

Modelo híbrido para previsão de séries temporais baseado em decomposição e redes neurais

João Lucas Ferreira dos Santos

Programa de Pós Graduação em Engenharia de Produção - PPGEPP
Universidade Tecnológica Federal do Paraná - UTFPR

Ponta Grossa-PR, Brasil

joaolucassantos@alunos.utfpr.edu.br

Tathiana Mikamura Barchi

Programa de Pós Graduação em Engenharia de Produção - PPGEPP
Universidade Tecnológica Federal do Paraná - UTFPR

Ponta Grossa-PR, Brasil

tathianabarchi@alunos.utfpr.edu.br

Yslene Rocha Kachba

Departamento de Engenharia de Produção

Universidade Tecnológica Federal do Paraná - UTFPR

Ponta Grossa-PR, Brasil

yslener@utfpr.edu.br

Sérgio Luiz Stevan Júnior

Programa de Pós Graduação em Engenharia Elétrica - PPGE

Universidade Tecnológica Federal do Paraná - UTFPR

Ponta Grossa-PR, Brasil

sstevanjr@utfpr.edu.br

Hugo Valadares Siqueira

Programa de Pós Graduação em Engenharia de

Produção e Programa de Pós Graduação em

Engenharia Elétrica - PPGEPP/PPGE

Universidade Tecnológica Federal do Paraná - UTFPR

Ponta Grossa-PR, Brasil

hugosiqueira@utfpr.edu.br

Resumo—Este estudo investiga a inserção de modelos híbridos de previsão de séries temporais. Para tal, avaliou-se a viabilidade de um modelo que combina decomposição aditiva, seleção progressiva de atrasos e redes neurais (MLP e LSTM) integradas por ELM para prever preços diários em cinco regiões brasileiras (RS, SC, SP, PR e MG) de preços de carne suína no contexto. Adotou-se uma abordagem experimental sobre 2.494 observações diárias (02/03/2015–28/02/2025) coletadas em bases secundárias e no Centro de estudos avançados em economia aplicada (CEPEA). As séries foram divididas em 60% treino, 20% validação e 20% teste, decompostas em tendência, sazonalidade e resíduos, e submetidas à seleção progressiva de atrasos; em seguida, MLP e LSTM foram treinados e suas saídas mapeadas/reconstruídas por uma ELM. O modelo híbrido apresentou desempenho superior aos modelos individuais em todos os datasets, obtendo as menores métricas de RMSE, MAE e MAPE. Neste sentido, propõe-se um modelo adaptável passível de extensão a outros mercados e horizontes de previsão.

Palavras chave—Previsão de séries temporais, Modelos híbridos, Seleção de atrasos, Preços da carne suína.

I. INTRODUÇÃO

Uma série temporal é uma sequência ordenada de valores observados em intervalos de tempo regulares. A análise de séries temporais, independente da metodologia adotada, envolve três etapas principais: (i) obtenção dos dados a serem

modelados; (ii) preparação ou pré-processamento dos dados conforme suas características; e (iii) ajuste do modelo para viabilizar as previsões futuras. Esse procedimento aplica-se a qualquer série temporal, de qualquer natureza e em qualquer área do conhecimento.

Desde a proposta de Zhang (2003) [1], que segmentou a série em componente linear (ARIMA) e não linear (rede neural), surgiram inúmeras estruturas híbridas [2]. Revisões recentes focadas em aplicações de consumo de energia residencial [3], [4], previsão de taxa de câmbio [5] e mercado financeiro [6] confirmam o papel central das redes neurais como combinadores, mas ressaltam a carência de critérios objetivos para o pré-processamento e a escolha de técnicas de decomposição.

Embora existam estudos comparativos envolvendo Transformada Discreta de Wavelet (DWT), Decomposição Empírica de Modo e sua variante Ensemble EMD (EMD/EEMD), Decomposição de Modo Variacional (VMD), Análise de Espectro Singular (SSA) e Decomposição Sazonal-Trend via Loess (STL) em cenários diversos [7], [8], a escolha da técnica e de sua parametrização deve considerar fatores como grau de não-linearidade, presença de ruído, padrões sazonais, dimensionalidade da série e custo computacional, em vez de apoiar-se em uma solução universal.

Neste sentido, este estudo propõe-se um comparativo que inclui tanto modelos individuais quanto um modelo híbrido. Nos modelos individuais, aplicamos diretamente um Multi-Layer Perceptron (MLP) e uma Long Short-Term Memory

Os autores agradecem aos órgãos brasileiros pelo apoio financeiro, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código Financiador 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processos nº 311159/2023-0. Os autores também agradecem a Universidade Tecnológica Federal do Paraná (UTFPR).

(LSTM) aos preços diários da carne suína em cinco estados brasileiros. Já no modelo híbrido, a série é primeiro decomposta em tendência, sazonalidade e resíduo: a tendência e a sazonalidade são modeladas por um MLP, os resíduos por uma LSTM e, por fim, as previsões parciais são integradas (stacked) por uma Extreme Learning Machine (ELM), escolhida por sua rapidez de treinamento e boa generalização em camada oculta única [9], [10].

II. SÉRIES TEMPORAIS E MODELOS DE PREVISÃO

Nesta seção, são apresentados os conceitos de série temporal e de suas componentes principais, a aplicação de decomposição aditiva e os modelos de previsão empregados, incluindo estratégias híbridas.

Uma série temporal consiste em observações de uma variável ao longo do tempo, como preços de carne suína registrados em intervalos diários, mensais ou anuais [11]. Para facilitar a modelagem, adotou-se a decomposição aditiva via (biblioteca `statsmodels.tsa.seasonal`), que isola tendência, sazonalidade e resíduo [12].

A. Multi Layer Perceptron (MLP)

As redes MLP constituem uma das arquiteturas de redes neurais mais clássicas e versáteis em previsão de séries temporais [13]. São formadas por uma camada de entrada, uma ou mais camadas ocultas de neurônios com funções de ativação não lineares e uma camada de saída, operando em modo feedforward (fluxo unidirecional de informação) [14]. O treinamento é conduzido pelo algoritmo de backpropagation, que ajusta iterativamente os pesos para minimizar o erro de saída [15]. Essa configuração permite à MLP capturar padrões não lineares e relações de alta complexidade entre variáveis, sendo particularmente eficaz quando a série apresenta dependências imediatas e correlações estáveis.

B. Long Short-Term Memory (LSTM)

As LSTM são redes recorrentes projetadas para lidar com dependências de longo prazo em sequências temporais, superando limitações de redes RNN tradicionais [16]. Cada célula LSTM incorpora portões de esquecimento, entrada e saída que regulam de forma dinâmica a retenção e atualização de informação interna [17]. Esse mecanismo de gating mitiga o problema do desvanecimento e do estouro de gradiente, garantindo que a rede aprenda padrões em diferentes escalas de tempo. Assim, LSTM é a escolha preferencial quando a série exibe ciclos prolongados ou efeitos de memória pronunciados.

C. Extreme Learning Machine (ELM)

As ELM surgem como alternativa de treinamento ultrarrápido em redes de camada oculta única, utilizando pesos ocultos gerados aleatoriamente e fixos, e determinando analiticamente apenas os pesos de saída via pseudoinversa de Moore–Penrose [10]. Desde que se empreguem funções de ativação contínuas e diferenciáveis, esse método dispensa otimização iterativa, reduzindo substancialmente o tempo de treinamento sem comprometer a capacidade de generalização

[9], [18]. Em aplicações práticas, ELM costuma apresentar desempenho comparável ao de MLP, especialmente em cenários de alta dimensionalidade ou exigências de resposta rápida.

D. Métodos para Seleção de Entradas

Em termos computacionais, nem sempre é praticável realizar busca exaustiva em todos os subconjuntos possíveis, mesmo em problemas relativamente pequenos, pois o custo computacional cresce de forma fatorial [15]. Além disso, inserir grande quantidade de atrasos nem sempre leva a melhores resultados [19]. Uma alternativa é a utilização do método wrapper com seleção progressiva, cujo procedimento estabelece uma forma de construir subconjuntos de entradas, considerando-as individualmente [15].

Nesse método, o processo inicia-se com um subconjunto de entradas vazio. Em cada iteração, todos os atrasos candidatos são testados individualmente no modelo. Aquele que obtiver o melhor desempenho, de acordo com uma métrica de erro, é incorporado ao subconjunto, e o erro correspondente é registrado [20]. No passo seguinte, o modelo passa a ter duas entradas: o lag inicialmente selecionado e cada um dos demais candidatos, inseridos um a um. Novamente, se a nova combinação minimizar o erro, o atraso é mantido e o erro é registrado. Ao final do processo, o subconjunto que apresentar o menor erro global é escolhido [19].

E. Modelos Híbridos

Modelos híbridos dividem a série em componentes (linear e não linear) e aplicam técnicas diferentes a cada parte [1]. A metodologia clássica utiliza um modelo ARIMA para capturar a dinâmica linear e uma rede neural para ajustar os resíduos não lineares, combinando-os de forma aditiva para obter a previsão final.

Abordagens posteriores propõem substituir a soma direta por um metamodelo de aprendizado de máquina: primeiro, um ARIMAX estima a componente linear; em seguida, redes como MLP, ESN, ELM ou RBF ajustam a parte não linear; por fim, um SVR aprende a função de combinação que gera a previsão híbrida [21]. Neste trabalho, inspiramo-nos nesse esquema para decompor a série em tendência, sazonalidade e resíduos, atribuindo a cada componente uma rede neural especializada e empregando um metamodelo final para integrar as previsões.

III. MATERIAIS E MÉTODOS

Os dados utilizados consistem nos preços diários da carne suína (R\$/kg), coletados entre 02/03/2015 e 28/02/2025, para os datasets referentes a RS, SC, SP, PR e MG [22]. Não houve dados ausentes nos datasets, eliminando a necessidade de imputação. Cada dataset, com 2494 observações, foi dividido em 60% para treinamento, 20% para validação e 20% para teste, garantindo a representatividade dos ciclos sazonais e das tendências de longo prazo.

Antes de aplicar a abordagem híbrida, cada modelo individual (MLP, LSTM) foi treinado e avaliado usando exatamente os mesmos hiperparâmetros da Tabela I, porém sem




Fig. 1: Fluxograma da metodologia: aquisição, avaliação de modelos individuais, decomposição, modelagem e reconstrução.

Tabela I: Parâmetros dos Modelos

Parâmetros	Modelos		
	MLP	LSTM	ELM
Otimizador	adam	adam	Moore–Penrose
Função de ativação	sigmoid	relu / linear	sigmoid
Número de neurônios	[2,5,10,20,50,100,500]	[2,5,10,20,50,100,500]	100
Atrasos	[1,2,5,10,15,20]	[1,2,5,10,15,20]	N/A
Épocas	50	50	N/A

realizar a decomposição da série. Em seguida, empregou-se a decomposição aditiva e as três etapas de modelagem modular descritas abaixo para gerar o modelo híbrido.

Aplicou-se decomposição aditiva considerando período de 365 dias (biblioteca `statsmodels.tsa.seasonal`) para isolar tendência, sazonalidade e resíduos [12]. Em seguida, usou-se o método *wrapper* progressivo para seleção de atrasos candidatos: na primeira iteração, cada atraso foi avaliado individualmente; nas seguintes, combinou-se o melhor conjunto de atrasos com um novo candidato, realizando uma busca exaustiva em todas as quantidades de neurônios ocultos, até que não houvesse ganho adicional no RMSE de validação.

A modelagem híbrida foi dividida em três etapas:

- **MLP (tendência e sazonalidade):** prevê a parte estrutural da série. Entradas normalizadas pelo `StandardScaler`, atrasos selecionados via *wrapper*, camada oculta única treinada por 50 épocas em `scikit-learn`, minimizando MSE.
- **LSTM (resíduos):** captura padrões não lineares nos resíduos da decomposição. Os mesmos lags candidatos reorganizados em sequências e normalizados; arquitetura implementada em `TensorFlow/Keras`, com camada LSTM seguida de camada densa e Relu, treinada por 50 épocas com Adam.

- **ELM (reconstrução):** integra as previsões da MLP e da LSTM. Pesos da camada oculta inicializados aleatoriamente (semente fixa) e mantidos; apenas pesos de saída calculados via pseudoinversa de Moore–Penrose, com entradas normalizadas contendo as três previsões.

IV. RESULTADOS E DISCUSSÕES

Os resultados deste estudo estão organizados em três etapas: (i) configuração dos modelos, apresentada na Tabela II; (ii) avaliação de desempenho, Tabela III; (iii) comparativo visual entre valores observados e previstos, exibido na Figura 2 para Rio Grande do Sul e nas Figuras 3a, 3b, 3c e 3d (ver Figura 3) para Santa Catarina, São Paulo, Paraná e Minas Gerais.

Com os atrasos selecionados observando a Tabela II, desconsiderou-se a utilização de atrasos para a ELM, visto que as dependências temporais foram modeladas via MLP e LSTM. O atraso 1 aparece em todos os datasets e em todos os modelos, sugerindo forte influência do valor imediatamente anterior. Neste sentido, o desejo de evitar propagação de erro optou-se em focar exclusivamente na previsão de um passo à frente.

A Tabela III mostra que o modelo híbrido (ELM) supera consistentemente MLP e LSTM individuais em todas as

Tabela II: Parâmetros utilizados

Dataset	Modelos									
	MLP		LSTM		MLP (tendência-sazonalidade)		LSTM (resíduos)		ELM (MLP-LSTM)	
	Atrasos	Neurônios	Atrasos	Neurônios	Atrasos	Neurônios	Atrasos	Neurônios	Atrasos	Neurônios
RS	[1,15]	100	[1,10,20,15]	500	[1]	500	[1,5]	20	–	100
SC	[1]	100	[1,10]	100	[1]	500	[1,5]	50	–	100
SP	[1,15]	100	[1,5,20,15,2]	500	[1,2]	500	[1,5,2,20,10]	500	–	100
PR	[1,15]	100	[1,5,15]	500	[1]	500	[1,5]	20	–	100
MG	[1,20]	100	[1,5,15,20,2]	500	[1]	50	[1,2]	500	–	100

Tabela III: Desempenho dos Modelos

Dataset	Modelos								
	MLP			LSTM			ELM (MLP-LSTM)		
	RMSE	MAE	MAPE (%)	RMSE	MAE	MAPE (%)	RMSE	MAE	MAPE (%)
RS	0.1563	0.1017	1.3346	0.0623	0.0437	0.6595	0.0250*	0.0183*	0.2853*
SC	0.1185	0.0814	1.1220	0.0719	0.0527	0.7928	0.0294*	0.0222*	0.3466*
SP	0.1388	0.1021	1.3247	0.0762	0.0552	0.7459	0.0353*	0.0261*	0.3647*
PR	0.1512	0.1005	1.3121	0.1144	0.0849	1.1530	0.0392*	0.0283*	0.4185*
MG	0.1762	0.1183	1.4716	0.0817	0.0573	0.7789	0.0357*	0.0267*	0.3703*

* Melhor desempenho (menor erro) por dataset e métrica.

métricas, evidenciando o ganho de precisão proporcionado pela abordagem modulada e analítica.

Os resultados apresentados na Tabela III mostram que o modelo híbrido ELM (MLP-LSTM) obteve o melhor desempenho em todos os datasets. No Rio Grande do Sul (RS), por exemplo, o ELM alcançou um MAPE de apenas 0,28%, contra 0,65% do LSTM e 1,33% do MLP, representando uma melhoria de mais de quatro vezes em relação ao modelo mais básico. Esses achados convergem com os relatados em [21] e [1], os quais também apontam vantagem para modelos híbridos.

O desempenho do ELM no RS pode ser atribuído à natureza dos dados deste dataset, que possivelmente apresentam padrões mais estáveis e sazonalidade bem definida. Estas características são comuns em estados com forte influência climática em suas atividades econômicas. A predominância da agroindústria no RS, com ciclos produtivos bem estabelecidos, parece favorecer modelos que capturam dependências temporais como o LSTM e o híbrido ELM.

Dados com padrões cíclicos, influenciados por fatores ambientais e com sazonalidade, beneficiam-se de abordagens híbridas, como o modelo ELM. A combinação de modelos com capacidades complementares supera métodos isolados, contornando suas limitações individuais e aproveitando sinergicamente seus pontos fortes, o que contribuiu para resultados superiores, quando comparados a propostas individuais.

Em SC o modelo MLP apresentou o menor MAPE entre todos os datasets (1,12%), indicando dados com relações mais lineares e diretas. Isto sugere que a economia diversificada de SC gera um comportamento de dados mais estável e menos suscetível a eventos extremos, facilitando a previsão mesmo para modelos mais simples. [24] destaca a eficácia de modelos simples em cenários com dados estáveis. O artigo enfatiza que métodos de previsão lineares podem performar bem quando os dados apresentam alta autocorrelação e relações diretas,

exatamente o cenário sugerido pelo baixo MAPE do MLP em SC.

Os resultados observados para São Paulo (SP), Paraná (PR) e Minas Gerais (MG) podem ser explicados pelo princípio teórico discutido por [25], que argumenta que a complexidade econômica fundamentalmente limita a precisão das previsões financeiras. Conforme esta teoria, economias complexas geram interações não lineares e fatores de alta ordem que introduzem níveis irredutíveis de imprevisibilidade.






Fig. 2: Previsões para Rio Grande do Sul (RS)


São Paulo demonstrou métricas intermediárias em todos os modelos, refletindo sua elevada complexidade econômica e diversificação. O Paraná apresentou os valores mais elevados de erro no modelo ELM (MAPE: 0,42%) e também nos demais modelos, possivelmente devido à combinação de características agrícolas com industrialização crescente, resultando em maior variabilidade nos dados. Já Minas Gerais teve os piores resultados com o MLP (RMSE: 0,1762; MAPE: 1,47%), sugerindo que este modelo encontra dificuldades em capturar as relações complexas e ciclos sazonais que caracter-




(a) SC



(c) PR



(b) SP



(d) MG

Fig. 3: Previsões para Santa Catarina, São Paulo, Paraná e Minas Gerais

izam a economia mineira, onde eventos passados influenciam fortemente o presente. A melhoria com o modelo híbrido sugere a presença de dependências temporais significativas, possivelmente relacionadas a ciclos econômicos específicos.

V. CONCLUSÃO

O objetivo geral deste trabalho foi investigar a viabilidade de um modelo híbrido baseado em decomposição aditiva de séries temporais, combinado com redes neurais (MLP e LSTM) e integrado por ELM, para prever os preços diários da carne suína. Foram realizados 5 estudos de caso, baseados em cinco regiões brasileiras (RS, SC, SP, PR e MG). Esse objetivo foi atingido, pois o modelo híbrido apresentou desempenho superior aos modelos individuais em todos os casos avaliados, resultando em menores erros de previsão (RMSE, MAE e MAPE). Dentre os principais resultados, destacam-se a capacidade do ELM (MLP-LSTM) de alcançar as menores métricas de erro, a seleção recorrente do atraso 1 em todas as configurações evidenciando forte dependência do valor imediatamente anterior e a eficácia da decomposição aditiva em simplificar a modelagem de tendência e sazonalidade, o que permitiu à LSTM concentrar-se na captura dos padrões residuais de curto e médio prazo.

Este estudo preliminar, propõe um framework modular que integra a decomposição, a seleção progressiva de atrasos e

a fusão analítica de previsões via ELM para séries temporais, demonstrando a eficácia da ELM como mecanismo de combinação de saídas de diferentes redes neurais. Além disso, valida a aplicabilidade desse framework no contexto específico da suinocultura brasileira.

Entretanto, o trabalho apresenta algumas limitações: não foram consideradas variáveis exógenas (como custos de insumos, câmbio e indicadores logísticos), restringiu-se a previsões de um passo à frente e a cinco estados produtores, o que pode limitar a generalização dos resultados. Como direções para pesquisas futuras, recomenda-se incorporar variáveis exógenas e avaliar a sensibilidade do modelo a choques externos; incluir métodos clássicos de previsão, como ARIMA, comparando-os às metodologias propostas por [21] e [1] para avaliar o impacto da decomposição; testar outros métodos de seleção de variáveis [15]; e estender o modelo híbrido para previsões multi-passos.

REFERÊNCIAS

- [1] G. P. Zhang, "ARIMA, Box-Jenkins methodology, Artificial neural networks, Time series forecasting," *Neurocomputing*, vol. 50, pp. 159–175, 2003.
- [2] Z. Hajirahimi e M. Khashei, "Hybrid structures in time series modeling and forecasting: A review," *Engineering Applications of Artificial Intelligence*, vol. 86, pp. 83–106, 2019.

- [3] C. Deb, F. Zhang, J. Yang, S. E. Lee e K. W. Shah, "A review on time series forecasting techniques for building energy consumption," *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 902–924, 2017.
- [4] A. A. Mamun, M. Sohel, N. Mohammad, M. S. Haque Sunny, D. R. Dipta e E. Hossain, "A Comprehensive Review of the Load Forecasting Techniques Using Single and Hybrid Predictive Models," *IEEE Access*, vol. 8, pp. 134911–134939, 2020.
- [5] D. Pradeepkumar e V. Ravi, "Soft computing hybrids for FOREX rate prediction: A comprehensive review," *Computers & Operations Research*, vol. 99, pp. 262–284, 2018.
- [6] A. M. Rather, V. N. Sastry e A. Agarwal, "Stock market prediction and Portfolio selection models: a survey," *OPSEARCH*, vol. 54, no. 3, pp. 558–579, 2017.
- [7] A. Tascikaraoglu e M. Uzunoglu, "A review of combined approaches for prediction of short-term wind speed and power," *Renewable and Sustainable Energy Reviews*, vol. 34, pp. 243–254, 2014.
- [8] Y. Chen, W. Wang, X. Hua e D. Zhao, "Survey of Decomposition-Reconstruction-Based Hybrid Approaches for Short-Term Traffic Forecasting," *Sensors*, vol. 22, no. 14, art. 5263, 2022.
- [9] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 4CH37541), 2004, pp. 985–990. doi:10.1109/IJCNN.2004.1380068.
- [10] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, no. 1, pp. 489–501, 2006. doi:10.1016/j.neucom.2005.12.126.
- [11] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, John Wiley & Sons, 2015.
- [12] T. Krake, D. Klötzl, D. Hägele, and D. Weiskopf, "Uncertainty-Aware Seasonal-Trend Decomposition Based on Loess," *IEEE Transactions on Visualization and Computer Graphics*, vol. 31, no. 2, pp. 1496–1512, 2025. DOI: 10.1109/TVCG.2024.3364388.
- [13] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall PTR, 1994.
- [14] E. Guresen, G. Kayakutlu, and T. U. Daim, "Using artificial neural network models in stock market index prediction," *Expert Systems with Applications*, vol. 38, no. 8, pp. 10389–10397, 2011. DOI: 10.1016/j.eswa.2011.02.068.
- [15] H. Siqueira, M. Macedo, Y. de S. Tadano, T. A. Alves, S. L. Stevan, D. S. Oliveira, M. H. Marinho, P. S. G. de Mattos Neto, J. F. L. de Oliveira, I. Luna, M. de A. L. Filho, L. A. Sarubbo, and A. Converti, "Selection of temporal lags for predicting riverflow series from hydroelectric plants using variable selection methods," *Energies*, vol. 13, no. 16, art. 4236, 2020. DOI: 10.3390/en13164236.
- [16] S. Siami-Namini, N. Tavakoli, and A. Siami Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series," in 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), 2018, pp. 1394–1401. doi:10.1109/ICMLA.2018.00227.
- [17] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997. doi:10.1162/neco.1997.9.8.1735.
- [18] Y. Kachba, D. M. G. Chirolí, J. T. Belotti, T. A. Antonini Alves, Y. de S. Tadano, and H. Siqueira, "Artificial neural networks to estimate the influence of vehicular emission variables on morbidity and mortality in the largest metropolis in South America," *Sustainability*, vol. 12, no. 7, art. 2621, 2020. [Online]. Available: <https://www.mdpi.com/2071-1050/12/7/2621>
- [19] I. Iguyon and A. Elisseff, "An introduction to variable and feature selection," *Journal of Machine Learning Research*, vol. 3, pp. 1157–1182, 2003.
- [20] J. T. Belotti, "Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles," *Dissertação (Mestrado em Ciência da Computação)*, Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa, 2019, 137 p. [Online]. Available: <http://repositorio.utfpr.edu.br/jspui/handle/1/4037>
- [21] P. S. de Mattos Neto, J. F. L. de Oliveira, D. S. de O. S. Junior, H. V. Siqueira, M. H. D. N. Marinho, and F. Madeiro, "A hybrid nonlinear combination system for monthly wind speed forecasting," *IEEE Access*, vol. 8, pp. 191365–191377, 2020.
- [22] Centro de Estudos Avançados em Economia Aplicada (CEPEA), "PIB do Agronegócio Brasileiro," [Online]. Available: <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>. Accessed: 7 Mar. 2025.
- [23] YUNIS, Roni; ANDRI, Andri; DJONI, Djoni. Hybridization Model for Air Pollution Prediction Using Time Series Data. *CogITo Smart Journal*, v. 10, n. 1, p. 1-14, 2024.
- [24] PANT, P. Narayan; STARBUCK, William H. Innocents in the forest: Forecasting and research methods. *Journal of Management*, v. 16, n. 2, p. 433-460, 1990.
- [25] OLKHOV, Victor. Economic complexity limits accuracy of price probability predictions by gaussian distributions. *arXiv preprint arXiv:2309.02447*, 2023.