

LETÍCIA LORENA CONCEIÇÃO ARAÚJO

**DETECÇÃO DE FOLGA EM CUNHAS DE GERADORES
HIDRELÉTRICOS VIA MONITORAMENTO DE
PARÂMETROS VIBRATÓRIOS**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

2026

LETÍCIA LORENA CONCEIÇÃO ARAÚJO

**DETECÇÃO DE FOLGA EM CUNHAS DE GERADORES
HIDRELÉTRICOS VIA MONITORAMENTO DE
PARÂMETROS VIBRATÓRIOS**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Mecânica da Universidade
Federal de Uberlândia como parte dos requisitos
para obtenção do título de Bacharel em Engenharia
Mecânica.

Faculdade de Engenharia Mecânica

Orientador: Prof. Dr. Aldemir Aparecido Cvallini Junior
Coorientador: Prof. Dr. Marcus Antonio Viana Duarte

**Uberlândia - MG
2026**

LETÍCIA LORENA CONCEIÇÃO ARAÚJO

**LOOSENESS'S DETECTION IN HYDROGENERATORS'S
WEDGES BY MONITORING VIBRATORY PARAMETERS**

Final Paper submitted to the Faculty of Mechanical Engineering from Federal University of Uberlândia in partial fulfillment of the requirements for the degree of Mechanical Engineer.

Faculty of Mechanical Engineering

Advisor: Prof. Dr. Aldemir Aparecido Cvallini Junior

Co-advisor: Prof. Dr. Marcus Antonio Viana Duarte

Uberlândia - MG

2026

LETÍCIA LORENA CONCEIÇÃO ARAÚJO

**DETECÇÃO DE FOLGA EM CUNHAS DE GERADORES
HIDRELÉTRICOS VIA MONITORAMENTO DE
PARÂMETROS VIBRATÓRIOS**

Trabalho de Conclusão de Curso apresentado
à Faculdade de Engenharia Mecânica da
Universidade Federal de Uberlândia como
parte dos requisitos para obtenção do título de
Bacharel em Engenharia Mecânica.

Faculdade de Engenharia Mecânica

Uberlândia, 29 de janeiro de 2026.

Banca Examinadora:

Aldemir Aparecido Cavallini Júnior – Professor Doutor (UFU)

Marcus Antonio Viana Duarte – Professor Doutor (UFU)

Lucas Costa Brito – Pós-Doutorando (UFU)

*Dedico este trabalho aos meus pais,
pelo estímulo, carinho e compreensão.*

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, que foram a base de tudo. Pelo exemplo, pela educação e por me ensinarem o valor transformador do conhecimento, incentivando-me e apoiando-me incondicionalmente na decisão de trilhar meu caminho na Universidade Federal de Uberlândia. À UFU, expresso minha gratidão pela excelência no ensino e pelas oportunidades concedidas. Um agradecimento especial ao Laboratório de Acústica e Vibração (LAV) e ao Laboratório de Mecânica de Estruturas (LMEST), que me acolheram e permitiram minha imersão em projetos de grande impacto junto a empresas como a Petrobras e a CPFL, proporcionando um aprendizado prático e técnico que levarei para toda a vida profissional.

Neste contexto de aprendizado, gostaria de destacar a importância fundamental dos professores Marcus Antonio Viana Duarte e Aldemir Aparecido Cavallini Junior. Agradeço por me aceitarem como orientada e por compartilharem seus conhecimentos e amor pela vida acadêmica com tanta dedicação. Por fim, e não menos importante, estendo minha gratidão a todos os amigos, colegas e professores que estiveram ao meu lado durante a graduação. A torcida, o companheirismo e a convivência diária tornaram essa jornada não apenas possível, mas inesquecível. A todos que, direta ou indiretamente, fizeram parte da minha formação, o meu muito obrigada.

*“Ninguém ignora tudo. Ninguém sabe tudo.
Todos nós sabemos alguma coisa.
Todos nós ignoramos alguma coisa.”
(FREIRE, 2002, p. 69)*

RESUMO

ARAÚJO, L. L. C. **DETECÇÃO DE FOLGA EM CUNHAS DE GERADORES HIDRELÉTRICOS VIA MONITORAMENTO DE PARÂMETROS VIBRATÓRIOS**. 2026. 43 p. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia - MG, 2026.

A integridade e a eficiência de geradores hidrelétricos dependem diretamente do sistema de fixação das barras do estator, realizado por cunhas e molas laminadas. Esse conjunto compensa dilatações térmicas e tolerâncias geométricas; contudo, seu afrouxamento configura uma falha crítica. A perda de aperto permite vibrações sob a ação de forças eletromagnéticas, o que acelera a degradação do isolamento e intensifica as correntes parasitas. Consequentemente, o gerador sofre uma redução em sua capacidade de conversão de energia. Diante dessa problemática, este trabalho propõe uma metodologia para classificar o nível de aperto de cunhas magnéticas através do monitoramento de parâmetros vibratórios. A abordagem integra procedimentos experimentais e numéricos em um sistema simplificado (cunha de 200 mm e mola *top ripple* de 1 mm). Inicialmente, realizou-se a caracterização dinâmica do conjunto em bancada sob excitação por ruído branco para identificar suas frequências naturais. Paralelamente, desenvolveu-se um modelo por Método dos Elementos Finitos (MEF), calibrado via otimização paramétrica das propriedades mecânicas. Para a cunha, obteve-se módulo de Young (E) de 35 GPa e coeficiente de Poisson (ν) de 0.2; para a mola, $E = 40$ GPa e $\nu = 0.2$. Com o modelo calibrado, simulações transientes geraram 100 sinais de aceleração para cada condição de aperto: “solto” (compressão de 5 a 11 N) e “preso” (11 a 15 N). A etapa final consistiu no treinamento e validação de três algoritmos de classificação utilizando dados experimentais: *k-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM) e *Autoencoder*. Os resultados demonstraram alta similaridade entre os sinais sintéticos e reais. O algoritmo SVM apresentou o melhor desempenho, com 95% de acurácia, seguido pelo KNN (92%) e pelo *Autoencoder* (83%), confirmando o potencial da metodologia para a detecção de folgas em cunhas.

Palavras-chave: Cunhas, Geradores Hidrelétricos, Manutenção Preditiva, Algoritmos de classificação, Detecção de Folga.

ABSTRACT

ARAÚJO, L. L. C. **Looseness's Detection in hydrogenerators's wedges by monitoring vibratory parameters**. 2026. 43 p. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia - MG, 2026.

The integrity and efficiency of hydroelectric generators are directly dependent on the stator bar fastening system, composed of wedges and ripple springs. This assembly compensates for thermal expansion and geometric tolerances; however, its loosening constitutes a critical failure. Insufficient clamping allows vibrations under electromagnetic forces, accelerating insulation degradation and intensifying eddy current losses. Consequently, the generator experiences a reduction in its energy conversion capacity. To address this issue, this work proposes a methodology for classifying the tightness level of magnetic wedges through the monitoring of vibratory parameters. The approach integrates experimental and numerical procedures using a simplified system (200 mm wedge and 1 mm top ripple spring). Initially, the dynamic characterization of the assembly was performed on an experimental bench under white noise excitation to identify its natural frequencies. In parallel, a Finite Element Method (FEM) model was developed and calibrated via parametric optimization of mechanical properties. For the wedge, a Young's modulus (E) of 35 GPa and a Poisson's ratio (ν) of 0.2 were obtained; for the spring, $E = 40$ GPa and $\nu = 0.2$. With the calibrated model, transient simulations generated 100 acceleration signals for each condition: "loose" (clamping force from 5 to 11 N) and "tight" (11 to 15 N). The final stage involved the training and validation of three classification algorithms using experimental data: *k-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), and *Autoencoder*. The results demonstrated high similarity between synthetic and real signals. The SVM algorithm showed the best performance with 95% accuracy, followed by KNN (92%) and *Autoencoder* (83%), confirming the potential of the methodology for detecting looseness in wedges.

Keywords: Wedges, Hydroelectric Generators, Predictive Maintenance, Classification Algorithms, Looseness Detection.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estator de gerador hidrelétrico.	18
Figura 2 – Cunhas no estator.	19
Figura 3 – Esquema ilustrativo do KNN.	25
Figura 4 – Interpretação geométrica da SVM.	26
Figura 5 – Arquitetura típica de autoencoder.	27
Figura 6 – Gerador de Sinais.	28
Figura 7 – Montagem do Experimento.	29
Figura 8 – Modelos da cunha e da mola.	30
Figura 9 – Modelo do Sistema Cunha-Mola.	31
Figura 10 – Bancada desenvolvida para simular o aperto nas cunhas.	32
Figura 11 – Sinal de batidas de martelo coletados em laboratório.	32
Figura 12 – Impulso.	33
Figura 13 – Comparação entre sinais: (a) sinal real e (b) sinal sintético.	36
Figura 14 – Sinais medidos em diferentes posições.	37
Figura 15 – Comparação entre sinais: (a) Cunha Presa e (b) Cunha Solta.	37
Figura 16 – Matriz de confusão do classificador KNN (92%).	38
Figura 17 – Matriz de confusão do classificador SVM (95%).	39
Figura 18 – Matriz de confusão do classificador Autoencoder (83%).	39

LISTA DE TABELAS

Tabela 1 – Frequência Naturais Experimentais.	29
Tabela 2 – Propriedades físicas estimadas para cunha e mola.	35
Tabela 3 – Propriedades mecânicas identificadas para cunha e mola.	35

LISTA DE ABREVIATURAS E SIGLAS

AE	<i>Autoencoder</i>
EMA	<i>Experimental Modal Analysis</i>
FN	Falso Negativo
FP	Falso Positivo
FRF	<i>Frequency Response Function</i>
IA	Inteligência Artificial
KNN	<i>k-Nearest Neighbors</i>
LAV	Laboratório de Acústica e Vibração
LMEST	Laboratório de Mecânica de Estruturas
MEF	Método de Elementos Finitos
NI	<i>National Instruments</i>
OMA	<i>Operational Modal Analysis</i>
RBF	<i>Radial Basis Function</i>
RMS	<i>Root Mean Square</i>
SHM	<i>Structural Health Monitoring</i>
SVM	<i>Support Vector Machine</i>

LISTA DE SÍMBOLOS

E — Módulo de Young

ν — Coeficiente de Poisson

k — Rigidez

k_{eq} — Rigidez equivalente

k_{cunha} — Rigidez equivalente da cunha

k_{mola} — Rigidez equivalente da mola

m — Massa

m_{eq} — Massa equivalente

ω_n — Frequência natural (rad/s)

f_n — Frequência natural (Hz)

F — Força

$\delta_{\max}$ — Deflexão máxima

I — Momento de inércia geométrico

b — Largura da seção

t — Espessura da seção

L — Comprimento

A_{tr} — Área transversal

ρ — Densidade

γ — Parâmetro do kernel RBF (SVM)

C — Parâmetro de penalização (SVM)

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Justificativa	16
1.2	Objetivo Geral	17
1.3	Objetivos Específicos	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	O Estator e as Cunhas Magnéticas	18
2.2	Dinâmica Estrutural das Cunhas	20
2.3	Método de Elementos Finitos e Model Updating	23
2.4	Inteligência Artificial aplicada ao Monitoramento de Condição (SHM)	24
2.4.1	<i>KNN</i>	24
2.4.2	<i>SVM</i>	25
2.4.3	<i>Autoencoders</i>	26
3	METODOLOGIA	28
3.1	Procedimento Experimental	28
3.2	Otimização do Modelo	30
3.3	Geração dos Dados Sintéticos	31
3.4	Procedimento Experimental na Bancada	32
3.5	Pré-processamento dos Dados de Treinamento e Validação	33
3.6	Implementação dos Algoritmos de Classificação	34
4	RESULTADOS E DISCUSSÕES	35
4.1	Propriedades Físicas	35
4.2	Propriedades Mecânicas e Elásticas	35
4.3	Sinais Sintéticos	36
4.4	Classificadores	38
5	CONCLUSÕES	41
5.1	Trabalhos Futuros	42
	REFERÊNCIAS	44

INTRODUÇÃO

O Brasil possui uma das matrizes elétricas mais limpas e renováveis do mundo, com a fonte hídrica respondendo por aproximadamente 60% da capacidade instalada nacional. De acordo com dados do Operador Nacional do Sistema Elétrico, o sistema elétrico brasileiro conta com mais de 200 usinas hidrelétricas de grande porte, totalizando uma potência instalada superior a 100 GW, o que evidencia a relevância estratégica desse tipo de empreendimento para o suprimento energético do país (ONS, 2024; EPE, 2023). Diante do crescimento contínuo da demanda por energia elétrica e da necessidade de operação ininterrupta dos geradores hidrelétricos ao longo de sua vida útil, que frequentemente ultrapassa várias décadas, torna-se fundamental assegurar elevados níveis de disponibilidade e confiabilidade dessas máquinas. Nesse contexto, a realização de atividades sistemáticas de manutenção e monitoramento da integridade dos equipamentos é essencial para garantir a segurança operacional e a eficiência energética do sistema.

O funcionamento de um hidrogerador baseia-se na conversão de energia mecânica em elétrica a partir da rotação do rotor no interior do estator, onde se encontram as barras de enrolamento responsáveis pela indução eletromagnética. Durante a operação, essas barras são submetidas a elevadas correntes e intensos campos magnéticos, originando forças eletromagnéticas pulsantes que tendem a induzir vibrações e deslocamentos mecânicos. Para assegurar a estabilidade dos enrolamentos, utilizam-se cunhas de estator instaladas na boca das ranhuras do núcleo, cuja função é travar mecanicamente as barras e resistir aos esforços eletromagnéticos, térmicos e dinâmicos atuantes. A fixação da cunha ao estator é realizada por um sistema de pré-carga, tipicamente composto por uma mola de fixação do tipo top ripple spring (lâmina ondulada), posicionada sob a cunha, que mantém pressão de contato contínua e reduz a possibilidade de afrouxamento devido a vibrações e ciclos térmicos.

Em projetos modernos, são frequentemente empregadas cunhas magnéticas fabricadas a partir de compósitos poliméricos reforçados com fibras de vidro e partículas ferromagnéticas,

uma vez que esses materiais permitem melhorar a distribuição do fluxo magnético no dente do estator, reduzindo perdas magnéticas e o aquecimento local, contribuindo assim para a eficiência e confiabilidade do gerador (KASTEN, 1999; WANG, 2010).

Ao longo do tempo de operação, contudo, as cunhas estão sujeitas a um processo gradual de afrouxamento decorrente de mecanismos como relaxamento viscoelástico e fluência dos materiais poliméricos, ciclos térmicos associados às variações de carga e vibrações induzidas pelas forças eletromagnéticas. A perda progressiva da pressão de contato entre a cunha, a mola e as paredes da ranhura resulta na redução da rigidez local do sistema, favorecendo microdeslizamentos e impactos intermitentes das barras de enrolamento. Como consequência, ocorre o desgaste do sistema de isolamento por abrasão mecânica e intensificação de descargas parciais, o que pode levar à elevação das perdas, ao aquecimento excessivo e, em casos extremos, a falhas catastróficas do estator, como curtos-circuitos entre espiras ou fase-terra (STONE et al., 2008; IEEE, 2010). Dessa forma, a detecção precoce do afrouxamento das cunhas constitui um aspecto fundamental para a manutenção preditiva e para a extensão da vida útil de geradores hidrelétricos.

1.1 Justificativa

Tradicionalmente, a avaliação da condição das cunhas é realizada por meio de metodologias clássicas de inspeção, como o ensaio por percussão manual (tap test), inspeções visuais detalhadas e, em alguns casos, medições instrumentadas de resposta dinâmica local. Embora amplamente difundidos, esses métodos apresentam limitações relevantes. Em primeiro lugar, são procedimentos invasivos, que exigem a parada da unidade e, frequentemente, a remoção do rotor, resultando em longos tempos de indisponibilidade (semanas ou até meses). Além disso, envolvem riscos ocupacionais aos operadores, que precisam trabalhar em espaços confinados e executar tarefas repetitivas no interior do estator. Do ponto de vista técnico, muitos desses métodos são fortemente dependentes da experiência do inspetor, apresentando elevado grau de subjetividade e limitada capacidade de quantificação e rastreabilidade dos resultados ao longo do tempo. Ademais, tais inspeções são realizadas em condição estática, não representando fielmente o comportamento do sistema sob regime de operação, no qual as forças eletromagnéticas e os efeitos térmicos desempenham papel fundamental.

Em contrapartida, este trabalho propõe uma abordagem tecnológica baseada no monitoramento de parâmetros vibratórios, eliminando a subjetividade humana e aumentando a segurança operacional. Ao integrar ensaios experimentais em bancada a modelos computacionais de elementos finitos, essa metodologia possibilita a geração de um banco de dados, atacando um problema real em ambiente industrial, a escassez de dados.

1.2 Objetivo Geral

Desenvolver e validar uma metodologia para detectar o estado de aperto de cunhas em geradores hidrelétricos, utilizando o monitoramento de parâmetros vibratórios, técnica de geração de dados sintéticos via Método de Elementos Finitos (MEF) e implementação de algoritmos de classificação de inteligência artificial para auxiliar o diagnóstico de manutenção preditiva.

1.3 Objetivos Específicos

1. Desenvolver um modelo numérico representativo do conjunto cunha–mola utilizando o Método dos Elementos Finitos (MEF);
2. Identificar as propriedades elásticas da cunha e da mola, especificamente o módulo de Young (E) e o coeficiente de Poisson (ν), por meio da correlação entre dados experimentais de análise modal experimental e modelos numéricos, empregando otimização paramétrica;
3. Gerar sinais sintéticos de aceleração representativos dos diferentes estados de aperto;
4. Extrair características relevantes desses sinais no domínio do tempo e da frequência;
5. Implementar e comparar o desempenho de algoritmos de classificação baseados em KNN, SVM e autoencoders, discutindo as limitações do modelo e as perspectivas de aplicação da metodologia em sistemas reais.

FUNDAMENTAÇÃO TEÓRICA

2.1 O Estator e as Cunhas Magnéticas

O estator (Figura 1) constitui um dos principais componentes estruturais e funcionais do gerador hidrelétrico, sendo responsável pela conversão da energia mecânica em energia elétrica por meio da indução eletromagnética. Ele é composto por um núcleo formado por chapas de aço silício laminadas, empilhadas axialmente, que apresentam ranhuras destinadas ao alojamento das barras de enrolamento de cobre. Durante a operação do gerador, a interação entre o campo magnético produzido pelo rotor e as correntes elétricas que percorrem os enrolamentos do estator gera forças eletromagnéticas de caráter pulsante e periódico. Essas forças atuam predominantemente no sentido radial e tangencial, tendendo a deslocar as barras para fora das ranhuras, o que pode comprometer a integridade mecânica e elétrica do sistema caso não haja um mecanismo de fixação adequado (STONE et al., 2008).


Figura 1 – Estator de gerador hidrelétrico.



Fonte: Bilfinger (2024).

Para garantir a imobilização das barras de enrolamento no interior das ranhuras, utilizam-se cunhas de estator (Figura 2), instaladas longitudinalmente na boca dos slots do núcleo. Essas cunhas exercem a função de travamento mecânico, resistindo às forças eletromagnéticas, térmicas e dinâmicas impostas durante a operação do gerador. De forma geral, as cunhas podem ser classificadas em não magnéticas, magnéticas e semimagnéticas. As cunhas não magnéticas são tradicionalmente fabricadas em materiais compósitos à base de resinas epóxi reforçadas com fibras de vidro, oferecendo elevada resistência mecânica e bom isolamento elétrico. Já as cunhas magnéticas e semimagnéticas incorporam partículas ferromagnéticas, como pó de ferro ou ferritas, à matriz polimérica, com o objetivo de modificar o comportamento do campo magnético na região do entreferro (KASTEN, 1999).

Figura 2 – Cunhas no estator.



Fonte: Fenhar (2024).

Segundo Wang (2010), o uso de cunhas magnéticas permite reduzir a relutância magnética nos dentes do estator, promovendo uma distribuição mais uniforme do fluxo magnético e atenuando os harmônicos associados à geometria das ranhuras. Como consequência, observa-se a redução das perdas magnéticas locais, do aquecimento nos dentes do estator e do ruído eletromagnético, contribuindo para a melhoria do desempenho térmico e elétrico do gerador. Esses benefícios tornam as cunhas magnéticas amplamente empregadas em geradores hidrelétricos de médio e grande porte, nos quais a eficiência e a confiabilidade operacional são requisitos críticos.

A integridade do sistema de fixação das barras de enrolamento é assegurada pela pré-carga exercida pelas cunhas, frequentemente em conjunto com molas de preenchimento ou elementos resilientes posicionados sob elas. Entretanto, ao longo da vida útil do gerador, esse sistema está sujeito a um processo gradual de degradação. Durante a operação normal, a temperatura do estator pode variar significativamente, partindo de valores próximos à temperatura ambiente quando o gerador está parado (tipicamente entre 25 °C e 40 °C) e atingindo valores entre 80 °C e 120 °C em regime permanente de carga, dependendo da classe térmica do isolamento e das condições de refrigeração (STONE et al., 2008; IEEE, 2010). Esses ciclos térmicos repetitivos induzem dilatações diferenciais entre o cobre, o aço do núcleo e os materiais poliméricos das

cunhas, favorecendo o relaxamento viscoelástico e a fluência sob compressão constante.

Além dos efeitos térmicos, as vibrações mecânicas induzidas pelas forças eletromagnéticas pulsantes e por eventuais transitórios severos, como curtos-circuitos próximos ao gerador, contribuem para a redução progressiva da pressão de contato entre a cunha e as paredes da ranhura. Moore (2005) destaca que, uma vez perdida a condição de aperto adequado, as barras de enrolamento passam a vibrar livremente dentro do slot, caracterizando um regime de contato intermitente. Esse comportamento é altamente prejudicial, pois provoca desgaste por abrasão mecânica e fretting, degradando o sistema de isolamento das barras e favorecendo o surgimento de descargas parciais. A progressão desses fenômenos pode culminar em falhas dielétricas severas, como curtos-circuitos entre espiras ou fase-terra, resultando em paradas não programadas, elevados custos de reparo e redução significativa da disponibilidade do hidrogenador.

2.2 Dinâmica Estrutural das Cunhas

A identificação do estado de integridade de componentes mecânicos, como as cunhas magnéticas, fundamenta-se na análise de sua resposta dinâmica. De acordo com Mottershead e Friswell (1993), qualquer alteração nas condições de contorno ou na rigidez de uma estrutura — como a perda de pré-carga de uma mola ou o afrouxamento de uma fixação — resulta em modificações mensuráveis em seus parâmetros dinâmicos, especialmente em suas frequências naturais, modos de vibrar e níveis de amortecimento. No contexto das cunhas de estator, a transição do estado “preso” para o “solto” altera a rigidez efetiva do conjunto cunha-ranhura-barras, produzindo deslocamentos de frequência, tipicamente para valores mais baixos, e mudanças no amortecimento aparente devido ao aumento de atrito e microimpactos associados a contato intermitente, fenômenos característicos de sistemas com folga mecânica (MOTTERSHEAD; FRISWELL, 1993).

Para quantificar essas mudanças, utiliza-se frequentemente a Função de Resposta em Frequência (FRF), que estabelece a relação matemática, no domínio da frequência, entre o sinal de excitação (entrada) e a resposta vibratória (saída) da estrutura. Em análises experimentais, a identificação visual das frequências naturais em analisadores é realizada por meio do diagrama de Bode da FRF. No gráfico de magnitude, cada modo estrutural manifesta-se como um pico de ressonância, caracterizado por um máximo local de amplitude. Concomitantemente, no gráfico de fase, observa-se uma variação aproximada de 90° na vizinhança da frequência natural, o que constitui um critério fundamental para a confirmação do modo e para a distinção entre ressonâncias físicas e picos espúrios associados a ruído ou efeitos numéricos. Essa combinação entre pico de magnitude e mudança de fase de 90° é amplamente adotada na Análise Modal Experimental (EMA) para a identificação confiável de modos vibratórios. Outra abordagem possível quando em aplicações a medição direta da força de excitação é complexa ou inviável, recorre-se à Análise Modal Operacional (OMA), na qual os parâmetros modais são estimados

exclusivamente a partir dos sinais de resposta, assumindo que a excitação presente possui conteúdo espectral amplo. Segundo Caicedo (2011), essa abordagem permite a extração confiável de frequências naturais e amortecimento mesmo na ausência da medição explícita da força excitadora (CAICEDO, 2011). Sabendo da entrada e da saída como é o caso desse trabalho, o mais indicado é a Análise Modal Experimental (EMA).

A sensibilidade dos parâmetros dinâmicos constitui o fundamento do diagnóstico vibro-acústico e das técnicas de Monitoramento da Saúde Estrutural (*Structural Health Monitoring* – SHM). Doebling, Farrar e Prime (1998) destacam que o dano deve ser interpretado como qualquer alteração física que modifique as propriedades dinâmicas do sistema, justificando o uso de descritores extraídos do sinal vibratório (*features*) para inferir estados estruturais. Para a detecção de folga em sistemas com contato e pré-carga, como cunhas e molas de preenchimento, a literatura aponta como principais parâmetros: (i) o deslocamento das frequências naturais e alterações nas formas modais, uma vez que $\omega_n \propto \sqrt{k/m}$, onde ω_n representa a frequência natural em rad/seg, k representa a rigidez do sistema (N/m) e m a massa do sistema (kg); (ii) o aumento do amortecimento aparente, associado a atrito e microdeslizamentos; (iii) a redistribuição da energia espectral em bandas específicas de frequência; e (iv) descritores estatísticos no domínio do tempo, como RMS, fator de crista e *kurtosis*, sensíveis a impulsividade e impactos intermitentes típicos de sistemas com folga (RANDALL, 2011). Complementarmente, métodos tempo-frequência baseados em transformadas wavelet permitem identificar fenômenos não estacionários associados à abertura e fechamento do contato, ampliando a capacidade de diagnóstico em estágios iniciais de afrouxamento.

Do ponto de vista de modelagem, a alteração da resposta dinâmica pode ser interpretada por meio da variação da rigidez equivalente do conjunto. Uma aproximação clássica consiste em representar a cunha como um elemento elástico submetido predominantemente à compressão, cuja rigidez pode ser expressa em função do módulo de Young do material, segundo:

$$k_{\text{cunha}} = \frac{E_{\text{cunha}} A_{\text{tr}}}{L_{\text{ef}}}, \quad (2.1)$$

onde E_{cunha} é o módulo de Young do material da cunha em Pa, A_{tr} é a área transversal em m² e L representa o comprimento do componente deformado em m. Essa relação evidencia que variações no módulo elástico ou na condição de contato afetam diretamente a rigidez do sistema e, consequentemente, suas frequências naturais.

Em modelos reduzidos, a cunha e os elementos resilientes associados, como as molas de preenchimento, podem ser representados como elementos elásticos em série, resultando em uma rigidez equivalente dada por:

$$\frac{1}{k_{\text{eq}}} = \frac{1}{k_{\text{cunha}}} + \frac{1}{k_{\text{mola}}}. \quad (2.2)$$

Essa formulação indica que a perda de rigidez de qualquer um dos componentes — por exemplo, devido à fluência ou relaxação da mola — resulta em uma redução significativa da rigidez global do sistema, mesmo que a cunha permaneça estruturalmente íntegra.

A mola de preenchimento pode ser modelada como uma viga prismática submetida à flexão, sendo sua rigidez dependente das condições de contorno. Considerando uma viga de comprimento L em m, módulo de Young E em Pa, momento de inércia I em m^4 e carga concentrada F em N aplicada no centro, para o caso biapoiado tem-se:

$$\delta_{\max} = \frac{FL^3}{48EI}, \quad (2.3)$$

resultando em uma rigidez equivalente:

$$k_{\text{biap}} = \frac{48EI}{L^3}. \quad (2.4)$$

Para o caso engastado–engastado, a deflexão máxima é dada por:

$$\delta_{\max} = \frac{FL^3}{192EI}, \quad (2.5)$$

e a rigidez equivalente assume a forma:

$$k_{\text{eng}} = \frac{192EI}{L^3}. \quad (2.6)$$

Observa-se, portanto, que a condição de engaste aumenta a rigidez em um fator de quatro em relação ao caso biapoiado, evidenciando a forte influência das condições de contorno na resposta dinâmica do sistema.

O momento de inércia geométrico I depende da seção transversal da mola. Para uma seção retangular de largura b em m e espessura t em m, considerando flexão na direção da espessura, utiliza-se:

$$I = \frac{bt^3}{12}. \quad (2.7)$$

Essa dependência cúbica da espessura implica elevada sensibilidade da rigidez a pequenas variações geométricas, reforçando a necessidade de calibração adequada dos parâmetros do modelo.

Finalmente, a relação entre rigidez equivalente e resposta dinâmica pode ser expressa, de forma simplificada, pela frequência natural de um sistema de um grau de liberdade:

$$\omega_n = \sqrt{\frac{k_{\text{eq}}}{m_{\text{eq}}}}, \quad (2.8)$$

sendo a frequência em hertz dada por:

$$f_n = \frac{\omega_n}{2\pi}. \quad (2.9)$$

A redução da rigidez equivalente devido ao afrouxamento das cunhas desloca as frequências naturais e altera a FRF, justificando o uso de parâmetros modais e descritores espectrais como *features* para a classificação do estado de aperto das cunhas magnéticas (FARRAR; WORDEN, 2012).

2.3 Método de Elementos Finitos e Model Updating

A modelação numérica por meio do Método de Elementos Finitos (MEF) é amplamente reconhecida na literatura como uma ferramenta fundamental para a análise do comportamento mecânico e dinâmico de sistemas estruturais complexos. A discretização do domínio contínuo em elementos finitos permite a obtenção de campos de deslocamento, tensão e deformação, bem como a estimativa das propriedades dinâmicas globais, como frequências naturais e modos de vibrar. Em aplicações envolvendo sistemas de fixação em máquinas elétricas, como cunhas magnéticas e molas de preenchimento de estatores, o MEF tem sido empregado para investigar a influência da rigidez local e das condições de contorno no comportamento vibratório do conjunto cunha–ranhura–enrolamento. Entretanto, diversos estudos ressaltam que a precisão dessas análises depende fortemente da qualidade das propriedades de material adotadas, em especial o módulo de Young e o coeficiente de Poisson, parâmetros que frequentemente apresentam elevada dispersão em materiais compósitos e nem sempre são fornecidos com exatidão pelos fabricantes (MOTTERSHEAD; FRISWELL, 1993; TEUGHELS; MAECK; DE ROECK, 2002).

Diante dessas incertezas, consolidou-se na literatura o uso de técnicas de otimização de modelos, conhecidas como *Model Updating*, cujo objetivo é reduzir a discrepância entre as previsões do modelo numérico e as respostas observadas experimentalmente. Segundo Mottershead e Friswell (1993), a atualização de modelos pode ser formulada como um problema de otimização inversa, no qual parâmetros físicos do modelo, como rigidez, massa ou condições de contorno, são ajustados iterativamente de modo a minimizar a diferença entre propriedades dinâmicas calculadas e medidas, tipicamente frequências naturais e formas modais. Teughels, Maeck e De Roeck (2002) ampliam essa abordagem ao demonstrar que alterações localizadas de rigidez podem ser identificadas por meio da atualização do MEF com base em parâmetros modais e funções de sensibilidade, evidenciando que a rigidez equivalente constitui um parâmetro-chave na representação de processos de degradação estrutural.

A geração de respostas dinâmicas no domínio do tempo também é amplamente discutida na literatura como complemento à análise modal clássica. Enquanto a análise modal fornece informações sobre as propriedades intrínsecas da estrutura, a análise dinâmica transiente permite simular a resposta temporal sob excitações arbitrárias, como impulsos ou sinais de banda larga. Caicedo (2011) destaca que excitações com conteúdo espectral amplo, como o ruído branco, possibilitam a obtenção de respostas ricas em informação modal, mesmo quando a força excitadora não é explicitamente conhecida. Essa abordagem é coerente com os fundamentos da Análise Modal, na qual as características dinâmicas do sistema estão embutidas na resposta temporal, podendo ser exploradas tanto no domínio do tempo quanto no domínio da frequência.

Entretanto, a literatura enfatiza que a representatividade física dessas respostas numéricas está diretamente associada às hipóteses adotadas no modelo. Em formulações lineares clássicas, é comum assumir amortecimento estrutural muito baixo ou mesmo desprezível, resultando em respostas praticamente conservativas. Embora essa hipótese seja aceitável para estruturas rígidas

em regime de contato pleno, ela não representa adequadamente sistemas com folga, nos quais mecanismos dissipativos como atrito, microdeslizamento e impactos intermitentes passam a dominar o comportamento dinâmico. Reynders, Teughels e De Roeck (2010) demonstram que tais não linearidades podem alterar significativamente tanto a resposta transiente quanto os parâmetros modais identificados, limitando a capacidade preditiva de modelos lineares.

As condições de contorno assumidas no MEF constituem outro fator crítico na fidelidade do modelo. Em sistemas de cunhas e molas, é comum a adoção de idealizações como engastes perfeitos ou apoios rígidos para representar o confinamento imposto pela ranhura do estator. Embora essas simplificações sejam necessárias do ponto de vista computacional, pequenas variações nessas restrições podem resultar em diferenças expressivas na rigidez equivalente e, consequentemente, nas frequências naturais do sistema. Estudos experimentais e numéricos indicam que a calibração dessas condições por meio de procedimentos de atualização de modelo é essencial para reduzir erros de modelagem (MOTTERSHEAD; FRISWELL, 1993; BADAN, 2010). Além disso, a ausência de modelagem explícita de contato e atrito entre cunha, mola e ranhura, apesar de tornar o problema linear e computacionalmente mais eficiente, implica a não representação de fenômenos não lineares fundamentais associados ao processo de afrouxamento.

2.4 Inteligência Artificial aplicada ao Monitoramento de Condição (SHM)


O Monitoramento de Integridade Estrutural (*Structural Health Monitoring* – SHM) tem evoluído de abordagens puramente baseadas em parâmetros modais e indicadores estatísticos para estruturas de decisão apoiadas por aprendizado de máquina, motivado pela necessidade de lidar com grandes volumes de dados, variabilidade operacional/ambiental e dificuldade de rotular estados de dano em condições reais. Em linhas gerais, um sistema SHM orientado a dados pode ser descrito como um encadeamento de etapas de aquisição sensorial, pré-processamento, extração/seleção de características, modelagem e tomada de decisão, na forma de detecção (binária), classificação (multiclasse) ou quantificação de severidade, conforme discutido na literatura clássica e em revisões do tema (FARRAR; WORDEN, 2012; DOEBLING et al., 1998). Em aplicações vibroacústicas, é comum partir de sinais temporais (aceleração/velocidade), extrair *features* no domínio do tempo e/ou frequência (p.ex. RMS, curtose, bandas espectrais, picos de ressonância, indicadores de envelope), e então treinar modelos supervisionados (quando há rótulos) ou não supervisionados (quando o objetivo é detecção de novidade/anomalia).

2.4.1 KNN

O *k-Nearest Neighbors* (KNN) é um classificador baseado em instâncias: não constrói um modelo paramétrico explícito; em vez disso, armazena os exemplos de treinamento e, para uma nova observação, atribui a classe por votação entre os k vizinhos mais próximos segundo

uma métrica de distância (por exemplo, Euclidiana, Manhattan ou Mahalanobis), como mostra a Figura 3 abaixo. A “arquitetura” do KNN, portanto, pode ser entendida como: (i) definição do vetor de entrada $\mathbf{x} \in \mathbb{R}^d$ (as *features*), (ii) escolha da métrica de distância e do hiperparâmetro k , (iii) regra de decisão por votação (simples ou ponderada pela distância). A interpretação geométrica é direta: regiões do espaço de características são particionadas conforme a densidade local de amostras de cada classe, o que é útil quando as fronteiras entre “apertado” e “solto” são não lineares, mas bem representadas pelos dados (FARRAR; WORDEN, 2012).

Figura 3 – Esquema ilustrativo do KNN.



Fonte: Própria (2024).


O algoritmo destaca-se por sua simplicidade e eficácia como *baseline*, apresentando um processo de treinamento praticamente inexistente e demonstrando robustez em problemas com fronteiras de decisão complexas, desde que amparado por dados representativos. Em contrapartida, a técnica impõe um elevado custo computacional durante a etapa de inferência, uma vez que a predição depende diretamente do volume do conjunto de treinamento. Adicionalmente, o modelo apresenta sensibilidade à escala das variáveis, tornando a normalização um pré-requisito indispensável, e sofre degradação em cenários de alta dimensionalidade, fenômeno conhecido como a maldição da dimensionalidade (*curse of dimensionality*). Por fim, a acurácia do método está intrinsecamente ligada à definição criteriosa do hiperparâmetro k e à escolha da métrica de distância apropriada.

2.4.2 SVM

A *Support Vector Machine* (SVM) é um classificador discriminativo que procura um hiperplano separador com *margem máxima* entre classes, como ilustra a Figura 4 abaixo. Na forma linear, a decisão é dada por $\text{sign}(\mathbf{w}^\top \mathbf{x} + b)$, onde $\mathbf{w}$ e b são obtidos por um problema de otimização convexa que maximiza a margem e penaliza erros via parâmetro C . Quando a separação linear não é adequada, introduz-se o *kernel trick*, mapeando implicitamente os dados para um

espaço de maior dimensão, com escolhas comuns como RBF (Gaussiano) e polinomial. Em SHM, SVM é frequentemente aplicada sobre *features* manuais (estatísticas, espectrais, AR/ARX etc.) por sua robustez e bom desempenho com conjuntos de dados moderados (FARRAR; WORDEN, 2012).

Figura 4 – Interpretação geométrica da SVM.




Fonte: Própria (2024).

As *Support Vector Machines* (SVM) destacam-se pelo bom desempenho em conjuntos de dados reduzidos quando comparadas a arquiteturas de aprendizagem profunda, beneficiando-se de uma teoria de otimização convexa bem estabelecida. O modelo apresenta excelente capacidade de generalização mediante uma regularização adequada, enquanto o emprego de funções de *kernel* permite a captura de relações não lineares complexas no espaço de características. Todavia, a eficácia da técnica depende de uma validação criteriosa para a seleção do *kernel* e de hiperparâmetros críticos, como a constante de penalidade C e o parâmetro γ . Adicionalmente, tais modelos podem apresentar menor interpretabilidade em comparação a métodos lineares e enfrentar limitações de escalabilidade em bases de dados massivas, devido à complexidade computacional associada às operações de matriz de *kernel*.

2.4.3 Autoencoders

Autoencoders (AE) são redes neurais treinadas para reconstruir a própria entrada, como mostra a Figura 5. A arquitetura clássica é composta por um **encoder** $f_{\theta}(\cdot)$ que comprime a entrada $\mathbf{x}$ em um vetor latente $\mathbf{z}$ (“gargalo”), e um **decoder** $g_{\phi}(\cdot)$ que reconstrói $\hat{\mathbf{x}}$ a partir de $\mathbf{z}$. O treinamento minimiza uma função de perda de reconstrução, por exemplo $\mathcal{L}(\mathbf{x}, \hat{\mathbf{x}}) = \|\mathbf{x} - \hat{\mathbf{x}}\|^2$ (ou variantes). Em SHM e monitoramento de condição, AEs são particularmente atrativos no regime **não supervisionado**: treina-se o modelo com dados considerados “saudáveis” e, em operação, desvios de padrão tendem a aumentar o erro de reconstrução, o que pode ser interpretado como anomalia/novidade (AHMAD, 2021; LEE et al., 2024). Para sinais vibratórios, é comum usar AE denso (com *features*) ou AE temporal (p.ex. LSTM-AE) quando se deseja explorar diretamente sequências no tempo (LEE et al., 2024).

Figura 5 – Arquitetura típica de autoencoder.



Fonte: Própria (2024).

Os *Autoencoders* oferecem uma vantagem significativa por operarem de forma não supervisionada, não exigindo rótulos de falha, o que é ideal em cenários onde dados de dano são escassos ou raros. A arquitetura é capaz de aprender representações compactas dos dados e atuar eficientemente como detector de novidades, sendo altamente versátil ao permitir extensões para séries temporais — via *Long Short-Term Memory* (LSTM) ou *Temporal Convolutional Networks* (TCN) — e para processamento de entradas brutas através de *Convolutional Neural Networks* (CNN-AE). Contudo, a eficácia do modelo requer uma definição rigorosa do que constitui o estado “normal” durante o treinamento. Adicionalmente, a técnica apresenta sensibilidade ao *drift* operacional, onde mudanças legítimas de regime podem ser erroneamente classificadas como anomalias. Por fim, o método demanda volumes maiores de dados e um ajuste detalhado da arquitetura, apresentando uma interpretabilidade limitada que frequentemente exige análises complementares para o diagnóstico da causa raiz.

METODOLOGIA

3.1 Procedimento Experimental

Para a determinação das propriedades dos materiais da cunha e da mola, foi inicialmente montado um aparato experimental composto pelos seguintes equipamentos:

- Excitador de vibração tipo 4808 (shaker);
- Gerador de sinais;
- Analisador digital Spectral Dynamics SD380 Signal Analyzer;
- Amplificador de sinal Brüel & Kjær tipo 2712;
- Amplificador de carga Brüel & Kjær tipo 2635;
- Dois acelerômetros, sendo um da PCB modelo 352A24, SN LW254097;
- Placa de aquisição National Instruments NI 9215 com conexão BNC.

O gerador de sinais foi configurado para produzir excitação por ruído branco na faixa de 2 Hz a 20 kHz, com amplitude de 1,25 V, conforme ilustrado na Figura 6.


Figura 6 – Gerador de Sinais.



Fonte: Própria (2026).

O aparato experimental foi montado conforme esquematizado na Figura 7 apresentada a seguir, com um acelerômetro posicionado sob a trava e o outro sob a cunha e sob a mola.

Figura 7 – Montagem do Experimento.



(a) Vista Frontal.

(b) Vista Superior.

Fonte: Própria (2026).

Após a coleta dos sinais vibratórios, a cunha e a mola foram pesadas e os volumes descobertos após a modelagem. O valor da massa e do volume dos componentes foi utilizado posteriormente para a definição da densidade do material no modelo numérico.

As frequências naturais da cunha de 200 cm e da mola foram identificadas diretamente no analisador dinâmico, sendo listadas na Tabela 1 a seguir.

Tabela 1 – Frequências Naturais Experimentais.


Ordem	Cunha (Hz)	Mola (Hz)
1º	417,5	362,0
2º	2025,0	1037,5
3º	2625,0	1287,5
4º	5750,0	2025,0
5º	6300,0	3512,5
6º	7088,0	4462,5
7º	-	5362,5
8º	-	7012,5
9º	-	8412,5
10º	-	9762,5

Observando a Tabela 1 é possível notar que as frequências naturais tanto da cunha como da mola concentram-se nas altas frequências.

3.2 Otimização do Modelo

O modelo geométrico da cunha magnética e da mola foi desenvolvido no *software SolidWorks Student*, conforme ilustrado na Figura 8.

Figura 8 – Modelos da cunha e da mola.



Fonte: Própria (2026).

A mola tem 200 mm de comprimento, 20 mm de largura e 1 mm de espessura. Enquanto a cunha tem 200 mm de comprimento, 20 de largura e 3 mm de espessura. Visto que ambos os componentes são simétricos, para diminuir o tempo das simulações as malhas foram partidas ao meio.

A malha foi construída como elemento *SOLID185* com um tamanho de 2.5 mm por elemento. A densidade da cunha e da mola consideradas foram de 2200 kg/m³ e 1800 kg/m³, respectivamente. Tanto o módulo de Young como o de Poisson foram parametrizados, o *E* foi parametrizado no intervalo de 10 GPa a 50 GPa e o *v* foi de 0.2 a 0.4 tanto para cunha quanto para mola.


As simulações numéricas foram realizadas no *software ANSYS APDL* por meio do Método dos Elementos Finitos (MEF). As condições de contorno consistiram na restrição dos deslocamentos ($dx = dy = 0$) dos nós centrais. Essa configuração reproduziu as condições reais do experimento, no qual a cunha/mola foi fixada ao shaker, garantindo uma condição de contorno engastada-livre.

A calibração do modelo foi conduzida por meio de um procedimento de otimização implementado em *MATLAB®*. Os valores do módulo de Young e do coeficiente de Poisson foram ajustados de modo a assegurar a concordância entre as frequências naturais obtidas experimentalmente e aquelas previstas numericamente, usando como métrica o erro médio quadrático (MSE).

3.3 Geração dos Dados Sintéticos

A partir do modelo numérico previamente calibrado, foram realizadas simulações dinâmicas transientes no *software* ANSYS APDL com o objetivo de gerar sinais sintéticos representativos de diferentes níveis de aperto do sistema cunha–mola. O modelo numérico adotado é ilustrado na Figura 9.

Figura 9 – Modelo do Sistema Cunha-Mola.



Fonte: Própria (2026).

As condições de contorno aplicadas consistiram na restrição de deslocamentos e rotações nas direções y e z nos vales das molas, de modo a reproduzir a condição física de apoio do sistema, onde a mola se encontra presa. Adicionalmente, foi aplicada uma carga distribuída sob toda a superfície superior da cunha, modelada na forma de pressão. Essa pressão foi parametrizada de forma a simular diferentes níveis de compressão da mola, correspondentes a distintos graus de aperto da cunha.

Para excitar dinamicamente o sistema, foi aplicado um impulso de força também parametrizado, com amplitude variando entre 9 e 12 N, representando a batida de um martelo durante o ensaio experimental. O procedimento completo de geração dos sinais foi automatizado por meio de um código desenvolvido em *MATLAB*®, responsável pela parametrização tanto das condições de aperto quanto da excitação aplicada.

Os níveis de compressão adotados foram definidos com base na rigidez identificada da cunha e no deslocamento máximo admissível da mola, de 3 mm. Para a condição de cunha solta, os valores de força de compressão variaram entre 5 e 11 N, enquanto para a condição de cunha presa os valores situaram-se entre 11 e 15 N.


Os sinais de aceleração foram extraídos em três posições distintas do modelo: extremidade direita, região central e extremidade esquerda da cunha. Para cada condição de aperto (presa e solta), foram gerados 500 sinais sintéticos, totalizando uma base de dados balanceada, posteriormente utilizada nas etapas de treinamento e validação dos algoritmos de inteligência artificial.

3.4 Procedimento Experimental na Bancada

Para validar os algoritmos e a semelhança dos dados gerados aos reais foi feito um experimento em laboratório composto pelos seguintes equipamentos:

- Martelo de impacto Hammer da B&K;
- Bancada desenvolvida para simular diversos níveis de aperto mostrada na Figura 10;
- Amplificador de sinal Brüel & Kjær tipo 2712;
- Dois acelerômetros, sendo um da PCB modelo 352A24, SN LW254097;
- Placa de aquisição National Instruments NI 9215 com conexão BNC.


Figura 10 – Bancada desenvolvida para simular o aperto nas cunhas.



Fonte: LMEST (2026).

Com o objetivo de obter sinais de vibração decorrentes das batidas aplicadas sobre a cunha, os acelerômetros foram posicionados no entreferro e diretamente sobre a cunha. Os sinais foram adquiridos durante um intervalo de 20 segundos, com taxa de aquisição de 12 kHz, período no qual diversas batidas foram aplicadas manualmente à cunha, conforme ilustrado na Figura 11.


Figura 11 – Sinal de batidas de martelo coletados em laboratório.



Fonte: Própria (2026).

A Figura 11 tem esse aspecto porque muitos impactos de curto período de tempo foram dados em um período relativamente longo, segue abaixo na Figura 12 um impulso em escala reduzida.

Figura 12 – Impulso.



Fonte: Própria (2026).

A Figura 12 mostra a resposta em aceleração a uma excitação impulsiva por martelo, evidenciando pico inicial de impacto seguido por vibração livre amortecida. Estes sinais coletados foram usados para validar os algoritmos de classificação implementados e treinados com os sinais sintéticos. Além disso, serviram para verificar a similaridade com os sinais artificial gerados por MEF.

3.5 Pré-processamento dos Dados de Treinamento e Validação

O pré-processamento dos dados teve como objetivo estruturar os sinais temporais brutos em um conjunto de características representativas, adequado à aplicação de algoritmos de aprendizagem de máquina supervisionados. Inicialmente, os sinais adquiridos no domínio do tempo foram organizados em um banco de dados padronizado, garantindo consistência dimensional e numérica entre as amostras.

A rotulagem das amostras foi realizada no *python*, associando cada sinal a uma variável dependente binária (*target*), representada pelos valores 0 e 1 (presa e solta).

A caracterização dos sinais foi conduzida exclusivamente no domínio do tempo, por meio da extração de um conjunto selecionado de atributos estatísticos e energéticos. As características extraídas incluíram o valor RMS, o desvio padrão, a energia do sinal, a amplitude pico a pico, o fator de crista e a curtose. Esses parâmetros foram escolhidos por sua capacidade de representar a variabilidade, o conteúdo energético e a presença de transientes e impulsos.

Antes do treinamento dos classificadores, as características foram normalizadas pela norma *z*, de modo a eliminar vieses de escala e garantir o correto funcionamento de métodos baseados em distância, como o classificador *k-Nearest Neighbors* (KNN). O conjunto final de dados foi então dividido em subconjuntos de treinamento (70%) e validação (30%), preservando a proporção entre as classes.

3.6 Implementação dos Algoritmos de Classificação

O primeiro modelo implementado foi o classificador k-Nearest Neighbors (KNN), um método supervisionado baseado em distância, aplicado à classificação das cunhas a partir de características extraídas no domínio do tempo. O modelo foi configurado considerando como principais hiperparâmetros o número de vizinhos (n neighbors), o tipo de ponderação das distâncias (uniform e distance) e a métrica de distância de Minkowski, com variação do parâmetro p .

O segundo modelo adotado foi a Support Vector Machine (SVM), empregada como classificador supervisionado para fins comparativos. O algoritmo foi configurado com kernel radial (Radial Basis Function – RBF), sendo considerados como hiperparâmetros o tipo de kernel e a ativação do cálculo de probabilidades para suporte à análise dos resultados.

Por fim, foi implementado um autoencoder com abordagem não supervisionada para detecção de anomalias. A arquitetura adotada consistiu em uma rede neural totalmente conectada, composta por camadas densas simétricas, com funções de ativação do tipo ReLU nas camadas ocultas e linear na camada de saída. O treinamento utilizou o erro quadrático médio como função de perda, sendo a classificação realizada a partir de um limiar definido sobre o erro de reconstrução.

RESULTADOS E DISCUSSÕES

4.1 Propriedades Físicas

A Tabela 2 apresenta as grandezas físicas utilizadas para o cálculo da densidade da cunha e da mola. Os valores são apresentados em termos de massa, volume e densidade, sendo esta última obtida pela razão entre massa e volume.

Tabela 2 – Propriedades físicas estimadas para cunha e mola.

Componente	Massa (g)	Volume (m ³)	Densidade (kg/m ³)
Cunha	54.65	24 715.214	2211.18
Mola	7.25	3 999.98	1812.96

Fonte: Própria (2026).

4.2 Propriedades Mecânicas e Elásticas

A Tabela 3 reúne as propriedades mecânicas identificadas, incluindo módulo de Young E , coeficiente de Poisson ν e a rigidez equivalente K dos componentes. Para esta etapa, os valores numéricos foram mantidos como zero, uma vez que a estrutura da seção está sendo estabelecida para posterior inserção dos resultados finais.

Tabela 3 – Propriedades mecânicas identificadas para cunha e mola.

Componente	E (GPa)	ν (-)	K (N/m)
Cunha	35	0.2	5250
Mola	40	0.2	400


Fonte: Própria (2026).

4.3 Sinais Sintéticos


Conforme critério adotado para caracterização do estado de aperto, a força aplicada sobre a mola para que ela atinja 70% de compressão é de 11,025 N. Esse valor é utilizado como referência para a definição do limiar de condição “apertado”, permitindo relacionar o deslocamento imposto e a rigidez equivalente do sistema com o nível de pré-carga atuante no conjunto.

A Figura 13 apresenta, lado a lado, um sinal obtido experimentalmente e um sinal sintético gerado via MEF. Observa-se que as respostas apresentam tendências qualitativamente compatíveis, sobretudo em termos de envelope e conteúdo modal predominante. Entretanto, o sinal sintético não reproduz de forma idêntica o sinal real, uma vez que o modelo numérico não inclui o ruído de medição, assume amortecimento simplificado e não contempla as não linearidades associadas a contato, atrito e microimpactos que emergem em sistemas com folga. Tais fatores alteram significativamente a resposta dinâmica em condições reais de operação, especialmente no regime de afrouxamento, no qual a dissipação e a excitação não linear tornam-se dominantes.

Figura 13 – Comparação entre sinais: (a) sinal real e (b) sinal sintético.



(a) Sinal real.




(b) Sinal sintético.

Fonte: Própria (2026).

Outra característica evidenciada pelo modelo numérico foi a influência da posição de medição na resposta vibratória do sistema, conforme ilustrado na Figura 14. Observa-se que os sinais adquiridos em diferentes pontos ao longo da cunha apresentam variações tanto em amplitude quanto em conteúdo dinâmico, refletindo a distribuição espacial dos modos de vibração e a sensibilidade local do sistema à excitação aplicada.


Figura 14 – Sinais medidos em diferenstes posições.



Fonte: Própria (2026).

Na Figura 14, o sinal representado em vermelho corresponde à medição realizada na região central da cunha, enquanto os sinais em roxo e azul claro foram obtidos nas extremidades direita e esquerda, respectivamente. As diferenças observadas entre esses sinais estão associadas à forma modal da estrutura, uma vez que determinadas regiões apresentam maiores deslocamentos e acelerações em função da participação modal dominante, além de variações na rigidez efetiva percebida pelo sensor em cada ponto de medição.

Figura 15 – Comparação entre sinais: (a) Cunha Presa e (b) Cunha Solta.



(a) Cunha presa.

(b) Cunha solta.

Fonte: Própria (2026).

A comparação entre os sinais obtidos nas condições de cunha presa e cunha solta, apresentada na Figura 15, evidencia diferenças significativas no comportamento dinâmico do sistema. Nota-se que, na condição de cunha presa, que são cunhas com pressão de aperto elevadas, os sinais apresentam amplitudes mais altas quando comparados à condição de cunha solta. Esse comportamento pode ser explicado pela maior rigidez de contato e pela menor dissipação de


energia associadas à condição de aperto, o que resulta em uma resposta vibratória mais intensa para uma mesma excitação aplicada.

Por outro lado, na condição de cunha solta, o contato entre a cunha e a mola torna-se menos rígido e passa a apresentar comportamento não linear, caracterizado por microdeslizamentos, perdas por atrito e possíveis impactos intermitentes. Esses mecanismos introduzem fontes adicionais de amortecimento no sistema, promovendo maior dissipação de energia e, consequentemente, redução da amplitude da resposta vibratória. Além disso, a não linearidade do contato contribui para a redistribuição de energia entre frequências, alterando o formato temporal do sinal e reduzindo a coerência da resposta quando comparada à condição de cunha presa.

4.4 Classificadores

As Figuras 16, 17 e 18 apresentam as matrizes de confusão para os classificadores KNN, SVM e Autoencoder. A interpretação é realizada em termos de falsos positivos (FP) e falsos negativos (FN), indicadores diretamente relacionados ao risco de diagnóstico. Neste contexto, FP corresponde à classificação de uma cunha solta como presa, representando risco de não intervenção, enquanto FN corresponde à classificação de uma cunha presa como solta, caracterizando uma intervenção desnecessária.


Figura 16 – Matriz de confusão do classificador KNN (92%).



Fonte: Própria (2026).

No classificador KNN (Figura 16), observam-se FP igual a 4 e FN igual a 4. Os erros apresentam distribuição aproximadamente simétrica entre as classes, indicando que o método cometeu tanto falhas associadas à não intervenção quanto classificações que poderiam gerar intervenções desnecessárias, embora em número reduzido frente ao total de amostras analisadas.


Figura 17 – Matriz de confusão do classificador SVM (95%).



Fonte: Própria (2026).

Para o classificador SVM (Figura 17), os valores de FP e FN reduzem-se para 3 e 2, respectivamente. Esse resultado evidencia maior capacidade de separação entre as condições de cunha presa e solta, com diminuição simultânea dos dois tipos de erro, especialmente daqueles associados à intervenção desnecessária.

Figura 18 – Matriz de confusão do classificador Autoencoder (83%).



Fonte: Própria (2026).

No caso do Autoencoder (Figura 18), verificam-se FP igual a 9 e FN igual a 8, indicando desempenho inferior quando comparado aos classificadores baseados em aprendizado supervisio-

nado. Esse comportamento sugere maior sobreposição entre as assinaturas vibratórias das classes no espaço latente aprendido, o que aumenta a probabilidade de erros em ambas as direções de classificação.

De modo geral, os resultados indicam que o classificador SVM apresentou o melhor desempenho global, seguido pelo KNN, enquanto o Autoencoder apresentou a menor taxa de acerto entre os métodos avaliados.

CONCLUSÕES

5.1 Conclusões

Este trabalho apresentou uma metodologia para a detecção de folga em cunhas de geradores hidrelétricos por meio do monitoramento de parâmetros vibratórios, integrando ensaios experimentais em bancada, modelagem numérica via Método dos Elementos Finitos (MEF) e técnicas de classificação baseadas em inteligência artificial. A motivação central foi a necessidade de métodos objetivos, seguros e quantitativos para o diagnóstico do estado de aperto das cunhas, elemento crítico para a integridade mecânica e elétrica dos enrolamentos do estator.

Inicialmente, foi realizada a caracterização dinâmica experimental da cunha e da mola por meio de excitação em banda larga, permitindo a identificação das frequências naturais dos componentes. Em paralelo, desenvolveu-se um modelo numérico representativo do conjunto cunha–mola, cuja calibração foi conduzida por otimização paramétrica das propriedades elásticas. Os valores identificados para o módulo de Young e o coeficiente de Poisson mostraram-se coerentes com a literatura para materiais compósitos e permitiram boa concordância entre resultados experimentais e numéricos.

A partir do modelo calibrado, foram gerados sinais sintéticos de aceleração para diferentes níveis de aperto, representando as condições de cunha presa e cunha solta. A comparação entre sinais sintéticos e experimentais indicou similaridade qualitativa em termos de envelope temporal e conteúdo modal, embora diferenças sejam observadas devido à ausência, no modelo numérico, de ruído de medição, amortecimento mais realista e não linearidades associadas ao contato, atrito e microimpactos.

A análise dos sinais evidenciou ainda a influência significativa do ponto de medição na resposta vibratória, associada à forma modal da cunha e à rigidez efetiva local do sistema. Além disso, a comparação entre as condições de cunha presa e solta mostrou diferenças claras de amplitude e dissipação de energia, explicadas pela variação da rigidez de contato e pelo aumento

do amortecimento aparente na condição de folga, decorrente de fenômenos não lineares.

Na etapa final, os sinais foram utilizados no treinamento e validação de três algoritmos de classificação: k-Nearest Neighbors (KNN), Support Vector Machine (SVM) e Autoencoder. Os resultados demonstraram que os classificadores supervisionados apresentaram desempenho superior ao método não supervisionado. O SVM destacou-se com a maior acurácia global, apresentando menor número de falsos positivos e falsos negativos, seguido pelo KNN. O Autoencoder, embora conceitualmente adequado para detecção de anomalias, apresentou desempenho inferior neste cenário, indicando limitações associadas à separação das classes no espaço latente aprendido.

De modo geral, os resultados obtidos confirmam o potencial da metodologia proposta como ferramenta de apoio à manutenção preditiva de geradores hidrelétricos, demonstrando que parâmetros vibratórios, aliados à modelagem numérica e a técnicas de aprendizado de máquina, podem fornecer informações relevantes sobre o estado de aperto das cunhas de estator.

5.2 Trabalhos Futuros

Como perspectivas para a continuidade e o aprimoramento deste estudo, destacam-se diversas possibilidades de extensão da metodologia desenvolvida. Uma linha natural de avanço consiste na incorporação explícita de modelos de contato não linear e atrito no MEF, permitindo representar de forma mais fiel os fenômenos de microdeslizamento e impacto observados na condição de cunha solta, bem como sua influência no amortecimento e na resposta transiente.

Outra possibilidade relevante é a ampliação da base de dados experimental, incluindo ensaios com diferentes níveis intermediários de aperto, condições ambientais variadas e rigidez variável, condições mais próximas daquelas observadas em operação real, como forças eletromagnéticas periódicas e a existência de ciclos térmicos. Essa ampliação permitiria a transição de uma classificação binária para uma abordagem multiclasse.

No âmbito do processamento de sinais, trabalhos futuros podem explorar a extração de características no domínio da frequência e no domínio tempo-frequência, utilizando técnicas como transformada wavelet, análise de envelope e decomposições empíricas, de modo a capturar fenômenos não estacionários associados à abertura e fechamento do contato. A combinação dessas características com aquelas do domínio do tempo pode aumentar a robustez dos classificadores.

Em relação aos algoritmos de inteligência artificial, sugere-se investigar arquiteturas mais avançadas, como redes neurais convolucionais aplicadas diretamente aos sinais ou espectrogramas, bem como autoencoders temporais baseados em LSTM ou TCN, especialmente para cenários com grande volume de dados. Adicionalmente, técnicas de validação cruzada mais extensas e análise de sensibilidade dos hiperparâmetros podem contribuir para uma avaliação

mais abrangente do desempenho dos modelos.

Por fim, como etapa de maior maturidade tecnológica, recomenda-se a aplicação da metodologia em sistemas reais de geradores hidrelétricos, integrando-a a rotinas de monitoramento contínuo. Essa validação em ambiente industrial permitiria avaliar a viabilidade prática da abordagem, sua robustez frente a variabilidades operacionais e seu potencial como ferramenta efetiva de suporte à tomada de decisão em manutenção preditiva.

REFERÊNCIAS

BADAN, M. A. B. C. **Caracterização experimental e modelagem do comportamento vibratório de estruturas submersas**. Dissertação (Dissertação (Mestrado em Engenharia Mecânica)) — Universidade Federal de Uberlândia, Uberlândia, 2010. Citado na página 13.

CAICEDO, J. M. Practical guidelines for the natural excitation technique (next) and the eigensystem realization algorithm (era) for operational modal analysis. **Mechanical Systems and Signal Processing**, v. 25, n. 7, p. 2569–2580, 2011. Citado na página 13.

CHICHKIN, I. Stator winding wedge tightness evaluation on large hydro generators. In: IRIS POWER. **Iris Power Rotating Machine Conference (IRMC)**. Toronto, 2022. Anais. Citado na página 13.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B.; SHEVITZ, D. W. A review of damage identification methods that examine changes in dynamic properties. **Shock and Vibration Digest**, v. 30, n. 2, p. 91–105, 1998. Citado na página 13.

FARRAR, C. R.; WORDEN, K. **Structural Health Monitoring: A Machine Learning Perspective**. Chichester: John Wiley & Sons, 2012. Citado na página 13.

KASTEN, D. G. Magnetic wedges improve generator performance. **IEEE Transactions on Energy Conversion**, v. 14, n. 1, p. 48–53, 1999. Citado na página 13.

MOTTERSHEAD, J. E.; FRISWELL, M. I. Model updating in structural dynamics: a survey. **Journal of Sound and Vibration**, v. 167, n. 2, p. 347–375, 1993. Citado na página 13.

RANDALL, R. B. **Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications**. Chichester: John Wiley & Sons, 2011. Citado na página 13.

REYNDERS, E.; TEUGHEL, A.; ROECK, G. D. Finite element model updating and structural damage identification using operational modal analysis data. **Mechanical Systems and Signal Processing**, v. 24, n. 5, p. 1306–1323, 2010. Citado na página 13.

STONE, G. C.; SEDOR, M. J.; STRANGES, M.; KAPLER, J. **Electrical Insulation for Rotating Machines: Design, Evaluation, Aging, Testing, and Repair**. 2. ed. Hoboken: John Wiley & Sons, 2008. Citado na página 13.

TEUGHEL, A.; MAECK, J.; ROECK, G. D. Damage assessment by fe model updating using damage functions. **Computers & Structures**, v. 80, n. 25-26, p. 1869–1879, 2002. Citado na página 13.

WANG, X. Analysis of electromagnetic and thermal performance of stator magnetic wedges in large generators. **IEEE Transactions on Energy Conversion**, v. 25, n. 2, p. 379–386, 2010. Citado na página 13.