

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
PROGRAMA DE PÓS GRADUAÇÃO EM MODELAGEM COMPUTACIONAL

Rafaelle Piazzaroli Finotti Amaral

**Aplicação de métodos computacionais a dados vibracionais para detecção de alterações
estruturais**

Juiz de Fora
2017

Rafaelle Piazzaroli Finotti Amaral

**Aplicação de métodos computacionais a dados vibracionais para detecção de
alterações estruturais**

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional, da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do grau de Mestre em Modelagem Computacional.

Orientador: Prof. D.Sc. Flávio de Souza Barbosa

Coorientador: Prof. Dr. Eng. Civil Alexandre Abraão
Cury

Juiz de Fora

2017

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Amaral, Rafaelle Piazzaroli Finotti.

Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais / Rafaelle Piazzaroli Finotti Amaral. -- 2017.

68 f.

Orientador: Flávio de Souza Barbosa

Coorientador: Alexandre Abrahão Cury

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, ICE/Engenharia. Programa de Pós-Graduação em Modelagem Computacional, 2017.

1. Dinâmica das estruturas. 2. Detecção de danos. 3. Inteligência computacional. I. Barbosa, Flávio de Souza, orient. II. Cury, Alexandre Abrahão, coorient. III. Título.

Rafaelle Piazzaroli Finotti Amaral

Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional, da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do grau de Mestre em Modelagem Computacional.

Aprovada em 7 de Março de 2017.


BANCA EXAMINADORA



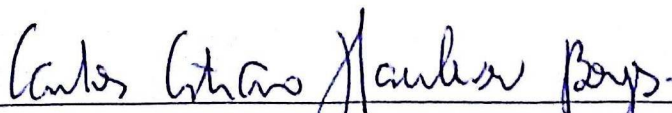
Prof. D.Sc. Flávio de Souza Barbosa - Orientador
Universidade Federal de Juiz de Fora



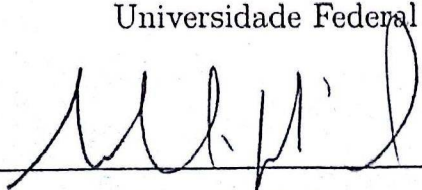
Prof. Dr. Eng. Civil Alexandre Abrahão Cury - Coorientador
Universidade Federal de Juiz de Fora



Prof. D.Sc. Leonardo Goliatt da Fonseca
Universidade Federal de Juiz de Fora



Prof. D.Sc. Carlos Cristiano Hasenclever Borges
Universidade Federal de Juiz de Fora



Prof. Ph.D Roberto Leal Pimentel
Universidade Federal da Paraíba

Dedicado aos meus pais.

AGRADECIMENTOS

Dedico meus agradecimentos:

- Primeiramente a Deus, por guiar meu caminho e permitir concluir mais essa etapa;
- Ao meu querido orientador Flávio Barbosa pelo incentivo, confiança, ensinamentos e amizade;
- Ao meu coorientador Alexandre Cury pela atenção e colaboração no trabalho;
- A todos os professores e funcionários do Programa de Pós-Graduação em Modelagem Computacional;
- Ao professor Roberto Pimentel pela colaboração, recepção e ajuda durante o período que passei na UFPB;
- Aos amigos que fiz no mestrado, em especial ao Aldemon, por toda ajuda, motivação e companhia;
- Aos meus amados pais que me incentivam e apoiam desde sempre;
- Aos meus irmãos, em especial ao Renan, pelo afeto, amizade e ajuda nas mais variadas situações;
- Ao meu namorado Bruno pelo companherismo, paciência e ajuda em todos os momentos;
- À Capes pelo suporte financeiro.

RESUMO

O desafio de se detectar danos e/ou alterações estruturais através de dados vibracionais tem levado ao desenvolvimento de diversas técnicas nas últimas décadas. Grande parte desses métodos busca associar variações de frequências naturais, modos de vibração e taxas de amortecimento em uma estrutura ao surgimento de danos localizados. Em vista disso, surgiram métodos como: o índice MAC (*Modal Assurance Criterion*), métodos baseados em energia de deformação, métodos baseados em variação de curvatura, análise da matriz de flexibilidade, dentre outros. Apesar de se mostrarem bastante eficazes na detecção de danos em modelos numéricos, salvo em raras exceções, os métodos supracitados apresentam dificuldades quando se trata de problemas práticos com dados obtidos de experimentos reais. Entretanto, abordagens envolvendo técnicas de inteligência computacional vêm sendo apontadas como uma linha de pesquisa promissora nesta área. Dessa forma, o presente trabalho avalia o uso das Redes Neurais Artificiais (ANN - *Artificial Neural Networks*) e Máquinas de Vetor Suporte (SVM - *Support Vector Machines*) na detecção de alterações estruturais baseadas na análise da evolução das respostas dinâmicas. Tanto as características modais quanto indicadores estatísticos extraídos diretamente dos sinais temporais são utilizados como parâmetros de entrada dos modelos de inteligência computacional. Além disso, apresenta-se ainda uma nova metodologia desenvolvida com base no histórico de variação das frequências naturais e temperatura, na qual é possível detectar mudanças no comportamento estrutural e apontar o momento em que elas ocorrem a partir de um classificador SVM. A eficiência da metodologia proposta é analisada através de dados obtidos em um modelo numérico de viga biapoiada e dados oriundos de um monitoramento contínuo da Torre de Gabbia, na Itália.

Palavras-chave: Dinâmica das estruturas. Detecção de danos. Inteligência computacional.

ABSTRACT

Structural damage detection using dynamic measurements has led to the development of several techniques in the last decades. Most of these methods associate variations of natural frequencies, mode shapes and damping ratios to damage, like the Modal Assurance Criterion (MAC), methods based on strain energy deviation, methods based on curvature mode shapes, flexibility matrix analysis, among others. Although these aforementioned techniques are mostly efficient to identify structural alterations in numerical models, they have difficulties in practical applications with experimental data. Thus, approaches involving computational intelligence to identify structural damage can be a promising field of research. This work evaluates the Artificial Neural Networks (ANN) and Support Vector Machine (SVM) to detect structural changes based on evolution of dynamic responses. The modal characteristics and statistical indicators extracted directly from raw dynamic measurements are used as inputs to computational intelligence models. Furthermore, a new methodology based on the time history of natural frequencies and temperature records is presented. The technique consists in detecting structural changes and when they occur by using a SVM algorithm. The efficiency of the proposed methodology is analyzed through data from a numerical model of a supported beam and from a continuous monitoring of the Gabbia Tower, in Italy.

Keywords: Dynamic of structures. Damage detection. Computational intelligence.

SUMÁRIO

1	INTRODUÇÃO.....	9
1.1	Contexto e motivação	9
1.2	Objetivos	14
1.3	Organização do texto	15
2	MÉTODOS PARA DETECÇÃO DE DANOS E ALTERAÇÕES ESTRUTURAIS.....	16
2.1	Métodos baseados em parâmetros modais	16
2.2	Métodos baseados em inteligência computacional	18
2.2.1	<i>Determinação dos parâmetros de entrada para modelos de inteligência computacional.....</i>	20
2.2.2	<i>Algoritmos para classificação.....</i>	22
2.2.2.1	<i>Rede Neural Artificial (ANN - Artificial Neural Network).....</i>	22
2.2.2.2	<i>Máquina de Vetor Suporte (SVM - Support Vector Machine).....</i>	25
2.2.2.3	<i>Método de validação cruzada k-fold.....</i>	28
3	APLICAÇÕES.....	30
3.1	Viga biapoiada - Modelo numérico	30
3.2	Laje de concreto - Aplicação com dados experimentais	36
3.3	Ponte PK 075+317 - Aplicação com dados experimentais	41
4	NOVA ESTRATÉGIA PARA DETECÇÃO DE ALTERAÇÕES ESTRUTURAIS.....	45
4.1	Metodologia	45
4.2	Resultados	48
4.2.1	<i>Viga biapoiada - Modelo numérico.....</i>	48
4.2.2	<i>Torre de Gabbia - Aplicação com dados experimentais.....</i>	54
5	CONCLUSÕES E TRABALHOS FUTUROS.....	59
	REFERÊNCIAS	62

1 INTRODUÇÃO

1.1 Contexto e motivação

Estruturas de engenharia estão constantemente sujeitas a mudanças em suas propriedades mecânicas devidas aos mais variados fatores, como falhas durante a concepção e execução do projeto, esforços de trabalho para os quais não foram projetadas, processos naturais de deterioração pelo tempo de uso, efeitos operacionais e ambientais ou, até mesmo, procedimentos de reforço estrutural. Levando isto em consideração, o monitoramento contínuo do comportamento mecânico de uma estrutura permite investigar e avaliar alterações a fim de se assegurar sua integridade, garantindo maior conforto e segurança aos usuários e reduzindo custos de manutenção.

O monitoramento da integridade estrutural, conhecido também pela sigla SHM (que vem do inglês *Structural Health Monitoring*), compreende um conjunto de métodos e equipamentos utilizados para a investigação da “saúde” das estruturas. Sabendo-se que as modificações nas propriedades mecânicas podem estar relacionadas ao surgimento de danos, os sistemas SHM tem como um dos objetivos principais o desenvolvimento de técnicas confiáveis e robustas capazes de detectar e avaliar danos e alterações estruturais.

A vantagem de se utilizar sistemas SHM é a possibilidade da detecção do dano ainda em estágio inicial. Em vista disso, a análise da segurança estrutural permite estabelecer condições adequadas de funcionamento ou, em casos extremos, evitar falhas catastróficas. Um exemplo relacionado à segurança e que poderia ter sido evitado ou minimizado através do uso de um programa de monitoramento adequado e confiável, é o caso do rompimento da barragem de rejeitos de minério de ferro, em Mariana, Minas Gerais (Figura 1.1). Considerado o maior desastre socioambiental do Brasil, a lama de rejeitos foi responsável pela morte de pessoas, pela contaminação dos rios da região e pela destruição de florestas e vilarejos inteiros. Cabe ressaltar que sistemas SHM unicamente não são suficientes para evitar acidentes desse porte, porém técnicas apropriadas podem alertar o operador da estrutura para que ele possa providenciar vistorias “*in loco*” e reparos, caso necessários. Desta forma, a identificação de comportamentos estruturais “anormais” tem sido um tema relevante em pesquisas de engenharia, ganhando crescente atenção ao longo dos anos.



Figura 1.1: Barragem rompida em Mariana [1].

Atualmente, programas de monitoramento contínuo têm sido mais utilizados em estruturas de grande vulto. A ponte Rio-Niterói, no Brasil [2], a ponte Tsing Ma, na China [3] e, o viaduto de Millau [4], na França, mostrados na Figura 1.2, são alguns exemplos. Um dos principais motivos da instalação de sistemas SHM são os processos de envelhecimento e degradação natural. Pode-se destacar ainda, a evolução tecnológica dos materiais empregados, que tem permitido a construção de estruturas cada vez mais esbeltas e flexíveis, e conseqüentemente, mais suscetíveis a vibrações excessivas causadas por efeitos ambientais e/ou operacionais (vento, tráfego intenso, abalos sísmicos, etc). Assim, a preocupação com o desempenho e confiabilidade de estruturas tem se mostrado cada vez maior em todo o mundo. Esses fatores contribuem para o aumento do interesse de pesquisa na área e mostram a importância do desenvolvimento e aperfeiçoamento de técnicas capazes de detectar e avaliar alterações e danos estruturais.

As técnicas de inspeção estrutural podem ser divididas em duas classes: técnicas destrutivas e técnicas não-destrutivas. Essa divisão leva em consideração se o método de monitoramento empregado danifica ou não a estrutura em questão. Normalmente, as técnicas não-destrutivas são mais empregadas que as destrutivas, dentre as quais pode-se citar os ensaios de emissão acústica, ultrassom, termografia, testes estáticos e dinâmicos [8, 9].

Por possuir diversas aplicações práticas, a análise estrutural que faz uso de dados



(a)



(b)



(c)

Figura 1.2: Exemplos de aplicações de sistemas de monitoramento contínuo. (a) Ponte Rio-Niterói [5]; (b) Ponte Tsing Ma [6]; (c) Viaduto de Millau [7].

vibracionais, tem sido bastante discutida, como em Alvandi & Cremona (2006)[10], Fan & Qiao (2011)[11] e Shih et al. (2013)[12].

De uma forma geral, as metodologias para detecção de danos através de dados vibracionais são desenvolvidas com base nos parâmetros modais ou utilizando diretamente as respostas dinâmicas da estrutura [11, 13, 14]. A ideia fundamental é que o processo de degradação muda as propriedades físicas da estrutura, tais como massa e rigidez.

Essas propriedades afetam diretamente o comportamento dinâmico estrutural, levando a modificações nas frequências naturais, modos de vibração e taxas de amortecimento.

Quando se trata de métodos baseados nas características modais, a sua natureza global é uma importante vantagem, uma vez que o dano pode ser detectado sem ser necessária a avaliação de pontos próximos à região danificada. Assim, vários métodos surgiram em vista dessa abordagem: o índice MAC (Modal Assurance Criterion), que mede a correlação entre dois modos de vibração, danificado e não danificado [15]; SEM (Strain Energy Method) que detecta e localiza o dano baseado na análise da energia de deformação antes e após a sua ocorrência [16]; indicador baseado na diferença de curvatura dos modos da estrutura danificada e não danificada, no qual associa-se a mudança da rigidez à flexão com a alteração da curvatura após o dano ter ocorrido [17]; análise da matriz de flexibilidade, em que a presença de dano é relacionada à redução de rigidez da estrutura e ao consequente aumento da flexibilidade [18]; entre outros. No entanto, existem métodos baseados em parâmetros modais (ou deles derivados) que não requerem informação sobre o estado íntegro da estrutura. Nestes casos, algumas considerações são feitas sobre tais parâmetros da estrutura íntegra a partir de medições realizadas na estrutura com dano.

Apesar de os métodos citados acima se mostrarem eficientes em modelos numéricos, eles apresentam algumas limitações quando aplicados a dados provenientes de ensaios experimentais. Muitos deles possuem problemas de sensibilidade ou não são eficientes em detectar falsos alarmes [10]. Assim, medições mais precisas e com um baixo nível de ruído tem que ser alcançadas, uma vez que os danos de pequena magnitude/extensão não provocam uma variação expressiva nos parâmetros modais. Além disso, o processo de identificação modal pode afetar consideravelmente os resultados dos métodos de detecção, pois pode ocasionar uma perda de informação se comparado aos sinais brutos, mascarando a presença de danos e introduzindo incertezas adicionais relacionadas aos dados.

Mais recentemente, técnicas focadas na análise direta dos sinais vem sendo discutidas, como pode ser visto em Alves (2016)[19]. Conhecidos como métodos baseados em indicadores de anormalidade, essas técnicas utilizam abordagens baseadas na análise estatística de sinais e reconhecimento de padrões [20, 21, 22, 23]. Uma das principais vantagens de se utilizar esses métodos é a possibilidade de trabalhar diretamente com as medidas dinâmicas no domínio do tempo, evitando-se a perda de informação ao longo do processamento dos dados. Mesmo sendo mais difíceis de se interpretar, os sinais dinâmicos

são capazes de fornecer uma boa ideia sobre o estado estrutural. Porém, o gerenciamento de grandes quantidades de dados podem tornar o processo de análise uma árdua tarefa. Em vista disso, evidencia-se a necessidade do desenvolvimento de ferramentas mais robustas para a solução desse tipo de problema. Por este motivo, muitas estratégias têm sido propostas utilizando, por exemplo, Estatística de Ordem Superior (HOS - *Higher-Order Statistics*) e inteligência computacional, como Redes Neurais Artificiais (ANN - *Artificial Neural Networks*) e Máquinas de Vetores Suporte (SVM - *Support Vector Machines*, entre outras metodologias [22, 24, 25, 26]. A HOS permite distinguir bases de dados aparentemente semelhantes, obtendo-se uma caracterização estatística mais completa a partir de cumulantes estatísticos de ordem maior que dois [26]; e os métodos de inteligência computacional têm por objetivo reconhecer as observações semelhantes encontradas em um mesmo grupo de dados e separá-las em grupos de características em comum.

Uma consideração importante é a influência de efeitos ambientais (variação térmica, umidade e vento) sobre o comportamento das estruturas. Muitos estudos relatam a influência da temperatura sobre as frequências naturais [20, 27, 28]. Neste caso, as modificações nas características dinâmicas podem ser confundidas e atribuídas aos danos, já que ambos podem provocar variações estruturais muito semelhantes. Portanto, as medições de temperatura devem ser levadas em conta no desenvolvimento dos métodos de detecção para que falsos alarmes sejam evitados, especialmente ao empregar estratégias baseadas nas frequências. Dessa forma, procedimentos de correção são propostos na literatura a fim de minimizar/eliminar o efeito das variações térmicas sobre os parâmetros modais [29, 30].

De acordo com Ritter [31], os métodos de detecção compreendem quatro níveis: Nível #1 - determinar se ocorre dano na estrutura; Nível #2 - identificar a localização geométrica do dano; Nível #3 - quantificar a gravidade do dano; Nível #4 - prever a vida útil restante da estrutura. Geralmente, os níveis de #1 a #4 podem ser alcançados em trabalhos baseados em simulações numéricas. No entanto, ao lidar com sinais advindos de um sistema dinâmico real, é difícil determinar a ocorrência do dano a partir apenas de dados modais, como já explicitado anteriormente nesta seção. Portanto, métodos robustos capazes de atingir o nível #1 ainda precisam ser explorados. Uma vez que a alteração estrutural seja corretamente detectada (nível #1), investigações mais detalhadas podem

ser providenciadas a fim de verificar e localizar a gravidade do dano, vislumbrando-se atingir os níveis de #2 a #4 na classificação de Ritter.

Algumas referências na literatura classificam os métodos de detecção segundo o comportamento linear ou não-linear da estrutura. Os métodos do primeiro grupo consideram que a estrutura permanece no domínio elástico linear após a ocorrência do dano. Todos os métodos baseados na avaliação de formas modais, matriz de flexibilidade, frequências naturais, entre outros, enquadram-se neste grupo, já que as mudanças nas características modais são resultados de uma redução local na rigidez ou uma mudança na geometria e/ou nas propriedades materiais da estrutura, geralmente decorrentes de danos em estágio inicial [13]. No segundo caso, considera-se que o comportamento da estrutura apresenta característica não-linear após a ocorrência de danos mais graves, tais como fissuras por fadiga ou deformação excessiva, plastificação de elementos por efeito de choques, entre outros.

Neste contexto, esta dissertação se concentra principalmente no primeiro nível da escala de Ritter, ou seja, na detecção de alterações estruturais em si, através da avaliação de técnicas, consideradas lineares, desenvolvidas com base em modelos computacionais de identificação de danos a partir da resposta dinâmica do sistema.

1.2 Objetivos

O presente trabalho tem por objetivo avaliar o uso de diferentes dados de entrada em conjunto com métodos computacionais, mais especificamente Redes Neurais Artificiais e Máquinas de Vetores Suporte, para a detecção de alterações estruturais a partir do desenvolvimento de modelos de predição baseados na análise das respostas dinâmicas. Tanto os parâmetros modais quanto indicadores estatísticos (HOS, entre outros) extraídos diretamente dos sinais medidos são utilizadas como variáveis de entrada para as técnicas de inteligência computacional. Os resultados fornecidos por cada tipo de dado e técnica são analisados e comparados através de dados provenientes de modelos estruturais numéricos e de ensaios experimentais.

Adicionalmente, apresenta-se ainda uma nova estratégia para detecção de comportamentos estruturais “anormais” baseada em modificações da frequência natural. Para uma dada estrutura monitorada em tempo integral, a evolução das frequências e

as temperaturas são utilizadas como dados de entrada para um algoritmo baseado em SVM. A estratégia consiste em detectar mudanças estruturais e o momento em que elas ocorrem, com base no histórico do comportamento dinâmico da estrutura. A metodologia proposta é validada através de simulações numéricas realizadas em um modelo de uma viga bi-apoiada. Em uma segunda aplicação desta nova estratégia, utilizou-se os dados de monitoramento contínuo da Torre de Gabbia, na Itália, submetida a um abalo sísmico. A partir do registro do seu comportamento dinâmico antes e depois do terremoto, verifica-se que a estratégia proposta é capaz de precisar a data em que ocorreu o tremor de terra.

1.3 Organização do texto

O presente capítulo apresenta o tema abordado, sua importância e motivação. Além disso, apontam-se ainda os objetivos pretendidos neste trabalho.

Uma breve revisão dos métodos de detecção de alterações e danos estruturais é realizada no capítulo 2. Neste contexto, as teoria de Redes Neurais Artificiais e Máquinas de Vetor Suporte são também introduzidas, abordando-se os fundamentos e conceitos utilizados na concepção dos algoritmos.

O terceiro capítulo avalia e compara os métodos de inteligência computacional, bem como os diferentes parâmetros de entrada, a partir de aplicações numéricas e experimentais.

Uma nova metodologia de detecção de alterações estruturais é apresentada no capítulo 4. Com o objetivo de validar a metodologia proposta, sua aplicação é estudada através de dados obtidos de um monitoramento real e um simulado.

Por fim, no quinto capítulo são expostas as conclusões e considerações finais, além de sugestões para pesquisas futuras.

2 MÉTODOS PARA DETECÇÃO DE DANOS E ALTERAÇÕES ESTRUTURAIS

2.1 Métodos baseados em parâmetros modais

Uma das metodologias mais empregadas na avaliação de alterações estruturais são aquelas desenvolvidas com base nos parâmetros modais, uma vez que a resposta dinâmica estrutural tem relação com suas propriedades mecânicas. A ideia básica é que o dano altera as propriedades físicas da estrutura, como massa, rigidez ou flexibilidade, afetando suas frequências naturais, modos de vibração e taxas de amortecimento. Dessa forma, a modificação desses parâmetros pode indicar a existência de danos no sistema estrutural. Assim, métodos baseados na alteração das características modais e em indicadores construídos a partir desses parâmetros têm sido desenvolvidos, conforme brevemente descrito nos parágrafos que seguem.

Os primeiros trabalhos realizados em vista dessa abordagem são baseados na variação direta das propriedades modais. Em geral, as frequências naturais são características sensíveis da integridade de uma estrutura e tendem a tornar-se ligeiramente menores na presença de danos. Fato que parece ser intuitivo, já que o dano conduz à perda de rigidez estrutural. Por se tratar de uma medida global da estrutura, e que pode ser obtida a partir de apenas alguns pontos, o uso das variações nas frequências naturais é bastante atrativo no problema de identificação de alterações estruturais. Cawley & Adams (1979)[32] foram um dos pioneiros na avaliação da integridade de estruturas utilizando a variação das frequências como indicativo de dano. Desde então, muitas técnicas e melhorias foram propostas ao longo dos anos. No trabalho de Fox (1992)[33], resultados numéricos e experimentais de uma viga fissurada mostraram a sensibilidade das frequências naturais como indicadores de danos. Messina et al. (1998)[34] desenvolveram um coeficiente de correlação chamado de MDLAC (*Multiple Damage Location Assurance Criterion*), capaz de detectar e quantificar danos. Este coeficiente é baseado na sensibilidade da frequência

aos danos e em uma correlação estatística entre as previsões de suas alterações e os valores realmente medidos. Pimentel et al. (2015)[35] avaliaram lajes de concreto pré-moldadas com e sem fissuras, e observaram uma variação de padrão distinta nas frequências naturais entre as duas situações.

Encontram-se também na literatura trabalhos focados no desenvolvimento de técnicas baseadas em mudanças dos modos de vibração. Um método clássico é o índice MAC (*Modal Assurance Criterion*), proposto por Allemang & Brown (1982)[36], que calcula a correlação entre modos danificados e não-danificados. O coeficiente MAC varia entre 0 e 1, onde 0 representa a inexistência de correlação entre os modos e 1 uma correlação perfeita. Um outro índice derivado do MAC foi apresentado por Lieven & Ewins (1988)[37], o COMAC (*Coordinate Modal Assurance Criterion*), que mede a correlação dos modos para cada grau de liberdade. Um grande desvio de 1 indica a presença de dano. Se o COMAC é igual a 1, significa uma correlação perfeita entre os deslocamentos de uma coordenada. Uma vantagem de se utilizar os modos é a possibilidade da detecção de danos múltiplos, já que eles contêm informações locais da estrutura. Porém, trata-se de um parâmetro de difícil obtenção em todos os graus de liberdade.

No que diz respeito à utilização das taxas de amortecimento para a identificação de alterações estruturais, não há muitos estudos sendo feitos. No entanto, os resultados dos trabalhos de Ndambi et al. (2000)[38] and Kawiecki (2001)[39] sugerem essas taxas como parâmetros úteis.

Além dos métodos citados anteriormente, pode-se destacar ainda as abordagens que usam a variação das características provenientes dos parâmetros modais, conhecidas também como técnicas baseadas em indicadores evoluídos [20]. Pandey et al. (1991)[17] apresentou um novo indicador baseado na variação da curvatura dos modos naturais de estruturas saudáveis e danificadas, que associa a mudança na rigidez de flexão à mudança na curvatura. Alguns anos depois, Kim & Stubbs (1993)[40] propuseram um método baseado na variação da energia de deformação antes e depois da ocorrência de um dano, capaz de detectar e localizar a região afetada da estrutura. Outra estratégia empregada na identificação e localização de danos estruturais é análise da matriz de flexibilidade, que consiste em associar a presença do dano à redução de rigidez e ao aumento da flexibilidade [18]. Alvandi & Cremona (2006) [10] elaboraram um estudo no qual diversos desses métodos baseado em indicadores evoluídos foram analisados e comparados. Neste

caso, o método baseado na variação da energia de deformação se mostrou o mais eficaz para localizar o dano. Entretanto, os métodos baseados na mudança de curvatura dos modos e na análise da flexibilidade permitiram quantificar o dano, o que não foi possível com o método da energia de deformação. Mais recentemente, Cury et al. (2011)[16] desenvolveram uma estratégia híbrida utilizando a variação da energia de deformação e as frequências naturais para localizar e quantificar o dano, e obtiveram bons resultados.

Por se mostrar um parâmetro sensível a alterações e danos estruturais, as variações das frequências naturais são utilizadas neste trabalho. Além disso, este tipo de abordagem não requer um modelo analítico da estrutura, sendo necessário apenas algumas frequências para se caracterizar suas diferentes configurações.

2.2 Métodos baseados em inteligência computacional

Novas abordagens baseadas no aprendizado de máquinas aplicado ao reconhecimento de padrões vêm sendo propostas para a detecção de comportamentos estruturais “anormais”. Neste tipo de estratégia, os sinais são processados através de técnicas estatísticas ou até mesmo por análise modal e, posteriormente, são comparados e classificados por algoritmos de inteligência computacional, sendo que alterações entre os dados podem indicar a presença de danos.

Existem muitos estudos na literatura relatando a efetividade e utilidade dessas estratégias na avaliação da integridade de estruturas. No trabalho de Chang et al. (2000)[41] foi proposto um método de detecção de danos estruturais baseado em Redes Neurais Iterativas e no conceito de matriz ortogonal, conceito este adotado a fim gerar combinações representativas das alterações dos parâmetros. Resultados obtidos em testes numéricos provaram a eficiência do método na identificação de danos. Iwasaki et al. (2004)[21] fizeram uso de algoritmos de agrupamento (*clustering*) para a detecção de danos em uma viga a partir de diferentes respostas de frequências. Os resultados das classificações mostraram a capacidade dos algoritmos na identificação dos diferentes níveis de danos impostos à estrutura. Ainda no mesmo ano, Zang et al. (2004)[42] propuseram uma nova abordagem utilizando a Análise de Componentes Independentes para extrair características dos sinais temporais e Redes Neurais Artificiais, a qual demonstrou boa precisão na detecção de estados estruturais danificados e não-danificados. Um estudo

realizado por Wen et al. (2007)[43] apresentou uma estratégia para a detecção de danos desenvolvida a partir da teoria de lógica nebulosa (*fuzzy*) e redes neurais, na qual um bom desempenho de classificação foi verificado. Haritos & Owen (2004)[44] compararam diversas técnicas estatísticas, tais como Análise dos Componentes Principais e Testes de Hipóteses em ensaios dinâmicos experimentais sobre uma viga metálica. Nesta situação, as técnicas não obtiveram sensibilidade suficiente para detectar pequenas fissuras. Nas pesquisas de Alves et al. (2015)[14] e Cury (2010)[20] a técnica estatística de Análise dos Dados Simbólicos se mostrou útil na compressão e representação dos sinais. Devido a taxas de classificação superiores, muitos trabalhos estão sendo focados também na detecção de danos através de Máquinas de Vetores Suporte, como pode ser visto em Worden & Lane (2001)[45], Ni et al. (2005)[46] e Kook et al. (2009)[47]. Estudos desenvolvidos por Cury & Crémona (2012)[25] compararam o desempenho de três técnicas computacionais de classificação, utilizando a Análise de Dados Simbólicos para extrair informações dos dados vibracionais. Os resultados obtidos por Árvores de Decisão Bayesianas, Redes Neurais e Máquinas de Vetores Suporte foram eficientes na classificação e discriminação das modificações estruturais, considerando tanto os sinais no domínio do tempo ou os parâmetros modais. Ressalta-se ainda as estratégias que empregam o uso de Wavelets na caracterização de diferentes comportamentos estruturais [3, 24, 48]. No trabalho de Li et al. (2008)[24] foi apresentado um método baseado na transformada Wavelet e em Estatística de Ordem Superior (4ª ordem) capaz de solucionar problemas de detecção de falhas em rolamentos de máquinas. Farrar & Worden (2012)[22] sugeriram diversos indicadores estatísticos, entre os quais estão também as Estatísticas de Ordem Superior, como boas ferramentas na caracterização dos sinais.

Em vista dos parágrafos anteriores e do bom desempenho verificado em diversos estudos [22, 24, 26], faz-se neste trabalho o uso das propriedades modais e dos indicadores estatísticos como características dos sinais dinâmicos. Salienta-se ainda que, diante das várias técnicas computacionais possíveis, as Redes Neurais e Máquinas de Vetor Suporte têm se mostrado particularmente adequadas para abordar problemas de classificação não-lineares, como o de detecção de alterações estruturais, conforme pode ser visto nas pesquisas de Cury & Cremona (2012)[25], Chang et al. (2000)[41] e Worden & Lane (2001)[45]. Assim, optou-se por utilizar esses dois métodos de inteligência computacional para classificar os dados modais e estatísticos das respostas das estruturas estudadas nesta

dissertação. A teoria e os conceitos dos métodos computacionais, tal como a determinação dos indicadores estatísticos empregados são apresentados a seguir.

2.2.1 Determinação dos parâmetros de entrada para modelos de inteligência computacional

Apesar de os métodos de inteligência computacional serem eficientes na solução de problemas de detecção de danos e alterações estruturais, é necessário o uso de dados capazes de fornecer informações suficientes e representativas dos sinais dinâmicos, uma vez que o aprendizado desses métodos se dá através do mapeamento desse conjunto de dados. Assim, a determinação das variáveis de entrada dos modelos de inteligência computacional é de grande importância para que as diferentes condições da estrutura sejam reconhecidas e classificadas com sucesso.

As características modais, como as frequências naturais, modos de vibração e taxa de amortecimento, são frequentemente utilizadas como indicadores de dano, conforme visto nas seções anteriores. Considerando que a ocorrência de dano induz a mudanças nas propriedades mecânicas das estruturas, as variações dos parâmetros modais podem ser interpretadas como características representativas das respostas dinâmicas. Dessa forma, emprega-se neste trabalho o uso de tais propriedades como variáveis de entrada dos algoritmos que serão propostos mais adiante.

Tem-se também como alternativa os parâmetros de entrada estatísticos, que possibilitam trabalhar diretamente com as medidas dinâmicas no domínio do tempo. Segundo Farrar & Worden (2012)[22], a análise de séries temporais das respostas estruturais permite a extração de parâmetros dos sinais de forma mais simples do que utilizando-se a análise modal.

A maioria dos conjuntos de dados podem ser completamente caracterizados pelas denominadas estatísticas de primeira e segunda ordem, como por exemplo, a média e a variância, respectivamente. No entanto existem situações em que estas simples estatísticas não fornecem informações suficientes.

Neste contexto, a Estatística de Ordem Superior (HOS - *Higher-Order Statistic*) utiliza cumulantes de ordem maior que dois para inferir novas propriedades sobre o conjunto de dados [26]. Como as respostas estruturais são muito semelhantes mesmo após a ocorrência de danos, a HOS pode fornecer parâmetros que identifiquem diferenças sutis entre os

sinais, possibilitando a detecção de alterações estruturais.

Os dez diferentes indicadores estatísticos sugeridos por Farrar & Worden (2012)[22] para caracterizar as respostas vibracionais são dados pelas Equações (2.1) à (2.10).

Valor de pico:

$$x_{pico} = \max |\mathbf{x}| \quad (2.1)$$

Média:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.2)$$

Média quadrática:

$$x_q = \frac{1}{n} \sum_{i=1}^n (x_i)^2 \quad (2.3)$$

Raiz da média quadrática:

$$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2} \quad (2.4)$$

Variância:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2.5)$$

Desvio-padrão:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.6)$$

Assimetria:

$$s = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sigma^3} \quad (2.7)$$

Curtose:

$$k = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\sigma^4} \quad (2.8)$$

Fator de crista:

$$Cf = \frac{x_{pico}}{rms} \quad (2.9)$$

Fator-K:

$$Kf = x_{pico} \cdot rms \quad (2.10)$$

A primeira estatística apresentada é a máxima amplitude de pico, e expressa a maior magnitude de oscilação do sinal. A média, média quadrática e a raiz da média quadrática medem a tendência central dos dados, enquanto que o desvio-padrão e a variância medem a sua dispersão em relação à média. Dentre as métricas estatísticas utilizadas, a assimetria e a curtose são HOS de 3ª e 4ª ordem, respectivamente, em que a primeira é uma medida da simetria de distribuição dos dados e a segunda representa o “achatamento” da distribuição em relação a uma curva gaussiana. Por fim, tem-se os fatores K e de crista, que são geralmente empregados com o intuito de identificar desvios nas respostas senoidais. Destaca-se, que todos os indicadores deste trabalho foram aplicados aos históricos das acelerações estruturais. Apesar de algumas medidas estatísticas serem altamente correlacionadas, todas foram utilizadas como entrada dos algoritmos de classificação, sem o uso de qualquer método de seleção das melhores características.

2.2.2 Algoritmos para classificação

O problema de detecção de alterações estruturais através de modelos de predição de danos é um desafio que pode ser superado utilizando-se diversos algoritmos de inteligência computacional, tais como regressões lineares e polinomiais, árvores de decisão, redes neurais, máquinas de vetor suporte, entre outras, conforme verificado em Finotti et al. (2016)[49]. Nesses casos, os métodos computacionais funcionam como classificadores de padrões, que tentam identificar comportamentos estruturais “normais” e “anormais” usando, como variáveis de entrada, características extraídas das respostas de vibração. A capacidade de aprender e generalizar informações ainda não processadas através de exemplos é uma das principais vantagens ao se utilizar esses algoritmos. Como já dito anteriormente, o presente trabalho utiliza algoritmos baseados em redes neurais e máquinas de vetor suporte, cujos conceitos são abordados a seguir.

2.2.2.1 Rede Neural Artificial (ANN - Artificial Neural Network)

Rede Neural Artificial é uma técnica computacional de sistema adaptativo que, no contexto deste trabalho, funciona como um classificador de padrões, uma vez que tenta discriminar diferentes configurações estruturais a partir de dados de entrada que caracterizam o sinal, identificando sua respectiva classe através da saída fornecida pela ANN.

Segundo Principe et al. (2000)[50], a classificação feita por uma ANN é de natureza estatística, onde as classes são representadas por pontos em um espaço de decisão multidimensional dividido em regiões que estão associadas a cada tipo de saída. Os limites de decisão são estimados pelo processo de treinamento e suas construções são feitas pela variabilidade estatística existente entre as classes, através de um esquema de otimização baseado na avaliação do erro de saída da rede, conforme será descrito mais adiante.

Um dos tipos de ANN mais utilizados é o *perceptron* de múltiplas camadas (MLP - *Multilayer Perceptron*), que é uma rede neural *feedforward*¹ composta por uma camada de entrada, uma ou mais camadas ocultas (intermediárias) e a camada de saída, onde os elementos de processamento (neurônios) trabalham com funções cujo objetivo é inserir uma não-linearidade no modelo, chamadas de funções de ativação ou de transferência. Os neurônios podem usar qualquer função diferenciável f para gerar sua saída, no entanto as funções de ativação mais comuns em problemas de classificação são a sigmóide logística e a sigmóide tangente hiperbólica, mostradas na Figura 2.1.

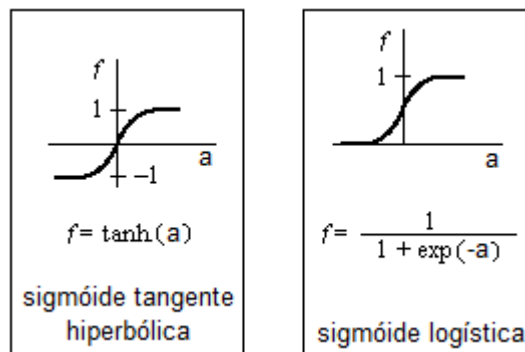


Figura 2.1: Funções de ativação (adaptado de Principe et al. (2000)[50]).

Dentre as várias técnicas de aprendizagem existentes para as redes MLP, a mais popular é a *backpropagation*, utilizada também neste trabalho. Nesta técnica, a saída fornecida pela rede é comparada com a resposta correta a fim de se obter um valor de erro por uma métrica predefinida. A partir disto, a técnica propaga o valor do erro obtido na camada de saída para as demais camadas e, posteriormente, atualiza os pesos relacionados a cada conexão da MLP[51]. Esse processo é repetido até que a diferença entre as respostas, alcançada pela rede e a alvo, convirja para um valor de erro que foi previamente especificado. Nesta situação, diz-se que a rede está treinada. A Figura 2.2

¹Propagação unidirecional dos sinais entre as conexões dos neurônios - da camada de entrada para a camada de saída.

ilustra uma MLP com n parâmetros de entrada, M saídas e K neurônios na camada oculta. Embora não representado na figura, é importante ressaltar que todas as conexões entre os neurônios possuem um peso w associado, pois indicam a influência que cada entrada possui.

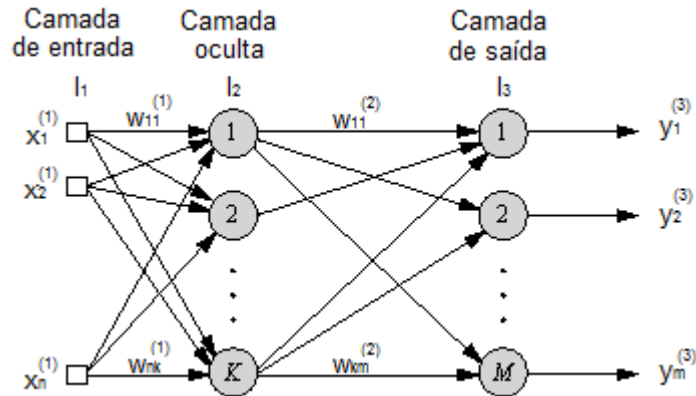


Figura 2.2: Rede MLP com uma camada oculta (adaptado de Principe et al. (2000)[50]).

No presente trabalho, as entradas correspondem aos parâmetros dos dados dinâmicos, ou seja, características modais ou indicadores estatísticos, e as saídas, que são representadas por notação binária, correspondem às classes de classificação (sem dano, dano nível 1, etc). Considerando-se a rede MLP de três camadas da Figura 2.2, para cada ensaio a ser classificado as entradas x_i são ponderadas pelos pesos w_{ij} antes de serem processadas pelos k neurônios da respectiva camada l ($l=2,3$). A soma dessas entradas ponderadas forma um valor para a variável da função de transferência f , resultando nas saídas y_j de cada neurônio, conforme a Eq.(2.11):

$$y_j^{(l)} = f \left(\sum_{i=1}^n w_{ij}^{(l-1)} x_i^{(l-1)} + b^{(l-1)} \right), \text{ para } j = 1, \dots, k^{(l)} \quad (2.11)$$

onde b é o *bias* associado às camadas.

O processo de ajuste de pesos se dá através de métodos para otimização não-linear, tais como o método do gradiente descendente, método de Newton, Levenberg-Marquardt, entre outros[50]. Optou-se neste trabalho utilizar o método de Levenberg-Marquardt, um dos mais eficientes e indicados para redes que contenham centenas de pesos a serem ajustados [52]. Resumidamente, calcula-se a matriz jacobiana da função de erro em relação aos respectivos pesos, estes são então alterados de modo que o erro diminua. A expressão

que avalia os pesos atualizados da rede é dada pela Eq.(2.12):

$$w(p+1) = w(p) - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \varepsilon(p) \quad (2.12)$$

onde μ é a taxa de aprendizado, p é o passo da iteração, \mathbf{I} é a matriz identidade, \mathbf{J} é a matriz jacobiana representada na Eq.(2.13) e ε é o erro médio quadrático, definido pela soma da diferença ao quadrado entre os valores alvos d_i e os obtidos pela rede y_i , conforme Eq.(2.14).

$$\mathbf{J} = \begin{bmatrix} \frac{\partial \varepsilon_1(w)}{\partial w_1} & \cdots & \frac{\partial \varepsilon_1(w)}{\partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial \varepsilon_N(w)}{\partial w_1} & \cdots & \frac{\partial \varepsilon_N(w)}{\partial w_n} \end{bmatrix} \quad (2.13)$$

$$\varepsilon = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (d_i - y_i)^2 \quad (2.14)$$

Ao término do treino a rede deverá ter adquirido a capacidade de generalizar resultados para o respectivo problema com base nos parâmetros extraídos. Para avaliar o desempenho do modelo neural, dados do sinal que não foram utilizados são classificados a fim de testar a capacidade de generalização da rede. Esta última etapa é denominada fase de teste. Cabe ressaltar que a fase de teste não tem efeito na construção do modelo de classificação, já que fornece apenas uma medida do desempenho da rede para dados ainda não “vistos”.

2.2.2.2 Máquina de Vetor Suporte (SVM - *Support Vector Machine*)

Outro método de inteligência computacional popular para o problema de reconhecimento de padrões é a Máquina de Vetor Suporte (SVM - *Support Vector Machine*). As SVMs são desenvolvidas a partir de um algoritmo de aprendizado estatístico treinado para determinar o limite entre duas classes de dados em um espaço, onde um hiperplano ótimo de separação é construído com o intuito de maximizar a margem entre as regiões de cada classe e minimizar as classificações erradas [53], como ilustrado na Figura 2.3. No entanto, a teoria da SVM pode ser estendida de problemas de classificação binários para problemas de classificação multiclass, através de estratégias baseadas na combinação de classificadores de duas classes, como as estratégias um contra um e um contra todos, por exemplo [51].

Considerando-se o conjunto de dados (\mathbf{x}_i, y_i) de um problema de classificação linear,

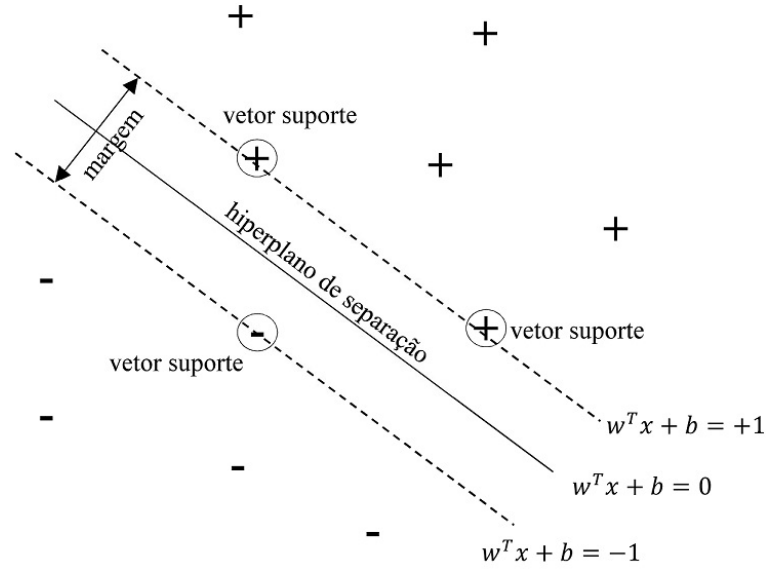


Figura 2.3: Representação de um SVM linear.

sendo \mathbf{x}_i o vetor de variáveis de entrada do sinal dinâmico i , y_i a saída desejada do sinal i e i representando o i -ésimo sinal do banco de dados, o hiperplano de separação é definido tal que:

$$\begin{aligned} y_i = 1 &\rightarrow \mathbf{w}^T \mathbf{x}_i + b > +1 \quad \forall \mathbf{x}_i \in \Omega_1 \\ y_i = -1 &\rightarrow \mathbf{w}^T \mathbf{x}_i + b < -1 \quad \forall \mathbf{x}_i \in \Omega_2 \end{aligned} \quad (2.15)$$

onde \mathbf{w} é o vetor de pesos das variáveis de entrada, b é o *bias*, Ω_1 e Ω_2 representam as regiões associadas às classes presentes na amostra ($\Omega_1 + \Omega_2 = \Omega$). A Eq.(2.15) acima é combinada de forma que:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \forall \mathbf{x}_i \in \Omega \quad (2.16)$$

em que para os dados (\mathbf{x}_i, y_i) cuja equação acima é satisfeita com igualdade, dá-se o nome de vetores suporte (Figura 2.3). O problema de aprendizagem do algoritmo SVM é interpretado como a minimização de $\|\mathbf{w}\|^2 = \mathbf{w}^T \mathbf{w}$, o que é equivalente a maximizar a distância normal ao hiperplano que separa as duas classes (margem). Assim, o problema de otimização pode ser enunciado como a minimização da função dada pela Eq.(2.17):

$$\Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.17)$$

a qual é sujeita à Eq.(2.16), com $i=1, \dots, n$. A função de Lagrange para este problema

pode ser escrita como:

$$L(\mathbf{w}, b, \Lambda) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \lambda_i [y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1] \quad (2.18)$$

onde $\Lambda = (\lambda_1, \dots, \lambda_n)^T$ são os multiplicadores de Lagrange. A solução deste problema é delineada pela maximização de L considerando $\Lambda_i \geq 0$, minimizando \mathbf{w} e b . Assim, a solução ótima é dada por:

$$w^* = \sum_{i=1}^n \lambda_i^* y_i x_i \quad (2.19)$$

Salienta-se que os multiplicadores de Lagrange são iguais a zero somente quando a Eq.(2.16) é igual a um (vetores suporte). O valor ótimo de *bias* é avaliado como:

$$b^* = y_i - \mathbf{w}^{*T} \mathbf{x}_i, \quad i = 1, \dots, n \quad (2.20)$$

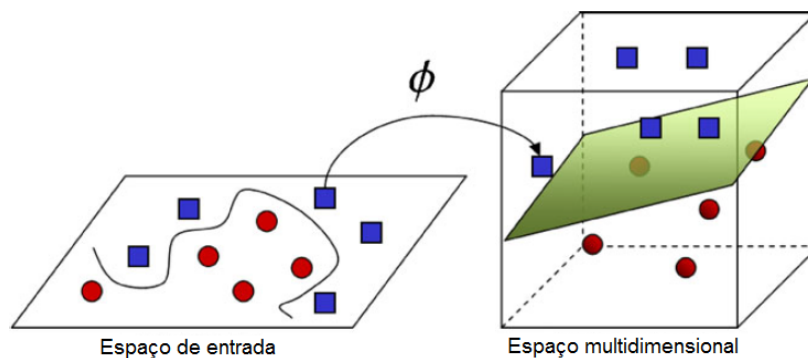


Figura 2.4: Representação do hiperplano separador de um SVM não-linear (adaptado de Cury & Cremona (2012)[25]).

No entanto, ao se considerar a classificação binária como sendo não-linear, as entradas são mapeadas em um espaço de características de dimensão maior que o espaço original através de alguma função de kernel, conforme ilustrado na Figura 2.4. Dessa forma, tem-se que:

$$\begin{aligned} X &\rightarrow H \\ \mathbf{x} &\rightarrow \phi(\mathbf{x}) \end{aligned} \quad (2.21)$$

O mapeamento de um determinado conjunto de testes $(\mathbf{x}_i, \mathbf{x}_i')$ é realizado através da Eq.(2.22):

$$K(\mathbf{x}_i, \mathbf{x}_i') \equiv \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_i') \quad (2.22)$$

Assim, faz-se necessária a escolha de um kernel apropriado, de fácil processamento

e capaz de ajustar os parâmetros do modelo razoavelmente. Neste trabalho, a função utilizada como kernel é a chamada Função de Base Radial (RBF - *Radial Basis Function*):

$$K(\mathbf{x}_i, \mathbf{x}_i') \equiv e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_i'\|^2}{2\sigma^2}} \quad (2.23)$$

Os modelos SVM utilizados nesta dissertação foram implementados a partir de *toolboxes* e funções presentes no Matlab R2016b. Neste caso, os modelos tem dois parâmetros livres que precisam ser especificados: σ da função do kernel RBF; e C , um parâmetro de regularização a partir da formulação da maximização da margem. Estes parâmetros são selecionados por um procedimento de busca exaustiva conhecido como *Grid Search*. Neste método, dois conjuntos finitos de valores (discretos) para σ e C são previamente determinados e empregados no treinamento de modelos SVM, onde todas as combinações são avaliadas através de uma validação cruzada *10-fold*. Por fim, o par de parâmetros (σ, C) que obtiver o modelo com o menor erro de generalização é escolhido. As Equações (2.24) e (2.25) mostram os conjuntos de valores para σ e C , respectivamente, utilizados no procedimento de *Grid Search* deste trabalho.

$$\sigma = \{0, 0316; 0, 0398; 0, 0501; 0, 0631; 0, 0794; 0, 3162; 0, 3981; 0, 5000; 0, 5012; 0, 6310; 0, 7943; 1, 0; 1, 5; 2, 0; 2, 5; 3, 0; 3, 5; 4, 0; 4, 5; 5, 0; 5, 5; 6, 0; 6, 5; 7, 0; 7, 5; 8, 0; 8, 5; 9, 0; 9, 5; 10, 0\} \quad (2.24)$$

$$C = \{0, 0316; 0, 3162; 0, 5000; 1, 0; 1, 5; 2, 0; 2, 5; 3, 0; 3, 5; 4, 0; 4, 5; 5, 0; 5, 5; 6, 0; 6, 5; 7, 0; 7, 5; 8, 0; 8, 5; 9, 0; 9, 5; 10, 0; 31, 6228; 100, 0; 316, 2278\} \quad (2.25)$$

2.2.2.3 Método de validação cruzada *k-fold*

O desempenho médio de um modelo obtido via ANN e SVM pode ser estimado com base no valor esperado do erro de predição ao longo do treinamento, conforme já discutido anteriormente.

Um dos problemas mais comuns durante o treinamento de uma rede neural é o de *overfitting*, caracterizado pela construção de um modelo que se ajusta perfeitamente aos exemplos utilizados no treino (alta precisão e baixo erro de predição), mas que não é capaz de alcançar bom desempenho quando avaliado para novos conjuntos daquele mesmo tipo de dado. Em outras palavras, o modelo não consegue generalizar bem.

Assim, técnicas de validação cruzada visam garantir a capacidade de generalização dos modelos computacionais quando submetidos a dados do conjunto não utilizados na fase de treino. Estas técnicas consistem em dividir o conjunto de treinamento em dois subconjuntos, treino e validação, e testar o desempenho da rede a cada certo intervalo de iterações com o conjunto de validação. O treinamento é interrompido assim que é encontrado o ponto de generalização máxima do modelo, ou seja, quando o erro no conjunto de validação começa a crescer.

Existem vários métodos de validação cruzada, porém este trabalho concentra-se apenas na validação *k-fold* [54]. Nesta técnica, o conjunto original de dados é dividido aleatoriamente em k subconjuntos com aproximadamente a mesma quantidade de dados, contendo exemplos de todas classes. A cada iteração, um subconjunto distinto é utilizado para teste, e os outros $k-1$ para treino. Os processos de treinamento e teste são repetidos k vezes. A estimativa de precisão é o número total de classificações corretas dividido pelo número de amostras no conjunto de dados k . Ao fim dessa validação, cada amostra do conjunto de dados original foi testada apenas uma vez pelos algoritmos, não havendo sobreposição de dados. A Figura 2.5 representa o esquema da validação *k-fold*. O desempenho final do modelo é calculado através da média de acerto de todas k classificações da validação *k-fold*.



Figura 2.5: Esquema de validação *k-fold*.

3 APLICAÇÕES

Como exposto no capítulo 2, métodos de aprendizagem de máquina têm sido amplamente aplicados na solução de problemas de identificação de danos e alterações estruturais. Diversos estudos foram conduzidos utilizando propriedades modais e análise estatística no processamento dos sinais dinâmicos, com o intuito de extrair alguma característica inerente à presença de danos. Diante disso, este capítulo concentra-se na avaliação dos métodos de inteligência computacional quando empregados na detecção de mudanças no comportamento vibracional das estruturas. Os parâmetros modais e os indicadores estatísticos extraídos das medições estruturais no domínio do tempo são utilizados como dados de entrada de algoritmos ANN e SVM. Os resultados obtidos são comparados em três aplicações: um modelo numérico de viga, um protótipo de laje e uma ponte ferroviária (PK 075+317, na França). Os modelos ANN e SVM, assim como os indicadores estatísticos, foram desenvolvidos utilizando *toolboxes* e funções *built-in* disponíveis no Matlab R2016b. Em vista de reproduzir os números aleatórios gerados nas execuções dos algoritmos, uma mesma semente foi previamente especificada para todos os modelos computacionais.

3.1 Viga biapoiada - Modelo numérico

A presente seção destina-se a analisar a abordagem proposta através de dados sintéticos obtidos por um modelo de elementos finitos de uma viga biapoiada de 6m de comprimento e seção transversal perfil I (desenvolvido no trabalho de Alves (2012)[55]), cujas propriedades mecânicas são:

- Módulo de elasticidade longitudinal (E) = 210 GPa;
- Massa específica = 7850 kg/m³;
- Área de seção transversal = 2.81×10^{-3} m²;
- Momento de inércia = 2.845×10^{-8} m⁴.

O modelo é constituído por uma malha de 200 elementos de viga de Bernoulli [56] formados por dois nós com dois graus de liberdade cada um (rotação e translação vertical), excitado por uma força com frequências e amplitudes aleatórias aplicada a 0,69m do apoio direito. As respostas dinâmicas foram consideradas como os deslocamentos verticais medidos em 10 pontos equidistantes da viga durante 100s com frequência de amostragem de 100Hz, simulando uma instrumentação real feita por meio de acelerômetros. A representação da viga modelada é apresentada na Figura 3.1.

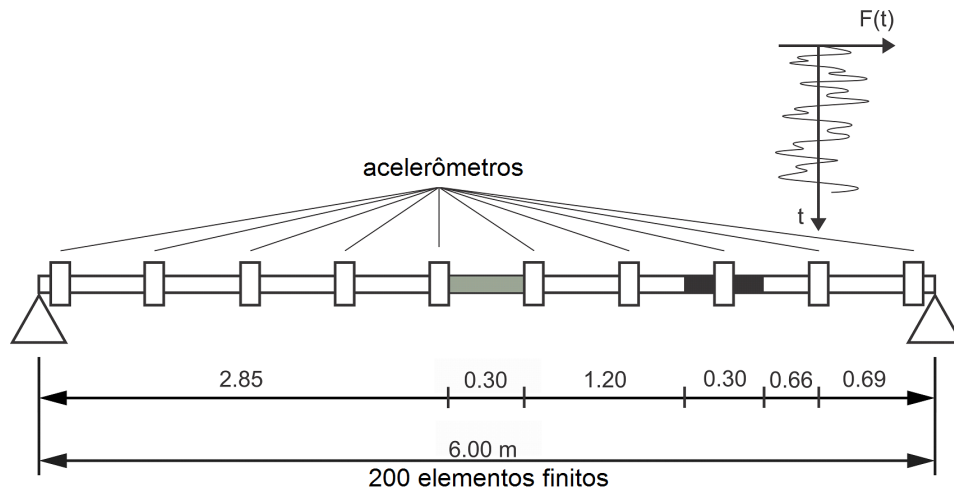


Figura 3.1: Modelo da viga biapoiada (Unidade: m).

Três configurações estruturais foram consideradas: Viga sem danos; Viga com dano, modelada através da redução de 20% do módulo de elasticidade longitudinal no meio do vão, representado pelo trecho em cinza no esquema da viga da Figura 3.1 (dano 1) e; Viga com dano, modelada através da redução de 10% do módulo de elasticidade no quarto de vão da viga, correspondente ao trecho em preto da viga da Figura 3.1, somada a redução anterior de 20% (dano 2). Para cada uma das situações de dano, admitiu-se três níveis de ruído às respostas dinâmicas: Sem ruído, 5% de ruído (ruído 1) e 10% de ruído (ruído 2). A maneira como os ruídos foram gerados e adicionados ao sinal dinâmico é definida pela Eq.(3.1) abaixo:

$$x_{i,ruído} = x_i + n_{ruído} \cdot \sigma_{x_i} \cdot V \sim N(0,1) \quad (3.1)$$

onde $x_{i,ruído}$ é o vetor do sinal com ruído, x_i é o vetor do sinal sem ruído, $n_{ruído}$ é o nível de ruído, σ_{x_i} é o desvio-padrão e $V \sim N(0,1)$ é um vetor gaussiano de média nula e desvio-padrão unitário.

Os dez indicadores utilizados para caracterizar a resposta temporal da estrutura são: Valor de pico (I1), média (I2), média quadrática (I3), raiz da média quadrática (I4), variância (I5), desvio padrão (I6), assimetria (I7), curtose (I8), fator de crista (I9) e fator-K (I10).

Ressalta-se que nesta aplicação, a classificação baseada nos indicadores estatísticos é feita de duas formas diferentes:

- Considerando o ensaio ao longo de todo o comprimento da viga, na qual os dados de entrada são organizados na matriz $[90 \times 100]$ apresentada na Eq.(3.2), onde as linhas representam o sinal em questão e as colunas são os indicadores estatísticos (10 indicadores \times 10 pontos de medição simulada computacionalmente = 100).

$$\begin{bmatrix} E_1 I_{1-m1} & E_1 I_{1-m2} & \cdots & E_1 I_{10-m10} \\ E_2 I_{1-m1} & E_2 I_{1-m2} & \cdots & E_2 I_{10-m10} \\ \vdots & \vdots & \ddots & \vdots \\ E_{90} I_{1-m1} & E_{90} I_{1-m2} & \cdots & E_{90} I_{10-m10} \end{bmatrix} \quad (3.2)$$

A cada dez colunas tem-se um tipo de indicador estatístico, assim o elemento $E_1 I_{1-m1}$ corresponde ao indicador estatístico I_1 obtido do sinal simulado no ponto de medição $m1$ para o ensaio dinâmico E_1 , o elemento $E_1 I_{1-m2}$ corresponde ao indicador estatístico I_1 obtido do sinal simulado no ponto de medição $m2$ para o ensaio dinâmico E_1 , e assim por diante até chegar no último elemento $E_{90} I_{10-m10}$, correspondente ao indicador I_{10} da resposta simulada no ponto $m10$ para o ensaio E_{90} .

- Considerando separadamente cada sinal simulado, com os dados de entrada arranjados na matriz $[900 \times 11]$ apresentada na Eq.(3.3), onde as linhas representam o sinal, as dez primeiras colunas são os indicadores estatísticos e a última coluna informa a posição associada ao acelerômetro em que a respectiva resposta foi medida

(de m_1 à m_{10}).

$$\begin{bmatrix} E_1 I_1 & E_1 I_2 & \cdots & E_1 I_{11} \\ E_2 I_1 & E_2 I_2 & \cdots & E_2 I_{11} \\ \vdots & \vdots & \ddots & \vdots \\ E_{900} I_1 & E_{900} I_2 & \cdots & E_{900} I_{11} \end{bmatrix} \quad (3.3)$$

Ou seja, dez ensaios foram simulados para cada caso de dano e ruído, totalizando 90 ensaios para a primeira forma de classificação (3 configurações estruturais \times 3 níveis de ruído \times 10 ensaios = 90 conjuntos de dados) e 900 ensaios para a segunda (3 configurações estruturais \times 3 níveis de dano \times 10 ensaios \times 10 acelerômetros = 900 conjuntos de dados). A Figura 3.2 mostra uma resposta típica da estrutura obtida por um dos ensaios.

No que tange às propriedades modais, somente as alterações observadas nas primeiras três frequências naturais são consideradas (Figura 3.3), gerando assim uma matriz de entrada $[90 \times 3]$. As frequências fornecidas por Alves (2012)[55] foram identificadas utilizando as técnicas de Decremento Aleatório e Método de Ibrahim[57], aplicadas às respostas dinâmicas no domínio do tempo dos sinais simulados computacionalmente.

Como se trata de um aprendizado de máquina supervisionado, é necessário também apontar a classe de dano para cada ensaio. Por esse motivo, para os algoritmos ANN é gerada uma matriz alvo $[90 \times 3]$, em que as linhas indicam a categoria do sinal através da seguinte codificação binária: (1 0 0) - Sem dano; (0 1 0) - Dano 1 e, (0 0 1) - Dano 2. Enquanto que, para os classificadores SVM, as três diferentes condições estruturais são representadas por um vetor alvo codificado como: 1 - Sem dano; 2 - Dano 1 e, 3 - Dano 2.

Os modelos de inteligência computacional foram executados e treinados 30 vezes aplicando-se o método de validação cruzada *10-fold*. As Tabelas 3.1, 3.2 e 3.3 apresentam os resultados obtidos pelos modelos de detecção na fase de teste, em que a taxa de classificação é representada pela média das 30 repetições (nº de acertos dividido pelo nº total de ensaios classificados).

Os modelos ANN implementados são do tipo MLP criados com 1 camada oculta composta por 20 neurônios para os dados $[900 \times 11]$ e 10 neurônios para os demais (entrada $[90 \times 100]$ e modal). O número de neurônios na camada oculta foi definido através de experimentos prévios, considerando-se o melhor desempenho nas classificações




Figura 3.2: Resposta típica do modelo numérico de viga.

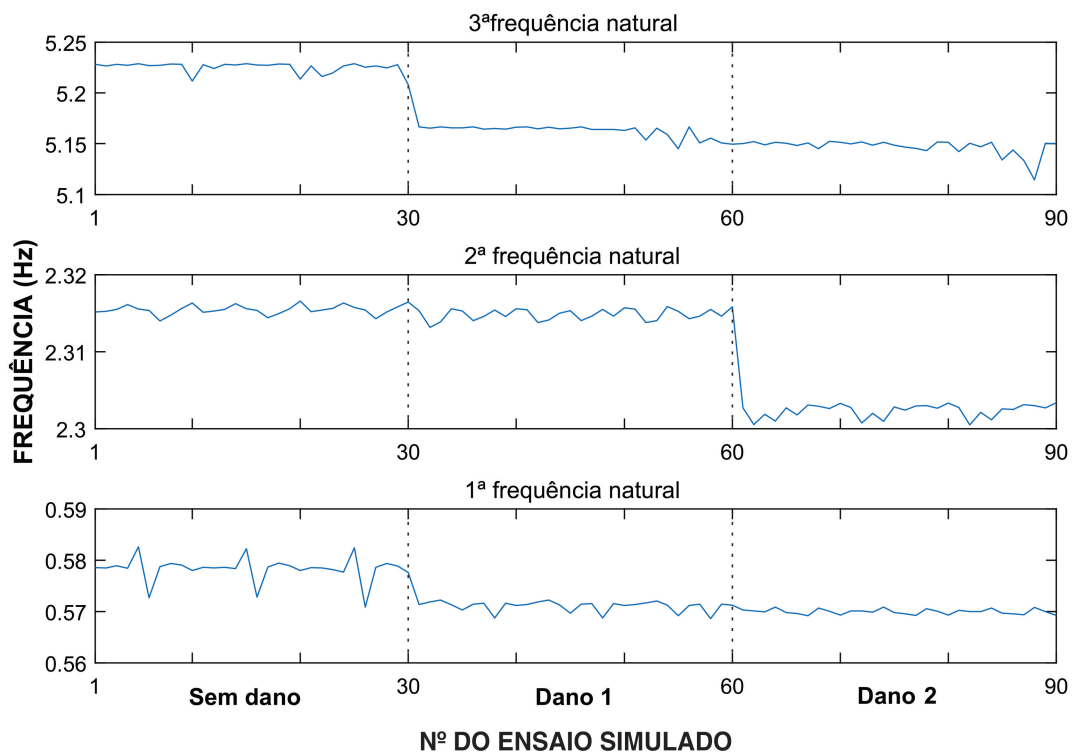


Figura 3.3: Variação das frequências naturais da viga de acordo com a classe de dano.

ao se treinar as redes para diferentes quantidades de neurônios. Por ter obtido melhores resultados de classificação, o método de otimização de Levenberg-Marquardt foi escolhido

como função de treinamento, utilizando a média quadrática como métrica de erro e uma sigmóide logística como função de ativação. A Figura 3.4 mostra uma ilustração da arquitetura da rede proposta com entrada $[900 \times 11]$.

Tabela 3.1: Resultados considerando os indicadores estatísticos - matriz de dados $[90 \times 100]$ ($\sigma = 3,00$ e $C = 8,50$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	86,78%	6,25%	95,56%	73,33%
SVM	99,41%	1,04%	100,00%	96,67%

Tabela 3.2: Resultados considerando os indicadores estatísticos - matriz de dados $[900 \times 11]$ ($\sigma = 0,3162$ e $C = 316,2278$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	83,13%	1,78%	86,33%	77,78%
SVM	93,14%	0,52%	94,00%	91,00%

Tabela 3.3: Resultados considerando os parâmetros modais ($\sigma = 0,0316$ e $C = 0,50$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	99,15%	2,06%	100,00%	93,33%
SVM	99,30%	0,54%	100,00%	98,89%

Por se tratar de um problema de classificação não-linear, o modelo SVM foi elaborado utilizando como kernel uma função de base radial (RBF - *Radial Basis Function*), onde os melhores parâmetros σ e C são selecionados através de um treinamento com diferentes valores deles em uma validação cruzada *10-fold* (procedimento de busca exaustiva *Grid Search* - seção 2.2). Como a aplicação é multiclasse, optou-se pela estratégia de classificação “um contra um”, que é a mais utilizada na literatura.

Ambos os algoritmos, ANN e SVM, alcançaram taxas satisfatórias de classificação. O pior desempenho foi para o caso da rede neural com matriz de entrada $[90 \times 100]$, no qual observa-se um desvio-padrão maior que 6%. Este resultado pode ser atribuído à grande quantidade de parâmetros (100) comparada ao tamanho do banco de dados (90), o que dificulta o processo de aprendizado do algoritmo. Tal dificuldade é refletida no tempo de

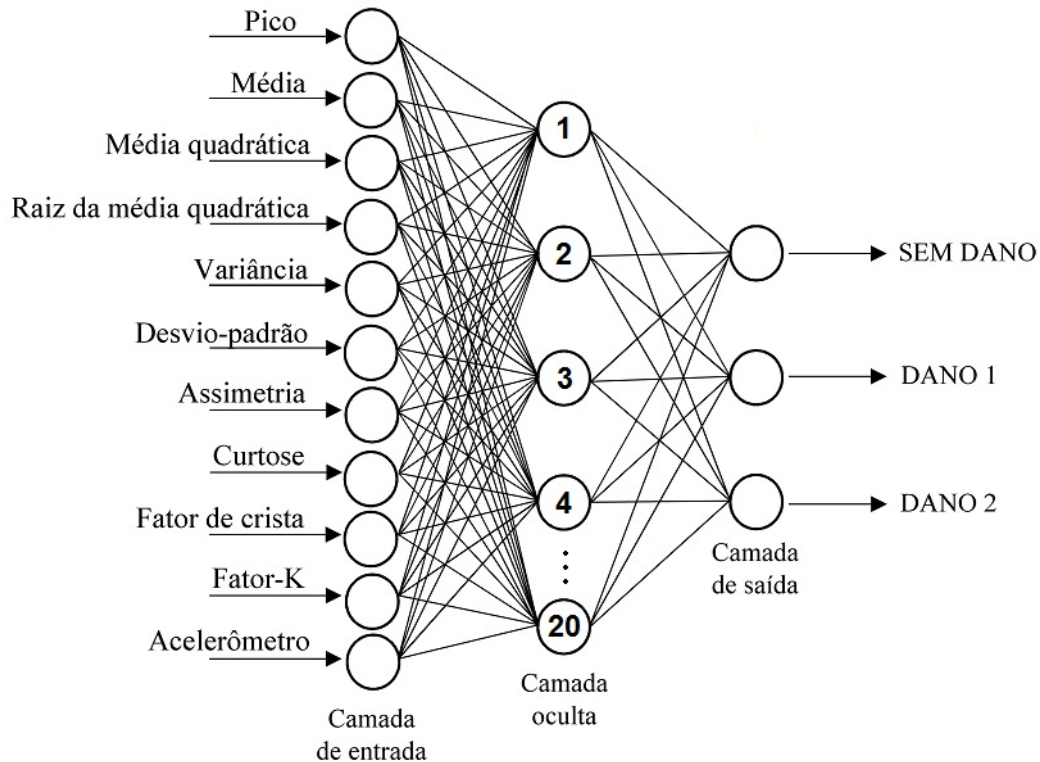


Figura 3.4: Arquitetura da rede MLP para os dados $[900 \times 11]$.

processamento do modelo, que foi de 1761s, contra a média de 25s dos outros casos. No geral, nota-se que nas três situações (dados $[90 \times 100]$, $[900 \times 11]$ e modais), o SVM obteve resultados superiores ao ANN. Ressalta-se ainda que as classificações com parâmetros modais se mostraram ligeiramente superiores as com índices estatísticos. Este aumento de desempenho pode ser explicado pelos valores das frequências naturais da viga, que apesar de não apresentarem muita variação, estão com valores bem definidos entre as diferentes condições estruturais (Figura 3.3).

3.2 Laje de concreto - Aplicação com dados experimentais

O comportamento dinâmico de uma laje é analisado através de investigações experimentais conduzidas no Laboratório de Ensaios de Materiais e Estruturas (LABEME) da Universidade Federal da Paraíba, cujos dados foram gentilmente cedidos pelo professor Roberto Pimentel. Para tanto, construiu-se um protótipo de laje de concreto de 3,00m de comprimento \times 1,35m de largura \times 0,08m de espessura, armado com barras de aço CA-60 (resistência de escoamento de 600MPa) de 5,0mm de diâmetro dispostas em ambas

as direções, conforme pode ser visto na Figura 3.5. O concreto foi moldado utilizando cimento Portland de alta resistência inicial CP V-ARI de 25MPa. A laje projetada para suportar uma carga máxima de 16kN foi simplesmente apoiada ao longo de duas vigas de aço, resultando em um vão de 2,89m entre os eixos dos apoios.




Figura 3.5: Armadura utilizada no protótipo da laje.

Os ensaios dinâmicos foram realizados utilizando-se um martelo instrumentado de 5kg B&K modelo 8210 e um acelerômetro piezoelétrico Endevco modelo 752A13, com sensibilidade 1V/g. Danos foram impostos à laje por meio de carregamento estático, considerando-se 4 estágios de carga: 0kN, 8kN, 16kN e 22kN. Destaca-se que com a aplicação da carga de 8kN, já foi possível verificar o aparecimento de uma fissura na laje. As cargas, aplicadas por um macaco hidráulico, eram distribuídas em duas linhas paralelas aos suportes, localizadas aproximadamente no terço do vão da laje. As respostas dinâmicas foram medidas após o respectivo ciclo de carga e descarga. A Figura 3.6 mostra o sistema de ensaio descrito anteriormente.

As respostas estruturais correspondentes à aplicação de cargas de impacto (golpes de martelo) em pontos previamente estabelecidos foram medidas por um único acelerômetro fixado em um nó específico da laje. A localização dos pontos de excitação e de medição está representada na Figura 3.10.

Cada sinal (excitação e resposta) é de 4s, com taxa de amostragem de 1024Hz. Os dados foram adquiridos e processados por um analisador de espectro Dataphysics modelo Quattro, a fim de se obter o sinal no domínio do tempo e as funções de resposta em frequência (FRFs), com resolução de frequência de 0,25Hz. Para minimizar os efeitos de ruído, calculou-se as FRFs como sendo a média de cinco excitações.

Quanto às medições dinâmicas (acelerações), somente a última resposta de cada ponto foi registrada. As respostas dos nós 5 e 41 foram descartados devido à problemas em suas



Figura 3.6: Esquema experimental da laje. (a) Sistema de transmissão da carga por macaco hidráulico; (b) Aquisição dos dados.

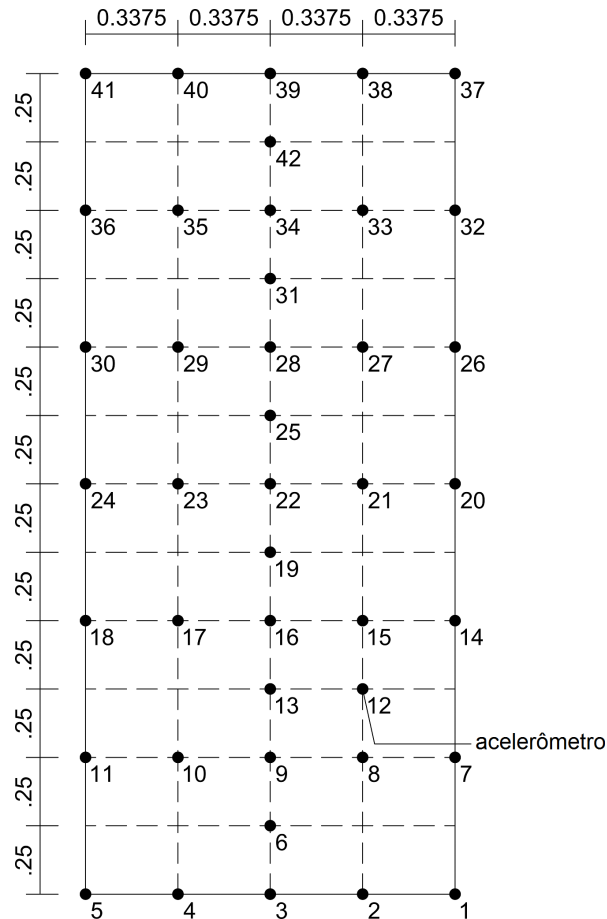


Figura 3.7: Pontos de aplicação da excitação na laje de concreto (Unidade: m).

aquisições, obtendo-se assim 40 sinais para cada estágio de carga, totalizando 160 ensaios.

A Figura 3.8 exibe a resposta típica da estrutura para este tipo de ensaio.

Tal qual o caso da viga (seção 3.1), considerou-se também dez indicadores estatísticos




Figura 3.8: Resposta típica do protótipo de laje.

para a caracterização dos ensaios dinâmicos, resultando na matriz de entrada $[160 \times 10]$ (10 indicadores \times 1 canal de acalêmetro). Já a primeira frequência natural da laje e as taxas de amortecimento, identificadas através das FRFs, estão organizadas em uma matriz $[160 \times 2]$. Os amortecimentos para o primeiro modo foram extraídos empregando o método da meia potência [58]. A variação dos parâmetros modais ao longo dos 4 estágios de carga são expostos na Figura 3.9.

As matrizes de saída (“alvo”) dos algoritmos são codificadas como:

- Sem dano (0kN) - (1 0 0 0) para ANN e 1 para SVM;
- Dano 1 (devido à carga de 8kN) - (0 1 0 0) para ANN e 2 para SVM;
- Dano 2 (devido à carga de 16kN) - (0 0 1 0) para ANN e 3 para SVM;
- Dano 3 (devido à carga 22kN) - (0 0 0 1) para ANN e 4 SVM.

As Tabelas 3.4 e 3.5 apresentam as taxas de acerto obtidas pelos modelos de detecção de danos ANN e SVM. Assim como na aplicação da viga, os algoritmos foram executados 30 vezes utilizando a validação cruzada *10-fold* e as taxas são os valores de acerto do algoritmo dividido pelo número de classificações realizadas.

A arquitetura da rede MLP e o modelo SVM propostos para a laje são semelhantes ao da seção 3.1, exceto pelos números de neurônios nas camadas e os parâmetros RBF (σ e C), respectivamente. Para ambos os dados (modais e estatísticos) o modelo MLP possui 10 neurônios na camada oculta, é treinado pela função de otimização de Levenberg-Marquardt, tem como função de ativação a sigmóide logística e utiliza como métrica de erro a média quadrática. Todos estes parâmetros foram definidos através de experimentos prévios, considerando-se o melhor desempenho nas classificações ao se treinar as redes para diferentes configurações. O tempo médio de processamento dos métodos de detecção na presente aplicação foi de 40 segundos.

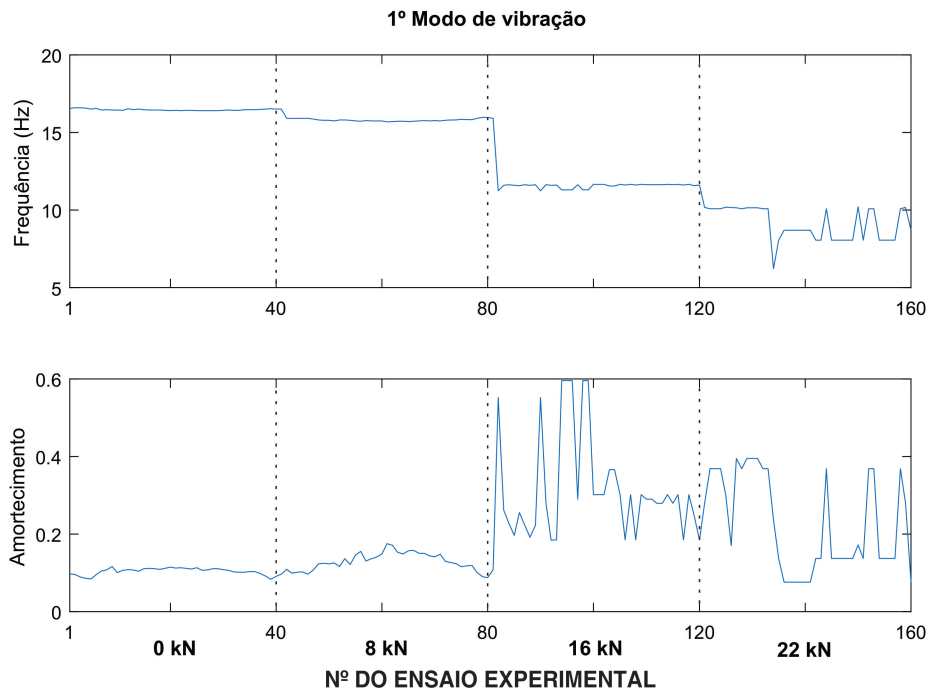


Figura 3.9: Variação das propriedades modais da laje de acordo com o estágio de carga.

Tabela 3.4: Resultados considerando os indicadores estatísticos ($\sigma = 9,00$ e $C = 1,50$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	56,44%	3,16%	62,50%	49,37%
SVM	45,37%	1,72%	48,75%	41,87%

Analisando o desempenho dos modelos, é possível observar que os indicadores estatísticos não forneceram informações suficientes sobre as respostas dinâmicas, já que os modelos não foram capazes de reconhecer os 4 padrões (média de classificação de 50%). Isto provavelmente se deve ao fato de que a carga de impacto aplicada pelo martelo

Tabela 3.5: Resultados considerando os parâmetros modais ($\sigma = 0,0501$ e $C = 0,3162$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	96,85%	2,15%	98,75%	91,25%
SVM	97,92%	0,66%	98,75%	95,62%

produziu uma resposta dinâmica curta, tornando difícil a caracterização dos sinais entre os níveis de dano. Ao contrário do que aconteceu com os parâmetros modais, situação em que os dois algoritmos apresentam desempenho similar. Cabe ressaltar, que neste caso, os resultados foram satisfatórios devidas as frequências naturais estarem bem definidas entre as diferentes configurações estruturais, fato não observado nas variações das taxas de amortecimento (Figura 3.9).

3.3 Ponte PK 075+317 - Aplicação com dados experimentais

A estrutura em questão é uma ponte ferroviária localizada no sudeste da França (PK 075+317) que atravessa a estrada secundária 939 entre as cidades de Sens e Sounicy no condado de Yonne e interliga Paris à Lyon. Testes dinâmicos foram efetuados em um dos trilhos com o intuito de caracterizar e quantificar o efeito de um procedimento de reforço estrutural, tal como ilustrado na Figura 3.10.


O procedimento de reforço deste viaduto consistiu no “aperto” do seu sistema de sustentação, mostrado na Figura 3.10(b), e tinha como propósito afastar a primeira frequência natural da estrutura (em torno de 5Hz) da frequência de excitação causada pela passagem dos trens (entre 4Hz e 5Hz). A instrumentação da ponte compreende três sensores de deslocamento vertical, situados entre o parapeito e o trilho 1, oito acelerômetros verticais e dois acelerômetros horizontais (longitudinais e transversais), todos instalados embaixo do tabuleiro, além de dois sensores de temperatura e dois de passagem de trem. Este último tem por objetivo medir as cargas no eixo na entrada e saída da ponte. No entanto, somente as medidas de aceleração serão utilizadas neste trabalho. A frequência de amostragem dos sinais é de 4096Hz. Três conjuntos de ensaios dinâmicos foram considerados: antes do reforço (15 ensaios), durante (13 ensaios) e depois (13 ensaios). Os ensaios realizados durante o procedimento de reforço não são utilizadas



(a)



(b)



(c)

Figura 3.10: Ponte PK 075+317 (adaptado de Cury et al. (2010)[59]). (a) Visão geral do viaduto durante o procedimento de reforço; (b) Sistema de reforço estrutural empregado; (c) Localização dos sensores.

neste estudo, totalizando assim 280 sinais (10 acelerômetros por ensaio). Uma resposta típica da estrutura é apresentada na Figura 3.11.

Os dez indicadores estatísticos foram calculados para cada sinal, formando uma matriz de entrada $[280 \times 11]$, onde a última coluna indica a posição do respectivo acelerômetro (de 1 a 10). Além desses índices, utilizou-se ainda as quatro primeiras frequências naturais como dados de entrada dos algoritmos, organizadas em uma matriz $[280 \times 4]$. O vetor de saída para os algoritmos de classificação da ponte possui valor 0 se o sinal pertencer à configuração estrutural antes do reforço e 1 se depois do reforço.

As Tabelas 3.6 e 3.7 abaixo apresentam as taxas de acerto obtidas pelos modelos de detecção de danos ANN e SVM para os parâmetros de entrada modais e estatísticos. Assim como na aplicações das seções anteriores, os algoritmos foram executados 30 vezes




Figura 3.11: Resposta típica da ponte ferroviária PK 075+317.

utilizando a validação cruzada *10-fold* e as taxas são os valores de acerto do algoritmo dividido pelo número de classificações realizadas.

Os modelos ANN implementados são do tipo MLP criados com 1 camada oculta composta por 10 neurônios para ambos os dados (estatísticos e modais), definidos através de experimentos prévios para estes sinais. Por ter obtido melhores resultados de classificação, o método de otimização de Levenberg-Marquardt foi escolhido como função de treinamento, utilizando a média quadrática como métrica de erro e uma sigmóide logística como função de ativação. No que diz respeito aos modelos SVM, os melhores parâmetros σ e C foram selecionados através de um treinamento com diferentes valores deles em uma validação cruzada *10-fold*, utilizando uma RBF como kernel.

Tabela 3.6: Resultados considerando os indicadores estatísticos ($\sigma = 2,00$ e $C = 316,2278$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	87,09%	1,35%	90,36%	85,00%
SVM	80,24%	1,29%	82,86%	77,86%

O tempo máximo de processamento dos algoritmos nesta aplicação foi de 35 segundos. Ambos os modelos, ANN e SVM, alcançaram taxas satisfatórias de classificação, porém

Tabela 3.7: Resultados considerando os parâmetros modais ($\sigma = 0,0794$ e $C = 1,00$).

	Média	Desvio-padrão	Melhor classificação	Pior classificação
ANN	99,88%	0,65%	100,00%	96,43%
SVM	99,80%	0,35%	100,00%	98,57%

as taxas de classificação alcançadas via dados modais foram superiores às obtidas pelos indicadores estatísticos, especialmente as do método SVM, que atingiram 100% de acerto com desvio-padrão de 0. Isto pode ser explicado pelas variações expressivas da primeira e quarta frequências naturais quando comparadas às restantes, como pode ser observado na Figura 3.12.




Figura 3.12: Variação das frequências naturais da ponte ferroviária antes e depois do reforço estrutural.

4 NOVA ESTRATÉGIA PARA DETECÇÃO DE ALTERAÇÕES ESTRUTURAIS

4.1 Metodologia

O interesse na investigação da influência dos efeitos ambientais sobre o comportamento estrutural tem levado ao desenvolvimento de programas de monitoramento dinâmico com o objetivo de detectar e avaliar possíveis anomalias. Hoje em dia, o monitoramento contínuo tem sido mais utilizado, especialmente para estruturas de grande porte. O viaduto de Millau, na França, a ponte Tsing Ma, na China são alguns exemplos. Em todos estes casos, as respostas estruturais sob carga ambiente e a temperatura são normalmente registradas. Dessa forma, propõe-se neste capítulo uma nova técnica de detecção de alterações estruturais baseada nas frequências naturais que pode ser utilizada diretamente em estruturas com sistemas SHM.

Considerando-se o histórico de acelerações e temperaturas de um monitoramento estrutural em tempo integral, os passos da nova estratégia podem ser estabelecidos:

1. Admitindo-se T como o tempo total da análise, o parâmetro de discretização N deve ser estabelecido, tal que

$$\Delta t = \frac{T}{N} \quad (4.1)$$

onde o tamanho de cada intervalo de tempo é dado por Δt , e:

$$\sum_{i=1}^N \Delta t_i = T \quad (4.2)$$

O esquema de discretização do tempo é ilustrado na Figura 4.1.

2. A identificação modal é realizada para cada intervalo de tempo Δt_i . Posteriormente, as frequências identificadas durante cada Δt_i são atribuídas à matriz \mathbf{F} de elementos $F_{i,j}$, cujas linhas i estão relacionadas ao respectivo Δt_i e as colunas j à j -ésima




Figura 4.1: Discretização do tempo.

frequência natural. A temperatura média do período Δt_i é definida como Γ_i , agrupada no vetor $\mathbf{\Gamma}$.

3. O próximo passo é definir as submatrizes de frequência \mathbf{f}_{und} , \mathbf{f}_{dam} e os subvetores de temperatura γ_{und} , γ_{dam} :

$$\mathbf{f}_{und} = \mathbf{F}_{(u\dots u+n-1),(1\dots j)} \quad (4.3)$$

$$\mathbf{f}_{dam} = \mathbf{F}_{(d\dots d+n-1),(1\dots j)} \quad (4.4)$$

$$\gamma_{und} = \mathbf{\Gamma}_{(u\dots u+n-1)} \quad (4.5)$$

$$\gamma_{dam} = \mathbf{\Gamma}_{(d\dots d+n-1)} \quad (4.6)$$

onde n é o número de linhas das submatrizes \mathbf{f}_{und} e \mathbf{f}_{dam} e $d = u + n$. A nomenclatura adotada $\mathbf{M}_{(l_i\dots l_f),(c_i\dots c_f)}$ significa submatriz da matriz \mathbf{M} incluindo as linhas de l_i à l_f e as colunas de c_i à c_f .

4. A partir deste momento, assume-se que a matriz \mathbf{f}_{und} e o vetor γ_{und} foram obtidos com a estrutura sem danos e que \mathbf{f}_{dam} e γ_{dam} foram adquiridos com a estrutura já danificada.
5. Ao aplicar um classificador baseado em SVM para os dados das duas classes consideradas (estrutura não danificada - índice u ; estrutura danificada - índice d), espera-se que o algoritmo seja capaz de distinguir corretamente os comportamentos estruturais (com e sem dano). Assim, se o algoritmo falha em diferenciar ambas as classes, isso indica que todos os dados são do mesmo tipo, ambos provenientes da estrutura sem dano, por exemplo. Portanto, admitindo-se a integridade da estrutura no início da aplicação do método, isto representa que nenhum dano foi detectado. Por outro lado, se o algoritmo detectar satisfatoriamente as duas classes, isso indica

a presença de dano na estrutura.

Para um problema de duas classes, as falhas nas previsões SVM são levadas em conta se cerca de 50 % dos dados de teste forem erroneamente previstos. Logo, não é possível diferir as duas classes assumidas e, conseqüentemente, nenhuma alteração é detectada. Dessa forma, com base nos gráficos que serão mostrados mais adiante, admite-se aqui que o dano só é considerado se a taxa de classificações corretas do SVM estiver acima de 90%.

No presente trabalho, aplica-se um modelo SVM com função de base radial implementado no Matlab[®]. Para cada classificação SVM, 2/3 dos dados são utilizados na fase de treino e 1/3 na fase de teste. As matrizes e os vetores de entrada são calculados como seguem:

for $u = 1$ **to** R (R é o número de análises)

$$\mathbf{f}_{und} = \mathbf{F}_{(u\dots u+n-1),(1\dots j)}$$

$$\mathbf{f}_{dam} = \mathbf{F}_{(d\dots d+n-1),(1\dots j)}, \text{ sendo } d = u+n$$

$$\gamma_{und} = \mathbf{\Gamma}_{(u\dots u+n-1)}$$

$$\gamma_{dam} = \mathbf{\Gamma}_{(d\dots d+n-1)}$$

$$SVM_{struct}(\mathbf{f}_{und}, \mathbf{f}_{dam}, \gamma_{und}, \gamma_{dam})$$

end

Ressalta-se que este algoritmo permite verificar em qual instante o dano acontece. A Figura 4.2 mostra uma representação gráfica dos dados para $R = 4$ e $n = 3$.

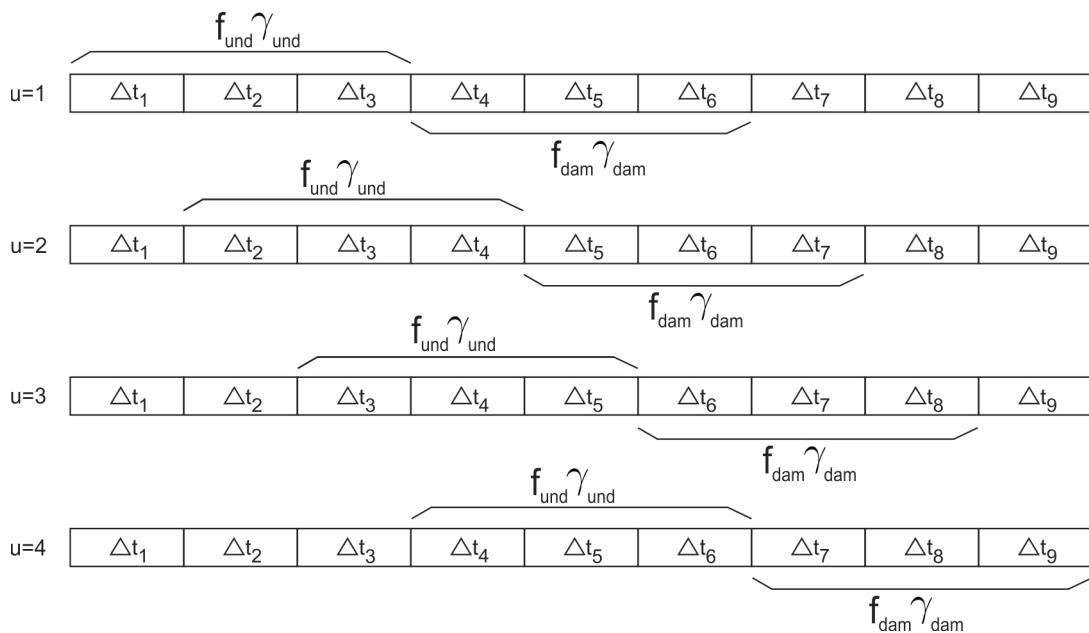


Figura 4.2: Ilustração da estratégia adotada para identificar alterações estruturais.

4.2 Resultados

4.2.1 Viga biapoiada - Modelo numérico

O histórico de frequências e temperaturas de uma simulação de monitoramento contínuo estrutural é utilizado para demonstrar a viabilidade da metodologia proposta neste capítulo. Para isto, considerou-se um modelo numérico de viga biapoiada, feita de aço, com 6m de comprimento e seção transversal de perfil I. O modelo, ilustrado na Figura 4.3, é constituído por uma malha de 10 elementos finitos formados por dois nós com dois graus de liberdade cada um (translação vertical e rotação).




Figura 4.3: Modelo numérico da viga biapoiada.

Na tentativa de reproduzir a influência da temperatura no comportamento estrutural, ao se modelar a viga, considerou-se o módulo de elasticidade em função da temperatura do aço conforme Eq.(4.7), extraída do trabalho de Callister (2007)[60]:

$$E(T) = -0,0002938T^4 + 0,1066T^3 - 89,035T^2 - 76581T + 205,83 \times 10^6 \quad (4.7)$$

onde E é o módulo de elasticidade em MPa do aço e T a temperatura em graus Celsius. Na Figura 4.4 é mostrada a relação entre a temperatura e módulo de elasticidade de materiais metálicos, bem como o gráfico da curva obtido a partir da Eq.(4.7).

Foram geradas temperaturas variando de acordo com o mês e a hora do dia, segundo as Tabelas 4.1 e 4.2 (Figura 4.5). Admitiu-se ainda uma variação aleatória de temperatura em cada hora do dia de $\pm 5^\circ$, a fim de se obter um cenário mais próximo do real.

Além do módulo de elasticidade (Eq.(4.7)), foram também estabelecidas as seguintes propriedades mecânicas:

- Massa específica = 7850 kg/m^3 ;
- Área de seção transversal = $8,45 \times 10^{-3} \text{ m}^2$;
- Momento de inércia = $1,3946 \times 10^{-5} \text{ m}^4$.




Figura 4.4: Influência da temperatura no módulo de elasticidade dos materiais metálicos (a) Módulo de elasticidade em função da temperatura para alumínio, aço e tungstênio (adaptado de Callister (2007)[60]); (b) Módulo de elasticidade em função da temperatura através da Eq.(4.7) (extraído de Bonifácio et al. (2013)[61]).

Tabela 4.1: Temperatura média de janeiro a dezembro às 9hs.

Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
27	28	27	24	23	21	21	23	24	24	25	26

Tabela 4.2: Variação da temperatura ao longo do dia.

00hs	01hs	02hs	03hs	04hs	05hs	06hs	07hs	08hs	09hs	10hs	11hs
0,80	0,75	0,71	0,70	0,75	0,80	0,85	0,90	0,95	1	1,05	1,10
12hs	13hs	14hs	15hs	16hs	17hs	18hs	19hs	20hs	21hs	22hs	23hs
1,20	1,30	1,40	1,30	1,2	1	0,95	0,90	0,80	0,80	0,80	0,80

Com o propósito de simular as vibrações ambientes (tráfego de veículos, por exemplo), considerou-se uma massa de 1% da massa total da estrutura, com posição variando aleatoriamente ao longo da viga. Dois meses de monitoramento contínuo foram simulados (maio - junho), resultando em 1440 sinais (24h×60dias). De forma a representar a ocorrência de dano, uma redução de 20% no módulo de elasticidade foi introduzida no meio do vão da viga a partir do tempo médio de monitoramento (1º de junho).

O conjunto de dados foi discretizado com $N = 1440$ e $\Delta t = 1$ hora. Adotou-se para a classificação $n = 200$. Os dados de Δt_1 à Δt_{720} correspondem aos sinais sem redução no módulo de elasticidade, o dado Δt_{721} representa o sinal obtido no momento da redução e, os dados de Δt_{722} à Δt_{1440} estão associados aos sinais gerados após a redução. As cinco primeiras frequências naturais e a temperatura de cada Δt_i são utilizadas para formar a matriz \mathbf{F} e o vetor $\mathbf{\Gamma}$, respectivamente. A variação da temperatura e das frequências

naturais em função do tempo são mostradas nas Figuras 4.5 e 4.6 respectivamente.

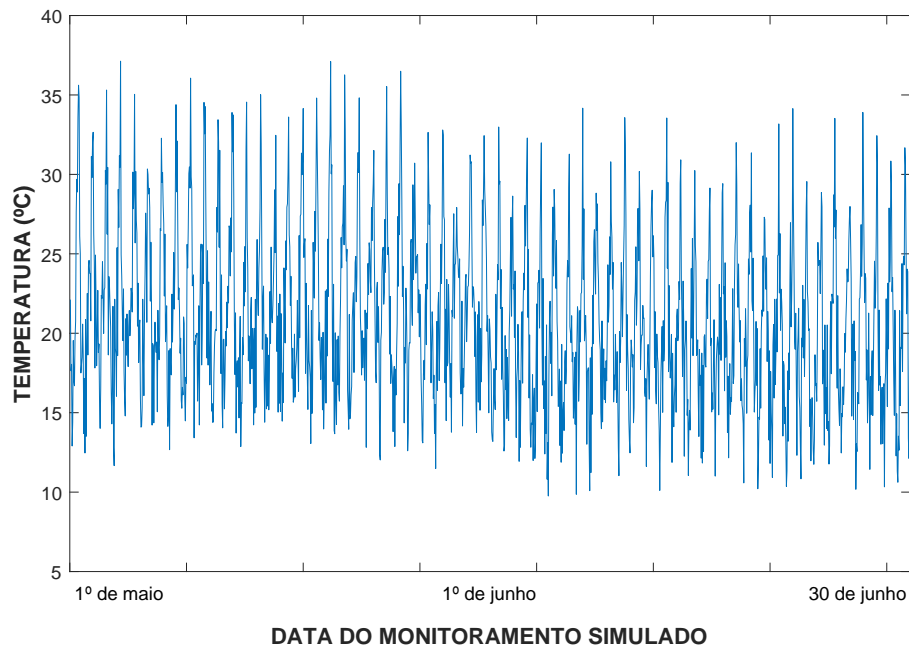


Figura 4.5: Variação da temperatura ao longo do tempo para o modelo numérico de viga.

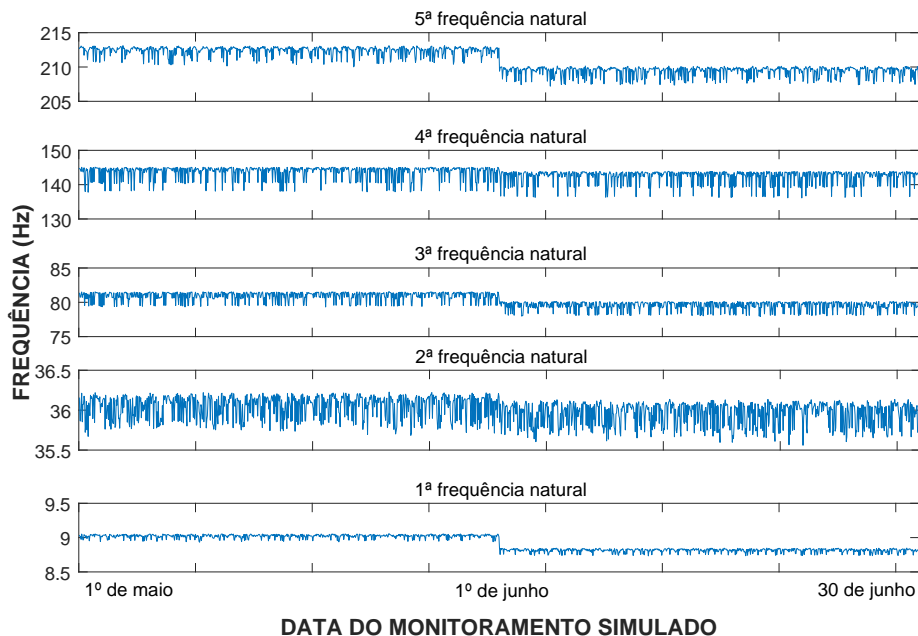


Figura 4.6: Variação das frequências naturais ao longo do tempo para o modelo numérico de viga.

Os resultados obtidos para cada frequência são mostrados nas Figuras 4.7, 4.8 e 4.9. O número de análises nesta aplicação foi de $R = 1041$. Em vista de facilitar a

compreensão do leitor, os tempos chaves d associados à $u+n-1$ (fim dos dados assumidos como não danificados) e à $u+n$ (início dos dados assumidos como danificados) foram representados no eixo horizontal dos gráficos, deixando claro o momento em que o dano ocorreu. O algoritmo SVM foi implementado utilizando como kernel a função RBF, em que os parâmetros σ e C foram escolhidos através do treinamento para diferentes valores deles em uma validação cruzada *10-fold* empregando-se o procedimento de busca exaustiva *Grid Search* apresentado na seção 2.2.

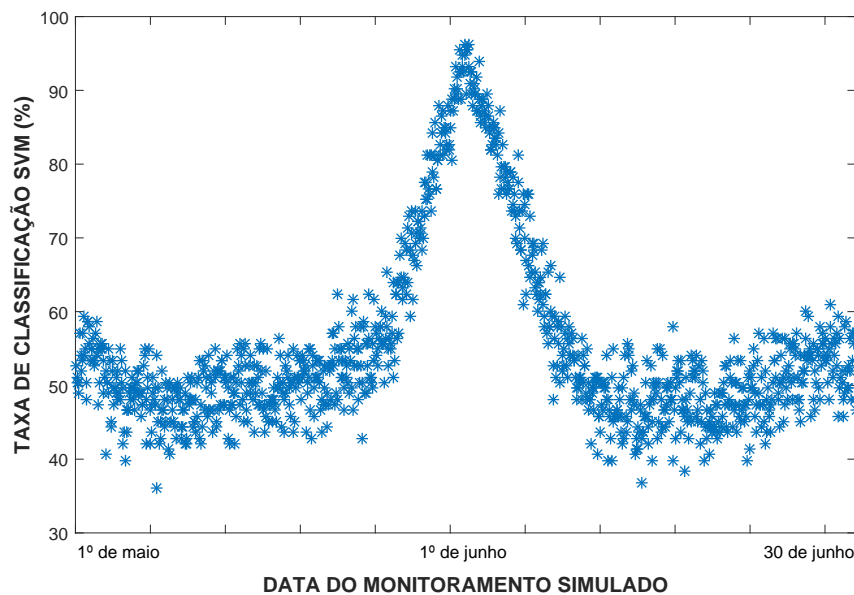


Figura 4.7: Detecção do dano estrutural - 1ª frequência natural do modelo de viga ($\sigma = 0,3162$ e $C=2,00$).

É possível verificar que os resultados associados às frequências #1, #3, #4 e #5 apresentam o mesmo comportamento, que podem ser divididos em três partes distintas:

- *Detecções em torno de 50% a 70%*. Observa-se que o algoritmo falha ao distinguir as duas condições assumidas (com e sem dano), indicando assim que não há alteração na integridade da estrutura para o momento em questão.
- *Detecções em torno de 70% a 80%*. Valores dentro desta faixa de classificação indicam possíveis alterações na integridade estrutural.
- *Detecções acima de 80%*. Neste caso, as taxas de classificação apontam para modificações no comportamento da estrutura, o que pode indicar que algum dano ocorreu naquele momento. Nota-se claramente que o pico nos gráficos dos resultados coincidem com o momento em que reduziu-se o módulo de elasticidade da viga.

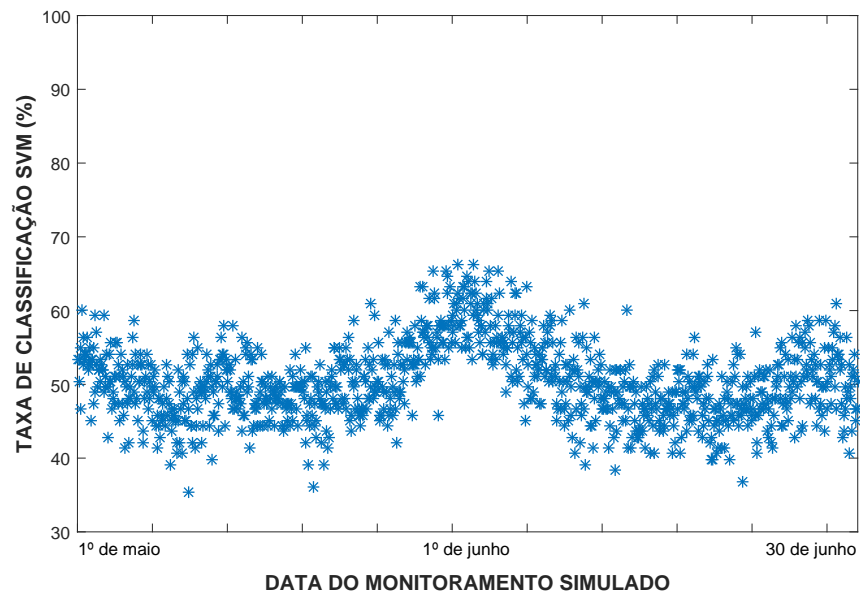


Figura 4.8: Detecção do dano estrutural - 2ª frequência natural do modelo de viga ($\sigma = 0,3981$ e $C=316,2278$).




Figura 4.9: Detecção do dano estrutural - 3ª frequência natural do modelo de viga ($\sigma = 0,7943$ e $C=316,2278$).

Como a estratégia proposta de detecção é realizada em um esquema do tipo “janela”, a taxa de acerto do SVM aumenta conforme a aproximação do momento em que ocorre a alteração estrutural (pontual), uma vez que o deslocamento da “janela” faz com que a cada análise sejam incluídos dados que realmente são diferentes (com redução de rigidez).

Apesar de se notar uma pequena variação das taxas de classificação no dia 1º de




Figura 4.10: Detecção do dano estrutural - 4ª frequência natural do modelo de viga ($\sigma = 0,50$ e $C=316,2278$).




Figura 4.11: Detecção do dano estrutural - 5ª frequência natural do modelo de viga ($\sigma = 0,3981$ e $C=0,50$).

junho, percebe-se que o algoritmo proposto não foi eficiente em classificar os dois estados estruturais quando utilizada a 2ª frequência natural. Tal fato pode ser explicado pela forma de vibração associada à esta frequência, que não é significativamente influenciada por alterações e cargas presentes no meio do vão, como é o caso da redução de rigidez imposta à viga.

4.2.2 Torre de Gabbia - Aplicação com dados experimentais

Nesta seção, a metodologia apresentada é avaliada através dos dados de monitoramento da Torre de Gabbia, em Mantova na Itália, mostrada na Figura 4.12. Construída no século XII, a estrutura investigada tem 54m de altura e é um símbolo do patrimônio cultural de Mantova.



Figura 4.12: Torre de Gabbia (extraído de Saisi & Gentile (2015)[62] e Saisi et al. (2015)[63]).

Devido à sequência sísmica ocorrida em maio de 2012, um extenso programa de pesquisa foi realizado com a intenção de avaliar a condição estrutural da torre [62, 63]. O presente trabalho utiliza dados experimentais extraídos de 44 dias de monitoramento contínuo (1056hs), a partir de junho de 2013, cedidos gentilmente pelo professor Carmelo Gentile da *Politecnico di Milano*. A instrumentação instalada na torre consiste em uma placa de aquisição de dados de 4 canais, 3 acelerômetros piezoelétricos com sensibilidade 10 V/g e 1 sensor de temperatura. Um arquivo binário contendo a resposta de 3 acelerômetros (frequência de amostragem de 200Hz) e a temperatura é criado a cada hora e armazenado em um computador no local, onde é transmitido à *Politecnico di Milano* para ser posteriormente processado. Em 21 de junho de 2013, a estrutura em questão foi submetida a um intenso evento sísmico, correspondente ao terremoto registrado na região de Garfagnana, na Toscana. Após este evento, detectou-se um dano estrutural, caracterizado por uma sutil redução da frequência natural dos modos principais [63].

Na técnica proposta, os dados são organizados utilizando $N = 1056$ e $\Delta t = 1$ hora. Os dados de Δt_1 à Δt_{492} correspondem aos sinais medidos antes do terremoto, Δt_{493} está relacionado à resposta obtida durante o abalo sísmico e, os dados restantes, de Δt_{494} à Δt_{1056} , estão associados ao tempo depois do terremoto. A matriz \mathbf{F} é formada a partir das frequências naturais de cada Δt_i , extraídas através de um procedimento automático [64] baseado em um algoritmo de Identificação Estocástica em Subespaços (SSI-Cov) [65]. O vetor $\mathbf{\Gamma}$ é calculado para a média das temperaturas de cada hora analisada. As cinco primeiras frequências naturais da torre foram identificadas entre 1Hz e 10Hz. A 1ª frequência natural apareceu em 975 dados Δt_i , a 2ª em 836, a 3ª em 347, a 4ª em 722 e a 5ª em 854. Por ter alcançado melhores resultados, adotou-se o $n = 200$, e por esta razão a 3ª não pôde ser considerada neste estudo já que, neste caso, é necessário no mínimo 400 dados para se realizar uma análise. Os gráficos da variação da temperatura e das frequências são apresentados nas Figuras 4.13 e 4.14, respectivamente.

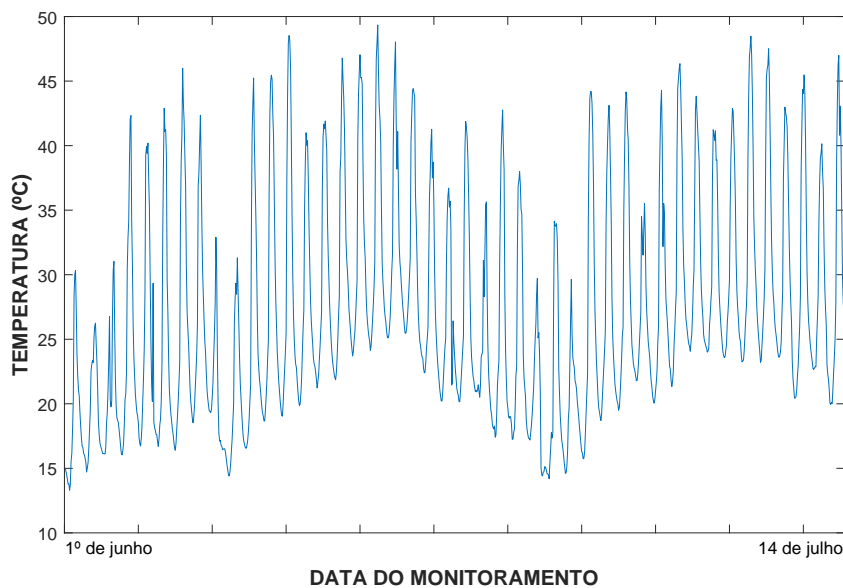


Figura 4.13: Variação da temperatura ao longo do tempo para a torre.

Devido à quantidade de dados das frequências não serem os mesmos, o método de detecção foi aplicado utilizando separadamente cada frequência j . Os resultados obtidos são mostrados nas Figura 4.15, 4.16, 4.17 e 4.18.

Tal como na aplicação da viga numérica, observa-se que os resultados da torre apresentam o mesmo comportamento entre si, e podem ser interpretados da seguinte maneira:

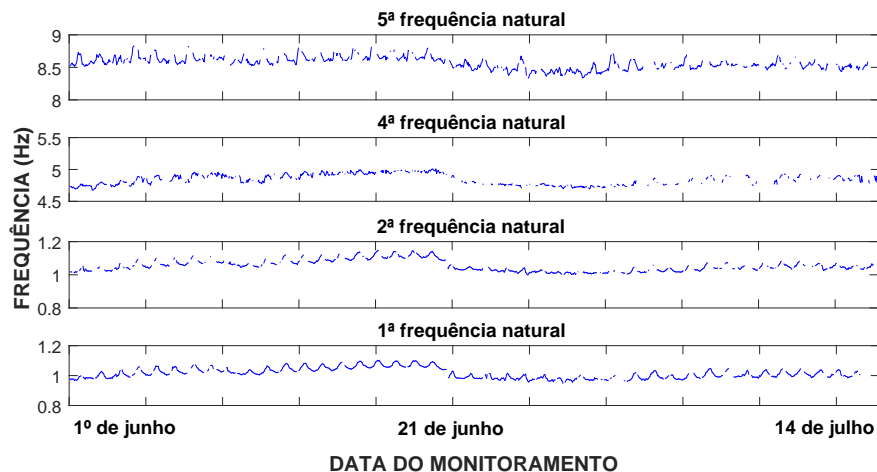


Figura 4.14: Variação das frequências naturais para os dados para a torre.

- *Detecções em torno de 50% a 80%.* Observa-se que o algoritmo falha ao distinguir as duas condições assumidas (com e sem dano), indicando assim que não há alteração na integridade da estrutura para os dias em questão.
- *Detecções em torno de 80% a 90%.* Denotam possíveis alterações na integridade estrutural.
- *Detecções acima de 90%.* Neste caso, as taxas de classificação apontam para modificações no comportamento da estrutura, o que pode indicar que algum dano ocorreu naquele momento. Desta forma, o pico nos gráficos dos resultados deixam claro o momento do terremoto.

Os gráficos obtidos se mostraram condizentes com a situação de dano da torre, sendo possível verificar que houve alguma alteração estrutural e, ainda, identificar o momento em que ocorreu. Nota-se que as taxas de acerto para o caso da torre oscilaram mais do que as taxas alcançadas pelo modelo numérico de viga. Essa diferença de comportamento entre as duas aplicações pode ser atribuída ao fato de que os dados da torre possuem influência de outros fatores, decorrentes dos próprios ensaios experimentais, efeitos operacionais e ambientais (além da temperatura), que não foram considerados no modelo de estrutura numérico.

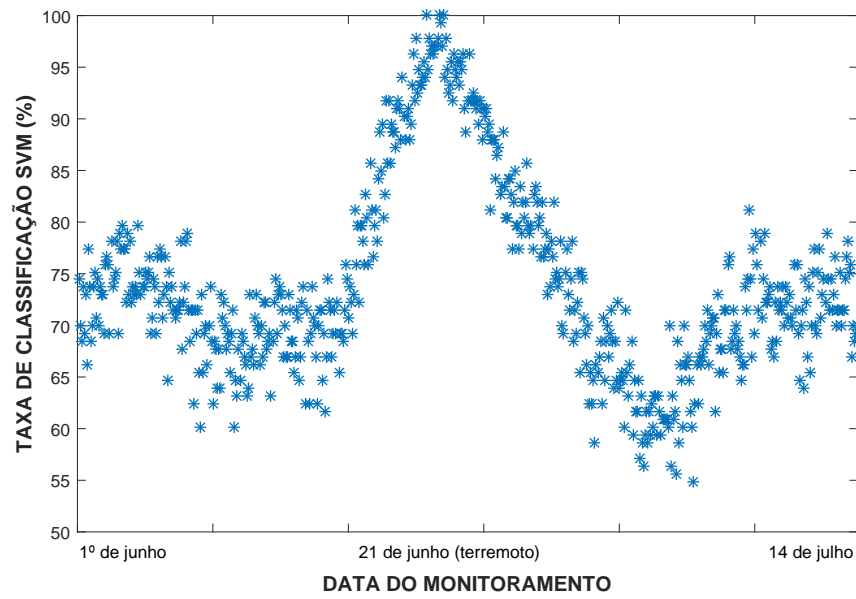


Figura 4.15: Detecção do dano estrutural - 1ª frequência natural da torre ($R = 576$; $\sigma = 2,00$ e $C=316,2278$).




Figura 4.16: Detecção do dano estrutural - 2ª frequência natural da torre ($R = 437$; $\sigma = 3,00$ e $C=316,2278$).




Figura 4.17: Detecção do dano estrutural - 4ª frequência natural da torre ($R = 323$; $\sigma = 4, 50$ e $C=100,00$).




Figura 4.18: Detecção do dano estrutural - 5ª frequência natural da torre ($R = 455$; $\sigma = 4, 50$ e $C=316,2278$).

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho concentrou-se na avaliação de Redes Neurais Artificiais e Máquinas de Vetor Suporte aplicadas ao problema de detecção de danos e alterações em estruturas. Modelos computacionais de predição de danos foram criados tendo como parâmetros de entrada propriedades modais ou indicadores estatísticos extraídos das respostas dinâmicas no domínio do tempo. O presente estudo investigou tais abordagens utilizando sinais gerados numericamente por um modelo de viga, sinais provenientes de um protótipo de laje e dados advindos de um ensaio experimental em uma ponte ferroviária.

Para ambos os métodos computacionais, as características modais alcançaram melhores resultados do que os indicadores estatísticos, inclusive quando se tratou de respostas dinâmicas curtas, como pode ser visto no caso da laje, em que os algoritmos não conseguiram reconhecer nenhum padrão nos dados de parâmetros estatísticos, cuja média de acerto ficou em torno de 50% (contra a média de 97% dos dados modais). Para uma resposta relativamente mais longa (situação da viga e da ponte), os dois tipos de dados possuíram taxas de classificação satisfatórias (acima de 80%). Nesses casos, os indicadores foram capazes de caracterizar os dados, identificando pequenas diferenças entre as configurações estruturais. Ressalta-se que na aplicação da ponte ferroviária, a diferença entre os resultados obtidos pelas entradas modais e estatísticas chegou a quase 20% para o algoritmo SVM.

Apesar de ambos os métodos computacionais se mostraram eficientes nas classificações, os algoritmos SVM tiveram desempenho ligeiramente melhor do que os ANN, com relativo baixo custo computacional, com exceção dos resultados da ponte, em que para o mesmo conjunto de dados de entrada, a porcentagem de identificações corretas do modelo ANN (87,09%) foi maior do que a do SVM (80,24%).

Destaca-se ainda, que além da avaliação dos métodos citados anteriormente, uma nova metodologia para detecção de alterações estruturais foi apresentada neste trabalho. A estratégia proposta consiste em utilizar o histórico das frequências naturais e das medições de temperatura como parâmetros de entrada de um algoritmo SVM, onde duas classes são

assumidas ao longo do tempo: estrutura danificada e não-danificada. Considerando-se a integridade estrutural no início do monitoramento, se o algoritmo não distinguir ambas as classes, significa que os dados são do mesmo tipo, logo, não há alteração estrutural. Caso contrário, se o algoritmo detectar com êxito as duas classes, significa que houve alteração estrutural. Com o intuito de validar a metodologia proposta foram utilizados dados simulados em um modelo numérico de viga e dados de um monitoramento contínuo realizado em uma torre. Estes dados contém o registro do comportamento estrutural antes, durante e depois da ocorrência de dano.

Analisando-se os resultados das duas aplicações, nota-se que os gráficos obtidos se mostraram condizentes com a situação de dano imposta à viga e com a situação real da torre. Assim, é possível verificar que a nova metodologia proposta foi eficiente em detectar as mudanças estruturais, já que os danos e os momentos em que ocorreram puderam ser claramente identificados. Dessa forma, a nova técnica pode auxiliar no gerenciamento de sistemas SHM, já que a partir dela o operador da estrutura pode identificar alterações e providenciar vistorias a fim de verificar possíveis danos.

As considerações anteriores encorajam o desenvolvimento de ferramentas computacionais para a avaliação de danos. Estudos desse tipo possuem grande utilidade dentro da área de monitoramento estrutural por fornecer informações da integridade de uma estrutura, a fim de evitar falhas e garantir a segurança de seus usuários.

No que tange a nova metodologia, é necessária uma maior investigação para viabilizar sua aplicação, onde diversos pontos têm que ser analisados. Portanto, objetiva-se em trabalhos futuros:

- Verificar o desempenho do método em outros tipos de estruturas e excitações;
- Utilizar as cinco primeiras frequências naturais em conjunto como entrada do algoritmo, incluindo um peso para cada parâmetro;
- Testar o uso de indicadores estatísticos como parâmetros de entrada do algoritmo;
- Incorporar um índice quantitativo baseado nas taxas de classificação para garantir maior confiabilidade ao método;
- Avaliar a estratégia fixando os dados assumidos como não-danificados (estado de referência inicial);

- Verificar a real influência da temperatura, através de testes com métodos que eliminam os efeitos das condições ambientais.
- Testar o uso de algoritmos de aprendizado online, e não em *batch*.

REFERÊNCIAS

- [1] Disponível em: <http://operamundi.uol.com.br/conteudo/reportagens/42318/>, acessado em 15 de fevereiro de 2017.
- [2] BATTISTA, R., PFEIL, M., “Reduction of vortex-induced oscillations of Rio–Niterói bridge by dynamic control devices”, *Journal of Wind Engineering and Industrial Aerodynamics*, v. 84, n. 3, pp. 273–288, 2000.
- [3] NI, Y., XIA, H., WONG, K., KO, J., “In-service condition assessment of bridge deck using long-term monitoring data of strain response”, *Journal of Bridge Engineering*, v. 17, n. 6, pp. 876–885, 2011.
- [4] CACHOT, E., VAYSSADE, T., VIRLOGEUX, M., LANCON, H., HAJAR, Z., SERVANT, C., “The Millau Viaduct: Ten Years of Structural Monitoring”, *Structural Engineering International*, v. 25, n. 4, pp. 375–380, 2015.
- [5] Disponível em <http://mgturismo.com.br/2016/08/16/wi-fi-na-ponte-rio-niteroi/>, acessado em 15 de fevereiro de 2017.
- [6] Disponível em: http://www.huffingtonpost.com/fodors/worlds-most-beautiful-bri_b_6523622.html, acessado em 15 de fevereiro de 2017.
- [7] Disponível em: <http://www.engenhariaeconstrucao.com/2011/02/viaduto-de-millau.html>, acessado em 15 de fevereiro de 2017.
- [8] MCCANN, D., FORDE, M., “Review of NDT methods in the assessment of concrete and masonry structures”, *Ndt & E International*, v. 34, n. 2, pp. 71–84, 2001.
- [9] REHMAN, S., IBRAHIM, Z., MEMON, S., JAMEEL, M., “Nondestructive test methods for concrete bridges: A review”, *Construction and Building Materials*, v. 107, pp. 58–86, 2016.
- [10] ALVANDI, A., CREMONA, C., “Assessment of vibration-based damage identification techniques”, *Journal of Sound and Vibration*, v. 292, n. 1, pp. 179–202, 2006.

- [11] FAN, W., QIAO, P., “Vibration-based damage identification methods: a review and comparative study”, *Structural Health Monitoring*, v. 10, n. 1, pp. 83–111, 2011.
- [12] SHIH, H., THAMBIRATNAM, D., CHAN, T., “Damage detection in slab-on-girder bridges using vibration characteristics”, *Structural Control and Health Monitoring*, v. 20, n. 10, pp. 1271–1290, 2013.
- [13] DOEBLING, S., FARRAR, C., PRIME, M., SHEVITZ, D., “Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review”, 2006.
- [14] ALVES, V., CURY, A., ROITMAN, N., MAGLUTA, C., CREMONA, C., “Novelty detection for SHM using raw acceleration measurements”, *Structural Control and Health Monitoring*, v. 22, n. 9, pp. 1193–1207, 2015.
- [15] ALLEMANG, R., “The modal assurance criterion—twenty years of use and abuse”, *Sound and Vibration*, v. 37, n. 8, pp. 14–23, 2003.
- [16] CURY, A., BORGES, C., BARBOSA, F., “A two-step technique for damage assessment using numerical and experimental vibration data”, *Structural Health Monitoring*, v. 10, n. 4, pp. 417–428, 2011.
- [17] PANDEY, A., BISWAS, M., SAMMAN, M., “Damage detection from changes in curvature mode shapes”, *Journal of sound and vibration*, v. 145, n. 2, pp. 321–332, 1991.
- [18] PANDEY, A., BISWAS, M., “Damage detection in structures using changes in flexibility”, *Journal of Sound and Vibration*, v. 169, n. 1, pp. 3–17, 1994.
- [19] ALVES, V., *Técnicas de anormalidade aplicadas à detecção de danos estruturais*. Tese de doutorado, Universidade Federal de Ouro Preto, 2016.
- [20] CURY, A., *Techniques d’anormalité appliquées à la surveillance de santé structurale*, Ph.D. Thesis, Université Paris-Est, 2010.
- [21] IWASAKI, A., TODOROKI, A., SHIMAMURA, Y., KOBAYASHI, H., “An unsupervised statistical damage detection method for structural health

- monitoring (applied to detection of delamination of a composite beam)”, *Smart materials and structures*, v. 13, n. 5, pp. N80, 2004.
- [22] FARRAR, C., WORDEN, K., *Structural health monitoring: a machine learning perspective*. John Wiley & Sons, 2012.
- [23] ALVES, V., CURY, A., ROITMAN, N., MAGLUTA, C., C., C., “Structural modification assessment using supervised learning methods applied to vibration data”, *Engineering Structures*, v. 99, pp. 439–448, 2015.
- [24] LI, F., MENG, G., YE, L., CHEN, P., “Wavelet transform-based higher-order statistics for fault diagnosis in rolling element bearings”, *Journal of Vibration and Control*, v. 14, n. 11, pp. 1691–1709, 2008.
- [25] CURY, A., CREMONA, C., “Pattern recognition of structural behaviors based on learning algorithms and symbolic data concepts”, *Structural Control and Health Monitoring*, v. 19, n. 2, pp. 161–186, 2012.
- [26] DE LA ROSA, J., AGÜERA-PÉREZ, A., PALOMARES-SALAS, J., MORENO-MUÑOZ, A., “Higher-order statistics: Discussion and interpretation”, *Measurement*, v. 46, n. 8, pp. 2816–2827, 2013.
- [27] PEETERS, B., MAECK, J., DE ROECK, G., “Vibration-based damage detection in civil engineering: excitation sources and temperature effects”, *Smart materials and Structures*, v. 10, n. 3, pp. 518–527, 2001.
- [28] RAMOS, L., MARQUES, L., LOURENÇO, P., DE ROECK, G., CAMPOS-COSTA, A., ROQUE, J., “Monitoring historical masonry structures with operational modal analysis: two case studies”, *Mechanical Systems and Signal Processing*, v. 24, n. 5, pp. 1291–1305, 2010.
- [29] XIA, Y., CHEN, B., WENG, S., NI, Y., XU, Y., “Temperature effect on vibration properties of civil structures: a literature review and case studies”, *Journal of civil structural health monitoring*, v. 2, n. 1, pp. 29–46, 2012.
- [30] REYNDERS, E., WURSTEN, G., DE ROECK, G., “Output-only structural health monitoring in changing environmental conditions by means of nonlinear system identification”, *Structural Health Monitoring*, v. 13, n. 1, pp. 82–93, 2014.

- [31] RYTTER, A., *Vibrational based inspection of civil engineering structures*, Ph.D. Thesis, Denmark: Department of Building Technology and Structural Engineering, Aalborg University, 1993.
- [32] CAWLEY, P., ADAMS, R., “The location of defects in structures from measurements of natural frequencies”, *The Journal of Strain Analysis for Engineering Design*, v. 14, n. 2, pp. 49–57, 1979.
- [33] FOX, C., “The location of defects in structures-A comparison of the use of natural frequency and mode shape data”. In: *10th International Modal Analysis Conference*, v. 1, pp. 522–528, 1992.
- [34] MESSINA, A., WILLIAMS, E., CONTURSI, T., “Structural damage detection by a sensitivity and statistical-based method”, *Journal of sound and vibration*, v. 216, n. 5, pp. 791–808, 1998.
- [35] PIMENTEL, R., FERREIRA, G., GONÇALVES, M., NYAWAKO, D., REYNOLDS, P., “Damage detection in concrete precast slabs: a quick assessment through modal tests”. In: *MATEC Web of Conferences*, v. 24, 2015.
- [36] ALLEMANG, R. J., BROWN, D., “A correlation coefficient for modal vector analysis”. In: *Proceedings of the 1st international modal analysis conference*, v. 1, pp. 110–116, 1982.
- [37] LIEVEN, N., EWINS, D., “Spatial correlation of mode shapes, the coordinate modal assurance criterion (COMAC)”. In: *Proceedings of the sixth international modal analysis conference*, v. 1, pp. 690–695, 1988.
- [38] NDAMBI, J., VANTOMME, J., DE VISSCHER, J., “Modal damping as a damage detection parameter in reinforced concrete structures”. In: *International conference on engineering computational technology*, pp. 1–7, 2000.
- [39] KAWIECKI, G., “Modal damping measurement for damage detection”, *Smart Materials and Structures*, v. 10, n. 3, pp. 466–471, 2001.
- [40] KIM, J., STUBBS, N., “Assessment of the relative impact of model uncertainty on the accuracy of global nondestructive damage detection in structures”, *Report prepared for New Mexico State University*, 1993.

- [41] CHANG, C., CHANG, T., XU, Y., WANG, M., “Structural damage detection using an iterative neural network”, *Journal of intelligent material systems and structures*, v. 11, n. 1, pp. 32–42, 2000.
- [42] ZANG, C., FRISWELL, M., IMREGUN, M., “Structural damage detection using independent component analysis”, *Structural Health Monitoring*, v. 3, n. 1, pp. 69–83, 2004.
- [43] WEN, C., HUNG, S., HUANG, C., JAN, J., “Unsupervised fuzzy neural networks for damage detection of structures”, *Structural Control and Health Monitoring*, v. 14, n. 1, pp. 144–161, 2007.
- [44] HARITOS, N., OWEN, J., “The use of vibration data for damage detection in bridges: a comparison of system identification and pattern recognition approaches”, *Structural Health Monitoring*, v. 3, n. 2, pp. 141–163, 2004.
- [45] WORDEN, K., LANE, A., “Damage identification using support vector machines”, *Smart Materials and Structures*, v. 10, n. 3, pp. 540, 2001.
- [46] NI, Y., HUA, X., FAN, K., KO, J., “Correlating modal properties with temperature using long-term monitoring data and support vector machine technique”, *Engineering Structures*, v. 27, n. 12, pp. 1762–1773, 2005.
- [47] OH, C., SOHN, H., “Damage diagnosis under environmental and operational variations using unsupervised support vector machine”, *Journal of Sound and Vibration*, v. 325, n. 1, pp. 224–239, 2009.
- [48] MOYO, P., BROWNJOHN, J., “Detection of anomalous structural behaviour using wavelet analysis”, *Mechanical Systems and Signal Processing*, v. 16, n. 2-3, pp. 429–445, 2002.
- [49] FINOTTI, R., BONIFÁCIO, A., BARBOSA, F., CURY, A., “Evaluation of computational intelligence methods using statistical analysis to detect structural damage”, *Mecánica Computacional*, v. 34, n. 22, pp. 1389–1397, 2016.
- [50] PRINCIPE, J., EULIANO, N., LEFEBVRE, W., *Neural and adaptive systems: fundamentals through simulations*. Wiley: London, 2000.

- [51] BISHOP, C., *Pattern recognition and machine learning*. Springer-Verlag, 2006.
- [52] HAGAN, M., MENHAJ, M., “Training feedforward networks with the Marquardt algorithm”, *IEEE transactions on Neural Networks*, v. 5, n. 6, pp. 989–993, 1994.
- [53] VAPNIK, V., *The nature of statistical learning theory*. Springer-Verlag, 1995.
- [54] KOHAVI, R., “A study of cross-validation and bootstrap for accuracy estimation and model selection”. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, v. 14, n. 2, pp. 1137–1145, 1995.
- [55] ALVES, V., *Estudo de novas estratégias para identificação de danos estruturais a partir de dados vibracionais..* Dissertação de mestrado, Universidade Federal de Ouro Preto, 2012.
- [56] HIBBELER, R., *Resistência dos materiais*. 7ª ed. Pearson Education do Brasil, 2010.
- [57] BARBOSA, F., “Identification Modale de Structures Sous Sollicitation Ambiante”, *Final Report, LCPC*, 2002.
- [58] DE SILVA, C., *Vibration: fundamentals and practice*. CRC press, 2006.
- [59] CURY, A., CREMONA, C., DIDAY, E., “Application of symbolic data analysis for structural modification assessment”, *Engineering Structures*, v. 32, n. 3, pp. 762–775, 2010.
- [60] CALLISTER, W., *Materials science and engineering: an introduction*. John Wiley & Sons, 2007.
- [61] BONIFACIO, A., BARBOSA, F., CURY, A., “Analyzing the reliability of two structural damage detection methods based on modal data”. In: *Proceedings of the International Conference on Experimental Vibration Analysis for Civil Engineering Structures*, pp. 339–346, 2013.
- [62] SAISI, A., GENTILE, C., “Post-earthquake diagnostic investigation of a historic masonry tower”, *Journal of Cultural Heritage*, v. 16, n. 4, pp. 602–609, 2015.

- [63] SAISI, A., GENTILE, C., GUIDOBALDI, M., “Post-earthquake continuous dynamic monitoring of the Gabbia Tower in Mantua, Italy”, *Construction and Building Materials*, v. 81, pp. 101–112, 2015.
- [64] CABBOI, A., *Automatic operational modal analysis: challenges and applications to historic structures and infrastructures*, Ph.D. Thesis, Università degli Studi di Cagliari, 2014.
- [65] PEETERS, B., DE ROECK, G., “Reference-based stochastic subspace identification for output-only modal analysis”, *Mechanical systems and signal processing*, v. 13, n. 6, pp. 855–878, 1999.