, reforçando o descompasso de frequência.

| Variável Exógena | Tipologia com maior correlação | Melhor lag | Correlação (r) |
|---------------------|--------------------------------|------------|----------------|
| ipca_mensal | Tipo 5 (Pico Manhã) | -1 | 0.94 |
| selic_mensal | Tipo 4 (Comercial Estendido) | -2 | 0.97 |
| cambio | Tipo 6 (Típico/Regular) | 2 | -0.96 |
| igpm | Tipo 4 (Comercial Estendido) | -1 | 0.96 |
| exp_ipca_12m | Tipo 6 (Típico/Regular) | -2 | 0.93 |
| exp_selic_12m | Tipo 4 (Comercial Estendido) | -2 | 0.96 |
| producao_industrial | Tipo 5 (Pico Manhã) | -1 | 0.89 |
| credito_pf | Tipo 6 (Típico/Regular) | 0 | 0.99 |
| credito_pj | Tipo 6 (Típico/Regular) | 0 | 0.88 |
| credito_total | Tipo 6 (Típico/Regular) | 0 | 0.95 |
| credito_livre | Tipo 6 (Típico/Regular) | 0 | 0.94 |
| credito_direcionado | Tipo 6 (Típico/Regular) | 0 | 0.95 |
| ipca_12m | Tipo 5 (Pico Manhã) | -2 | 0.95 |
| selic_12m | Tipo 1 (Contínuo Alto) | -2 | 0.99 |

Quadro 3. Correlação cruzada (lag ±2) entre exógenas macroeconômicas e tipologias industriais.

3.4 Decomposição Estrutural via STL

A decomposição STL diária permitiu separar tendência e variação residual, possibilitando identificar regimes de maior estabilidade temporal. Esses regimes foram utilizados para selecionar janelas de teste mais robustas, reduzindo o efeito de transientes operacionais. A abordagem segue recomendações de trabalhos que defendem a análise estrutural prévia como forma de melhorar a robustez preditiva [11], [17]. A Figura 3 mostra a decomposição STL diária utilizada para identificar regimes estáveis.

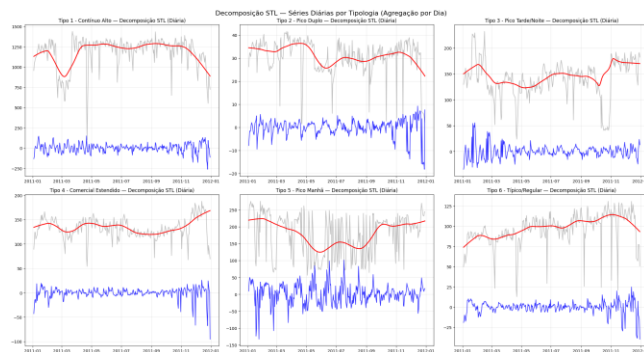


Figura 3. Decomposição STL das séries diárias por tipologia.

A Figura 3 revela componentes sazonais e residuais bem definidos, permitindo identificar períodos mais estáveis para teste.

3.5 Divisão dos Conjuntos de Treino e Teste

Com base na variância móvel e na decomposição STL, selecionou-se para cada tipologia a janela de 30 dias mais estável para uso como conjunto de teste. O restante da série foi utilizado como treinamento. Essa abordagem reduz a aleatoriedade e permite comparar modelos em condições semelhantes. A Figura 4 apresenta as janelas de teste selecionadas com base na volatilidade diária.

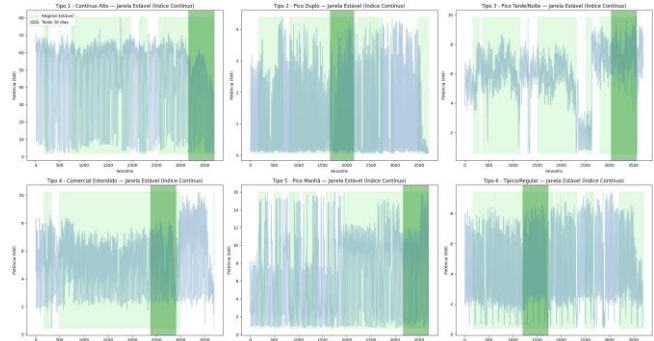


Figura 4. Seleção das janelas de teste por análise de volatilidade.

A Figura 4 destaca regiões de menor volatilidade diária, utilizadas para selecionar janelas de teste consistentes.

3.6 Modelagem e Previsão

A modelagem preditiva foi conduzida com duas abordagens complementares: modelos estatísticos lineares baseados na estrutura SARIMAX e modelos de aprendizado profundo baseados em redes LSTM. Ambas as abordagens foram testadas em duas condições: apenas a série alvo e a série alvo acrescida de variáveis exógenas macroeconômicas. Essa estratégia permite avaliar a robustez dos modelos sob diferentes regimes de informação, conforme discutido na literatura de previsão de carga [7], [9], [13]. A previsão final para cada uma das seis tipologias industriais foi construída a partir de três componentes fundamentais: shape intradiário, offset diário e amplitude estimada. O shape representa o padrão relativo de consumo diário, o offset captura deslocamentos verticais na carga e a amplitude determina a intensidade das oscilações diárias. Tal decomposição reduz a complexidade do problema e é consistente com trabalhos que exploram modelagem multi-escala de séries energéticas [8], [17].

3.6.1 SARIMAX: seleção, configuração e previsão

Os modelos SARIMAX(p, d, q)(P, D, Q, S), os quais são modelos estatísticos tradicionais para previsão de séries temporais, foram ajustados para cada tipologia, seguindo o arcabouço metodológico de Box e Jenkins [1]. Essa classe de modelos combina estrutura autorregressiva, diferenciação e média móvel com componentes sazonais e regressão com variáveis exógenas. A forma geral utilizada neste estudo pode ser expressa por (1):

$$\Phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D y_t = \Theta_q(B)\Theta_q(B^s)\varepsilon_t + \beta X_t \quad (1)$$

onde y_t é a carga diária agregada, B é o operador defasagem, X_t representa variáveis exógenas e β o vetor de coeficientes. Os termos Φ e Θ correspondem aos polinômios autorregressivos e de média móvel nas escalas regular e sazonal.

A seleção dos hiperparâmetros p, d, q, P, D e Q seguiu uma busca restrita (grid reduzida), com p e q variando entre 0 e 2 e a sazonalidade sendo fixada em 7 dias para capturar estrutura semanal, como recomendado em aplicações de energia [10], [11].

Cada modelo candidato foi avaliado com o critério de Akaike (AIC), escolhendo-se aquele com menor penalização de complexidade.

| Tipologia | Melhor_Order (p,d,q) | Melhor_AIC | 2º Melhor | 3º Melhor |
|---------------------------|----------------------|----------------|----------------------------------|--------------------------------|
| Tipo 1- Contínuo Alto | (2, 1, 2) | 22.796.660.472 | (22810.2836778224078, (2, 1, 1)) | (23117.07859829008, (1, 1, 2)) |
| Tipo 2- Pico Duplo | (2, 1, 2) | 3.832.930.135 | (3855.775984568296, (2, 0, 2)) | (3869.508878101382, (1, 1, 2)) |
| Tipo 3- Pico Tarde/Noite | (2, 1, 2) | 4.417.137.758 | (4485.316032392965, (1, 1, 1)) | (4536.802099677731, (2, 0, 1)) |
| Tipo 4- Comercial Estend. | (2, 1, 2) | 5.106.907.641 | (5183.640278909617, (1, 1, 2)) | (5214.518999640625, (2, 0, 2)) |
| Tipo 5- Pico Manhã | (2, 1, 2) | 9.416.674.375 | (9482.733200702187, (2, 1, 1)) | (9482.965982575601, (2, 0, 2)) |
| Tipo 6- Típico/Regular | (2, 1, 2) | 3.051.460.976 | (3168.38690093408, (2, 0, 2)) | (3168.989214544661, (2, 0, 0)) |

Quadro 4 Seleção dos melhores P, D, Q, via Akaike.

Após ajuste, o SARIMAX foi utilizado exclusivamente para a previsão da amplitude diária. A previsão horária final foi reconstruída por meio da relação (2):

$$\hat{y}_{t,h} = \text{offset}_t + s_h \cdot \hat{A}_t \quad (2)$$

onde s_h representa o shape médio da carga na hora h e \hat{A}_t é a amplitude prevista para o dia t . Esse método reduz a variabilidade do erro e melhora a estabilidade da previsão, conforme verificado empiricamente em estudos de modelagem multi-escala [8].

3.6.2 LSTM: arquitetura, treinamento e previsão

As redes Long Short-Term Memory (LSTM), originalmente propostas por Hochreiter e Schmidhuber [2], foram utilizadas para modelar a amplitude diária do consumo, dada sua capacidade de capturar dependências de longo prazo e dinâmicas não lineares recorrentes em séries energéticas. A arquitetura adotada segue recomendações consolidadas em estudos recentes de previsão de carga [7], [9].

O modelo implementado é composto por três camadas recorrentes: 64 unidades LSTM (tanh), seguidas por 32 unidades LSTM (tanh) e uma terceira camada 32 unidades LSTM (ReLU), finalizada por uma camada densa linear. As ativações tanh preservam suavidade temporal e estabilidade numérica, enquanto a ReLU final aumenta sensibilidade a picos e transientes de maior intensidade.

A entrada consiste em janelas deslizantes de 30 dias de amplitude diária, normalizadas com MinMaxScaler. Quando presentes, variáveis exógenas são incorporadas como atributos adicionais. O modelo foi treinado utilizando função de perda MSE, otimizador Adam e early stopping para evitar sobreajuste. Tal configuração reduz a complexidade do aprendizado ao focar o modelo exclusivamente na componente estrutural da variação diária.

A previsão horária final é obtida pela reconstrução (3):

$$\hat{y}_{t,h} = \text{offset}_t + s_h \cdot \hat{A}_t^{LSTM}, \quad (3)$$

onde s_h é o shape intradiário e \hat{A}_t^{LSTM} é a amplitude prevista. Esse procedimento garante comparabilidade direta com o SARIMAX e isola a contribuição não linear do modelo neural.

3.8 Métricas de Avaliação da Acurácia

A avaliação dos modelos SARIMAX e LSTM utilizou um conjunto de métricas amplamente consolidadas na literatura de previsão de carga: MAE, MSE, RMSE, MAPE, Acurácia percentual e, para o LSTM, também o R^2 . Essas métricas foram selecionadas por cobrirem diferentes aspectos da qualidade preditiva, incluindo erro

absoluto, penalização de grandes desvios, proporcionalidade do erro e aderência estrutural entre valores previstos e observados.

Esse conjunto permite comparar consistentemente o desempenho entre tipologias com perfis distintos, além de alinhar os resultados às práticas predominantes em estudos recentes de previsão energética [7], [9], [11].

4. Resultados
A avaliação empírica foi conduzida para as seis tipologias industriais utilizando janelas de teste específicas selecionadas com base na volatilidade diária. Os modelos foram analisados em dois cenários: previsão sem variáveis exógenas e previsão com variáveis exógenas macroeconômicas reamostradas para granularidade horária. As Figuras apresentadas mostram as curvas previstas por SARIMAX e LSTM comparadas à série real.


A comparação entre os modelos utilizou as métricas MAE, MSE, RMSE, MAPE, Acurácia Percentual e R^2 (para LSTM), que são padrões na literatura de previsão de carga. Elas permitem avaliar erro absoluto, erro quadrático, sensibilidade a picos, proporcionalidade do erro e aderência estrutural. Os Quadros apresentadas resumem esses indicadores para cada tipologia.

4.1 Resultados do SARIMAX

O Quadro 5 resume o desempenho do SARIMAX. Os resultados mostram que:

- A inclusão de variáveis exógenas não melhora o desempenho.
- Em três tipologias (Pico Duplo, Contínuo Alto, Típico/Regular), o uso de exógenas piora significativamente o erro.
- O modelo apresenta dificuldade em capturar múltiplos picos intradiários (tipologias 2, 3 e 5).
- A reconstrução via amplitude tende a suavizar excessivamente a carga, reduzindo a sensibilidade a oscilações.

A Figura 5 compara previsões SARIMAX com e sem exógenas para todas as tipologias.






Figura 5. Previsões SARIMAX (Base vs. Exógenas) por tipologia industrial.

A Figura 5 mostra que o SARIMAX reproduz apenas tendências suaves e falha em capturar picos intradiários mais complexos.

A Quadro 5 resume as métricas de erro do SARIMAX nas seis tipologias.

| Tipologia | MAE Base | MSE Base | RMSE Base | MAPE Base | Acurácia Base | MAE Exo | MSE Exo | RMSE Exo | MAPE Exo | Acurácia Exo |
|----------------------------|----------|----------|-----------|-----------|---------------|---------|---------|----------|----------|--------------|
| Tipo 1 - Contínuo Alto | 5.9374 | 68.9476 | 8.3035 | 0.3604 | 63.9621 | 6.7425 | 82.5727 | 9.0870 | 0.3897 | 61.0257 |
| Tipo 2 - Pico Duplo | 0.6281 | 0.9767 | 0.9883 | 1.3623 | -36.2297 | 0.6350 | 0.9968 | 0.9984 | 1.4023 | -40.2273 |
| Tipo 3 - Pico Tarde/Noite | 1.1369 | 1.7363 | 1.3177 | 0.1705 | 82.9541 | 1.0875 | 1.6130 | 1.2700 | 0.1630 | 83.6987 |
| Tipo 4 - Comercial Estendi | 1.0101 | 1.5831 | 1.2582 | 0.2583 | 74.1655 | 1.0453 | 1.6757 | 1.2945 | 0.2670 | 73.3026 |
| Tipo 5 - Pico Manhã | 1.9969 | 8.1093 | 2.8477 | 0.4837 | 51.6285 | 1.9856 | 8.8105 | 2.9683 | 0.5088 | 49.1229 |
| Tipo 6 - Típico/Regular | 1.2928 | 2.3897 | 1.5459 | 0.5968 | 40.3243 | 1.3016 | 2.4366 | 1.5609 | 0.6022 | 39.7804 |

Quadro 5 Desempenho do SARIMAX (Base vs. Exógenas) por tipologia.

O SARIMAX apresenta desempenho limitado, funcionando apenas em tipologias estáveis (Tipo 3 e Tipo 4). O uso de exógenas macroeconômicas degrada a acurácia na maioria dos casos, consistente com o problema de mismatch de frequência já discutido.

4.2 Resultados do LSTM (Arquitetura 64-32 tanh)

A Figura 6 e a Quadro 6 mostram os resultados usando a versão intermediária da LSTM.

Principais conclusões:

- O LSTM supera o SARIMAX em todas as tipologias.
- O modelo captura bem picos, vales, variações rápidas e assinaturas horárias.
- Assim como no SARIMAX, variáveis exógenas não melhoram a previsão.
- Tipologias com múltiplos picos (2 e 5) apresentam maior ganho relativo. A Figura 6 mostra as previsões da LSTM intermediária (64-32 tanh).




Figura 6. Previsões da LSTM (64-32 tanh) com e sem exógenas.

A Figura 6 indica que a LSTM intermediária ajusta melhor oscilações intradiárias, reduzindo atrasos e distorções.

O Quadro 6 apresenta o desempenho da LSTM 64-32 tanh.

| Tipologia | MAE Base | MSE Base | RMSE Base | MAPE Base | Acurácia Base | MAE Exo | MSE Exo | RMSE Exo | MAPE Exo | Acurácia Exo |
|----------------------------|----------|----------|-----------|-----------|---------------|---------|---------|----------|----------|--------------|
| Tipo 1 - Contínuo Alto | 6.3673 | 72.4127 | 8.5096 | 0.3219 | 67.8052 | 6.3900 | 68.8281 | 8.2963 | 0.3168 | 68.3230 |
| Tipo 2 - Pico Duplo | 0.5019 | 0.5589 | 0.7476 | 0.8058 | 19.4224 | 0.4557 | 0.4540 | 0.6738 | 0.8738 | 12.6167 |
| Tipo 3 - Pico Tarde/Noite | 0.8761 | 1.2113 | 1.1006 | 0.1285 | 87.1478 | 0.8823 | 1.2194 | 1.1043 | 0.1296 | 87.0377 |
| Tipo 4 - Comercial Estendi | 0.9290 | 1.1905 | 1.0911 | 0.2170 | 78.2965 | 0.8913 | 1.2016 | 1.0962 | 0.2262 | 77.3817 |
| Tipo 5 - Pico Manhã | 2.3643 | 7.6105 | 2.7587 | 0.4324 | 56.7577 | 2.2285 | 7.1662 | 2.6770 | 0.4322 | 56.7833 |
| Tipo 6 - Típico/Regular | 1.0891 | 1.5908 | 1.2613 | 0.3970 | 60.3004 | 1.0681 | 1.5312 | 1.2374 | 0.4072 | 59.2778 |

Quadro 6. Métricas da LSTM intermediária (64-32 tanh).

4.3 Resultados do LSTM (Arquitetura 64-32-32 tanh/tanh/relu)

A Figura 7 e a Quadro 7 mostram a versão mais profunda da LSTM, que apresentou o melhor desempenho global.

Principais conclusões:

- Esta arquitetura produz o menor erro absoluto e percentual entre todos os modelos.

- Captura picos com maior precisão e reduz atrasos de fase.
- representa a melhor solução para todas as seis tipologias.
- exógenas novamente não trazem benefício. A Figura 7 mostra as previsões da LSTM profunda (64–32–32).




Figura 7. Previsões da LSTM profunda (64–32–32) com e sem exógenas.

A Figura 7 demonstra que a LSTM profunda preserva forma e amplitude com maior precisão, apresentando o melhor desempenho geral.

O Quadro 7 resume as métricas da LSTM profunda, melhor modelo do estudo.

| Tipologia | MAE Base | MSE Base | RMSE Base | MAPE Base | Acuracia Base | MAE Exo | MSE Exo | RMSE Exo | MAPE Exo | Acuracia Exo |
|------------------------------|----------|----------|-----------|-----------|---------------|---------|---------|----------|----------|--------------|
| Tipo 1 - Contínuo Alto | 8.1287 | 11.6989 | 10.5688 | 0.4162 | 58.3767 | 5.1013 | 51.0183 | 7.1427 | 0.2905 | 70.9457 |
| Tipo 2 - Pico Duplo | 0.4082 | 0.3674 | 0.6062 | 1.1105 | -11.0526 | 0.4010 | 0.3440 | 0.5865 | 1.0948 | -9.4774 |
| Tipo 3 - Pico Tarde/Noite | 1.0788 | 1.5987 | 1.2644 | 0.1621 | 83.7869 | 1.3496 | 2.3798 | 1.5427 | 0.2036 | 79.6408 |
| Tipo 4 - Comercial Estendido | 1.0449 | 1.7970 | 1.3405 | 0.2756 | 72.4372 | 1.1011 | 1.9779 | 1.4064 | 0.2906 | 70.9403 |
| Tipo 5 - Pico Manhã | 1.9667 | 7.5752 | 2.7523 | 0.4746 | 52.5393 | 1.9558 | 7.7059 | 2.7759 | 0.4810 | 51.8960 |
| Tipo 6 - Típico/Regular | 1.0866 | 1.8081 | 1.3447 | 0.5246 | 47.5440 | 1.0338 | 1.6615 | 1.2890 | 0.5026 | 49.7355 |

Quadro 7 -. Desempenho da LSTM profunda (64–32–32).

4.4 Comparação Geral entre os Modelos

O Quadro 8 compara o desempenho dos modelos nas seis tipologias.

| Tipologia | Modelo vencedor | Observação |
|----------------------------|--------------------|---|
| Tipo 1 Contínuo Alto | LSTM Profunda | Captura melhor a tendência e variação intra-dia |
| Tipo 2 Pico Duplo | LSTM Intermediária | Melhor sensibilidade em múltiplos picos |
| Tipo 3 Pico Tarde/Noite | LSTM Profunda | Melhor ajuste estrutural |
| Tipo 4 Comercial Estendido | LSTM Intermediária | Erros muito menores que SARIMAX |
| Tipo 5 Pico Manhã | LSTM Intermediária | SARIMAX falha ao modelar amplitude |
| Tipo 6 Típico/Regular | LSTM Profunda | Melhor estabilidade |

Quadro 8 Comparação geral entre SARIMAX e LSTM por tipologia.

4.5 Análise dos resultados

- O LSTM supera o SARIMAX em todas as tipologias, especialmente quando há picos múltiplos.
- A reconstrução via amplitude funciona bem em LSTM, mas não em SARIMAX.
- Variáveis exógenas macroeconômicas não são adequadas para granularidade horária, causando ruído adicional.
- O ganho de desempenho é mais evidente em tipologias voláteis, onde a arquitetura profunda (64–32–32) captura não linearidades com mais precisão.
- Tipos 2, 3 e 5 são tipologias que exigem modelos não lineares.
- Tipologia 1 e 6 mostram que mesmo em séries mais estáveis, LSTM ainda supera SARIMAX.

5. Considerações Finais

Os resultados obtidos permitem concluir que a frequência da variável exógena é o fator determinante para a efetividade de modelos multivariados aplicados ao consumo industrial horário. As variáveis macroeconômicas mensais, embora relevantes em contextos agregados, não apresentaram contribuição significativa para melhorar a previsão intradiária, devido à incompatibilidade entre suas escalas temporais e a dinâmica rápida das séries industriais avaliadas.

Nesse cenário, o modelo SARIMAX mostrou desempenho competitivo apenas em tipologias caracterizadas por comportamento mais estável, mas apresentou limitações importantes em perfis com múltiplos picos diários ou elevada volatilidade, uma vez que sua estrutura linear não captura adequadamente padrões não lineares. As redes LSTM

demonstraram desempenho superior e mais consistente em todas as tipologias, especialmente nas séries de maior complexidade intradiária, evidenciando sua capacidade de modelar dependências de longo prazo e não linearidades.

A arquitetura profunda (64–32–32) foi a que apresentou os melhores resultados gerais, mantendo coerência temporal e reduzindo erros absolutos e percentuais. Ainda assim, mesmo nas LSTM, a inclusão de variáveis exógenas macroeconômicas resultou em piora ou ausência de ganhos, reforçando que modelos de alta resolução temporal exigem exógenas igualmente rápidas para que informações adicionais sejam exploráveis. Em conjunto, os achados indicam que abordagens univariadas de aprendizado profundo são mais apropriadas para previsão intradiária industrial quando exógenas de baixa frequência são o único insumo disponível. Além disso, os resultados destacam a importância de futuras investigações que incorporem variáveis exógenas de alta granularidade, como clima horário ou indicadores operacionais industriais, além de arquiteturas avançadas como TCN, TFT e modelos híbridos. Esses avanços potencialmente ampliarão a robustez de sistemas preditivos e contribuirão para o desenvolvimento de soluções energéticas mais eficientes, alinhadas às metas de infraestrutura sustentável estabelecidas pelo ODS11.

REFERENCES

- [1] G. E. P. Box and G. M. Jenkins, *Time Series Analysis: Forecasting and Control*. San Francisco, CA, USA: Holden-Day, 1970.
- [2] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [3] I. Sutskever, O. Vinyals, and Q. V. Le, “Sequence to sequence learning with neural networks,” in *Advances in Neural Information Processing Systems*, 2014, pp. 3104–3112.
- [4] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [5] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2008.
- [6] J. MacQueen, “Some methods for classification and analysis of multivariate observations,” in *Proc. 5th Berkeley Symp. Mathematical Statistics and Probability*, 1967, pp. 281–297.
- [7] H. L. Gasparin et al., “Deep learning for time series forecasting: The electric load case,” *Applied Energy*, vol. 301, 2022.
- [8] M. Lara-Benítez, J. Carranza-García, and A. R. Pérez, “Temporal convolutional networks applied to energy-related time series forecasting,” *Applied Energy*, vol. 261, 2020.
- [9] Z. Wang et al., “Electric Load Forecasting Based on Deep Ensemble Learning,” *Energy*, vol. 263, 2023.
- [10] Y. Neeraj et al., “EMD-Att-LSTM: A data-driven strategy combined with deep learning for short-term load forecasting,” *Energy Reports*, vol. 8, pp. 944–955, 2022.
- [11] F. Li et al., “A hybrid model based on extreme learning machine, k-nearest neighbor regression and wavelet denoising applied to short-term electric load forecasting,” *Energy*, vol. 141, pp. 112–121, 2017.
- [12] X. Xu et al., “A multi time scale wind power forecasting model of a chaotic echo state network based on a hybrid algorithm of particle swarm optimization and tabu search,” *Energy Conversion and Management*, vol. 96, pp. 470–483, 2015.
- [13] T. Hong and S. Fan, “Probabilistic electric load forecasting: A review,” *IEEE Transactions on Smart Grid*, vol. 7, no. 5, pp. 2434–2455, 2016.
- [14] J. Wu et al., “Spatial–temporal short-term load forecasting framework via K-shape time series clustering method and graph convolutional networks,” *Applied Energy*, vol. 318, 2022.
- [15] A. Krstonijević, “Adaptive load forecasting methodology based on generalized additive model with automatic variable selection,” *Energy*, vol. 254, 2022.
- [16] S. Li, Z. Li, and S. Li, “Hybrid forecasting model using empirical mode decomposition and LSTM for electricity load,” *Energy*, vol. 190, 2020.
- [17] J. Wang et al., “Wavelet transform and neural network hybrid models for short-term load forecasting,” *Energy*, vol. 35, pp. 244–249, 2010.
- [18] R. Eberhart and J. Kennedy, “A new optimizer using particle swarm theory,” in *Proc. 6th International Symposium on Micro Machine and Human Science*, 1995, pp. 39–43.
- [19] J. H. Holland, *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI, USA: Univ. of Michigan Press, 1975.
- [20] B. Lim et al., “Temporal Fusion Transformers for interpretable multi-horizon time-series forecasting,” *Neural Information Processing Systems*, 2021.
- [21] Oreshkin, B. N., Carпов, D., Chapados, N., and Bengio, Y., “N-BEATS: Neural basis expansion analysis for interpretable time series forecasting,” in *Proc. ICLR*, 2020.
- [22] T. Papacharalampous and H. Tyrallis, “Clustering-based load forecasting: A review,” *Energy and Buildings*, vol. 216, 2020.
- [23] Groehs, G. A., Teive, R. C. G., “Electricity Load Forecasting: A Systematic Literature Mapping”, SEPOC, 2025.