

## **XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA**

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

*Campus Itapetininga*

### **PLANO DE ANÁLISE COMPARATIVA DE TÉCNICAS DE REGRESSÃO PARA OTIMIZAÇÃO DO CONSUMO ENERGÉTICO INDUSTRIAL**

Vitor Rabello Mendes – PIBIC/IFSP<sup>1</sup>

Prof. Me. Elcio Rodrigues Aranha - IFSP<sup>2</sup>

#### **Introdução**

O consumo energético nas indústrias representa uma das principais fontes de custos operacionais e também uma significativa preocupação ambiental. Com o aumento da demanda global por sustentabilidade e a crescente pressão para reduzir as emissões de carbono, torna-se imperativo que as indústrias adotem práticas mais eficientes de gestão energética. Nesse contexto, o uso de dados históricos e técnicas avançadas de modelagem preditiva tem se mostrado uma ferramenta promissora para a otimização do consumo energético, permitindo ajustes mais assertivos nos processos industriais (Silva & Santos, 2012). O emprego de modelos de aprendizado de máquina, especialmente a regressão, tem se destacado na literatura como uma abordagem eficaz para prever e controlar o consumo energético em ambientes industriais (Irffi et al., 2009). Nos últimos anos, diversos estudos têm investigado o uso de modelos de regressão para prever o consumo de energia, como o Random Forest, XGBoost e as Redes Neurais LSTM. A aplicação desses modelos a grandes volumes de dados históricos têm demonstrado resultados promissores na melhoria da precisão das previsões (Wang et al., 2019). No entanto, ainda há um debate sobre qual técnica apresenta melhor desempenho em termos de precisão preditiva e adaptabilidade a diferentes tipos de processos industriais. Além disso, a maioria dos estudos existentes foca em modelos isolados, sem uma comparação direta e sistemática entre as abordagens, deixando uma lacuna significativa na literatura quanto à avaliação comparativa de técnicas de regressão aplicadas a diferentes tipos de indústrias (Lobão & Costa Ferreira, 2015). A definição de critérios e a coleta de dados são elementos essenciais para a construção de modelos preditivos. A literatura destaca que a adoção de tecnologias digitais, como medidores de energia inteligentes e sistemas de monitoramento em tempo real, tem revolucionado a forma como os dados de consumo energético são coletados, permitindo uma análise mais precisa e integrada (Le, Pang & Zhang, 2012). Além disso, a combinação de diferentes fontes de dados, como sistemas de gestão de produção e medidores de energia, é recomendada para o acompanhamento do consumo energético industrial (Henning et al., 2020). A coleta padronizada e consistente desses dados é fundamental para garantir a qualidade das previsões, especialmente em grandes datasets industriais. A relevância deste estudo reside na oportunidade de preencher essa lacuna, proporcionando uma comparação entre diferentes modelos de regressão para prever o consumo energético industrial, com base em dados históricos amplamente disponíveis. A pesquisa tem o potencial de contribuir para indústrias que buscam otimizar seu uso de energia, ao mesmo tempo em que aumenta a literatura acadêmica sobre a aplicação de

---

<sup>1</sup>Estudante do curso de Engenharia de Controle e Automação, IFSP – Cubatão/SP. E-mail do primeiro autor: vitor.rabello@aluno.ifsp.edu.br.

<sup>2</sup>Docente Mestre Engenheiro Eletricista, IFSP - Cubatão/SP. E-mail do autor: aranha@ifsp.edu.br

## **XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA**

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

*Câmpus Itapetininga*

aprendizado de máquina em processos industriais de grande escala. A análise crítica dessas abordagens preditivas poderá fornecer não apenas a base para a escolha do modelo mais adequado, mas também abrir novos caminhos para o uso de dados históricos como ferramenta decisiva na transformação dos processos produtivos em indústrias mais sustentáveis e eficientes.

### **Objetivo**

O objetivo deste estudo é comparar diferentes modelos de regressão aplicados à predição do consumo energético em processos industriais de grande escala, utilizando dados históricos de eficiência energética. A pesquisa visa avaliar o desempenho de modelos como Random Forest, XGBoost, e Redes Neurais LSTM, identificando o modelo com maior precisão preditiva e menor erro absoluto médio (MAE). A partir dessa análise, busca-se fornecer uma base para a escolha do modelo mais adequado para otimização de consumo energético em indústrias, com ênfase na capacidade de generalização a grandes volumes de dados industriais reais e na redução do impacto de outliers nos resultados preditivos.

### **Metodologia**

Este estudo propõe a comparação de diferentes modelos de regressão aplicados à predição do consumo energético em processos industriais de grande escala, utilizando dados históricos de eficiência energética. De natureza quantitativa, a pesquisa se justifica pela necessidade de análise estatística de grandes volumes de dados numéricos para prever padrões de consumo, permitindo uma abordagem objetiva e mensurável (CRESWELL, 2014). A metodologia inclui três estratégias complementares: estudo de caso, para investigar a aplicação dos modelos em uma indústria específica, favorecendo uma análise contextualizada e profunda (YIN, 2018); pesquisa experimental, para testar e comparar a eficácia de modelos como Random Forest, XGBoost e redes neurais LSTM de maneira controlada (FIELD, 2013); e survey, com o objetivo de compreender a adoção de técnicas de predição em larga escala no setor industrial (FINK, 2013). A população-alvo são indústrias de grande porte, especialmente do setor de manufatura que já implementaram sistemas digitais de monitoramento energético, sendo utilizada a amostragem por conveniência devido às limitações de acesso. A amostra, composta por 5 a 10 indústrias, buscará garantir diversidade de dados para uma análise comparativa. O estudo será realizado preferencialmente em indústrias brasileiras, dada a relevância econômica do setor e a disponibilidade de dados históricos de consumo energético, fundamentais para a comparação dos modelos. A coleta de dados será baseada na extração de registros históricos diretamente dos sistemas de monitoramento das empresas, utilizando scripts desenvolvidos em Python com o suporte das bibliotecas Pandas e Scikit-learn, o que garante eficiência na manipulação e preparação dos dados para análise. A análise dos dados envolverá a detecção de outliers, exploração de características relevantes e aplicação dos modelos de regressão, sendo a performance avaliada por métricas como coeficiente de determinação ( $R^2$ ), erro quadrático médio (RMSE) e erro absoluto médio (MAE), conforme recomendado na literatura para avaliação de desempenho preditivo (FIELD, 2013). A validade e a confiabilidade dos resultados serão reforçadas pela aplicação da validação cruzada, técnica essencial para garantir a capacidade de generalização dos modelos em diferentes contextos industriais (JAMES et al., 2013). Reconhecem-se como limitações a possível restrição de acesso a bases de dados reais e a representatividade

## **XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA**

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

*Campus Itapetininga*

limitada às indústrias que já possuem sistemas de monitoramento, sendo previstas o uso de bases simuladas complementares, quando necessário. Dessa forma, pretende-se contribuir para a escolha fundamentada de modelos de regressão capazes de otimizar o consumo energético industrial, com elevada precisão preditiva e resistência a dados atípicos.

### **Resultados**

Espera-se que esta pesquisa contribua de maneira significativa em diferentes dimensões. No aspecto prático, a comparação entre modelos de regressão poderá apontar quais algoritmos apresentam melhor desempenho na predição do consumo energético em processos industriais de grande escala, possibilitando o desenvolvimento de diretrizes aplicáveis para a utilização de métodos preditivos em ambientes industriais e a criação de um repositório de códigos em Python para suporte a futuras aplicações. Em termos sociais, a aplicação de técnicas de predição poderá fomentar práticas industriais mais sustentáveis, incentivar a redução do consumo excessivo de energia e democratizar o acesso a ferramentas analíticas entre pequenas e médias indústrias que buscam melhorar sua eficiência energética. No campo teórico, o estudo contribuirá para o avanço da literatura sobre modelagem de dados industriais, ao analisar o desempenho de diferentes modelos de regressão em cenários caracterizados por grandes volumes de dados históricos e presença de outliers, além de propor uma metodologia estruturada para a coleta, preparação e modelagem de dados de consumo energético. Como desdobramentos futuros, o trabalho poderá motivar pesquisas aplicadas no uso de técnicas de deep learning para predição de séries temporais industriais, incentivar adaptações dos modelos avaliados para outros setores, como agricultura de precisão e gestão energética urbana, e estimular o desenvolvimento de sistemas automáticos de seleção de modelos com base nas características dos dados. Ademais, há a possibilidade de realização de estudos de caso em parceria com indústrias para validar empiricamente os modelos aplicados, ampliando o impacto prático da pesquisa e servindo como base para novos projetos voltados à otimização do consumo energético no setor industrial.

### **Conclusão**

Nesta apresentação inicial propõe-se a comparação de diferentes modelos de regressão aplicados à predição do consumo energético em processos industriais de grande escala, destacando-se como uma iniciativa relevante para preencher lacunas existentes na literatura acadêmica e apoiar práticas industriais mais eficientes. Os principais resultados previstos indicam que a avaliação sistemática de modelos como Random Forest, XGBoost e Redes Neurais LSTM poderá fornecer subsídios sólidos para a escolha de abordagens mais eficazes na previsão de padrões de consumo energético, contribuindo para a melhoria da eficiência operacional das indústrias. A relevância dos resultados é evidenciada tanto no campo acadêmico, ao enriquecer o conhecimento sobre modelagem de dados industriais, quanto no campo profissional e social, por oferecer instrumentos que podem favorecer práticas sustentáveis, reduzir custos e democratizar o acesso a tecnologias de predição, especialmente para pequenas e médias empresas. Contudo, reconhecem-se limitações relacionadas à disponibilidade de bases de dados industriais reais e à representatividade da amostra, restrita às indústrias que já utilizam sistemas digitais de monitoramento energético. Para mitigar essas limitações, foi previsto o uso complementar de bases

## **XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA**

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

*Campus Itapetininga*

simuladas. Considerações éticas também foram incorporadas, assegurando que os dados utilizados respeitem princípios de confidencialidade e consentimento institucional. A partir das reflexões oriundas deste estudo, propõem-se como sugestões para trabalhos futuros a ampliação do escopo para outros setores produtivos, o aprofundamento da investigação em técnicas de deep learning para séries temporais industriais e a exploração do desenvolvimento de sistemas automáticos de seleção de modelos com base nas características dos dados. Assim, este trabalho estabelece bases consistentes para pesquisas subsequentes e para aplicações práticas voltadas à transformação sustentável do setor industrial.

### **Referências**

- CRESWELL, John W. *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*. 4. ed. Thousand Oaks: SAGE Publications, 2014.
- FIELD, Andy. *Discovering Statistics Using IBM SPSS Statistics*. 4. ed. London: SAGE Publications, 2013.
- FINK, Arlene. *How to Conduct Surveys: A Step-by-Step Guide*. 5. ed. Thousand Oaks: SAGE Publications, 2013.
- HENNING, Sören; HASSELBRING, Wilhelm; BURMESTER, Heinz; MÖBIUS, Armin; WOJCIESZAK, Maik. Goals and measures for analyzing power consumption data in manufacturing enterprises. *arXiv preprint*, arXiv:2009.10369, set. 2020. Disponível em: <https://arxiv.org/abs/2009.10369>. Acesso em: 27 abr. 2025.
- IRFFI, Guilherme; CASTELAR, Ivan de Melo; SIQUEIRA, Marcelo Lettieri; LINHARES, Fabrício Carneiro. Previsão da demanda por energia elétrica para classes de consumo na região Nordeste, usando OLS dinâmico e mudança de regime. *Economia Aplicada*, São Paulo, v. 13, n. 1, p. 69–98, mar. 2009. DOI: 10.1590/S1413-80502009000100004.
- JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. *An Introduction to Statistical Learning: With Applications in R*. New York: Springer, 2013.
- LE, Kelvin C. V.; PANG, Chee Khiang; ZHANG, Dan Hong. Energy saving and monitoring technologies in manufacturing systems with industrial case studies. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICATIONS – ICIEA, 7., 2012, Singapore. Anais... Singapore: IEEE, 2012. p. 1–6. Disponível em: [https://www.researchgate.net/publication/260189799\\_Energy\\_Saving\\_and\\_Monitoring\\_Technologies\\_in\\_Manufacturing\\_Systems\\_with\\_Industrial\\_Case\\_Studies](https://www.researchgate.net/publication/260189799_Energy_Saving_and_Monitoring_Technologies_in_Manufacturing_Systems_with_Industrial_Case_Studies). Acesso em: 27 abr. 2025.
- LOBÃO, Waldir; COSTA FERREIRA, Pedro Guilherme. Modelagem da carga de energia elétrica no Brasil: uma proposta VAR-VEC via estimação da demanda. *Texto de Discussão IE/FGV*, Rio de Janeiro, n. 73, fev. 2015.
- SILVA, Alexandre Alex; SANTOS, Eucymara França Nunes. Previsão de consumo de energia elétrica em Petrolina – PE. *Revista Brasileira de Energia*, São Paulo, v. 18, n. 1, p. 129–141, 1º sem. 2012.
- WANG, Hao; LEI, Zhiqiang; ZHANG, Xiaoyan; ZHOU, Bao; PENG, Jian. A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, Kidlington, v. 198, p. 111799, dez. 2019. DOI: 10.1016/j.enconman.2019.111799.
- YIN, Robert K. *Case Study Research and Applications: Design and Methods*. 6. ed. Thousand Oaks: SAGE Publications, 2018