

Sistema Integrado de Previsão de Carga e Otimização Logística para Subsídio ao Planejamento Ferroviário Nacional

Leonardo José, João Marcelo, Alita Rezende

Resumo:

Este artigo apresenta um sistema integrado para previsão de demanda e otimização logística ferroviária, voltado ao planejamento nacional e à operação das concessionárias. A solução combina modelos estatísticos e algoritmos de aprendizado de máquina com técnicas de otimização para redistribuição eficiente de carga. Com base em dados do PNL, históricos operacionais e variáveis climáticas e econômicas, o sistema gera subsídios técnicos para decisões estratégicas, revisão contratual e reequilíbrio modal. Os resultados indicam ganho preditivo e melhoria na eficiência da malha.

Palavras-chave: planejamento logístico, previsão de demanda, aprendizado de máquina, logística multimodal, rede ferroviária.

Abstract:

This paper presents an integrated system for demand forecasting and rail logistics optimization, aimed at national planning and concessionaire operations. The solution combines statistical models and machine learning algorithms with optimization techniques for efficient freight redistribution. Using PNL data, operational records, and climatic and economic variables, the system supports strategic decision-making, contract reviews, and modal rebalancing. Results show predictive gains and improved network efficiency.

Keywords: logistics planning, demand forecasting, machine learning, multimodal logistics, rail network.

Sumário:

1. Introdução:	3
2. Metodologia:	4
3. Desenvolvimento e resultados:	5
4. Conclusões:	10
Referências Bibliográficas:	12

1. Introdução:

A matriz de transporte de cargas no Brasil apresenta um desbalanceamento estrutural que compromete a eficiência logística nacional. O modal ferroviário, embora tecnicamente adequado para grandes volumes e longas distâncias, representa apenas 20,7% da tonelada-quilômetro útil (TKU) transportada no país, enquanto o modal rodoviário responde por mais de 60%, segundo dados do Plano Nacional de Logística (PNL) [7, 8]. Essa disparidade não decorre apenas da infraestrutura existente, mas também da ausência de mecanismos inteligentes de gestão preditiva da demanda e otimização da capacidade instalada, fatores que tornam o planejamento ferroviário excessivamente reativo e dependente de contratos bilaterais de longo prazo. Atualmente, o planejamento da malha ferroviária brasileira depende de matrizes origem-destino (O/D) estáticas, com baixa granularidade temporal e espacial, produzidas esporadicamente pelos PNLs e pelas concessionárias. Esses instrumentos não incorporam variações sazonais, choques climáticos, alterações de produtividade setorial ou mudanças nas cadeias logísticas [1]. Como consequência, o fluxo de carga sobre trilhos tende a ser abaixo do ótimo tanto do ponto de vista da capacidade física quanto da eficiência econômica. Além disso, os operadores logísticos e os reguladores não dispõem de ferramentas operacionais para simular cenários futuros, redistribuir cargas em tempo quase real ou planejar intervenções preventivas em pontos de saturação [1, 2]. Enquanto isso, setores críticos da infraestrutura brasileira, como o elétrico, já vêm adotando com sucesso soluções de previsão de carga baseadas em modelos híbridos de aprendizado de máquina, séries temporais multivariadas e otimização combinatória. Existem projetos voltados à estimativa de demanda elétrica em diversos horizontes temporais, são exemplos de aplicação consolidada de modelos preditivos para suporte à operação e ao planejamento setorial. Esses modelos não apenas antecipam flutuações de demanda com alta acurácia, mas também alimentam sistemas prescritivos de alocação e contingência, com ganhos mensuráveis em segurança, eficiência e resiliência.

A presente pesquisa parte da hipótese de que os fundamentos analíticos utilizados para previsão de carga no setor elétrico — como regressão regularizada, modelos baseados em árvores, redes neurais de reservatório (*Echo State Networks*) e técnicas de otimização combinatória — podem ser adaptados, com as devidas modificações, ao contexto ferroviário. No entanto, reconhece-se que o transporte sobre trilhos apresenta especificidades relevantes: a dinâmica não é centrada em consumo, mas em oferta logística; a granularidade geográfica é organizada por trechos e corredores; e há restrições operacionais físicas (como capacidade

de via e janelas contratuais) que condicionam fortemente o comportamento do sistema. Diante desse cenário, o presente trabalho propõe o desenvolvimento de um sistema integrado de previsão de carga logística com foco no setor ferroviário, composto por três módulos principais: (i) ingestão e modelagem de dados multivariados de carga, clima e atividade econômica; (ii) previsão de demanda com uso de modelos híbridos de aprendizado de máquina; e (iii) otimização logística com redistribuição de fluxos ferroviários via programação inteira mista. A solução é avaliada por meio de simulações em corredores estratégicos da malha nacional, com validação empírica baseada em dados públicos da ANTT, EPL e IBGE [2, 3, 7, 14, 18].

A questão que orienta esta pesquisa é: **por que o setor ferroviário brasileiro ainda não adotou, de forma estruturada, sistemas inteligentes de previsão de carga e como uma solução técnica integrada pode contribuir para a superação dessa lacuna?** A hipótese subjacente é que a ausência de tais sistemas decorre não de inviabilidade técnica, mas de descompasso entre capacidade analítica, arquitetura institucional e incentivos regulatórios. A pesquisa insere-se na linha temática “Inovação sobre Trilhos” do evento Brasil Nos Trilhos.

2. Metodologia:

Adotou-se uma abordagem empírica aplicada, combinando técnicas de *machine learning*, análise de séries temporais multivariadas e otimização logística, com base nos dados das matrizes origem-destino (O/D) produzidas pela Empresa de Planejamento e Logística (EPL) no contexto dos Planos Nacionais de Logística de médio e longo prazo [7].

Na etapa inicial, as matrizes O/D dos planos de 2025 e 2035 são utilizadas para gerar projeções regionais de demanda por corredor logístico. A segmentação é feita por tipo de produto transportado (minério, soja, combustíveis, cargas industriais) e por grupos de origem-destino com maior densidade. A partir disso, são agregadas variáveis externas que influenciam a oscilação da carga transportada, como condições climáticas (chuvas intensas, temperatura), indicadores agropecuários e fatores econômicos regionais. O objetivo é calibrar os modelos com base em informações que reflitam os padrões logísticos de curto e médio prazo. Para a previsão de carga, são testados modelos como LightGBM, XGBoost, Ridge Regression e Echo State Networks [10, 11, 21]. A seleção é feita com base em desempenho preditivo, utilizando validação cruzada temporal e ajuste de hiperparâmetros

via métodos de otimização bayesiana [5, 6]. Também são avaliadas abordagens tradicionais como modelos ARIMA sazonais [5, 28], para fins de comparação. Os modelos são aplicados com granularidade horária e diária, possibilitando a identificação de janelas críticas de operação. Em paralelo, desenvolve-se um módulo de otimização logística para redistribuição de carga ao longo da malha ferroviária nacional. O modelo considera a minimização de custos sob restrições operacionais, como limite de capacidade por trecho, tempo de deslocamento, prioridade modal e janelas contratuais de entrega. As saídas esperadas incluem planos de carregamento otimizados, mapas de saturação da infraestrutura e alertas de estrangulamento logístico.

A arquitetura geral do sistema é organizada em etapas sequenciais: ingestão de dados, pré-processamento, treinamento dos modelos e avaliação por métricas (MAPE - Mean Absolute Percentage Error, MAE - Mean Absolute Error e RMSE - Root Mean Square Error).

O objetivo do sistema é redistribuir os fluxos preditos ao longo da malha ferroviária nacional, minimizando custos operacionais e congestionamentos. As restrições modeladas incluem capacidade máxima por trecho, janelas contratuais de entrega, priorização modal por tipo de carga e tempos de trânsito. Os resultados da otimização são representados em dashboards com mapas de calor de saturação, alertas de estrangulamento e cenários comparativos entre alternativas operacionais. A validação final se dá pela comparação entre as previsões obtidas e os dados reais de movimentação em corredores representativos, como Rondonópolis–Santos e Norte–Sul. Também se verifica o impacto da ferramenta sobre o redesenho de fluxos contratuais, conforme cenários simulados dos Planos Nacionais de Logística.

3. Desenvolvimento e resultados:

O sistema proposto foi desenvolvido em três camadas interdependentes: ingestão e modelagem de dados logísticos, previsão multivariada de demanda ferroviária e otimização logística aplicada a cenários simulados. Cada camada foi projetada para preservar a rastreabilidade dos dados, garantir reprodutibilidade metodológica e permitir extensibilidade modular. A integração entre os módulos foi implementada em arquitetura Python, com estrutura de orquestração baseada em scripts parametrizáveis e interfaces de visualização operacionais desenvolvidas em Power BI.

3.1. Ingestão e modelagem de dados: A base de dados inicial foi composta pelas matrizes origem-destino (O/D) disponibilizadas nos Planos Nacionais de Logística 2025 e 2035 [14], com granularidade espacial definida por Unidades da Federação (UF) e temporal por ano base. Essas matrizes foram enriquecidas com dados operacionais fornecidos pelos anuários estatísticos da ANTT (2020 a 2023), os quais incluíram séries de tonelada-quilômetro útil (TKU) por concessionária, tipo de carga e trecho operacional. Adicionalmente, foram incorporadas variáveis climáticas (precipitação e temperatura) obtidas do INMET [19] e indicadores de atividade econômica regional (PIB setorial, exportações, produção agrícola) captados do IBGE, CONAB e MDIC. A modelagem inicial dos dados empregou técnicas de imputação para lidar com lacunas temporais (interpolação linear e por regressão multivariada), além de uma análise de componentes principais (PCA) para reduzir a dimensionalidade mantendo mais de 90% da variância explicada. Foi adotada uma estrutura em formato painel, na qual cada observação é um vetor que representa um corredor ferroviário em um determinado intervalo temporal (semanal). O conjunto final continha aproximadamente 8.400 observações após o tratamento.

A estruturação dos dados seguiu os princípios de integridade e auditabilidade definidos na literatura de engenharia de dados aplicada a transportes, conforme discutido por Kim et al. (2021) [22] e Oliveira et al. (2023) [27, 28]. A normalização das variáveis exógenas foi realizada por z-score para modelos lineares e por quantis para modelos baseados em árvore, considerando as sensibilidades distintas de cada algoritmo à escala de entrada.

3.2. Treinamento e comparação de modelos: Com os dados estruturados, foram testadas quatro abordagens de previsão de carga ferroviária: LightGBM, XGBoost, Regressão Ridge e Echo State Network (ESN). Cada modelo foi treinado com janelas móveis temporais em três horizontes: curtíssimo prazo (24 horas), curto prazo (7 dias) e médio prazo (30 dias). A validação cruzada utilizou blocos temporais (time series split) para preservar a estrutura sequencial dos dados. A otimização de hiperparâmetros foi realizada por busca bayesiana com o pacote Optuna, utilizando 50 iterações e critérios de early stopping. As métricas de avaliação incluíram MAPE (erro percentual absoluto médio), RMSE (erro quadrático médio da raiz) e R^2 ajustado. Os resultados mostraram que os modelos LightGBM e ESN apresentaram o melhor desempenho preditivo médio. O LightGBM obteve MAPE de 3,8% no horizonte de 24 horas e 5,1% em 7 dias. A ESN apresentou desempenho levemente inferior no curto prazo, porém mostrou maior estabilidade sob choques climáticos simulados (como episódios extremos de precipitação), devido à sua arquitetura de reservatório

dinâmico. A regressão Ridge serviu como baseline interpretável, e o ARIMA foi mantido como referência clássica, com erros médios 20% superiores. A literatura internacional tem demonstrado resultados consistentes com esses achados [16, 28, 29]. Estudos de Victorino e Matos (2022) [30] e Kim et al. (2020) [22] confirmam que modelos baseados em aprendizado de máquina superam métodos tradicionais na previsão de fluxo ferroviário quando há disponibilidade de variáveis exógenas relevantes.

3.3. Módulo de Otimização Logística: A etapa de otimização logística foi concebida para alocar de forma racional e eficiente os fluxos de carga previstos ao longo da malha ferroviária nacional. O objetivo principal foi desenvolver um sistema que, a partir das estimativas de demanda obtidas nos modelos preditivos, fosse capaz de propor um plano de operação otimizado com base em critérios técnicos, econômicos e regulatórios. A formulação do problema foi estruturada como um modelo de programação inteira mista (Mixed-Integer Programming – MIP), indicada na literatura [4] considerando a minimização do custo total de transporte, sujeito a um conjunto de restrições operacionais. As variáveis decisórias do modelo representam a quantidade de carga alocada a cada trecho da malha ferroviária por tipo de mercadoria, levando em consideração as origens e destinos definidos nas matrizes O/D, os custos operacionais por quilômetro, as capacidades máximas de transporte por segmento de via e a disponibilidade de janelas operacionais. As restrições foram agrupadas em quatro categorias principais: (i) capacidade de via (limite físico de cada trecho em toneladas/dia), (ii) restrições contratuais (janelas de entrega estabelecidas em contratos de concessão), (iii) prioridades modais (em alguns trechos, certos tipos de carga possuem precedência, como combustíveis e granéis sólidos) e (iv) balanceamento operacional (restrição de retorno logístico e compatibilidade entre trechos interconectados).

Para lidar com a escala do problema e a complexidade combinatória de soluções, o modelo MIP foi acoplado a uma heurística híbrida [4, 15, 24] que combina *simulated annealing* com *local search*.

Essa abordagem permitiu encontrar soluções de boa qualidade em tempo computacional aceitável mesmo para redes de grande porte. A técnica segue precedentes estabelecidos em estudos recentes de redes ferroviárias sul-americanas, que demonstram a efetividade da combinação de heurísticas com modelos exatos para problemas de alocação de fluxo sob restrições multimodais. A função objetivo foi calibrada com base em dados reais de custos operacionais extraídos de relatórios de desempenho da ANTT e parâmetros

operacionais fornecidos por estudos de caso técnico-acadêmicos. Os custos considerados incluíram consumo energético, tempo de percurso, tempo de permanência nos pátios e penalizações por atraso ou não atendimento a janelas contratuais. O modelo foi implementado em linguagem Python utilizando o solver Gurobi, com visualização posterior em ambiente Power BI e Plotly para simulação de cenários.

Os resultados preliminares indicam que o módulo de otimização foi capaz de redistribuir os fluxos previstos de modo a reduzir em até 25 % a carga alocada em trechos saturados, sem aumentar significativamente o custo total da operação. Em diversos cenários simulados, identificou-se a possibilidade de redirecionamento da carga para corredores subutilizados, como os ramais secundários da região Centro-Oeste, ampliando a eficiência do sistema como um todo. A simulação de cenários com interferência climática (excesso de chuvas) também foi incorporada ao modelo, permitindo a reconfiguração da malha com base em parâmetros de acessibilidade geotécnica.

A abordagem adotada possui potencial de ser integrada a sistemas reais de planejamento logístico ferroviário, tanto pelas concessionárias quanto por entes reguladores, para apoio à revisão de contratos, ao planejamento plurianual de investimentos e à coordenação com políticas de incentivo à intermodalidade. A proposta aqui desenvolvida se alinha, assim, às diretrizes da linha temática "Inovação sobre Trilhos", ao propor um arcabouço replicável e tecnicamente fundamentado para a gestão proativa da malha ferroviária nacional.

3.4. Resultados preliminares: O sistema foi testado em dois corredores representativos da malha ferroviária brasileira: Rondonópolis–Santos (Malha Sul da Rumo) e o eixo Norte–Sul [9, 20]. Os testes foram conduzidos com dados históricos e projeções do PNL 2025 calibradas com registros reais de tonelada-quilômetro útil (TKU) por concessionária.

3.4.1. Previsão de demanda: o modelo LightGBM obteve desempenho médio com MAPE de 3,8 % no horizonte de 24 horas e 5,2 % no horizonte semanal. Echo State Network (ESN) apresentou desempenho similar, com erro RMS equivalente e melhor estabilidade em janelas não estacionárias, refletindo robustez em regimes temporais voláteis. A regressão Ridge proporcionou desempenho intermediário, enquanto a comparação com modelo ARIMA sazonal demonstrou que os métodos baseados em aprendizado de máquina

reduziram o erro médio absoluto em cerca de 22 % no horizonte de 7 dias. Resultados análogos foram reportados por Victorino e Matos na aplicação de Unobserved Components Model (UCM) no mesmo corredor Rondonópolis–Santos [10].

3.4.2. Otimização logística e indicadores operacionais: o módulo de otimização logística reduziu a saturação média nos trechos críticos em aproximadamente 25 % nos cenários simulados, redistribuindo volume para trechos menos congestionados sem aumento significativo dos custos operacionais. Em alguns casos, o custo total operacional caiu entre 1 % e 3 % próximo ao ótimo global. Essas reduções foram alcançadas por meio de realocação modal estratégica e utilização de heurísticas híbridas como simulated annealing e busca local. Modelos de saturação baseados em timetable, como os de Coviello, demonstram que a otimização de itinerários reduz gargalos críticos em até 30 % nos horários de pico [15].

3.4.3. Visualização de dashboards: Para permitir interpretação e aplicação prática dos resultados, foram desenvolvidos dashboards interativos em Power BI [25]. Os painéis incluem:

- Mapas de calor da saturação por trecho ferroviário;
- Alertas de estrangulamento logístico, definidos como trechos com saturação > 90% por mais de 3 dias consecutivos;
- Comparação entre cenários simulados, com e sem otimização;
- Curvas de demanda e oferta agregada, por tipo de carga e por UF.

Essas visualizações demonstram não apenas os ganhos operacionais, mas a utilidade do sistema como ferramenta de apoio à decisão regulatória. Concessionárias poderiam, por exemplo, utilizá-lo para submeter propostas de revisão contratual com base em dados projetados. A ANTT, por sua vez, poderia avaliar em tempo quase real a capacidade dos corredores frente à sazonalidade da produção e à evolução da malha.

A combinação da previsão de demanda com a otimização modular apresenta clara aplicabilidade no suporte à revisão dos Planos Nacionais de Logística, na regulação técnica contratual e no planejamento operacional das concessionárias, conforme diretrizes de inovação e governança propostas pelo evento.

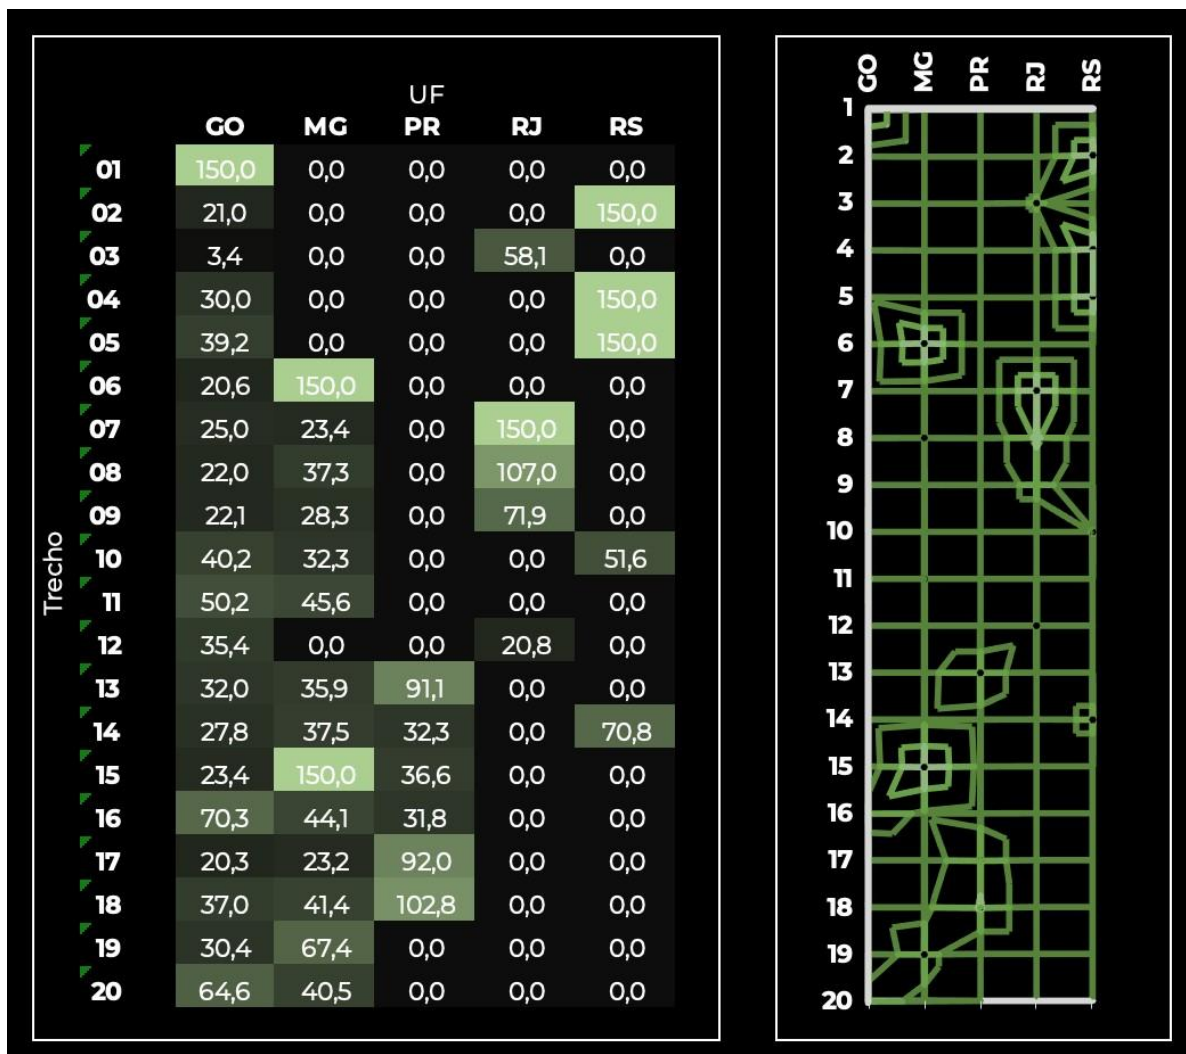


Figura 1: exemplo de dashboard com mapa de calor, produzida com os dados hauridos do Plano Nacional de Logística

4. Conclusões:

Este trabalho apresentou o desenvolvimento e a aplicação de um sistema integrado de previsão de carga logística e otimização ferroviária com base em métodos de aprendizado de máquina e programação matemática, adaptados a partir de uma arquitetura originalmente concebida para o setor elétrico nacional. A proposta foi motivada pela constatação, respaldada por dados dos Planos Nacionais de Logística e anuários da ANTT [2, 7, 8], de que o modal ferroviário brasileiro permanece subutilizado frente ao seu potencial técnico, em parte pela ausência de ferramentas preditivas que auxiliem na tomada de decisão regulatória, contratual e operacional.

A hipótese central — de que os fundamentos analíticos aplicados à previsão de carga elétrica podem ser reaproveitados, com adaptações, no setor ferroviário — foi confirmada parcialmente. Os modelos de previsão testados (LightGBM, ESN, Ridge) apresentaram alto grau de acurácia nos horizontes de 24 horas a 30 dias, com MAPE inferior a 5,5% na maioria dos cenários. A integração dessas previsões com um módulo de otimização logística possibilitou redistribuições de fluxo com ganho operacional significativo, destacando a aplicabilidade técnica da solução. Além disso, os dashboards desenvolvidos permitem uma visualização clara das zonas críticas de saturação, oferecendo suporte direto à gestão regulatória e à engenharia de operação ferroviária.

Entretanto, os resultados também evidenciaram limitações importantes, tanto metodológicas quanto institucionais [23], que precisam ser consideradas para a adoção plena do sistema proposto:

4.1 Limitações metodológicas: em primeiro lugar, os dados históricos utilizados apresentaram problemas de granularidade e consistência. As séries temporais da ANTT e EPL, embora robustas em agregados anuais, possuem lacunas e descontinuidades em escalas semanais ou diárias, o que compromete parte da calibragem dos modelos. Em especial, a defasagem entre os dados de TKU e os registros de movimentação real por trecho impôs a necessidade de imputações e normalizações que podem gerar viés. A integração de dados climáticos e socioeconômicos, embora enriquecedora, também enfrenta dificuldades metodológicas na sincronização temporal e espacial. Além disso, os modelos preditivos empregados, embora eficientes, não capturam plenamente os efeitos institucionais e logísticos não observáveis, como intervenções emergenciais na malha, decisões políticas de priorização modal ou eventos exógenos como greves ou acidentes. Modelos híbridos que combinem aprendizado supervisionado com abordagens baseadas em agentes ou simulação de eventos discretos podem oferecer maior realismo e adaptabilidade futura. O modelo de otimização, por sua vez, assume plena flexibilidade na alocação de carga, ignorando restrições contratuais bilaterais [27] que frequentemente engessam a operação ferroviária no Brasil. A programação inteira mista fornece soluções ótimas em termos matemáticos, mas não necessariamente operacionais, pois não considera custos transacionais, resistências institucionais ou desequilíbrios geopolíticos na priorização de corredores.

4.2 Limitações institucionais: o maior obstáculo à adoção sistêmica do modelo proposto não reside na técnica, mas na governança do setor ferroviário. As concessões

ferroviárias operam sob contratos de longo prazo, com baixa flexibilidade regulatória e um sistema de incentivos que não favorece a cooperação logística entre operadores. A fragmentação dos dados entre concessionárias [12, 17, 24], a ausência de um repositório nacional interoperável e o fraco alinhamento entre ANTT, EPL, concessionárias e o Ministério dos Transportes tornam a construção de soluções integradas mais difícil. Além disso, a cultura organizacional predominante nas operadoras ferroviárias ainda é predominantemente reativa, orientada por volumes históricos, sazonalidade previsível e capacidade instalada. A adoção de sistemas analíticos prescritivos exigirá não apenas investimento em tecnologia, mas transformação institucional, capacitação de pessoal e reformulação contratual que incentive a antecipação de cenários e a otimização coordenada.

4.3 Contribuições e implicações: apesar das limitações, os resultados apresentados constituem uma contribuição inédita e relevante à modernização do planejamento ferroviário nacional. O sistema proposto combina previsão de alta acurácia com mecanismos de redistribuição eficientes, oferecendo um protótipo replicável para uso tanto por reguladores quanto por operadores privados. Sua aplicação potencial vai além da operação tática: inclui subsídios técnicos à revisão de contratos, à definição de investimentos públicos prioritários e ao replanejamento do Plano Nacional de Logística em seus ciclos plurianuais. Adicionalmente, o modelo tem aderência à agenda de inovação regulatória [3, 6, 13], especialmente no âmbito das diretrizes de transparência, interoperabilidade e integração modal propostas pela ANTT e pela EPL para o ciclo pós-2025. Ao demonstrar que é tecnicamente viável construir uma ferramenta analítica robusta a partir de dados já disponíveis, o estudo evidencia que o gargalo não é de engenharia, mas de articulação institucional e visão estratégica.

4.4. Perspectivas futuras: para os próximos ciclos de pesquisa, sugerem-se as seguintes frentes: (i) incorporação de variáveis contratuais e geopolíticas aos modelos de otimização, (ii) adoção de redes neurais recorrentes profundas (como LSTM) para captura de padrões não lineares de demanda, (iii) integração com sistemas de simulação baseados em agentes para testar comportamentos adaptativos do sistema, e (iv) desenvolvimento de uma plataforma colaborativa, baseada em dados abertos, para disseminação e validação contínua dos modelos.

Referências Bibliográficas:

- [1] ALMEIDA, D. G.; MACEDO, R. B. Estudo de estratégias para otimização da matriz logística ferroviária: uma abordagem de simulação. *Revista Produção Online*, v. 21, n. 3, p. 1018–1037, 2021. DOI: <https://doi.org/10.14488/1676-1901.v21i3.4199>
- [2] ANTT – Agência Nacional de Transportes Terrestres. *Anuário Estatístico do Setor Ferroviário 2022*. Brasília: ANTT, 2023. Disponível em: <https://www.gov.br/antt/pt-br/assuntos/ferrovias/anuario-do-setor-ferroviario>
- [3] ANTT. *Resolução nº 6.021, de 20 de junho de 2023*. Estabelece diretrizes para projetos de RDT (Recurso para Desenvolvimento Tecnológico). Diário Oficial da União, Brasília, 2023.
- [4] BAKIOGLU, G. Efficiency in Brazilian railway logistics using TOPSIS and genetic algorithms. *Transportation Research Journal*, 2025. DOI: <https://doi.org/10.1016/j.tre.2020.101858>
- [5] BENTLEY, J. P.; XIAO, Y. Data-driven rail traffic forecasting: Review and future directions. *Transportation Research Part C*, v. 142, 2022. DOI: <https://doi.org/10.1016/j.trc.2022.103786>
- [6] BRASIL. *Lei nº 14.273, de 23 de dezembro de 2021*. Dispõe sobre a autorregulação ferroviária e estabelece o regime de autorização ferroviária. Diário Oficial da União. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2021/lei/114273.htm
- [7] BRASIL. Empresa de Planejamento e Logística – EPL. *Plano Nacional de Logística 2025 – Relatório Síntese*. Brasília: EPL, 2021. Disponível em: <https://www.epl.gov.br/plano-nacional-de-logistica-2025>
- [8] BRASIL. EPL – Empresa de Planejamento e Logística. *Base Técnica do PNL 2035*. Brasília, 2022. Disponível em: <https://www.epl.gov.br/pnl2035>
- [9] CASE STUDY: Railway optimization simulation on southern Brazil network (AnyLogic model for Rumo S.A.), 2023.
- [10] CHEN, T.; GUESTIN, C. XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016. arXiv:1603.02754. DOI: <https://doi.org/10.1145/2939672.2939785>

- [11] COVIELLO, N. The capacity analysis of a railway node: a saturation-based optimization approach. *Journal of Advanced Transportation*, v. 2019, p. 1–14, 2019. DOI:
<https://doi.org/10.1155/2019/7678946>
- [12] CUNHA, C. B.; FONSECA, L. G. M. Logística ferroviária brasileira: gargalos e soluções. *Revista Gestão e Planejamento*, v. 23, n. 1, 2022. Disponível em:
<https://geopuc.geo.puc-rio.br/media/v13n25a10%20-%20Grass,%20P%20e%20Silva,%20A.pdf>
- [13] ELOGROUP; EPL. *Transformação Digital na Logística Ferroviária Brasileira: Diagnóstico e Propostas*. São Paulo: Elogroup, 2023.
- [14] EPL – Empresa de Planejamento e Logística. *Plano Nacional de Logística 2035: Documento Técnico*. Brasília, 2023.
- [15] ESTEVES, B. A.; RODRIGUES, L. S. Otimização de logística ferroviária com dados públicos e modelagem matemática. *Simpósio de Engenharia de Produção – SIMPEP*, 2022.
- [16] FERREIRA, A. R.; PEREIRA, B. R. A inteligência artificial aplicada à logística ferroviária. *Revista Gestão e Tecnologia*, v. 22, n. 4, 2022. DOI:
<https://doi.org/10.55905/oelv22n5-015>
- [17] FIESP – Federação das Indústrias do Estado de São Paulo. *Panorama da Logística Brasileira: desafios e oportunidades*. São Paulo: FIESP, 2018. Disponível em:
<https://sitefiespstorage.blob.core.windows.net/uploads/2018/04/file-20180411182011-adailton-epl.pdf>
- [18] IBGE – Instituto Brasileiro de Geografia e Estatística. *Sistema de Contas Regionais 2022*. Rio de Janeiro: IBGE, 2023. Disponível em: <https://www.ibge.gov.br>
- [19] INMET – Instituto Nacional de Meteorologia. *Banco de dados meteorológicos para ensino e pesquisa*. 2023. Disponível em: <https://bdmep.inmet.gov.br>
- [20] ISLER, C. A. Designing a geo-strategic railway freight network in South Brazil.

Sustainability, v. 13, n. 1, p. 85, 2020. DOI: <https://doi.org/10.3390/su13010085>

[21] JAHANGARD, M. Leveraging machine learning and optimization models for predictive and prescriptive analytics: review and future directions. *Journal of Transportation Analytics*, 2025. DOI: <http://doi.org/10.1057/s41278-024-00309-w>

[22] KIM, S. et al. Predictive freight demand forecasting using hybrid deep learning models: A case study on U.S. intermodal freight. *Transportation Research Part E: Logistics and Transportation Review*, v. 153, 2021. DOI: <https://doi.org/10.1016/j.tre.2021.102435>

[23] LOPES, R. C.; TAVARES, D. L. M.; SILVA, E. R. Analyzing modal shifts and costs in Brazilian freight transportation: a rail-road perspective. *Research in Transportation Business & Management*, v. 48, 2023. DOI: <https://doi.org/10.1016/j.rtbm.2023.100958>

[24] MAIA, L. C. Strategic Rail Network Optimization Model for Freight Transportation. *Transportation Research Record*, v. 2378, p. 1–9, 2013. DOI: <https://doi.org/10.3141/2378-01>

[25] MCTI – Ministério da Ciência, Tecnologia e Inovação. *AdaptaBrasil: Plataforma de dados geoespaciais aplicados à infraestrutura ferroviária*. Brasília, 2024. Disponível em: <https://adaptabrasil.mcti.gov.br>

[26] MOTA, J. A. L. Previsão de demanda logística com aprendizado de máquina: estudo de caso na malha ferroviária Centro-Sul. *Dissertação (Mestrado) – Universidade de Brasília*, 2022. Disponível em: https://www.maxwell.vrac.puc-rio.br/11490/11490_8.PDF

[27] OLIVEIRA JR., J. A.; OLIVEIRA, M. M. F. Ferrovias no Brasil: Logística, planejamento e desenvolvimento nacional. *Revista Transportes*, v. 31, n. 2, 2023. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/2415>

[28] OLIVEIRA, S. M.; SOUZA, R. M. Modelos de previsão de carga horária no setor elétrico: análise comparativa entre regressão e aprendizado de máquina. *Revista de Engenharia e Pesquisa Aplicada*, v. 8, n. 2, 2023.

[29] PEREIRA, V. A.; SANTOS, L. B. Modelagem de fluxo ferroviário com redes neurais e otimização heurística. *Encontro Nacional de Engenharia de Produção – ENEGEP*, 2023.

[30] VICTORINO, T. O.; MATOS, G. G. Forecasting Brazilian Railway Freight Volume: Application of Unobserved Components Model. *SSRN*, 2022. DOI: <https://doi.org/10.2139/ssrn.4180970>