

MODELOS DE *DEEP LEARNING* APLICADOS À PREVISÃO DE DEMANDA NO TRANSPORTE RODOVIÁRIO DE CARGAS

Lucas Gomes Pereira – d2021100736@unifei.edu.br
Matheus Brendon Francisco – matheus_brendon@unifei.edu.br
Renato da Silva Lima – rslima@unifei.edu.br

Palavras-chave: *Deep Learning*, Previsão de Demanda, Transporte Rodoviário de Cargas, Brasil.

1. INTRODUÇÃO

O transporte rodoviário de cargas constitui 61% do movimento de cargas no Brasil e é fundamental para a estrutura logística do país (Coppe *et al.*, 2020). Este setor é suscetível a flutuações econômicas e a mudanças sazonais, exigindo previsões precisas para estratégias de distribuição, roteamento e precificação de fretes (Moschovou; Giannopoulos, 2021).

Metodologias estatísticas convencionais, incluindo ARIMA, têm sido amplamente empregadas para prever a demanda (Semekonawo; Kam, 2022), mas apresentam restrições ao lidar com séries temporais não lineares e com grandes conjuntos de dados (Qin *et al.*, 2019). Por outro lado, as metodologias de Aprendizado Profundo (*Deep Learning*) estabeleceram sua eficácia na previsão de séries temporais em diversos setores (Rane *et al.*, 2024), com arquiteturas como LSTM (*Long Short-Term Memory*), GRU (*Gated Recurrent Unit*), CNN (*Convolutional Networks*) e *Transformer* demonstrando bons resultados (Jahin; Shahriar; Amin, 2025).

Apesar dos avanços, a aplicação sistemática dessas metodologias no domínio do transporte de cargas permanece incipiente (Kotenko, 2022). Consequentemente, esta pesquisa de doutorado visa avaliar a eficácia de várias estruturas de *Deep Learning* na previsão de demanda por transporte rodoviário de cargas, utilizando dados empíricos. A pergunta principal é: “Os modelos de Aprendizado Profundo

apresentam desempenho satisfatório nesse setor? Quais arquiteturas são consideradas mais adequadas?”. Além de suas contribuições metodológicas, esta investigação objetiva fornecer orientação prática para o planejamento logístico.

2. METODOLOGIA

A análise exploratória preliminar conduzida neste estudo foi baseada no banco de dados obtido de um *marketplace* logístico contendo 5.666.790 anúncios de cargas de 2019 a maio de 2022. A série temporal abrangeu o peso total postado na plataforma diariamente, quantificado em quilogramas. Essa variável específica foi selecionada devido ao seu *status* como a métrica mais indicativa da demanda real por serviços de transporte.

A fase de pré-processamento envolveu a retificação de valores faltantes, a eliminação de valores discrepantes empregando o Método de Intervalo Interquartil (IQR), a agregação diária de dados e a normalização por meio do *MinMaxScaler*. O conjunto de dados foi dividido temporalmente: as observações de 2019 a 2021 foram alocadas para o treinamento, enquanto as de 2022, designadas para teste.

Cinco arquiteturas distintas de Aprendizado Profundo foram empregadas: LSTM, GRU, CNN-1D, *Transformer* e um modelo combinando CNN e LSTM. Cada arquitetura passou por treinamento utilizando uma janela deslizante de sete dias. A otimização dos modelos foi executada utilizando uma função de perda baseada no erro quadrático médio (MSE).

A avaliação do desempenho dos modelos empregou um conjunto de métricas para fornecer uma perspectiva sobre a precisão. O coeficiente de determinação (R^2) serviu como o principal indicador, complementado pelo erro quadrático médio (RMSE), erro médio absoluto (MAE) e erro percentual médio absoluto (MAPE). Essa análise quantitativa foi ainda subsidiada por análises gráficas.

3. RESULTADOS E DISCUSSÃO

A Tabela 1 delinea as métricas de desempenho dos cinco modelos de *Deep Learning* que foram executados. As descobertas indicam que o modelo GRU se destacou por demonstrar um desempenho superior em todas as métricas avaliadas.

O valor elevado de R^2 indica a capacidade aprimorada da GRU de compreender a variabilidade dos dados. As métricas de erro, especificamente RMSE e MAE, corroboram que, em média, o algoritmo incorre no mínimo de erros em termos absolutos. Além disso, o modelo *Transformer* alcançou um valor de R^2 de 0,7640, excedendo assim o desempenho do modelo LSTM. Esse modelo também registrou o menor MAPE. Esse desempenho sugere que, embora tenda a suavizar as tendências dos dados, o algoritmo gera erros percentuais menores, aumentando assim a confiabilidade de suas previsões do ponto de vista prático. O modelo LSTM ficou em terceiro lugar, enquanto o modelo híbrido CNN+LSTM produziu resultados intermediários. Por fim, o modelo CNN-1D por si só demonstrou desempenho menos efetivo, indicando suas restrições na captura de dependências de tempo estendidas.


Tabela 1 – Desempenho dos modelos de Aprendizado Profundo

Modelo	R^2	RMSE (kg)	MAE (kg)	MAPE (%)
GRU	0,7856	47.388.864,93	27.556.165,32	720,50
<i>Transformer</i>	0,7640	51.893.438,96	36.731.174,53	598,43
LSTM	0,7467	51.520.567,21	34.435.028,36	767,50
CNN+LSTM	0,6872	60.942.613,53	43.513.073,53	702,50
CNN-1D	0,6332	58.576.045,64	41.136.744,44	759,79

Fonte: Autoria própria.

A Figura 1 ilustra uma justaposição visual dos valores empíricos e das previsões produzidas pelos cinco modelos empregados ao longo de um período de 60 dias no conjunto de dados de teste. Esta análise gráfica fundamenta as descobertas numéricas de desempenho, fornecendo uma representação mais clara da conformidade de cada modelo com a dinâmica temporal da série.

Figura 1 – Valores reais versus valores previstos no conjunto de teste



Fonte: Autoria própria.

É evidente que o modelo GRU exibiu a aderência visual mais favorável, refletindo com precisão as tendências ascendentes e os picos de demanda. Essa característica reforça a eficácia quantitativa do modelo, significando sua preeminência em capturar a estrutura da série. O modelo *Transformer* também exibiu um desempenho consistente, particularmente dentro das faixas intermediárias, mantendo a proximidade da curva real e evitando ruídos excessivos. Apesar da propensão à moderação nos extremos, seu desempenho confirma sua capacidade de capturar a estrutura da série, alinhando-se com seu erro percentual (MAPE). A previsão do LSTM se alinha adequadamente com a série real; no entanto, ela demonstra uma precisão reduzida em altos e baixos, o que explica seu coeficiente de R^2 um pouco reduzido, embora exiba estabilidade. O modelo híbrido CNN+LSTM manifestou um nível intermediário de desempenho, acompanhando o comportamento geral da série, embora com uma resposta mais lenta às flutuações abruptas. Isso restringe sua capacidade preditiva durante períodos de maior volatilidade. Por fim, o modelo CNN-1D foi o que mais divergiu da série real. Essa observação se correlaciona com o seu menor coeficiente de determinação e reflete as limitações inerentes às redes convolucionais mais simples em tarefas que necessitam de uma memória temporal estendida.

4. CONSIDERAÇÕES FINAIS

Os resultados deste estudo elucidam a capacidade das metodologias de *Deep Learning* na previsão da demanda por transporte rodoviário de cargas, destacando particularmente a eficácia das arquiteturas GRU e *Transformer*. O modelo GRU emergiu como o mais proficiente, alcançando métricas de desempenho superiores, evidenciadas por um valor de R^2 de 0,7856 e pelos erros médios pequenos (RMSE e MAE). Esse resultado comprova a eficácia das redes neurais recorrentes na captura da dependência temporal em séries de logística. Além disso, o desempenho promissor do modelo *Transformer* constitui uma observação digna de nota. Embora tenha exibido um R^2 menor em comparação ao GRU, esse modelo registrou o menor MAPE. Do ponto de vista prático, essa descoberta é significativa, pois implica que as previsões do *Transformer* produzem a maior precisão em termos percentuais, aprimorando assim os processos de tomada de decisão gerencial.

Como isso representa a fase preliminar da tese, os esforços subsequentes se concentrarão em refinar os modelos por meio de ajustes mais precisos. Uma análise de correlação também será executada entre séries que exibem defasagens temporais, com o objetivo de elucidar as dependências entre variáveis e otimizar a utilização das informações. Arquiteturas adicionais de Aprendizado Profundo, incluindo Prophet, TCN e DeepAR, serão avaliadas para expandir a análise comparativa. Em última análise, a intenção é implementar esses modelos de forma prática, facilitando previsões que informem a tomada de decisões estratégicas no setor de transporte rodoviário de cargas, particularmente em mercados de logística.

AGRADECIMENTOS

Os autores agradecem ao CNPq, à CAPES e à FAPEMIG pelo apoio financeiro concedido aos projetos que subsidiaram este trabalho.

REFERÊNCIAS

COPPE, L. M. *et al.* Precificação de fretes rodoviários via modelos paramétricos. **Revista Produção Online**, [s. l.], v. 20, n. 4, p. 1214–1237, 2020.

JAHIN, M. A.; SHAHRIAR, A.; AMIN, M. A. **MCDFN: Supply chain demand forecasting via an explainable multi-channel data fusion network model**. [S. l.]: arXiv, 2025. Disponível em: <http://arxiv.org/abs/2405.15598>. Acesso em: 11 out. 2025.

KOTENKO, V. Application of algorithmic models of machine learning to the freight transportation process. **Transport technologies**, [s. l.], v. 2022, n. 2, p. 10–21, 2022.

MOSCHOVOU, T. P.; GIANNOPOULOS, A. G. Road freight transportation in a period of economic instability: A panel data study in four EU Mediterranean countries. **Research in Transportation Business & Management**, [s. l.], v. 41, p. 100622, 2021.

QIN, L. *et al.* The impact of lengths of time series on the accuracy of the ARIMA forecasting. **International Research in Higher Education**, [s. l.], v. 4, n. 3, p. 58, 2019.

RANE, N. L. *et al.* Applications of deep learning in healthcare, finance, agriculture, retail, energy, manufacturing, and transportation: A review. *In*: RANE, N. L. *et al.* **Applied Machine Learning and Deep Learning: Architectures and Techniques**. [S. l.]: Deep Science Publishing, 2024. Disponível em: <https://deepscienceresearch.com/index.php/dsr/catalog/book/6/chapter/64>. Acesso em: 11 out. 2025.

SEMEKONAWO, K. P.; KAM, S. Linear regression and ARIMA models for electricity demand forecasting in West Africa. **Journal of Energy Research and Reviews**, [s. l.], p. 26–36, 2022.