



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
CURSO DE ENGENHARIA MECÂNICA

MARCOS AURÉLIO NUNES VIEIRA

**MODELAGEM DE SINAIS VIBRACIONAIS POR SENSORES
VIRTUAIS BASEADOS EM LSTM PARA ANÁLISE MODAL**

GOIÂNIA
2026



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TRABALHO DE CONCLUSÃO DE CURSO DE GRADUAÇÃO NO REPOSITÓRIO INSTITUCIONAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio do Repositório Institucional (RI/UFG), regulamentado pela Resolução CEPEC no 1240/2014, sem ressarcimento dos direitos autorais, de acordo com a Lei no 9.610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo dos Trabalhos de Conclusão dos Cursos de Graduação disponibilizado no RI/UFG é de responsabilidade exclusiva dos autores. Ao encaminhar(em) o produto final, o(s) autor(a)(es)(as) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do Trabalho de Conclusão de Curso de Graduação (TCCG)

Nome completo do autor: Marcos Aurélio Nunes Vieira

Título do trabalho: Modelagem de sinais vibracionais por sensores virtuais baseados em LSTM para análise modal

2. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador) Concorda com a liberação total do documento [X] SIM [] NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante: a) consulta ao(à)(s) autor(a)(es)(as) e ao(à) orientador(a); b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo do TCCG. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro.

Obs.: Este termo deve ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Marlipe Garcia Fagundes Neto, Professor do Magistério Superior**, em 01/07/2026, às 10:17, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Aurélio Nunes Vieira, Discente**, em 02/07/2026, às 15:33, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6303507** e o código CRC **F15447D1**.

Referência: Processo nº 23070.012784/2026-38

SEI nº 6303507

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
CURSO DE ENGENHARIA MECÂNICA

MARCOS AURÉLIO NUNES VIEIRA

MODELAGEM DE SINAIS VIBRACIONAIS POR SENSORES VIRTUAIS BASEADOS EM LSTM PARA ANÁLISE MODAL

Monografia apresentada na disciplina de Projeto Final de Curso da graduação em Engenharia Mecânica da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás.

Orientador(a): Prof. Dr. Marlipe Garcia Fagundes Neto

Goiânia
2026

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Vieira, Marcos Aurélio Nunes

Modelagem de Sinais Vibracionais por Sensores Virtuais Baseados em
LSTM para Análise Modal [manuscrito] / Marcos Aurélio Nunes Vieira. – 2026.
LVI, 61 f.: 2026

Orientador: Prof. Dr. Marlipe Garcia Fagundes Neto.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal de
Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC),
Engenharia Mecânica, Goiânia, 2026.

Bibliografia.

Inclui siglas, gráfico, tabelas, lista de figuras, lista de tabelas.

1. Sensores Virtuais. 2. Sinais Vibracionais. 3. Análise Modal Operacional. 4.
Redes Neurais Recorrentes. I. Fagundes Neto, Marlipe Garcia, orient. II. Título.

CDU 621



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO

Ao primeiro dia do mês de julho do ano de 2026 iniciou-se a sessão pública de defesa do Trabalho de Conclusão de Curso (TCC) intitulado “Modelagem de sinais vibracionais por sensores virtuais baseados em LSTM para análise modal”, de autoria de Marcos Aurélio Nunes Vieira, do curso de graduação em Engenharia Mecânica, da Escola de Engenharia Elétrica, Mecânica e de Computação da UFG. Os trabalhos foram instalados pelo Prof. Dr. Marlipe Garcia Fagundes Neto EMC/UFG com a participação dos demais membros da Banca Examinadora: Prof. Dr. Gino Bertollucci Colherinhas EMC/UFG e Prof. Dr. Álisson Assis Cardoso EMC/UFG. Após a apresentação, a banca examinadora realizou a arguição do(a) estudante. Posteriormente, de forma reservada, a Banca Examinadora atribuiu a nota final de 10,0 , tendo sido o TCC considerado aprovado.

Proclamados os resultados, os trabalhos foram encerrados e, para constar, lavrou-se a presente ata que segue assinada pelos Membros da Banca Examinadora.



Documento assinado eletronicamente por **Marlipe Garcia Fagundes Neto, Professor do Magistério Superior**, em 01/07/2026, às 11:11, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alisson Assis Cardoso, Professor do Magistério Superior**, em 01/07/2026, às 11:12, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Gino Bertollucci Colherinhas, Professor do Magistério Superior**, em 02/07/2026, às 19:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6303471** e o código CRC **D8CB14EE**.

*À minha mãe, meu pai e minhas irmãs,
que ficaram perto mesmo de longe:
a distância me trouxe até aqui,
mas o coração nunca deixou de morar
em casa.*

AGRADECIMENTOS

À minha fé em Jesus Cristo, que tem me acompanhado nessa caminhada, crendo que Ele faz infinitamente mais além daquilo que pedimos ou pensamos. Tudo o que cheguei a projetar, Ele superou.

À minha família por serem o porto de onde parti e o lugar onde sempre volto. À minha mãe, Maria, pelo zelo que não tira férias. Ao meu pai, Márcio, por um apoio que nunca precisou de muitas palavras para ser sentido. E às minhas irmãs, Maria Clara e Mayra, pela torcida, pelo companheirismo e cumplicidade de uma vida inteira.

Aos meus tios, Ostiano e Damiana, que me acolheram desde o início da minha trajetória acadêmica. Vocês se tornaram família nos momentos em que senti falta da minha, sem nunca deixar de ser a minha própria família também. Estendo este agradecimento a todos os meus demais familiares, pelo incentivo constante e por serem força motriz nesta jornada.

Ao meu orientador, Marlipe Garcia Fagundes Neto, que me acompanha desde o primeiro semestre da Engenharia Mecânica até esta conclusão de curso. Sua orientação moldou não apenas esta pesquisa, mas minha formação como um todo. Agradeço também aos demais professores e servidores da UFG, em especial aos da EMC — Escola de Engenharia Elétrica, Mecânica e de Computação, pela estrutura e pelo conhecimento compartilhado.

Aos amigos que a vida me deu e aos que o curso me apresentou, e aos colegas de turma: obrigado pelo incentivo diário e por dividir o peso desta jornada.

Ao PET Engenharias, que me trouxe um sentimento de pertencimento que carrego com gratidão e que se tornou um pilar nesta trajetória. Aos colegas petianos e aos tutores Marlipe e Andreia, que foram fundamentais nesse processo.

A todos que, mesmo sem nome citado nessas páginas, de algum modo, fizeram parte deste percurso.

Por fim, a mim mesmo, por ter insistido mesmo quando o caminho pedia novos rumos e ajuste de rota, e ter chegado até aqui carregando o mesmo sonho que me fez partir.

RESUMO

O monitoramento estrutural baseado em sinais vibracionais tem se tornado uma ferramenta relevante no acompanhamento da integridade de estruturas submetidas a diversos carregamentos operacionais, principalmente em situações onde a instrumentação de sensores físicos se torna limitada por diversos fatores. Nesse contexto, os sensores virtuais atuam como uma alternativa complementar ao monitoramento tradicional, permitindo estimar respostas em regiões não instrumentadas a partir de variáveis conhecidas. Ademais, para aplicações em análise modal, não basta que o sinal previsto apresente apenas baixos índices de erro estatístico, também é necessário que o sinal estimado conserve as características modais da estrutura, como frequências naturais, amortecimento e formas modais. Diante disso, este trabalho teve como objetivo avaliar o desempenho de diferentes configurações de redes neurais LSTM na construção de sensores virtuais para modelagem de sinais vibracionais de uma viga engastada-livre. A pesquisa foi desenvolvida com base em sinais coletados em túnel de vento nas velocidades de 5 m/s e 10 m/s, no qual uma viga foi instrumentada com cinco acelerômetros, sendo os sensores A1 e A5 utilizados como entradas da rede e os sensores A2, A3 e A4 como pontos de varredura a serem estimados. Foram avaliadas três configurações de LSTM, variando o tamanho da janela temporal, número de neurônios e na taxa de *dropout*, onde a comparação foi realizada por métricas estatísticas, considerando MAE e RMSE. Em seguida, os sinais previstos pela melhor configuração foram avaliados utilizando os métodos SSI, FDD e pelo Critério de Garantia Modal (MAC). Os resultados mostraram que a configuração C2, arquitetada com janela temporal de 256 pontos, 64 neurônios por camada e *dropout* em 0,2, apresentou o melhor desempenho global, indicando que o simples aumento da janela temporal contribuiu de forma mais efetiva com a estimativa dos sinais do que o aumento da complexidade da rede. Na análise modal, os sinais virtuais mantiveram as características modais, apresentando baixos valores de erro relativo em frequência e taxas de amortecimento. Além disso, os valores de MAC igual a 1,00 na diagonal principal indicaram forte correspondência entre as formas modais reais e virtuais. Dessa forma, os resultados permitem concluir que os sensores virtuais baseados em redes LSTM apresentaram desempenho satisfatório na modelagem dos sinais vibracionais além do potencial para aplicações em Análise Modal Operacional.

Palavras-chave: Sensores virtuais. Sinais vibracionais. Análise modal operacional. Redes neurais recorrentes.

ABSTRACT

Structural monitoring based on vibration signals has become a relevant tool for tracking the integrity of structures subjected to different operational loads, mainly in situations where the instrumentation of physical sensors becomes limited by several factors. In this context, virtual sensors act as a complementary alternative to traditional monitoring, allowing responses in regions without instrumentation to be estimated from known variables. Furthermore, for applications in modal analysis, it is not enough for the predicted signal to present only low statistical error indexes, it is also necessary for the estimated signal to preserve the modal characteristics of the structure, such as natural frequencies, damping and mode shapes. Therefore, this work aimed to evaluate the performance of different configurations of LSTM neural networks in the construction of virtual sensors for modeling vibration signals of a cantilever beam. The research was developed based on signals collected in a wind tunnel at velocities of 5 m/s and 10 m/s, in which a beam was instrumented with five accelerometers, with sensors A1 and A5 used as network inputs and sensors A2, A3 and A4 used as scanning points to be estimated. Three LSTM configurations were evaluated, varying the size of the temporal window, the number of neurons and the dropout rate, while the comparison was carried out using statistical metrics, considering MAE and RMSE. Then, the signals predicted by the best configuration were evaluated using the SSI and FDD methods and the Modal Assurance Criterion (MAC). The results showed that configuration C2, designed with a temporal window of 256 points, 64 neurons per layer and dropout of 0.2, presented the best overall performance, indicating that the simple increase in the temporal window contributed more effectively to the estimation of the signals than the increase in network complexity. In the modal analysis, the virtual signals maintained the modal characteristics, presenting low values of relative frequency error and damping ratios. In addition, MAC values equal to 1.00 on the main diagonal indicated a strong correspondence between the real and virtual mode shapes. Thus, the results allow concluding that the virtual sensors based on LSTM networks presented satisfactory performance in the modeling of vibration signals, as well as potential for applications in Operational Modal Analysis.

Keywords: Virtual sensors. Vibration signals. Operational modal analysis. Recurrent neural networks.

SUMÁRIO

LISTA DE QUADROS		vii
LISTA DE FIGURAS		viii
LISTA DE ABREVIATURAS E SÍMBOLOS		ix
1	INTRODUÇÃO	1
1.1	JUSTIFICATIVA	4
1.2	OBJETIVOS.....	5
1.2.1	Objetivo Geral.....	5
1.2.2	Objetivos Específicos	5
2	REFERENCIAL TEÓRICO	6
2.1	MONITORAMENTO ESTRUTURAL	6
2.2	VIBRAÇÃO E ANÁLISE MODAL	7
2.2.1	Frequências Naturais e Modos de Vibração.....	8
2.2.2	Fundamentos de Análise Modal	10
2.2.3	Análise Modal Experimental e Operacional.....	11
2.3	SENSORES VIRTUAIS	12
2.4	SÉRIES TEMPORAIS E REDES NEURAIS	15
2.5	HIPERPARÂMETROS LSTM	16
2.5.1	Métricas de Desempenho.....	17
3	METODOLOGIA	19
3.1	ESTRUTURA E APARATOS EXPERIMENTAIS.....	20
3.2	COLETA E TRATAMENTO DE DADOS EXPERIMENTAIS.....	23
3.3	CONSTRUÇÃO DO SENSOR VIRTUAL.....	24
3.4	AVALIAÇÃO DE DESEMPENHO DO SENSOR VIRTUAL.....	26
4	RESULTADOS E DISCUSSÕES	28
4.1	SELEÇÃO DA CONFIGURAÇÃO DE REDE LSTM	28
4.2	ANÁLISE MODAL OPERACIONAL.....	31
4.2.1	Extração dos Parâmetros Modais pelos Métodos SSI e FDD	32
4.2.2	Análise das Formas Modais	36
4.2.3	Correspondência Modal pelo Critério de Garantia Modal.....	38
4.3	COMPARATIVO COM TRABALHOS ANTERIORES	40
5	CONCLUSÃO	41

5.1	SUGESTÕES DE TRABALHOS FUTUROS	41
	REFERÊNCIAS BIBLIOGRÁFICAS	43

LISTA DE QUADROS

Quadro 1: Parâmetros técnicos dos acelerômetros utilizados	21
Quadro 2: Especificações técnicas túnel de vento subsônico	23
Quadro 3: Configuração de arquiteturas LSTM estabelecidas.....	26
Quadro 4. Métricas de desempenho por sensor de varredura (5 m/s)	30
Quadro 5. Métricas de desempenho por sensor de varredura (10 m/s)	30
Quadro 6. Parâmetros modais em 5m/s (SSI)	32
Quadro 7. Parâmetros modais em 10 m/s (SSI)	33
Quadro 8. Parâmetros modais em 5 m/s (FDD)	34
Quadro 9. Parâmetros modais em 10 m/s (FDD)	34

LISTA DE FIGURAS

Figura 1. Resultados MAC entre EMA e OMA em 10 m/s	2
Figura 2. Comparativo entre OMA e Euler-Bernoulli, porção intermediária	3
Figura 3: Base conceitual do trabalho proposto	4
Figura 4: Quatro primeiros modos normais de uma viga engastada-livre	9
Figura 5: Fluxograma das etapas da análise modal.....	10
Figura 6: Análise modal experimental de uma viga engastada-livre	11
Figura 7: Instrumentação física e virtual de uma planta de destilação de gás GLP	13
Figura 8: Fluxograma do processo de atuação de um sensor virtual	14
Figura 9: Fluxograma Geral da Metodologia	19
Figura 10: Representação gráfica do modelo de viga [mm]	20
Figura 11: Representação da instrumentação da viga	21
Figura 12: Instrumentos de aquisição de sinais vibracionais	22
Figura 13: Túnel de vento subsônico modelo AA-TVSH1	22
Figura 14: Esquematisação de aplicação dos sensores de referência e varredura.....	24
Figura 15: Processo de atuação da rede neural desenvolvida	25
Figura 16. <i>Plot</i> da resposta vibracional (C3, A2).....	28
Figura 17: Parâmetros de avaliação de desempenho das redes em 5 m/s	29
Figura 18: Parâmetros de avaliação de desempenho das redes em 10 m/s	29
Figura 19: Parâmetros modais pelo método SSI para 5m/s	32
Figura 20: Parâmetros modais pelo método SSI para 10m/s	33
Figura 21: Parâmetros modais pelo método FDD para 5m/s	34
Figura 22: Parâmetros modais pelo método FDD para 10m/s	35
Figura 23. Formas modais (método SSI)	36
Figura 24. Formas modais (método FDD)	36
Figura 25. Modos de vibração	37
Figura 26: Matriz MAC pelo método SSI em 5 m/s	38
Figura 27: Matriz MAC pelo método SSI em 10 m/s	38
Figura 28: Matriz MAC pelo método FDD em 5 m/s	39
Figura 29: Matriz MAC pelo método FDD em 10 m/s	39
Figura 30. Comparativo com trabalhos anteriores	40

LISTA DE ABREVIATURAS E SÍMBOLOS

ABREVIATURAS

ADC	Conversor Analógico Digital (<i>Analog to Digital Converter</i>)
EMA	Análise Modal Experimental (<i>Experimental Modal Analysis</i>)
B&K	Brüel & Kjær
FDD	Decomposição no Domínio da Frequência (<i>Frequency Domain Decomposition</i>)
FRF	Função Resposta em Frequência (<i>Frequency Response Function</i>)
GLP	Gás Liquefeito de Petróleo
LSTM	Memória de Longo e Curto Prazo (<i>Long Short Term Memory</i>)
MAC	Critério de Garantia Modal (<i>Modal Assurance Criterion</i>)
MAE	Erro Médio Absoluto (<i>Mean Absolute Error</i>)
MEF	Método dos Elementos Finitos
MLP	Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
MSE	Erro Quadrático Médio (<i>Mean Squared Error</i>)
OMA	Análise Modal Operacional (<i>Operational Modal Analysis</i>)
PFC	Projeto Final de Curso
RAM	Memória de Acesso Aleatório (<i>Random Access Memory</i>)
RI	Repositório Institucional
RNA	Rede Neural Artificial
RNN	Rede Neural Recorrente (<i>Recurrent Neural Network</i>)
RMSE	Raiz do Erro Quadrático Médio (<i>Root Mean Squared Error</i>)
SHM	Monitoramento da Integridade Estrutural (<i>Structural Health Monitoring</i>)
SSI	Identificação Estocástica de Subespaço (<i>Stochastic Subspace Identification</i>)

1 INTRODUÇÃO

O monitoramento estrutural tem se tornado uma área de crescente relevância na engenharia moderna, principalmente em sistemas sob carregamentos dinâmicos, variações ambientais e condições operacionais cuja ação pode modificar suas propriedades de amortecimento, rigidez e massa efetiva, afetando diretamente sua resposta dinâmica. Assim, acompanhar o comportamento estrutural deixa de ser apenas uma medida corretiva e passa a integrar uma estratégia de manutenção, diagnóstico e prevenção de falhas.

Nesse viés, a Análise Modal surge como uma ferramenta essencial para caracterização dinâmica de estruturas, pela qual é possível identificar parâmetros que descrevem a forma como a estrutural responde às excitações, sendo estes: frequências naturais, formas modais e razões de amortecimento. A Análise Modal Experimental permite avaliar o comportamento da estrutura laboratorialmente baseada em uma excitação controlada, enquanto que a Análise Modal Operacional permite obter os parâmetros modais por meio de respostas captadas em condições operacionais, sem que haja um conhecimento mensurável da força de excitação, tornando-a especialmente útil em situações em que a excitação forçada é inviável (LEME, 2014; REYNDERS, 2012).


O monitoramento baseado em sensores físicos apresenta limitações práticas em questão de custos elevados, dificuldade de acesso e complexidade de instalação ao necessitar um considerável número de pontos instrumentados para alcançar uma descrição completa do comportamento da estrutura. Assim, surge a demanda por métodos capazes de estimar respostas estruturais em regiões não instrumentadas (ZOU; CHAKRABARTY, 2003).

Considerando esse contexto, os sensores virtuais apresentam-se como um modelo computacional capaz de estimar uma variável de interesse a partir de outras grandezas físicas medidas, permitindo alcançar medidas em pontos não instrumentados. Contudo, o sensor virtual não elimina a necessidade de medições reais, mas aumenta a capacidade de interpretação dos dados adquiridos além de inserir uma camada extra nas técnicas de monitoramento (FREITAS, 2023; IBRAHIM *et al.*, 2023).

Nessa linha de pesquisa, Rodrigues (2023) investigou a aplicação de sensores virtuais associados à análise modal de uma viga engastada-livre submetida a ensaios em túnel de vento, utilizando rede neural dinâmica para estimar as respostas vibracionais da estrutura. No entanto, embora as frequências naturais obtidas por EMA (do inglês *Experimental Modal Analysis*) e OMA (do inglês *Operational Modal Analysis*) tenham apresentado valores próximos, a comparação das formas modais apresentou limitações, com valores de MAC (do inglês *Modal*

Assurance Criterion) de aproximadamente 0,40 entre os modos correspondentes, indicando baixa correlação modal entre as técnicas avaliadas, conforme apresentado na Fig. 1.


Figura 1. Resultados MAC entre EMA e OMA em 10 m/s



Fonte: Rodrigues (2023)

Por outro lado, Moraes (2024) também utilizou uma viga engastada-livre como representação de torres de turbinas eólicas e avançou na caracterização modal da estrutura por meio de EMA, OMA, Euler Bernoulli e Método dos Elementos Finitos (MEF), mas sem utilizar sensores virtuais como parte da metodologia. Para a caracterização modal fez-se uso de sinais medidos fisicamente por acelerômetros instrumentados ao longo da viga, contudo, o próprio estudo apontou a influência da posição dos sensores sobre a qualidade da caracterização modal, recomendando uma melhor distribuição dos sensores, evidenciada nos resultados onde apenas o primeiro e o segundo modo apresentaram uma boa correspondência, enquanto o terceiro modo indicou correlação modal fora da diagonal principal, conforme mostra a Fig. 2.

Figura 2. Comparativo entre OMA e Euler-Bernoulli, porção intermediária



Fonte: Moraes (2024)

Rodrigues (2023) demonstrou a capacidade de redes neurais em estimar respostas vibracionais, porém com limitações na correspondência modal entre os métodos avaliados. Por outro lado, Moraes (2024) realizou uma caracterização modal aprofundada da mesma estrutura, porém dependendo exclusivamente de sinais provenientes de sensores físicos, destacando inclusive a importância da distribuição espacial dos pontos de medição.


Nesse contexto, surge a necessidade de investigar a aplicação de redes neurais recorrentes, em especial a arquitetura LSTM (do inglês *Long Short-Term Memory*), na construção de sensores virtuais capazes de estimar sinais vibracionais e preservar as informações dinâmicas necessárias para a caracterização modal da estrutura. Além disso, o desempenho de redes LSTM depende diretamente da configuração de seus hiperparâmetros, tornando necessário avaliar diferentes configurações da rede para identificar aquela que apresenta melhor capacidade de reconstrução dos sinais estruturais.

Diante disso, este trabalho propõe o desenvolvimento e avaliação de sensores virtuais baseados em redes neurais LSTM aplicados a uma viga engastada-livre submetida a condições de Análise Modal Operacional. Inicialmente, diferentes configurações da rede serão comparadas por meio de métricas estatísticas aplicadas aos sinais reais e previstos, e posteriormente, a configuração de melhor desempenho será utilizada para a identificação modal pelos métodos FDD (do inglês *Frequency Domain Decomposition*) e SSI (do inglês *Stochastic Subspace Identification*), enquanto a correspondência entre as formas modais reais e virtuais

será avaliada pelo MAC, permitindo verificar a capacidade do sensor virtual em preservar o comportamento dinâmico da estrutura.

A Figura 3 traz um fluxograma com a sobreposição dos trabalhos de Rodrigues (2023) e Moraes (2024), evidenciando a lacuna identificada e o direcionamento da proposta desenvolvida neste trabalho.

Figura 3: Base conceitual do trabalho proposto



Fonte: Próprio Autor (2026)

1.1 JUSTIFICATIVA

A justificativa deste trabalho está pautada na necessidade de ampliar a capacidade de monitoramento estrutural utilizando um número reduzido de pontos instrumentados sem que haja uma perda das características dinâmicas da resposta estrutural. Em aplicações reais, a instalação de sensores físicos em todos os pontos de interesse pode ser impraticável, fazendo com que os sensores virtuais sejam uma forte alternativa devido a capacidade de estimar respostas em posições não medidas diretamente.

A dissertação de Rodrigues (2023) demonstrou que redes neurais podem ser utilizadas para estimar grandezas estruturais a partir de poucos sensores reais. Já Moraes (2024) evidenciou a potencialidade da análise modal experimental e operacional em caracterizar o comportamento dinâmico de modelos de viga engastada-livre. Assim, a presente pesquisa se justifica na interseção entre essas duas contribuições, ao utilizar sensores virtuais para prever sinais vibracionais e avaliar esses sinais por meio de métricas estatísticas e análise modal.

A escolha da LSTM é justificada pela capacidade dessa arquitetura em representar dependências sequenciais características dos sinais vibracionais. Contudo, considerando que a arquitetura da rede neural influencia diretamente na qualidade dos sinais previstos, estudar a

influência de diferentes arquiteturas contribui para a identificação da configuração mais adequada ao conjunto experimental estudado.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Avaliar o desempenho de diferentes configurações de redes neurais LSTM na construção de sensores virtuais para modelagem de sinais vibracionais de uma viga engastada-livre, verificando a capacidade dos sinais previstos em preservar características modais obtidas por técnicas de Análise Modal Operacional.

1.2.2 Objetivos Específicos

- Realizar revisão bibliográfica sobre monitoramento estrutural, vibrações, análise modal, sensores virtuais, redes neurais recorrentes e LSTM.
- Desenvolver modelos de sensores virtuais baseados em redes LSTM para predição de sinais vibracionais em pontos da estrutura.
- Implementar diferentes configurações de redes LSTM para avaliar sua capacidade de reconstrução dos sinais vibracionais.
- Comparar o desempenho dos modelos por meio de métricas estatísticas.
- Selecionar a configuração de rede com melhor desempenho para avaliação dos sinais estimados via análise modal.
- Avaliar a preservação das características dinâmicas nos sinais previstos, utilizando as técnicas FDD, SSI e do MAC.

2 REFERENCIAL TEÓRICO

Esta seção tem como objetivo apresentar os fundamentos teóricos essenciais para embasamento e desenvolvimento deste trabalho, articulando o monitoramento estrutural, a análise de vibrações, os sensores virtuais, as séries temporais e as redes LSTM. A discussão surge da necessidade de acompanhar o comportamento de estruturas submetidas à comportamentos dinâmicos baseada na interpretação de sinais de vibração e finaliza nos hiperparâmetros e métricas utilizados na modelagem preditiva.

2.1 MONITORAMENTO ESTRUTURAL

O monitoramento da integridade estrutural abrange um campo interdisciplinar e tem se tornado uma área de crescente relevância na engenharia moderna, desde a civil, mecânica até aeroespacial. Seu crescimento e avanço é impulsionado pela necessidade de garantir que estruturas de infraestrutura crítica, como viadutos, pontes, edificações de grande porte e até turbinas eólicas, permaneçam operacionalmente seguras ao longo de toda sua vida útil.

A degradação estrutural é um fenômeno ao qual toda estrutura real está sujeita, onde o envelhecimento natural somando a ação de cargas dinâmicas cíclicas, as intempéries, a fadiga e a corrosão podem alterar progressivamente as propriedades mecânicas dos materiais e comprometer a resistência do sistema. Conforme apontado por Poudel, Fu e Ye (2005) e Singh e Gupta (2023), estruturas das áreas mecânica, civil e aeroespacial podem sofrer deterioração quando submetidas a longos períodos de operação, reforçando a necessidade de técnicas capazes de acompanhar sua condição ao longo do tempo.

Nesse contexto, apresenta-se o estudo de Alves, V. H. M., Alves, V. A. M. e Cury (2023), voltado a pontes e viadutos, no qual destacam que vibrações excessivas e trincas estão entre as principais causas de anomalias estruturais, exigindo um acompanhamento contínuo para basear ações preditivas e preventivas. Embora essa aplicação não baseie o objetivo central deste trabalho, ela reforça que danos estruturais afetam diretamente o comportamento dinâmico da estrutura como rigidez, flexibilidade e resistência.

Ainda nesse cenário, Farrar e Worden (2007) ressaltam o complexo desafio para a detecção de dano em estruturas, uma vez que as mudanças observadas na resposta estrutural podem estar associadas tanto a deterioração real quanto a alterações nas condições de coleta de dados e do ambiente. Nessa mesma direção, Poudel, Fu e Ye (2005) afirmam que, sendo essas mudanças medidas com precisão, podem ser utilizadas para identificar e localizar danos estruturais. Assim, o monitoramento baseado na resposta dinâmica depende não apenas da

aquisição de sinais, mas, principalmente, na capacidade e qualidade de interpretação das variações observadas.

O SHM (do inglês *Structural Health Monitoring*), surge como um conjunto de estratégias e ferramentas unidas, voltadas ao contínuo monitoramento do estado de uma estrutura, com finalidade de detectar, localizar e, potencialmente, quantificar danos antes que estes evoluam para falhas severas. Conforme expresso por Lee e Lee (2025), para a prevenção da falha final de uma estrutura, seu estado operacional deve ser continuamente monitorado, evidenciando o caráter preventivo e preditivo das técnicas de SHM.

Apesar das técnicas de inspeções convencionais, realizadas por equipes de manutenção em intervalos definidos, ainda sejam bastante empregadas atualmente, apresentam limitações na detecção de falhas sutis ou iniciais. Melo *et al.* (2026) destacam que essas inspeções tradicionais podem ser inadequadas para detectar danos iniciais, podendo levar a intervenções tardias e de alto custo. Nesse ponto, os sistemas de SHM surgem como uma alternativa complementar de monitoramento baseado em dados, com potencial capacidade de identificar anomalias de forma contínua sem a depender de equipes em campo.

Atualmente esse conjunto de metodologias de monitoramento tem sido integrado às técnicas de aprendizado de máquina e vêm apresentando resultados promissores na detecção precoce de falhas ou defeitos. Segundo apontado por Poudel, Fu e Ye (2005) os avanços em aprendizado de máquinas tem revolucionado o campo do SHM ao permitir análises aprofundadas de grandes volumes de dados, fundamentais para que redes neurais possam ser treinadas e testadas e, por consequência, conseguirem emitir uma predição de estado e garantir informações necessárias para implementação de um plano de manutenção da estrutura, constituindo uma base para o acompanhamento estrutural eficaz e inteligente.

Por fim, cabe ressaltar que as necessidades de monitoramento variam de acordo com a natureza da estrutura e condições operacionais, no entanto, independente da aplicação dessas técnicas, os desafios principais do SHM permanecem os mesmos: reconhecer alterações relevantes no comportamento estrutural, diferenciá-las de variações ambientais ou operacionais e gerar informações úteis para tomada de decisão. Assim, o desenvolvimento de ferramentas capazes de contornar esses desafios tornam-se essenciais para o avanço do monitoramento estrutural.

2.2 VIBRAÇÃO E ANÁLISE MODAL

Estruturas de engenharia estão constantemente sujeitas à ação de carregamentos dinâmicos provenientes de fontes naturais ou artificiais, tais como vento, tráfego, máquinas

rotativas, impactos e excitações ambientais, onde a junção entre essas ações e as propriedades físicas da estrutura produz uma resposta vibratória que carrega uma assinatura a respeito do seu comportamento dinâmico permitindo que o estudo das vibrações mecânicas e análise modal constituam uma ferramenta importante para compreender a resposta estrutural à carregamentos e apoiar técnicas de monitoramento.

Rao (2008, p. 6) define vibração como “qualquer movimento que se repita após um intervalo de tempo”, e de forma complementar, Leme (2014), aponta que as vibrações representam fenômenos físicos amplamente presentes em sistemas mecânicos e estruturais, podendo surgir tanto devido às características próprias e operacionais da estrutura quanto causadas por excitações externas. Em sistemas reais, essa resposta vibratória reflete uma relação direta entre as propriedades do sistema e condições às quais está submetido.

Do ponto de vista físico, um sistema vibratório é geralmente composto por elementos associados à massa, à rigidez e ao amortecimento, onde a massa está relacionada ao armazenamento de energia cinética, a rigidez ao armazenamento de energia potencial e o amortecimento à dissipação de energia, e a união entre esses três elementos determina a resposta dinâmica da estrutura diante das diferentes formas de excitação às quais está submetida (RAO, 2008).

A importância do estudo das vibrações tem aumentado significativamente nas últimas décadas visto que o aumento da esbeltez estrutural, junto com a crescente intensidade dos carregamentos dinâmicos tem exigido uma compreensão cada vez mais detalhada do comportamento vibratório das estruturas para garantir condições adequadas de segurança, confiabilidade e funcionalidade, corroborando ainda com a necessidade do monitoramento contínuo da integridade estrutural (REYNDERS, 2012).

2.2.1 Frequências Naturais e Modos de Vibração


Os modos de vibração são caracterizados por três parâmetros fundamentais, sendo estes a frequência natural, amortecimento modal e forma modal, permitindo com que uma mesma estrutura não possua apenas uma frequência natural, mas sim um conjunto de frequências associadas aos seus diferentes modos de vibração. A frequência natural corresponde à frequência na qual a estrutura tende a vibrar após uma perturbação inicial, enquanto a forma modal descreve o padrão geométrico de deformação associado a essa vibração. Essas características constituem uma espécie de assinatura dinâmica da estrutura, sendo amplamente utilizadas para sua caracterização (LEME, 2014).

A análise das frequências naturais possui grande importância devido sua sensibilidade às alterações das propriedades estruturais, visto que mudanças na rigidez, na massa ou nas condições de contorno provocam modificações, geralmente, mensuráveis nas frequências naturais da estrutura. Nesse sentido, Li e Huang (2024) destacam que a variação das frequências naturais constitui um dos principais indicadores de alterações estruturais, uma vez que danos modificam diretamente as propriedades dinâmicas do sistema, enquanto que Salehi (2021) também reforça essa ideia ao apontar que as frequências naturais representam características intrínsecas da estrutura e são influenciadas principalmente pela massa, rigidez e condições de contorno, onde a alterações nesses parâmetros provocam mudanças na resposta dinâmica, permitindo que as frequências naturais sejam utilizadas como indicadores do estado estrutural. Ademais, as formas modais também contribuem para a descrição do comportamento vibratório onde a comparação entre formas modais de estruturas em diferentes condições permite identificar modificações associadas a alterações de integridade física (DAS, SAHA E PATRO, 2016; LI E HUANG, 2024).

Sirqueira (2008), ao realizar a análise modal de uma torre eólica, verificou que o primeiro modo de vibração apresenta comportamento predominantemente de flexão, evidenciando que a estrutura pode ser aproximada pelo comportamento típico de uma viga engastada-livre. Essa observação é relevante para este trabalho, uma vez que esse modelo estrutural representa uma das configurações mais utilizadas em análises experimentais e numéricas de vibração.

A Figura 4 apresenta os quatro primeiros modos normais de uma viga engastada-livre estudada por Figueiredo *et al.* (2014). As formas modais identificadas permitem avaliar o comportamento oscilatório da estrutura e corroboram a afirmação de Sirqueira (2008) pela identificação do primeiro modo normal associado à flexão.

Figura 4: Quatro primeiros modos normais de uma viga engastada-livre




Fonte: Figueiredo *et al.* (2014)

2.2.2 Fundamentos de Análise Modal

A caracterização das propriedades dinâmicas de uma estrutura pode ser realizada por meio da análise modal, uma vez que essa técnica permite estimar parâmetros como frequências naturais, modos de vibração e amortecimento a partir da avaliação da resposta vibratória do sistema, sem que seja necessariamente conhecido o sinal de excitação aplicado à estrutura, conforme apontado por Valente, Siqueira e Sousa (2016). De forma complementar, Leme (2014) define a análise modal como o estudo das propriedades dinâmicas de um sistema por meio de excitações vibratórias, com objetivo de determinar seus parâmetros modais.

A relevância da análise modal é evidenciada por sua ampla utilização em diferentes aplicações de engenharia, onde o conhecimento das frequências naturais e dos modos de vibração é fundamental para avaliar a integridade estrutural, especialmente em situações envolvendo carregamentos dinâmicos variáveis no tempo, conforme destacado por Chaudhary e Nallasivam (2024). Para uma análise modal efetiva e eficaz, Reynders (2012) aponta que o processo deve abranger três etapas principais: aquisição dos dados vibratórios, identificação do sistema e extração dos parâmetros modais; tornando possível obter uma representação confiável do comportamento dinâmico da estrutura.

Figura 5: Fluxograma das etapas da análise modal




Fonte: Adaptado de Reynders (2012, p. 52)

A Figura 5 apresenta um fluxograma do processo de análise modal sugerido por Reynders (2012), permitindo uma visualização prática das etapas básicas envolvidas na caracterização dinâmica de estruturas sob carregamentos variáveis no tempo.

2.2.3 Análise Modal Experimental e Operacional

A análise modal experimental é uma das abordagens mais utilizadas para a identificação dos parâmetros modais de estruturas, e consiste no uso de dados obtidos diretamente da estrutura real, permitindo determinar suas características dinâmicas com base em medições físicas. Nesse tipo de análise, a estrutura é submetida a uma excitação controlada e sua resposta é medida por sensores apropriados, assim, a partir da medição simultânea da força aplicada e da resposta vibratória, torna-se possível determinar as Funções Resposta em Frequência, FRF (do inglês *Frequency Response Functions*), que descrevem a relação entre a entrada e a saída do sistema (LEME, 2014).

Figura 6: Análise modal experimental de uma viga engastada-livre



Fonte: Vieira *et al.* (2024)

A Figura 6 apresenta o arranjo experimental utilizado por Vieira *et al.* (2024) para a análise dinâmica de uma viga engastada-livre por meio de ensaio de impacto, apresentando os principais elementos do procedimento experimental, como o engaste responsável por representar a condição de contorno da estrutura, o martelo de impacto utilizado para aplicar a excitação, o acelerômetro empregado na medição da resposta vibratória, o módulo de aquisição responsável pelo registro dos sinais e o computador utilizado no processamento dos dados. Tal aparato ilustra uma das técnicas mais consolidadas no âmbito da análise modal experimental e auxiliou os autores na identificação de parâmetros modais associados ao comportamento estrutural.

A obtenção da FRF normalmente é realizada por meio de ensaios experimentais, nos quais uma força conhecida é aplicada à estrutura e sua resposta vibratória é registrada por sensores, e a partir desses sinais, técnicas de processamento digital são empregadas para

converter as informações do domínio do tempo para o domínio da frequência. A interpretação das FRFs permite identificar os picos de ressonância associados às frequências naturais da estrutura, onde, nessas regiões de ressonância, pequenas forças de excitação podem produzir respostas vibratórias significativamente amplificadas de modo que os picos observados indicam as faixas em que ocorre maior amplificação da resposta estrutural e estão diretamente associados às frequências naturais dos respectivos modos de vibração (VALENTE, SIQUEIRA E SOUSA, 2016).

Embora a análise modal experimental seja amplamente utilizada, sua aplicação é limitada em situações onde a utilização de excitações controladas seja inviável, exigindo assim a criação de novas técnicas capazes de contornar essa limitação, impulsionando o desenvolvimento das técnicas de Análise Modal Operacional (OMA, do inglês, *Operational Modal Analysis*), que segundo Valente, Siqueira e Sousa (2016), permite obter parâmetros modais utilizando exclusivamente as respostas vibratórias da estrutura sem a necessidade de medir ou conhecer a força de excitação aplicada, considerando que a estrutura é excitada por fontes ambientais ou de operação, como vento, tráfego urbano ou vibrações de serviço, enquanto que Reynders (2012) destaca sua importância para aplicações envolvendo grandes estruturas, nas quais a utilização de excitações forçadas é impraticável.

Magalhães, Cunha e Caetano (2012) destacam que as técnicas de análise modal operacional permitem identificar parâmetros modais em condições reais de funcionamento sem a necessidade de interromper a operação da estrutura. Essa abordagem favorece o monitoramento de longo prazo já que pequenas variações nas frequências naturais podem ser percebidas mesmo em ambientes que sofram interferências operacionais e ambientais fazendo com que a análise modal operacional represente um avanço importante das técnicas de caracterização dinâmica em estruturas de grande porte.

Em síntese, o estudo das vibrações mecânicas e da análise modal fornece a base necessária para compreender o comportamento dinâmico estrutural por meio das frequências naturais e modos de vibrar, por exemplo. Esses parâmetros constituem características de assinatura estrutural e podem alimentar modelos preditivos voltados à estimativa de grandezas físicas e ao monitoramento estrutural.

2.3 SENSORES VIRTUAIS


O cerne do monitoramento de estruturas e sistemas dinâmicos baseia-se na capacidade de acompanhar grandezas físicas relevantes ao longo do tempo por meio do uso de transdutores que convertem essas grandezas físicas mensuráveis em sinais elétricos processáveis. A escolha

e o posicionamento desses instrumentos de medição são fundamentais para a qualidade dos dados coletados, conforme apontado por Zou e Chakrabarty (2003) ao afirmarem que a cobertura proporcionada pelo posicionamento desses instrumentos implica diretamente na eficiência da rede de sensores e qualidade das informações obtidas. Assim, seria necessário um número elevado de pontos instrumentados para captar um comportamento vibratório de uma estrutura de médio ou grande porte, o que pode ser inviável por elevar os custos, dificuldade de acessos ou interferências na operação.

Considerando todo o cenário de limitações operacionais, custos elevados e inviabilidade de instrumentação eficaz, surgem os sensores virtuais como uma alternativa complementar visando especialmente contornar essas limitações e, em muitos casos, tornando-se indispensável. Essa lógica é particularmente importante quando não há possibilidade de instrumentar todos os pontos de interesse, contudo ainda se deseja prever a resposta de uma grandeza física a partir dos sinais disponíveis.

Na Figura 7 é apresentado um sistema de destilação de GLP, no qual é possível observar a instrumentação de alguns pontos físicos responsáveis pela coleta dos dados de monitoramento e também para alimentação dos sensores virtuais associados à coluna de destilação, permitindo que a rede estime a composição do GLP em pontos não instrumentados.

Figura 7: Instrumentação física e virtual de uma planta de destilação de gás GLP



Fonte: Lima, 2018 *apud* Rodrigues (2023)


Um sensor virtual é um modelo computacional que estima variáveis que não são diretamente mensuráveis por meio de outras variáveis disponíveis no sistema, onde a “medição” de saída do sensor virtual é realizada por inferência matemática, em vez de utilizar um transdutor físico. Essa “medida virtual” possui uma mesma natureza funcional da leitura de um instrumento real, contudo obtida sem contato direto com o fenômeno físico. Freitas (2023)

desenvolve essa ideia ao propor a aplicação de sensoriamento virtual usando aprendizado de máquina, para prever uma variável operacional a partir de outras variáveis mensuráveis do sistema, sem modelagem física da dinâmica do escoamento.

Do ponto de vista prático, um sensor virtual se desenvolve inicialmente com o treinamento da rede onde o modelo aprende as correlações entre as variáveis de entrada e as variáveis-alvo, utilizando dados históricos nos quais ambas eram conhecidas e assim segue para a fase de inferência, na qual o modelo recebe apenas os dados das variáveis de entrada e retorna uma estimativa das variáveis-alvo. Ibrahim *et al.* (2023) reforçam que para obter-se estimativas representativas do comportamento real deve haver uma validação e ajuste do sensor virtual com dados reais do sistema, evitando que o modelo esteja apenas sobreajustado aos dados de treinamento e falhando ao ser testado com outro conjunto de dados reais.

A fim de apresentar de forma clara o processo prático da construção e validação de um sensor virtual, a Fig. 8 estabelece um fluxograma do processo de treinamento e inferência aplicada a esse tipo de modelo.

Figura 8: Fluxograma do processo de atuação de um sensor virtual



Fonte: Próprio Autor (2026)

Apesar das particularidades das aplicações, a ideia central continua sendo usar dados disponíveis para estimar informações que não são diretamente acessíveis. Ademais, os sensores virtuais também podem atuar na detecção de desvio de integridade quando os valores reais medidos se afastam significativamente das estimativas produzidas pelo modelo, onde, nessa lógica, o sensor virtual estabelece um padrão de referência do comportamento esperado, e qualquer desvio considerável entre a estimativa e o padrão esperado torna-se um indicador de mudança no estado estrutural (MOUSAVI *et al.*, 2025).

2.4 SÉRIES TEMPORAIS E REDES NEURAIS

Na coleta de sinais vibracionais de uma estrutura mecânica, a resposta dinâmica registrada pelos sensores carrega informações sobre o comportamento estrutural que dependem da sequência que foram medidas. Esse tipo de dado é denominado série temporal, que pode ser definido como "uma coleção de observação de uma variável aleatória, dispostas de maneira sequencial e ordenada em uma determinada unidade de tempo" (CAMARGO; SOUZA, 1996 *apud* MARTINS, 2024, p. 17), diferenciando-se de um conjunto de dados comum pela dependência entre observações consecutivas.

No caso de sinais de vibração, a resposta da estrutura em um dado instante é condicionada pelas excitações e estados anteriores. Portanto, em um sensor virtual, essa característica precisa ser preservada durante todo o processamento e admitida à entrada do modelo preditivo, pois o histórico do sinal implica diretamente no desempenho do modelo (CONTARINI, 2020).

As redes neurais artificiais (RNAs) constituem uma classe de modelos computacionais inspirados no funcionamento do sistema nervoso biológico, capazes de estabelecer funções complexas a partir de exemplos, tornando-as adequadas para representação de problemas em que o fenômeno físico de interesse seja não-linear ou de difícil parametrização. Assim, esses modelos se enquadram como altamente relevantes para aplicações e desenvolvimentos de sensores virtuais, onde a rede aprende a estimar as variáveis de interesse por meio de outras grandezas mensuráveis (OLIVEIRA, 2020).

A arquitetura mais básica de RNA, o perceptron multicamadas MLP (do inglês *Multilayer Perceptron*), não possui mecanismo nativo para lidar com dependências temporais, impedindo que o modelo retenha qualquer estado entre as amostras processadas. Nesse contexto, as redes neurais recorrentes (RNN, do inglês, *Recurrent Neural Network*) foram desenvolvidas para contornar essa lacuna ao incorporar um mecanismo de realimentação fazendo com que a predição atual dependa não apenas da entrada presente, mas do conteúdo acumulado ao longo da sequência, configurando uma forma de memória temporal, que, por sua vez, explica a afinidade das RNNs com fenômenos temporalmente dependente (OLIVEIRA, 2020).

Apesar disso, as RNN (do inglês *Recurrent Neural Network*) convencionais apresentam uma limitação em sequências longas: a dificuldade de manter informações de instantes mais distantes, refletindo no “enfraquecimento” dos ajustes realizados durante o treinamento à medida que passam por muitos passos de tempo. Esse problema motivou o desenvolvimento de

arquiteturas com mecanismos de controle sobre a informação retida ou descartada ao longo da sequência.

A rede neural recorrente LSTM (do inglês, *Long-Short Term Memory*) foi desenvolvida com mecanismos internos de controle de seleção da informação ao longo do tempo por meio de “portas” que regulam a entrada de informações novas na célula, qual parte da informação do estado anterior deve ser descartada e o que será utilizado para emitir uma saída. Essa arquitetura permite que a rede retenha dependências de longo prazo sem que se degradem ao longo da sequência, tornando-a capaz de modelar sinais com comportamento oscilatório e de múltiplas frequências (MARTINS, 2024; ALFRED *et al.*, 2025; OLIVEIRA, 2020). No contexto do sensor virtual proposto neste trabalho, essa propriedade é crucial, pois a modelagem dos pontos de resposta da viga a partir de sinais de entrada requer que a rede considere o histórico da excitação de estrutura.

2.5 HIPERPARÂMETROS LSTM

Estabelecer uma configuração de LSTM envolve um conjunto de decisões de hiperparâmetros que precisam ser avaliados em função das características dos dados e do desempenho observado. Kervancı e Akay (2023) e Contarini (2020) apontam que um modelo de rede neural produz respostas bem distintas em função da escolha de seus hiperparâmetros, necessitando que sejam otimizados de forma empírica para cada problema específico, já que não existem regras consolidadas que determinem a melhor configuração. É nesse contexto que se insere o objetivo central desse trabalho ao investigar diferentes configurações de redes neurais LSTM aplicadas à modelagem de sinais vibracionais de uma viga engastada-livre.

O número de camadas é um dos hiperparâmetros mais pautados em contextos de arquiteturas LSTM, onde, em geral, adicionar camadas aumenta a capacidade de representação do modelo, mas também eleva o custo operacional e risco de sobreajuste (*overfitting*). Kervancı e Akay (2023) relatam que uma LSTM de duas camadas, com parâmetros otimizados, apresentou um desempenho melhor do que arquiteturas com três e quatro camadas, indicando que nem sempre uma configuração mais robusta e profunda retornará a melhor modelagem. Em sinais vibratórios, a arquitetura deve ser complexa o suficiente para captar a assinatura do comportamento estrutural, porém não tão complexa a ponto de aprender e modelar ruídos.

O número de neurônios, ou células, interfere diretamente na capacidade de aprendizagem, onde um maior número de células implica em um aumento da capacidade da rede de representar padrões temporais, contudo, aumentando o custo de processamento também, necessitando ser compatível com o volume e complexidade dos dados (CHOLLET,

2018). Já o *batch size* define quantos exemplos são utilizados em cada iteração de treinamento, influenciando diretamente a atualização dos pesos da rede. Isso ocorre porque o modelo recalcula seus pesos e ajusta gradualmente seu aprendizado a partir dos erros observados nos exemplos que integram cada lote (MARTINS, 2024).

Outro parâmetro importante é a janela deslizante, e corresponde à quantidade de informações anteriores fornecidas na entrada para que a rede estime o valor seguinte de saída. Em termos práticos, uma janela muito curta pode não fornecer características suficientes sobre o comportamento da série temporal, enquanto uma janela muito longa acaba aumentando a complexidade fazendo com que o modelo “arraste” informações pouco relevantes ao longo do treinamento (MARTINS, 2024). Semelhantemente, o número de épocas tem forte influência em levar o modelo à uma robustez exagerada ou ao baixo aprendizado. Por definição, as épocas constituem quantas passagens completas pelos dados de treinamento serão realizadas. Assim, um número muito baixo de épocas pode resultar em treinamento insuficiente, reduzindo o aprendizado de padrões relevantes, enquanto que treinar durante muitas épocas pode levar o modelo a se especializar demais nos dados de treinamento agregando um potencial sobreajuste (CHOLLET, 2018).

No contexto de sobreajuste e mecanismo de regularização, o *dropout* entra como principal agente ao reduzir a dependência excessiva em determinadas conexões de neurônios durante o processo de treinamento, de forma mais didática, esse hiperparâmetro desativa aleatoriamente (CHOLLET, 2018). Romeiro (2025, p. 37) afirma que “as taxas de *dropout* [...] foram definidos empiricamente com base em testes que equilibravam o desempenho preditivo e o custo computacional”, dessa maneira, não basta escolher uma taxa de *dropout* por conveniência, mas avaliar como ela interfere no erro de previsão e capacidade do modelo em generalizar para novo conjunto de dados e estabelecer o melhor ajuste possível desse parâmetro.

2.5.1 Métricas de Desempenho

Tanto durante quanto após o processo de treinamento, é necessário quantificar o erro entre os valores preditos pela rede e os valores reais. Para isso, utiliza-se métricas de erro que norteiam o modelo na ponderação dos dados durante o treinamento e, posteriormente, servem como indicadores da sua acurácia. Entre as métricas mais utilizadas, destacam-se o erro médio absoluto, MAE (do inglês, *Mean Absolute Error*), o erro quadrático médio, MSE (do inglês, *Mean Squared Error*), e a raiz do erro quadrático médio, RMSE (do inglês, *Root Mean Squared Error*).

O erro médio absoluto corresponde à média das diferenças, em módulo, entre os valores reais e os valores previstos pelo modelo. Por apresentar uma variação linear em relação à magnitude do erro, ou seja, trata todos os desvios de forma proporcional, faz com que haja uma certa insensibilidade a presença de picos ou valores discrepantes. Seu cálculo é apresentado na Equação 1, em que n representa o número de amostras da série temporal, Y corresponde ao valor real observado e $\hat{Y}$ indica o valor previsto para o mesmo ponto da série (PENTEADO, 2021 *apud* ROMEIRO, 2025; CHOLLET, 2018).

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} \quad (1)$$

O RMSE corresponde à raiz quadrada do erro quadrático médio e se diferencia do MAE por elevar ao quadrado a diferença entre os valores reais e previstos antes do cálculo médio. Isso faz com que erros maiores tenham maior influência no resultado, tornando a métrica mais sensível a valores discrepantes (PENTEADO, 2021 *apud* ROMEIRO, 2025). A raiz quadrada aplicada ao final volta o erro para a mesma unidade da variável analisada, sem anular o peso dos maiores desvios. Assim, quando o RMSE é muito superior ao MAE, pode se interpretar que a rede não erra de maneira uniforme, mas concentra erros mais elevados em pontos específicos da série, como *outliers*.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2)$$

O MSE, obtido pela equação 3, representa a média dos erros quadráticos sem a aplicação da raiz ao final, fazendo com que sua leitura física seja menos direta, já que o resultado fica em unidade quadrática. Por penalizar os maiores desvios com mais intensidade, o MSE é bastante utilizado como função de perda no treinamento de redes neurais por favorecer a construção de modelos menos tolerantes a grandes discrepâncias (CHOLLET, 2018).

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (3)$$

3 METODOLOGIA

Este trabalho foi desenvolvido a partir de uma abordagem experimental e computacional, visando a modelagem de sinais vibracionais e caracterização modal em uma viga engastada-livre por meio da construção e avaliação de sensores virtuais baseados em redes neurais LSTM. Todo o procedimento experimental foi elaborado para investigar como diferentes configurações da rede afetam a capacidade de previsão das respostas dinâmicas da estrutura a partir de sinais obtidos experimentalmente em túnel de vento.

A metodologia foi dividida em etapas sucessivas: caracterização da estrutura, instrumentação com acelerômetros, ensaio em túnel de vento e aquisição de sinais, organização dos dados, definição dos sensores de referência e de varredura, definição dos hiperparâmetros, treinamento da LSTM, avaliação por métricas de desempenho e validação complementar por análise modal. O fluxograma da Fig. 9, apresenta essa metodologia aplicada de forma visual.

Figura 9: Fluxograma Geral da Metodologia




Fonte: Próprio Autor (2026)

3.1 ESTRUTURA E APARATOS EXPERIMENTAIS

A estrutura utilizada nesse estudo consiste em uma viga engastada-livre, fabricada em alumínio, instrumentada com acelerômetros ao longo de seu comprimento. Essa condição de contorno foi adotada por representar uma configuração clássica em estudos de vibração estrutural além de permitir a observação de respostas dinâmicas bem definidas. Contudo, a Fig. 10 apresenta uma representação gráfica da estrutura estudada, bem como suas dimensões geométricas: 300,00 mm de altura, 18,50 mm de largura e espessura de 3,00 mm.


Figura 10: Representação gráfica do modelo de viga [mm]



Fonte: Próprio Autor (2026)

A viga foi instrumentada com cinco acelerômetros, nomeados de A1, A2, A3, A4 e A5 respectivamente a partir do engaste em direção à extremidade livre, fazendo com que cada medição experimental apresente um conjunto de sinais sincronizados, composto por uma coluna tempo e cinco colunas de aceleração, uma para cada sensor. Ademais, a Fig. 11 apresenta a viga instrumentada, bem como o posicionamento dos acelerômetros espaçados em um intervalo de 75 mm.

Figura 11: Representação da instrumentação da viga



Fonte: Próprio Autor (2026)

Foram utilizados dois modelos diferentes de acelerômetros para mensuração dos sinais vibracionais da viga. No ponto de engaste, correspondente ao sensor A1, foi empregado o acelerômetro Brüel & Kjær, modelo Type 4516, com massa de 1,5 gramas e sensibilidade de 10,45 mV/g, por apresentar maior massa em relação ao segundo modelo e buscando reduzir a interferência na resposta dinâmica da estrutura. Para as posições A2, A3, A4 e A5, foram utilizados acelerômetro da marca PCB Piezotronics, modelo 352C23, massa de 0,19 g e sensibilidade de 5 mV/g.

A utilização de dois modelos de acelerômetros ocorreu em função da disponibilidade de apenas quatro unidades do modelo PCB 352C23. Assim, para completar os cinco pontos de instrumentação, empregou-se uma unidade do modelo B&K 4516, posicionada no ponto de engaste por apresentar maior massa, de modo a reduzir sua influência sobre a resposta dinâmica da viga.

As principais informações de cada modelo são apresentadas no Quadro 1.

Quadro 1: Parâmetros técnicos dos acelerômetros utilizados

Parâmetros	PCB Modelo 352C23	B&K Type 4516
Sensibilidade	5 mV/g	10,45 mV/g
Massa	0,19 g	1,5 g
Faixa de Frequência	2,0 – 10.000 Hz	1,0 – 20.000 Hz
Freq. De Ressonância	≥ 70 kHz	40 kHz

Fonte: Adap. de PCB Piezotronics (2026) e Brüel & Kjær (2004)

Para a captação dos sinais vibracionais foram utilizados dois módulos de aquisição de dados e um chassi responsável pela integração dos instrumentos. Os módulos utilizados são da marca National Instruments, modelo NI-9234, com quatro canais analógicos, resolução ADC de 24 bits e frequência máxima de aquisição de 51,2 KHz. O chassi modular, também da National Instruments, possui quatro slots para acoplamento dos módulos e resolução de 32 bits. A Figura 12 mostra os acelerômetros utilizados e o sistema modular de aquisição de dados.

Figura 12: Instrumentos de aquisição de sinais vibracionais



Fonte: Próprio Autor (2026)

Após a montagem do aparato de instrumentação e coleta de dados, o sistema foi conectado a um notebook, permitindo a configuração das condições de medição, coleta dos sinais de vibração e o armazenamento dos dados experimentais. Para essa etapa, foi utilizado o software ARTeMIS Modal para definição dos parâmetros de aquisição, como frequência de aquisição, número de pontos por medição e identificação dos canais associados a cada acelerômetro, enquanto que o processamento e o armazenamento dos dados foi realizado em um notebook Lenovo, com processador Intel(R) Core i5, 8 GB de memória RAM e sistema operacional Windows 11. Esse conjunto possibilitou a coleta padronizada das medições dos sinais vibracionais utilizados nas etapas posteriores desse estudo.

Figura 13: Túnel de vento subsônico modelo AA-TVSH1



Fonte: Aeroalcool Tecnologia LTDA (2026)

Os ensaios foram realizados em túnel de vento subsônico, representado na Fig. 13, com a viga sob escoamento de ar, caracterizando uma análise modal operacional, visto que a resposta estrutural é obtida a partir de uma excitação sem medição direta da força aplicada sobre a estrutura. Este equipamento, fabricado pela Aeroalcool Tecnologia, modelo AA-TVSH1, possui uma câmara de teste fechada, minimizando interferências externas, um circuito de escoamento aberto horizontal e velocidade máxima do escoamento de 58 m/s. As características técnicas do túnel de vento são detalhadas no Quadro 2.

Quadro 2: Especificações técnicas túnel de vento subsônico

Modelo AA-TVSH1c	
Velocidade de escoamento	0 – 58 m/s
Área de ensaios	462 x 462 mm
Comprimento da seção de ensaios	1200 mm
Dimensão total	5,5 (C) x 2,1 (A) x 1,3 (L) m
Peso	200 kg
Relação do difusor	3:1
Relação de contração	4,5:1

Fonte: Aeroalcool Tecnologia LTDA (2026)

3.2 COLETA E TRATAMENTO DE DADOS EXPERIMENTAIS

Para o procedimento experimental, após a montagem da bancada, foram adotadas duas velocidades de escoamento: 5,0 m/s e 10,0 m/s. Para cada velocidade, foram realizadas duas coletas independentes, sendo a primeira coleta com duração de 3 minutos, destinada ao treinamento e teste das redes LSTM, enquanto que a segunda coleta teve duração de 1 minuto e foi utilizada para a validação externa do sensor virtual. Além disso, adotou-se uma frequência de aquisição de 3200 Hz fazendo com que cada coleta de dados de 3 minutos tenha 576000 pontos por sensor e 192000 pontos por sensor na coleta de 1 minuto de duração.

Conforme mencionado anteriormente, cada amostra é composta por seis colunas: uma coluna referente ao tempo e cinco colunas de aceleração, uma para cada sensor. Na organização dos dados experimentais, os sensores foram divididos em sensores de referência e sensores de varredura, de tal forma que os sinais dos sensores de referência foram utilizados como variáveis de entrada da rede neural, enquanto os sinais dos sensores de varredura foram tratados como variáveis alvo a serem estimadas.


Assim, o treinamento da rede ocorre com os sinais de referência como entradas e os sinais de varredura como saídas reais esperadas, considerando a amostra de 3 minutos de

duração. Na etapa de validação, a rede recebe novos sinais dos sensores de referência e, a partir deles, estima as respostas dos sensores de varredura, reconstruindo as respostas vibracionais em pontos não medidos diretamente.

A configuração dos sensores foi escolhida considerando critérios de distribuição espacial dos instrumentos de medição, além do interesse em estimar regiões intermediárias da viga. Desse modo, os sensores A1 e A5 foram definidos como sensores de referência, enquanto A2, A3 e A4 foram classificados como sensores de varredura.

A Figura 14 apresenta a esquematização da alimentação da rede neural pelos sensores de referência e de varredura.

Figura 14: Esquematização de aplicação dos sensores de referência e varredura




Fonte: Próprio Autor (2026)

3.3 CONSTRUÇÃO DO SENSOR VIRTUAL

Todo o procedimento computacional foi executado no ambiente Spyder, desde a manipulação e normalização dos dados adquiridos até a construção da rede neural e obtenção dos seus resultados.

Inicialmente, foi-se utilizado a biblioteca Pandas para importação dos arquivos de informações dos sinais, separação dos dados de referência e varredura e descarte da coluna de tempo, já que a entrada da rede será apenas as informações de aceleração captada pelos sensores. Em seguida, utilizou-se a biblioteca Scikit learn para padronizar os sinais antes do treinamento da rede LSTM, onde os dados passaram a apresentar média próxima de zero e desvio padrão próximo de um, reduzindo diferenças de escala entre os sinais. O Scikit learn também foi o responsável por pautar o cálculo de métricas de desempenho da rede.

Após o tratamento dos dados, a biblioteca TensorFlow foi a ferramenta fundamental que permitiu a construção das redes neurais recorrentes LSTM. A arquitetura base da rede foi estruturada de forma sequencial com cinco camadas, iniciando com duas camadas profundas LSTM para modelar a dependência temporal, seguida de uma camada densa para refinar as informações obtidas pelas camadas LSTM anteriores. Logo após, foi adicionada uma camada *Dropout* para minimizar os riscos de sobreajuste de treinamento e por fim, a camada de saída responsável por fornecer a estimativa do sinal de varredura. A Figura 15 traz uma esquematização desse processo de atuação da rede neural desenvolvida.



Fonte: Próprio Autor (2026)

A fim de estudar o desempenho de diferentes arquiteturas, foram selecionados três hiperparâmetros para avaliação de influência: tamanho da janela temporal, número de neurônios na camada LSTM e taxa de *dropout*, enquanto que os demais parâmetros foram mantidos nas configurações padrão da biblioteca utilizada ou em um valor pré-estabelecido. O tamanho da janela temporal é responsável por determinar a quantidade de informações passadas à rede; o número de neurônios da camada LSTM se relaciona à capacidade da rede em representar padrões complexos, enquanto que a taxa de *dropout* é utilizada como técnica de redução de sobreajuste. O parâmetro *batch size* foi mantido em 64, enquanto o número de épocas foi limitado superiormente a 12 épocas, porém contando com um sistema de parada antecipada caso não haja melhora de treino em 0,0007 por três épocas consecutivas.

O Quadro 3 apresenta a configuração das três redes neurais LSTM pré-estabelecidas. A Configuração C1 foi definida como modelo de referência por utilizar valores intermediários de janela temporal, número de neurônios e regularização. A Configuração C2 foi estabelecida com uma janela temporal maior, permitindo avaliar se o aumento do histórico temporal fornecido à

rede contribui para uma melhor representação dos sinais vibracionais, enquanto a Configuração C3 une um maior número de neurônios a uma taxa de *dropout* mais elevada permitindo investigar a influência do aumento da capacidade de modelagem da rede, acompanhada de uma maior regularização. Vale ressaltar ainda, que o aumento da taxa de *dropout* para 0,32 na Configuração C3 visou aplicar uma maior regularização da rede ao desativar um número maior de neurônios, tendo em vista que o aumento do número de neurônios pode elevar um ajuste excessivo aos dados de treinamento.

Quadro 3: Configuração de arquiteturas LSTM estabelecidas

Configuração	Janela Temporal	Nº de Neurônios	Dropout
C1	128	64	0,20
C2	256	64	0,20
C3	128	128	0,32

Fonte: Próprio Autor (2026)

Estabelecidos os valores de hiperparâmetros e arquiteturas a serem avaliadas, cada configuração foi treinada para cada velocidade de escoamento, permitindo analisar o desempenho do sensor virtual em diferentes condições operacionais, além de verificar se as arquiteturas propostas apresentam comportamento consistente em diferentes condições de escoamento.

3.4 AVALIAÇÃO DE DESEMPENHO DO SENSOR VIRTUAL

O desempenho dos sensores virtuais foi avaliado por dois métodos: análise das métricas de desempenho e validação por análise modal, ambos realizados pela comparação entre os sinais reais dos sensores de varredura e os sinais previstos pela rede LSTM.

A avaliação inicial foi estabelecida pelas seguintes métricas:

- Erro Médio Absoluto (MAE)
- Raiz do Erro Quadrático Médio (RMSE),

no qual o uso dessas métricas visa não apenas avaliar o erro médio da estimativa, mas também apontar a presença de desvios mais críticos em pontos específicos do sinal.

A avaliação estatística permitiu selecionar a configuração de rede que melhor se adequa para modelagem do sinal estrutural da viga. Feita a seleção da configuração, os sinais previstos por essa rede LSTM selecionada foram analisados por meio de uma comparação modal com os sinais reais mensurados, assim, cada sinal estimado foi comparado com seu respectivo sinal real no domínio da frequência, buscando observar a capacidade da rede em preservar características dinâmicas relevantes da estrutura, em especial as frequências naturais e os modos de vibração.

Essa etapa foi realizada com o auxílio da biblioteca Modalyzer, desenvolvida por Shamsaddinlou *et al.* (2026). Essa ferramenta em Python é voltada à Análise Modal Operacional, contando com recursos de pré-processamento, visualização de formas modais e aplicação de métodos como FDD e SSI. A comparação foi conduzida para cada velocidade de escoamento através dos valores de frequências naturais, taxa de amortecimento e análise dos valores de MAC para comparar as formas modais obtidas.

Dessa forma, a metodologia de avaliação combina métricas estatísticas e comparação modal, permitindo apontar a configuração de rede neural que apresenta melhor capacidade de modelagem e representação modal, além de avaliar a capacidade de carregar informações modais pelos sinais estimados.


4 RESULTADOS E DISCUSSÕES

4.1 SELEÇÃO DA CONFIGURAÇÃO DE REDE LSTM

A primeira etapa da análise de resultados pautou a escolha da configuração de rede LSTM mais adequada para a previsão dos sinais vibracionais nas duas condições de velocidade de escoamento empregadas. Para isso, foram consideradas as três configurações definidas na metodologia, variando a janela temporal, número de neurônios e taxa de *dropout*, enquanto que o treinamento manteve-se limitado superiormente a 12 épocas, com implementação de parada antecipada caso não haja melhora mínima de 0,0007 por 3 épocas consecutivas, além do tamanho do lote, *batch size*, fixado em 64.


O sensor virtual recebeu como entrada os sinais dos sensores nas posições A1 e A5, estimou a resposta vibracional nos pontos A2, A3 e A4, e retornou as métricas de desempenho para cada um dos sensores de varredura estimados, as quais foram tratadas por média para representação geral da rede. A Figura 16 representa o *plot* sobreposto do sinal real e sinal estimado, a título de exemplificação, para a Configuração C3, sensor A2, enquanto os resultados médios das métricas de erro, obtidos para as velocidades 5 m/s e 10 m/s são apresentados, respectivamente, nas Figuras 17 e 18.

Figura 16. *Plot* da resposta vibracional (C3, A2)




Fonte: Próprio Autor (2026)

Figura 17: Parâmetros de avaliação de desempenho das redes em 5 m/s



Fonte: Próprio Autor (2026)

Figura 18: Parâmetros de avaliação de desempenho das redes em 10 m/s



Fonte: Próprio Autor (2026)

Para mais, os Quadro 4 e 5 apresentam os valores das métricas em função da posição do acelerômetro de varredura para as velocidades de 5m/s e 10m/s. Esses valores permitiram calcular a média das métricas de erro para cada configuração, bem como avaliar as posições de acelerômetros que apresentaram melhor desempenho na previsão dos sinais de varredura, denominados de posição ótima, e aquelas consideradas críticas, nas quais a estimativa da resposta vibracional se mostrou mais difícil, chamados de posição crítica.

Quadro 4. Métricas de desempenho por sensor de varredura (5 m/s)

Velocidade de 5 m/s						
Config.	C1		C2		C3	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
A2	0,0181	0,0227	0,0178	0,0223	0,0177	0,0222
A3	0,0169	0,0211	0,0167	0,0210	0,0169	0,0213
A4	0,0161	0,0201	0,0158	0,0198	0,0159	0,0199
Média	0,0170	0,0213	0,0168	0,0210	0,0169	0,0211

Fonte: Próprio Autor (2026)

Quadro 5. Métricas de desempenho por sensor de varredura (10 m/s)

Velocidade de 10 m/s						
Config.	C1		C2		C3	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
A2	0,0380	0,0479	0,0372	0,0468	0,0385	0,0485
A3	0,0361	0,0454	0,0357	0,0449	0,0359	0,0452
A4	0,0313	0,0394	0,0309	0,0388	0,0310	0,0390
Média	0,0351	0,0442	0,0346	0,0435	0,0351	0,0442

Fonte: Próprio Autor (2026)

Pelos resultados apresentados na Fig. 17 e Quadro 4, a configuração C2 apresentou os menores valores de erro em média, ainda que com diferenças discretas. Ao comparar C1 e C2, que se diferem apenas pelo tamanho da janela temporal, pode-se afirmar que o melhor desempenho de C2 se deu pela ampliação da janela de 128 para 256 amostras ao permitir que a rede utilizasse um histórico mais amplo da resposta estrutural. Por outro lado, a configuração C3, mesmo com maior número de neurônios, não superou a C2, apresentando erros ligeiramente superiores e exigindo mais épocas de treinamento. Esse resultado mostra que o aumento da complexidade da rede não levou a uma previsão mais precisa, pois a maior quantidade de

neurônios, associada a uma taxa de *dropout* mais elevada, pode ter reduzido a eficiência do ajuste.

Esse mesmo padrão também foi observado na velocidade de 10 m/s, onde a C2 novamente apresentou os menores erros em média, apontados na Fig. 18 e Quadro 5. Apesar de que todas as configurações tenham apresentado aumento expressivo dos erros em relação à velocidade de 5 m/s, efeito esperado devido à maior intensidade dinâmica do escoamento e maior complexidade do sinal, a C2 manteve a melhor resposta relativa. Esse comportamento é importante por apontar que a configuração não foi superior apenas em uma condição específica, mas apresentou maior consistência quando avaliada nas duas velocidades simultaneamente.

Ao analisar o número de épocas, observa-se que na velocidade de 5 m/s, a C2 alcançou o melhor desempenho com 7 épocas, o mesmo número da C1 e inferior ao da C3 com 9 épocas, indicando maior eficiência de treinamento já que a rede atingiu um erro menor sem demandar um prolongamento do ajuste e poupando custo computacional. Já em 10 m/s, a C2 atingiu o limite máximo de 12 épocas, enquanto C1 e C3 foram interrompidas anteriormente em 9 e 10 épocas, respectivamente, apontando que a C2 ainda apresentou melhorias relevantes ao longo do treinamento, respeitando o critério de parada antecipada. Dessa forma, o número de épocas atingido pela C2 não deve ser interpretado como desvantagem, mas como reflexo da maior dificuldade de modelagem do sinal nessa condição.

Por fim, avaliando as métricas de erro individuais em cada posição instrumentada, apontadas nos Quadros 4 e 5, notou-se que a posição A2, ponto de varredura mais próximo do engaste, apresentou os maiores valores de erro, sendo considerada a posição crítica e mais difícil de prever, enquanto a posição A4, mais próxima da extremidade livre, apresentou os menores valores de erro, sendo classificada como a posição ótima e mais favorável à previsão do sinal.

Diante disso, a escolha da configuração C2 é justificada por apresentar os menores valores médios de MAE e RMSE nas duas velocidades avaliadas, sendo adotada como configuração final da rede LSTM para as etapas posteriores de validação e análise modal dos sinais previstos.

4.2 ANÁLISE MODAL OPERACIONAL

Com a seleção da C2 como configuração final da rede LSTM, essa configuração foi adotada nas etapas posteriores de validação e análise modal dos sinais previstos, a fim de averiguar se os sensores virtuais foram capazes de preservar as características dinâmicas da viga. Para essa análise, foram utilizadas duas técnicas implementadas na biblioteca Modalyzer, desenvolvida por Shamsaddinlou *et al.* (2026): o Método de Identificação Estocástica de Subespaço (SSI) no domínio do tempo e o Método de Decomposição no Domínio da Frequência

(FDD) no domínio da frequência. A partir dos parâmetros modais obtidos por esses métodos, utilizou-se o Critério de Garantia Modal (MAC) para avaliar a correlação entre as formas modais dos sinais reais de varredura e os estimados pelos sensores virtuais.

4.2.1 Extração dos Parâmetros Modais pelos Métodos SSI e FDD


A execução computacional da análise modal, considerando os três primeiros modos e os resultados amparados pela Configuração C2, permitiu que as Figuras 19 e 20 apresentassem os parâmetros modais obtidos pelo método SSI para as velocidades de 5 m/s e 10 m/s, enquanto as Figuras 21 e 22 apresentam os resultados obtidos pelo método FDD. Em ambos os casos, foram comparadas as frequências naturais extraídas dos sinais reais de varredura e dos sinais “virtuais” estimados pela rede LSTM, ambos reconstruídos com os sensores de referência A1 e A5 para conterem informação de 5 sensores, além das respectivas taxas de amortecimento. Além disso, os Quadros 6 a 9 apresentam um compilado dos valores de frequência natural e amortecimento para cada modo normal, considerando tanto os sinais reais quanto os sinais virtuais, sendo os Quadro 6 e 7 referentes ao método SSI e o Quadro 8 e 9 ao método FDD.

Quadro 6. Parâmetros modais em 5m/s (SSI)

Velocidade de 5 m/s				
Modo	Frequência Real (Hz)	Amortecimento Real	Frequência Virtual (Hz)	Amortecimento Virtual
1	24,773	0,010	24,777	0,010
2	149,633	0,018	149,476	0,017
3	411,384	0,022	410,958	0,023

Fonte: Próprio Autor (2026)

Figura 19: Parâmetros modais pelo método SSI para 5m/s




Fonte: Próprio Autor (2026)

Quadro 7. Parâmetros modais em 10 m/s (SSI)

Velocidade de 10 m/s				
Modo	Frequência Real (Hz)	Amortecimento Real	Frequência Virtual (Hz)	Amortecimento Virtual
1	24,655	0,015	24,647	0,015
2	147,490	0,030	147,413	0,030
3	405,987	0,015	405,993	0,015

Fonte: Próprio Autor (2026)

Figura 20: Parâmetros modais pelo método SSI para 10m/s



Fonte: Próprio Autor (2026)


Pelo método no domínio do tempo, SSI, Fig. 19 e 20, notou-se elevada proximidade entre as frequências naturais reais e virtuais, nas duas velocidades de escoamento analisadas, visto que, ao considerar a velocidade de 5 m/s, o maior erro relativo foi de 0,10% no segundo e terceiro modos normais, enquanto que em 10 m/s o maior erro relativo foi de 0,05%, no segundo modo. Ademais, conforme Quadros 6 e 7, para a velocidade de 5 m/s, a maior taxa de amortecimento se deu no terceiro modo, diminuindo conforme queda da frequência natural. Já na velocidade de 10 m/s, o segundo modo apresentou maior taxa de amortecimento, no valor de 0,003, enquanto os demais modos ficaram logo em seguida com o mesmo valor inferior de 0,015. De modo geral, os resultados foram coincidentes e consistentes, indicando que os sinais previstos conseguiram manter as características de frequências naturais e de amortecimento com boa precisão, mesmo com o aumento da velocidade de escoamento.

Quadro 8. Parâmetros modais em 5 m/s (FDD)

Velocidade de 5 m/s				
Modo	Frequência Real (Hz)	Amortecimento Real	Frequência Virtual (Hz)	Amortecimento Virtual
1	25,020	0,027	24,990	0,027
2	150,730	0,006	150,780	0,006
3	424,250	0,001	424,280	0,001

Fonte: Próprio Autor (2026)

Figura 21: Parâmetros modais pelo método FDD para 5m/s




Fonte: Próprio Autor (2026)

Quadro 9. Parâmetros modais em 10 m/s (FDD)

Velocidade de 10 m/s				
Modo	Frequência Real (Hz)	Amortecimento Real	Frequência Virtual (Hz)	Amortecimento Virtual
1	24,420	0,030	24,470	0,030
2	150,180	0,004	150,100	0,003
3	404,710	0,001	404,680	0,001

Fonte: Próprio Autor (2026)

Figura 22: Parâmetros modais pelo método FDD para 10m/s



Fonte: Próprio Autor (2026)

Quanto aos resultados obtidos pelo método FDD, Fig. 21 e 22, estes também reafirmaram a capacidade dos sinais previstos em modelar e conter as características dinâmicas da estrutura, tendo em vista que, para a velocidade de 5 m/s, o maior relativo ocorreu no primeiro modo com 0,12%, enquanto que em 10 m/s, o maior erro foi de 0,2% também no primeiro modo normal. Ademais, ao avaliar as taxas de amortecimento, Quadro 8 e 9, notou-se que os primeiros modos apresentaram as maiores taxas e diminuindo com o aumento da frequência, tanto para a velocidade de 5 m/s quanto de 10 m/s, divergindo da tendência obtida pelo método SSI. Essa divergência pode estar associada a diferenças de processamento e método de identificação, particular de cada método.

A comparação entre os métodos SSI e FDD reforça a consistência dos resultados obtidos, onde ambos identificaram os três primeiros modos em faixas de frequência semelhantes, indicando ainda que o aumento da velocidade de 5 m/s para 10 m/s não impediu a identificação dos modos principais pelos sinais previstos.


De modo geral, os resultados das Figuras 19 a 22 demonstram que os sinais estimados pela rede LSTM foram capazes de reproduzir adequadamente os principais parâmetros modais da viga. A baixa diferença entre frequências reais e virtuais, a repetição dos modos identificados nas duas velocidades e a concordância entre SSI e FDD indicam que os sensores virtuais preservaram as características dinâmicas essenciais da estrutura. Assim, a análise modal

confirma que a qualidade dos sinais previstos não se restringiu ao domínio do tempo, estendendo-se também à representação física do comportamento modal da viga.

4.2.2 Análise das Formas Modais


As Figuras 23 e 24 apresentam as formas modais obtidas a partir dos sinais reais e dos sinais estimados pelos sensores virtuais, considerando, respectivamente, os métodos SSI e FDD, permitindo avaliar não apenas a proximidade entre as frequências naturais identificadas, mas também a coerência espacial dos modos ao longo das posições instrumentadas da viga.

Figura 23. Formas modais (método SSI)



Fonte: Próprio Autor (2026)

Figura 24. Formas modais (método FDD)




Fonte: Próprio Autor (2026)

No método SSI, Fig. 23, as formas modais obtidas pelos sinais reais e virtuais apresentaram elevada coerência espacial, com boa sobreposição entre as formas nas duas velocidades avaliadas. Para 10 m/s, a correspondência visual é evidente nos três modos, sem

alteração do padrão modal identificado, enquanto que para 5 m/s, esse mesmo comportamento se mantém consistente, apesar de o terceiro modo apresentar uma discrepância mais perceptível, principalmente nas posições intermediárias. Ainda assim, essa diferença não compromete a avaliação modal pela forma, pois a tendência de deformação é preservada.

No método FDD, Fig. 24, também se observa comportamento semelhante, com forte concordância entre as formas modais reais e virtuais ao avaliar a sobreposição dos modos. Contudo, o terceiro modo aparece novamente como o caso mais sensível, principalmente em 5 m/s, onde há pequenas diferenças em alguns pontos da viga. Mesmo assim, o formato geral da resposta modal é mantido.

Figura 25. Modos de vibração




Fonte: Morais (2024)

Comparando esses resultados com os obtidos por Morais (2024), apresentados na Fig. 25, nota-se que, de forma geral, o comportamento modal permanece compatível, mesmo com algumas diferenças ao comparar as frequências naturais obtidas. Nesse contexto, Morais (2024) trouxe formas modais consistentes a partir de medições físicas enquanto os resultados deste trabalho indicam que os sensores virtuais foram capazes de reproduzir essas tendências modais, reforçando que a abordagem proposta mantém compatibilidade e coerência com as metodologias de caracterização modal tradicionais.

4.2.3 Correspondência Modal pelo Critério de Garantia Modal


Após a identificação das frequências naturais e das taxas de amortecimento, a análise foi complementada pelo Critério de Garantia Modal (MAC), visando avaliar a semelhança entre as formas modais obtidas dos sinais reais e estimados pela rede LSTM, permitindo assim, verificar se a rede preservou as formas modais ao longo da viga além dos valores de frequência normal e taxa de amortecimento. Dessa forma, os resultados de MAC apresentados nas Fig. 26 a 29 apontam uma medida da correlação entre os modos reais e virtuais, onde valores mais próximos de 1 são indicativos de elevada correspondência modal.

Figura 26: Matriz MAC pelo método SSI em 5 m/s




Fonte: Próprio Autor (2026)

Figura 27: Matriz MAC pelo método SSI em 10 m/s




Fonte: Próprio Autor (2026)

Figura 28: Matriz MAC pelo método FDD em 5 m/s



Fonte: Próprio Autor (2026)

Figura 29: Matriz MAC pelo método FDD em 10 m/s



Fonte: Próprio Autor (2026)

Os resultados da correspondência modal pelo MAC apresentados nas Figuras 26 a 29 indicam elevada correspondência entre as formas modais reais e virtuais, visto que os valores da diagonal principal, de todas as matrizes, foram iguais a 1,00 ou aproximadamente 1,00. No SSI, os valores fora da diagonal permaneceram baixos, variando aproximadamente entre 0,11 e 0,16, enquanto no FDD ficaram entre 0,12 e 0,15, indicando baixa correlação entre modos

diferentes, o que é desejável, pois mostra que a rede não misturou, de forma relevante, as características de um modo com outro.


Assim, os resultados de MAC confirmam que os sensores virtuais foram capazes de representar adequadamente as características modais principais da viga, sustentando a validade dos sinais previstos para a análise dinâmica da estrutura.

4.3 COMPARATIVO COM TRABALHOS ANTERIORES

A comparação dos resultados obtidos neste trabalho com os estudos de Moraes (2024) e Rodrigues (2023) evidencia avanços na utilização de sensores virtuais aplicados à análise modal operacional de estruturas. Por um lado, Moraes (2024) realizou a caracterização modal de uma viga engastada-livre por meio de técnicas de Análise Modal Operacional utilizando apenas sinais provenientes de sensores físicos, enquanto que o presente trabalho apresenta a capacidade de preservação de características modais por sinais reconstruídos por uma rede LSTM.

Por sua vez, Rodrigues (2023), ao aplicar sensores virtuais baseados em redes neurais convencionais, obteve limitações na correspondência entre as formas modais, determinadas por diferentes abordagens de análise modal, sendo observados valores de MAC inferiores a 0,40 ao comparar EMA e OMA.

Figura 30. Comparativo com trabalhos anteriores



Fonte: Rodrigues (2023)^(a), Moraes (2024)^(b), Próprio Autor (2026)^(c)

A Figura 30 traz um comparativo entre os resultados dos trabalhos de Rodrigues (2023), Moraes (2024) e os obtidos pelo presente trabalho. Com essa comparação, observa-se que a técnica OMA associada a sensores virtuais, empregada neste estudo, foi capaz de trazer a robustez dos métodos tradicionais de análise modal baseados em sinais físicos, desenvolvidos por Moraes (2024), ao mesmo tempo que superou a baixa correspondência modal indicada por Rodrigues (2023) ao utilizar sensores virtuais.

5 CONCLUSÃO

Este trabalho avaliou a aplicação de redes LSTM como sensores virtuais para a previsão de sinais vibracionais em uma viga engastada-livre submetida a diferentes velocidades de escoamento. A partir da comparação entre as três configurações propostas, a configuração C2 foi selecionada como a mais adequada, por apresentar os menores valores médios de MAE e RMSE, tanto na velocidade de 5 m/s quanto de 10 m/s. Esse resultado indicou que a ampliação da janela temporal teve maior impacto no desempenho da rede do que o aumento do número de neurônios e taxa de *dropout*.

A análise modal dos sinais previstos demonstrou que a rede LSTM foi capaz de preservar as principais características dinâmicas da estrutura. Os métodos SSI e FDD identificaram os três primeiros modos com baixos erros relativos entre os sinais reais e virtuais, enquanto que as taxas de amortecimento também apresentaram comportamento similar entre os dois conjuntos de sinais, inclusive nos casos em que os valores foram aproximadamente nulos.

Os resultados obtidos pelo Critério de Garantia Modal reforçaram essa validação ao indicar elevada correspondência entre as formas modais reais e virtuais, com valores próximos a 1,00 na diagonal principal. Além disso, os baixos valores fora da diagonal também mostraram que a rede não misturou de forma relevante as características de modos distintos.

Por fim, conclui-se que os sensores virtuais baseados em arquiteturas LSTM apresentaram desempenho satisfatório para reconstruir sinais vibracionais e ainda manter as principais propriedades modais da viga estudada. Ademais, os resultados indicam que a abordagem proposta possui forte potencial para aplicações em Análise Modal Operacional, principalmente em situações onde se deseja reduzir a dependência de sensores físicos sem comprometer a caracterização dinâmica da estrutura.

5.1 SUGESTÕES DE TRABALHOS FUTUROS

Diante do exposto e dos resultados satisfatórios obtidos, algumas limitações ainda podem ser exploradas em trabalhos futuros. Recomenda-se que estudos posteriores considerem:

- Aplicar a presente metodologia em condições mais próximas de cenários reais, como variação de massa, rigidez ou presença de dano.
- Investigar a influência da quantidade e da posição dos sensores físicos como entrada do sensor virtual, buscando avaliar se a instrumentação pode ser reduzida sem prejudicar a qualidade dos sinais previstos.

- Ampliar a análise para outras velocidades de escoamento e diferentes condições operacionais, a fim de verificar a capacidade de generalização da rede LSTM.

REFERÊNCIAS BIBLIOGRÁFICAS

- AEROALCOOL. **AA-TVSH1 (H1c): túnel de vento subsônico**: Aeroalcool. Disponível em: <https://www.aeroalcool.com.br/index.php/tuneis-de-vento/25-gallery/tuneis-de-vento/29-aa-tvsh1>. Acesso em: 22 jun. 2026.
- ALFRED, Rayner; FAID, Shahdatul Syahirah binti; PAILUS, Rayner; CHEKIMA, Khalifa; SANI, Zaidatul Haslinda Abdullah; LIM, Yuto. **Hyperparameter-tuned LSTM for high-performance Malay sentiment classification**. In: IEEE INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE IN ENGINEERING AND TECHNOLOGY (IICAIET), 2025. IEEE, 2025. DOI: 10.1109/IICAIET67254.2025.11264942.
- ALVES, Victor Higino Meneguitte; ALVES, Vinicius Antônio Meneguitte; CURY, Alexandre Abrahão. **Monitoramento de integridade estrutural utilizando inteligência artificial: desafios, avanços e aplicações**. Revista da UFMG, Belo Horizonte, v. 30, e047533, 2023. DOI: 10.35699/2965-6931.2023.47533.
- BRÜEL & KJÆR. **Product data: piezoelectric accelerometer: miniature DeltaTron accelerometers, types 4516 and 4516-001**. Nærum: Brüel & Kjær, 2004. Disponível em: <https://www.bksv.com/media/doc/Bp2067.pdf>. Acesso em: 17 jun. 2026.
- CHAUDHARY, Aniket; NALLASIVAM, K. **Modal analysis of a coupled ballastless railway track surrounding a horse shoe shape shield tunnel linked to a box-girder bridge with substructure using finite element method**. Innovative Infrastructure Solutions, v. 9, artigo 211, 2024. DOI: 10.1007/s41062-024-01519-0.
- CHOLLET, François. **Deep learning with Python**. Shelter Island: Manning Publications, 2018. ISBN 9781617294433.
- CONTARINI, Gabriel. **Redes neurais LSTM e modelo GARCH: uma abordagem conjunta para previsão de retornos**. 2020. Monografia (Bacharelado em Ciências Econômicas) – Instituto de Economia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2020.
- DAS, Swagato; SAHA, P.; PATRO, S. K. **Vibration-based damage detection techniques used for health monitoring of structures: a review**. Journal of Civil Structural Health Monitoring, v. 6, p. 477-507, 2016. DOI: 10.1007/s13349-016-0168-5.
- FARRAR, Charles R.; WORDEN, Keith. **An introduction to structural health monitoring**. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, v. 365, n. 1851, p. 303-315, 2007. DOI: 10.1098/rsta.2006.1928.
- FIGUEIREDO, F. B. *et al.* **Análise Computacional dos Modos e Frequências de Vibração de uma Viga Engastada-livre**. Colloquium Exactarum, v. 6, n. 1, 144 – 127, DOI: 10.5747/ce.2014.v06.n1.e072.
- FREITAS, Vinicius José Macedo de. **Aplicação de sensoriamento virtual data-driven para a predição da vazão de sistema de bombeio**. 2023. Trabalho de Conclusão de Curso (Bacharelado

- em Engenharia Química) – Universidade Federal da Bahia, Salvador, 2023.
- IBRAHIM, Mahmoud *et al.* **Digital twin as a virtual sensor for wind turbine applications**. *Energies*, v. 16, n. 17, artigo 6246, 2023. DOI: 10.3390/en16176246.
- KERVANCI, I. Sibel; AKAY, M. Fatih. **LSTM hyperparameters optimization with Hparam parameters for Bitcoin price prediction**. *Sakarya University Journal of Computer and Information Sciences*, v. 6, n. 1, p. 1-9, 2023. DOI: 10.35377/saucis.1172027.
- LEE, Gyeongju; LEE, Jin Woo. **Artificial neural network model to extract modal participation factors for damage localization in beam-like structures**. *Journal of Mechanical Science and Technology*, v. 39, n. 3, p. 1299-1311, 2025. DOI: 10.1007/s12206-025-0225-2.
- LEME, Leandro Marinho Marques. **Estudo comparativo de técnicas de análise modal experimental no domínio da frequência em uma barra na condição de contorno livre-livre**. 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2014.
- LI, Miao; HUANG, Tianli. **Structural damage detection based on quadratic correlation function of strain responses**. *Latin American Journal of Solids and Structures*, v. 21, n. 1, e528, 2024. DOI: 10.1590/1679-78257359
- MAGALHÃES, F.; CUNHA, A.; CAETANO, E. **Vibration-based structural health monitoring of an arch bridge: from automated OMA to damage detection**. *Mechanical Systems and Signal Processing*, v. 28, p. 212-228, 2012. DOI: 10.1016/j.ymssp.2011.06.011.
- MARTINS, Daniel Walter de Paula. **Inteligência artificial aplicada em séries temporais**. 2024. Dissertação (Mestrado em Estatística), Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2024.
- MELO, Renato da Silva *et al.* **Monitoramento da integridade estrutural de vias férreas a partir de medições de vibração a bordo utilizando técnicas de aprendizado profundo**. *Vetor: Revista de Ciências Exatas e Engenharias*, Rio Grande, v. 36, n. 1, e18345, 2026. DOI: 10.63595/vetor.v36i1.18345.
- MORAIS, Pedro Henrique Debs de. **Análise modal de um modelo simplificado de torre de turbina eólica em escala reduzida**. 2024. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia, 2024.
- MOUSAVI, Zohreh *et al.* **Enhanced vibration-based damage detection for monopile offshore structures considering soil interaction based on VMD and deep CNN-LSTM**. *Applied Ocean Research*, v. 165, artigo 104856, 2025. DOI: 10.1016/j.apor.2025.104856.
- OLIVEIRA, Emerson Vilar. **Análise de desempenho de método baseado em rede LSTM para classificação de falhas em um processo de controle de nível**. 2020. Dissertação (Mestrado em Engenharia Elétrica e de Computação) – Univ. Federal do Rio Grande do Norte, Natal, 2020.
- PCB PIEZOTRONICS. **Accelerometer: model 352C23**. PCB Piezotronics. Disponível em: <https://www.pcb.com/products?m=352c23>. Acesso em: 17 jun. 2026.

- POUDEL, U. P.; FU, G.; YE, J. **Structural damage detection using digital video imaging technique and wavelet transformation**. Journal of Sound and Vibration, v. 286, p. 869-895, 2005. DOI: 10.1016/j.jsv.2004.10.043.
- RAO, Singiresu. **Vibrações Mecânicas**. 4. ed. São Paulo: Pearson Prentice Hall, 2008. ISBN 9788576052005.
- REYNDERS, Edwin. **System identification methods for (operational) modal analysis: review and comparison**. Archives of Computational Methods in Engineering, v. 19, p. 51-124, 2012. DOI: 10.1007/s11831-012-9069-x.
- RODRIGUES, Pedro Augusto Dias. **Utilização de inteligência artificial para análise modal de uma viga engastada sob escoamento em túnel de vento**. 2023. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia, 2023.
- ROMEIRO, Phelipe Pachler Maia. **Aplicação de redes neurais recorrentes na previsão de demanda de materiais: comparação entre modelos de aprendizado profundo**. 2025. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Controle e Automação) – Instituto de Ciência e Tecnologia, Universidade Estadual Paulista (UNESP), Sorocaba, 2025.
- SALEHI, Mohammadreza. **Modal identification and finite element model updating of railway bridges considering boundary conditions using artificial neural networks**. 2021. Dissertação (Mestrado em Structural Engineering and Building Technology) – Department of Civil Engineering and Energy Technology, Oslo Metropolitan University, Oslo, 2021.
- SHAMSADDINLOU, Amir; NIKOOFARAZ, Mehrab; DE DOMENICO, Dario; LONGO, Monica. **Computationally efficient Python based operational modal analysis of structures: Modalyzer**. Journal of Vibration and Control, 2026. DOI: 10.1177/10775463251410790.
- SINGH, Lokendra; GUPTA, Arpan. **Estimation of natural frequency of cantilever beam using Harris corner detection technique**. In: INTERNATIONAL CONFERENCE FOR ADVANCEMENT IN TECHNOLOGY (ICONAT), 2023, Goa, India. IEEE, 2023. p. 1-6. DOI: 10.1109/ICONAT57137.2023.10080841.
- SIRQUEIRA, Alan da Silva. **Comportamento estrutural de torres de aço para suporte de turbinas eólicas**. 2008. Dissertação (Mestrado em Engenharia Civil) – Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2008
- VALENTE, João Pedro B.; SIQUEIRA, Gustavo H.; SOUSA, José Luiz Antunes de Oliveira. **Implementação em linguagem MATLAB de uma técnica de análise modal operacional de estruturas**. In: XXIV CONGRESSO DE INICIAÇÃO CIENTÍFICA DA UNICAMP, 2016, Campinas. DOI: 10.19146/pibic-2016-51680.
- VIEIRA, Bruno Zanelli; FRANCO, Vitor Ramos; MORAES, Anderson Antonio Ubices de; MALAVOLTA, Alexandre Tácito. **Investigação de danos em uma viga engastada utilizando a técnica SHM baseada em vibrações e modelo de elementos finitos**. In: CONGRESSO

NACIONAL DE ESTUDANTES DE ENGENHARIA MECÂNICA, 30., 2024, Uberaba, MG.
ZOU, Yi; CHAKRABARTY, Krishnendu. **Sensor deployment and target localization based on virtual forces**. In: IEEE INFOCOM 2003: TWENTY SECOND ANNUAL JOINT CONFERENCE OF THE IEEE COMPUTER AND COMMUNICATIONS SOCIETIES, 22., 2003, San Francisco, CA, USA. IEEE, 2003. v. 2, p. 1293-1303. DOI: 10.1109/INFCOM.2003.1208965.