


UNIVERSIDADE FEDERAL DO PARANÁ

CAMILA CRISTINA GONÇALVES TEIXEIRA LEITE MOSCIBROCKI

MODELAGEM DE ENGATES FERROVIÁRIOS EM TRENS DE CARGA
PARA GESTÃO DE CONDUÇÃO

CURITIBA

2025



CAMILA CRISTINA GONÇALVES TEIXEIRA LEITE MOSCIBROCKI

MODELAGEM DE ENGATES FERROVIÁRIOS EM TRENS DE CARGA
PARA GESTÃO DE CONDUÇÃO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do grau de Mestre em Engenharia Mecânica.

Orientador: Prof. Eduardo M. O. Lopes, PhD
Coorientador: Prof. Eduardo L. O. Batista, Dr.Eng.

CURITIBA

2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Moscibrocki, Camila Cristina Gonçalves Teixeira Leite
Modelagem de engates ferroviários em trens de carga para gestão de
condução / Camila Cristina Gonçalves Teixeira Leite Moscibrocki. – Curitiba,
2025.

1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de
Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica.

Orientador: Eduardo Márcio de Oliveira Lopes

Coorientador: Eduardo Luiz Ortiz Batista

1. Ferrovias. 2. Engates. 3. Aprendizagem do computador. 4. Redes
neurais (Computação). I. Universidade Federal do Paraná. II. Programa de
Pós-Graduação em Engenharia Mecânica. III. Lopes, Eduardo Márcio de
Oliveira. IV. Batista, Eduardo Luiz Ortiz. V. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
MECÂNICA - 40001016040P5

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA MECÂNICA da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **CAMILA CRISTINA GONÇALVES TEIXEIRA LEITE MOSCIBROCKI**, intitulada: **MODELAGEM DE ENGATES FERROVIÁRIOS EM TRENS DE CARGA PARA GESTÃO DA CONDUÇÃO**, sob orientação do Prof. Dr. EDUARDO MÁRCIO DE OLIVEIRA LOPES, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa. A outorga do título de mestra está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 29 de Agosto de 2025.

Assinatura Eletrônica

02/09/2025 10:12:09.0

EDUARDO MÁRCIO DE OLIVEIRA LOPES

Presidente da Banca Examinadora

Assinatura Eletrônica

01/09/2025 14:23:55.0

JOSÉ MANOEL BALTHAZAR

Avaliador Externo (UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO)

Assinatura Eletrônica

01/09/2025 17:20:11.0

GIULIANA SARDI VENTER

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

RESUMO

O aumento da demanda por trens de carga mais longos e pesados no setor ferroviário impõe tensões dinâmicas elevadas sobre os engates, que fazem a conexão entre os vagões, potencializando riscos de falhas operacionais e comprometendo a integridade desses componentes. Para mitigar tais desafios, este trabalho propõe o desenvolvimento de um modelo de comportamento dinâmico dos engates ferroviários, focado na gestão de condução e previsão de esforços críticos. O estudo aborda a modelagem dos engates e emprega técnicas de aprendizagem de máquina, com o uso de redes neurais artificiais (RNA), para diagnosticar comportamentos prejudiciais durante a operação. Os dados utilizados para a modelagem são obtidos por sensores instalados nos engates, fornecendo informações sobre esforços de tração e compressão, especialmente em trechos caracterizados por altimetria variável e curvas acentuadas. A metodologia aplicada combina o pré-processamento dos dados, a modelagem dos engates e a integração com algoritmos de aprendizado supervisionado, permitindo a identificação de padrões que indicam esforços críticos. Os resultados obtidos apontam para a melhoria na vida útil dos engates e maior eficiência na condução ferroviária. Espera-se contribuir ainda para a prevenção de falhas, possibilitando a adoção de medidas proativas e reforçando a segurança e a eficiência no transporte ferroviário.

Palavras-chave: Engates ferroviários, Modelagem dinâmica, Aprendizagem de máquina, Redes neurais artificiais, Gestão de condução.

ABSTRACT

The increasing demand for longer and heavier freight trains in the railway sector imposes high dynamic stresses on couplers, which make the connection between the wagons, escalating the risk of operational failures and compromising the integrity of these components. To address these challenges, this study proposes the development of a dynamic behavior model for railway couplers, focused on operational management and the prediction of critical forces. The research includes the modeling of couplers and the application of machine learning techniques, specifically artificial neural networks (ANN), to diagnose harmful behaviors during train operations. Data for the model are collected from sensors installed on the couplers, providing information on traction and compression forces, particularly in segments characterized by variable altimetry and sharp curves. The methodology combines data preprocessing, coupler modeling, and integration with supervised learning algorithms, enabling the identification of patterns indicative of critical forces. The obtained outcomes point to the extension of coupler lifespan and increased operational efficiency in train management. Further contributions to failure prevention are also expected, supporting proactive measures and enhancing safety and efficiency in railway transportation.

Keywords: Railway couplers, Dynamic modeling, Machine learning, Artificial neural networks, Operational management.

LISTA DE FIGURAS

FIGURA 1 – Veículos interligados em uma composição ferroviária.....	20
FIGURA 2 – Funcionamento dos sistemas de tração CA e CC.....	21
FIGURA 3 – Funcionamento do sistema de frenagem pneumática	22
FIGURA 4 – Conjunto de choque e tração de um engate tipo “E”	23
FIGURA 5 – Conjunto de choque e tração de um engate tipo “F”.....	24
FIGURA 6 – Exemplo de um mapa topográfico de via.	27
FIGURA 7 – Exemplo de diagrama de distribuição de esforços.	28
FIGURA 8 – Ocorrência de quebra de mandíbula e arrancamento de longarina.....	30
FIGURA 9 – Detalhamento estrutural do vagão.....	30
FIGURA 10 – Posicionamento dos sensores na longarina e corpo do engate (vista lateral, mostrando SG1).	32
FIGURA 11 – Posicionamento dos sensores na longarina e corpo do engate (vista de topo, com extensômetros SG2 e SG3).....	33
FIGURA 12 – Calibração do canal de deflexão do engate	34
FIGURA 13 – Esforços no engate “F” entre Santos e Rondonópolis.	34
FIGURA 14 – Legenda utilizada para escala de forças no engate	35
FIGURA 15 – Leitura de velocidade, esforço no engate F, flexão do engate, curso do ACT e pressão no encanamento geral no trecho Rondonópolis (MT) – Santos (SP).....	36
FIGURA 16 – Gráfico de operação da locomotiva líder.....	37
FIGURA 17 – Esforço de frenagem dinâmica de uma locomotiva AC44	38
FIGURA 18 – Perfil de rampa e raios para o trecho 1	41
FIGURA 19 – Esquema de funcionamento de um ACT por fricção	43
FIGURA 20 – Ciclo de histerese típico de um ACT	44
FIGURA 21 – Ciclo do ACT Mark 70E.....	45
FIGURA 22 – Ciclo do ACT Endurance 325.....	46
FIGURA 23 – Modelo com 1 grau de liberdade e não linearidade cúbica.....	48
FIGURA 24 – Modelo com 2 graus de liberdade	60
FIGURA 25 – Modelo com 1 grau de liberdade e não linearidade cúbica.....	60
FIGURA 26 – Curva original com as linhas de carregamento (vermelho) e descarregamento (azul).....	61
FIGURA 27 – Máscara lógica aplicada à curva de histerese do ACT.....	61

FIGURA 28 – Divisão entre conjunto de dados	63
FIGURA 29 – Curva de histerese, regenerada e expandida, do ACT Endurance 325.	68
FIGURA 30 – Curva força x curso com ajuste polinomial cúbico da curva média.	69
FIGURA 31 – Deslocamento x Tempo (Excitação Medida).	70
FIGURA 32 – Velocidade x Tempo (Excitação Medida).	70
FIGURA 33 – Deslocamento x Tempo (Excitação Tipo Degrau).	71
FIGURA 34 – Velocidade x Tempo (Excitação Tipo Degrau).	71
FIGURA 35 – Deslocamento x Tempo (Excitação Harmônica).....	72
FIGURA 36 – Velocidade x Tempo (Excitação Harmônica).....	72
FIGURA 37 – Deslocamento x Tempo (Excitação Impulsiva).	72
FIGURA 38 – Velocidade x Tempo (Excitação Impulsiva).	72
.FIGURA 39 – Comparativo Linear vs. Não Linear – Deslocamento e Velocidade	73
FIGURA 40 – FRF – Amplitude e Fase	73
FIGURA 41 – Comparação deslocamentos simulados vs. reais (Compressão – trechos 3, 5, 6 e 7).....	75
Figura 42 – Comparação deslocamentos simulados vs. reais (Tração – trechos 1, 2 e 4).	76
Figura 433 – Comparação deslocamentos simulados vs. reais (rigidez aumentada em tração).	77
FIGURA 44 – Comparação entre valores reais e previstos pela RNA (modelo inicial, menos neurônios).	78
FIGURA 45 – Comparação entre valores reais e previstos pela RNA (modelo aperfeiçoado).....	78
FIGURA 46 – Convergência da função perda (MSE) e do MAE durante o treinamento da RNA.....	80
FIGURA 47 – Variáveis mais influentes nos esforços.....	81
FIGURA 48 – Influência de variáveis para os esforços de tração.....	83
FIGURA 49 – Influência de variáveis para os esforços de compressão	84
FIGURA 50 – Impacto da redução de 50% da velocidade nos esforços longitudinais.	85
FIGURA 51 – Simulação multivariável com redução coordenada de parâmetros operacionais.	85
FIGURA 52 – Alerta de esforço crítico.....	87

SUMÁRIO

1. INTRODUÇÃO	12
1.1. CONTEXTUALIZAÇÃO	12
1.2. ESTADO DA ARTE	13
1.3. OBJETIVOS	16
1.3.1. Objetivo Geral	17
1.3.2. Objetivos Específicos	17
1.4. ORGANIZAÇÃO DO TEXTO.....	18
2. FUNDAMENTOS TEÓRICOS E EXPERIMENTAIS.....	19
2.1. INFLUÊNCIAS NA DINÂMICA DE UM TREM DE CARGA	19
2.1.1. Composição de veículos	19
2.1.2. Sistema de tração	20
2.1.3. Sistema de frenagem	21
2.1.4. Conjunto de choque e tração (CCT).....	23
2.1.5. Altimetria de via.....	25
2.1.6. Operação e condução	27
2.2. USO DE DADOS EXPERIMENTAIS	31
2.2.1. Configuração dos sensores.....	32
2.2.2. Parâmetros operacionais para esforços	33
2.2.3. Análise preliminar de dados	35
2.3. INFORMAÇÕES DE OPERAÇÃO E CONDUÇÃO DE TRENS.....	37
2.3.1. Variáveis pertinentes à análise das viagens.....	37
2.3.2. Altimetria do trecho selecionado.....	40
2.4. MODELAGEM MATEMÁTICA.....	41
2.4.1. Caracterização do ACT	41
2.4.2. Formulação e resolução de equação de movimento	47
2.5. APRENDIZAGEM SUPERVISIONADA	50
2.5.1. Estruturação dos dados e pré-processamento	51
2.5.2. Atributos de entrada e saída do modelo.....	51
2.5.3. Obtenção de previsões da RNA.....	52
2.6. INTEGRAÇÃO ENTRE MODELOS	54
3. MATERIAIS E MÉTODOS	56
3.1. ETAPAS METODOLÓGICAS.....	56
3.2. DADOS, MATERIAIS E MEIOS UTILIZADOS.....	58
3.3. MODELO MATEMÁTICO NÃO LINEAR.....	59
3.3.1. Modelagem de ACT via curva de histerese	61

3.3.2.	Resolução numérica de equações de movimento	62
3.4.	MODELO DA REDE NEURAL ARTIFICIAL (RNA).....	63
3.4.1.	Treinamento e validação do modelo	63
3.4.2.	Funcionamento da RNA	65
3.4.3.	Estrutura e configuração da rede	66
3.4.4.	Considerações complementares	67
4.	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	68
4.1.	MODELAGEM MATEMÁTICA.....	68
4.1.1.	Parâmetros para simulação numérica	68
4.1.2.	Simulações dinâmicas com o método de Runge-Kutta	70
4.1.3.	Análise no domínio da frequência	73
4.1.4.	Validação com dados reais de deslocamento	74
4.2.	MODELAGEM VIA REDE NEURAL ARTIFICIAL	78
4.2.1.	Desenvolvimento progressivo da arquitetura da RNA	78
4.2.2.	Análise da convergência de treinamento.....	79
4.2.3.	Análise de importância das variáveis	80
4.2.4.	Análise de casos extremos.....	81
4.2.4.1.	Esforços positivos (tração).....	82
4.2.4.2.	Esforços negativos (compressão)	83
4.2.5.	Aplicabilidade da RNA por simulações, alertas e ferramenta prática	85
4.2.5.1.	Simulações operacionais	85
4.2.5.2.	Sistema inteligente de alertas preventivos	86
4.2.5.3.	Ferramenta prática interativa de previsão de esforços.....	87
4.2.6.	Limitações de aplicação e replicabilidade.....	88
5.	CONSIDERAÇÕES FINAIS	90
6.	REFERÊNCIAS	92

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

O transporte ferroviário é um pilar vital na logística de transporte de cargas, que variam de minerais até grãos. O crescente aumento na demanda por esse tipo de serviço tem impulsionado o desenvolvimento de trens de carga mais longos e pesados, resultando em cargas dinâmicas consideravelmente maiores em equipamentos ferroviários, especialmente sobre os engates, que são dispositivos de acoplamento entre vagões.

Recentemente, tem-se observado um aumento nos incidentes de falha de engates e arrancamento de longarinas em trens de carga, principalmente atribuídos ao estresse dinâmico gerado por condições operacionais variáveis (ANTF, 2014). Uma compreensão aprofundada dos fatores que contribuem para altos valores de choque e esforço nos engates, bem como para a frequência destas ocorrências, é crucial para o desenvolvimento de estratégias eficazes de mitigação e aumento de vida útil desses componentes críticos.

As quebras de engates e os arrancamentos de longarinas representam um desafio significativo para as empresas ferroviárias, resultando em interrupções operacionais e custos substanciais associados à manutenção e ao tempo de inatividade não planejado. O aumento do peso dos trens, juntamente com as condições operacionais adversas, como a variação da altimetria da via, rampas agressivas e raios de curva reduzidos, contribui para o estresse dinâmico sobre os engates, levando à fadiga e à deformação plástica ao longo do tempo.

No entanto, a análise da integridade dos engates ferroviários é predominantemente reativa, identificando falhas apenas após ocorrência. Há a necessidade de um enfoque proativo que permita a identificação precoce de comportamentos operacionais prejudiciais bem como a implementação de medidas corretivas antes que falhas catastróficas ocorram.

Tendo em vista os pontos destacados acima, busca-se com este trabalho construir um modelo do comportamento dinâmico de engates ferroviários em trens de carga, com base em informações acerca dos esforços atuantes. Busca-se também empregar técnicas de aprendizado de máquina para diagnosticar comportamentos

operacionais prejudiciais de condução, que contribuem para a degradação dos engates.

1.2. ESTADO DA ARTE

Em Zhang, Huang e Yan et al.(2024), é proposta uma abordagem baseada em dados obtidos sob diversas condições de operação para monitorar as forças dentro dos trens ferroviários, fazendo uso da tecnologia de operação automática de trens (ATO) e de modelos de redes neurais convolucionais. Os autores ressaltam a importância das forças internas em um trem de carga para a avaliação do desempenho dos vagões. Diferentemente de estudos que utilizam exclusivamente dados oriundos de instrumentações, os sistemas de operação automática de trens (ATO) considerados no estudo em questão apresentam o potencial de fornecer informações em tempo real sobre os trens e suas condições de pista por meio de dispositivos a bordo e na infraestrutura ao longo da via, permitindo assim o monitoramento contínuo das forças internas.

Ainda no estudo acima, foram inicialmente realizadas simulações da dinâmica longitudinal dos trens de carga para estabelecer a relação entre os dados obtidos via tecnologia ATO e as forças internas nos engates específicos dos vagões, utilizando uma grande quantidade de dados de treinamento. Em seguida, foi empregada uma rede neural convolucional causal baseada em autoatenção (SA-CNN) entre o histórico de quebra de engates e os registros obtidos a partir da primeira instrumentação de forças nos engates, considerando as dependências temporais. Os dados simulados foram gerados utilizando Simulações de Dinâmica Longitudinal de Trens (LTSS - Longitudinal Train Dynamics Simulations)

Comparando com outros modelos de rede neural, como rede convolucional 1D (CNN), rede recorrente (LSTM), rede híbrida CNN-LSTM, rede convolucional temporal (TCN) e rede baseada em atenção causal convolucional (SA-CNN), a rede SA-CNN apresentou uma precisão maior na estimativa dos esforços. Além disso, a capacidade de generalização do modelo SA-CNN bem treinado foi confirmada por meio de simulações numéricas relativas a quatro condições de serviço diferentes.

Os resultados indicam que a abordagem baseada em dados possui uma compatibilidade superior para entradas combinadas de forma arbitrária, com tempo de computação significativamente reduzido em comparação com as simulações de

dinâmica longitudinal dos trens. De forma semelhante ao pretendido no presente trabalho, os autores utilizam dados em tempo real e modelagem por rede neural para melhorar a compreensão e a previsão das forças atuantes em engates em diversas condições de operação.

Em Wu et al. (2023), aborda-se a detecção de trincas em engates de vagões ferroviários utilizando análise por ultrassom e redes neurais artificiais. Os autores destacam a importância da análise não-destrutiva por ultrassom para inspecionar os engates dos vagões, visando identificar trincas críticas que possam comprometer a integridade estrutural e a segurança do trem durante a operação.

O estudo acima propõe um modelo de rede neural artificial treinado com dados de histórico de análises anteriores, capaz de prever com alto grau de confiabilidade a presença de trincas críticas nos engates, a partir dos relatórios do equipamento de ultrassom. Verifica-se que a aplicação de técnicas de aprendizado de máquina possibilita uma detecção mais precisa de trincas, contribuindo para a manutenção preditiva e a prevenção de falhas nos engates ferroviários.

Barbosa (1993) e Oliveira Junior (2017) investigam a dinâmica longitudinal de trens e as forças envolvidas nos aparelhos de choque e tração entre os vagões, apresentando métodos de modelagem matemática para estudar o comportamento pertinente. É destacada a importância de modelos precisos para compreender o comportamento do sistema, a fim de entender a operação de um trem sob diferentes condições operacionais.

Os autores ora mencionados descrevem e modelam os elementos mecânicos longitudinais (conjuntos de engates e aparelhos de choque), bem como os sistemas que compõem a suspensão dos vagões (truques, pacote de molas, cunha de fricção e rodeiros), utilizando, para obtenção de respostas, dois procedimentos de resolução: integração numérica com elementos não lineares e método analítico linear. Em particular, estuda-se o comportamento de interesse durante processos de frenagem e partida.

Os resultados alcançados naqueles trabalhos fornecem uma compreensão dos efeitos das forças externas sobre o sistema, com base nas respostas associadas a essas forças. Eles permitem avaliar o desempenho de engates sob diferentes condições operacionais, ajudando no desenvolvimento de estratégias de mitigação de falhas e prolongamento da vida útil.

Oliveira Junior (2017) avalia ainda a interação entre os sistemas de freio pneumático e os componentes de choque e tração dos vagões. Esse autor desenvolve modelos computacionais para simular o comportamento dos aparelhos de choque e tração sob diferentes condições operacionais, como frenagem e aplicação de carga motriz. Esses modelos são necessários para compreender os esforços e impactos gerados durante a operação, principalmente se alimentados com dados reais das condições de condução da composição como um todo.

Pensando em explorar a integridade dos engates como parte do sistema de acoplamento, Gao et al. (2020) e Kim e Park (2018) apresentam soluções para o monitoramento de condições de pré-carga e avaliação do desempenho dos sistemas de choque e tração em engates. Gao et al. (2020), em específico, abordam a necessidade de monitoramento de sensores autossuficientes em vagões ferroviários. Esses autores propõem um modelo de simulação para prever a resposta à vibração dos vagões e desenvolvem um sistema de colheita de energia vibracional para alimentar sensores de monitoramento, fornecendo informações sobre como a condição dos engates afeta a precisão e confiabilidade do monitoramento de sensores em vagões ferroviários.

Após a etapa de implementação dos sensores, o estudo de Gao et al. (2020) se aprofunda no sistema de monitoramento de saúde estrutural para acopladores ferroviários, visando melhorar a eficiência das inspeções e a precisão na detecção de danos. Os autores propõem um sistema baseado em sensores piezoelétricos montados nos acopladores, capaz de realizar inspeções em tempo real durante a operação do trem.

No trabalho de Amaral (2021), propõe-se a utilização de um algoritmo baseado em redes neurais de aprendizado contínuo, para detectar de maneira preventiva os esforços nocivos à integridade dos engates em trens de passageiros. Consideram-se acoplamentos realizados virtualmente através de uma central de controle, sem a necessidade de acompanhamento de manobreadores ou operadores ferroviários em campo. Esse tipo de acoplamento ocorre entre vagões reais em pátio, porém com controle a distância por um operador na central de controle.

Os autores exploram técnicas de controle para melhorar a eficiência e segurança do acoplamento virtual em sistemas ferroviários, revisando diferentes técnicas de controle e classificando-as em cinco grupos distintos, com discussão das vantagens e desvantagens para aplicações de acoplamento virtual. Considerando que

o desempenho do acoplamento virtual pode ser influenciado pela condição dos engates reais, entende-se que a modelagem de engates ferroviários em trens de carga para gestão de condução, aqui proposta, pode fornecer estratégias mais eficazes de controle e operação dos sistemas ferroviários.

Em Bernal et al. (2024), utiliza-se um modelo desenvolvido a partir de dados de dinâmica de multicorpos, captados por instrumentação, e técnicas de aprendizado de máquina para prever o risco de descarrilamento em tempo real. Considera-se, de forma complementar, a integridade dos engates ferroviários como parte do sistema ferroviário, correlacionando o impacto de forças longitudinais com a estabilidade dos veículos em movimento.

Ao considerar a integridade dos engates em conjunto com outros aspectos da operação ferroviária, como a dinâmica do trem e o risco de descarrilamento, o trabalho dos autores enfocados anteriormente contribui para uma compreensão mais abrangente e precisa da segurança e eficiência do sistema ferroviário como um todo. Os dados adicionais fornecidos sobre a condição dos engates possibilitam não só melhorar a precisão das previsões de risco de descarrilamento como também obter uma resposta mais proativa a potenciais problemas de segurança.

Os estudos revisados anteriormente apresentam avanços significativos. Entretanto, destaca-se que ainda existem lacunas importantes no entendimento e previsão do impacto das condições de operação sobre os engates ferroviários.

Modelos como o de Zhang et al. (2024) utilizam simulações LTSs e redes neurais para estimar forças longitudinais, mas não exploram de forma detalhada como essas forças afetam a degradação e a vida útil dos componentes de acoplamento. Além disso, a dependência de dados simulados, sem validação extensiva em campo, limita a aplicabilidade prática dos resultados, especialmente em cenários operacionais mais complexos, como composições ferroviárias longas ou condições extremas de condução. Outros trabalhos, como os de Wu et al. (2023) e Gao et al. (2020), focam na detecção de falhas e monitoramento, mas carecem de uma análise integrada que conecte a dinâmica longitudinal e o envelhecimento dos engates.

1.3. OBJETIVOS

Este projeto visa desenvolver um modelo de comportamento dinâmico dos engates ferroviários que permita compreender e prever os impactos das condições de

condução nos componentes de acoplamento e amortecimento de impactos longitudinais. Busca-se identificar os fatores mais influentes na vida útil desses componentes e fornecer subsídios para melhorias no projeto e na operação ferroviária. Ao integrar simulações avançadas, aprendizado de máquina e dados experimentais, espera-se oferecer uma contribuição significativa para a gestão eficiente e segura de sistemas ferroviários.

1.3.1. Objetivo Geral

O objetivo geral deste trabalho é desenvolver um modelo de comportamento dinâmico de engates ferroviários que permita compreender e prever o impacto das condições de condução de um trem nesses componentes, que são responsáveis por acoplamento e amortecimento de impactos longitudinais, buscando, assim, identificar os fatores que mais influenciam na vida útil de tais componentes e fornecer subsídios para melhorias no projeto e na operação ferroviária.

1.3.2. Objetivos Específicos

- Organizar dados coletados de instrumentação dos engates ferroviários e de condução do trem, garantindo sua qualidade e consistência;
- Documentar a análise exploratória ampla dos dados, incluindo visualização, identificação de padrões e correlações preliminares entre variáveis relevantes;
- Elaborar um modelo preliminar que descreva o comportamento dinâmico dos engates ferroviários em resposta a diferentes forças e condições, considerando grandezas como tração e vibração.;
- Implementar um algoritmo de aprendizagem de máquina (*machine learning*) para analisar os dados coletados e identificar padrões complexos relacionados aos impactos das condições de condução do trem nos engates ferroviários, bem como às informações associadas à ocorrência dos esforços por localidade;
- Integrar o modelo elaborado previamente com o algoritmo de aprendizagem de máquina, comparando os resultados obtidos e, em decorrência, alterando os parâmetros do modelo para sua atualização e validação;

- Estabelecer estratégia para melhoria contínua da previsão do comportamento dos engates ferroviários em diferentes cenários operacionais, para elevação permanente de sua eficácia e confiabilidade.

1.4. ORGANIZAÇÃO DO TEXTO

Na presente INTRODUÇÃO, parte-se da importância do transporte ferroviário e abordam-se os desafios enfrentados devido ao aumento da carga dinâmica sobre os engates ferroviários. É destacada a necessidade de compreender os fatores que contribuem para a degradação dos engates e a importância de uma abordagem proativa para mitigar potenciais falhas. Uma revisão da literatura é apresentada, considerando, de forma específica, estudos anteriores relacionados à análise da integridade dos engates ferroviários, incluindo técnicas de monitoramento, detecção de falhas e análise de dados.

O Capítulo 2 – Fundamentos Teóricos e Experimentais descreve os componentes da dinâmica longitudinal de um trem de carga e a instrumentação dos engates, com vistas ao desenvolvimento do modelo de interesse e à análise dos dados. Aborda-se também a modelagem matemática pertinente e faz-se ainda uma exposição da abordagem de aprendizagem de máquina que, entende-se, contribui para o objetivo do trabalho.

Já no Capítulo 3 – Materiais e Métodos são apresentadas as etapas percorridas no desenvolvimento do trabalho. Informações associadas à elaboração dos modelos são relacionadas naquele capítulo, bem como outras informações pertinentes.

São expostos, no Capítulo 4 – Apresentação e Discussão de Resultados, os diversos resultados alcançados. Ressaltam-se, em correspondência, a identificação de padrões de comportamento operacional nocivos para os engates, o desenvolvimento de um sistema de diagnóstico e a melhoria da segurança e eficiência do transporte ferroviário.

Por fim, no Capítulo 5 – Considerações Finais, são apresentadas as conclusões decorrentes da realização do presente trabalho. São indicados também os possíveis desdobramentos de pesquisa e os pontos para aprimoramento futuro.

2. FUNDAMENTOS TEÓRICOS E EXPERIMENTAIS

2.1. INFLUÊNCIAS NA DINÂMICA DE UM TREM DE CARGA

Visando um melhor entendimento da modelagem a ser proposta em relação aos componentes que integram o sistema do conjunto de choque e tração (CCT), com inclusão das variáveis que influenciam diretamente o desempenho dos engates, são descritos abaixo os equipamentos e demais aspectos relevantes sob a perspectiva da dinâmica longitudinal de um trem. Faz-se uma descrição sucinta e específica, que também contempla o contexto de interesse em que os equipamentos se encontram inseridos.

2.1.1. Composição de veículos


Uma composição ferroviária consiste em um agrupamento de veículos interligados por acoplamentos. A configuração dessa composição varia conforme o propósito do transporte e a disponibilidade dos veículos para agrupamento. Desde pequenas composições destinadas à manobra em pátios até composições longas com centenas de veículos para o transporte de minério, a extensão pode variar significativamente.

Cada veículo em uma composição possui um peso total, composto pela soma do peso da própria estrutura do veículo (tara) e do peso transportado (lotação). Para que a composição se mova, é preciso vencer uma resistência intrínseca ao rolamento, resultante dos mancais e do contato entre as rodas e os trilhos (FREITAS, 2015). À medida que a velocidade aumenta, surgem efeitos aerodinâmicos, como arrasto, devido à área frontal e às irregularidades laterais.

A Figura 1 traz a concepção de uma composição, ilustrada como uma corrente longa, com cada veículo sendo um elo interligado por acoplamentos (HUNGRIA, 2018). Essa representação figurativa ajuda a visualizar a dinâmica complexa envolvida no movimento e no comportamento de composições ferroviárias.

Observa-se na Figura 1 que a mudança de perfil altimétrico faz com que alguns vagões estejam em subida enquanto outros fiquem em descida, causando variações de velocidade entre vagões. Observa-se ainda que, em alguns vagões, as folgas entre engates se fecham, enquanto que, em outros, elas se abrem.

FIGURA 1 – Veículos interligados em uma composição ferroviária.



Fonte: Hungria, 2018.

2.1.2. Sistema de tração

As locomotivas de carga são máquinas projetadas para mover grandes quantidades de carga ao longo de trilhos. O sistema de tração dessas locomotivas pode ser alimentado por corrente alternada (CA) ou corrente contínua (CC), cada qual com suas características e aplicações específicas.

No caso das locomotivas com sistema de tração CA, o funcionamento geral é baseado em um motor a diesel que aciona um gerador elétrico. Esse gerador produz eletricidade que é então distribuída para os motores de tração localizados nas rodas das locomotivas (HUNGRIA, 2018). O motor a diesel funciona como uma fonte de energia primária, convertendo energia química em energia mecânica para movimentar o gerador.

O gerador elétrico produz uma corrente alternada que é regulada por um sistema de controle conhecido como governador. O governador controla a velocidade do motor a diesel para manter a produção de energia elétrica dentro dos parâmetros necessários para operação eficiente da locomotiva. Isso garante que a locomotiva mantenha uma velocidade constante ou varie a velocidade, de acordo com as exigências da rota e da carga.

Os motores de tração, alimentados pela eletricidade fornecida pelo gerador, são responsáveis por converter energia elétrica em energia mecânica para impulsionar as rodas da locomotiva. Esses motores são motores elétricos de indução trifásicos,


projetados para suportar as demandas de torque e potência necessárias para mover cargas pesadas.

Uma das vantagens do sistema de tração CA em locomotivas de carga é a capacidade de controlar com exatidão a velocidade e o torque dos motores de tração. Isso é essencial ao lidar com altimetria e geometria de via variável (esses conceitos são aprofundados adiante, na seção 2.1.5).

Por outro lado, locomotivas de carga com sistema de tração CC operam de maneira semelhante, mas com eletricidade gerada em corrente contínua. Essas locomotivas são menos comuns em comparação com as de tração CA devido a algumas limitações técnicas, como a necessidade de sistemas mais complexos de comutação de energia (MORAES, 2020).

A Figura 2 apresenta um diagrama simplificado do funcionamento de ambos os sistemas mencionados anteriormente. São ilustrados, na figura, os componentes principais.

FIGURA 2 – Funcionamento dos sistemas de tração CA e CC.



Fonte: Moraes, 2020.


2.1.3. Sistema de frenagem

O sistema de frenagem de trens de carga é composto por dois subsistemas principais, doravante tratados como sistemas em si. Eles são o sistema de frenagem dinâmica e o sistema de frenagem pneumática.

O sistema de frenagem dinâmica funciona através da conversão da energia cinética dos vagões em energia elétrica, que é dissipada como calor pelos resistores montados nas locomotivas. Quando o maquinista aplica os freios dinâmicos, os motores elétricos dos veículos passam a funcionar como geradores, convertendo a energia cinética em eletricidade, que é então dissipada (MORAES, 2020). Este processo é controlado automaticamente pelo sistema de controle de tração da locomotiva.

Já o sistema de frenagem pneumática é utilizado para proporcionar uma frenagem eficiente e segura, controlando a dinâmica longitudinal dos vagões. Ele é ilustrado esquematicamente (BARBOSA, 1993), com seus componentes principais, na Figura 3.

FIGURA 3 – Funcionamento do sistema de frenagem pneumática.



Fonte: Barbosa, 1993.

Os componentes mostrados na Figura 3 são:

- Reservatório principal (Rp): armazena o ar comprimido a ser utilizado para acionar os freios, sendo carregado durante a operação normal do trem.
- Válvula manipuladora de controle automático (Vm): é responsável por controlar a pressão do ar no sistema, garantindo uma frenagem suave e progressiva.


- c) Válvula de controle do freio (Vc): regula o fluxo de ar comprimido para os cilindros de freio dos vagões, permitindo que a pressão seja aplicada de forma adequada.
- d) Reservatório auxiliar combinado com o de emergência (Ra/Re): é utilizado em situações de emergência para fornecer pressão adicional de ar aos cilindros de freio.
- e) Cilindros de freio (Cil): são dispositivos pneumáticos responsáveis por aplicar a pressão do ar nos sistemas de freio dos vagões, acionando as pastilhas ali contidas.
- f) Válvula redutora de alívio (Vra): é responsável por liberar o ar comprimido em excesso do sistema, garantindo que a pressão nos cilindros de freio seja mantida dentro dos limites seguros.
- g) Válvula de redução (A1): é acionada automaticamente para reduzir a pressão do ar nos cilindros de freio quando o maquinista libera os freios, permitindo que os vagões se movam livremente novamente.

2.1.4. Conjunto de choque e tração (CCT)

Os engates ferroviários são elementos de conexão entre vagões de trens de carga, proporcionando a transmissão de forças de tração e compressão durante a movimentação. Entre os tipos mais comuns estão os engates tipo "E" e tipo "F", cada um com características específicas.

O engate tipo "E" é composto por uma chaveta, que é uma peça retangular de aço, e por braçadeiras, que prendem a chaveta no engate do veículo (ROSA, 2012). A chaveta é inserida em uma ranhura no engate do veículo, sendo fixada, então, pelas braçadeiras para manter sua posição durante o movimento, conforme mostrado na Figura 4.


FIGURA 4 – Conjunto de choque e tração de um engate tipo "E".



Fonte: Rosa, 2012.

Já o engate tipo "F" utiliza pinos de conexão em vez de chavetas. Esses pinos são inseridos em orifícios nos engates dos veículos, sendo travados no lugar por meio de uma alavanca de bloqueio (ROSA, 2012). Essa configuração, mostrada na Figura 5, proporciona uma conexão mais rápida e segura entre os vagões.

FIGURA 5 – Conjunto de choque e tração de um engate tipo "F".



Fonte: Rosa, 2012.

Os componentes comuns em ambos os tipos de engate são:

- a) Mandíbula: componente que se encaixa no engate do veículo adjacente para formar a conexão entre os vagões.
- b) Cruzetas: peças transversais que conectam a mandíbula ao resto do engate, proporcionando estabilidade e distribuindo as forças.
- c) Colar rotativo: elemento que permite a articulação entre a mandíbula e o corpo do engate, facilitando a manobra dos vagões em curvas.
- d) Aparelho de Choque e Tração (ACT): conjunto responsável por absorver impactos e transmitir forças de tração entre os vagões.

O ACT desempenha um papel significativo na dinâmica longitudinal do trem, absorvendo energia durante frenagens, colisões e acelerações. O ACT é geralmente composto por elementos elásticos e dissipativos, como molas e amortecedores, para reduzir as forças de impacto transmitidas entre os vagões.

O comportamento de um ACT pode ser descrito por curvas características. As curvas características de histerese e absorção descrevem a relação entre a energia absorvida pelo sistema e a deformação sofrida durante os ciclos de compressão e expansão. Essas curvas são determinadas pelos materiais e pela geometria dos componentes do ACT, bem como pela configuração do engate.

As Figuras 4 e 5 ainda apresentam a conexão entre o corpo dos engates dos tipos “E” e “F”, respectivamente, e a longarina. Esta conexão é feita por uma viga estrutural que conecta os engates dos vagões. Ela suporta as forças de tração e compressão transmitidas pelo ACT e distribui essas forças ao longo do comprimento do vagão.

Durante a operação do trem, ocorrem variações nas forças de tração e compressão devido às acelerações, frenagens e mudanças na altimetria da via (HUNGRIA, 2018). O conjunto de choque e tração é projetado para absorver essas variações e minimizar os impactos sobre os vagões e a carga transportada.

Neste trabalho, a análise é direcionada para vagões com engates tipo “F”. Isso se justifica pelo fato de que esses possuem maior representatividade na frota atual de vagões em ferrovias brasileiras.

2.1.5. Altimetria de via

A via permanente é composta por uma série de elementos que garantem a estabilidade do tráfego de trens ao longo do percurso. A altimetria de via refere-se ao estudo das variações de altitude ao longo do trajeto ferroviário, determinando parâmetros fundamentais como a inclinação vertical (rampa) e o raio de curva do trecho de via (BARBOSA, 1993).

Os componentes básicos para a construção de uma via férrea são:

- a) Trilhos: constituem os elementos longitudinais da via permanente, responsáveis por guiar as rodas dos trens. Geralmente feitos de aço, os trilhos são fixados à grade estrutural por meio de conexões adequadas.
- b) Grade estrutural: consiste na base de suporte dos trilhos, composta por dormentes e lastro. A grade estrutural distribui as cargas provenientes dos trens para o subleito de forma eficiente, garantindo a estabilidade da via.
- c) Dormentes: são elementos transversais que sustentam os trilhos, fixando-os à grade estrutural. Podem ser de madeira, concreto ou material sintético, sendo dispostos perpendicularmente à direção dos trilhos.
- d) Lastro: trata-se de uma camada de material granular (geralmente pedra britada) colocada entre os dormentes para garantir a estabilidade e absorver as cargas transmitidas pelos trens. O lastro também auxilia na drenagem da água da chuva, prevenindo erosões e afundamentos.
- e) Sublastro: é uma camada de solo compactado localizada abaixo do lastro, fornecendo suporte adicional à via e auxiliando na distribuição de cargas para o subleito.

No tocante à dinâmica longitudinal, a interação entre o veículo ferroviário e a via férrea está sujeita a diversos parâmetros (BARBOSA, 1993). Salientam-se como fundamentais, como já antecipado, os seguintes parâmetros:

- a) Inclinação vertical (Rampa): refere-se à variação da altitude ao longo do trecho de via, expressa como uma porcentagem. Rampa positiva indica uma subida, enquanto rampa negativa indica uma descida. A inclinação vertical afeta diretamente o desempenho dos trens, influenciando na eficiência energética e nas forças de tração e frenagem.
- b) Raio de curva: indica a curvatura da via, afetando a velocidade máxima permitida e a dinâmica do veículo. Curvas com raios menores exigem redução da velocidade para evitar descarrilamentos e tensões excessivas nos trilhos.

Estes parâmetros compõem os mapas topográficos de via, que são ferramentas essenciais para o planejamento, construção e manutenção da infraestrutura ferroviária. Eles representam a altimetria da via, indicando variações de altitude, inclinações verticais, curvaturas e outros elementos relevantes para a operação ferroviária.


A Figura 6 apresenta um exemplo típico de mapa topográfico de via. Através da análise desses mapas, é possível identificar pontos críticos, otimizar o traçado da via e garantir uma operação segura e eficiente dos trens.

2.1.6. Operação e condução

A operação de trens de carga é uma tarefa que envolve uma série de considerações técnicas e práticas essenciais (BARBOSA, 1993). Deve-se garantir não apenas o desempenho adequado, mas também a segurança ao longo de todo o percurso.

Durante a fase de aceleração, as locomotivas aplicam tração para movimentar o trem, porém, a distribuição dos esforços de tração pode ser desigual ao longo da composição, especialmente em trens longos. Isso ocorre devido a diferenças de atrito entre os vagões, variações na altimetria da via e outras condições operacionais. Como resultado, os vagões mais próximos das locomotivas podem sofrer forças de tração mais intensas do que os vagões mais distantes, exigindo um controle preciso por parte dos maquinistas para evitar problemas de tração excessiva ou deslizamento das rodas.

FIGURA 6 – Exemplo de um mapa topográfico de via.




Fonte: Barbosa, 1993.

Um diagrama típico de distribuição de esforços é apresentado na Figura 7, que diz respeito a um trem de carga da malha ferroviária que se estende de Rondonópolis (MT) até o porto de Santos (SP). Estes trens são compostos por 4 a 5 locomotivas (a depender da altimetria do trecho) e 120 vagões carregados com grãos.

Para lidar com a massa e a resistência ao movimento desses tipos de composições, as locomotivas podem ser agrupadas em diferentes pontos do trem, em uma configuração conhecida como tração múltipla. Essa configuração permite uma distribuição mais uniforme da força de tração ao longo do trem, reduzindo, conseqüentemente, o risco de deslizamento das rodas e melhorando a eficiência energética. Na Figura 7, o trem é composto por 2 locomotivas + 54 vagões + 1 locomotiva + 81 vagões + 1 locomotiva. A utilização de uma locomotiva na cauda do trem se justifica pela necessidade de tração para empurrar o trem em rampas ascendentes de elevação superior a 2%.

FIGURA 7 – Exemplo de diagrama de distribuição de esforços.



Fonte: Autora, 2023.

Em composições ferroviárias mais longas, é necessário dissipar a energia cinética acumulada pelo trem de forma controlada, a fim de garantir uma desaceleração suave e segura durante o processo de frenagem. O sistema de frenagem pneumática, em conjunto com o sistema de frenagem dinâmica, é responsável pelo controle da dinâmica longitudinal do trem, prevenindo colisões ou descarrilamentos. Como já exposto, enquanto a frenagem dinâmica converte a energia cinética dos vagões em energia elétrica, o sistema pneumático aplica pressão nos cilindros de freio para reduzir a velocidade do trem.

Considerando o perfil altimétrico e a extensão do trem como um todo, as folgas nos acoplamentos dos vagões podem variar durante a operação do trem, dependendo das condições da via, da aceleração e da frenagem. Essas folgas, sejam elas oriundas de compressão, distensão ou combinação de ambas nos acoplamentos, afetam a dinâmica longitudinal do trem (HUNGRIA, 2018). O comportamento das folgas pode resultar na formação de ondas de choque ao longo do trem, que devem ser consideradas para garantir uma operação suave e estável.

Em situações em que os esforços e choques longitudinais ultrapassam os limites estabelecidos pela operação ferroviária, face às as propriedades mecânicas do conjunto de choque e tração, são observadas a nucleação e propagação de trincas nos componentes estruturais dos vagões. Isso leva a ocorrências de quebra dos engates, ou até mesmo arrancamento de longarinas, conforme mostra a Figura 8. Já


a Figura 9 apresenta o detalhamento estrutural do vagão, destacando o posicionamento da longarina como elemento de sustentação central do vagão.

FIGURA 8 – Ocorrência de quebra de mandíbula e arrancamento de longarina.



Fonte: Autora, 2023.

FIGURA 9 – Detalhamento estrutural do vagão.



Fonte: Freitas et al., 2018.

A operação e condução de trens de carga estão intrinsecamente ligadas aos conceitos abordados anteriormente acerca da dinâmica longitudinal de trens. A concentração dos esforços de tração, a distribuição não uniforme durante a aceleração, o uso de tração múltipla, a frenagem eficiente e o gerenciamento das folgas no acoplamento são todos aspectos que impactam diretamente o comportamento dinâmico do trem ao longo da via.

2.2. USO DE DADOS EXPERIMENTAIS

A fundamentação experimental deste trabalho está baseada em um relatório técnico previamente elaborado, no qual foram descritos os ensaios e medições realizados em um vagão graneleiro HTT instrumentado. Esse conjunto de dados constitui a base utilizada para a validação e calibração do modelo proposto.

Os dados, já disponíveis e organizados, correspondem a registros de tração e compressão longitudinais, bem como deslocamentos do aparelho de choque e tração (ACT), obtidos durante um ciclo de viagens no período de outubro de 2023 a maio de 2024. Nesta seção, apresentam-se a origem e as características desses dados, ressaltando-se sua importância como fundamento empírico para o desenvolvimento do modelo matemático e das análises subsequentes.

Com o objetivo de realizar a análise de comportamento e degradação, são considerados apenas os dados correspondentes à passagem do trem no trecho que vai do município de Araraquara (SP) até Santos (SP). Destaca-se que, nesse trecho, é observada maior incidência de choques e esforços, uma vez que ele possui a altimetria mais variável em relação a rampas e raios de curva.

Para o uso de dados ora proposto, é necessário um pré-processamento dos sinais adquiridos. Inicialmente, é realizada a verificação de consistência dos sinais, a remoção de *spikes* (picos anômalos ou abruptos nos dados que não representam fenômenos físicos reais, geralmente associados a falhas nos sensores ou ruídos externos), e a sincronização e união de arquivos.

Em seguida, os sinais de força, deflexão, deformação e deslocamento são submetidos a um filtro passa-baixas de 40 Hz, uma vez que as frequências superiores a este valor geralmente correspondem a ruídos não relacionados à dinâmica longitudinal do sistema, como vibrações mecânicas de alta frequência ou interferências eletromagnéticas. Esse valor é escolhido por ser adequado para preservar as frequências características do comportamento dos engates, garantindo a integridade dos dados analisados.


Posteriormente, os dados provenientes do GPS (sinais de velocidade, latitude e longitude) são utilizados para a localização aproximada do vagão na via. Tal procedimento consiste em buscar cada coordenada do GPS do trem em um banco de dados que correlaciona as coordenadas com a posição real e o tronco da via.

Nas subseções abaixo são fornecidas informações complementares e gerais relacionadas aos dados experimentais. Contempla-se, em particular, a configuração dos sensores, os parâmetros operacionais relevantes e a análise preliminar dos dados.

2.2.1. Configuração dos sensores

Extensômetros designados por SG1 (Figura 10), SG2 e SG3 (Figura 11) são posicionados num vagão, nas regiões circuladas em azul. O posicionamento dos sensores é feito de modo a evitar as regiões da longarina do vagão, que possuem chapas de reforços soldadas, e, assim, não comprometer a precisão das medições que esses sensores precisam realizar.

FIGURA 10 – Posicionamento dos sensores na longarina e corpo do engate (vista lateral, mostrando SG1).




Fonte: IPT, 2023.

As regiões com chapas de reforço soldadas apresentam áreas onde as tensões se acumulam devido à diferença de rigidez e à forma como o material se deforma sob carga. Essas concentrações podem interferir nas leituras dos sensores, levando a medições imprecisas.

Para facilitar a comparação dos resultados dos extensômetros uniaxiais, os canais com estes dados são convertidos de *microstrain* para MPa, utilizando-se o módulo de elasticidade longitudinal de 210 GPa. Esta é uma aproximação adotada considerando-se que os maiores esforços decorrem da força longitudinal.

Os transdutores de proximidade são medições adicionais, com sinal binário em volts, sendo +5V quando o engate está afastado do sensor e -5V quando próximo. Esses transdutores estão indicados em verde na Figura 11, enquanto os extensômetros SG2 e SG3 estão representados em suas respectivas posições de fixação no corpo do engate.

FIGURA 11 – Posicionamento dos sensores na longarina e corpo do engate (vista de topo, com extensômetros SG2 e SG3).



Fonte: IPT, 2023.


2.2.2. Parâmetros operacionais para esforços

A definição de esforço crítico se aplica a todos os esforços que ultrapassem 136 tf (toneladas força). Deve ser sinalizado o tempo que um esforço permanece acima de 136 tf. Também deve ser indicado o maior esforço encontrado neste período e os demais parâmetros no mesmo instante do maior esforço.

A calibração do canal de deflexão do engate, apresentada na Figura 12, utiliza proximômetros e extensômetros de forma integrada. Os proximômetros medem os deslocamentos lineares associados à deflexão do engate, enquanto os extensômetros captam as deformações locais no material. A combinação dessas duas medições permite determinar, com maior exatidão, a relação entre o deslocamento mecânico e as forças aplicadas ao engate. Esse processo é essencial para a validação dos dados

experimentais, garantindo que as deflexões medidas reflitam de forma acurada os esforços atuantes nos engates.


FIGURA 12 – Calibração do canal de deflexão do engate.



Fonte: IPT, 2023.

Os mapas gráficos dos esforços críticos seguem o mesmo padrão dos mapas de choques, contendo os pontos que indicam os locais de ocorrências dos esforços em questão. A Figura 13 mostra os esforços registrados em um engate tipo “F” no trajeto de Rondonópolis, ponto de partida e carregamento do trem, até o porto de Santos, onde é realizada a descarga dos vagões.

FIGURA 13 – Esforços no engate “F” entre Santos e Rondonópolis.



Fonte: IPT, 2023.

Na Figura 13, os pontos destacados em vermelho correspondem aos esforços de tração e os pontos em azul aos esforços de compressão, concentrados por nível de cores, conforme escala da Figura 14. Os registros da Figura 13 são extraídos dos dados utilizados no presente trabalho.

FIGURA 14 – Legenda utilizada para escala de forças no engate.



Fonte: IPT, 2023.


2.2.3. Análise preliminar de dados

Dentre os eventos observados na viagem entre Rondonópolis (MT) e Santos (SP), considerada neste trabalho, há ocorrências de esforço trator contínuo acima do usual. A Figura 15 contém gráficos típicos para ilustração de um engate tipo “F”. Na figura, os gráficos em cores distintas representam, respectivamente: em azul, a velocidade do vagão; em vermelho, o esforço no engate acoplado ao vagão HTT (em kgf); em verde, o curso do ACT (em mm); e, em azul claro, a pressão do encanamento geral (em psi), associada à aplicação de freio e desaceleração do vagão.

Ressalta-se que esses resultados compõem a fundamentação experimental do presente trabalho. Entre eles, os registros de esforço no engate, curso do ACT e pressão do encanamento geral foram analisados diretamente pela autora, enquanto os cálculos de tensões e deformações associados às simulações estruturais do engate foram obtidos a partir de análises externas, constantes do relatório técnico de referência..

Nota-se que, mesmo que o ACT esteja longe do fim de curso (quando ainda há capacidade de absorção do ACT perante ao esforço/ choque entre vagões), o engate pode sofrer compressão significativa. Os valores indicados na Figura 15 correspondem a alguns dos picos de maior intensidade encontrados no trecho. Os valores máximos desses esforços, com data e hora de sua ocorrência e localização estão na Tabela 1, que contém ainda a indicação dos trechos correspondentes.

FIGURA 15 – Leitura de velocidade, esforço no engate F, flexão do engate, curso do ACT e pressão no encanamento geral no trecho Rondonópolis (MT) – Santos (SP).



Fonte: IPT, 2023.

TABELA 1 – Maiores esforços identificados no engate F.

Evento	Data/Hora	Velocidade (km/h)	Posição (km)	Trecho	Engate (tf)	Flexão (tf.m)	ACT (mm)	PEG (PSI)
1	12:22.0	32	168.9	T1	-168.5	-0.4	-81.3	84.9
2	00:27.6	19.1	119.9	T1	167.7	-0.2	16.7	92
3	21:38.1	20.9	252.9	T2	-167.6	-0.4	-79.1	91.8
4	50:50.3	12.7	118.3	T2	-223.1	-0.4	-81.4	90.4
5	43:50.0	17.6	149.7	T1	181.3	1.2	16.8	91.9
6	59:45.3	16.9	153.7	T1	-209.8	3.8	-84	91.5

Fonte: IPT, 2023.

Observa-se na Tabela 1 (como se voltará a abordar na sequência) que a maior incidência de eventos tende a ocorrer no trecho 1 (T1), segmentação da operação

Rumo localizada entre os municípios de Araraquara (SP) e Santos (SP). Desta forma, deve-se concentrar a análise dos eventos no trecho acima mencionado, utilizando os dados destas localidades para a construção do modelo desejado, posto que se considera que tais dados são os mais representativos para a investigação de degradação dos componentes de interesse.


2.3. INFORMAÇÕES DE OPERAÇÃO E CONDUÇÃO DE TRENS

Usando dados do registrador de bordo (CBL) de viagens das locomotivas presentes nos trens que transportam os engates instrumentados, é possível visualizar os comandos de condução empregados em cada uma das ocorrências registradas pela instrumentação. Para tanto, cruzam-se as informações de coordenadas GPS dos vagões com as locomotivas, e o instante de tempo que cada registro é efetuado. Faz-se abaixo esse cruzamento para os dados pertinentes, para fins de ilustração.

2.3.1. Variáveis pertinentes à análise das viagens

A Figura 16 apresenta um recorte da visualização dos comandos operacionais na locomotiva líder, em um evento de esforço no trecho T1. Esse trecho possui maior demanda de tração na viagem (vide seção 2.2.3).

FIGURA 16 – Gráfico de operação da locomotiva líder.



Fonte: Autora, 2024.


Na Figura 16, são indicadas, em cinco cores distintas, em função do marco de quilometragem da ferrovia, as seguintes informações relevantes:

- em azul: pressão do encanamento geral, em psi, indicando as aplicações de freio pneumático quando o valor decai a partir de 110 psi;
- em vermelho: Velocidade Máxima Permitida (VMA) (magnitude) para o trecho em circulação, em km/h;
- em amarelo: ponto de potência utilizado para tração da locomotiva (grandeza adimensional, relativa apenas ao posicionamento do manípulo);
- em verde: Velocidade da composição (magnitude), em km/h;
- em cinza: Ponto de aplicação do freio dinâmico.

Para os pontos de potência disponíveis para tração de uma locomotiva AC44 (presente na viagem dos vagões instrumentados), existe uma variação de 8 pontos de tração. Esses pontos representam níveis discretos de aplicação de esforço, correspondentes às posições da alavanca de potência do maquinista, e não uma variação contínua. Em cada posição, a locomotiva fornece uma fração da sua capacidade máxima de esforço de tração, ajustada de acordo com a velocidade. Assim, os pontos funcionam como “degraus” sucessivos de potência, desde o esforço mínimo necessário para movimentar a composição até a capacidade máxima de tração da máquina. A Tabela 2 apresenta a relação entre velocidade e esforço de tração (em kgf) para cada um desses níveis discretos.

A mesma consideração anterior se aplica ao esforço de frenagem dinâmica da máquina, em kgf, até a capacidade máxima de tração disponível por locomotiva. A Figura 17 apresenta a relação da velocidade (magnitude), em km/h, e o esforço de tração executado pela locomotiva, em kgf. Na Figura 17, as linhas correspondem a cada um dos pontos de tração da locomotiva, variando a entrega de esforço trator em kgf, em função da velocidade.

FIGURA 17 – Esforço de frenagem dinâmica de uma locomotiva AC44.



Fonte: Autora, 2024.

TABELA 2 – Esforço de tração exercido por uma locomotiva AC44.

Veloc.	Esforços de tração, kgf							
Km/h	P1	P2	P3	P4	P5	P6	P7	P8
0.00	6,803.96	23,328.04	37,907.56	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
1.61	6,803.96	23,328.04	37,907.56	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
3.22	6,803.96	23,328.04	37,907.56	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
4.83	6,803.96	22,613.17	37,907.56	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
6.44	6,803.96	17,153.23	35,854.58	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
8.05	4,760.05	13,673.23	29,228.89	50,543.86	61,235.14	69,983.67	76,787.63	90,719.40
9.66	3,943.12	11,431.10	24,423.93	37,253.47	52,499.32	69,983.67	76,787.63	90,719.40
11.27	3,421.48	9,862.56	20,958.45	32,075.66	45,547.49	59,903.84	76,787.63	87,544.23
12.87	3,051.80	8,694.09	18,363.88	28,098.52	40,116.12	52,899.85	65,452.69	78,018.69
14.48	2,766.94	7,782.36	16,349.45	24,974.14	35,788.35	47,298.38	58,689.10	71,088.18
16.09	2,534.25	7,046.63	14,738.73	22,464.85	32,272.52	42,733.83	53,168.83	64,505.58
17.70	2,336.93	6,438.36	13,419.67	20,410.96	29,367.23	38,950.38	48,568.90	59,037.92
19.31	2,165.93	5,924.88	12,318.33	18,700.90	26,930.06	35,767.94	44,674.32	54,408.06
20.92	2,014.88	5,484.90	11,383.92	17,256.19	24,858.48	33,056.79	41,334.03	50,429.10
22.53	1,880.61	5,103.42	10,580.60	16,020.14	23,078.56	30,721.22	38,439.17	46,970.88
24.14	1,759.96	4,768.67	9,882.52	14,951.47	21,533.16	28,689.10	35,907.65	43,936.77
25.75	1,651.55	4,472.47	9,270.16	14,017.51	20,180.08	26,906.47	33,676.40	41,253.74
27.36	1,553.12	4,208.02	8,728.57	13,194.68	18,986.21	25,329.77	31,696.00	38,864.65
28.97	1,463.30	3,970.79	8,245.49	12,464.39	17,924.79	23,925.88	29,928.33	36,725.03
30.58	1,382.11	3,756.69	7,812.30	11,811.67	16,975.87	22,668.51	28,341.65	34,798.60
32.19	1,307.72	3,561.64	7,421.75	11,224.26	16,122.65	21,535.88	26,910.55	33,056.79
33.80	1,239.23	3,384.29	7,067.04	10,692.64	15,351.08	20,510.75	25,614.17	31,474.19
35.40	1,176.63	3,221.45	6,744.08	10,209.56	14,649.82	19,577.70	24,434.36	30,031.30
37.01	1,119.02	3,071.76	6,448.79	9,767.76	14,010.25	18,725.85	23,357.07	28,711.33

38.62	1,065.95	2,932.96	6,177.08	9,362.70	13,424.66	17,944.30	22,369.59	27,499.32
40.23	1,016.51	2,804.59	5,926.25	8,988.93	12,885.78	17,224.89	21,461.94	26,383.02
41.84	971.15	2,685.29	5,694.46	8,643.29	12,388.19	16,560.37	20,625.06	25,352.44
43.45	928.97	2,574.16	5,479.00	8,322.60	11,927.79	15,944.84	19,850.31	24,398.08
45.06	889.50	2,470.29	5,278.05	8,024.13	11,500.05	15,372.86	19,132.27	23,511.75
46.67	852.76	2,372.31	5,090.72	7,745.17	11,101.33	14,839.88	18,464.57	22,687.56
48.28	818.74	2,280.69	4,914.72	7,483.44	10,729.38	14,341.83	17,841.79	21,918.26
49.89	786.54	2,194.05	4,749.61	7,238.05	10,380.57	13,875.08	17,260.27	21,199.76
51.50	756.60	2,112.40	4,594.03	7,006.71	10,053.07	13,436.90	16,715.50	20,526.17
53.11	728.02	2,035.29	4,447.07	6,788.08	9,744.62	13,024.58	16,203.85	19,894.31
54.72	701.71	1,961.81	4,307.81	6,581.69	9,453.87	12,635.85	15,723.03	19,300.10
56.33	676.31	1,891.95	4,175.81	6,385.74	9,178.99	12,268.44	15,269.44	18,739.91
57.93	652.27	1,825.73	4,050.17	6,199.31	8,918.62	11,920.98	14,841.69	18,211.47
59.54	629.59	1,762.22	3,930.87	6,021.95	8,671.41	11,590.76	14,436.63	17,711.60

Fonte: Wabtec, 2018.


O conhecimento das forças aplicadas pelas locomotivas nos vagões a partir da tração e frenagem, em conjunto com o somatório das resistências ao movimento ocasionadas pela altimetria do trecho, é necessário para melhor entendimento da ação dessas forças nos engates. As considerações relativas à altimetria são expostas na subseção seguinte.

2.3.2. Altimetria do trecho selecionado

Considerando os principais componentes citados na seção 2.1.5 para análise da altimetria de via, a Figura 18 apresenta o percentual de rampa e os raios de curva nos trechos com maior incidência de esforços registrados pela instrumentação. Pode-se observar que, para ambos os trechos, existem percentuais de rampa variando de 1% a 3%, e raio de curvas superiores a 183 metros de raio. Ambas as características citadas representam um desafio significativo na operação de trens longos, face às resistências ao movimento.

O perfil altimétrico do trecho bem como o peso do trem e a disponibilidade de tração são fatores determinantes para definição de quais procedimentos devem ser adotados na condução padrão do trem. Os dados fornecidos pela base de altimetria, juntamente com as informações de condução, são utilizados para melhor entendimento do impacto e da combinação de diferentes fatores nas forças aplicadas nos engates.

FIGURA 18 – Perfil de rampa e raios para o trecho 1.



Fonte: Autora, 2024.

2.4. MODELAGEM MATEMÁTICA

Para o desenvolvimento pertinente do modelo de interesse neste projeto, há que se descrever, com acurácia, as forças exercidas pelos engates. Essas forças são, via de regra, dependentes dos deslocamentos relativos e das velocidades relativas entre os vagões. Com base no conhecimento dessas forças, pode-se avançar para a concepção do modelo. Assim sendo, faz-se, inicialmente, a caracterização do engate, para depois abordar a questão mais ampla da modelagem do sistema investigado.

2.4.1. Caracterização do ACT

Para uma descrição realista do engate, baseada em sua curva de histerese, constata-se que as forças de acoplamento devem ser representadas por polinômios que contenham tanto termos lineares quanto não lineares. Esses polinômios podem, inclusive, apresentar eventualmente coeficientes diferentes, correspondendo a diferentes comportamentos de um engate ao longo de seu curso. Ao considerar termos não lineares, pode-se empregar, caso seja adequada, a resolução numérica de equações de movimento associadas, como se verá mais adiante.

Salienta-se que, quando são mencionadas forças de acoplamento exercidas por engates (que podem ser forças de tração ou compressão), está se referindo, em essência, às forças desenvolvidas pelos aparelhos de choque e tração (ACTs). As

características dinâmicas de um ACT podem ser levantadas e descritas a partir de um ensaio de histerese correspondente.

Face à diversidade de modelos de ACT existentes para diferentes tipos de vagões com características distintas, faz-se necessário definir um conjunto de parâmetros que permita selecionar o tipo de ACT mais apropriado para as condições operacionais. Há que se considerar que os engates só suportam esforços de, no máximo, 136.000 kgf (300.000 lbf) (HUNGRIA, 2018).

Existem basicamente três tipos de ACT (ROSA, 2012), classificados conforme o mecanismo de amortecimento da seguinte forma:

- a) Por fricção: o amortecimento se dá por meio de atrito seco. É indicado para altas forças em baixas velocidades. Pelo atrito seco gerado entre os seus componentes de aço (cunhas, placas e mola) dissipa-se a energia do choque.
- b) Polimérico: possui um fluido polimérico dentro de um cilindro que recebe o choque. Mostra evidentes características viscosas e resiste a impactos associados a velocidades mais altas e forças mais elevadas.
- c) Híbridos: tem dois mecanismos de amortecimento, a saber, por fricção (cunhas e placas) e viscoso (molas poliméricas). Seu propósito é combinar as vantagens dos dois tipos de ACT anteriores.

A curva de desempenho característico de um ACT (força x deslocamento) permite a obtenção dos seguintes parâmetros:


- Curso de deslocamento do ACT (mm);
- Energia absorvida (kJ);
- Força de reação ao longo do curso (kN);
- Constantes de rigidez (kN/mm, se linear).

A partir destes parâmetros, pode-se calcular o valor do parâmetro conhecido como índice de amortecimento histerético equivalente (indicado pela letra grega ζ). Trata-se de um parâmetro muito relevante, também empregado para avaliar os modelos de ACT e determinar sua aplicação.

A título de simples ilustração, a Figura 19 apresenta um esquema de funcionamento de um ACT por fricção. À medida que o suporte é inserido no corpo do ACT, a força normal nas cunhas aumenta devido ao aumento da força na mola principal. Isso resulta em um aumento da força tangencial de fricção conforme as

cunhas são introduzidas na caixa, face à relação proporcional entre fricção e força normal (BARBOSA, 1993). Em ACTs de alta capacidade, uma segunda cunha de fricção entra em ação após certo deslocamento, aumentando a rigidez do ACT.

FIGURA 19 – Esquema de funcionamento de um ACT por fricção.




Fonte: Barbosa, 1993.

No que diz respeito ao acoplamento entre dois veículos por meio de um conjunto de engate e ACT, são feitas as seguintes observações de caráter geral:

- I. As características do primeiro quadrante (curvas “A” e “B”) do ciclo de histerese típico da Figura 20, de força versus deslocamento, se aplicam ao terceiro quadrante com sinal trocado (curvas “D” e “E”), devido ao ACT trabalhar em compressão ou tração.
- II. Os engates possuem uma folga intrínseca, indicada por $2a$ na Figura 20, que permite movimento relativo entre os veículos. A falta de rigidez na ligação pode causar impactos quando as folgas se fecham ou se abrem.
- III. Cada ligação entre veículos possui dois engates e dois ACTs montados em série, resultando, em abordagem linear, em uma constante de rigidez e um coeficiente de amortecimento equivalentes iguais à metade do que se obtém com um único engate e ACT.

Com base nessas observações, uma curva experimental obtida em ensaio pode ser adotada, servindo de base para montagem de um gráfico representativo que contém as características de interesse. Inclui-se, em particular, uma região morta para deslocamentos próximos a zero, correspondentes às folgas do engate, conforme ilustrado na Figura 20.

FIGURA 20 – Ciclo de histerese típico de um ACT.



Fonte: Barbosa, 1993.


Para deslocamentos maiores que o comprimento sólido do ACT, a rigidez longitudinal da estrutura do veículo participa nas deflexões decorrentes, resultando em uma força que não aumenta infinitamente. Portanto, a curva característica do ACT também deve ser estendida com inclinações correspondentes à rigidez do veículo.

Isso faz com que o conjunto responda a deslocamentos maiores com forças proporcionais a essa rigidez. Para forças oscilantes com valores médios diferentes de zero, o deslocamento está associado a forças dentro dos limites estabelecidos, na Figura 20, pelos trechos "A" e "D", bem como pelos trechos estabelecidos pela mola de retorno, "B" e "E", descrevendo uma curva de histerese (BARBOSA, 1993).

Durante o movimento dos veículos, as forças de interação entre eles variam. Como a curva de crescimento da força difere da curva de alívio (efeito de histerese), é importante considerar isso ao determinar a força no ACT para deslocamentos que não atingem os extremos das curvas “A” ou “B”. Para tanto, é necessário conhecer o deslocamento do ACT gerado pelas forças no instante anterior. Com esse conhecimento, é possível determinar o valor da força dentro do ciclo de histerese.

Abordam-se abaixo, para exemplificação, dois modelos de ACT, o Mark 70E, fabricado pela Wabtec, e o Endurance 325, da Amsted Rail. O Mark 70E apresenta uma menor capacidade de absorção de energia, sendo adequado para situações de impacto com forças moderadas. Seu ciclo de histerese é ilustrado na Figura 21.

FIGURA 21 – Ciclo do ACT Mark 70E.



Fonte: Wabtec, 2001.

Com base no ciclo de histerese do Mark 70E, pode-se determinar que sua capacidade de absorção vai até 54,5 kJ. Analisando os setores da curva da Figura 21, tem-se que:

I. Setor $\bar{O}\bar{A}$:

Curso: 1,0 in (0,0254 m);

Rigidez: 2.287 kgf/mm;

Índice de amortecimento: 12,4 %;

II. Setor $\bar{A}\bar{B}$:

Curso: 2,5 in (0,0635 m);

Rigidez: 924 kgf/mm (que é baixa, permitindo um aumento da energia absorvida; atinge 240.000 lbf, sendo que 109.000 kgf = 1.068 kN);

Índice de amortecimento: $\zeta = 30,6$ %;

III. Setor $\bar{B}\bar{C}$:

Curso: 3,25 in (0,08255 cm) (utiliza todo o curso total, sem reserva);

Rigidez: 6.183 kgf/mm (que é alta, não permitindo um aumento da energia absorvida; choques superiores a 500.000 lbf (2.225 kN) irão exigir curso do ACT nesta faixa, gerando desgaste acelerado do componente);

Índice de amortecimento: $\zeta = 4,6$ %;

IV. Acima do ponto C:

Força de reação acima de 500.000 lbf (2.225 kN), que não será amortecida.

Extraíram-se dos testes experimentais todos os valores obtidos via curva de histerese.

Já o ACT Endurance é projetado para absorver forças de impacto bem maiores, sendo apropriado para trens que operam em condições extremas de carga e altimetria variável. Seu ciclo de histerese é mostrado na Figura 22.

A partir do ciclo de histerese da Figura 22, pode-se determinar que, para esse ACT, a capacidade de absorção vai até 64,6 kJ. Analisando os setores da curva da Figura 22, tem-se que:

I. Setor $\bar{\bar{O}}\bar{\bar{A}}$

Curso: 1,0 in (0,0254 m);

Rigidez: 2.232 kgf/mm;

Índice de amortecimento: $\zeta = 16,4 \%$;

II. Setor $\bar{\bar{A}}\bar{\bar{B}}$:

Curso: 1,89 in, (0,048006 m);

Rigidez: 5.337 kgf/mm (que é elevada, não permitindo um aumento da energia absorvida, sendo que 176.900 kgf = 1.735 kN);

Índice de amortecimento: $\zeta = 6,9 \%$;

III. Setor $\bar{\bar{B}}\bar{\bar{C}}$:

Curso: 2,53 in (0,064262 m);

Rigidez: 15.158 kgf/mm (o que não permite um aumento da energia absorvida; choques superiores a 300.000 lbf (1.335 kN) irão exigir curso do ACT nesta faixa);


Índice de amortecimento: $\zeta = 2,9 \%$;

IV. Acima do ponto C:

Força de reação acima de 503.000 lbf (2.239 kN), que não será amortecida.

Como há ainda reserva de 0,71 in de curso, o ACT não ficará sólido, evitando repassar parte da energia do choque para a estrutura do vagão.

FIGURA 22 – Ciclo do ACT Endurance 325.



Fonte: Amsted Rail, 2018.

Enquanto o Mark 70E apresenta capacidade de absorção efetiva de 54,5 kJ (valor obtido experimentalmente), podendo chegar a até 60 kJ em condições de projeto com curso total de 90 mm, o Endurance apresenta 64,6 kJ de absorção efetiva, podendo atingir até 120 kJ no curso máximo de 110 mm. Esses dois modelos são de interesse, em especial o segundo, dado que o trem de 135 vagões exige componentes capazes de lidar com forças dinâmicas severas, especialmente em trechos com rampas acentuadas e curvas de pequeno raio.


Ainda a partir da curva de histerese do ACT, pode-se também determinar a energia dissipada em um ciclo de funcionamento. Na sequência, iguala-se esse valor de energia dissipada à energia dissipada por um amortecedor viscoso em um ciclo, para obtenção de seu coeficiente de amortecimento equivalente. Usa-se, então, esse dispositivo equivalente para modelar o comportamento dissipativo do dispositivo original, com produção de forças que são diretamente proporcionais à velocidade.

2.4.2. Formulação e resolução de equação de movimento

Há várias alternativas para se modelar a dinâmica longitudinal de uma composição ferroviária. O modelo apresentado na Figura 23 foi desenvolvido pelos autores do presente trabalho no âmbito deste trabalho e constitui parte da fundamentação teórica própria da pesquisa. Ele representa um vagão intermediário em uma composição ferroviária, considerando a presença de engates na dianteira

(lado direito da figura) e na traseira (lado esquerdo da figura). Nesse modelo, tem-se que m_v (em kg) é a massa equivalente do vagão; k_{elk} (em N/m) a constante de rigidez linear; k_{enl} (em N/m³) a constante de rigidez não linear cúbica; e c_e (em kg/s) o coeficiente de amortecimento viscoso equivalente do engate associado. Esse modelo matemático foi elaborado especificamente para representar o comportamento dinâmico do sistema e servir de base para as análises subsequentes.

FIGURA 23 – Modelo com 1 grau de liberdade e não linearidade cúbica.



Fonte: Autora, 2025.

No modelo, tem-se que m_v (em kg) é a massa (concentrada) do vagão, enquanto que k_{el} (em N/m), k_{enl} (em N/m³) e c_e (em kg/s) são, respectivamente, a constante de rigidez linear, a constante de rigidez não linear cúbica e o coeficiente de amortecimento viscoso equivalente do engate associado ao vagão. Diz-se que o coeficiente de amortecimento é equivalente por ele estar associado, de forma equivalente (WIJESUNDARA, NASCIMBENE, SULLIVAN, 2011), à energia dissipada em um ciclo no engate. Ainda no modelo, $x_v(t)$ (em m) e $f_v(t)$ (em N) são, pela ordem, o deslocamento (vibração) do vagão e a força horizontal aplicada nele, sendo t , em ambos, o tempo.

Assume-se que a força $f_v(t)$, que pode ser prescrita ou medida, está associada ao que vem da dianteira do vagão. Assume-se também que os componentes na traseira constituem uma impedância infinita, que faz com que o vagão, para fins de descrição de seu comportamento vibratório (que se superpõe ao movimento de corpo rígido), esteja conectado, à esquerda, a uma superfície rígida.

Aplicando a segunda lei de Newton ao modelo, e omitindo a dependência no tempo por conveniência, chega-se à seguinte equação de movimento (WORDEN e TOMLINSON, 2001):

$$m_v \ddot{x}_v + c_e \dot{x}_v + k_{el} x_v + k^{enl} x_v^3 = f_v \quad (1)$$

Esta equação pode ser resolvida numericamente, pelo método de Runge-Kutta (INMAN, 2018; VARGAS e ARAKI, 2017) ou pelo método de Newmark (LINDFIELD e PENNY, 2019). Já analiticamente, a resolução pode se dar pelo método do balanço harmônico (WORDEN e TOMLINSON, 2001).

Opta-se, no presente trabalho, pela resolução numérica, tendo em vista a maior flexibilidade na consideração de diversos tipos de forças externas. É usado, nessa resolução, o método de Runge-Kutta, com o qual já se tem muita familiaridade, sempre alcançando ótimos resultados.

No método de Runge-Kutta, um sistema com N equações diferenciais de ordem 2 é transformado em um sistema de 2N equações diferenciais de ordem 1, pela introdução de novos vetores temporais. Esses vetores, ditos vetores de estado, contêm os deslocamentos e as velocidades do sistema que se modela. Deslocamentos e velocidades constituem o estado do sistema, que é obtido ao final da resolução numérica. O método de Runge-Kutta encontra-se bem implementado, de várias formas, em distintas linguagens de programação, sendo que mais informações sobre ele podem ser encontradas em Vargas e Araki (2017), com sua aplicação a sistemas com não linearidades sendo mostrada em Inman (2018).

No desenvolvimento do modelo, quando da confrontação de seus resultados com dados experimentais, deve ocorrer a atualização de seus parâmetros, para sua validação. Essa atualização pode ser feita por simples ajuste manual dos parâmetros associados ou através de um processo de minimização (otimização) da soma das diferenças, ao quadrado, entre as respostas numéricas e experimentais (função objetivo), sendo os parâmetros de interesse (vetor de projeto) variados judiciosamente dentro de limites pertinentes (restrições). Essa segunda abordagem, já usada com sucesso em várias oportunidades, é descrita em Júnior e at al. (2019).

Neste trabalho, na resolução numérica, as seguintes informações devem ser consideradas:

I. Massa (m_v):

Dado que cada vagão tem massa de 126 toneladas, essa massa, em quilogramas, é igual a 126.000 kg.

II. Constantes de rigidez (k_{el} , k_{enl}) e coeficiente de amortecimento (c_e):

Esses parâmetros necessitam de dados experimentais ou de projeto para sua especificação. No caso, são usados dados experimentais.

III. Condições iniciais:

No tocante à posição inicial, pode-se iniciar na posição de repouso, ou em um valor específico, se conhecido e a simulação assim o requerer. Quanto à velocidade inicial, ela pode ser igualada a zero para simulações que começam do repouso, ou à velocidade média de operação, que é 35 km/h (9,72 m/s).

IV. Passo de tempo:

O valor do passo de tempo pode ser inicialmente definido, por interesse da simulação, como uma fração de segundo, por exemplo, igual a 0,01 s, ou deixado por conta da particular rotina de Runge-Kutta empregada, pois há rotinas que lidam com o passo de tempo por si próprias, em função da evolução da resolução numérica. Esse segundo modo é, via de regra, adotado.

Vale destacar adicionalmente que, para os parâmetros de rigidez e amortecimento do ACT, os principais métodos de testes experimentais, que analisam a resposta do dispositivo a cargas e impactos, são:

1. Teste de compressão estática: Aplica-se uma força crescente ao ACT e mede-se o deslocamento, obtendo progressivamente a constante de rigidez pela razão $\Delta F / \Delta x$.
2. Teste dinâmico de impacto: O ACT é submetido a um impacto conhecido e a resposta do dispositivo é analisada para determinar os parâmetros desejados.
3. Ensaio modal: O ACT é excitado harmonicamente e os resultados podem ser usados para determinar valores de rigidez e amortecimento.
4. Curvas de histerese: Mede-se a resposta do ACT em ciclos de carga e descarga, possibilitando descrever seu comportamento em termos tanto de rigidez quanto de amortecimento.

Cada método fornece informações que podem ser associadas para, em conjunto, permitir uma modelagem satisfatória do ACT.

2.5. APRENDIZAGEM SUPERVISIONADA

A aprendizagem supervisionada baseia-se no uso de pares de entrada e saída para treinar modelos capazes de generalizar padrões a novos dados (Goodfellow, Bengio e Courville, 2016), permitindo que o modelo aprenda relações complexas entre

variáveis a partir de dados rotulados, sendo aplicado a uma ampla gama de problemas preditivos (Bishop, 2006; Hastie, Tibshirani e Friedman, 2009). Nesta seção, detalha-se a abordagem de aprendizagem supervisionada a ser utilizada para estimar, de forma adicional, os esforços nos engates ferroviários. Para tanto, consideram-se os dados do engate instrumentado, os históricos de condução e o perfil altimétrico correspondente.

2.5.1. Estruturação dos dados e pré-processamento

Na abordagem de interesse, a primeira fase consiste na coleta e preparação dos dados de entrada, que incluem variáveis como força, velocidade, altimetria e perfil de operação do trem. Esses dados são rotulados, isto é, para cada conjunto de entradas, os valores reais de esforço são conhecidos, possibilitando o treinamento do modelo. Conforme salientado por Goodfellow, Bengio e Courville (2016), a etapa de pré-processamento é necessária para garantir que o modelo receba entradas consistentes e representativas. Técnicas como normalização e remoção de *outliers* ajudam a reduzir a variância e a melhorar a generalização (Hastie, Tibshirani e Friedman, 2009).

O pré-processamento dos dados consiste em:

- Eliminação de valores inconsistentes e *outliers*;
- Normalização dos dados para a faixa $[-1, 1]$;
- Segmentação do conjunto em 80% para treinamento e 20% para teste, garantindo a preservação da distribuição temporal dos eventos críticos.

2.5.2. Atributos de entrada e saída do modelo

O modelo de aprendizado supervisionado desenvolvido neste trabalho utiliza uma rede neural artificial (RNA) para prever os esforços nos engates ferroviários com base em variáveis operacionais e ambientais. Essa abordagem segue princípios descritos por Bishop (2006) e reforçados por Hastie, Tibshirani e Friedman (2009), nos quais a escolha criteriosa das variáveis de entrada e a correta definição das saídas do modelo são determinantes para o desempenho e a interpretabilidade.

Os atributos de entrada representam os fatores operacionais, ambientais e mecânicos que influenciam diretamente os esforços nos engates. Esses atributos são

coletados por sensores embarcados e pelo registrador de bordo (CBL) das locomotivas. Os principais atributos de entrada incluem:

- Velocidade do vagão (km/h) – Captação a partir dos sensores de GPS do vagão instrumentado.
- Posição na via (km) – Identificação do quilômetro ferroviário onde o esforço é registrado.
- Altimetria do trecho (rampa e curvatura) – Inclinação da via no ponto de medição.
- PEG (PSI) – Pressão do encanamento geral do freio pneumático, representando aplicação de freio.
- Esforço de tração da locomotiva (kgf) – Nível de potência aplicado para movimentação do trem.
- Comando de freio dinâmico da locomotiva – Intensidade do freio dinâmico aplicado no trecho analisado.
- Trecho ferroviário – Identificação do trecho específico da ferrovia, permitindo correlação com características operacionais e ambientais.

Os atributos de saída representam as previsões do modelo, ou seja, os valores esperados para os esforços nos engates ferroviários com base nas entradas fornecidas. Os atributos de saída incluem:

- Esforço previsto no engate (tf) – Valor estimado da força de tração ou compressão no engate ferroviário.
- Classificação da severidade do esforço – Identificação se o esforço se enquadra em níveis aceitáveis, elevados ou críticos, considerando o limite de 136 tf para esforços críticos.
- Correlação entre esforço e evento operacional – Análise do modelo para identificar a principal causa do esforço elevado, seja variação de rampa, comando de potência e aplicação de freio, dentre outros.

2.5.3. Obtenção de previsões da RNA

Neste trabalho, as variáveis de entrada são fatores operacionais do trem, como força de tração, velocidade, posição na via e altimetria. A RNA processa essas informações ao longo das camadas ocultas, aplicando a função de ativação ReLU

(*Rectified Linear Unit*), escolhida por sua eficiência computacional e por atenuar problemas de gradiente em redes profundas.

Para a camada de saída, considerando que a variável alvo é contínua (esforço longitudinal em kgf), utilizou-se a função de ativação linear, de modo a permitir previsões em escala real.

Para cada camada da RNA, a previsão é obtida multiplicando os valores de entrada pelos neuronios da camada e aplicando a função de ativação, tal que:

$$a^{(l)} = g(W^{(l)}a^{(l-1)} + b^{(l)}) \quad (2)$$

onde:

- $a^{(l)}$ é a ativação da camada l ;
- $W^{(l)}$ são os pesos da camada l ;
- $b^{(l)}$ é o *bias* da camada l ;
- g é a função de ativação.

Após a previsão (*output*) da RNA, a próxima etapa é calcular a diferença (erro) entre a previsão feita pela RNA e o valor real esperado (esforços registrados no engate). Esse erro é mensurado por uma função de custo ou *loss function* (Goodfellow et al., 2016).

No presente trabalho, o erro mede o quão próximo o modelo está de prever corretamente o esforço nos engates ferroviários, com base nos dados de entrada (dados de condução e altimetria). Se o erro for alto, significa que a RNA está longe de acertar os valores de esforço reais, o que indica que os pesos da rede ainda precisam ser devidamente ajustados.

Depois de calcular o erro, a próxima etapa é o ajuste dos pesos na RNA para reduzir esse erro. Isso é feito por meio da *backpropagation* (retropropagação), um algoritmo que calcula o gradiente da função de custo em relação aos pesos da rede e ajusta esses pesos para minimizar o erro. O algoritmo de retropropagação utiliza a descida do gradiente para atualizar os pesos da rede, através da seguinte equação:

$$W^{(l)} = W^{(l)} - \eta \cdot \nabla W^{(l)} \quad (3)$$

onde:

- $W^{(l)}$ são os pesos da camada l ;

- η é a taxa de aprendizado (*learning rate*), que controla a magnitude do ajuste;
- $\nabla W^{(l)}$ é o gradiente da função de custo em relação aos pesos.

Para um modelo de aprendizagem de máquina em treinamento com dados reais de engates ferroviários, essa etapa é particularmente necessária, uma vez que, após cada iteração, o modelo ajusta os pesos para melhorar suas previsões de esforços nos engates. Se o modelo inicialmente subestimar ou superestimar o valor do esforço, deve haver ajuste dos pesos para que, em iterações futuras, ele se aproxime cada vez mais dos valores reais de esforço registrados pelos sensores. Por exemplo, se o sistema prever um choque de 10 mil kgf e o valor real for 8 mil kgf, o erro será de 2 mil kgf, devendo a RNA, então, ajustar os pesos para diminuir esse erro nas próximas previsões.

A otimização desses ajustes é realizada através de algoritmos como o Gradiente Descendente ou Adam (Goodfellow et al., 2016), que minimizam iterativamente a função de custo. Esse processo permite que a Rede Neural Artificial (RNA) aprenda padrões dos dados reais de esforço de forma eficiente, convergindo para previsões cada vez mais precisas.

Durante o treinamento, cada erro, como o exemplificado acima, é utilizado pelo algoritmo de otimização para ajustar os pesos, reduzindo essa diferença nas próximas previsões. Além disso, a escolha de uma taxa de aprendizado adequada é essencial: uma taxa alta pode causar oscilações, enquanto uma taxa baixa pode tornar o processo de aprendizagem lento.

Por fim, foi realizada o aumento do número de neurônios, o ajuste do *batch size* e o processo de parada antecipada (quando se interrompe o treinamento a partir do momento em que as atualizações de parâmetros não produzem mais melhorias em um conjunto de validação), para obter o aperfeiçoamento do modelo.

2.6. INTEGRAÇÃO ENTRE MODELOS

Originalmente, previa-se a integração entre o modelo matemático dos engates ferroviários e o modelo baseado em redes neurais artificiais (RNA). Desejava-se que essa integração possibilitasse uma retroalimentação entre previsões de esforços e parâmetros físicos da modelagem.

Contudo, após análises detalhadas e discussões a respeito das entradas e saídas do modelo, bem como as limitações da abrangência do modelo matemático em relação ao comportamento do trem, constatou-se que a natureza distinta das saídas geradas inicialmente por cada abordagem inviabilizava, de imediato, uma integração consistente. Enquanto o modelo matemático simula a resposta dinâmica do sistema a partir de equações diferenciais governadas por parâmetros físicos (como massa, constante de rigidez e coeficiente de amortecimento), o modelo de RNA realiza previsões diretas dos valores de esforço com base em dados de sensores instrumentados.

Dessa forma, optou-se por, neste trabalho, adotar uma abordagem de comparação entre os modelos, mantendo suas estruturas independentes. A comparação é estabelecida com base nos seguintes critérios:

- Capacidade de prever ou simular adequadamente os valores máximos de esforço longitudinal;
- Aderência temporal entre eventos previstos e eventos observados em dados experimentais;
- Robustez frente às variações operacionais dos trens (rampas, curvas e regimes de frenagem/tracionamento).

Essa estratégia permite avaliar as vantagens e limitações de cada modelo, sem comprometer a validade física ou estatística das previsões geradas.

3. MATERIAIS E MÉTODOS

Este capítulo contém as etapas metodológicas do trabalho. Progressivamente, detalham-se os materiais, meios, ferramentas e procedimentos usados ao longo da pesquisa. Destaques são dados, em seções dedicadas, para a modelagem do engate e a concepção do modelo de rede neural artificial.

3.1. ETAPAS METODOLÓGICAS

As etapas metodológicas do trabalho encontram-se sumarizadas na Tabela 3. Nessa tabela são relacionados também os objetivos específicos atendidos, bem como as ferramentas e técnicas associadas.

TABELA 3 – Resumo das etapas metodológicas.

Etapas Metodológica	Objetivo Específico Atendido	Técnicas e Ferramentas
Coleta e pré-processamento de dados	Organizar e garantir a qualidade dos dados	Python (Pandas, NumPy)
Modelagem dinâmica não linear	Elaborar e aplicar modelo de comportamento dinâmico	Método de Runge-Kutta, Python
Treinamento e validação da RNA	Implementar e aplicar algoritmo de ML	TensorFlow, PyTorch
Comparação entre modelos	Cotejar os modelos desenvolvidos	Análises gráficas e estatísticas (MAE, MAPE, R ²)

Fonte: Autora, 2025.

Especialmente quanto à aquisição, processamento e análise de dados de esforços longitudinais em engates ferroviários instrumentados, para garantir a clareza e a reprodutibilidade da abordagem, seguiu-se o seguinte procedimento:

- I. Coleta e Estruturação da Base de Dados: A base de dados utilizada neste estudo foi construída a partir de viagens instrumentadas de trens em operação, contemplando variáveis relevantes para a análise dos esforços longitudinais em engates ferroviários. A descrição detalhada dos sensores empregados na instrumentação encontra-se apresentada na Seção 2.2.2 – Instrumentação do Engate, de modo que, nesta etapa, destacam-se apenas as variáveis estruturadas para análise, incluindo:
 - a. Esforços longitudinais (choque e tração) e deslocamentos do Aparelho de Choque e Tração (ACT);

- b. Velocidade do trem, potência das locomotivas e pressão do encanamento geral;
- c. Registros de aceleração.

Os dados coletados passaram por um processo de pré-processamento, incluindo remoção de *outliers*, normalização e fusão de fontes distintas para garantir a consistência da base. A remoção de *outliers* foi realizada pelo método do desvio interquartil (IQR), considerando limites de $1,5 \times \text{IQR}$. Em seguida, os dados foram normalizados pela técnica de normalização min-max e, por fim, realizou-se a fusão de fontes distintas via chave temporal (*timestamp*).

Foram consideradas como variáveis de entrada: velocidade do vagão, deslocamento do ACT, pressão do encanamento geral e gradiente da via. As variáveis foram organizadas em janelas temporais de 5 segundos, com sobreposição de 50%, de modo a capturar a evolução dinâmica dos esforços.

- II. Regressão para Predição de Esforços: O modelo de regressão foi treinado para prever os valores de força nos engates, com base nas variáveis operacionais e na geometria da via. Essa abordagem buscou capturar padrões de comportamento dos esforços longitudinais em diferentes condições de operação.
- III. Arquitetura do Modelo de Aprendizado de Máquina: Para a predição dos esforços nos engates, foi utilizada uma Rede Neural Artificial (RNA) especificamente treinada para estimar a magnitude dos esforços longitudinais com base nos dados operacionais e da via. A RNA foi ajustada por meio de validação cruzada *k-fold* ($k=5$) e uso de *early stopping*, evitando sobreajuste e garantindo melhor generalização dos resultados.
- IV. Validação e Métricas de Avaliação: A validação do modelo correspondente foi conduzida comparando as previsões da RNA com os valores reais registrados nas viagens instrumentadas. As métricas utilizadas incluem:
 - Erro Médio Absoluto (MAE): Mede a precisão das previsões dos esforços.
 - Erro Percentual Absoluto Médio (MAPE): Avalia a discrepância percentual entre os valores previstos e reais.
 - Coeficiente de Determinação (R^2): Indica o quão bem o modelo de interesse se ajusta aos dados observados.

V. Implementação e Análise dos Resultados: A implementação dos modelos foi validada por meio de duas abordagens complementares. Para o modelo matemático, utilizou-se a base reduzida descrita na Seção 4.1.4, contendo registros reais de deslocamento do ACT obtidos em viagens instrumentadas, o que permitiu comparar diretamente os deslocamentos previstos e medidos, avaliando a aderência em condições reais.

Já para a Rede Neural Artificial, foram realizadas simulações variando condições de aplicação de freio, tração e velocidade (Seção 4.2.5.1), a fim de verificar a resposta do modelo frente a diferentes cenários operacionais. Foram utilizados três conjuntos de dados: (i) base completa das viagens instrumentadas, contendo 450 mil registros; (ii) base reduzida para validação do modelo matemático, com 120 mil registros selecionados por qualidade de sinal; (iii) base para treino e teste da RNA, dividida em 70% para treino, 15% validação e 15% teste.

Embora não tenha sido conduzida uma análise de robustez com um grande número de viagens, essas aplicações forneceram evidências consistentes de que os modelos reproduzem as tendências observadas nos dados reais e permitem identificar situações críticas que podem subsidiar estratégias de otimização da condução ferroviária.

Após a obtenção dos resultados dos modelos matemático e de RNA, realizou-se uma análise comparativa, sem integração mútua, avaliando a aderência de cada abordagem aos dados experimentais. Foram utilizadas métricas de erro (MAE, MAPE, R^2) e análises gráficas para aferir a capacidade de cada modelo em representar o comportamento real dos esforços nos engates ferroviários.

3.2. DADOS, MATERIAIS E MEIOS UTILIZADOS

Os principais dados, materiais e meios utilizados no desenvolvimento deste projeto incluíram:

- Dados da instrumentação: Foram coletados diretamente dos sensores de força (*strain gauges*) e deslocamento instalados nos engates ferroviários (SG1, SG2 e SG3, como citado na seção 2.2);


- Dados operacionais: Foram coletados por transdutores específicos em viagens instrumentadas, incluindo parâmetros de altimetria e comandos de tração e frenagem;
- Dados do ACT: Foram obtidos a partir da curva de histerese do componente, disponibilizada pelo fabricante;
- Ambiente Python: Foi utilizado para estruturar e cruzar as bases de dados, além de gerar gráficos para exibição dos resultados da modelagem do engate ferroviário. A biblioteca Pandas foi usada para manipulação e organização dos dados, enquanto as bibliotecas Matplotlib e NumPy foram empregadas para a visualização gráfica e cálculos numéricos. Já para a análise preditiva e classificação de padrões de condução, empregou-se a aprendizagem de máquina via RNA, implementada em Python, utilizando *frameworks* como TensorFlow ou PyTorch.

3.3. MODELO MATEMÁTICO NÃO LINEAR

No decorrer do desenvolvimento do trabalho, foram considerados vários modelos, visando alcançar uma descrição satisfatória do sistema investigado. Pensou-se, em especial, em um sistema com 2 graus de liberdade, com 2 vagões acoplados pelos respectivos engates. Nesse caso, o sistema poderia apresentar modo de corpo rígido, caso os vagões conectados estivessem sem outras conexões na dianteira e na traseira, como ilustrado na Figura 24. Agora, caso os vagões também estivessem conectados a impedâncias finitas ou infinitas na dianteira e na traseira, não haveria modo de corpo rígido.

Porém, após investigações preliminares, acabou-se convergindo para o modelo com 1 grau de liberdade já exposto na subseção 2.4.2, pois ele, de forma mais simples e eficaz (como se verá no próximo capítulo), não só contempla um vagão e um engate como também possibilita aplicação de força no mesmo ponto onde foram feitos os registros experimentais do trabalho. Além disso, como o vagão instrumentado encontrava-se em posição intermediária de uma composição com vagões e locomotivas, entendeu-se que seria razoável assumir que, na extremidade oposta à aplicação da força, ele estaria conectado a uma impedância infinita (ou seja, a um corpo que oferecesse resistência infinita ao movimento vibratório).


FIGURA 24 – Modelo com 2 graus de liberdade.



Fonte: Autora, 2025.

No modelo adotado, novamente mostrado por conveniência de apresentação na Figura 25 (com algumas adaptações em relação à Figura 23), é de fundamental importância a representação fidedigna do engate com seu ACT. Como já abordado antes, um comportamento não linear deve ser considerado. Na sequência, em subseções próprias, discorre-se sobre a modelagem do ACT e a resolução numérica do modelo matemático que contempla vagão e engate.

FIGURA 25 –Modelo com 1 grau de liberdade e não linearidade cúbica.



Fonte: Autora, 2025.

Tal comportamento é consequência da incapacidade do modelo Kelvin-Voigt de representar adequadamente a dissipação de energia dependente da direção de movimento e a histerese característica dos ACTs ferroviários. Esse resultado motivou a busca por abordagens de modelagem mais complexas e realistas. Dessa forma, concluiu-se que o modelo Kelvin-Voigt deve ser considerado apenas como referência inicial na fundamentação, uma vez que apresenta limitações relevantes frente às condições reais observadas. Assim, para o desenvolvimento deste trabalho, optou-se


por adotar como base de modelagem o comportamento histerético característico do ACT Endurance, descrito a seguir.

3.3.1. Modelagem de ACT via curva de histerese

Neste trabalho, foi considerado um engate com Aparelho de Choque e Tração (ACT) Endurance 325. Para a sua modelagem, empregou-se inicialmente o seguinte procedimento:

- A imagem da curva de histerese do ACT, disponibilizada pelo fabricante, foi carregada utilizando bibliotecas Python, como *matplotlib*, para visualização interativa;
- Foi implementado um sistema de marcação manual de pontos diretamente sobre a imagem, utilizando a função *ginput*, para registrar as coordenadas do gráfico, de modo que cada ponto selecionado representava uma coordenada de deslocamento e força na curva original, conforme Figura 26;


FIGURA 26 – Curva original com as linhas de carregamento (vermelho) e descarregamento (azul).



Fonte: Autora, 2025.

- Após a coleta dos pontos, foi criada uma máscara lógica para separar os dados em dois regimes, compressão (em que a derivada do deslocamento era positiva) e alívio (em que a derivada do deslocamento era negativa), como ilustrado na Figura 27.

FIGURA 27 – Máscara lógica aplicada à curva de histerese do ACT.



Fonte: Autora, 2025.

- Em seguida, esses regimes foram reunidos em única curva, curva esta que foi então rebatida do primeiro quadrante para o terceiro quadrante, pela hipótese de que o comportamento em tração seria análogo ao de compressão, como mostrado na Figura 28.

3.3.2. Resolução numérica de equações de movimento

Devido à não linearidade cúbica na rigidez do modelo, as equações de movimento foram resolvidas numericamente utilizando o método de Runge-Kutta, como exposto na seção 2.4.2. Empregou-se uma rotina com algoritmo de quarta ordem e passo de tempo determinado pela própria rotina.

Para representar a força excitadora f_v e x_v , foram consideradas duas abordagens distintas: (i) funções matemáticas clássicas de excitação (harmônica, impulsiva, degrau e rampa), utilizadas para fins comparativos e validação preliminar do modelo; e (ii) sinais experimentais medidos em vagão instrumentado, que foram adotados como base principal para simulações representativas das condições reais. Nos casos de uso de dados experimentais, as séries temporais foram tratadas e interpoladas linearmente para permitir a aplicação contínua dos valores a cada instante da simulação.

O uso, nas simulações numéricas, de registros de força obtidos experimentalmente em campo, refletindo diretamente as condições operacionais reais enfrentadas pelos engates ferroviários, é um dos destaques deste trabalho. Ressalta-se que esses registros experimentais foram previamente tratados para eliminar inconsistências, como valores duplicados, de modo a garantir qualidade nos resultados decorrentes.

Ao analisar os resultados alcançados, apresentados e discutidos no capítulo seguinte, deve-se ter em mente que o vagão constante do modelo adotado pertencia

a uma composição com 135 vagões, na configuração 2 locomotivas AC + 52 vagões + 1 locomotiva AC44 + 83 vagões + 3 locomotivas AC44. O vagão era o primeiro dos 83 vagões, tendo atrás de si, portanto, 82 vagões e 3 locomotivas AC44.

3.4. MODELO DA REDE NEURAL ARTIFICIAL (RNA)


3.4.1. Treinamento e validação do modelo

Para a implementação prática da RNA, foram definidas as seguintes configurações: três camadas ocultas com 64 neurônios cada, função de ativação ReLU nas camadas intermediárias e função linear na camada de saída. O otimizador utilizado foi o Adam, com taxa de aprendizado inicial de 0,001 e critério de parada por early stopping com paciência de 20 épocas. A regularização foi aplicada via dropout de 0,2 entre as camadas ocultas. O conjunto de dados foi dividido em 70% para treino, 15% para validação e 15% para teste. A seleção dos hiperparâmetros foi conduzida por meio de grid search, garantindo que a combinação final resultasse no menor erro médio absoluto (MAE) no conjunto de validação.

No contexto dos engates ferroviários, onde a variação de força é significativa, ajustes de exatidão nos pesos são necessários para que o modelo capture tanto os picos críticos quanto os valores médios de força. Deve-se, assim, assegurar previsões que respondam de forma proativa aos eventos de esforço e reduzam riscos de falha estrutural nos engates.

Utiliza-se então, a validação cruzada, que é uma técnica usada para garantir que o modelo generalize bem e não sofra de *overfitting* (sobreajuste excessivo aos dados de treinamento). O conjunto total de dados é dividido em partes, e o modelo é treinado em algumas dessas partes (conjunto de treinamento), e validado em outras (conjunto de validação), conforme ilustrado na Figura 28.

FIGURA 28 – Divisão entre conjunto de dados.



Fonte: Autora, 2024.

O método mais comum é a *K-fold cross-validation* (Goodfellow et al., 2016), onde os dados são divididos em k subconjuntos (folds). O modelo é treinado em $k - 1$ subconjuntos e testado no subconjunto restante. Esse processo é repetido k vezes, e a média dos resultados de validação é usada para medir o desempenho geral do modelo.

No contexto desse trabalho, a diferença entre o conjunto de teste e o conjunto de validação está relacionada à forma como os dados são utilizados para ajustar e avaliar o desempenho do modelo de rede neural artificial (RNA). O conjunto de validação possui as seguintes características:

- **Função:** Há utilização do conjunto de validação durante o treinamento do modelo para ajustar hiperparâmetros e evitar overfitting.
- **Utilização:** Há que se decidir, por exemplo, quantas camadas ocultas usar, qual função de ativação escolher e qual a melhor taxa de aprendizado, entre outros fatores. A RNA é treinada em um subconjunto dos dados e avaliada continuamente no conjunto de validação ao longo das épocas. O modelo não aprende diretamente com esses dados, mas seus resultados orientam ajustes para otimização.
- **Objetivo:** O desempenho ao longo do treinamento é monitorado, para se definir qual configuração de modelo apresenta o melhor desempenho antes de generalizar para novos dados.

Já o conjunto de teste possui as seguintes características:

- **Função:** O conjunto de teste é utilizado após o treinamento e validação, para medir a capacidade real do modelo de generalizar para novos dados.

- Utilização: Esse conjunto representa situações operacionais nunca vistas pelo modelo e é utilizado para obter métricas finais de desempenho (ex.: MAE, MAPE, R^2), apenas depois que o modelo final já foi definido. Nenhum ajuste adicional é feito a partir do conjunto de teste.
- Objetivo: Deve-se garantir que o modelo funcione bem fora do ambiente de treinamento, ou seja, em dados novos e reais.

Entende-se, neste projeto, que a validação cruzada é necessária para garantir que o modelo de RNA funcione bem com diferentes perfis de altimetria do trecho de interesse. A validação cruzada permite que o modelo seja testado em diferentes cenários, garantindo que ele consiga prever adequadamente os esforços em diversas situações operacionais, como rampas íngremes ou curvaturas acentuadas. Isso também ajuda a evitar que o modelo fique "viciado" em um subconjunto específico de dados, garantindo que ele seja eficaz em diferentes condições, e não apenas nos dados de treinamento.

3.4.2. Funcionamento da RNA

Neste trabalho, foi adotada uma arquitetura do tipo Rede Neural Densa *feedforward* totalmente conectada. Essa decisão baseou-se nas seguintes justificativas:

- A previsão do esforço longitudinal nos engates é um problema clássico de regressão não linear com múltiplas variáveis contínuas e categóricas, para o qual as MLPs são amplamente utilizadas;
- A rede do tipo *feedforward* oferece simplicidade na implementação, boa capacidade de generalização e ótimo desempenho computacional para inferência em tempo real;
- O uso de funções de ativação não lineares (ReLU) permite representar transições abruptas entre estados operacionais distintos (ex: de tração para frenagem dinâmica).

As funções de ativação, a função de perda e o otimizador também foram escolhidos com base em critérios consolidados na literatura, quais sejam:

- ReLU: evita saturação de gradientes e melhora a velocidade de convergência;
- MSE (Erro Quadrático Médio): é ideal para regressão com valores contínuos e penalização forte de grandes erros;

- Adam: apresenta excelente estabilidade e convergência mesmo com dados ruidosos e de alta dimensionalidade, ajustando taxas de aprendizado por peso.

3.4.3. Estrutura e configuração da rede

A rede neural foi configurada com:

- Camada de entrada: 30 neurônios, correspondentes a variáveis de contexto operacional, quais sejam, velocidade do trem, pressão do encanamento geral, localização, altitude, rampa e curva, além de variáveis associadas às 6 locomotivas presentes no trem, a saber, esforço trator (*tractive effort*), esforço de frenagem dinâmica (*dynamic braking effort*), posição do manípulo em tração (*throttle position*) e posição do manípulo em modo dinâmico (*dynamic brake position*);
- Camadas ocultas:
 - Primeira camada: 64 neurônios (ReLU);
 - Segunda camada: 32 neurônios (ReLU).
- Camada de saída: 1 neurônio (predição do esforço longitudinal), com ativação linear.
- Otimizador: Adam com taxa de aprendizado $\eta=0,001$;
- Função de perda: MSE.

As variáveis foram escolhidas com base em sua correlação com os esforços atuantes nos engates, observada na análise estatística dos dados instrumentados. Foram, então, incluídas as seguintes variáveis:

- Variáveis locais (altitude, rampa, curva, localização), que indicam condição de via;
- Variáveis operacionais (velocidade e pressão de freio), que indicam condições de operação;
- Variáveis dinâmicas da locomotiva, que indicam diretamente a força gerada em tração e frenagem.

A inclusão de todas as locomotivas permite que a RNA capte o comportamento distribuído da potência ao longo do trem, característica em composições longas e com múltiplas fontes de tração.

3.4.4. Considerações complementares

Como já exposto, considerou-se inicialmente a possibilidade de realizar uma integração mútua entre o modelo matemático e o modelo de RNA, buscando realimentação entre as previsões e o comportamento físico modelado. Entretanto, durante a análise dos resultados, optou-se, no momento, por adotar uma abordagem comparativa entre os dois modelos, em virtude de diferenças na natureza das saídas (*outputs*) geradas. Tem-se que:

- O modelo matemático simula a resposta dinâmica do vagão com engate considerando os parâmetros físicos correspondentes;
- A RNA realiza a previsão direta dos esforços longitudinais a partir dos sinais instrumentados.

A comparação entre os modelos permite avaliar a capacidade de cada um em reproduzir o comportamento real observado, sem necessidade de se realizar integração mútua, que poderia, por ora, introduzir inconsistências indesejadas. Assim, o trabalho avançou com a análise independente e a comparação de desempenho entre o modelo físico e o modelo baseado em aprendizagem de máquina.

4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

4.1. MODELAGEM MATEMÁTICA

4.1.1. Parâmetros para simulação numérica


Com base nas curvas de histerese construída com detalhado na seção 3.3.1, os parâmetros de rigidez e amortecimento do modelo foram determinados. No caso do amortecimento, obteve-se um coeficiente de amortecimento equivalente, como exposto na seção 2.4.2. Já no caso das constantes de rigidez linear e cúbica, elas vieram do ajuste de polinômios cúbicos às curvas de histerese. Observou-se, nos ajustes, que os termos quadráticos e constantes eram desprezíveis, resultando em funções descritas pelas seguintes equações:

- curva média ajustada: $f_{tm}(x) = 1,083 \cdot 10^6 x^3 + 1,424 \cdot 10^4 x$. (4)

- curva de carregamento ajustada: $f_{tc}(x) = 4,244 \cdot 10^5 x^3 + 2,750 \cdot 10^4 x$. (5)

Esses ajustes foram realizados considerando uma confiança estatística de 95%, conferindo confiabilidade e precisão na representação da rigidez do engate.


FIGURA 29 – Curva de histerese, regenerada e expandida, do ACT Endurance 325.



Fonte: Autora, 2025.

Figura 30 apresenta a curva força x curso obtida por instrumentação no ACT tipo Endurance 325, considerado neste trabalho, onde se observa o comportamento de histerese pertinente. As curvas de carregamento (vermelha), descarregamento (azul) e média (preta) foram extraídas, representando a resposta mecânica do engate sob diferentes condições de solicitação.

FIGURA 30 – Curva força x curso com ajuste polinomial cúbico da curva média.



Fonte: Autora, 2025.

A curva média foi ajustada por um polinômio cúbico (graficamente representado em verde na Figura 30), resultando na seguinte equação:

$$f(x) = 1,083 \cdot 10^6 x^3 + 1,424 \cdot 10^4 x. \quad (\text{kN}) \quad (6)$$

Esse ajuste permitiu determinar os coeficientes de rigidez linear e não linear cúbica, utilizados na formulação do modelo matemático (ver seção 2.4.2). Os termos quadrático e constante foram considerados desprezáveis.

Com base em todas as informações extraídas, são relacionados abaixo, de forma consolidada, os valores adotados para simulação numérica do modelo dinâmico adotado no trabalho. São eles:

- Massa do sistema: $m = 126.000 \text{ kg}$;


- Constante de rigidez linear: $k = 1,424 \cdot 10^7 \text{ N/m}$;
- Constante de rigidez não linear cúbica: $1,083 \cdot 10^9 \text{ N/m}^3$;
- Coeficiente de amortecimento viscoso equivalente: $1,47 \cdot 10^5 \text{ kg/s}$.

Esses parâmetros foram implementados no modelo matemático para reprodução dos comportamentos dinâmicos de interesse. Já as condições iniciais foram atribuídas caso a caso. Os valores apresentados foram determinados a partir de cálculos descritos na Seção 3.3.2 – Caracterização Experimental do ACT, onde se detalha o procedimento de obtenção da rigidez linear e não linear a partir das curvas de histerese medidas em ensaios. A massa do sistema foi considerada como a massa total equivalente do vagão HTT (126 t) e o coeficiente de amortecimento viscoso foi estimado a partir da área do laço de histerese, conforme descrito na mesma seção.

4.1.2. Simulações dinâmicas com o método de Runge-Kutta


Foram utilizadas, como entradas do modelo em questão, vários tipos de força (excitação). A Figura 31 e a Figura 32 apresentam, respectivamente, o deslocamento e a velocidade correspondente ao caso em que se empregou, como entrada, a força real medida no terceiro trecho dos dados de instrumentação. Foram consideradas condições iniciais nulas.

FIGURA 31 – Deslocamento x Tempo (Excitação Medida).



Fonte: Autora, 2025.

FIGURA 32 – Velocidade x Tempo (Excitação Medida).




Fonte: Autora, 2025.

Observa-se que a resposta obtida apresenta uma variação de velocidade compatível com o comportamento registrado experimentalmente, refletindo a natureza flutuante das excitações reais medidas em campo. Embora haja dispersão nos valores instantâneos, o padrão geral da resposta simulada mantém proximidade com as tendências observadas nos ensaios instrumentados, reforçando a validade do modelo adotado.

Para a excitação do tipo degrau, consideraram-se condições iniciais nulas e a aplicação de uma força que variou abruptamente de 0 a 1 MN no instante $t = 2\text{ s}$, representando um acoplamento súbito. A Figura 33 apresenta a resposta em termos de deslocamento, enquanto a Figura 34 mostra a velocidade correspondente do sistema.

FIGURA 33 – Deslocamento x Tempo (Excitação Tipo Degrau).



Fonte: Autora, 2025.

FIGURA 34 – Velocidade x Tempo (Excitação Tipo Degrau).



Fonte: Autora, 2025.

Na excitação harmônica, foi empregada uma força senoidal de frequência 1,5 Hz, com amplitude de 1 MN. A Figura 35 e a Figura 36 ilustram, de forma respectiva, o deslocamento e a velocidade correspondentes. Também aqui as condições iniciais foram nulas. Nota-se o comportamento oscilatório esperado, com estabelecimento de regime estacionário periódico, face à natureza não linear do modelo.

FIGURA 35 – Deslocamento x Tempo (Excitação Harmônica).



Fonte: Autora, 2025.


FIGURA 36 – Velocidade x Tempo (Excitação Harmônica).



Fonte: Autora, 2025.


Com excitação impulsiva, simulou-se a resposta do sistema a um impulso curto e intenso, aplicado no tempo $t = 0$ s e correspondente a uma colisão. A intensidade foi de 10 kN.s, com uma duração de 0,01 s, ainda sob condições iniciais nulas. A Figura 37 e a Figura 38 ilustram o deslocamento e a velocidade decorrentes, respectivamente.

FIGURA 37 – Deslocamento x Tempo (Excitação Impulsiva).



Fonte: Autora, 2025.


FIGURA 38 – Velocidade x Tempo (Excitação Impulsiva).



Fonte: Autora, 2025.

Simulações com e sem a rigidez cúbica demonstraram que o modelo linear subestima o deslocamento e não capta os picos com precisão. Os resultados dessas simulações, em termos de deslocamento e velocidade, são apresentados na Figura 39. Entende-se que o modelo não linear realmente apresentou maior aderência aos dados reais, como ainda é detalhado em subseções subsequentes.

.FIGURA 39 – Comparativo Linear vs. Não Linear – Deslocamento e Velocidade.




Fonte: Autora, 2025.

4.1.3. Análise no domínio da frequência

A Figura 40 mostra a função resposta em frequência (FRF) do sistema, em amplitude e fase. Essa função foi levantada graficamente através da aplicação de excitação harmônica com amplitude de 1 MN e frequência progressivamente variável de 0 e 35 rad/s, com incremento de 0,01 rad/s.

FIGURA 40 – FRF – Amplitude e Fase.



Fonte: Autora, 2025.

Observa-se, como esperado, três ramos característicos do comportamento não linear: o ramo inferior (estável), indicado em azul, o ramo intermediário (instável), indicado em vermelho, e o ramo superior (estável), indicado em verde. Nota-se ainda a ocorrência de saltos de frequência distintos quando se percorre a curva no sentido crescente e decrescente. A frequência de ressonância correspondente ao ponto de maior amplitude identificado nos gráficos acima foi de 24 rad/s (3,82 Hz).

4.1.4. Validação com dados reais de deslocamento

Com o intuito de validar o modelo matemático desenvolvido, foi realizada uma comparação entre deslocamentos simulados (via método de Runge-Kutta) e deslocamentos reais obtidos, apenas para esforços elevados, via instrumentação embarcada. Foram selecionados sete trechos onde os valores experimentais de força associados estavam próximos no tempo, o que viabilizou a reconstrução da trajetória de deslocamento. Em cada trecho, o valor inicial de deslocamento adotado na simulação numérica foi o valor real do início do intervalo considerado. A Tabela 4 apresenta os trechos analisados, com os respectivos índices, duração e regime.


TABELA 4 – Trechos de força elevada, com os respectivos regimes.

Trecho	Intervalo de índices	Duração (s)	Nº de pontos	Regime
1º	67 a 100	20 s	34	Tração
2º	127 a 191	58 s	65	Tração
3º	221 a 270	82 s	50	Compressão
4º	271 a 353	47 s	83	Tração
5º	404 a 424	26 s	21	Compressão
6º	460 a 495	26 s	36	Compressão
7º	523 a 543	10 s	21	Compressão

Fonte: Autora, 2025.

Nos trechos em compressão, observou-se forte compatibilidade entre os deslocamentos simulados e os medidos, com os resultados numéricos geralmente ligeiramente superiores. Essa diferença pode estar relacionada ao uso da curva média para o modelo de rigidez, que suaviza os extremos da resposta real. A comparação para os trechos de compressão pode ser visualizada na Figura 41.

FIGURA 41 – Comparação deslocamentos simulados vs. reais (Compressão – trechos 3, 5, 6 e 7).





Nota-se na figura 41, que os valores permanecem na mesma faixa linear (entre numérico e experimental), tendo em vista que a comparação de deslocamentos utilizou apenas a base de dados que continha os *outliers* (valores acima de 136 mil kgf, negativos e positivos, para compressão e tração respectivamente) dos esforços registrados pela instrumentação do IPT.

Por outro lado, nos trechos em tração, o modelo numérico superestimou o deslocamento real, como apresentado na Figura 42, apontando para uma possível subestimação da rigidez em tração. Para investigar essa hipótese, foi testada uma versão do modelo com rigidez linear arbitrariamente aumentada em cerca de 6 vezes, apenas no comportamento em tração. Os resultados associados a esse teste são mostrados na Figura 43.

Essa ação arbitrária melhorou substancialmente a aproximação com os dados reais, sugerindo o fato de que o engate pode apresentar uma rigidez efetiva maior sob tração. Ou seja, o engate poderia ter um comportamento não linear distinto de compressão para tração. Pode ser também outros elementos (como batentes ou folgas) contribuam para dominar a resposta no regime de tração, o que não se tem conhecimento ainda no momento.




Figura 42 – Comparação deslocamentos simulados vs. reais (Tração – trechos 1, 2 e 4).





Fonte: Autora, 2025.

Figura 433 – Comparação deslocamentos simulados vs. reais (rigidez aumentada em tração).



Fonte: Autora, 2025.

Para confirmar a hipótese de comportamento distinto em tração (de modo a não se basear apenas no rebatimento do comportamento à compressão, considerado na montagem da Figura 28, como exposto na seção 3.3.1), maiores informações vindas do fabricante seriam necessárias. A partir dessas informações adicionais, hoje não disponíveis, seria possível avançar na investigação.

4.2. MODELAGEM VIA REDE NEURAL ARTIFICIAL


4.2.1. Desenvolvimento progressivo da arquitetura da RNA

No processo de treinamento e validação da RNA, foram conduzidos diversos experimentos variando o número de neurônios nas camadas ocultas. Visou-se, com isso, avaliar o impacto dessas alterações sobre o desempenho preditivo da rede.

De início, foi testada uma arquitetura mais simples, com menor número de neurônios. Depois, foram feitas simulações com estruturas mais complexas, o que permitiu melhor extração de padrões não lineares nos dados instrumentados.

A Figura 44 apresenta a comparação entre os valores reais e os valores previstos pela rede neural em sua versão inicial (menos neurônios). Nota-se uma tendência geral de correlação, mas com dispersão considerável em torno da linha ideal $y = x$, especialmente para valores extremos de tração e compressão.


FIGURA 44 – Comparação entre valores reais e previstos pela RNA (modelo inicial, menos neurônios).



Fonte: Autora, 2025.

A Figura 45 mostra a performance da versão final da rede, com arquitetura 64–32, onde os pontos se alinham de forma muito mais precisa à linha ideal, representando previsões com menor erro e maior precisão estatística.

FIGURA 45 – Comparação entre valores reais e previstos pela RNA (modelo aperfeiçoado).



Fonte: Autora, 2025.

As métricas de avaliação quantitativa reforçam esse avanço. Elas são apresentadas na Tabela 5.

TABELA 5 – Métricas de avaliação.

Métrica	Modelo Inicial	Modelo Otimizado
MAE (tf)	6,11	3.95
MSE (tf ²)	$7,4 \times 10^8$	$3,7 \times 10^8$
Coeficiente R ²	98,4	99,2

Fonte: Autora, 2025.

4.2.2. Análise da convergência de treinamento


Para garantir que o modelo fosse não apenas preciso, mas também estável e generalizável, foi realizada uma análise detalhada da curva de aprendizado da RNA. Buscou-se observar a convergência das métricas de erro quadrático médio (MSE) e erro absoluto médio (MAE) tanto no conjunto de treinamento quanto no de validação.

A Figura 46 mostra a evolução do MSE e do MAE ao longo de 100 épocas. Nessa evolução, nota-se:

- Um padrão de convergência progressiva de ambas as métricas;
- Boa aderência entre as curvas de treino e validação, indicando baixo *overfitting*;

- Algumas oscilações pontuais no conjunto de validação (épocas 40 e 78), provavelmente causadas por instabilidades nos dados de entrada (p.ex.: picos de esforço mal representados estatisticamente).

FIGURA 46 – Convergência da função perda (MSE) e do MAE durante o treinamento da RNA.



Fonte: Autora, 2025.

Essas análises reforçam que o modelo atingiu uma convergência estável, sem apresentar sinais de sobreajuste, e com erros que se estabilizam em patamares baixos após cerca de 60 épocas. Como medida adicional, foi aplicada a *early stopping* (parada antecipada).

A análise gráfica, junto com as métricas quantitativas finais, reforça a efetividade e confiabilidade do modelo desenvolvido. Outros aspectos são abordados abaixo.

4.2.3. Análise de importância das variáveis

Com o objetivo de compreender quais fatores operacionais têm maior influência nos esforços de acoplamento, foi realizada uma análise de importância das variáveis de entrada. Embora redes neurais sejam, por natureza, modelos não lineares e menos interpretáveis, algumas abordagens permitem inferir a sensibilidade da saída frente a alterações nas entradas.

Foram utilizadas as seguintes técnicas:

- *Permutation Importance* (reordenação de variáveis);
- Análise de Gradiente (em redes treinadas via Keras).

Os resultados indicaram as variáveis com maior influência na predição do esforço. Elas estão listadas na Tabela 6. A análise de importância de variáveis também pode ser observada na Figura 47.

TABELA 6 – Variáveis com maior influência na predição do esforço.

Variável	Justificativa
<i>Train Speed</i>	Relaciona-se diretamente com a inércia do trem e propagação de esforço ao longo da composição.
Rampa e Curva	Alteram significativamente a resistência ao movimento dos vagões, afetando o esforço trator.
0000 e 0138 <i>Tractive Effort</i>	Correspondem às locomotivas da cabeça e do meio, responsáveis pela maior parte da força transmitida ao engate instrumentado.
PEG (<i>Average Brake Pipe Pressure</i>)	Indica o grau de aplicação dos freios, sendo determinante em esforços de compressão.
<i>Throttle Position</i> 0000, 0138	Indicam o comando de potência e resposta dinâmica das locomotivas.

Fonte: Autora, 2025.


4.2.4. Análise de casos extremos

Para avaliar a confiabilidade do modelo em situações críticas, foi conduzida uma análise dos casos com maior erro absoluto de predição. Ou seja, nas amostras em que a RNA mais se afastou do valor real observado.

Foram extraídos os 10 piores erros, avaliando para cada um:

- o valor real e o previsto;
- o tipo de esforço (tração ou compressão);
- as condições operacionais no momento do registro.

FIGURA 47 – Variáveis mais influentes nos esforços.



Fonte: Autora, 2025.

Os principais padrões observados foram:

- erros em extremos absolutos (valores próximos ou superiores a ± 150.000 tf);
- maior ocorrência em situações de transição entre tração e frenagem dinâmica, em que o trem ainda não havia estabilizado sua resposta;
- alguns casos com valores atípicos de *PEG* ou *Throttle Position*, sugerindo comandos ou respostas anormais (ex: degradação de resposta de válvula ou atuação parcial de locomotivas remotas).


Apesar da maior dispersão nestes pontos, a RNA manteve coerência de sinal e magnitude aproximada, com erros da ordem, em geral, de 10 a 20 mil tf. Isso representa uma margem de erro aceitável frente à amplitude total dos esforços operacionais (> 300.000 tf de variação entre pico positivo e negativo).

4.2.4.1. Esforços positivos (tração)

Na Figura 48, os casos de maior tração revelam forte influência de variáveis relacionadas à posição de acelerador (*Throttle Position*) e ao esforço trativo de locomotivas intermediárias e traseiras, especialmente as locomotivas 0054, 0138,

0139 e 0141. Os valores de z-score (uma medida estatística que indica quantos desvios padrão um certo valor está acima ou abaixo da média de um conjunto de dados) positivos acentuados nessas variáveis sugerem atuação intensa de aceleração nesses momentos, o que contribui para aumento dos esforços longitudinais em tração.

FIGURA 48 – Influência de variáveis para os esforços de tração.




Fonte: Autora, 2025.

Além disso, observa-se contribuição relevante das variáveis de velocidade, localização, inclinação de rampa e curvatura. Isso reforça a importância da topografia e do perfil da via no comportamento dinâmico da composição.

4.2.4.2. Esforços negativos (compressão)

Faz-se agora a análise da Figura 49. Nessa figura, os casos de maior compressão destacam-se como principais influenciadores.

FIGURA 49 – Influência de variáveis para os esforços de compressão.



Fonte: Autora, 2025.

Nesse caso, têm-se:

- Rampa e Altitude: com z-scores extremamente elevados (p.ex.: 2,12 para rampa), indicando segmentos de descida acentuada;
- Posições de frenagem dinâmica (*Dynamic Braking Effort* e *Position*) das locomotivas 0000 e 0001 (locomotivas de cabeça), indicando forte atuação de freios dinâmicos na extremidade frontal do trem;
- Baixos valores de tração nas locomotivas traseiras, reforçando o “empurrar passivo” e gerando acúmulo de compressão nos vagões intermediários.

Há assimetria na atuação das locomotivas ao longo da composição (cabeça ativa vs. cauda passiva). Essa assimetria e os trechos descendentes da via formam a combinação crítica para a ocorrência de esforços compressivos intensos.

4.2.5. Aplicabilidade da RNA por simulações, alertas e ferramenta prática


Com base no desempenho observado com a rede neural, foram exploradas diferentes formas de aplicação prática do modelo na operação ferroviária. A versatilidade da RNA permite seu uso não apenas como ferramenta analítica, mas como parte de sistemas ativos de suporte à decisão.

4.2.5.1. Simulações operacionais

Com o modelo treinado, foi possível realizar simulações do tipo *what-if* para verificar o impacto de alterações operacionais nos esforços longitudinais. As simulações de maior interesse são apresentadas abaixo.

A Figura 50 ilustra o efeito da redução de 50% na velocidade do trem, mantendo as demais variáveis constantes. Nota-se aumento em diversos picos de compressão, indicando que a redução de velocidade pode amplificar esforços em algumas regiões.


FIGURA 50 – Impacto da redução de 50% da velocidade nos esforços longitudinais.



Fonte: Autora, 2025.

Já a Figura 51 mostra o resultado de uma redução coordenada de velocidade, esforço trator e frenagem dinâmica. A suavização de comandos mostra-se mais efetiva na redução de picos de esforço, revelando a importância da integração entre variáveis.

FIGURA 51 – Simulação multivariável com redução coordenada de parâmetros operacionais.



Fonte: Autora, 2025.

A comparação quantitativa entre o cenário base e a simulação de redução combinada (Figura 51) indica que, apesar da proximidade geral das curvas, há diferenças perceptíveis em determinados pontos de operação. Foi calculado um erro médio absoluto (MAE) da ordem de 8.000 kgf, o que corresponde a aproximadamente 5% do esforço médio registrado. Esse valor evidencia que a estratégia de redução multivariável é eficaz em suavizar os esforços longitudinais, mantendo a coerência global com os dados originais.

4.2.5.2. Sistema inteligente de alertas preventivos

Visando viabilizar a aplicação prática da Rede Neural Artificial (RNA) em um contexto operacional, foi desenvolvido um sistema inteligente de alertas preventivos capaz de sinalizar riscos de esforços extremos nos engates, com base nas previsões do modelo. O sistema utiliza as previsões de esforço longitudinal geradas pela RNA e as compara com limiares críticos de segurança, definidos a partir de valores máximos admissíveis para compressão e tração nos engates ferroviários, a saber:

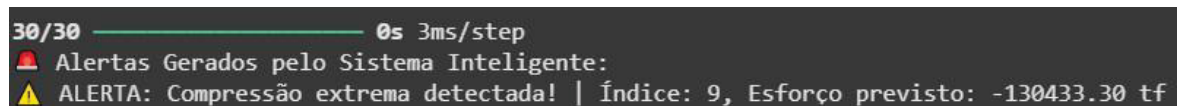
- Tração extrema: esforços superiores a +130.000 kgf.
- Compressão extrema: esforços inferiores a -130.000 kgf.

A lógica de detecção de risco é implementada em um *loop* que percorre todas as previsões geradas pelo modelo. Quando qualquer valor ultrapassa os limites mencionados, um alerta é gerado com a estrutura apresentada na figura 52.

O sistema ora proposto pode ser dividido nas seguintes etapas:

- I. Geração das previsões usando o modelo RNA previamente treinado;
- II. Retirada de normalização das saídas, convertendo de volta os valores para a unidade original (kgf);
- III. Construção de um *DataFrame* com as variáveis operacionais e o esforço previsto para cada exemplo de entrada. Nesta etapa não há criação de um novo *dataset* para treinamento, mas apenas a estruturação das variáveis operacionais e do esforço previsto em formato tabular, de forma a possibilitar a avaliação individual de cada previsão e a geração automática dos alertas
- IV. Avaliação individual de cada previsão quanto aos limites críticos estabelecidos;
- V. Exibição dos alertas com mensagens padronizadas de risco.

FIGURA 52 – Alerta de esforço crítico.



Fonte: Autora (2025).

4.2.5.3. Ferramenta prática interativa de previsão de esforços

Como desdobramento prático da Rede Neural Artificial (RNA) treinada neste estudo, foi desenvolvida uma ferramenta interativa para previsão em tempo real dos esforços longitudinais no engate, com base na entrada manual de variáveis operacionais. Essa ferramenta foi criada com o propósito de tornar o modelo acessível e aplicável diretamente por engenheiros de campo, planejadores operacionais ou profissionais de simulação.

A interface recebe como entrada os valores reais (em unidades físicas) de:

- Velocidade do trem (km/h);
- Pressão média do tubo de freio (psi);
- Altitude (m), inclinação de rampa (%), e curvatura (1/m);
- Posições de acelerador e freio dinâmico;
- Esforços de tração e frenagem dinâmica para as locomotivas 0000, 0001, 0054, 0138, 0139 e 0141.

Conforme detalhado na subseção anterior, o sistema realiza a normalização dos dados de entrada e a conversão da saída prevista para a unidade original (kgf), possibilitando a comparação com limites críticos e a emissão automática de alerta.

Ao fornecer um conjunto de valores representando uma situação real ou simulada, a ferramenta retorna instantaneamente o esforço previsto. Essa ação é ilustrada na Figura 53.

FIGURA 53 – Parâmetros de retorno do sistema de previsão.



Fonte: Autora (2025).

Essa resposta permite avaliar rapidamente se a condução está dentro dos limites operacionais aceitáveis ou se há risco iminente de falha estrutural no acoplamento. A versatilidade da abordagem abre diversas frentes de aplicação, a saber:

- Suporte a decisões de engenharia em análises de novos desenhos de trem;
- Planejamento de operações sob diferentes cenários de tração, frenagem ou velocidade;
- Capacitação de maquinistas por meio de simulações parametrizadas;
- Análise de sensibilidade para identificar variáveis mais críticas no esforço longitudinal;
- Ambiente de testes virtual para explorar limites operacionais com segurança.

A combinação da praticidade da interface com a robustez do modelo torna essa ferramenta um instrumento estratégico de análise e prevenção. Reforça, assim, o valor prático do aprendizado de máquina no contexto ferroviário.

4.2.6. Limitações de aplicação e replicabilidade

Apesar da alta acurácia obtida pela Rede Neural Artificial (RNA) desenvolvida neste trabalho, é importante destacar que o modelo apresenta limitações em sua aplicação prática, especialmente relacionadas ao escopo dos dados utilizados no treinamento. A RNA foi treinada exclusivamente com dados coletados de uma composição específica, com 135 vagões e 6 locomotivas AC44 (2 na cabeça, 1 intermediária e 3 na cauda), bem como configuração e distribuição de potência e

frenagem padronizadas, além de operação em trecho fixo da malha, com perfil de via conhecido.

Como consequência, o modelo apresenta alta especialização para esse padrão de operação. Isso poderá gerar erros de predição significativos devido à ausência de representatividade no conjunto de treinamento

O modelo, no entanto, apresenta alto grau de replicabilidade, desde que sejam seguidos os seguintes passos:

- I. Coleta de dados equivalentes (variáveis operacionais e valores reais de esforço) para outras composições;
- II. Treinamento supervisionado com novo conjunto de dados representativo das novas configurações;
- III. Ajuste da arquitetura, se necessário, para contemplar novas locomotivas, entradas ou variáveis;
- IV. Validação cruzada para garantir generalização e evitar sobreajuste.

Destaca-se que a estrutura modular da RNA (*feedforward* MLP) permite rápida adaptação. Salienta-se também que sua implementação em ambiente Python garante compatibilidade com diferentes ferramentas e sistemas operacionais.

5. CONSIDERAÇÕES FINAIS

Neste estudo, foi desenvolvido e validado um modelo matemático não linear, baseado em curva real de histerese de Aparelho de Choque e Tração (ACT). O modelo mostrou-se apto a representar, em determinadas situações, o comportamento de engates ferroviários em trens de carga. Ressalta-se, em especial, sua eficácia na simulação e análise de esforços em regimes operacionais críticos de compressão.

Paralelamente, a utilização da Rede Neural Artificial (RNA) apresentou resultados altamente satisfatórios na previsão de esforços longitudinais nos engates, com R^2 superior a 0,95 nos testes realizados. Essa abordagem possibilitou a criação de uma ferramenta prática e interativa, apta a gerar previsões rápidas em situações operacionais reais e fornecer alertas preventivos para esforços críticos, permitindo uma atuação proativa em termos operacionais.

Embora não tenha sido implementado um modelo híbrido completo, com integração direta entre o modelo matemático e o modelo via RNA, constata-se que a combinação dos resultados dos dois modelos permite comparações diretas e validações cruzadas, trazendo contribuições práticas importantes. Destacam-se especialmente:

- **Segurança Operacional:** Identificação antecipada de situações críticas, possibilitando ações corretivas antes da ocorrência de falhas graves nos engates ferroviários.
- **Manutenção Preditiva:** Possibilidade de prever e monitorar esforços extremos nos engates, direcionando ações de manutenção para os pontos mais vulneráveis, reduzindo custos e interrupções operacionais.
- **Otimização da Condução:** Avaliação prévia do impacto das estratégias operacionais (ajuste de velocidade, distribuição da tração e frenagem) para redução efetiva de picos críticos de esforços longitudinais.

No entanto, cabe ressaltar que os modelos apresentados têm algumas limitações importantes. No caso do modelo físico, ainda não se chegou a uma boa representação quando da ocorrência de esforços críticos em tração. Também ainda não se encontra contemplada a associação de engates em série, algo usual nas composições ferroviárias.

No tocante ao modelo via RNA, há a questão da generalização dos resultados, visto que o estudo foi realizado com base em dados específicos de uma composição

ferroviária com configuração bem definida (135 vagões e 6 locomotivas AC44, em disposição específica), operando em um trecho ferroviário particular. Assim, a aplicação direta desses modelos a outras composições ou condições operacionais diferentes requer adaptações adicionais, ajustes nos parâmetros dos modelos e novas validações com dados representativos dessas novas condições.

Como recomendações futuras, sugere-se explorar diretamente a integração entre modelos matemáticos e técnicas de aprendizado de máquina em arquiteturas híbridas. Nesse contexto, destaca-se o potencial de aplicação das *Physics-Informed Neural Networks* (PINNs), que permitem incorporar explicitamente as equações diferenciais que regem a dinâmica dos engates ao processo de treinamento da rede neural. Tal abordagem poderia potencializar ainda mais a capacidade de predição robusta das ferramentas desenvolvidas, ampliando a eficácia em cenários operacionais diversos.

Expõe-se também que a metodologia desenvolvida para a modelagem da RNA abre portas para diversas possibilidades futuras, dentre as quais indicam-se:

- Modelos generalistas treinados com múltiplas composições (p.ex.: 120, 135, 160 vagões), capazes de atuar como preditores adaptativos;
- Desenvolvimento de *dashboards* operacionais, embarcando o modelo em tablets de maquinistas ou simuladores para testes em tempo real.

Entende-se que, apesar da complexidade do sistema investigado e de suas condições de operação, o trabalho realizado não só alcançou objetivos propostos como também apresenta contribuições de interesse para o setor ferroviário.

6. REFERÊNCIAS

Amaral, M. C. Emprego e otimização de redes neurais artificiais na classificação de trincas detectadas por ultrassom em engates metálicos de vagões ferroviários. Dissertação (mestrado). Instituto Federal do Espírito Santo, Programa de Pós-Graduação em Engenharia Metalúrgica e de Materiais, Vitória, ES, 2021.

Disponível em:

https://repositorio.ifes.edu.br/bitstream/handle/123456789/1490/DISSERTAÇÃO_Em_prego_Otimização_Redes_Neuralis_Artificiais.pdf?sequence=1&isAllowed=y.

Amsted Rail Company, Inc. Draft Gear Endurance 325™ Friction Draft Gear Sell Sheet. Chicago, 2018. Disponível em: <https://www.amstedrail.com/wp-content/uploads/2019/08/DraftGear-SellSheet-3-18.pdf>. Acesso em: 06 mai. 2024.

ASSOCIAÇÃO NACIONAL DOS TRANSPORTADORES FERROVIÁRIOS – ANTF.

As ferrovias nos trilhos do desenvolvimento. Brasília: ANTF, 2014.

Disponível em:

<http://www2.antf.org.br/antf/images/stories/material-institucional/documento-dos-presidenciaveis-ago2014.pdf>>. Acesso em: 02 set. 2025.

Barbosa, R. S. Estudo da dinâmica longitudinal do trem. Dissertação (mestrado). Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP, 1993. Disponível em:

<http://libdigi.unicamp.br/document/?code=vtls000069888>.

Bernal, E. et al. Augmented digital twin for railway systems. *Vehicle System Dynamics*, Volume 62, Issue 1, pp. 67-83, 2024. Disponível em:

<https://ui.adsabs.harvard.edu/abs/2024VSD....62...67B/abstract>.

BISHOP, Christopher M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.

FREITAS. Fundamentos de vagões MRS. Juiz de Fora: [s.n.], 2015.

Gao, M. et al. Dynamic modeling and experimental investigation of self-powered sensor nodes for freight rail transport, *Applied Energy*, Volume 257, 2020.

Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0306261919316563>.

Goodfellow, I., Bengio, Y., Courville, A. *Deep Learning*. MIT Press, Cambridge, MA, 2016. Disponível em: <http://www.deeplearningbook.org>.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009.

Hungria, L. H. *Segurança Operacional de Trens de Carga* (2ª. edição). All Print Editora, Curitiba, PR, 2018.

Inman, D. J. *Vibrações Mecânicas* (tradução da 4ª edição), Elsevier / GEN, 2018.

IPT. Análise dos dados da instrumentação dos vagões HPT e HTT, viagens realizadas entre os dias 13/11/2023 e 17/05/2024. Relatório Técnico nº 168 446-205. São Paulo: Unidade de Negócios em Energia - EN, Laboratório de Infraestrutura em Energia – LInE, 2023.

Kim, N., Park, Y. Collision tests and model development of a train coupling system using a high-capacity energy absorber. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, Volume 232, Issue 9, 2018. Disponível em: <https://journals.sagepub.com/doi/10.1177/0954409718766930>.

Lindfield, G. & Penny, J. *Numerical Methods using Matlab* (4th edition). Academic Press/Elsevier, 2019.

Medeiros Júnior, W. B., Prêve, C. T., Balbino, F. O., Silva, T. A., Lopes, E. M. O. On an Integrated Dynamic Characterization of Viscoelastic Materials by Fractional Derivative and GHM Models, *Latin American Journal of Solids and Structures*, vol. 16(2), doi 10.1590/1679-78254983, 2019.

Moraes, C. G. S. Análise e Concepção de um Sistema Híbrido de Armazenamento de Energia para Aplicação em Locomotivas Diesel-Elétricas. Dissertação (mestrado). Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, SC, 2020. Disponível em: <https://repositorio.ufsc.br/handle/123456789/216618>.

Oliveira Junior, A. J. S. Forças e choques na dinâmica longitudinal de composições ferroviárias. Dissertação (mestrado). Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP, 2017. Disponível em: <https://core.ac.uk/download/pdf/296888822.pdf>.

Rosa, P. M. C. F. *Sistemas de Choque e Tração*. Disciplina ministrada na Pós-Graduação em Engenharia Ferroviária na AmstedMaxion. 2012.

Vargas, J. V. C., Araki, L. K., *Cálculo Numérico Aplicado*, Manole, 2017.

Wabtec Corporation, Tabela de Esforço Trator da Locomotiva AC44i, 2018.

Wabtec Corporation, Mark 70E Freight Car Draft Gear - AAR M901E, 2001.

Wijesundara, K.K., Nascimbene, R., Sullivan, T.J. Equivalente viscous damping for steel concentrically braced frame structures. *Bulletin of Earthquake Engineering*, vol. 9, pp. 1535-1558, doi 10.1007/s10518-011-9272-4, 2011.

Worden, K., Tomlinson, G.R. *Nonlinearity in Structural Dynamics – Detection, Identification and Modelling*. IOP Publishing Ltd, 2001.

Wu, Q. et al. Railway Virtual Coupling: A Survey of Emerging Control Techniques. *IEEE Transactions on Intelligent Vehicles*, Volume 8, No. 5, pp. 3239-3255, 2023. Disponível em: <https://ieeexplore.ieee.org/document/10079173>.

Zhang, S., Huang, P., Yan, W. A data-driven approach for railway in-train forces monitoring. *Advanced Engineering Informatics*, Volume 59, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1474034623003865>.