

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL**

Lorena Andrade Nunes

Detecção de dano em estruturas baseada em técnicas de aprendizado híbrido

Juiz de Fora

2020

Lorena Andrade Nunes

Detecção de dano em estruturas baseada em técnicas de aprendizado híbrido

Dissertação apresentada ao Programa de pós-graduação em Engenharia Civil, da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Civil. Área de concentração: Estruturas e Materiais.

Orientador: Prof. Dr. Alexandre Abrahão Cury

Coorientador: Prof. Dr. Flávio de Souza Barbosa

Juiz de Fora

2020

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

Nunes, Lorena Andrade.

Detecção de dano em estruturas baseada em técnicas de
aprendizado híbrido / Lorena Andrade Nunes. -- 2020.

120 f. : il.

Orientador: Alexandre Abrahão Cury

Coorientador: Flávio de Souza Barbosa

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz
de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em
Engenharia Civil, 2020.

1. Modificações estruturais. 2. Detecção de danos. 3.

Classificador híbrido. I. Cury, Alexandre Abrahão, orient. II. Barbosa ,
Flávio de Souza, coorient. III. Título.

Lorena Andrade Nunes

Detecção de dano em estruturas baseada em técnicas de aprendizado híbrido

Dissertação apresentada ao Programa de pós-graduação em Engenharia Civil, da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Civil. Área de concentração: Estruturas e Materiais.

Aprovada em 19 de fevereiro de 2020

BANCA EXAMINADORA


Prof. Dr. Alexandre Abrahão Cury - Orientador
Universidade Federal de Juiz de Fora


Prof. Dr. Flávio de Souza Barbosa - Coorientador
Universidade Federal de Juiz de Fora


Prof. Dr. Leonardo Goliatt da Fonseca
Universidade Federal de Juiz de Fora


(conforme ATA)
Prof. Dr. Cláudio José Martins
CEFET-MG

Dedico este trabalho à minha família.

AGRADECIMENTOS

Esta dissertação não é apenas o resultado de uma dedicação pessoal, mas também do incentivo emocional e intelectual que recebi, direta e indiretamente, de muitas pessoas ao decorrer desses últimos dois anos, pessoas as quais não poderia deixar de agradecer. Sendo assim, registro aqui meus mais sinceros agradecimentos:

Primeiramente a Deus e a Nossa Senhora, pois sem dúvidas me guiaram do início ao fim nessa jornada. Senti a presença de vocês em cada detalhe, cada decisão tomada, cada momento difícil e feliz. Obrigada por me fazerem forte e me darem a graça de poder realizar esse sonho. Hoje mais do que nunca sinto que há um momento certo para tudo nessa vida, e sei que estou onde deveria estar.

Ao meu pai Alcides, minha mãe Maria e ao meu irmão Lucas, por não medirem esforços para me ajudar, por sonharem meus sonhos junto comigo e me levantarem sempre nos momentos difíceis. Vocês são a base da minha vida, o motivo por eu querer ser melhor a cada dia. Obrigada por toda ajuda, por todos os conselhos e por sempre acreditarem em mim. Dedico essa vitória a vocês.

Ao meu namorado Vinícius por todo apoio, força e por sempre acreditar em meu potencial. Obrigada por sempre estar ao meu lado e me colocar para cima em todos os momentos. Você foi fundamental nessa etapa da minha vida.

Ao meu orientador Alexandre Cury o qual tenho imensa admiração, por toda confiança em mim depositada, por nunca medir esforços para me ajudar e por estar sempre presente. Agradeço imensamente por toda atenção dispensada às orientações, os conhecimentos transmitidos e por me dar a oportunidade de trabalhar com uma pessoa incrível como você. Sem dúvidas não chegaria até aqui sem a sua participação.

Ao meu coorientador Flávio Barbosa por toda atenção e colaboração no trabalho, por todo conhecimento transmitido ao longo desses anos e por estar disponível em todos os momentos. Tenho grande admiração por você e agradeço imensamente a oportunidade de trabalharmos juntos nesses últimos anos.

Aos meus amigos de longa data por todo apoio e confiança em mim e por estarem ao meu lado nos momentos de angustia e dificuldades. Agradeço também as amizades que conquistei ao longo do mestrado, em especial a Rafaelle e aos meus colegas de turma, por toda ajuda, motivação e companhia.

À minha cunhada e amiga Olívia, por sempre me receber tão bem em sua casa em Juiz de Fora nos momentos em que precisei. Obrigada por todo carinho e apoio.

Aos professores: George, Pedro e Marcelo, os quais tive o prazer de conviver. Obrigada por todo conhecimento transmitido.

Aos funcionários do Programa de Pós-graduação em Engenharia Civil, principalmente à Tatiana, pelo apoio e prontidão nas informações prestadas.

À Universidade Federal de Juiz de Fora e em especial ao Programa de Pós-graduação em Engenharia Civil, pela acolhida e por ter contribuído para uma das melhores experiências da minha vida. Quanto orgulho tenho em adquirir o meu título de Mestre em uma Instituição de conduta tão admirável, honrosa e respeitável.

À FAPEMIG pelo suporte financeiro.

RESUMO

As estruturas de engenharia estão frequentemente sujeitas a alterações em suas propriedades dinâmicas por conta de diversos fatores, tais como a deterioração da construção devido ao tempo de uso, a falta de manutenção, os efeitos ambientais e operacionais adversos, os carregamentos inesperados, os procedimentos de reforço estrutural, entre outros. Na maioria dos casos, essas modificações podem estar associadas a danos estruturais. O monitoramento contínuo do comportamento dinâmico de uma estrutura possibilita a investigação e a análise de alterações com o objetivo de assegurar sua integridade, garantindo maior conforto e segurança aos usuários, além de possibilitar ações mais eficazes de reparo e manutenção, impactando diretamente na redução dos custos operacionais. Para tanto, sistemas de monitoramento devem dispor de ferramentas computacionais aptas a avaliar as informações adquiridas em tempo real e continuamente. Nesta dissertação, uma nova abordagem baseada na análise direta de medições de aceleração para detectar danos e modificações estruturais utilizando técnicas de inteligência computacional é apresentada. A abordagem consiste na utilização em conjunto de métodos de classificação supervisionados (RNA) e não supervisionados (*k-means*) para a construção de um classificador híbrido. O objetivo é detectar não apenas estados de dano já conhecidos, mas também estados estruturais que ainda não foram identificados. A ideia é permitir, dessa forma, o monitoramento da integridade estrutural em tempo real, provendo respostas de forma automática e contínua, baseando-se apenas em testes vibracionais ambientes com a estrutura em operação. Para atestar a robustez dessa abordagem, dados oriundos de simulações numéricas e de ensaios experimentais realizados em laboratório e *in situ* são utilizados. Os resultados obtidos demonstram desempenho promissor da metodologia proposta.

Palavras-chave: Modificações estruturais. Detecção de danos. Classificador híbrido.

ABSTRACT

Engineering structures are often subject to changes in their dynamic properties due to various factors such as deterioration of construction due to time of use, the lack of maintenance, adverse environmental and operational effects, unexpected loads, structural reinforcement procedures, among others. In most cases, these modifications may be associated with structural damage. Continuous monitoring of the dynamic behavior of a structure makes it possible to investigate and analyze changes to ensure their integrity, ensuring greater comfort and safety for users and enabling more effective repair and maintenance actions, directly impacting the reduction of operating costs. For such, monitoring systems must have computational tools able to evaluate the acquired information in real time and continuously. In this dissertation, a new approach based on the direct analysis of acceleration measurements to detect structural damage and modifications using computational intelligence techniques is presented. The approach is to use together supervised (RNA) and unsupervised (k-means) classification methods to construct a hybrid classifier. The goal is to detect not only known damage states but also unidentified structural states. The idea is thus to allow the real-time monitoring of structural integrity, providing answers automatically and continuously, based only on vibrational testing environments with the structure in operation. To attest to the robustness of this approach, data from numerical simulations and experimental tests performed in the laboratory and in situ are used. The results show promising performance of the proposed methodology.

Keywords: Structural modifications. Damage Detection. Hybrid sorter.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ponte Morandi em Gênova.....	13
Esquema 1 – Esquema de funcionamento de um SHM.....	15
Figura 2 – Rede MLP com uma camada intermediária	31
Esquema 2 – Diagrama de um RNA com uma camada oculta.....	36
Figura 3 – Funções de ativação mais utilizadas	37
Esquema 3 – Funcionamento da validação cruzada k-fold	40
Figura 4 – Funcionamento do algoritmo <i>k-means</i>	44
Figura 5 – Exemplo da sensibilidade do <i>k-means</i> à seleção dos centroides iniciais	45
Esquema 4 – Funcionamento do algoritmo k-means++	47
Esquema 5 – Criação do modelo de detecção de danos proposto (1 ^a fase)	50
Esquema 6 – Classificação de novos ensaios dinâmicos (2 ^a fase)	51
Figura 6 – Representação da viga modelada	55
Figura 7 – Configurações de danos simulados	56
Gráfico 1 – Resposta típica do modelo numérico de viga	57
Figura 8 – Sistema da estrutura testada	67
Figura 9 – Imagem ampliada: (a) suporte e (b) posicionamento da massa	68
Figura 17 – Estrutura testada: (a) vista em planta e (b) vista leste.....	69
Figura 18 – Níveis de danos impostos a estrutura	70
Gráfico 2 – Histórico dos sinais de aceleração	70
Figura 12 – Vista geral do viaduto	81
Figura 21 – Detalhes do procedimento de reforço e dos mancais	82
Esquema 7 – Posição dos sensores sob o pavimento.....	83

LISTA DE TABELAS

Tabela 1 – Exemplos de falhas em pontes e suas causas.....	12
Tabela 2 – Estatísticas de alta ordem.....	27
Tabela 3 – Resumo dos ensaios simulados.....	56
Tabela 4 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)	59
Tabela 5 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em%)	61
Tabela 6 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)	63
Tabela 7 – Média de classificações corretas dos classificadores híbridos e das RNAs	64
Tabela 8 – Casos de danos impostos a estrutura	69
Tabela 9 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %)	73
Tabela 10 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %).....	75
Tabela 11 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %).....	78
Tabela 12 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %).....	79
Tabela 13 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %).....	85
Tabela 14 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %).....	87
Tabela 15 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %).....	89
Tabela 16 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %).....	90

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVO GERAL	16
1.1.1	Objetivos específicos	16
1.2	JUSTIFICATIVA.....	16
1.3	ORGANIZAÇÃO DO TEXTO.....	17
2	REVISÃO BIBLIOGRÁFICA.....	19
3	INDICADORES DE DANO E MÉTODOS DE CLASSIFICAÇÃO	25
3.1	INDICADORES DE DANO OBTIDOS A PARTIR DAS RESPOSTAS DINÂMICAS	25
3.2	MÉTODOS DE CLASSIFICAÇÃO.....	28
3.2.1	Redes Neurais Artificiais	28
3.2.2	Métodos de <i>clustering</i>	40
3.2.3	Determinação dos limites de associação aos <i>clusters</i>	47
4	METODOLOGIA	49
5	APLICAÇÕES.....	54
5.1	SIMULAÇÕES NUMÉRICAS.....	54
5.2	ANÁLISES EXPERIMENTAIS.....	66
5.2.1	Pórtico amarelo	66
5.2.2	Viaduto ferroviário PK 075+317	81
6	CONCLUSÕES	92
6.1	RECOMENDAÇÕES	95
6.2	TRABALHOS FUTUROS.....	95
	REFERÊNCIAS	97
	APÊNDICE A – Comparação das métricas e formas de inicialização dos centroides do algoritmo <i>k-means</i> no método híbrido	102

APÊNDICE B – Resultados obtidos com o método híbrido considerando a probabilidade igual a 90%	104
APÊNDICE C – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 97,5% e a 85%	108
APÊNDICE D – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 97,5% e a 85%	110
APÊNDICE E – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85%	112
APÊNDICE F – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 97,5% e a 85%	114
APÊNDICE G – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85%	115
APÊNDICE H – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 90% e a 85%..	117
APÊNDICE I – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85% ..	119

1 INTRODUÇÃO

Atualmente, as necessidades atreladas ao estilo de vida da população e às atividades econômicas a ele relacionadas demandam construções de infraestrutura de grande porte como pontes, túneis, barragens, viadutos, entre outros. Estas e outras estruturas de engenharia estão frequentemente sujeitas a alterações em suas propriedades dinâmicas devido a vários fatores, tais como a deterioração da construção devido ao tempo de uso, a falta de manutenção, os efeitos ambientais e operacionais, os carregamentos inesperados e os procedimentos de reforço estrutural (ALVES *et al.*, 2015). Diante deste panorama, o monitoramento contínuo do comportamento dinâmico de uma estrutura possibilita a investigação e a análise de alterações com o objetivo de assegurar sua integridade, garantindo maior conforto e segurança aos usuários, além de possibilitar ações mais eficazes de reparo e manutenção, impactando diretamente na redução dos custos operacionais. Dessa forma, surge o conceito de Monitoramento da Integridade Estrutural, também conhecido pela sigla SHM (do inglês – *Structural Health Monitoring*), que engloba um conjunto de técnicas e equipamentos utilizados para investigar a saúde das estruturas. Uma vez que as alterações nas propriedades dinâmicas podem estar ligadas ao aparecimento de danos, os sistemas de monitoramento visam desenvolver estratégias capazes de detectar e avaliar a extensão e magnitude das modificações estruturais.

O paradigma do monitoramento da saúde estrutural baseia-se no uso de indicadores robustos e confiáveis que possibilitam detectar, localizar, quantificar e, caso possível, prever a ocorrência do dano (ALVES *et al.*, 2015). A detecção de danos integra o núcleo fundamental para atender aos aspectos de segurança e manutenção. Para tanto, sistemas de monitoramento devem dispor de ferramentas computacionais aptas a avaliar as informações adquiridas em tempo real e continuamente (CARDOSO, 2018).

Estudos relativos à detecção de danos em estruturas de engenharia civil são de grande interesse para pesquisadores dessa área devido às possíveis consequências sociais e econômicas que se originam pela existência de anomalias em uma estrutura. Sabe-se que se o dano não for detectado a tempo, o sistema estrutural pode sofrer graves consequências relacionadas a sua segurança (ALVES *et al.*, 2015; CURY *et al.*, 2011). Entender o comportamento dinâmico e identificar alterações estruturais em tempo hábil é imprescindível para assegurar que a ocorrência de colapso em estruturas e problemas de gerenciamento econômico sejam otimizados (ALVES *et al.*, 2015).

A utilização de sistemas SHM tem como vantagem a grande probabilidade de detecção do dano estrutural ainda em sua fase inicial. Diante disso, a avaliação da segurança estrutural possibilita a determinação de condições apropriadas de funcionamento e, em situações extremas, prevenir falhas catastróficas.

Diversos exemplos podem ser mencionados para provar a importância de se identificar danos rapidamente com o intuito de se evitar catástrofes. Na Tabela 1, alguns exemplos de pontes que ruíram e o que levou a tal fato são apresentados. Tais incidentes poderiam ter sido minimizados – ou até mesmo evitados – com a utilização de sistemas de monitoramento confiáveis e adequados.

Tabela 1 – Exemplos de falhas em pontes e suas causas

Ponte	Localização	Ano	Causa
Ponte do rio Mianus	EUA	1983	Corrosão do metal e fadiga
Viaduto da rua Cypress	EUA	1989	Terremoto
Ponte Seongsu	Coréia do Norte	1994	Falha estrutural: defeito na solda
Ponte Tarcoles Myllysilta	Costa Rica Finlândia	2009 2010	Sobrecarga devido a caminhões pesados Inclinação devido à falha nos pilares
Ponte Gongguan	China	2011	Sobrecarga
Ponte Skjeggestad	Noruega	2015	Deslocamento de pilar
Viaduto Vivekananda	Índia	2016	Ligaçāo seção e pilar
Viaduto no Eixão Sul	Brasília (Brasil)	2018	Deterioração da estrutura/falta de manutenção

Fonte: Adaptado de Alves (2016).

Além dos incidentes mencionados na Tabela 1, outro exemplo relevante de catástrofe em pontes e que mostra a necessidade do desenvolvimento de novos métodos de detecção de danos em estruturas é o desabamento de uma seção de 210 m da Ponte Morandi (Figura 1) em Gênova – Itália, que ocorreu no dia 14 de agosto de 2018, causando 43 mortes. Investigações apontam que a ponte não havia sido projetada para suportar os 25 milhões de veículos que passaram a trafegar por ela anualmente. Outras opiniões também sugerem que um procedimento de manutenção em um dos pilares pode ter tido influência na queda (SANTOS, 2018).

Figura 1 – Ponte Morandi em Gênova



Fonte: SANTOS (2018).

É importante ressaltar que apenas sistemas SHM podem não ser suficientes para evitar catástrofes desse porte, mas técnicas adequadas podem alertar operadores de estruturas para que eles possam providenciar vistorias no local e reparos quando necessários.

As estruturas precisam ser monitoradas para evitar que danos as levem a sua interdição total ou, até mesmo, ao seu colapso. Atualmente, sistemas de monitoramento contínuo estão sendo mais utilizados em estruturas de grande porte. Como exemplo, pode-se citar o viaduto de Millau (CACHOT *et al.*, 2015) na França, a ponte Tsing Ma na China (NI *et al.*, 2011), a ponte Rio-Niterói no Brasil (BATTISTA; PFEIL, 2000), o arranha-céu Burj Khalifa em Dubai (KIJEWSKI-CORREA *et al.*, 2013), a ponte Golden Gate nos Estados Unidos, a ponte Minami Bisan-Seto no Japão, a ponte Grande Belt na Dinamarca, entre outras que são mencionadas em (XIA; XU, 2012). A degradação natural e o envelhecimento das estruturas são uma das principais causas da instalação dos programas de monitoramento.

Muitas pesquisas vêm sendo realizadas nos últimos anos com o objetivo de desenvolver indicadores robustos e confiáveis capazes de detectar, localizar, quantificar e até mesmo prever danos. Neste contexto, muitas questões surgem. Saber o que causa dano na estrutura e como detectá-lo, são as questões mais relevantes.

O que causa o dano em uma estrutura é uma questão um tanto complexa, pois vários motivos podem explicar uma disfunção estrutural. Em particular, o monitoramento da integridade estrutural precisa levar em consideração as diferentes etapas da vida útil de uma

estrutura (estudos já realizadas, ações de manutenção anteriores e reabilitação, etc.). Porém, até mesmo estruturas recentes podem apresentar erros de execução e/ou sofrer eventos inesperados o que pode levar a falhas localizadas ou até globais da estrutura. O surgimento de danos estruturais pode estar ligado a alterações na capacidade de resistência da estrutura devido à degradação dos materiais que as constituem (por exemplo, corrosão de aço, fissuras, etc.) ou então, as diferentes tensões às quais a estrutura pode estar sujeita. De fato, as estruturas são geralmente submetidas a carregamentos ao longo da vida que podem causar danos estruturais de forma contínua ao longo do tempo (por exemplo, fadiga de uma estrutura metálica devido ao tráfego de veículos) ou de maneira descontínua (ocorrência de terremoto, por exemplo).

O dano em uma estrutura pode ser definido como alterações que prejudicam seu desempenho atual e/ou futuro, tais como segurança. Claramente, o conceito de dano é significativo somente se dois estados da estrutura forem identificados e comparados (considerando o primeiro estado estrutural como sendo o estado de referência, sendo esse estado geralmente não danificado) (CURY, 2010). Em sistemas estruturais, o efeito do dano é normalmente causado por alterações dos materiais e em suas propriedades geométricas. Mudanças nas ligações e nas condições de apoio, são outros fatores que também podem alterar o desempenho estrutural (ALVES, 2016).

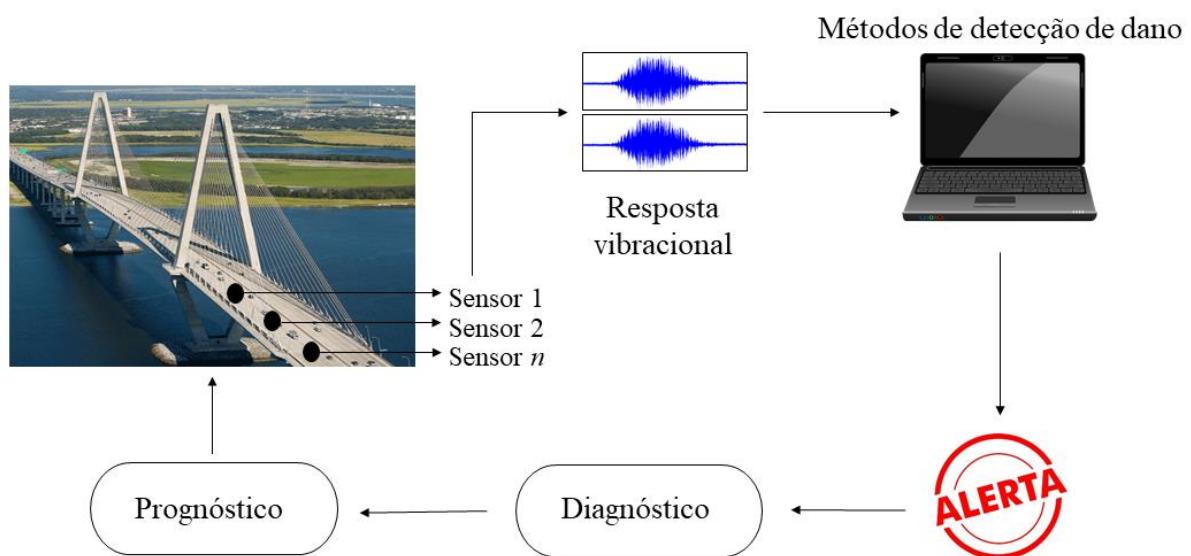
Sobre como detectar danos estruturais, a resposta está normalmente ligada a avaliação do desempenho estrutural. Em grande parte dos casos, procedimentos de inspeção visual servem como base para a detecção de danos e para a definição de procedimentos de manutenção da estrutura por um período. Porém, avaliações visuais podem não ser suficientes para detectar danos, uma vez que não quantificam o desempenho estrutural. Além disso, o acesso do profissional responsável pela inspeção aos vários elementos estruturais pode ser difícil ou até mesmo impossível em alguns casos, o que limita o uso deste tipo de procedimento. A necessidade de abordagens alternativas à inspeção visual tem sido uma grande motivação para o desenvolvimento de métodos de monitoramento estrutural. Geralmente, duas famílias de técnicas de inspeção estrutural são usadas: as técnicas destrutivas e as técnicas não-destrutivas. Essa divisão leva em conta se a técnica de monitoramento utilizada danifica ou não a estrutura. Em geral, os métodos não-destrutivos são os mais procurados. Os exemplos mais conhecidos são os testes dinâmicos e estáticos, ensaios de emissão acústica, termografia, ultrassom, etc. (MCCANN; FORDE, 2001; REHMAN *et al.* 2016).

Dentre as técnicas não-destrutivas, a mais adequada para o monitoramento da integridade estrutural é aquela baseada na variação das características de vibração e que tem sido muito discutida como em Fan e Qiao (2011), Alvandi e Crémona (2006) e Shih *et al.*

(2013). Os métodos baseados em vibração consideram as respostas dinâmicas da estrutura como funções das suas propriedades dinâmicas. A ideia básica é que o dano provoca alterações nas propriedades físicas da estrutura, incluindo rigidez e massa, e essas alterações se refletem diretamente no comportamento dinâmico estrutural, levando a modificações nos parâmetros modais da estrutura (frequências naturais, modos de vibração, taxas de amortecimento) (CURY *et al.*, 2011). Alterações nesses parâmetros são indicadores muito importantes da presença de dano em estruturas. Além disso, uma grande vantagem dos métodos baseados em vibração é a possibilidade de se usar as vibrações ambientes como fonte de excitação.

Um sistema de monitoramento estrutural baseado em vibração pode ser representado pelo Esquema 1. Basicamente, o funcionamento se dá da seguinte forma: a estrutura é monitorada por sensores que tem a função de captar seu sinal (dados vibracionais) gerando-se um banco de dados. As respostas estruturais (resposta vibracional) são analisadas e comparadas a partir de métodos de detecção de danos. Caso o dano seja detectado, um alerta é emitido ao operador para que um diagnóstico seja elaborado e, com base neste, ações na estrutura (prognóstico) sejam definidas.

Esquema 1 – Esquema de funcionamento de um SHM



Fonte: Elaborado pelo autor.

Segundo Rytter (1993), os métodos de detecção de dano são utilizados para informar quatro níveis de conhecimento:

- Nível 1: Ocorrem danos na estrutura (existência)?
- Nível 2: Qual a localização geométrica do dano (localização)?

- c) Nível 3: Qual a magnitude do dano (quantificação)?
- d) Nível 4: Qual é o tempo de vida útil restante da estrutura (prognóstico)?

Neste contexto, esta dissertação foca principalmente no “Nível 1” da escala de Rytter (1993), ou seja, na identificação de alterações estruturais em si. Abordagens originais serão propostas para detecção de danos estruturais a partir da resposta dinâmica da estrutura.

1.1 OBJETIVO GERAL

O principal objetivo desta dissertação é propor uma nova abordagem para identificação de danos e modificações estruturais baseada na análise direta de medições de aceleração. Esta abordagem consiste na utilização em conjunto dos métodos de classificação supervisionados e não supervisionados com o objetivo de detectar não apenas estados estruturais já conhecidos, mas também estados de dano ainda não identificados. A ideia é permitir, dessa forma, o monitoramento da integridade estrutural em tempo real, provendo respostas de forma automática e contínua, baseando-se apenas em testes vibracionais ambientais com a estrutura em operação. Salvo melhor juízo, a metodologia proposta não foi encontrada na literatura e isso evidencia o caráter original deste trabalho.

1.1.1 Objetivos específicos

- a) Avaliar a influência do ruído inerente aos sinais de aceleração na classificação dos comportamentos dinâmicos;
- b) Avaliar a influência de parâmetros intrínsecos aos métodos de classificação nos resultados obtidos, tais como o número de neurônios utilizados na camada oculta da rede neural, probabilidade de um novo ensaio pertencer aos *clusters* existentes, métricas de distâncias, formas de inicialização dos centroides e forma de organização dos dados de entrada.

1.2 JUSTIFICATIVA

A primeira justificativa para realização deste trabalho é o fato de que poucas pesquisas se concentram na avaliação direta das respostas dinâmicas de uma estrutura sob excitações operacionais/ambientais. Isso ocorre devido à falta de ferramentas adequadas para manipulação

dos sinais das medições dinâmicas e à dificuldade em se utilizá-los diretamente, devido a presença de ruídos e a complexidade de utilizar esse tipo de dado corretamente. Apesar das dificuldades, o uso direto das medições de aceleração facilita de forma considerável o problema de identificação de danos, pois o procedimento se torna mais direto podendo-se, por exemplo, ser descartada a necessidade de um processo de identificação modal.

A segunda justificativa é que muitos métodos de detecção de danos são baseados exclusivamente em técnicas de aprendizado supervisionado, como as redes neurais por exemplo. Essas técnicas já provaram sua eficiência, porém elas requerem do analista o conhecimento prévio das classes de dano existentes na estrutura para o treinamento do método em questão. Tal fato pode ser uma limitação em aplicações práticas, já que não é possível “rotular” uma nova classe de dano quando esta surge. Além disso, o conhecimento prévio dos níveis de danos aos quais a estrutura está submetida, em casos reais, normalmente são as respostas que se deseja obter, não dados do problema.

A principal motivação deste trabalho é oferecer, portanto, uma nova metodologia para detecção de danos e alterações estruturais baseada no uso direto das medições de aceleração e na acoplagem de técnicas supervisionadas e não supervisionadas para construção de um classificador híbrido que tenha capacidade de detectar modificações estruturais.

1.3 ORGANIZAÇÃO DO TEXTO

Essa dissertação é composta de 6 capítulos, incluindo o presente, onde foi realizada uma breve introdução sobre o tema abordado e sua importância. Apresentou-se, também, os objetivos pretendidos nesta pesquisa e a justificativa para sua realização.

No segundo capítulo apresenta-se uma revisão bibliográfica sobre os métodos de classificação baseados em inteligência computacional para detecção de danos e alterações estruturais, desenvolvidos nos últimos anos.

No terceiro capítulo são apresentados os indicadores de dano utilizados para caracterizar a resposta dinâmica da estrutura e as teorias dos métodos de classificação empregados neste trabalho. Os conceitos e fundamentos utilizados na concepção das técnicas são abordados.

No quarto capítulo, a metodologia proposta para detecção de danos e alterações estruturais é apresentada.

No quinto capítulo, o método proposto é avaliado a partir de aplicações numéricas e experimentais. Testes de sensibilidade do classificador híbrido são realizados e duas formas de organização dos dados de entrada são testadas.

Por fim, as conclusões e considerações finais, além de sugestões para trabalhos futuros são apresentadas no sexto capítulo.

2 REVISÃO BIBLIOGRÁFICA

Nas últimas décadas, a utilização de inteligência computacional para identificação de danos em estruturas tornou-se muito importante. Diversas abordagens baseadas na aprendizagem de máquinas aplicada ao reconhecimento de padrões vêm sendo propostas para identificação de comportamentos “anormais” da estrutura. Neste tipo de abordagem, os sinais dinâmicos são processados a partir de técnicas estatísticas (ou por análise modal, por exemplo) e, em seguida, são comparados e classificados através do uso de algoritmos de inteligência computacional, sendo que alterações nos dados podem indicar a existência de danos. Na literatura existem vários estudos que relatam a eficiência e utilidade dessas técnicas na avaliação da integridade estrutural e algumas destas serão mencionados a seguir.

Chang *et al.* (2000) propuseram um método de detecção de danos estruturais baseado na identificação de parâmetros usando uma técnica de rede neural iterativa e no conceito de matriz ortogonal (adotado para gerar combinações representativas de alterações de parâmetros), com o intuito de reduzir significativamente o número de dados de treinamento de forma a manter a integridade dos dados. Testes numéricos foram realizados e os resultados obtidos provaram a eficácia da abordagem na detecção e localização de danos.

Sahin e Shenoi (2003), fizeram um estudo numérico e experimental com o objetivo de localizar e quantificar danos em uma viga. Frequências naturais e formas modais obtidas numericamente foram utilizadas como entrada das redes neurais na etapa de treinamento. Três redes diferentes foram criadas, cada uma com dados de entrada distintos (frequências naturais, modos de vibração e diferença máxima entre as curvaturas). Diferentes cenários de danos foram utilizados no treinamento das redes. Para validar a metodologia proposta, as redes foram testadas utilizando dados extraídos do modelo experimental. Os resultados mostraram que as diferenças percentuais entre as frequências são dados que podem indicar a presença e severidade de danos. Em relação à localização do dano, a diferença máxima entre as curvaturas ofereceu resultados mais precisos.

Gomes (2004) utilizou redes neurais artificiais com funções de base radial para detectar danos em uma viga numérica biapoiada. Os dados de entrada da rede neural foram as variações das frequências naturais da estrutura. Os dados de treino e teste da rede foram obtidos através do modelo numérico de viga, o qual foi submetido a diferentes níveis de dano e ruído. O autor concluiu que a escolha dos dados de treinamento deve ser criteriosa, pois esses dados precisam apresentar de forma adequada a totalidade da variação do comportamento estrutural a fim de

que seja possível realizar previsões confiáveis através da rede neural. Além disso, o autor também verificou a robustez da rede quanto à presença de ruídos em seus dados de entrada.

Zang *et al.* (2004) apresentaram uma nova abordagem para detectar danos em estruturas baseada na combinação de Análise de Componentes Independentes para extração de características do sinal no domínio do tempo e Redes Neurais Artificiais. Os resultados obtidos mostraram que a metodologia proposta pelos autores foi capaz de detectar estados danificados e não-danificados com uma boa precisão.

Lee *et al.* (2005) propuseram uma abordagem baseada na utilização de redes neurais para detecção de danos. Para testar a eficiência do método, dois modelos numéricos – uma viga simples e uma ponte – foram utilizados. Como padrões de entrada da rede foram utilizadas diferenças e relações entre os modos de vibração dos modelos danificados e não-danificados. Os dados utilizados para o treinamento da rede foram obtidos através dos modelos numéricos, enquanto os dados de teste foram extraídos de um modelo de ponte construído em laboratório. Resultados demonstram que a metodologia é eficiente para a identificação de danos.

Fang *et al.* (2005) exploraram a detecção de danos estruturais utilizando Funções de Respostas em Frequências (FRF) como dados de entrada de uma rede neural. Estudos numéricos foram realizados em uma viga submetida a diferentes cenários de danos. Os resultados demonstram que a técnica funcionou de forma adequada, sendo a rede neural capaz de classificar os níveis de dano com uma boa precisão.

Jeyasehar e Sumangala (2006) apresentaram uma abordagem baseada em redes neurais artificiais para avaliar danos em vigas de concreto protendido. O desempenho de uma rede neural treinada apenas com dados de frequências naturais foi comparado com o desempenho de outras redes treinadas com uma mistura de dados estáticos e dinâmicos (frequências naturais, largura de trincas, deflexões, carregamentos). A partir dos resultados, foi possível verificar que as redes treinadas apenas com dados dinâmicos obtiveram melhores resultados na detecção de danos, apresentando menores margens de erro que as demais. Concluiu-se, portanto, que as propriedades dinâmicas são parâmetros mais apropriados para o contexto do monitoramento da integridade estrutural.

Mehrjoo *et al.* (2008) propuseram um método para estimar a intensidade de danos em articulações de pontes treliçadas, através do uso de redes neurais artificiais com o algoritmo *Backpropagation*. Por se tratar de uma grande estrutura com muitas articulações, a abordagem propõe uma repartição da estrutura em subestruturas que tenham a capacidade de representar a ponte completa. A rede recebeu como parâmetros de entrada frequências naturais e os modos de vibração das estruturas. Dados obtidos de uma subestrutura foram utilizadas na fase de

treinamento da rede e a partir de seu aprendizado foi possível generaliza-la, com o objetivo de se conhecer os danos da estrutura completa. Os resultados demonstraram um ótimo aprendizado da rede e uma boa precisão na detecção dos danos.

Park *et al.* (2008) propuseram uma abordagem para monitorar parafusos frouxos em uma estrutura de alumínio. Análise de Componentes Principais foi utilizada para compactar os dados e eliminar ruídos indesejados, incluindo-se efeitos ambientais como umidade, temperatura, entre outros. O método de *clustering, k-means*, é utilizado para discriminar os estados estruturais utilizando como indicador de dano duas componentes principais. A abordagem permitiu o alcance de resultados satisfatórios.

Rucka e Wilde (2010) utilizaram redes neurais e ondas *wavelet* para detectar e localizar danos estruturais. A abordagem consiste em aplicar a transformada de *wavelet* nos modos de vibração da estrutura e utilizar tais dados como parâmetros de entrada da rede neural, como saída tem-se a detecção e localização dos danos. Para treinamento e validação do método, modelos numéricos e experimentais de vigas, placas e cascas foram utilizados. Os autores concluíram com base nos resultados, que a combinação das técnicas apresenta boa precisão na identificação de danos, podendo ainda ser melhorada com a otimização da arquitetura da rede.

Borowiec e Ziemianski (2011) utilizaram redes neurais para detectar danos em uma viga confeccionada em laboratório. Dois modelos numéricos também foram construídos e a partir deles foram obtidas as características dinâmicas, especificamente, as modificações nas frequências naturais devido a adição de massa e à redução de rigidez em alguns pontos da viga e, em seguida, foram utilizadas como dados de treinamento da rede neural. Para o teste da rede foram utilizados dados extraídos do modelo experimental. Os resultados demonstram que as redes neurais podem ser bastante eficazes na identificação de danos.

Cury e Crémonea (2012) apresentaram uma nova abordagem que combina Análise de dados Simbólicos com três técnicas de classificação supervisionadas: Árvores de Decisão Bayesiana, Redes Neurais e Máquinas de Vetor de Suporte. A Análise de Dados Simbólicos é utilizada para manipular dados de vibração (sinal) e também propriedades modais (frequências naturais e modos de vibração). Para avaliar a eficiência da abordagem proposta simulações numéricas considerando diferentes cenários de dano e níveis de ruído em uma viga e testes experimentais em uma ponte ferroviária na França, foram realizadas. Os resultados demonstram que a abordagem proposta é eficiente e suficiente para classificar e discriminar as alterações estruturais, considerando parâmetros modais ou dados de vibração.

Yu *et al.* (2013) propuseram uma nova metodologia baseada em vibração para detectar danos em um modelo de ponte treliçada fabricada em laboratório que consiste no uso de

Funções de Respostas em Frequência e *clustering fuzzy*. Vários cenários de danos foram simulados afrouxando parafusos no modelo de ponte e os efeitos ambientais são levados em consideração através de alterações nos níveis de força de excitação de um *shaker*. As Funções de Respostas em Frequência da estrutura não danificada e danificada são utilizadas como dados iniciais. A Análise de Componentes Principais e a Análise de Componentes Principais de Kernel são adotadas para compactação dos dados e extração de características de dano. O algoritmo de *clustering fuzzy c-means* é utilizado para categorizar esses recursos a fim de detectar danos estruturais. Os resultados mostram que o método proposto é sensível a danos estruturais, mas não é sensível aos efeitos das variações operacionais e ambientais.

Nguyen *et al.* (2015) apresentaram uma técnica de monitoramento estrutural baseada em vibração para detectar danos em um protótipo da seção de uma viga em arco da ponte *Sydney Harbour*. A metodologia proposta utiliza funções de resposta em frequência combinadas com análise de componentes principais a fim de definir características específicas de danos e então utilizá-las como parâmetros de entrada de uma rede neural. Para validar o método, testes experimentais na peça sem danos foram realizados e, depois de obtidas as respostas dinâmicas, foram feitos cortes com três níveis de severidade na estrutura para simular os níveis de dano e, novamente, as respostas estruturais foram medidas. As informações foram divididas em dados para treinamento e teste da rede, porém, os dados de treino não foram suficientes e isso limitou o seu desempenho. Para solucionar essa questão, modelos numéricos foram desenvolvidos e mais dados de treinamentos foram gerados. Por fim, os resultados mostraram uma melhora significativa, com um aumento do desempenho e precisão da rede na identificação dos danos.

Alves *et al.* (2016) propuseram um novo método baseado no acoplamento de Análise de Dados Simbólicos com três métodos de *clustering*: nuvens dinâmicas, aglomeração hierárquica e *fuzzy c-means* para detectar danos estruturais utilizando, especialmente, dados “brutos” de aceleração, ou seja, medições *in situ*. Parâmetros modais e modos de vibração, também foram considerados na análise. Para atestar a eficiência da abordagem proposta, investigações experimentais em laboratório e dois estudos de caso reais em pontes ferroviárias e rodoviárias, foram realizados. Os resultados obtidos demonstram que a análise de dados simbólicos associada a técnicas de classificação é capaz de classificar e discriminar alterações estruturais considerando a vibração “bruta”.

Zhou *et al.* (2016) utilizaram a transmissibilidade juntamente com *clustering* hierárquico e análises de similaridade para detectar danos estruturais. A transmissibilidade deriva das respostas dinâmicas da estrutura que caracterizam o estado estrutural. O *clustering* hierárquico é adotado para discriminar os cenários de dano, tendo como recurso a

transmissibilidade para diferenciar os padrões não danificados dos danificados. Para fins de comparação, medidas de similaridade também são adotadas. Para avaliar a abordagem proposta, testes numéricos e experimentais são realizados. Os resultados indicam que a metodologia possui bom desempenho na detecção de danos estruturais.

Tan *et al.* (2017) propuseram um método baseado em redes neurais para localizar e mensurar danos em vigas de aço. O estudo foi realizado numericamente, e índices de danos baseados na energia de deformação modal de vários cenários simulados, foram utilizados como dados de entrada da rede neural. Como saída, a rede fornecia o local e o valor da redução de rigidez dos elementos danificados. Os resultados demonstram que a metodologia é eficiente e precisa.

Torres *et al.* (2018) propuseram uma abordagem que consiste no uso de Estatísticas de Ordem Superior (HOS – do inglês *Higher-Order Statistic*) em conjunto com técnicas de agrupamento (algoritmo *k-means* e *c-means*) com o objetivo de detectar alterações estruturais. A abordagem proposta é aplicada diretamente as medidas de aceleração obtidas *in situ*. A eficiência da metodologia é avaliada através de aplicações em um modelo numérico de viga biapoiada e em uma ponte ferroviária de caso real, na França. Os resultados demonstram que a HOS utilizada em conjunto com os métodos de agrupamentos é capaz de discriminar os diferentes cenários de danos com taxas de classificação adequadas.

Finotti *et al.* (2019) apresentaram uma estratégia para identificar modificações estruturais baseada em indicadores estatísticos e métodos de classificação (Redes Neurais Artificiais e Máquinas de Vetores-Suportes). Dez indicadores estatísticos foram extraídos dos dados vibracionais e utilizados como dados de entrada dos métodos de classificação. O método proposto foi avaliado através de aplicações em um modelo numérico de viga biapoiada submetida a diferentes níveis de dano, uma viga de aço confeccionada em laboratório e uma ponte ferroviária na França. Os resultados obtidos com as duas técnicas de classificações foram comparados e ambos obtiveram resultados satisfatórios e desempenhos semelhantes para os problemas de detecção de modificações estruturais.

Uma ampla variedade de métodos baseados em inteligência artificial vem sendo utilizada na solução de problemas de detecção de danos estruturais, como é possível verificar nos parágrafos anteriores. Portanto, ainda não foi definida qual técnica poderia ser a mais apropriada. É nítida a grande utilização de métodos de classificação supervisionada, como redes neurais, em diversos trabalhos que buscam detectar modificações estruturais. Porém, este tipo de técnica requer do analista o conhecimento prévio das classes de dano existentes na estrutura

para o treinamento do método em questão, e isso pode ser uma limitação em aplicações práticas já que não é possível rotular uma nova classe de dano quando esta surge.

Em contrapartida, o uso de métodos baseados exclusivamente em classificação não supervisionada, por possuírem a “desvantagem” de não conhecerem os estados estruturais *a priori*, pode levar a resultados imprecisos.

Assim, no presente trabalho, a ideia é unir o “melhor dos dois mundos”, isto é, acoplar métodos de classificação supervisionada (no caso, as redes neurais) a métodos de classificação não supervisionada (*k-means*, neste estudo) para que seja possível a detecção de novos estágios de dano quando estes surgem.

Por último, mas não menos importante, analisando-se os trabalhos citados anteriormente, é possível notar a vasta utilização de parâmetros modais como dados de entrada dos diversos métodos de detecção de danos e a consequente pouca utilização direta dos dados “brutos” de vibração extraídos da estrutura. Neste trabalho, um maior enfoque é dado no emprego dos sinais dinâmicos como indicadores de danos estruturais.

3 INDICADORES DE DANO E MÉTODOS DE CLASSIFICAÇÃO

Neste capítulo, as técnicas utilizadas para classificar os estados da estrutura através do uso direto das respostas dinâmicas obtidas no domínio do tempo são apresentadas.

3.1 INDICADORES DE DANO OBTIDOS A PARTIR DAS RESPOSTAS DINÂMICAS

Nesta seção, os indicadores construídos a partir das respostas dinâmicas “brutas”¹ e que são utilizados como parâmetros de entrada do método de classificação proposto neste trabalho são apresentados.

O desenvolvimento de indicadores de danos extraídos diretamente dos dados vibracionais “brutos” é de grande interesse para o problema de detecção de danos estruturais, uma vez que pode evitar procedimentos extras, como por exemplo, a identificação modal. Porém, esta pode ser uma tarefa difícil, uma vez que essas respostas, na maioria das vezes, possuem tamanho considerável. Normalmente, os procedimentos de aquisição de dados em estruturas de engenharia geram milhares de valores de aceleração medidos através de diversos sensores. Como resultado, a avaliação direta desses dados “brutos” pode, em grande parte dos casos, demandar muito tempo ou até mesmo ser proibitiva. Dessa forma, transformar essa numerosa quantidade de dados em um tipo de dado mais compacto, mas com a mesma riqueza de informações, torna-se uma abordagem interessante.

Outro fator importante é a escolha do indicador a ser utilizado, pois este tem grande influência na precisão dos métodos de identificação de dano. Apesar de as técnicas de inteligência computacional serem muitos eficientes na resolução de problemas de identificação de danos e modificações estruturais, a utilização de dados capazes de fornecer informações representativas e suficientes dos sinais dinâmicos é necessária, pois o aprendizado dessas técnicas se dá através da transformação desses dados. Dessa forma, a definição das variáveis de entrada dos métodos de inteligência computacional é muito importante para que os diferentes estados estruturais sejam reconhecidos e classificados com sucesso.

Neste trabalho, os indicadores estatísticos de ordem superior são utilizados para caracterizar os sinais dinâmicos, devido ao seu bom desempenho verificado em trabalhos anteriores (DE LA ROSA, 2013; FARRAR; WORDEN, 2012; FINOTTI *et al.*, 2019; LI *et al.*, 2008). Segundo Farrar e Worden (2012), a análise de séries temporais de respostas dinâmicas

¹ Sinais de aceleração no domínio do tempo.

estruturais possibilita a extração de informações dos sinais mais facilmente do que quando se utiliza análise modal. Além disso, o cálculo dos indicadores estatísticos constitui um procedimento significativamente mais simples que, por exemplo, análise modal, filtros, dentre outros.

Grande parte dos conjuntos de dados pode ser inteiramente caracterizada pelas chamadas estatísticas de primeira e segunda ordem como, respectivamente, a média e a variância. Porém, existem casos em que essas duas estatísticas não oferecem informações suficientes sobre a base de dados. Dessa forma, surgem as Estatísticas de Ordem Superior (HOS – do inglês *Higher-Order Statistic*) que utilizam cumulantes estatísticos de ordem maior que dois para inferir novas características sobre o conjunto de dados (DE LA ROSA *et al.*, 2013). Como as respostas dinâmicas da estrutura se assemelham muito, mesmo após a ocorrência de danos, as HOS pode oferecer parâmetros que indiquem diferenças sutis entre os sinais, permitindo assim a identificação de modificações estruturais.

Farrar e Worden (2012) sugerem a utilização de dez diferentes indicadores estatísticos para caracterizar um sinal dinâmico (x). O objetivo é reduzir o volume de dados a serem tratados, preservando suas principais propriedades. Os indicadores utilizados são apresentados na Tabela 2. Além dos parâmetros estatísticos, existem outras formas simples de se extrair informações importantes do sinal dinâmico “bruto”, como por exemplo a Análise de Dados Simbólicos (CURY; CREMONA, 2012). Esses procedimentos podem ser encarados como alternativas a análise modal ou à Análise de Componentes Principais (YAN *et al.*, 2005) pois demandam um esforço computacional significativamente inferior para definir características relevantes dos sinais analisados.

Tabela 2 – Estatísticas de alta ordem

Valor de pico	$x_{pico} = \max x_i $
Média	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
Média quadrática	$x_q = \frac{1}{n} \sum_{i=1}^n (x_i)^2$
Raiz da média quadrática	$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2}$
Variância	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
Desvio-padrão	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
Assimetria	$s = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sigma^3}$
Curtose	$k = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\sigma^4}$
Fator de crista	$Cf = \frac{x_{pico}}{rms}$
Fator-K	$Kf = x_{pico} \cdot rms$

Fonte: Farrar e Worden (2012).

A primeira estatística da Tabela 2 é a maior amplitude de pico e representa a maior magnitude de oscilação do sinal. A média, a média quadrática e a raiz da média quadrática, fornecem a tendência central do conjunto de dados. Já o desvio-padrão e a variância medem a dispersão dos dados em relação à média. A assimetria e a curtose são, respectivamente, HOS de 3º e 4º ordem, onde a primeira indica o grau de assimetria de uma distribuição de dados e a segunda representa o grau de “achatamento” de uma distribuição medido em relação ao de uma distribuição normal que é considerada padrão. Os fatores K e de crista são geralmente empregados com a finalidade de se identificar desvios nas respostas senoidais. Apesar de algumas métricas estatísticas serem bastante correlacionadas, todas foram utilizadas como parâmetros de entrada do método de classificação, sem o uso de nenhuma técnica de seleção das “melhores características”.

3.2 MÉTODOS DE CLASSIFICAÇÃO

O desafio da detecção de alterações estruturais a partir de modelos de predição de danos pode ser superado com o uso de diversos algoritmos de inteligência computacional. Métodos baseados na aprendizagem de máquinas aplicada ao reconhecimento de padrões vêm sendo propostos para identificação de comportamentos “anormais” na estrutura, como já mencionado. O reconhecimento de padrões abrange um conjunto de técnicas capazes de identificar características intrínsecas da estrutura que permitem a identificação e a discriminação de comportamentos estruturais distintos.

Existem vários métodos baseados no reconhecimento de padrões descritos na literatura e utilizados para detectar danos estruturais. Esses métodos são geralmente divididos em duas famílias: os métodos de classificação supervisionada (máquinas de vetores suporte, redes neurais, etc.) e os métodos de classificação não-supervisionada (métodos de *clustering*, teste de hipóteses, etc.). Para os métodos supervisionados, uma série de rótulos conhecidos anteriormente é fornecida como dados de entrada para a definição das diferentes classes. Já para os métodos não-supervisionados, as informações desconhecidas são agrupadas em diferentes grupos. O objetivo é criar grupos cujas informações mais semelhantes se encontrem em um mesmo grupo e as mais distintas sejam separadas em grupos diferentes. Uma vantagem dos métodos não-supervisionados é a capacidade da criação automática de novos grupos ou classes (BRAGA *et al.*, 2000; HAYKIN, 1999). Já a outra família de métodos demanda um rótulo para cada classe, o que pode ser uma limitação em aplicações práticas. O presente trabalho utiliza a acoplagem de técnicas de métodos supervisionados (redes neurais) e não supervisionados (*k-means*), cujas definições serão detalhadas nas próximas seções.

3.2.1 Redes Neurais Artificiais

A utilização de Redes Neurais Artificiais (RNAs) é realizada com sucesso em vários problemas de engenharia, como classificadores de padrões, aprimoradores de sinal, previsão e controle do sistema, entre outros. No contexto deste trabalho, a RNA funciona como um classificador de padrões, pois tenta distinguir, a partir de dados de entrada, diferentes estados estruturais que caracterizam o sinal através da saída fornecida pela rede.

De acordo com Príncipe *et al.* (2000), a classificação realizada por uma RNA é de caráter estatístico, na qual objetos correspondem a classes em um espaço multidimensional de decisão dividido em regiões que estão relacionadas a cada tipo de saída. As superfícies de

decisão são estabelecidas durante o processo de treinamento e são construídas com base na variabilidade estatística que existe entre as classes a partir de um método de otimização fundado na análise do erro da saída da rede. Tal procedimento é detalhado mais adiante neste texto.

As redes neurais são sistemas adaptativos paralelos de aprendizagem distribuída, formados por elementos de processamentos (neurônios) que calculam certas funções matemáticas geralmente não-lineares (BRAGA *et al.*, 2000; PRÍNCIPE *et al.*, 2000). Esses neurônios são distribuídos entre uma ou mais camadas e são interligados através de conexões usualmente unidirecionais. Comumente nos modelos de redes neurais, estas conexões estão associadas a parâmetros ajustáveis chamados pesos. Esses parâmetros são constantemente modificados durante a fase de treinamento e, na fase de teste, são fixos. Eles possuem a função de armazenar o conhecimento evidenciado no modelo e também de ponderar cada entrada recebida por neurônios da rede (BRAGA *et al.*, 2000; HAYKIN, 1999). Os neurônios somam todas as entradas ponderadas e produzem uma função não linear dessa soma, gerando uma saída (ABRAHAM, 2004). O funcionamento das RNAs é inspirado na estrutura fisiológica básica das redes neurais biológicas (BRAGA *et al.*, 2000).

A grande utilização de RNAs para a solução de diversos tipos de problemas decorre não só dos sucessos obtidos, mas também de promissoras aplicações em tarefas de otimização (ABRAHAM, 2004). O poder computacional de uma rede neural se dá através de sua habilidade em aprender através de exemplos e, além disso, de generalizar essa informação aprendida. A capacidade de generalização de uma rede neural diz respeito ao poder que esta tem em gerar saídas apropriadas para entradas nunca antes vistas, tendo como base a informação aprendida (BRAGA *et al.*, 2000; HAYKIN, 1999).

Pode-se caracterizar uma rede neural com base em três aspectos principais: a forma de conexão entre as unidades de processamento (arquitetura), as funções de ativação utilizadas e a técnica de atualização de pesos das conexões (algoritmos de aprendizagem ou treinamento), que serão vistos com mais detalhes no decorrer deste capítulo. Dentre os modelos de redes neurais existentes (RBF – *Radial Basis Functions*, SOM – *Self-Organize Maps*, etc.) o utilizado neste trabalho é o modelo *perceptron* de múltiplas camadas, que é discutido com mais detalhes no tópico seguinte.

3.2.1.1 Redes Multilayer Perceptron

O modelo *Perceptron* de Múltiplas Camadas (MLP – do inglês *Multilayer Perceptron*) é adotado neste trabalho devido a sua grande utilização e aceitação. Além disso, seu uso tem tido grande sucesso em soluções de diversos problemas que abrangem altos graus de não-linearidade (BRAGA *et al.*, 2000; HAYKIN, 1999). Dessa forma, este modelo mostra-se adequado para abordar problemas de classificação não-lineares como o de detecção de modificações estruturais.

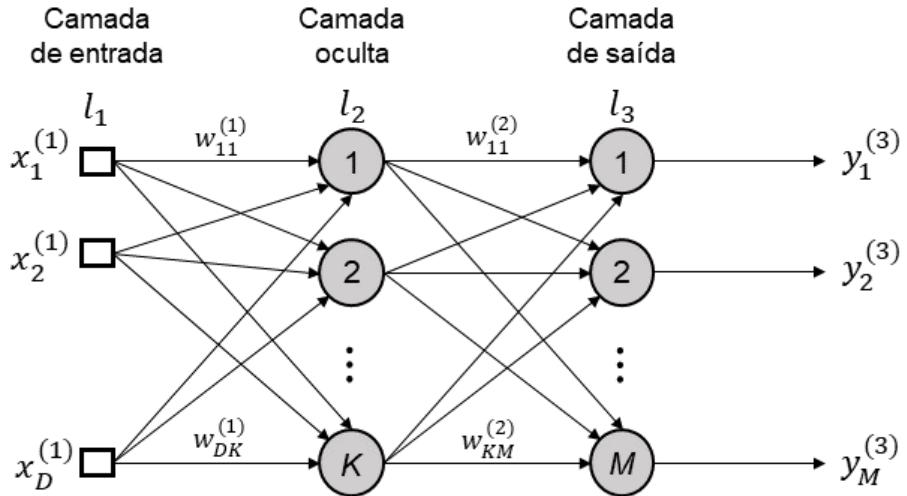
Uma rede do tipo MLP possui uma camada de entrada composta por um conjunto de unidades sensoriais, uma ou mais camadas ocultas (intermediárias) e uma camada de saída, sendo as duas últimas mencionadas compostas de elementos de processamento (neurônios). As camadas ocultas e de saída utilizam funções que possuem como objetivo aumentar uma não linearidade no modelo, conhecidas como funções de transferência ou de ativação (HAYKIN, 1999).

Em redes multicamadas, o processamento feito por cada neurônio é estabelecido pela combinação das saídas dos neurônios da camada anterior que estão ligados a ele. De acordo com Braga *et al.* (2000), as funções implementadas ficam ainda mais complexas quando se parte da primeira camada oculta em direção a camada de saída. Estas funções são responsáveis por definir as divisões do espaço de decisão.

Segundo Braga *et al.* (2000), os neurônios de uma rede MLP atuam como detectores de características. Eles criam uma codificação interna para os padrões de entrada, que é utilizada para definir a saída da rede. Para um número suficiente de elementos de processamento, torna-se possível a formação de representações internas para qualquer padrão de entrada.

A Figura 2 mostra a arquitetura de uma MLP com uma camada de entrada, uma camada intermediária e uma camada de saída. A camada de entrada é definida pelos D parâmetros do espaço de entrada; a camada de saída é definida pelos M componentes do espaço de saída, ou ainda, pela quantidade de classes existentes; e a camada oculta é definida empiricamente pelo número de neurônios K responsáveis pela complexidade da superfície de separação da MLP (PRÍNCIPE *et al.*, 2000). **Neste trabalho, os elementos da camada de entrada são os dados “brutos” de aceleração caracterizados pelos indicadores estatísticos e as saídas equivalem as classes de classificação (sem danos, dano nível 1, etc.), representadas por notação binária.**

Figura 2 – Rede MLP com uma camada intermediária



Fonte: Adaptado de Príncipe *et al.* (2000).

A informação é propagada da camada de entrada da rede para a camada seguinte que possui neurônios capazes de produzir uma saída, através do uso de uma função de ativação. As conexões entre os neurônios possuem pesos associadas, representados por w . Cada elemento de processamento da primeira camada oculta separa o espaço de entrada em regiões de decisão com base nos pesos. A camada de saída possui a capacidade de combinar algumas dessas regiões por um efeito aditivo ou multiplicativo, gerando uma estrutura de separação ainda mais complexa, conforme os ajustes realizados nos pesos das camadas adjacentes (BRAGA *et al.*, 2000; PRÍNCIPE *et al.*, 2000). No entanto, é possível concluir que a classificação feita por uma rede MLP depende do controle apropriado da posição das regiões de decisão, conforme os dados de entrada e a resposta desejada.

O procedimento de obtenção de conhecimento de uma RNA é chamado de *aprendizado*. Segundo Bishop (2006), existem várias técnicas de aprendizagem para redes MLP. Entretanto, a mais utilizada é a retropropagação do erro (*error backpropagation*). Esta técnica consiste em comparar a saída gerada pela rede com a resposta correta dos exemplos apresentados a fim de se obter um valor de erro da rede baseado em uma função de erro predefinida. Em seguida, o valor de erro obtido na camada de saída é propagado para as camadas anteriores e, posteriormente, os pesos são atualizados com a finalidade de reduzir o erro da rede (BISHOP, 2006). Este processo é repetido por um número de épocas² de treinamento, até que a rede

² Passagem completa por todo o conjunto de dados de treinamento.

convirja para um estado no qual o seu erro é baixo. Neste caso, fala-se que a rede está treinada ou que aprendeu (HAYKIN, 1999).

Codificar uma transformação entre entradas e saídas nos pesos da rede é a base do treinamento/aprendizagem de uma rede MLP (HAYKIN, 1999). Para obtenção de sucesso na criação dessa transformação, o conjunto de dados do problema é fracionado em dois subconjuntos, chamados de conjunto de treinamento e conjunto de teste. O conjunto de treinamento, por sua vez, é dividido em outros dois subconjuntos, denominados estimação e validação. Contudo, o subconjunto estimação também é chamado de conjunto de treinamento, devido ao fato de suas observações serem utilizadas no processo de atualização de pesos da rede (treinamento). Já as observações do subconjunto validação são utilizadas para detectar o momento de parada da fase de treinamento, que geralmente ocorre quando o erro obtido na validação ultrapassa o valor de erro da etapa de treinamento. Além disso, são utilizados para prever a habilidade de generalização da rede durante a fase de aprendizagem (BRAGA *et al.*, 2000). O conjunto de testes não influencia na construção do modelo de classificação, pois são observações nunca antes apresentadas à rede (HAYKIN, 1999).

3.2.1.2 Arquitetura

Um ponto importante na concepção de uma rede neural é a determinação de sua arquitetura, pois ela limita os problemas a serem tratados pela rede (BRAGA *et al.*, 2000). Os parâmetros que integram a arquitetura de uma RNA são: o número de camadas existentes, o número de neurônios presentes em cada camada, o tipo de conexão entre os neurônios e a topologia da rede (BRAGA *et al.*, 2000).

Segundo Rumelhart (1986), uma rede neural deve possuir duas camadas no mínimo, uma de entrada de dados e a outra de saída dos resultados. Porém, este tipo de rede possui um desempenho limitado. Assim, o acréscimo de camadas intermediárias é necessário para melhoria desse desempenho, uma vez que torna possível a solução de uma gama maior de problemas. Aliado a isso, também é necessária a determinação do número de neurônios a ser utilizado nas camadas ocultas da rede. Essas definições são de fundamental importância para um desempenho satisfatório do modelo e nem sempre são realizadas facilmente, sendo gasto um tempo significativo com tentativas e erros para que sejam definidos o número de camadas ocultas e o número de neurônios adequados para um dado problema.

Redes que possuem simples configurações, como por exemplo uma camada oculta e um neurônio, podem ser suficientes para obtenção de uma boa solução em determinados problemas. Entretanto, outros problemas necessitam de mais camadas ocultas e talvez milhares de neurônios. Panchal *et al.* (2011) afirmam que não existem motivos teóricos para se utilizar mais de duas camadas intermediárias.

Segundo Braga *et al.* (2000), o uso de um grande número de camadas ocultas não é aconselhável, pois cada vez que se propaga o erro obtido durante a fase de treinamento para as camadas anteriores, ele se torna menos preciso e menos útil. A camada de saída é a única que tem um conhecimento preciso sobre o erro cometido pela rede. A última camada oculta recebe da camada de saída apenas uma estimativa do erro; a penúltima camada oculta recebe uma estimativa da estimativa, e assim sucessivamente. **Neste trabalho, as redes neurais utilizadas possuem apenas uma camada oculta, haja vista a sua adequada representação para os problemas aqui tratados.**

Segundo Príncipe *et al.* (2000), a definição adequada do número de elementos de processamento é uma das questões mais relevantes da neurocomputação. Existem duas situações extremas: a rede possui poucos neurônios para realizar o trabalho ou possui muitos. Quando a rede não possui elementos de processamento suficientes, ela gasta um tempo excessivo na tentativa de encontrar uma solução ótima para o problema, podendo deixar os neurônios sobrecarregados e incapazes de gerar uma solução adequada. Já o uso de um número excessivo de neurônios pode induzir a rede a memorizar os exemplos de treinamento, prejudicando sua capacidade de generalização para dados não vistos antes (BRAGA *et al.*, 2000).

Vários fatores influenciam na definição da quantidade de elementos de processamento, como: o número de dados de treinamento, quantidade de ruído existente nos dados, complexidade do problema a ser tratado e a divisão estatística dos exemplos de treinamento. Geralmente, o número de neurônios é definido empiricamente após vários testes e a melhor configuração é escolhida. Outros métodos têm sido propostos e podem ser consultados em Braga *et al.* (2000), **porém o método empírico é o utilizado neste trabalho.**

Em relação à topologia da rede e ao tipo de conexão entre os neurônios, uma RNA pode ter uma arquitetura completamente conectada, na qual um neurônio de uma camada se conecta a todos os neurônios da camada posterior; ou parcialmente conectada, na qual um ou mais neurônios de uma camada não se conectam a todos os neurônios da camada seguinte (HAYKIN, 1999). Em relação às conexões existentes entre esses neurônios, estas podem ser do tipo *feedforward*, onde a propagação do sinal ocorre de forma unidirecional, isto é, da camada de

entrada, o sinal segue apenas em uma direção, passando pelos neurônios da camada oculta até chegar aos neurônios da camada de saída, não havendo retorno do sinal para camadas anteriores; ou do tipo *feedback*, quando podem formar ciclos (BRAGA *et al.*, 2000). **A rede utilizada neste trabalho é totalmente conectada e as conexões entre os elementos de processamento são do tipo *feedforward*.**

3.2.1.3 Funções de ativação

Os neurônios recebem entradas ponderadas por pesos e calculam o somatório dessas entradas para posteriormente gerar uma saída (HAYKIN, 1999). O resultado dessa soma é submetido a uma função, geralmente não linear, conhecida como função de ativação ou de transferência, que restringe o valor de saída do neurônio a um intervalo de valor finito.

As funções de transferência podem ter grande influência nas propriedades de convergência de uma rede neural (KORDOS; DUCH, 2004). Segundo Bishop (2006), a escolha da função de ativação utilizada nos neurônios da camada de saída depende do tipo de problema a ser resolvido, por exemplo: para problemas de regressão, são utilizadas funções lineares; para classificações binárias, pode-se utilizar sigmoides logísticas; para classificações multiclasse, funções *softmax*, etc. Existem diversos tipos de funções de ativação e as redes neurais podem fazer uso de apenas um tipo de função de transferência para todos os elementos de processamento ou pode utilizar um tipo de função para cada neurônio ou camada da RNA.

A resposta da rede para um determinado exemplo de um problema é fornecida após a execução de vários cálculos. De acordo com Bishop (2006), primeiro são realizadas M combinações lineares das variáveis de entrada, x_1, \dots, x_D como mostrado na equação (3.1):

$$\alpha_j = \sum_{i=1}^D w_{ji}^{(1)} x_i + b_j^{(1)} \quad (3.1)$$

onde $j = 1, \dots, M$ e o sobrescrito (1) indica que os parâmetros correspondentes se encontram na primeira camada oculta da rede. Os w_{ji} são os pesos e b_j é o *bias* associado às camadas, que tem o efeito de diminuir ou aumentar o valor líquido de entrada da função de transferência. Os valores de α_j são conhecidos como ativações. Eles são transformados utilizando uma função de ativação $h(\cdot)$ diferenciável e geralmente não linear como indicado na equação (3.2) (BISHOP, 2006).

$$z_j = h(\alpha_j) \quad (3.2)$$

O valor de z corresponde à saída dos neurônios ocultos. Para o caso de redes neurais sem camadas ocultas, z seria a saída da rede. Como a rede neural utilizada neste trabalho possui uma camada oculta, o cálculo prossegue combinando linearmente esses valores para o fornecimento de ativações das unidades da camada de saída, como é mostrado na equação (3.3) (BISHOP, 2006).

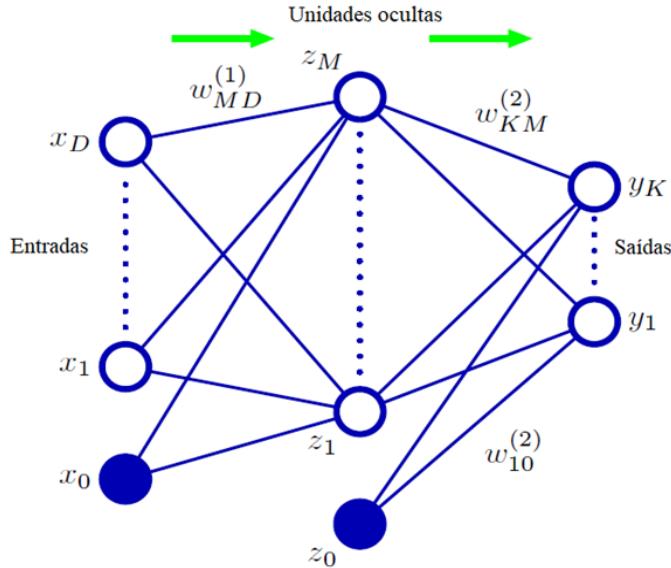
$$\alpha_k = \sum_{j=1}^M w_{kj}^{(2)} z_j + b_k^{(2)} \quad (3.3)$$

onde $k = 1, \dots, K$, e K é o número total de saídas da rede. O sobrescrito (2) indica que os parâmetros estão na segunda camada (camada de saída) da rede e w_{kj} são os pesos. As ativações α_k dos neurônios da camada de saída são então transformadas utilizando uma função de transferência adequada para o problema (Equação 3.4), que posteriormente fornece um conjunto de saídas y_k da rede (BISHOP, 2006).

$$y_k = \sigma(\alpha_k) \quad (3.4)$$

O Esquema 2 mostra o funcionamento de uma rede neural com uma camada oculta para auxiliar no entendimento das equações (3.1) a (3.4). Os componentes da camada de entrada, da camada oculta e da de saída são representados por nós, os pesos estão presentes nas conexões, os *bias* são as entradas extras x_0 e as saídas da camada oculta, z_0 . As setas indicam o sentido do fluxo de informações.

Esquema 2 – Diagrama de um RNA com uma camada oculta

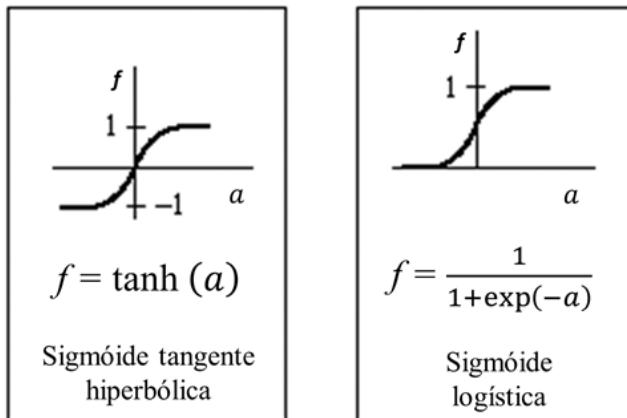


Fonte: Adaptada de Bishop (2006).

Dentre as diversas funções de ativação/transferência existentes, a mais utilizada em redes neurais artificiais é a função sigmoide. Seu gráfico possui o formato de um “S” e ela é a base das funções de transferência não lineares. As funções sigmoides são continuamente diferenciáveis, sendo que a diferenciabilidade é a condição fundamental que a função de transferência deve satisfazer em casos de redes multicamadas com algoritmos de aprendizado baseado em gradiente de erro (HAYKIN, 1999).

Segundo Haykin (1999), as formas mais utilizadas da função não-linear sigmoide são a função sigmoide logística e a sigmoide tangente hiperbólica, mostradas na Figura 3. A principal divergência entre essas sigmoides é o intervalo dos valores de saída. A função logística gera valores de saída entre [0,1], ao passo que a tangente hiperbólica produz valores no intervalo de [-1,1] (PRÍNCIPE *et al.*, 2000).

Figura 3 – Funções de ativação mais utilizadas



Fonte: Adaptado de Príncipe *et al.* (2000).

Neste trabalho, a função de transferência utilizada na camada oculta é a sigmóide tangente hiperbólica e na camada de saída a função utilizada é a softmax (Equação 3.5), também chamada de exponencial normalizado e pode ser considerada como uma generalização multiclassificadora da função sigmoide logística (BISHOP, 2006).

$$y_k(x, w) = \frac{\exp(a_k(x, w))}{\sum_j \exp(a_j(x, w))} \quad (3.5)$$

3.2.1.4 Algoritmos de aprendizado

O método de trabalho das redes neurais possibilita a construção de sistemas não-lineares que admitem um grande número de entradas, onde o seu desenvolvimento é baseado somente nas relações dos pares de entrada-saída das redes (ABRAHAM, 2004). Para um conjunto T de treinamento que possui n vetores de observação, com uma componente x e um valor alvo t que será a saída da RNA, a função de aproximação pode ser representada como:

$$T = \{(x_i, t_i) : i = 1:n\} \quad (3.6)$$

O constante ajuste dos pesos de uma rede neural tem como objetivo tentar aprender da forma mais coerente possível as informações que existem no conjunto de treinamento. A noção de quão próximos estão o conjunto de treinamento e o conhecimento adquirido pela rede neural sobre esse conjunto se dá através de uma função de erro na forma da equação (3.7), onde y_i representa a saída da rede neural.

$$\varepsilon = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (t_i - y_i)^2 \quad (3.7)$$

O objetivo consiste em encontrar uma rede γ tal que a saída gerada $y_i = (\gamma(x_i), w)$ seja a mais próxima possível da saída desejada t_i . Os algoritmos de aprendizagem se baseiam na ideia de utilizar a informação de erro da rede para realizar o ajuste dos pesos de forma que o conhecimento adquirido pela rede seja bem próximo ao existente nos dados de treino e, além disso, que a rede tenha capacidade de generalização. O ajuste de pesos pode ser realizado de diferentes formas, a depender do algoritmo de aprendizado escolhido. Os algoritmos tentam realizar esse ajuste de forma que a rede não caia em mínimos locais, comprometendo seu desempenho.

O processo de ajuste dos pesos da rede se dá através de técnicas de otimização não-linear, como o método de Newton, o método do gradiente descendente, Levenberg-Marquardt, entre outros (PRÍNCIPE *et al.*, 2000). **Neste trabalho, o método escolhido foi o de Levenberg-Marquardt por ser um dos mais eficientes e indicados para redes neurais que possuam centenas de pesos a serem ajustados** (HAGAN; MENHAJ, 1994). Basicamente, a matriz Jacobiana da função de erro é calculada em relação aos respectivos pesos que são modificados de forma que o erro diminua. A equação (3.8) mostra como é realizada a atualização dos pesos:

$$w(p+1) = w(p) - [J^T J + \mu I]^{-1} J^T \varepsilon(p) \quad (3.8)$$

onde p é o passo da iteração, μ é a taxa de aprendizagem, I é a matriz identidade, J representa a matriz Jacobiana mostrada na equação (3.9) e ε é o erro médio quadrático, determinado pela soma da diferença ao quadrado entre os valores alvos t_i e os gerados pela rede y_i , de acordo com a equação (3.7).

$$J = \begin{bmatrix} \frac{\partial \varepsilon_1(w)}{\partial w_1} & \dots & \frac{\partial \varepsilon_1(w)}{\partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial \varepsilon_N(w)}{\partial w_1} & \dots & \frac{\partial \varepsilon_N(w)}{\partial w_n} \end{bmatrix} \quad (3.9)$$

Após o treinamento, a rede neural deverá ter adquirido a habilidade de generalizar a informação aprendida do problema em questão com base nos parâmetros que foram extraídos.

3.2.1.5 Método de validação cruzada *k-fold*

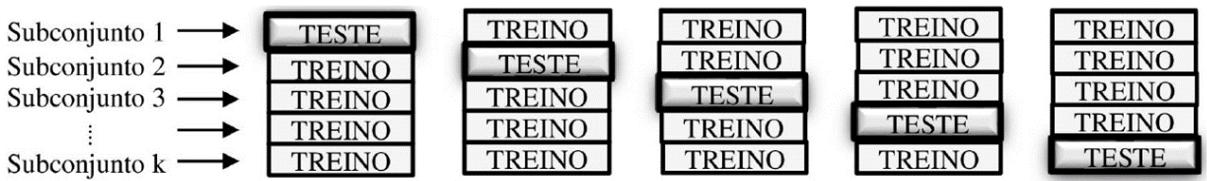
O método de validação cruzada é utilizado para avaliar a capacidade de generalização de um determinado modelo através de um conjunto de dados (KOHAVI, 1995). O objetivo é estimar quão preciso o modelo é na prática, ou seja, qual é o seu desempenho para um novo conjunto de dados. Além disso, os métodos de validação cruzada buscam garantir a capacidade de generalização de um modelo computacional quando estes são submetidos a um conjunto de dados não visto na fase de treino.

Um dos problemas mais comuns durante a fase de treinamento de uma RNA é a ocorrência de *overfitting*, definido pela concepção de um modelo que perfeitamente se ajusta as amostras utilizadas para treinamento (com baixo erro de predição e alta precisão), porém que não é capaz de atingir bom desempenho quando submetido a novos conjuntos daquele mesmo tipo de dado, ou seja, o modelo não consegue generalizar a informação aprendida (AMARAL, 2017). Para que este tipo de problema seja evitado e a capacidade de generalização dos modelos de redes neurais seja garantida, o uso da validação cruzada se faz necessário nas aplicações desta pesquisa.

Os métodos de validação cruzada consistem em particionar o conjunto de treinamento em dois subconjuntos, denominados treino e validação. O conjunto de validação é utilizado para testar o desempenho da rede a cada certo intervalo de iterações. A fase de treinamento é interrompida assim que o ponto de máxima generalização do modelo é encontrado, ou seja, quando o erro no conjunto de validação começa a subir (KOHAVI, 1995).

Existem diversas técnicas de validação cruzada, sendo que, neste trabalho, a validação *k-fold* é a utilizada (KOHAVI, 1995). Neste método, o conjunto de dados original é particionado aleatoriamente em k subconjuntos com a mesma quantidade de dados aproximadamente e contendo amostras de todas as classes. Em cada iteração, um subconjunto diferente é utilizado para teste e os outros restantes ($k-1$) para treino. Os procedimentos de treino e teste são repetidos k vezes. A precisão estimada é o número total de classificações corretas dividido pela quantidade de exemplos no conjunto de dados k . No final dessa validação, cada exemplo do conjunto de dados original foi testado uma única vez pelos algoritmos. O Esquema 3 apresenta o funcionamento do método de validação cruzada *k-fold*. O desempenho final do modelo computacional é medido através da média de acertos de todas as k classificações do *k-fold*.

Esquema 3 – Funcionamento da validação cruzada k -fold



Fonte: Amaral (2017).

3.2.2 Métodos de *clustering*

O *clustering*, também conhecido como agrupamento ou particionamento de dados, exerce um papel significativo na busca por estruturas em dados. É uma ferramenta utilizada durante anos em diversas áreas como medicina, economia, estudos estatísticos, etc. (BOCK; DIDAY, 2000). Segundo Jain *et al.* (1999), o procedimento de clusterização consiste na classificação não supervisionada de dados, formando grupos (*clusters*). O objetivo, de forma geral, é separar um determinado conjunto de dados em diferentes *clusters*, segundo uma noção de dissimilaridade ou de similaridade. Os dados considerados “similares” pertencerão a um mesmo *cluster* enquanto os considerados “diferentes” pertencerão a *clusters* distintos (ALVES, 2012).

Uma grande vantagem dos métodos de *clustering* é a sua capacidade de organizar grandes conjuntos de dados, simplificando informações e generalizando a análise de diferentes componentes. As informações simplificadas podem ser utilizadas para realizar previsões e efetuar suposições baseando-se nos grupos formados.

Existem diferentes técnicas de *clustering* catalogadas na literatura e essas técnicas podem ser classificados como métodos hierárquicos ou de partição. Para o primeiro caso, uma hierarquia de grupos é formada para determinar a similaridade existente entre os elementos. Os métodos hierárquicos podem ser aglomerativos ou ascendentes e divisivos ou descendentes. Os métodos aglomerativos ou ascendentes se iniciam com um elemento em cada *cluster*. Em seguida, os grupos vão sendo sucessivamente aglomerados de acordo com algum critério até todos os elementos estarem agrupados em um único *cluster*. Já o método descendente se inicia com um único *cluster* no qual estão presentes todos os elementos. Esse grupo inicial é então dividido sucessivamente em diversos grupos segundo algum critério até que todos os elementos estejam agrupados em grupos distintos, ou seja, até que cada *cluster* contenha apenas um elemento. Em relação aos métodos de partição, os grupos também são definidos de acordo com um critério de similaridade, porém o conceito de hierarquia não é aplicado.

Com base em resultados obtidos em trabalhos anteriores (CURY, 2010; ALVES, 2016; ALVES *et al.*, 2016) o método de *clustering* empregado neste trabalho é o algoritmo *k-means*, classificado como um método por partição e será discutido com mais detalhes no decorrer deste capítulo. Na seção seguinte, apresentam-se algumas métricas de distâncias utilizadas na medição da similaridade entre os objetos.

3.2.2.1 Métricas de distância

As métricas de distância exercem um papel fundamental na medição da similaridade entre objetos. É preciso identificar de que forma os objetos estão inter-relacionados, como eles são semelhantes ou diferentes entre si e quais medidas são utilizadas para tal comparação (SINGH *et al.*, 2013). A similaridade entre os elementos é avaliada através de uma função que estima a distância entre eles. Objetos são considerados similares se a distância entre eles é pequena. Caso contrário, são considerados diferentes, pois estão distantes (BOCK; DIDAY, 2000). Após a distância ser definida, o método de *clustering* tem a função de minimizar as distâncias entre os objetos de um mesmo grupo, o que é chamado de inércia intra-cluster e maximizar as distâncias entre os elementos de grupos distintos, o que é chamado de inércia inter-cluster (ALVES, 2012). O método de *clustering* deve gerar *clusters* com elevada similaridade intra-cluster e elevada dissimilaridade inter-cluster.

A escolha da função adequada de distância/similaridade é uma etapa fundamental do método de *clustering*. Um elemento A pode estar distante de um elemento B considerando uma métrica de distância, porém pode ser considerado próximo caso outra métrica seja utilizada. Existem diversas medidas de distância que podem ser encontradas na literatura. Algumas delas são apresentadas a seguir.

3.2.2.1.1 Distância Minkowski

A distância Minkowski é a métrica mais geral para o cálculo de distâncias entre dois objetos. Sendo E_i e E_j dois ensaios hipotéticos, então:

$$gs(E_i, E_j) = \sqrt[p]{\sum_{k=1}^n |E_{ik} - E_{jk}|^p} \quad (3.10)$$

onde p é o parâmetro de Minkowski e possui valores inteiros.

3.2.2.1.2 Distância Euclidiana

A distância Euclidiana calcula o comprimento do segmento de reta entre dois pontos no espaço. É a métrica de distância mais utilizada e é um caso especial da métrica Minkowski onde $p=2$ (FONTANA; NALDI, 2009). Sendo E_i e E_j dois ensaios dinâmicos e n a quantidade de categorias dos ensaios, têm-se:

$$gs(E_i, E_j) = \sqrt{\sum_{k=1}^n (E_{ik} - E_{jk})^2} \quad (3.11)$$

3.2.2.1.3 Distância *Cityblock*

A métrica *Cityblock* é um caso especial da distância de Minkowski onde o parâmetro $p=1$. Sendo E_i e E_j dois ensaios hipotéticos, têm-se:

$$gs(E_i, E_j) = \sum_{k=1}^n |E_{ik} - E_{jk}| \quad (3.12)$$

3.2.2.1.4 Distância *Cosine*

A métrica de distância *Cosine*, também é conhecida como similaridade do cosseno. Sejam E_i e E_j dois ensaios hipotéticos, então:

$$gs(E_i, E_j) = 1 - \frac{\sum_{k=1}^n E_{ik} \times E_{jk}}{\sqrt{\sum_{k=1}^n (E_{ik})^2} \times \sqrt{\sum_{k=1}^n (E_{jk})^2}} \quad (3.13)$$

3.2.2.2 Algoritmo *k-means*

O algoritmo *k-means* é um método de clusterização que tem como objetivo encontrar a divisão mais adequada de n dados em k grupos, de modo que a distância total entre os elementos de um grupo e o seu respectivo centroide, somada por todos os grupos, seja a mínima possível

(PIMENTEL *et al.*, 2003). O *k-means* é classificado como um método por partição onde o número de *clusters* ou grupos é considerado fixo e é definido inicialmente. Ele também é conhecido como k-médias e é o algoritmo mais comumente utilizado devido a facilidade de sua implementação (JAIN *et al.*, 1999). Esse algoritmo faz uso do conceito de centroides, que representam os grupos. O centroide é o centro de um grupo, e é calculado pela média de todos os elementos do grupo (FONTANA; NALDI, 2009).

A ideia por trás do algoritmo *k-means* é um processo iterativo que começa atribuindo aleatoriamente k elementos como centroides iniciais. Então é calculada a distância entre cada elemento e cada centroide através de uma função de distância/similaridade. Cada elemento é atribuído ao grupo ou *cluster* correspondente ao centroide do qual ele se encontra mais próximo. Após todos os elementos serem atribuídos aos *clusters*, os centroides de cada grupo são recalculados usando esses elementos dos grupos recém-criados. Esse processo continua até que os centroides se movam pouco em relação a sua posição anterior.

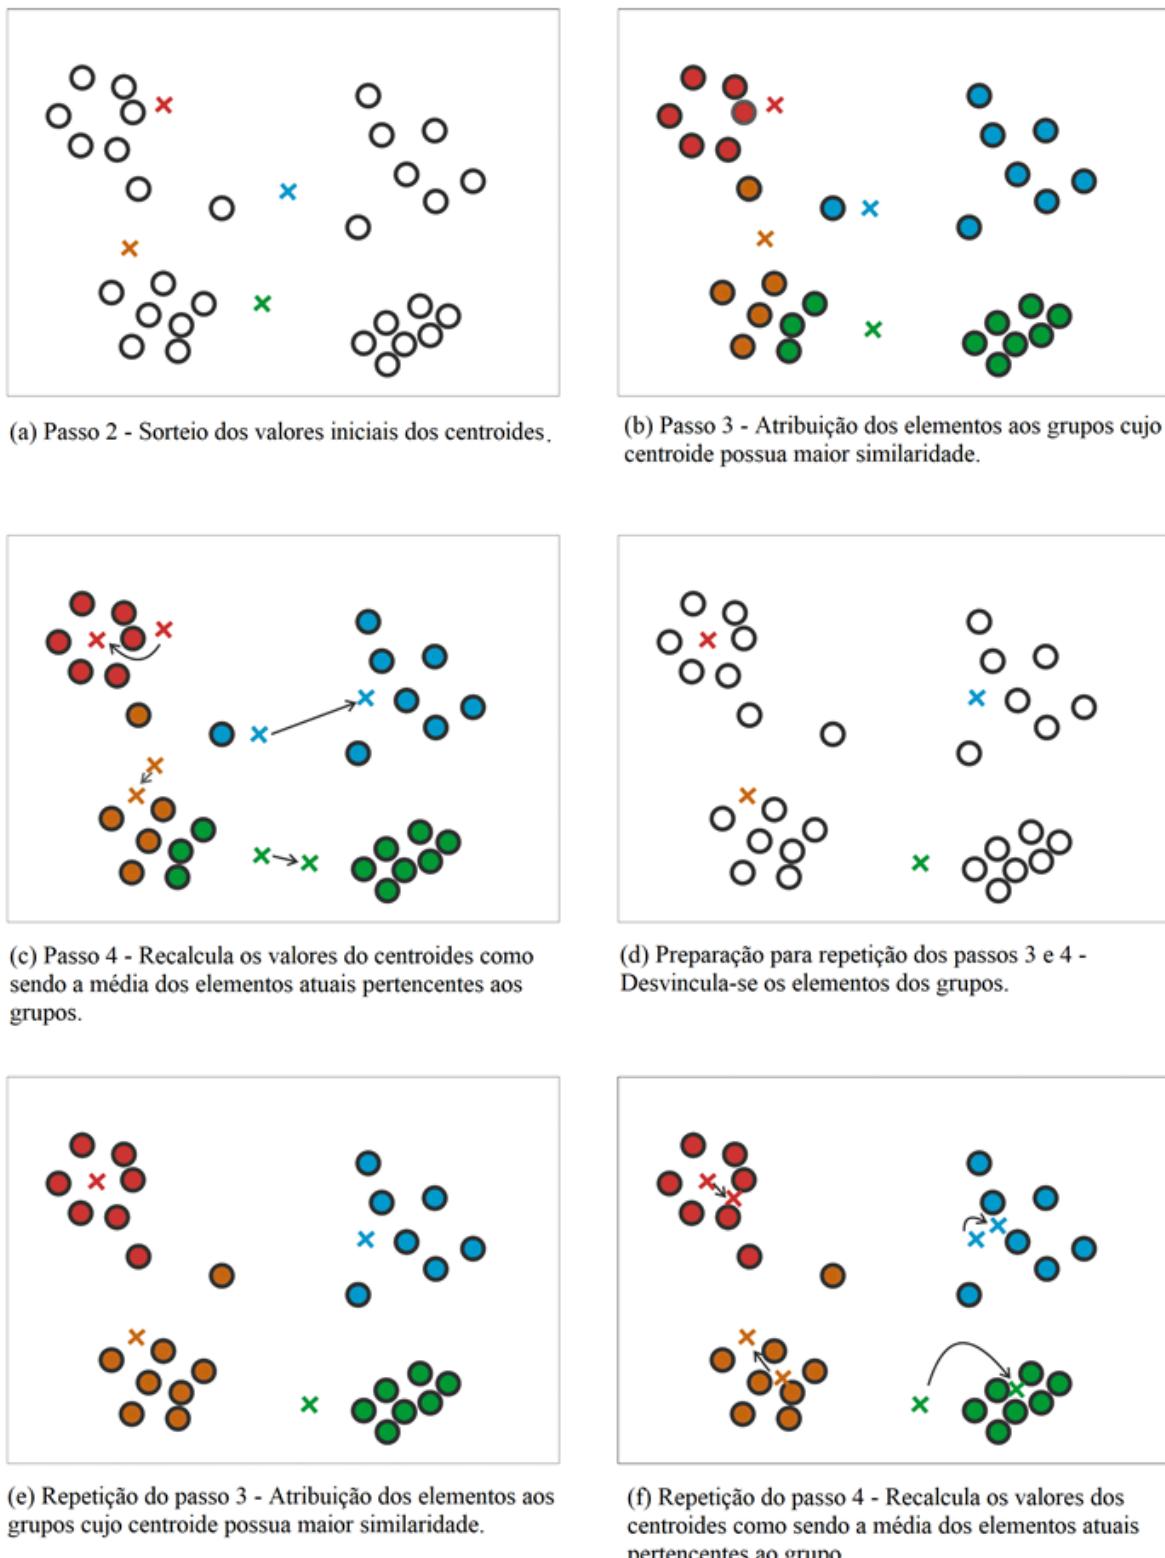
Segundo Fontana e Naldi (2009), o funcionamento do algoritmo *k-means* pode ser descrito pelas seguintes etapas:

- a) Define-se o número k de grupos a serem formados;
- b) Define-se os valores dos k centroides iniciais, seguindo algum critério, como por exemplo, sorteio aleatórios dos valores dentro das limitações de domínio de cada elemento;
- c) Atribui-se cada elemento ao *cluster* cujo centroide tenha maior similaridade com o elemento;
- d) Recalcula-se o valor do centroide de cada *cluster* como sendo a média dos novos elementos do *cluster*;
- e) Repetem-se as duas etapas anteriores até que os clusters se estabilizem, ou melhor, até que os centroides se movam pouco em comparação a sua posição anterior.

A Figura 4 ilustra o funcionamento do algoritmo *k-means* para divisão de um conjunto de dados em quatro grupos. Os objetos do conjunto são representados por círculos e os centroides por um “x”. Em 4(a), realiza-se a execução do passo 2 do algoritmo, isto é, a inicialização dos centroides; em 4(b), executa-se o passo 3 que é a atribuição dos elementos aos *clusters* correspondentes aos centroides dos quais eles se encontram mais próximos; em 4(c), realiza-se o passo 4, ou seja, o recálculo dos valores dos centroides utilizando os elementos dos *clusters* recém-criados; em 4(d), tem-se a preparação para repetição dos passos 3 e 4 e, em 4(e)

e 4(f), repetem-se os passos 3 e 4, respectivamente. Enquanto ocorrerem alterações nos grupos, os passos 3 e 4 permanecem se repetindo.

Figura 4 – Funcionamento do algoritmo *k-means*

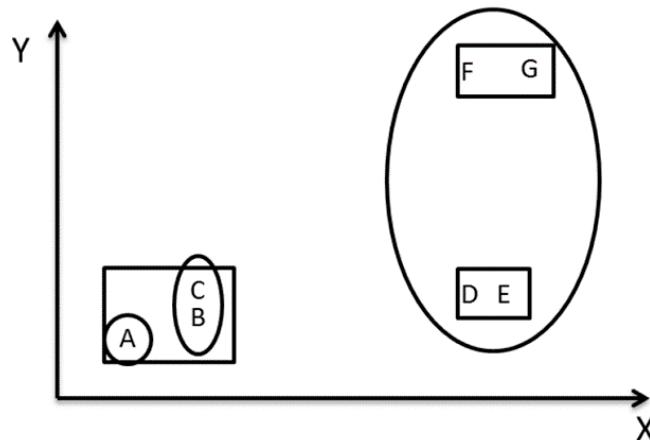


Fonte: Adaptado de Fontana e Naldi (2009).

Segundo Jain *et al.* (1999), um dos grandes problemas do algoritmo *k-means* é que ele é sensível a seleção dos centroides iniciais, pois pode convergir a um mínimo local se os *clusters* iniciais não forem escolhidos corretamente.

Para ilustrar esse problema, a Figura 5 mostra sete elementos bidimensionais. Se os elementos A, B e C forem considerados os centroides iniciais, a partição final será $\{(A, (B, C), (D, E, F, G)\}$ representada pelas elipses. Porém, os elementos seriam melhor agrupados se os elementos A, D e F fossem escolhidos como centroides iniciais. Então os grupos finais seriam $\{(A, B, C), (D, E), (F, G)\}$ representados pelos retângulos.

Figura 5 – Exemplo da sensibilidade do *k-means* à seleção dos centroides iniciais



Fonte: Jain *et al.* (1999).

Na literatura, existem diferentes formas de inicialização dos centroides. No entanto, as que mais se destacam são:

- Plus*: Seleciona k elementos implementando o algoritmo *k-means++* para inicializar o centro do *cluster*;
- Sample*: Seleciona k elementos da base de dados de forma aleatória;
- Uniform*: Seleciona k elementos aleatórios distribuídos de forma uniforme;
- Cluster*: Utiliza 10% de dados pré-selecionados de k subgrupos. Os centroides decorrentes são utilizados como centroides iniciais para o agrupamento.

3.2.2.2.1 Algoritmo *k-means++*

O algoritmo *k-means++* foi desenvolvido por Arthur e Vassilvitskii (2007) e tem como objetivo principal a implementação do método de inicialização dos centroides que é a seleção do melhor conjunto de valores iniciais dos centroides antes de aplicar o *k-means* tradicional. O *k-means++* tem como vantagem a melhoria do tempo de execução do *k-means* além de melhorar também a qualidade de seus resultados. Para um número k de *clusters*, o algoritmo de seleção de centroides iniciais funciona da seguinte forma:

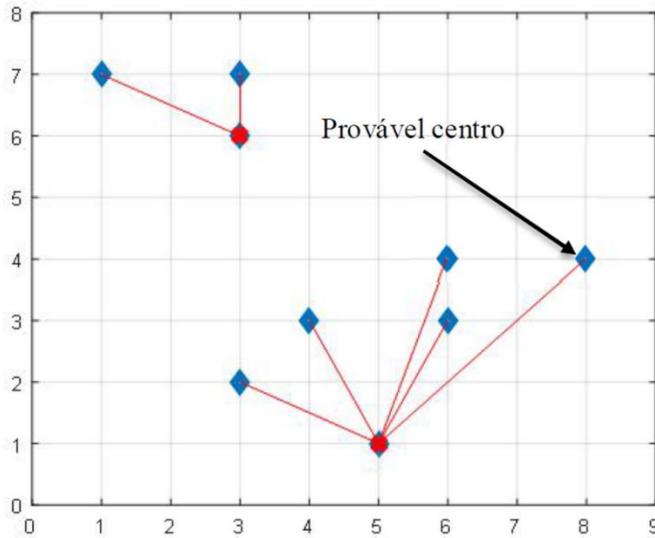
- a) Seleciona-se o primeiro centroide (c_1), escolhido aleatoriamente do conjunto de dados X ;
- b) Calcula-se as distâncias entre cada observação x e o centroide c_1 . Denomina-se a distância entre c_j e a observação m como $d(x_m, c_j)$;
- c) Seleciona-se uma nova observação do conjunto de dados como um novo centroide, utilizando-se uma distribuição de probabilidade ponderada, onde um ponto x é selecionado com probabilidade proporcional a $d^2(x_m, c_j)$:

$$\frac{d^2(x_m, c_1)}{\sum_{j=1}^n d^2(x_j, c_1)} \quad (3.14)$$

- d) Repete-se os passos 2 e 3 até que os k centroides tenham sido definidos;
- e) Após a definição dos centroides iniciais utiliza-se o *k-means* tradicional.

O funcionamento do método de inicialização dos centroides do *k-means++* é ilustrado no Esquema 4. Neste exemplo, o conjunto de dados possui apenas 9 observações, nas quais o algoritmo precisa definir os 3 melhores centroides ($k = 3$). O primeiro centroide c_1 , escolhido aleatoriamente, é a observação com coordenada (3,6). Em seguida, calcula-se a distância de cada uma das 8 observações restantes em relação ao primeiro centroide. A observação mais distante de c_1 provavelmente será aquela com coordenada (5,1), escolhida então como o segundo centroide c_2 . O terceiro centroide será selecionado de forma que os itens dos dados com valores das distâncias ao quadrado tenham uma baixa probabilidade de serem selecionados e as observações com grandes valores de distância ao quadrado tenham uma elevada probabilidade de serem escolhidos. Sendo assim, provavelmente c_3 será a observação com coordenada (8,4) (DAMASCENO, 2016).

Esquema 4 – Funcionamento do algoritmo *k-means++*



Fonte: Damasceno (2016).

3.2.3 Determinação dos limites de associação aos *clusters*

Para avaliar se um novo teste pertence aos *clusters* existentes ou se se trata de um novo comportamento, utiliza-se uma abordagem desenvolvida por Cury (2010) em sua tese de doutorado. Considere-se o exemplo de uma partição $P_1 = \{C^1, C^2\}$ contendo os *clusters* $C^1 = \{E_1, E_2, E_4\}$ e $C^2 = \{E_3, E_5\}$, onde E_i representam objetos (ensaios dinâmicos). O objetivo desta abordagem é atribuir a um desses dois grupos C^1 ou C^2 um novo ensaio E_6 . Entretanto, é possível que E_6 represente um novo comportamento que não seja descrito por nenhum dos dois *clusters* existentes. Assim, os ensaios são atribuídos aos grupos com base em suas distâncias a cada protótipo calculado. Os protótipos são uma representação de cada grupo (C^1, C^2). No caso deste trabalho, eles são os centroides dos *clusters*.

A metodologia proposta por Cury (2010) consiste nas seguintes etapas:

- Avaliação dos protótipos (centroides) do particionamento final, denominados G_1 e G_2 ;
- Avaliação de um vetor de distância (Equação (3.11)) entre o conjunto de testes do *cluster* 1 $\{E_1, E_2, E_4\}$ e seu protótipo G_1 e entre o conjunto do *cluster* 2 $\{E_3, E_5\}$ e o seu protótipo G_2 ;
- Ajustar uma função de distribuição de probabilidade acumulada às distâncias calculadas;

- d) Determinar um limite de associação para cada *cluster*, denominados dt_1 e dt_2 , correspondendo a 97,5% da função de distribuição;
- e) Calcular as distâncias entre o novo teste E_6 e o protótipo G_1 , denotadas por $\varphi(E_6, G_1)$ e também as distâncias de E_6 até o protótipo G_2 , denotadas por $\varphi(E_6, G_2)$;
- f) Os critérios de decisão para atribuir o novo teste a um dos dois grupos são:

$$Se \begin{cases} \varphi(E_6, G_1) < \varphi(E_6, G_2) \quad \& \quad \varphi(E_6, G_1) < dt_1 \Rightarrow E_6 \in C^1 \\ \varphi(E_6, G_1) < \varphi(E_6, G_2) \quad \& \quad \varphi(E_6, G_1) > dt_1 \Rightarrow E_6 \in C^3 \\ \varphi(E_6, G_1) > \varphi(E_6, G_2) \quad \& \quad \varphi(E_6, G_2) < dt_2 \Rightarrow E_6 \in C^2 \\ \varphi(E_6, G_1) > \varphi(E_6, G_2) \quad \& \quad \varphi(E_6, G_2) > dt_2 \Rightarrow E_6 \in C^3 \end{cases}$$

onde C^3 representa um novo grupo e dt_1 e dt_2 são os limites de associação estabelecidos correspondentes aos *clusters* C^1 e C^2 , respectivamente.

4 METODOLOGIA

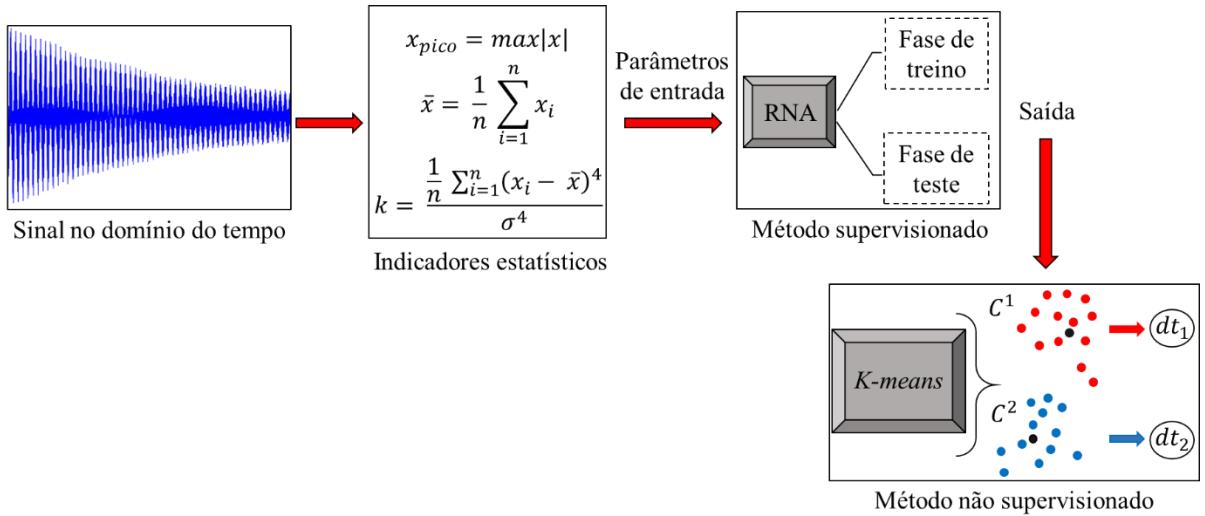
A metodologia proposta é dividida em duas fases, sendo que a primeira consiste na criação do modelo de detecção de danos proposto (Esquema 5) e, a segunda, na classificação de novos ensaios dinâmicos (Esquema 6).

Neste trabalho, os ensaios dinâmicos (sinais no domínio do tempo) são caracterizados por indicadores estatísticos. Na primeira fase da metodologia proposta, os indicadores são extraídos de sinais dinâmicos relativos a dois estados estruturais (níveis de danos, por exemplo) conhecidos e, em seguida, são organizados em matrizes para servirem de entrada ao método supervisionado (RNA) juntamente com seus respectivos rótulos (sem danos, dano nível 1, dano nível 2, etc.). Alguns parâmetros da rede, tais como o número de neurônios, o método de treinamento e função de erro, são definidos *a priori*. Parte dos dados de entrada é utilizada para o treinamento (treino e validação) da RNA e, o restante, utilizada para teste.

É importante destacar que esta primeira etapa da metologia proposta, apesar de ser classificada como supervisionada, não requer necessariamente o conhecimento de dois estados estruturais (estrutura com e sem danos, por exemplo) para sua aplicação. Assegurando-se que os sinais referentes à estrutura nesta primeira etapa estejam associados a um único estado estrutural, pode-se lançar mão de dados fictícios (que serão explicados mais adiante) que exprimem um comportamento dinâmico verdadeiramente diferente daquele extraído dos dados experimentais. Assim, de posse desses dois grupos de parâmetros (um proveniente da estrutura monitorada e outro de dados fictícios), pode-se estabelecer um método para a aplicação das redes neurais sem a necessidade de se conhecer dois estados estruturais. Essa observação é importante pois qualifica a metodologia proposta para sua aplicação em situações reais de SHM onde, *a priori*, não se conhece quando ocorreu alguma mudança no comportamento estrutural. Assim, para essa primeira etapa da metodologia, demanda-se apenas que os sinais estruturais empregados sejam todos referentes ao mesmo estado da estrutura, como já mencionado.

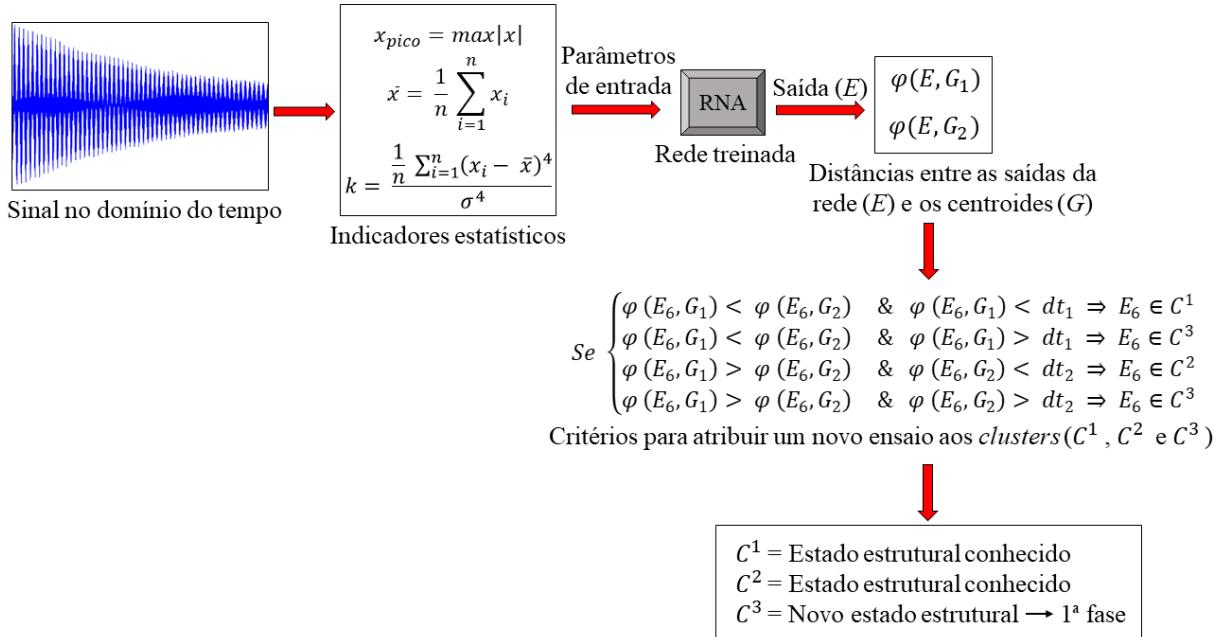
Em seguida, emprega-se a rede treinada para classificar todos os dados de entrada (treino, validação e teste) e as respostas (saídas) para esses dados são utilizadas como dados de entrada para o método não supervisionado (*k-means*). Parâmetros como o número de *clusters* a serem formados, métrica de distância e forma de inicialização dos centroides são definidos *a priori*. O algoritmo *k-means* clusteriza essas entradas e dois *clusters* (C^1 e C^2) são formados inicialmente, cada um representando um estado estrutural. Depois dos grupos formados, as distâncias limites de associação (dt_1 e dt_2) de cada *cluster* são calculadas, conforme mencionado na seção 3.2.3 (etapas de “a” a “d”).

Esquema 5 – Criação do modelo de detecção de danos proposto (1^a fase)



Fonte: Elaborado pelo autor.

Na segunda fase da metodologia (Esquema 6), após todos os parâmetros serem definidos, inicia-se a classificação de novos ensaios dinâmicos através do método híbrido proposto. Indicadores estatísticos são extraídos do sinal dinâmico e organizados em matrizes para serem classificados utilizando-se a rede neural já treinada. Calcula-se, em seguida, as distâncias entre as respostas da rede (saídas), os novos dados e os centroides (G_1 e G_2) de cada cluster, denotadas por $\varphi(E, G_1)$ e $\varphi(E, G_2)$, conforme etapa “e” da seção 3.2.3. Com base nessas distâncias e nas distâncias limites de associação, verifica-se se os novos ensaios pertencem aos clusters existentes (estados de danos conhecidos) ou se representam um novo comportamento dinâmico estrutural, de acordo com a etapa “f” da seção 3.2.3. Para o primeiro caso, novos ensaios continuarão sendo classificados na segunda fase da metodologia até que se identifique um novo comportamento estrutural. Caso contrário, o novo ensaio passa a ser utilizado como entrada do método proposto na primeira fase, já que um novo comportamento estrutural foi identificado. Dessa forma, começa-se a partir de três estados estruturais conhecidos.

Esquema 6 – Classificação de novos ensaios dinâmicos (2^a fase)

Fonte: Elaborado pelo autor.

Foi criado um estado de dano fictício (matriz formada por “1”) para ser utilizado como dado de entrada do método híbrido juntamente com o estado atual da estrutura até que se identifique um novo comportamento estrutural. A ideia é que o estado fictício fique bem distante do estado de dano real de forma a não influenciar na classificação do método proposto. Após o novo comportamento ser detectado, o estado fictício é descartado e passa-se a trabalhar apenas com os estados de dano reais.

Os indicadores estatísticos utilizados para caracterizar as respostas dinâmicas temporais, extraídas da estrutura, são os sugeridos por Farrar e Worden (2012) (Tabela 2) e são: Valor de pico (I_1), média (I_2), média quadrática (I_3), raiz da média quadrática (I_4), variância (I_5), desvio-padrão (I_6), assimetria (I_7), curtose (I_8), fator de crista (I_9) e fator-K (I_{10}). Em todas as aplicações (numéricas e experimentais) os indicadores estatísticos foram organizados de duas formas diferentes: por “sensores” e por “ensaios”, para depois serem utilizados como entrada da RNA no método proposto. A forma como os dados de entrada são organizados influencia no aprendizado e na resposta final da RNA, o que consequentemente influencia na classificação do método híbrido. Sendo assim, verificou-se qual das duas formas mais contribuía para o bom desempenho da abordagem proposta.

Quando os dados são organizados por “sensores” (Equação 4.1), os sinais de cada sensor são considerados separadamente. Os dados de entrada são organizadas em matrizes de forma

que o número de linhas corresponde ao número de sensores (n) existentes e o número de colunas corresponde ao número total de estatísticas extraídas de cada sinal de cada ensaio (m) por sensor.

$$\begin{bmatrix} S_1 I_{1-E1} & S_1 I_{2-E1} & \dots & S_1 I_{10-E1} & \dots & S_1 I_{1-Em} & \dots & S_1 I_{10-Em} \\ S_2 I_{1-E1} & S_2 I_{2-E1} & \dots & S_2 I_{10-E1} & \dots & S_2 I_{1-Em} & \dots & S_2 I_{10-Em} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots \\ S_n I_{1-E1} & S_n I_{2-E1} & \dots & S_n I_{10-E1} & \dots & S_n I_{1-Em} & \dots & S_n I_{10-Em} \end{bmatrix} \quad (4.1)$$

A primeira linha da matriz, por exemplo, representa o sensor 1 (S_1) e as dez primeiras colunas são os dez indicadores estatísticos (I) extraídos do sensor S_1 do primeiro ensaio (E_1). As dez colunas seguintes são o dez indicadores extraídos do sinal deste mesmo sensor (S_1), do segundo ensaio (E_2), e assim por diante, até se chegar aos dez últimos indicadores extraídos do sensor S_1 do ensaio E_m .

Nos dados organizados por “ensaios” (Equação 4.2), considera-se o ensaio ao longo de toda a estrutura analisada. Cada linha da matriz representa um ensaio, e as colunas são os indicadores estatísticos de todos os sensores. A cada dez colunas, tem-se os dez indicadores extraídos do sinal de um determinado sensor.

$$\begin{bmatrix} E_1 I_{1-s1} & E_1 I_{2-s1} & \dots & E_1 I_{10-s1} & \dots & E_1 I_{1-sn} & \dots & E_1 I_{10-sn} \\ E_2 I_{1-s1} & E_2 I_{2-s1} & \dots & E_2 I_{10-s1} & \dots & E_2 I_{1-sn} & \dots & E_2 I_{10-sn} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots \\ E_m I_{1-s1} & E_m I_{2-s1} & \dots & E_m I_{10-s1} & \dots & E_m I_{1-sn} & \dots & E_m I_{10-sn} \end{bmatrix} \quad (4.2)$$

A primeira linha da matriz, por exemplo, representa o primeiro ensaio (E_1) e as dez primeiras colunas são os dez indicadores estatísticos (I) extraídos do sensor 1 (S_1) do primeiro ensaio (E_1). As dez colunas seguintes são os dez indicadores extraídos do sensor 2 (S_2) do primeiro ensaio (E_1), e assim por diante, até se chegar aos dez últimos indicadores extraídos do sensor S_n do ensaio E_1 .

Tanto nas aplicações numéricas, quanto nas experimentais, os procedimentos seguem os seguintes passos:

- a) Os indicadores estatísticos são extraídos dos sinais dinâmicos registrados durante os ensaios que são realizados sob diferentes estados estruturais (diferentes níveis de dano, ruído, etc.);

- b) Os indicadores são organizados por “ensaios” e por “sensores”, conforme mencionado anteriormente;
- c) Os indicadores estatísticos relativos a dois estados estruturais são utilizados como entrada da rede neural no método híbrido e os parâmetros necessários são definidos (fase 1 – metodologia);
- d) Novos estados estruturais são apresentados ao método híbrido para classificação (fase 2 – metodologia).

No capítulo seguinte, a presente estratégia é avaliada a partir de testes numéricos e de ensaios experimentais. Os algoritmos de inteligência computacional (RNA e *k-means*) e os indicadores estatísticos foram desenvolvidos usando *toolboxes* e funções internas disponíveis no Matlab R2018a.

5 APLICAÇÕES

Como já mencionado, o objetivo desta dissertação é realizar a acoplagem de métodos supervisionados (Redes Neurais Artificiais) e não supervisionados (*k-means*) para construção de um classificador híbrido que tenha capacidade de detectar modificações estruturais. Sabe-se que os métodos supervisionados não são capazes de rotular uma nova classe de dano quando esta surge. Assim, tais técnicas são utilizadas em conjunto com métodos de classificação não supervisionada para que, a partir das respostas das técnicas supervisionadas, seja possível a detecção de novos estágios de dano quando estes surgem, sendo necessário de início, apenas o conhecimento prévio do estado atual da estrutura.

Neste capítulo, o desempenho do classificador híbrido é avaliado quando este é empregado na detecção de alterações nas respostas vibracionais de três diferentes estruturas. Inicialmente, o método proposto é aplicado a um modelo numérico de viga. Em seguida, a uma estrutura 3D localizada no Laboratório de Pesquisa em Engenharia de Terremotos da Universidade da Colúmbia Britânica (UBC – University of British Columbia), no Canadá e, por último, a um viaduto ferroviário (PK 075+317, na França). Indicadores estatísticos extraídos dos sinais de aceleração registrados durante os ensaios dinâmicos realizados sob diferentes estados estruturais são utilizados como parâmetros de entrada do método proposto. Como resultado, o classificador híbrido permite categorizar as respostas dinâmicas a cada um dos seus respectivos estados estruturais.

5.1 SIMULAÇÕES NUMÉRICAS

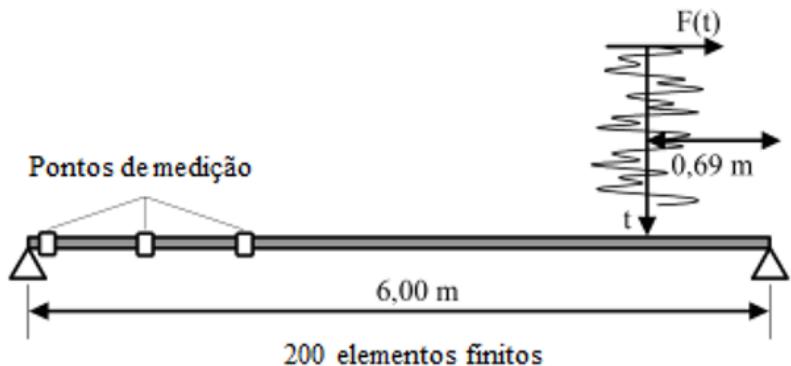
Nesta seção, a fim de se explorar as potencialidades da abordagem proposta utilizando diretamente os dados de aceleração, o classificador híbrido é aplicado a um estudo de uma viga numérica submetida a diferentes níveis de dano e ruído. Os estudos numéricos são, geralmente, o primeiro passo para a análise do desempenho e aptidão dos métodos de detecção de danos estruturais. Eles possibilitam o teste de diferentes condições estruturais (diferentes níveis de dano, ruído, etc.). Assim, considera-se relevante o seu uso para análise da eficiência do método proposto. O objetivo geral desta aplicação é verificar a capacidade do classificador híbrido para distinguir estados estruturais diante da presença de diferentes níveis de dano e ruído nos sinais.

Os dados sintéticos utilizados nos testes realizados são obtidos através de um modelo de elementos finitos de uma viga biapoiada de seção transversal perfil I e 6m de comprimento (desenvolvido na pesquisa de Cury (2010)). As propriedades mecânicas do modelo são:

- a) Massa específica = 7850 kg/m^3 ;
- b) Módulo de elasticidade longitudinal (E) = 210 GPa;
- c) Momento de inércia = $2.845 \times 10^{-8} \text{ m}^4$;
- d) Área de seção transversal = $2.81 \times 10^{-3} \text{ m}^2$.

O modelo discretizado é formado por uma malha de 200 elementos de viga de Euler-Bernoulli (HIBBELER, 2010), na qual cada elemento possui dois nós com dois graus de liberdade cada um (translação vertical e rotação). A excitação é uma força com amplitudes e frequências aleatórias aplicada a 0,69 m de distância do apoio direito. As respostas dinâmicas são medidas durante 100 segundos em dez pontos equidistantes da viga, com frequência de amostragem igual a 1/100s. A representação esquemática da viga estudada é apresentada na Figura 6.

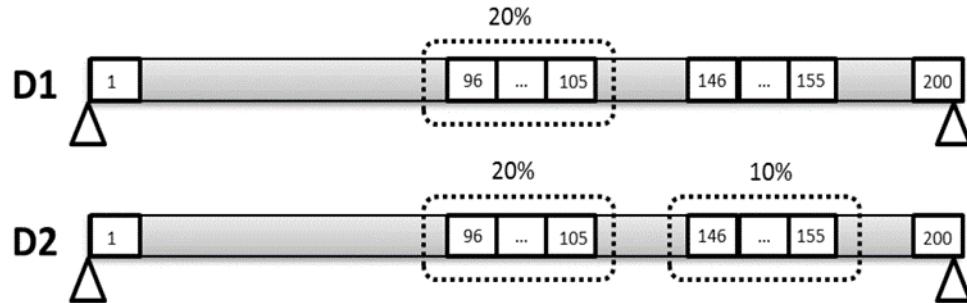
Figura 6 – Representação da viga modelada



Fonte: Cury (2010).

Três configurações estruturais são proposta: (i) o estado inicial da estrutura (viga sem danos), denominado D0; (ii) o nível de dano 1, representado a partir de uma redução de 20% do módulo de elasticidade longitudinal no meio do vão da viga (nos elementos 96 ao 105), denominado D1; (iii) o nível de dano 2, onde além da redução de 20% no meio do vão, também é feita uma redução de 10% do módulo de elasticidade no quarto de vão da viga (nos elementos 146 ao 155), denominado D2. A Figura 7 ilustra as configurações de danos impostos à viga.

Figura 7 – Configurações de danos simulados



Fonte: Alves (2012).

Para cada configuração de dano, três níveis de ruídos foram adicionados às respostas dinâmicas: sem ruído (R0), 5% de ruído (R1) e 10% de ruído (R2). A forma como os ruídos são gerados e adicionados aos sinais dinâmicos é definida pela equação (5.1):

$$x_{i,ruído} = x_i + \eta_{ruído} \cdot \sigma_{x_i} \cdot V \sim N(0,1) \quad (5.1)$$

onde $x_{i,ruído}$ e x_i representam respectivamente, o sinal dinâmico com ruído e sem ruído medidos pelo sensor i , $\eta_{ruído}$ corresponde ao nível de ruído adicionado, σ_{x_i} é o desvio-padrão de x_i e $V \sim N(0,1)$ é um vetor gaussiano com média nula e desvio-padrão unitário.

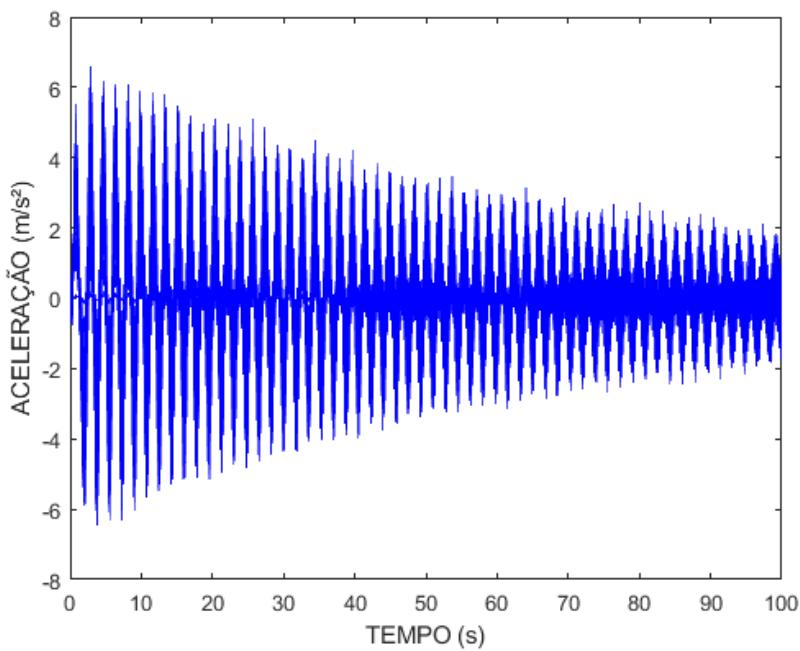
Para cada nível de dano e de ruído, 10 ensaios diferentes são simulados, o que gera um total de 90 ensaios (vide resumo na Tabela 3). Para cada ensaio, 10.000 pontos são medidos para cada um dos 10 sensores. Dos sinais de cada sensor são extraídos os dez indicadores estatísticos que em seguida são organizados por “ensaios” e por “sensores”. O Gráfico 1 mostra uma resposta típica da estrutura obtida por um dos ensaios.

Tabela 3 – Resumo dos ensaios simulados

		Níveis de ruído			
		R0	R1	R2	
		D0	10	10	10
Níveis de dano	D1	10	10	10	
	D2	10	10	10	

Fonte: Alves (2012).

Gráfico 1 – Resposta típica do modelo numérico de viga



Fonte: Elaborado pelo autor.

A organização dos dados de entrada é feita das seguintes formas:

- a) Dados organizados por “ensaios”: os indicadores estatísticos referentes a cada nível de dano e de ruído foram organizados separadamente em nove matrizes de entrada de dimensão [10x100], ou seja, cada matriz representa uma configuração estrutural, onde as 10 linhas correspondem ao número de ensaios realizados por nível de dano e ruído e as 100 colunas são os indicadores estatísticos extraídos dos sinais dos 10 sensores (10 indicadores x 10 sensores = 100 indicadores);
- b) Dados organizados por “sensores”: os indicadores estatísticos de cada nível de dano e de ruído foram organizados separadamente em nove matrizes de entrada de dimensão [10x100], ou seja, cada matriz também representa uma configuração estrutural, onde as 10 linhas correspondem ao número de sensores utilizados nos ensaios, e as 100 colunas são os indicadores estatísticos extraídos de cada sensor para todos os 10 ensaios realizados (10 indicadores x 10 ensaios = 100 indicadores por sensor).

O modelo de RNA implementado no método híbrido é do tipo MLP com uma camada oculta. O número de neurônios utilizados na camada oculta da rede influencia em sua resposta final e, como consequência, também influencia na resposta final do classificador híbrido. Tendo isso em vista, foram realizados testes de sensibilidade do método proposto em relação ao

número de neurônios a serem utilizados na camada oculta da RNA. Quando os dados de entrada são organizados por “sensores” os números de neurônios testados são: 25, 35 e 50, e quando são organizados por “ensaios” os números testados são: 15, 25 e 35. Para definir esses três valores, diversos números também foram testados. Os testes começaram com o número de neurônios igual a 10, e foram variando em uma escala de 5 até se chegar a 100 neurônios. De todos os números testados os três valores que mais influenciavam positivamente no funcionamento do método proposto foram selecionados e os resultados obtidos com estes são analisados e comparados mais adiante.

O algoritmo de aprendizado utilizado na RNA é o de Levenberg-Marquardt por ser um dos mais eficientes e indicados (HAGAN; MENHAJ, 1994) e o erro médio quadrático é empregado como função de custo. As funções de ativação utilizadas nos neurônios da camada oculta e nos da saída foram, respectivamente, a função sigmoide tangente hiperbólica (Figura 3) e a função *softmax* (Equação 3.5).

Para a escolha da métrica de distância e forma de inicialização dos centroides a serem empregados no algoritmo *k-means* no método híbrido, foram realizados testes utilizando as diferentes entradas (dados organizados por “ensaios” e por “sensores”). As métricas de distâncias testadas foram a *squareeuclidean*, *cityblock* e *cosine* e as formas de inicialização dos centroides foram a *plus*, *sample*, *uniform* e a *cluster*. Todas essas métricas de distância e formas de inicialização testadas no *k-means* geraram bons resultados no método híbrido, não havendo diferenças significativas entre elas, conforme é possível verificar no Apêndice A. Sendo assim, optou-se por utilizar a métrica *cityblock* e a forma de inicialização *plus* em todas as aplicações desta pesquisa.

Como em um monitoramento real o que se tem inicialmente é apenas o estado atual da estrutura, primeiro foram realizados testes treinando a rede no método híbrido com o estado de dano fictício (matriz de “1”) e o estado sem danos, ambos sem ruído. Os outros níveis de dano foram utilizados para teste do classificador híbrido e são apresentados, em uma segunda etapa, um a um. Sendo assim, a matriz de entrada da RNA possui dimensão [20x100], tanto quando os dados de entrada são organizados por “sensores” quanto por “ensaios”, onde as linhas 1 a 10 da matriz representam o estado de dano fictício e as linhas 11 a 20 o estado sem danos, ruído zero. Por se tratar de um algoritmo de aprendizado supervisionado, as RNAs também necessitam, como dados de entrada, dos rótulos (classes de dano) correspondentes a cada observação existente na matriz de entrada. Assim, foi gerada uma matriz alvo [20x2], onde as linhas indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Dano fictício; [0 1] – Sem danos.

Como as redes foram treinadas com o estado de dano fictício e o estado sem danos (D0), os *clusters* formados pelo *k-means* no método híbrido são relativos a esses dois estados estruturais, ou seja, um *cluster* representa o estado de dano fictício e o outro representa o estado sem danos. Neste caso, os estados de dano 1 e 2 (D1 e D2) se tratam de novos comportamentos estruturais.

Nas simulações realizadas, as redes neurais utilizadas no método híbrido foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold, gerando, assim, 10 classificadores híbridos. O desempenho final da rede, medido para os dados de teste das 10 classificações do 10-fold é igual a 100% para as duas formas de organização dos dados e para todos os números de neurônios testados. A Tabela 4 e a Tabela 5 apresentam os resultados obtidos pelo método híbrido e pelas redes para as diferentes formas de organização dos dados de entrada (por “sensores” e por “ensaios” respectivamente). A taxa de classificação é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 4 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)

		Número de neurônios									
		25			35			50			
		R0	R1	R2	R0	R1	R2	R0	R1	R2	
Método híbrido	D0	Média	- (2)	90	100	-	90	90	-	100	100
		DP (1)	-	0	0	-	0	0	-	0	0
	D1	Média	0	0	10	60	60	60	80	80	80
		DP	0	0	0	0	0	0	0	0	0
RNA	D2	Média	0	0	0	30	20	20	90	90	90
		DP	0	0	0	0	0	0	0	0	0
	D0	Média	-	100	100	-	100	100	-	100	100
		DP	-	0	0	-	0	0	-	0	0
D1/D2		Média	N/A(3)	N/A							
		DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificação com as redes neurais.

Analizando os resultados da Tabela 4, é possível observar como o número de neurônios utilizados na camada oculta da rede influencia na classificação do método híbrido e essa influência pode ser negativa ou positiva. Isso ocorre pois, apesar de o número de neurônios não afetar a classificação final da RNA, ele causa variações nas respostas da rede que serão clusterizadas. Essas variações influenciam, portanto, na resposta final do método híbrido. A depender do número de neurônios a ser utilizado, as respostas da rede podem estar mais próximas umas das outras para um mesmo nível de dano, como podem também estar bastante heterogêneas. Além disso, podem ser mais ou menos precisas. O ideal para o bom funcionamento do classificador híbrido é que as respostas da rede para um mesmo nível de dano a serem clusterizadas sejam precisas e o mais próximas possíveis umas das outras. Assim, as distâncias dos elementos dos *clusters* até seus respectivos centroides também serão próximas umas das outras e então haverá mais chances de se chegar a uma distância limite de associação de cada *cluster* mais apropriada. Com isso, evita-se uma tendência de que novos dados apresentados sejam classificados – incorretamente – como estados de dano conhecidos.

Ainda com base nos resultados da Tabela 4, é possível verificar que o desempenho do método híbrido ao se utilizar 25 ou 35 neurônios na camada oculta da rede foi satisfatório na identificação do estado estrutural conhecido (D0), mesmo havendo a presença de ruído, o que mostra uma certa robustez do classificador. Porém, para estes dois números de neurônios, o desempenho do método híbrido na detecção de novos comportamentos estruturais (D1 e D2) não foi satisfatório. Os melhores resultados foram obtidos ao se utilizar 50 neurônios na camada oculta da RNA. Neste caso, o desempenho do método híbrido foi satisfatório tanto na identificação de comportamentos estruturais conhecidos, quanto na detecção de novos comportamentos estruturais, obtendo-se taxas de classificações superiores a 80%. Em relação a presença de ruído, o classificador se mostrou bastante robusto.

No que se refere às RNAs, suas taxas de classificações foram as mesmas para todos os números de neurônios testados. É possível verificar que esta técnica apresentou excelente desempenho no reconhecimento do estado de dano o qual ela foi treinada para identificar (D0), mesmo havendo presença de ruído nos dados. Porém, quando os novos estados de dano (D1 e D2) são apresentados a rede, ela sempre os classifica como estado sem danos (D0). Isto ocorre, pois, a rede sempre irá atribuir os novos ensaios apresentados a uma das classes que foram fornecidas a ela durante seu treinamento, ou seja, ela não é capaz de rotular uma nova classe de dano.

Analizando-se os resultados obtidos com os dados de entrada organizados por “ensaios” na Tabela 5, é possível verificar que para todos os números de neurônios testados o método

híbrido apresentou um bom desempenho na identificação do estado estrutural conhecido (D0), mesmo com a presença de ruído. Entretanto, os resultados não foram satisfatórios na detecção dos estados estruturais desconhecidos (D1 e D2). Quando o número de neurônios utilizado na camada oculta da rede é igual a 25, os resultados do método híbrido são melhores. Porém, ainda assim, para os estados de danos desconhecidos, os resultados não são tão bons. Isso ocorre, pois, a rede classifica a maioria dos novos dados apresentados (D1 e D2) na fase 2 da metodologia como estado sem danos (D0) com precisão parecida com a que ela classifica D0 na fase 1 da metodologia. Dessa forma, a resposta da rede para esses novos dados fica bem próxima aos elementos do *cluster* D0 e isso faz com que o método híbrido os classifique como pertencentes a esse *cluster*. Os dados relativos aos estados D1 e D2 que o método híbrido classificou corretamente como um novo estado estrutural foram dados que a rede classificou como estado sem danos, porém com uma precisão menor.

Tabela 5 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em%)

		Número de neurônios								
		15			25			35		
		R0	R1	R2	R0	R1	R2	R0	R1	R2
Método híbrido	D0	Média	-(2)	90	90	-	90	90	-	90
		DP (1)	-	0	0	-	0	0	-	0
	D1	Média	40	40	50	70	80	70	10	10
		DP	0	0	0	0	0	0	0	0
RNA	D2	Média	40	40	40	20	30	30	10	10
		DP	0	0	0	0	0	0	0	0
	D0	Média	-	100	100	-	100	100	-	100
		DP	-	0	0	-	0	0	-	0
D1/	Média	N/A(3)	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
	DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
D2	Média	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
	DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificação com as redes neurais.

Em relação à rede neural, esta alcançou excelente desempenho na classificação do estado de dano para o qual ela foi treinada para reconhecer. Além disso, ela obteve um ótimo desempenho na classificação dos dados de teste, como mencionado anteriormente. Porém,

apesar de a rede ter alcançado altas taxas de classificações corretas para este caso, foi observado que suas respostas ainda precisam ser melhoradas para bom funcionamento do método proposto.

Na metodologia proposta, após um novo estado estrutural ser detectado, o estado de dano fictício é descartado e passa-se a trabalhar apenas com os estados de danos reais. Para os resultados mostrados na Tabela 6 e na Tabela 7, as redes neurais dos classificadores híbridos são treinadas com o estado sem danos e o estado de dano 1, ambos sem ruído. Sendo assim, a matriz de entrada da RNA fica com dimensão [20x100], tanto quando os dados de entrada são organizados por “sensores” quanto por “ensaios”, onde as linhas 1 a 10 da matriz representam o estado sem danos e as linhas 11 a 20 o estado de dano 1. Também foi criada uma matriz alvo [20x2] contendo os rótulos (classes de dano) correspondentes a cada observação contida na matriz de entrada, onde as linhas indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Sem danos; [0 1] – Dano nível 1. Como as redes foram treinadas com o estado sem danos e estado de dano um, os *clusters* formados pelo *k-means* no método híbrido são relativos a esses dois estados estruturais. Neste caso, o estado de dano 2 se trata de um comportamento estrutural desconhecido.

As redes neurais utilizadas no método híbrido foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede, medido para os dados de teste, das 10 classificações do 10-fold é igual a 100% quando os dados são organizados por “sensores” e igual a 95% quando são organizados por “ensaios”, para todos os números de neurônios testados. A Tabela 6 e a Tabela 7 apresenta os resultados obtidos pelo método híbrido e pelas redes, para as diferentes formas de organização dos dados de entrada. A taxa de classificação é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 6 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)

		Número de neurônios									
		25			35			50			
		R0	R1	R2	R0	R1	R2	R0	R1	R2	
Método híbrido	D0	Média	-(2)	100	90	-	80	60	-	90	90
	D0	DP(1)	-	0	0	-	0	0	-	0	0
	D1	Média	-	98	96	-	90	90	-	90	90
	D1	DP	-	4,22	8,43	-	0	0	-	0	0
	D2	Média	100	100	100	100	100	100	100	100	100
	D2	DP	0	0	0	0	0	0	0	0	0
RNA	D0	Média	-	100	100	-	100	100	-	100	100
	D0	DP	-	0	0	-	0	0	-	0	0
	D1	Média	-	100	100	-	100	100	-	100	100
	D1	DP	-	0	0	-	0	0	-	0	0
	D2	Média	N/A(3)	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
	D2	DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificação com as redes neurais.

Analizando-se a Tabela 6, novamente é possível observar que o número de neurônios utilizados na camada oculta da rede influencia a resposta do método híbrido. Para todos os números de neurônios testados, o método híbrido obteve excelente desempenho na detecção do estado de dano desconhecido (D2). Mesmo com a presença de ruído nos dados, as taxas de classificações corretas mantiveram-se as mesmas.

Sobre a identificação de comportamentos estruturais conhecidos, o método híbrido também obteve um bom desempenho na maioria dos casos. Porém, os melhores resultados foram obtidos quando o número de neurônios utilizados é igual a 25 e a 50, para os quais o método proposto alcançou taxas de classificações corretas superiores a 90%. Em relação ao ruído, é possível verificar que quando o número de neurônios é igual a 25 e a 35, as porcentagens de classificações corretas da técnica proposta, em alguns casos, diminuem na medida em que o nível de ruído aumenta. Já para o caso em que o número de neurônios é igual a 50, o classificador híbrido se mostrou robusto em relação ao ruído. Sobre os desvios-padrões, os valores foram iguais a zero na maioria dos casos, o que mostra uma certa estabilidade do método proposto quando submetido às mudanças nos *clusters* existentes.

Observando-se os resultados obtidos apenas com as RNAs, é possível verificar o excelente desempenho desta técnica na identificação dos estados estruturais conhecidos (D0 e

D1), para todos os números de neurônios testados. Entretanto, a rede não é capaz de classificar o estado de dano desconhecido (D2) corretamente. É importante ressaltar que para um bom desempenho do método proposto, é necessário que o número adequado de neurônios a serem utilizados na camada oculta da rede seja encontrado.

Analisando-se os resultados obtidos com os dados de entrada organizados por “ensaios” na Tabela 7, é possível observar que para todos os números de neurônios testados, na maioria dos casos, o método híbrido apresentou bom desempenho na identificação dos estados estruturais conhecidos (D0 e D1), principalmente quando o número de neurônios utilizados é igual a 25. Porém, novamente os resultados não foram satisfatórios na detecção do estado estrutural desconhecido (D2). Isso ocorre, pois, a rede classifica grande parte dos dados de D2 com precisão parecida com os elementos do *cluster* que representa D1. Assim, a resposta da rede para esses novos dados fica bem próxima dos elementos do *cluster* de D1. Dessa forma, o método híbrido os classificam como estado de dano 1. Nos dados organizados por “sensores”, a rede classifica D2 como estado de dano 1 com precisão muito inferior aos elementos do *cluster* que representa D1. Tal fato é de se esperar, uma vez que D2 é desconhecido pela rede.

Tabela 7 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em%)

			Número de neurônios								
			15			25			35		
			R0	R1	R2	R0	R1	R2	R0	R1	R2
Método híbrido	D0	Média	-(2)	87	74	-	90	80	-	81	76
		DP(1)	-	14,94	8,43	-	9,43	4,71	-	3,16	5,16
	D1	Média	-	88	91	-	91	96	-	81	90
		DP	-	13,16	5,68	-	9,94	9,66	-	9,94	11,55
RNA	D2	Média	41	44	49	51	41	36	35	34	36
		DP	16	10,75	16,63	12	16,63	13,5	15,81	17,76	17,76
	D0	Média	-	100	92	-	96	96	-	92	92
		DP	-	0	4,22	-	5,16	5,16	-	7,89	7,89
	D1	Média	-	100	100	-	97	100	-	93	94
		DP	-	0	0	-	6,75	0	-	14,94	12,65
	D2	Média	N/A(3)	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
		DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificação com as redes neurais.

Outro fator que pode influenciar na classificação do método híbrido é que as respostas da rede para os dados de treino, validação e teste que são clusterizadas na fase 1 da metodologia, apesar de serem precisas, estão distantes umas das outras para um mesmo tipo de dano. Isso faz com que as distâncias dos elementos dos *clusters* até seus respectivos centroides também sejam distantes umas das outras, o que pode levar a uma distância limite de associação aos *clusters* inadequada. Essa distância selecionada pode gerar uma tendência maior para que um novo ensaio seja classificado pelo método híbrido como um estado de dano conhecido, ou seja, pertencente aos *clusters* já existentes.

Em relação aos desvios-padrões obtidos, eles foram altos na maioria dos casos, o que mostra que as respostas dos classificadores híbridos estão variando bastante. Quando o número de neurônios utilizados é igual a 15 e a 25, as máximas taxas de classificações corretas obtidas para o estado de dano desconhecido (D2) variaram entre 60% e 70%. Para 35 neurônios essas taxas não ultrapassaram 50% nos testes realizados.

Analizando-se apenas os resultados obtidos com as redes neurais na Tabela 7, é possível verificar seu adequado desempenho na identificação de D0 e D1, mesmo havendo presença de ruído nos dados. Os melhores resultados também são obtidos ao se utilizar 15 ou 25 neurônios na camada oculta da rede.

O baixo desempenho do método híbrido na detecção de novos comportamentos estruturais quando os dados de entrada são organizados por “ensaios” pode ser melhorado com o aumento do número de amostras por nível de dano utilizadas para treinar a rede. Sendo o número de parâmetros de entrada da RNA (100) muito maior que o número de amostras (20), o processo de aprendizado da rede pode ter sido prejudicado. Com o aumento do número de amostras, a RNA pode vir a melhorar seu desempenho, distinguindo com mais clareza os diferentes níveis de dano e alcançar respostas mais precisas. Consequentemente, haverá uma melhoria no desempenho do classificador híbrido. O aumento do número de amostras também leva a um aumento do número de elementos dos *clusters* e, por conseguinte, haverá mais distâncias no ajuste da função de distribuição de probabilidade acumulada. Quanto mais dados, melhor fica a distribuição de probabilidades e mais chances se tem de alcançar uma distância limite de associação aos *clusters* mais apropriada, o que também poderia levar a um avanço no desempenho do método proposto.

Um outro ponto importante a ser destacado se refere ao fato de que as distâncias-limite de associação aos *clusters* (dt_1 e dt_2) selecionadas então bem próximas ou correspondem a

97,5% da função de distribuição, conforme mencionado na seção 3.2.3. Entretanto, devido à pouca quantidade de amostras existentes (distâncias) no ajuste da função de distribuição, a distância limite de associação mais próxima selecionada corresponde a 100% de probabilidade. Devido a isso, também foram realizados testes com a probabilidade de um novo ensaio pertencer aos *clusters* existentes iguais a 90% (que representa a “outra” distância mais próxima a 97,5% e que corresponde a 90% da função de distribuição). Os resultados se encontram no Apêndice B. Em síntese, para os dados organizados por “sensores”, os resultados obtidos com o método híbrido com a probabilidade de um novo ensaio pertencer aos *clusters* existentes iguais a 90% não foram melhores que os obtidos com a probabilidade igual a 100%. Em relação aos dados organizados por “ensaios”, ao diminuir a probabilidade para 90%, as taxas de classificações corretas do método híbrido aumentaram em alguns casos na detecção de novos comportamentos – porém ainda continuaram baixas – e na identificação de estados estruturais conhecidos, houve um declínio dessas taxas na maioria dos casos.

Em todas as simulações realizadas, dez valores de distância foram utilizados no ajuste da função de distribuição de probabilidade acumulada. O ideal é que um número maior de valores seja utilizado para que uma melhor distribuição de probabilidade seja realizada e, assim, chegue-se a uma distância limite de associação aos *clusters* mais apropriada.

5.2 ANÁLISES EXPERIMENTAIS

Nesta seção o desempenho do classificador híbrido é avaliado quando este é aplicado a dados obtidos experimentalmente de uma estrutura 3D e de um viaduto ferroviário. O objetivo destas aplicações é verificar se o método proposto é capaz de detectar as diferentes ocorrências de dano as quais as estruturas foram submetidas, utilizando diretamente os dados de aceleração extraídos dos elementos em questão.

5.2.1 Pórtico amarelo

A estrutura 3D testada, denominada “*Yellow Frame*”, mostrada na Figura 8, é um modelo em escala (1/3) de estrutura de aço com quatro andares e dois compartimentos por dois compartimentos, localizada no Laboratório de Pesquisa em Engenharia de Terremotos da Universidade da Colúmbia Britânica (UBC – *University of British Columbia*), no Canadá. A estrutura foi montada em uma laje de concreto fora do laboratório de testes estruturais no campus da UBC para simular condições típicas de vibração ambiente. As nove colunas são

aparafusadas a uma base de aço fixada sobre a laje de concreto. Os dados experimentais descritos e utilizados nesta seção estão disponíveis em Dyke *et al.* (2015).

Figura 8 – Sistema da estrutura testada



Fonte: Dyke *et al.* (2015).

A estrutura possui 2,50 m x 2,50 m em planta baixa e 3,60 m de altura. Os membros foram laminados a quente. As seções foram especificamente projetadas para essa estrutura de teste de modelo em escala. As colunas são seções B100x9 e as vigas do piso são seções S75x11. A Figura 9 mostra a conexão típica da coluna e viga e o sistema de suporte. A Figura 10 apresenta a vista em planta e a vista leste da estrutura.

Figura 9 – Imagem ampliada: (a) suporte e (b) posicionamento da massa



Fonte: Dyke *et al.* (2015).

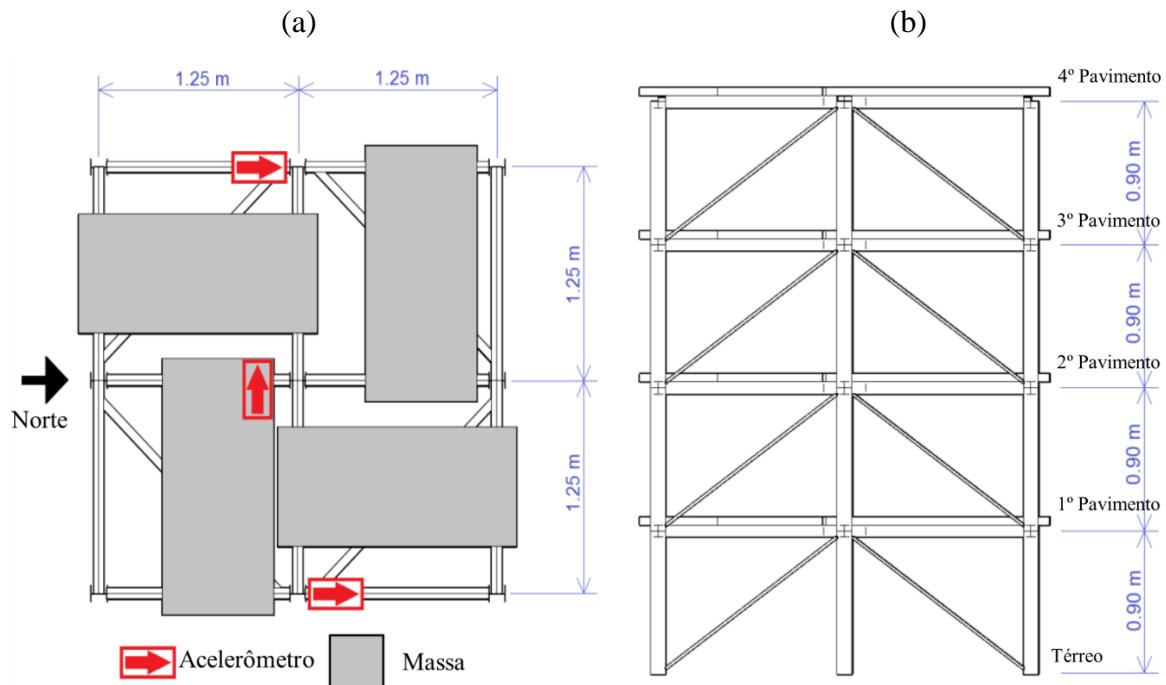
Em cada compartimento, o sistema de suporte consiste em duas hastes de aço com meia polegada de diâmetro posicionadas paralelamente ao longo da diagonal. Para tornar a distribuição de massa razoavelmente realista, uma laje é colocada em cada compartimento por andar: quatro lajes de 1000 kg são colocadas em cada um dos três primeiros pavimentos e no quarto pavimento são colocadas quatro lajes de 750 kg (ver Figura 9 (b) e Figura 10 (a)).

Desde a montagem da estrutura, vários ensaios foram realizados, a saber: testes em vibração ambiente, testes com *shaker* e testes de impacto. Para avaliar a capacidade do método proposto aplicado ao monitoramento contínuo, apenas os testes de vibração ambiente foram utilizados. No entanto, as excitações foram devidas a pedestres, ao vento e ao tráfego nas proximidades da estrutura. Mais detalhes sobre os experimentos podem ser encontrados em Dyke *et al.* (2003) e Dyke *et al.* (2015).

Quinze acelerômetros foram colocados em toda a estrutura, três por andar, incluindo o nível do solo. Esses transdutores foram posicionados de forma que pudessem medir os movimentos em todas as direções e também nos modos de torção (Figura 10 (a)). Utilizou-se o ponto de corte do filtro *anti-aliasing* de 50 Hz e os dados foram amostrados em 200 Hz.

Para criar diferentes cenários, a estrutura foi submetida a diferentes níveis de dano (1 a 5), onde os contraventamentos foram removidos e colocados gradualmente conforme mostrado na Figura 11. Em ordem de aquisição, os níveis 1, 5, 4, 3, e 2 simulam danos graduais no sistema de suporte. Todos esses níveis estão descritos na Tabela 8.

Figura 10 – Estrutura testada: (a) vista em planta e (b) vista leste.



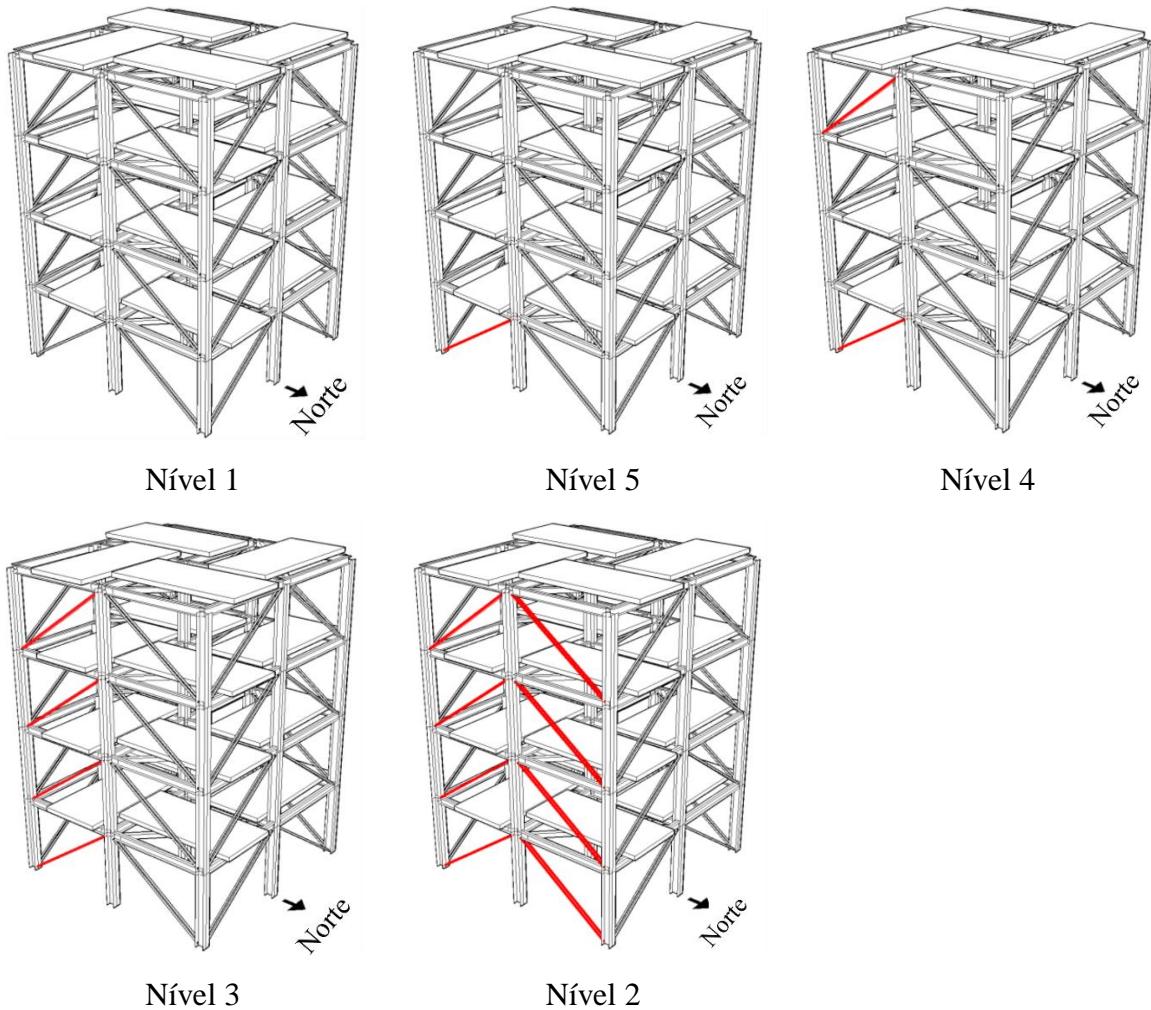
Fonte: Adaptado de Dyke *et al.* (2015).

Tabela 8 – Casos de danos impostos a estrutura

Nível	Configuração
1	Configuração sem danos
2	Todos os contraventamentos do lado leste foram removidos
3	Os contraventamentos foram removidos nos compartimentos do canto sudeste de todos os andares
4	Os contraventamentos foram removidos nos compartimentos do canto sudeste dos 1º e 4º andares
5	O contraventamento foi removido no compartimento do canto sudeste do 1º andar

Fonte: Dyke *et al.* (2015).

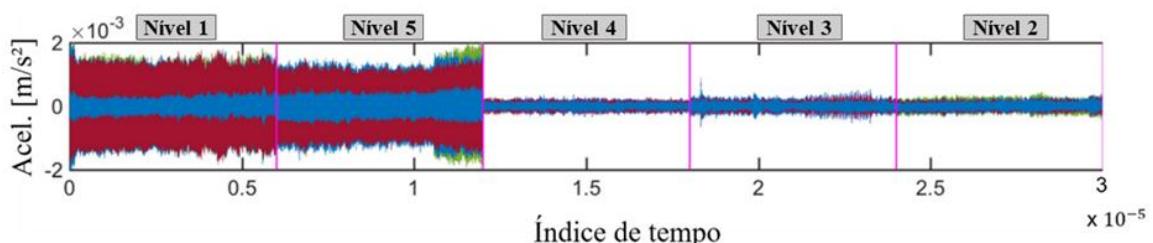
Figura 11 – Níveis de danos impostos a estrutura



Fonte: Adaptado de Dyke *et al.* (2015).

O Gráfico 2 mostra o histórico dos sinais de aceleração dos 15 sensores. As linhas verticais em cor magenta indicam os limites entre os níveis de dano. Vale ressaltar que a grande variação em termos de amplitude de resposta deve-se principalmente aos diferentes níveis de excitação ambiental dos cenários testados (mais ou menos tráfego ou vento).

Gráfico 2 – Histórico dos sinais de aceleração



Fonte: Adaptado de Cardoso *et al.* (2019).

Para cada nível de dano, 60000 pontos foram medidos para cada um dos 15 sensores. Assim, as respostas dinâmicas no domínio do tempo de dimensão [60000x15] foram repartidas em 6 partes de dimensão [10000x15], formando então 6 matrizes para cada nível de dano, como se cada parte fosse um ensaio realizado separadamente. Essa repartição do sinal foi necessária para que os testes com o classificador híbrido pudessem ser realizados, uma vez que um número maior de amostras por nível de dano é gerado. Após esse procedimento, os dez indicadores estatísticos foram extraídos dos sinais repartidos de cada sensor e em seguida foram organizados por “ensaços” e por “sensores”.

- a) Dados organizados por ensaços: os indicadores estatísticos referentes a cada nível de dano foram organizados separadamente em 5 matrizes de entrada de dimensão [6x150], ou seja, cada matriz representa uma configuração estrutural, onde as 6 linhas correspondem ao número de partes que representam os ensaços por nível de dano e as 150 colunas são os indicadores estatísticos extraídos dos sinais dos 15 sensores (10 indicadores x 15 sensores = 150 indicadores);
- b) Dados organizados por sensores: os indicadores estatísticos de cada nível de dano foram organizados separadamente em dez matrizes de entrada de dimensão [15x30]. Neste caso, foram criadas duas matrizes por nível de dano, ou seja, foram considerados três ensaços (partes) por sensor para cada matriz. Isso foi necessário para que se pudesse verificar o desempenho do método híbrido na identificação de comportamentos conhecidos. As 15 linhas da matriz correspondem ao número de sensores utilizados nos ensaços e as 30 colunas são os indicadores estatísticos extraídos do sinal de cada sensor para os 3 ensaços realizados (10 indicadores x 3 ensaços = 30 indicadores por sensor).

O modelo de RNA implementado no método híbrido é do tipo MLP com uma camada oculta. Como se trata de uma aplicação experimental e que, portanto, possui incertezas inerentes ao processo de aquisição de dados, além do teste de sensibilidade do método proposto em relação ao número de neurônios, também foi realizado um teste de sensibilidade em relação a probabilidade de um novo ensaço pertencer aos *clusters* existentes (item “d” – seção 3.2.3). As diferentes probabilidades testadas foram 97,5%, 90% e 85%.

Como já mencionado, o número de neurônios influencia no desempenho da rede e, como consequência, também influencia o desempenho do classificador híbrido. Quando os dados de entrada são organizados por “sensores”, os números de neurônios testados são 10, 15 e 20 e, quando são organizados por “ensaços”, os números testados são 15, 25 e 55. Outras quantidades também foram verificadas como mencionado na seção anterior, porém essas foram as que mais

contribuíram para o bom funcionamento do método proposto. Os resultados obtidos com essas três quantidades são analisados e comparados mais adiante.

O algoritmo de aprendizado utilizado na RNA é o de Levenberg-Marquardt e o erro médio quadrático é empregado como função de custo. As funções de ativação utilizadas nos neurônios da camada oculta e nos da de saída foram, respectivamente, a função sigmoide tangente hiperbólica (Figura 3) e a função *softmax* (Equação 3.5). A métrica de distância e a forma de inicialização dos centroides empregados no algoritmo *k-means* foram, respectivamente, a *cityblock* e a *plus*, como já mencionado na seção 5.1.

Primeiramente foram realizados testes treinando a rede neural no método híbrido com o estado de dano fictício (matriz de “1”) e o nível de dano 1. Os outros níveis de dano são utilizados para teste do classificador híbrido e são apresentados um a um. Para os dados organizados por “ensaios”, a matriz de entrada da RNA possui dimensão [6x150], onde as linhas 1 a 3 da matriz representam o estado de dano fictício e, as restantes, o nível de dano 1. Apenas metade dos ensaios da matriz do nível de dano 1 foram utilizados no treinamento da RNA. As amostras restantes são utilizadas no teste do método híbrido.

Quando os dados são organizados por “sensores”, a matriz de entrada da rede no método híbrido possui dimensão [30x30], onde as linhas 1 a 15 representam o estado de dano fictício e, as restantes, o nível de dano 1. Também foram fornecidas como entrada da rede as matrizes com os rótulos (classes de dano) correspondentes a cada observação contida nas matrizes de entrada. Para os dados organizados por “ensaios”, essa matriz possui dimensão [6x2] e, para os organizados por “sensores”, possui dimensão [30x2]. As linhas das matrizes indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Dano fictício; [0 1] – Nível de dano 1.

Como as redes foram treinadas com o estado de dano fictício e o nível de dano 1, os *clusters* formados pelo *k-means* no método híbrido são relativos a esses dois estados estruturais, ou seja, um *cluster* representa o estado de dano fictício e o outro representa o nível de dano 1. Os níveis de dano 2, 3, 4 e 5 tratam de “novos” comportamentos estruturais desconhecidos.

Na Tabela 9 estão os resultados obtidos com o método híbrido e com a RNA quando os dados de entrada são organizados por “ensaios”. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada *6-fold*, devido a quantidade de amostras utilizadas, gerando, portanto, 6 classificadores híbridos. O desempenho final da rede medido para os dados de teste das 6 classificações do *6-fold* é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 9 é representada pela média de respostas corretas das 6 repetições (nº de acertos dividido pelo número total de ensaios classificados). Para as

diferentes probabilidades de um novo ensaio pertencer aos *clusters* existentes testadas (97,5%, 90% e 85%), os resultados foram os mesmos.

Tabela 9 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %)

			Número de neurônios		
			15	25	55
Método híbrido	D1	Média	66,67	100	33,33
		Desvio-padrão	0	0	0
	D2	Média	83,33	100	100
		Desvio-padrão	0	0	0
	D3	Média	83,33	100	100
		Desvio-padrão	0	0	0
	D4	Média	100	100	100
		Desvio-padrão	0	0	0
	D5	Média	16,67	66,67	33,33
		Desvio-padrão	0	0	0
RNA	D1	Média	100	100	100
		Desvio-padrão	0	0	0
	D2/D3/D4/D5	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificação com as redes neurais.

Com base nos resultados da Tabela 9, é possível observar novamente a influência do número de neurônios no desempenho do método híbrido. Em relação à rede neural, para todos os números de neurônios testados suas taxas de classificações corretas se mantiveram as mesmas, porém as respostas da rede variam de um número de neurônios para o outro. Os melhores resultados com o método híbrido foram obtidos ao se utilizar 25 neurônios na camada oculta da rede. Neste caso, o desempenho do método híbrido foi bastante satisfatório tanto na identificação de comportamentos estruturais conhecidos (D1), quanto na detecção de novos comportamentos estruturais desconhecidos (D2, D3 e D4), à exceção do nível de dano 5, o qual aparenta estar bem próximo ao nível 1. A rede classificou grande parte dos dados relativos a este nível de dano como nível 1, com precisão parecida aos elementos do *cluster* de D1. Consequentemente, o método híbrido também os classifica como pertencentes a esse *cluster*.

Quando o número de neurônios utilizados é igual a 15 e a 55 o desempenho do método híbrido é insatisfatório na identificação do nível de dano conhecido (D1) e satisfatório na

detecção dos novos níveis de dano (D2, D3, D4) à exceção também do nível de D5, para o qual baixas taxas de classificação são alcançadas.

Em relação à rede neural, é possível observar com base nos resultados da Tabela 9, que esta técnica novamente obteve um bom desempenho na classificação do nível de dano para o qual foi treinada para reconhecer, para todos os número de neurônios testados. Porém, para um bom desempenho do método proposto é necessário que o número adequado de neurônios a serem utilizados na camada oculta da rede seja encontrado.

Na Tabela 10 estão os resultados obtidos com o método híbrido e com a RNA, agora com os dados de entrada organizados por “sensores”. Quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 90%, observa-se um melhor desempenho do método híbrido. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-*fold*. O desempenho final da rede medido para os dados de teste das 10 classificações do 10-*fold* é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 10 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 10 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %)

		Número de neurônios			
		10	15	20	
Método híbrido	D1	Média	100	80	66,67
		Desvio-padrão	0	0	0
	D2/1(1)	Média	6,67	53,33	26,67
		Desvio-padrão	0	0	0
	D2/2(2)	Média	6,67	66,67	53,33
		Desvio-padrão	0	0	0
	D3/1	Média	60	53,33	73,33
		Desvio-padrão	0	0	0
RNA	D3/2	Média	6,67	86,67	60
		Desvio-padrão	0	0	0
	D4/1	Média	20	73,33	53,33
		Desvio-padrão	0	0	0
	D4/2	Média	0	40	13,33
		Desvio-padrão	0	0	0
	D5/1	Média	13,33	13,33	46,67
		Desvio-padrão	0	0	0
D5/2	D1	Média	0	6,67	26,67
		Desvio-padrão	0	0	0
	D2/D3/D4/D5	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificação com as redes neurais.

Observando-se os resultados da Tabela 10, é possível novamente observar a influência do número de neurônios utilizado na camada oculta da rede no desempenho do método híbrido. Na identificação do nível de dano conhecido (D1), o desempenho do método híbrido é satisfatório quando o número de neurônios utilizados é igual a 10 e a 15. Porém, com esse número igual a 20, as taxas de classificações corretas alcançadas para o nível de dano 1 são baixas. Na detecção dos novos níveis de dano, o método híbrido não obteve bom desempenho para este caso. Quando o número de neurônios utilizados é igual a 10, as taxas de classificação correta do método híbrido para os novos níveis de dano são baixas. Ao se aumentar esse número para 15 ou 20, os resultados melhoram, porém ainda continuam insatisfatórios para a maioria dos novos níveis de dano.

Em relação à rede neural, para todos os números de neurônios testados, suas taxas de classificação se mantiveram as mesmas.

Os resultados obtidos com probabilidades iguais a 97,5% e a 85% estão disponíveis no Apêndice C. Em síntese, ao se utilizar a probabilidade igual a 97,5%, a distância limite selecionada mais próxima corresponde a 100% de probabilidade na função de distribuição. Neste caso, o desempenho do método híbrido na identificação do comportamento conhecido é bom. Entretanto, na detecção de novos estados estruturais, é insatisfatório, uma vez que a distância limite selecionada gera uma tendência maior dos novos dados pertencerem aos *clusters* existentes. Ao reduzir a probabilidade para 90%, o desempenho do classificador híbrido ainda continua satisfatório na identificação do estado de dano conhecido (D1) e apresenta uma melhora na detecção de novos comportamentos estruturais, apesar de ainda não ser suficiente em alguns casos. Com a probabilidade igual a 85%, o desempenho do método híbrido na detecção do comportamento conhecido começa a cair, mas, em relação a novos comportamentos estruturais, não sofre mudanças significativas.

Para o caso dos dados organizados por “sensores”, pode-se observar que os resultados obtidos com o método híbrido não foram satisfatórios como aqueles obtidos quando organizados por “ensaios”. Alguns fatores podem explicar tal fato: primeiramente, a rede classifica grande parte dos novos estados estruturais apresentados como nível de dano 1 com precisão parecida com os elementos do *cluster* que representa D1. Dessa forma, as respostas da rede para esses novos dados ficam bem próximas desse *cluster*. Assim, o método híbrido classifica grande parte desses dados como pertencentes ao *cluster* referente a D1. Já quando os dados são organizados por “ensaios”, a rede classifica os estados de dano que são desconhecidos por ela como caso de dano 1, porém com precisão inferior. Sendo assim, as saídas (respostas da rede) referentes aos novos estados de danos ficam mais distantes do *cluster* de D1. Portanto, o método híbrido consegue classificar corretamente grande parte dos dados como um novo comportamento estrutural.

Outro fator que pode ter influenciado no desempenho do método híbrido quando os dados são organizados por “sensores” é que as respostas da rede para um mesmo nível de dano mudam bastante. Como consequência, as distâncias dos elementos dos *clusters* até seus respectivos centroides também variam muito, ou seja, estão bem distantes umas das outras, o que pode levar a uma distância limite inadequada, gerando uma tendência dos novos ensaios serem classificados pelo método híbrido como estados de dano conhecidos.

Como já mencionado, após um novo estado estrutural ser identificado, o estado de dano fictício é descartado e passa-se a trabalhar apenas com estados de dano reais. Agora, as redes

neurais no método híbrido passam a ser treinadas com o nível de dano 1 e o nível de dano 2. Dessa forma, a matriz de entrada da rede possui dimensão [12x150] quando os dados são organizados por “ensaios” e dimensão [30x30] quando organizados por “sensores”. Foi gerada, também, uma matriz alvo de dimensão [12x2] para os dados organizados por “ensaios” e [30x2] para os dados organizados por “sensores”, onde as linhas da matriz indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Dano 1; [0 1] Dano 2.

Como as redes foram treinadas com o nível de dano 1 e o nível de dano 2, os *clusters* formados pelo *k-means* no método híbrido são relativos a esses dois estados estruturais. Sendo assim, os níveis de dano 3, 4 e 5 tratam-se de “novos” comportamentos desconhecidos.

Na Tabela 11 estão os resultados obtidos com o método híbrido e com a RNA, para os dados de entrada organizados por “ensaios”. Quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 90%, observa-se um melhor desempenho do método híbrido. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 6-fold. O desempenho final da rede medido para os dados de teste das 6 classificações do 6-fold é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 11 é representada pela média de respostas corretas das 6 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Devido a pequena quantidade de dados, todas as amostras referentes aos casos de dano 1 e 2 foram utilizadas como entrada da rede para seu treinamento. Além disso, nota-se que quanto mais amostras forem utilizadas no treinamento, melhor é a aprendizagem desta técnica. Dessa forma, para medir o desempenho do método híbrido na identificação de comportamentos conhecidos, apenas para os dados organizados por “ensaios”, a resposta da rede para os dados de treino e validação foi clusterizada pelo *k-means*. Os dados de teste (DT) foram utilizados para medir o desempenho do método proposto na identificação de estados de dano conhecidos (D1 e D2). Na classificação dos novos estados de dano (D3, D4 e D5), a saída da rede para os dados de treino, validação e teste foi clusterizada normalmente.

Tabela 11 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %)

		Número de neurônios		
		15	25	55
Método híbrido	DT	Média	66,67	83,33
		Desvio-padrão	40,8248	40,8248
	D3	Média	100	100
		Desvio-padrão	0	0
	D4	Média	100	100
		Desvio-padrão	0	0
RNA	D5	Média	66,67	83,33
		Desvio-padrão	0	0
D3/D4/D5	DT	Média	100	100
		Desvio-padrão	0	0
		Média	N/A(1)	N/A
		Desvio-padrão	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificação com as redes neurais.

Com base nos resultados mostrados na Tabela 11, é possível verificar que os melhores resultados com o método híbrido são obtidos ao se utilizar 25 neurônios na camada oculta da rede neural. Neste caso, o desempenho do método proposto foi satisfatório tanto na identificação de comportamentos conhecidos (DT), quanto na detecção de estados estruturais desconhecidos (D3, D4 e D5). Quando o número de neurônios utilizados é igual a 15 e a 55 o desempenho do método híbrido não é satisfatório na identificação dos níveis de dano conhecidos (DT), e em relação a detecção de novos níveis de dano os resultados foram satisfatórios na maioria dos casos, exceto na classificação de D5 para 15 neurônios e D4 para 55 neurônios, onde baixas taxas foram alcançadas.

Os resultados obtidos com a probabilidade igual a 97,5% e a 85% estão disponíveis no Apêndice D. Em resumo, ao se utilizar a probabilidade igual a 97,5% a distância limite selecionada mais próxima corresponde a 100% de probabilidade na função de distribuição. Neste caso, o desempenho do método híbrido é satisfatório na identificação de comportamentos conhecidos e também na detecção de novos comportamentos, exceto na detecção de D5. Ao reduzir a probabilidade para 90%, as taxas de classificações corretas permanecem as mesmas para os estados de dano conhecidos e aumentam em relação aos novos níveis de dano. Isso mostra que as distâncias limites de associação aos *clusters* correspondentes a 90% da função de distribuição foram as mais adequadas para o bom funcionamento do método híbrido neste caso. Com a probabilidade igual a 85%, o desempenho do método híbrido na detecção de

comportamentos conhecidos começa a cair e em relação a novos comportamentos estruturais as taxas de classificações corretas se mantêm as mesmas, o que torna as distâncias limites correspondentes a essa probabilidade inadequadas.

Na Tabela 12 estão os resultados obtidos com o método híbrido e com a RNA, agora com os dados de entrada organizados por “sensores”, quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 97,5%. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede medido para os dados de teste das 10 classificações do 10-fold é igual a 90% para 10 e 20 neurônios e 93,33% para 15. A taxa de classificação da Tabela 12 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 12 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %)

			Número de neurônios		
			10	15	20
Método híbrido	D1	Média	68,67	46,67	64
		DP(3)	4,49	12,95	8,43
	D2	Média	62,67	60	60
		DP	8,43	15,96	12,88
	D3/1(1)	Média	12	28,67	15,33
		DP	4,21	19,13	14,76
	D3/2(2)	Média	7,33	30	16,67
		DP	7,98	11,00	11,86
	D4/1	Média	5,34	41,33	18,67
		DP	8,20	8,78	13,98
RNA	D4/2	Média	10,66	40	21,33
		DP	8,43	7,98	7,57
	D5/1	Média	6,67	20,67	10,67
		DP	3,14	13,50	12,65
	D5/2	Média	10	29,33	12
		DP	10,54	8,43	12,88
	D1	Média	76	69,33	72,67
		DP	10,04	4,66	7,98
	D2	Média	73,33	68,67	65,99
		DP	7,70	3,22	7,98
	D3/D4/D5	Média	N/A(4)	N/A	N/A
		DP	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

- (3) Desvio-padrão.
- (4) Não se aplica a classificação com as redes neurais.

Analizando-se os resultados da Tabela 12, é possível verificar que, para os dados organizados por “sensores”, o método híbrido não obteve bom desempenho. Os resultados obtidos apenas com as redes neurais também não foram satisfatórios neste caso. Os desvios-padrões mostram que as respostas dos classificadores híbridos estão variando muito. Na classificação de D1 por exemplo, a máxima taxa de classificações corretas obtida foi de 80% para 10 e 20 neurônios. Já para D2, a máxima taxa obtida foi de 73,33% para todos os números de neurônios testados. Em relação aos estados de dano desconhecidos, as taxas de classificações corretas do método híbrido são baixas. Observando-se os resultados obtidos apenas com as redes neurais, nota-se também uma variação nas respostas das redes através dos desvios-padrões. Na classificação de D1, a máxima taxa de classificações corretas obtida pela rede foi de 86,67% para 10 e 20 neurônios. Para D2, a máxima taxa obtida foi de 80% para 10 neurônios.

Em relação às probabilidades, ao reduzi-las para 90% e 85%, as taxas de classificações corretas do método híbrido para estados de dano conhecidos decaem e, para novos estados de dano, não sofrem alterações relevantes (estes resultados são apresentados no Apêndice E).

Observa-se, portanto, que uma melhoria no desempenho da rede pode levar a melhores resultados com o método híbrido, e alguns fatores podem colaborar para isto, como por exemplo: (i) o número de parâmetros de entrada da rede utilizados quando os dados são organizados por “sensores” foi igual a 30, ou seja, 30 indicadores foram utilizados para caracterizar os sinais dinâmicos de cada nível de dano. Talvez se um número maior de parâmetros fosse utilizado para melhor caracterização desses sinais, o desempenho da rede pudesse vir a melhorar; (ii) um aumento do número de amostras de treinamento para melhor aprendizado da rede também pode levar a uma melhoria de desempenho; (iii) o aumento do número de amostras, como já mencionado, também gera um aumento do número de elementos dos *clusters* e, consequentemente, aumentará o número de distâncias no ajuste da função de distribuição de probabilidade acumulada. Quanto mais dados, melhor a distribuição de probabilidade e, portanto, mais chances de se alcançar uma distância limite de associação aos *clusters* mais apropriada (o que também poderia causar uma melhora no desempenho do método proposto).

5.2.2 Viaduto ferroviário PK 075+317

O viaduto ferroviário PK 075+317 se localiza no sudeste da França, próximo às cidades de Sens e Soucy no condado de Yonne (Figura 12). Diariamente, diversos trens de alta velocidade (TGVs) passam por esse viaduto que interliga Paris à Lyon. A estrutura é formada por duas vigas mistas e possui 17,5m de comprimento.

Figura 12 – Vista geral do viaduto



Fonte: Cury (2010).

Um monitoramento dinâmico foi realizado neste viaduto com o intuito de caracterizar e quantificar o efeito de um procedimento de reforço estrutural nele realizado. Tal procedimento consistiu no “aperto” dos mancais de sustentação, mostrados na Figura 13 e tinha como propósito distanciar a primeira frequência natural de vibração da estrutura (em torno de 4,5 Hz) da frequência de excitação causada pela passagem dos trens (em torno de 4Hz). A instrumentação e as medições foram realizadas somente no trilho 1, onde passam os trens que viajam no sentido Paris à Lyon.

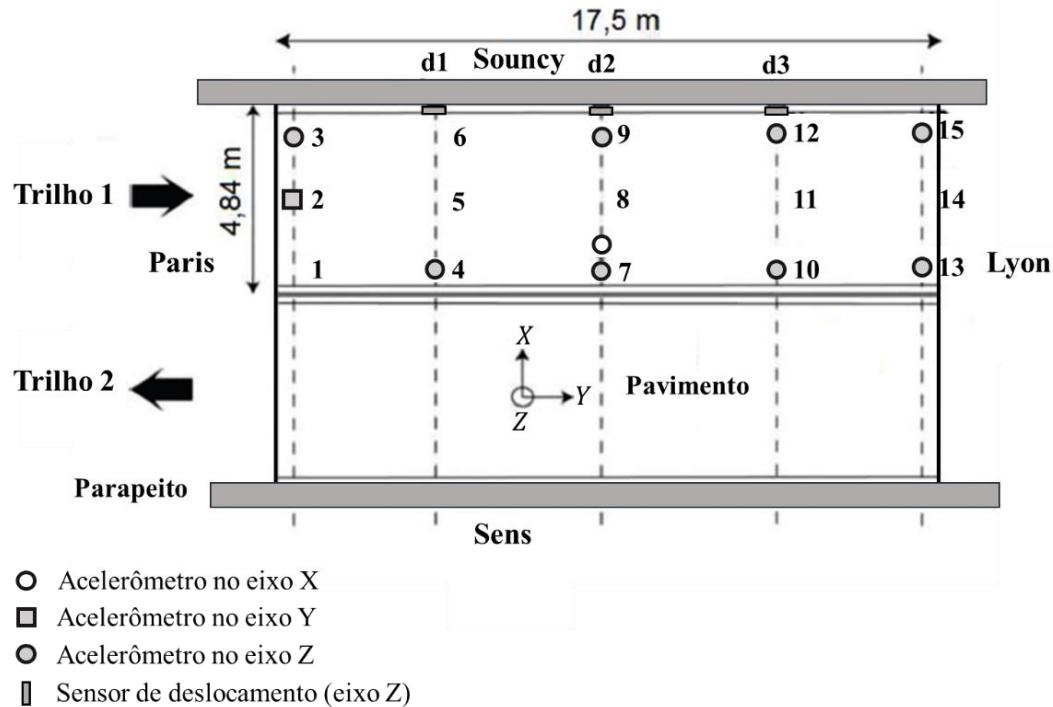
Figura 13 – Detalhes do procedimento de reforço e dos mancais



Fonte: Cury (2010).

A instrumentação do viaduto compreende três sensores de deslocamento vertical, localizados entre o parapeito e o trilho 1; oito acelerômetros verticais e dois horizontais (longitudinais e transversais), todos instalados sob o tabuleiro; dois sensores de passagem de trem cada um com o objetivo de medir os carregamentos no eixo na entrada e saída e dois sensores de temperatura. Entretanto, apenas os sinais de aceleração serão utilizados neste trabalho. O Esquema 7 apresenta a instrumentação dos sensores sob o pavimento. A frequência de amostragem dos sinais é de 4096Hz. Três campanhas de medição foram efetuadas, sendo a primeira no dia 24 de junho de 2003, antes do procedimento de reforço, na qual 15 ensaios dinâmicos foram realizados. A segunda, no dia 25 de junho, durante a realização do procedimento de reforço, 13 ensaios foram registrados. Por fim, a terceira campanha de medições, que ocorreu no dia 26 de junho de 2003, após a realização do reforço, 13 ensaios foram realizados. O procedimento de reforço foi realizado em quatro etapas. Na primeira, quatro mancais foram apertados e na segunda mais três. Nessas duas etapas, os mancais apertados estão localizados no lado de Lyon. Durante a terceira etapa, quatro mancais foram apertados e, na quarta etapa, outros três mancais. Nestas duas últimas etapas, os mancais estão localizados no lado de Paris.

Esquema 7 – Posição dos sensores sob o pavimento



Fonte: Adaptado de Cury (2010).

No total, 410 sinais foram registrados (41 ensaios x 10 acelerômetros por ensaio). De cada sinal, foram calculados os 10 indicadores estatísticos que, em seguida, foram organizados por “ensaios” e por “sensores” para serem aplicados a metodologia proposta.

- Dados organizados por “ensaios”: os indicadores estatísticos referentes a cada condição estrutural foram organizados separadamente em três matrizes de entrada. Para o estado estrutural antes do reforço, a matriz possui dimensão [15x100]. Para os estados durante e após o reforço a dimensão é [13x100]. As linhas da matriz correspondem ao número de ensaios realizados por estado estrutural e as 100 colunas são os indicadores estatísticos extraídos dos sensores;
- Dados organizados por “sensores”: Os indicadores estatísticos de cada nível de dano foram organizados separadamente em 6 matrizes de entrada de dimensão [10x60]. Neste caso, foram criadas duas matrizes por estado estrutural, ou seja, foram considerados 6 ensaios por sensor para cada matriz. Isso foi necessário para que se pudesse verificar o desempenho do método híbrido na identificação de comportamentos conhecidos. As 10 linhas da matriz correspondem ao número de sensores utilizados nos ensaios e as 60 colunas são os indicadores estatísticos extraídos do sinal de cada sensor dos 6 ensaios realizados.

O modelo de RNA implementado no método híbrido é do tipo MLP com uma camada oculta. Foram realizados testes de sensibilidade do método proposto em relação ao número de neurônios e em relação a probabilidade de um novo ensaio pertencer aos *clusters* existentes (item “d” – seção 3.2.3). As diferentes probabilidades testadas foram 97,5%, 90% e 85%. Os números de neurônios testados quando os dados de entrada são organizados por “ensaços” são 15, 25 e 50 e, quando organizados por “sensores”, são 20, 25 e 30. Outras quantidades também foram verificadas, porém essas foram as que mais contribuíram para o bom funcionamento do método proposto. Os resultados obtidos com essas três quantidades são analisados e comparados mais adiante.

O algoritmo de aprendizado utilizado na RNA é o de Levenberg-Marquardt e o erro médio quadrático é empregado como função de custo. A função de ativação utilizada nos neurônios da camada oculta é a sigmoide tangente hiperbólica (Figura 3) e nos da de saída, a função *softmax* (Equação 3.5). A métrica de distância e a forma de inicialização dos centroides empregados no algoritmo *k-means* foram, respectivamente, a *cityblock* e a *plus*, como já mencionado na seção 5.1.

Primeiramente, foram realizados testes treinando a rede neural no método híbrido com o estado de dano fictício (matriz de “1”) e o estado estrutural antes do reforço. Os outros estados estruturais são utilizados para teste do classificador híbrido e são apresentados um a um. Para os dados organizados por “ensaços”, a matriz de entrada da RNA possui dimensão [20x100], na qual as linhas 1 a 10 da matriz representam o estado de dano fictício e, as restantes, o estado estrutural antes do reforço. Apenas 10 amostras deste estado são utilizadas para treinamento da rede, sendo as restantes utilizadas para teste do método proposto.

Quando os dados são organizados por “sensores”, a matriz de entrada da rede no método híbrido fica com dimensão [20x60], as linhas 1 a 10 representam o estado de dano fictício e as restantes o estado antes do reforço. Também foram fornecidas como entrada da rede as matrizes com os rótulos (classes de dano) dimensão [20x2], correspondentes a cada observação contida nas matrizes de entrada, onde as linhas da matriz indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Dano fictício; [0 1] – Estado antes do reforço.

Como as redes foram treinadas com o estado de dano fictício e o estado antes do reforço, os *clusters* formados pelo *k-means* no método híbrido são relativos a esses dois estados estruturais, ou seja, um *cluster* representa o estado de dano fictício e o outro representa o estado antes do reforço. O estado estrutural durante e o estado após o reforço tratam de “novos” comportamentos estruturais desconhecidos.

Na Tabela 13 estão os resultados obtidos com o método híbrido e com a RNA quando os dados de entrada são organizados por “ensaios”, quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 90%, onde observa-se melhor desempenho do método proposto. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede medido para os dados de teste das 10 classificações do 10-fold é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 13 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 13 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	100	80	40
		DP(1)	0	0	0
	Durante o reforço	Média	7,69	38,46	23,08
		DP	0	0	0
	Depois do reforço	Média	15,38	84,62	69,23
		DP	0	0	0
RNA	Antes do reforço	Média	100	100	100
		DP	0	0	0
	Durante o reforço/Depois do reforço	Média	N/A(2)	N/A	N/A
		DP	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão.

(2) Não se aplica a classificação com as redes neurais.

Analizando-se os resultados da Tabela 13, é possível verificar que apesar do número de neurônios utilizado na camada oculta da rede não influenciar em sua classificação, influencia bastante no desempenho do método híbrido. Os melhores resultados com o classificador híbrido são obtidos ao se utilizar 25 neurônios na camada oculta da rede neural. Neste caso, o desempenho do método proposto foi satisfatório tanto na identificação do comportamento conhecido (antes do reforço), quanto na detecção dos estados estruturais desconhecidos. Exceto na classificação do estado durante o reforço, onde o método proposto obteve baixas taxas de classificações corretas. O fato de os dados vibracionais dos ensaios referentes ao estado estrutural “durante o reforço” se alterarem ao longo da realização dessa campanha de ensaios, uma vez que os mancais iam sendo apertados gradativamente, pode explicar essas baixas taxas.

Quando o número de neurônios utilizados é igual a 15 o método híbrido obtém um bom desempenho na identificação do estado estrutural conhecido, porém seu desempenho não é satisfatório na detecção dos novos estados estruturais. Quando o número de neurônios é igual a 50 os resultados obtidos com o método proposto não são bons.

Os resultados obtidos com a probabilidade igual a 97,5% e a 85% estão disponíveis no Apêndice F. Em resumo, os resultados obtidos com o método híbrido ao se utilizar a probabilidade igual a 97,5%, foram bons na detecção do comportamento estrutural conhecido, mas foram insatisfatórios na detecção dos novos estados estruturais, uma vez que a distância limite selecionada mais próxima corresponde a 100% de probabilidade na função de distribuição, o que gerou uma tendência dos novos ensaios pertencerem aos *clusters* existentes.

Ao reduzir esta probabilidade para 90%, o desempenho do método híbrido ainda continua satisfatório na identificação do comportamento conhecido e apresenta uma grande melhora na detecção de novos comportamentos, principalmente ao se utilizar 25 neurônios na camada oculta da rede. Os resultados obtidos com a probabilidade igual a 85% foram iguais ao da probabilidade igual a 90%.

Na Tabela 14 estão os resultados obtidos com o método híbrido e com a RNA, agora com os dados de entrada organizados por “sensores”, quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 97,5%. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede, medido para os dados de teste, das 10 classificações do 10-fold é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 14 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 14 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %)

			Número de neurônios		
			20	25	30
Método híbrido	Antes do reforço	Média	90	70	100
		DP(3)	0	0	0
	Durante o reforço/1(1)	Média	10	10	0
		DP	0	0	0
	Durante o reforço/2(2)	Média	10	10	10
		DP	0	0	0
	Depois do reforço/1	Média	0	20	0
		DP	0	0	0
RNA	Depois do reforço/2	Média	10	0	10
		DP	0	0	0
	Antes do reforço	Média	100	100	100
		DP	0	0	0
	Durante o reforço/ Depois do reforço	Média	N/A(4)	N/A	N/A
		DP	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

- (1) Matriz 1.
- (2) Matriz 2.
- (3) Desvio-padrão.
- (4) Não se aplica a classificação com as redes neurais.

A partir dos resultados da Tabela 14 é possível verificar que quando os dados de entrada da RNA são organizados por “sensores”, o desempenho do método híbrido é satisfatório na identificação de comportamentos conhecidos ao se utilizar 20 ou 30 neurônios na camada oculta da rede e é razoável para 25 neurônios. Já na detecção dos novos estados estruturais o desempenho do método híbrido é insatisfatório para todos os número de neurônios testados. Grande parte dos dados relativos a esses novos estados, a rede classifica como estado antes do reforço com precisão semelhante aos elementos (respostas da rede) referentes ao *cluster* que representa o estado antes do reforço, devido a isso, grande parte desses dados são classificados pelo método híbrido como pertencentes a esse *cluster*.

Ao reduzir a probabilidade de um novo ensaio pertencer aos *clusters* existentes para 90% e 85%, ocorre um decaimento das taxas de classificações corretas do método híbrido para o estado estrutural conhecido e um aumento dessas taxas para os novos estados estruturais, porém para este último caso as taxas ainda continuam baixas, ou seja, as distâncias limites de associação aos *clusters* não foram adequadas (estes resultados são mostrados no Apêndice G).

Em relação à rede neural, pode-se observar, com base nos resultados da Tabela 14, seu excelente desempenho na detecção do estado antes do reforço, para o qual foi treinada para reconhecer. Porém, apesar das excelentes taxas de classificações alcançadas pela RNA uma melhoria em seu desempenho de forma que esta venha a classificar os novos ensaios dos mesmos estados estruturais utilizados para seu treinamento com alta precisão e baixo erro de predição e os ensaios referentes a novos estados estruturais, com uma precisão inferior a esses, pode ocasionar em uma melhoria no desempenho do método proposto.

Em seguida, as redes neurais no método híbrido passam a ser treinadas com os estados estruturais antes e durante o reforço. A matriz de entrada da rede fica com dimensão [20x100] quando os dados são organizados por “ensaios” e dimensão [20x60] quando são organizados por “sensores”. Também foi gerada uma matriz alvo de dimensão [20x2] onde as linhas da matriz indicam a classe do sinal a partir da seguinte codificação binária: [1 0] – Estado antes do reforço; [0 1] Estado durante o reforço.

Como as redes foram treinadas com os estados estruturais antes e durante o reforço, os *clusters* formados pelo *k-means* no método híbrido são relativos a essas duas condições estruturais. Sendo assim, o estado após o reforço se trata de um comportamento desconhecido.

Na Tabela 15 estão os resultados obtidos com o método híbrido e com a RNA, para os dados de entrada organizados por “ensaios”, quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 97,5%. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede medido para os dados de teste das 10 classificações do 10-fold é igual a 100% para todos os números de neurônios testados. A taxa de classificação da Tabela 15 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 15 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em %)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	80	100	84
		DP(1)	0	0	8,43
	Durante o reforço	Média	40	70	63,34
		DP	14,05	10,54	10,54
	Depois do reforço	Média	43,07	22,31	32,31
		DP	6,5	2,43	3,24
RNA	Antes do reforço	Média	100	100	100
		DP	0	0	0
	Durante o reforço	Média	100	100	100
		DP	0	0	0
	Depois do reforço	Média	N/A(2)	N/A	N/A
		DP	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão.

(2) Não se aplica a classificação com as redes neurais.

Analizando os resultados da Tabela 15, é possível verificar que o desempenho do método híbrido foi satisfatório na identificação do estado estrutural “antes do reforço”, onde alcançou taxas de classificações superiores a 80% para todos os números de neurônios testados. Na identificação do estado “durante o reforço”, os resultados foram razoáveis ao se utilizar 25 neurônios na camada oculta da rede, onde foi possível atingir uma taxa de classificação correta igual a 70%. Porém, na detecção do novo estado estrutural “depois do reforço” o método híbrido não alcançou taxas de classificação satisfatórias.

Os resultados obtidos nos dois últimos casos podem ser explicados pelo fato de se ter treinado a rede com o estado “durante o reforço”. Como já mencionado, os dados vibracionais dos ensaios referentes ao estado estrutural “durante o reforço”, se alteram ao longo da realização dessa campanha de ensaios, uma vez que os mancais vão sendo apertados gradativamente. Isso faz com que a rede classifique alguns dos novos ensaios relativos ao estado “durante o reforço” com baixa precisão e grande parte dos dados relativos a condição “após o reforço” com alta precisão de pertencerem ao estado “durante o reforço”. Sendo assim, o método híbrido classifica esses dados relativos ao estado “durante o reforço” como um novo comportamento estrutural e grande parte dos dados referentes ao estado “após o reforço” como pertencentes ao *cluster* que representa o estado “durante o reforço”.

Ao reduzir a probabilidade de um novo ensaio pertencer aos *clusters* existente para 90% e 85%, as taxas de classificações corretas do método híbrido para os estados estruturais

conhecidos decaem, principalmente para o estado “durante o reforço”. Já as taxas para o estado “após o reforço” aumentam, porém não ultrapassam 63% (resultados no Apêndice H).

Na Tabela 16 estão os resultados obtidos com o método híbrido e com a RNA, agora com os dados de entrada organizados por “sensores”, quando a probabilidade de um novo ensaio pertencer aos *clusters* existentes é igual a 97,5%. As redes neurais foram executadas e treinadas aplicando-se o método de validação cruzada 10-fold. O desempenho final da rede medido para os dados de teste das 10 classificações do 10-fold é igual a 90% para 20 e 30 neurônios e igual a 95% para 25 neurônios. A taxa de classificação da Tabela 16 é representada pela média de respostas corretas das 10 repetições (nº de acertos dividido pelo número total de ensaios classificados).

Tabela 16 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em %)

			Número de neurônios		
			20	25	30
Método híbrido	Antes do reforço	Média	18	14	57
		DP(3)	11,35	14,29	19,4651
	Durante o reforço	Média	60	90	60
		DP	37,41	6,67	33,9935
	Depois do reforço 1(1)	Média	21	8	24
		DP	18,53	7,89	28,7518
RNA	Depois do reforço 2(2)	Média	19	8	17
		DP	22,34	7,89	12,5167
	Antes do reforço	Média	67	46	66
		DP	22,63	12,65	13,499
	Durante o reforço	Média	91	98	85
		DP	5,68	4,21	8,49837
	Depois do reforço	Média	N/A(4)	N/A	N/A
		DP	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Desvio-padrão.

(4) Não se aplica a classificação com as redes neurais.

Os resultados obtidos com os dados organizados por “sensores” não foram bons como quando os dados são organizados por “ensaios”. Porém, é possível observar a partir dos desvios-padrões que as respostas dos classificadores híbridos estão variando bastante. Os melhores resultados com o método híbrido foram obtidos ao se utilizar 30 neurônios na camada oculta da rede, onde foi possível atingir taxas máximas de classificação igual a 80% para o estado antes

do reforço, 90% para o estado durante e uma taxa razoável de classificações corretas igual a 70% para o estado após o reforço.

Ao reduzir a probabilidade de um novo ensaio pertencer aos *clusters* existentes para 90% e 85% (vide Apêndice I), as taxas médias de classificações corretas do método híbrido para os estados estruturais conhecidos decaem bastante e para a nova condição estrutural aumentam, porém ainda continuam baixas.

Em relação às redes neurais, também é possível observar que suas classificações estão variando bastante. Para o estado antes do reforço a taxa máxima de classificações corretas alcançada foi igual a 90% e para o estado durante foi igual a 100% em alguns casos.

Assim como nas aplicações com o pórtico (seção 5.2.1), observou-se que uma melhoria no desempenho da rede pode levar à uma melhora nos resultados do método híbrido. Como já mencionado, utilizar uma maior quantidade de parâmetros de entrada na rede para melhor caracterização do sinal e um número maior de amostras de treinamento podem colaborar para melhor aprendizagem e desempenho das RNAs. Como consequência, espera-se um melhor desempenho do método proposto.

6 CONCLUSÕES

Neste trabalho, uma nova abordagem para detectar danos e modificações estruturais baseada na análise direta de medições de aceleração e no uso de métodos de aprendizado de máquinas foi apresentada. Indicadores estatísticos extraídos dos sinais dinâmicos “brutos” foram utilizados como dados de entrada para o classificador híbrido (RNA + *k-means*). Os dados de entrada foram organizados de duas formas: por “ensaios” e por “sensores”, para posterior comparação. A abordagem proposta foi avaliada a partir de aplicações em um modelo numérico de viga, em uma estrutura de médio porte testada em laboratório e em um viaduto ferroviário (PK 075+317, na França). Testes de sensibilidade do método proposto em relação ao número de neurônios utilizados na camada oculta da rede neural e em relação a probabilidade de um novo ensaio pertencer aos *clusters* existentes foram realizados.

Nas aplicações com a viga numérica, os melhores resultados foram obtidos quando os dados de entrada da rede neural no método proposto são organizados por “sensores”. Neste caso, o classificador híbrido obteve excelente desempenho tanto na identificação de comportamentos conhecidos, quanto na detecção de novos casos de dano. Taxas de classificações corretas superiores a 80% foram obtidas e, em alguns casos, chegaram a 100%. Observou-se também que o ruído influenciou negativamente na classificação do método híbrido para alguns números de neurônios testados e para outros números o método híbrido se mostrou robusto na presença deste.

Quando o método híbrido é empregado na detecção de alterações nas respostas vibracionais do pórtico testado em laboratório, os melhores resultados são obtidos quando os dados de entrada são organizados por “ensaios”. Neste caso, o método proposto obteve excelente desempenho na identificação de comportamentos conhecidos e também na detecção de novos estados estruturais, alcançando taxas de classificações corretas superiores a 80% e, em alguns casos, essas taxas também chegam a 100%.

Nas aplicações com o viaduto ferroviário (PK 075+317, na França), os melhores resultados alcançados com o método híbrido foram quando os dados de entrada são organizados por “ensaios”. Ao se treinar a rede no método proposto com o estado de dano fictício e o estado antes do reforço, taxas de classificações corretas superiores a 80% foram alcançadas com o método híbrido para os novos dados apresentados. Tais taxas ocorreram exceto para o estado “durante o reforço”. Ao se treinar a rede com o estado “antes” e “durante” o reforço, os resultados com o método híbrido na classificação de novos ensaios relativos ao estado “durante” e “após” o reforço também foram comprometidos. O fato de os dados vibracionais dos ensaios

referentes ao estado estrutural “durante o reforço” se alterarem ao longo da realização dessa campanha de ensaios, uma vez que os mancais iam sendo apertados gradativamente, explica essas taxas de classificações insatisfatórias. O estado “durante o reforço” não apresenta apenas uma configuração estrutural, mas sim quatro, pois o procedimento de reforço foi realizado em quatro etapas. Dessa forma, nas aplicações com o método híbrido, o ideal é que os dados vibracionais de cada etapa fossem considerados separadamente.

É importante ressaltar que nas análises experimentais realizadas com o pórtico e o viaduto ferroviário, as variações de temperatura que ocorreram durante a realização das campanhas de ensaios não foram consideradas nessa pesquisa. Não se sabe, portanto, se tais variações foram significativas ou não. Para avaliar a robustez do método híbrido em relação às variações de temperatura ainda são necessários novos testes. É de grande importância que tal efeito seja considerado, uma vez que ele pode influenciar negativamente os métodos de detecção de danos.

Em todas as aplicações realizadas, a rede neural isoladamente alcançou excelente desempenho na classificação dos estados estruturais para os quais ela foi treinada para reconhecer, para as duas formas de entrada na maioria dos casos. Porém, como amplamente conhecido, as redes não são capazes de rotular um novo comportamento estrutural quando este surge.

Nas aplicações mencionadas anteriormente, para os casos em que o método proposto não alcançou bom desempenho, algumas medidas podem ser tomadas para que sejam alcançados bons resultados. Porém, em casos onde as variações nos parâmetros estatísticos de um nível de dano para o outro são muito pequenas, ou seja, quando o novo nível de dano apresentado é extremamente próximo aos níveis de dano conhecidos, pode ser que o método proposto não consiga identificá-lo, entretanto isto não o torna ineficiente.

Como mencionado no decorrer do Capítulo 5, para que haja um incremento no desempenho do método proposto, primeiro é necessário uma melhoria no desempenho da rede, principalmente em sua resposta. Alguns fatores podem colaborar para isso, como: i) utilizar um número maior de amostras por estado estrutural para treinamento da rede sempre que possível; ii) utilizar um número maior de parâmetros de entrada da RNA para melhor caracterização dos sinais; iii) na seleção desses parâmetros, analisar os que mais sofrem modificações e utilizá-los como entrada da rede para seu treinamento. Como mencionado na seção 3.1, o aprendizado das técnicas de inteligência computacional, como as redes neurais no caso deste trabalho, se dá através da transformação dos dados de entrada. Dessa forma, a utilização de dados capazes de

fornecer informações representativas e suficientes dos sinais dinâmicos é necessária. Caso contrário, o aprendizado da rede fica comprometido.

Em relação ao número de neurônios utilizados na camada oculta da RNA, em todas as aplicações realizadas foi possível observar sua influência no desempenho do método proposto. Com base nos resultados, é possível observar que o aumento desse número nem sempre gera uma melhora no desempenho do método híbrido. É necessário que a quantidade adequada de neurônios seja encontrada para que o método híbrido alcance um bom desempenho nas classificações. Esse número adequado vai depender do tamanho da entrada da rede, da quantidade de ruído existentes nos dados, entre outros.

Também se observou que é necessário um número maior de amostras no ajuste da função de distribuição de probabilidade acumulada para que se alcance distâncias limites de associação aos *clusters* mais adequadas ao bom funcionamento do método proposto.

Em geral, ficou demonstrado o bom desempenho do método híbrido, tanto na identificação de comportamentos conhecidos, como na detecção de novos comportamentos estruturais. Nas simulações numéricas, os melhores resultados são obtidos quando os dados são organizados por “sensores”, e nas aplicações experimentais quando são organizados por “ensaios”. Com isso, busca-se, no médio prazo, o monitoramento da integridade estrutural em tempo real, provendo respostas de forma automática e contínua, baseando-se apenas em testes vibracionais ambientes com a estrutura em operação, atingindo dessa forma, os objetivos esperados para esta dissertação.

Na prática, a principal vantagem da abordagem proposta é identificar novos comportamentos estruturais a partir da resposta de métodos supervisionados, sendo necessário, de início, apenas o conhecimento prévio do estado atual da estrutura. Além disso, o uso direto das medições de aceleração facilita de forma considerável o problema de identificação de danos, pois, o procedimento se torna mais direto e rápido uma vez que é descartada a necessidade de um processo de identificação modal.

O novo método pode auxiliar no gerenciamento de sistemas de monitoramento da integridade estrutural, uma vez que a partir dele o operador da estrutura pode identificar modificações estruturais e providenciar vistorias a fim de avaliar possíveis danos. Estudos desse tipo tem grande importância dentro da área do monitoramento de estruturas, pois fornecem informações da integridade estrutural, a fim de garantir a segurança dos usuários e evitar falhas catastróficas.

6.1 RECOMENDAÇÕES

Para utilização da abordagem proposta, algumas recomendações são sugeridas baseadas nos resultados obtidos neste trabalho:

- a) Com relação à forma de organização dos dados de entrada, pode-se notar que, na maioria dos casos, o método híbrido alcançou melhores resultados quando esses dados são organizados por “ensaios”;
- b) Recomenda-se, sempre que possível, utilizar um número maior de amostras por “estado estrutural” para melhor treinamento da rede e desempenho do método híbrido;
- c) Em relação à rede neural, o número de neurônios utilizado na camada oculta que mais colaborou para alcance de bons resultados com o método híbrido foi igual a 25. Porém, essa quantidade pode variar a depender do número de parâmetros de entrada da rede, quantidade de ruído nos dados, entre outros. Recomenda-se, também, o uso de uma camada oculta na RNA, o algoritmo de aprendizado de Levenberg-Marquardt e o erro médio quadrático como função de custo. Como funções de ativação, sugere-se a sigmoide tangente hiperbólica na camada oculta e a *softmax* na camada de saída;
- d) Para o algoritmo de agrupamento *k-means*, recomenda-se o uso da métrica de distância *cityblock* com a forma de inicialização dos centroides *plus*;
- e) Sugere-se que as distâncias limites de associação aos *clusters* sejam definidas a partir da probabilidade acumulada igual a 90%.

6.2 TRABALHOS FUTUROS

Como trabalhos futuros, sugere-se:

- a) Implementar a técnica proposta para funcionar em tempo real. Ou seja, a partir do momento em que um novo estado estrutural for detectado, automaticamente ele passa também a ser utilizado como entrada do classificador híbrido na 1º fase da metodologia;
- b) Realizar testes utilizando a Análise de Componentes Principais ou Autoencoders para extrair recursos do sinal “bruto” e eliminar ruídos indesejados, incluindo-se efeitos ambientais/operacionais como umidade, temperatura, tráfego, entre outros;

- c) Realizar testes utilizando mais amostras por nível de dano e mais parâmetros de entrada para treinamento da rede neural.

REFERÊNCIAS

- ABRAHAM, A. Meta learning evolutionary artificial neural networks. **Neurocomputing**, v. 56, p. 1-38, 2004.
- ALVANDI, A.; CRÉMONA, C. Assessment of vibration-based damage identification techniques. **Journal of Sound and Vibration**, v. 292, n. 1, p. 179-202, 2006.
- ALVES, V.; CURY, A.; CREMONA, C. On the use of symbolic vibration data for robust structural health monitoring. **Structures and Buildings**, v. 169, p. 715-723, 2016.
- ALVES, V.; CURY, A.; ROITMAN, N.; MAGLUTA, C.; CREMONA, C. Structural modification assessment using supervised learning methods applied to vibration data. **Engineering Structures**, v.99, p. 439–448, 2015.
- ALVES, V. **Estudo de novas estratégias para identificação de danos estruturais a partir de dados vibracionais**. 2012. Dissertação (Mestrado em Ciências da Engenharia Civil) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2012.
- ALVES, V.; CURY, A.; ROITMAN, N.; MAGLUTA, C.; CREMONA, C. Novelty detection for SHM using raw acceleration measurements. **Structural Control Health Monitoring**, v. 22, n. 9, p. 1193-1207, 2015.
- ALVES, V. N. **Técnicas de anormalidade aplicadas à detecção de danos estruturais**. 2016. Tese (Doutorado em Ciências da Engenharia Civil) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2016.
- AMARAL, R. **Aplicação de métodos computacionais a dados vibracionais para detecção de alterações estruturais**. 2017. Dissertação (Mestrado em Modelagem Computacional) – Faculdade de Engenharia, Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.
- ARTHUR, D.; VASSILVITSKII, S. K-means++: The Advantages of Careful Seeding. **SODA '07: Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms**, p. 1027–1035, 2007.
- 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, p. 273-288, 2000.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer-Verlag, 2006.
- BOCK, H.-H.; DIDAY, E. **Analysis of Symbolic Data: Exploratory Methods for Extracting Statistical Information from Complex Data**. Berlin: Springer-Verlag, 2000.
- BRAGA, D. P.; CARVALHO, A.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. [S.l.]: LTC - Livros Técnicos e Científicos Editora S.A., 2000.

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, p. 375-380, 2015.

CARDOSO, R. A. **Approaches for automated damage detection in structural health monitoring**. 2018. Tese (Doutorado em Engenharia Civil) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2018.

CARDOSO, R. A.; CURY, A.; BARBOSA, F. Automated real-time damage detection strategy using raw dynamic measurements. **Engineering Structures**, v. 196, 2019.

CHANG, C. C.; CHANG, T. Y. P.; XU, Y. G. Structural Damage Detection Using an Iterative Neural Network. **Journal of Intelligent Material Systems and Structures**, v. 11, p. 32-42, 2000.

CURY, A. A. **Techniques D'anormalité Appliquées à la surveillance de Santé Structurale**. 2010. Tese (Doutorado em Engenharia Civil) – Université Paris-Est, França, 2010.

CURY, A. A.; BORGES, C. C.; BARBOSA, F. S. A two-step technique for damage assessment using numerical and experimental vibration data. **Structural Health Monitoring**, v. 10, n. 4, p. 417-428, 2011.

CURY, A. 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, p. 161-186, 2012.

DAMASCENO, N. C.; **Novas estratégias para conserto de soluções degeneradas do algoritmo k-means**. 2016. Tese (Doutorado em Engenharia Elétrica e Computação) – Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Natal, 2016.

DE LA ROSA, J.; AGUERA-PÉREZ, A.; PALOMARES-SALAS, J.; MORENO-MUÑOZ, A. Higher-order statistics: Discussion and interpretation. **Measurement**, v. 46, n. 8, p. 2816-2827, 2013.

DYKE, S.; AGRAWAL, A. K.; CAICEDO, J. M.; CHRISTENSON, R.; GAVIN, H.; JOHNSON, E.; NAGARAJAIAH, S.; NARASIMHAN, S.; SPENCER, B. **NEES: Database for Structural Control and Monitoring Benchmark Problems**, 2015, <https://datacenterhub.org/resources/257>.

DYKE, S.; BERNAL, D.; BECK, J.; VENTURA, C. Experimental Phase II of the Structural Health Monitoring Benchmark Problem. In: **Proceedings of the 16th ASCE Engineering Mechanics Conference**, 2003.

FAN, W.; QIAO, P. Vibration-based damage identification methods: a review and comparative study. **Structural Health Monitoring**, v. 10, n. 1, p. 83-111, 2011.

FANG, X.; LUO, H.; TANG, J. Structural Damage Detection Using Neural Network with Learning Rate Improvement. **Computers and Structures**, v. 83, p. 2150-2161, 2005.

FARRAR, C. R.; WORDEN, K. **Structural Health Monitoring: A Machine Learning Perspective.** [S.I.]: John Wiley e Sons, Ltd, 2012.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, n. 2, e165, 2019.

FONTANA, A.; NALDI, C. Estudo e Comparação de Métodos para Estimação de Números de Grupos em Problemas de Agrupamento de Dados. **Relatório técnico, ICM, Universidade de São Paulo**, São Carlos, 2009.

GOMES, H. M. Redes Neurais Artificiais para Detecção de Danos. **Mecânica Computacional Vol. XXIII**. Bariloche, Argentina, 2004.

HAGAN, M. T.; MENHAJ, B. Training Feedforward Networks with the Marquardt Algorithm. **IEEE transactions on Neural Networks**, v. 5, n. 6, p. 989-993, 1994.

HAYKIN, S. **Neural Networks: a comprehensive foundation.** [S.I.]: Prentice Hall, 1999.

HIBBELER, R. **Resistência dos materiais.** 7º. ed. [S.I.]: Pearson Education do Brasil, 2010.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data Clustering: A Review. **ACM Computing Surveys**, v. 31, n. 3, p. 264-323, 1999.

JEYASEHAR C. A.; SUMANGALA, K. Damage Assessment of Prestressed Concrete Beams Using Artificial Neural Network (ANN) Approach. **Computers and Structures**, v.84, p. 1709-1718, 2006.

KIJEWSKI-CORREA, T.; KWON, D. K.; KAREEM, A.; BENTZ, A.; GUO, Y.; BOBBY, S.; ABDELRAZAQ, A. SmartSync: An Integrated Real-Time Structural Health Monitoring and Structural Identification System for Tall Buildings. **Journal of Structural Engineering**, v. 139, p. 1675-1687, 2013.

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, p. 1137-1145, 1995.

KORDOS, M.; DUCH, W. A Survey of Factors Influencing MLP Error Surface. **Control and Cybernetics**, v.33, n.4, p. 611-631, 2004.

LEE, J. J.; LEE, J. W.; YI, J. H.; YUN, C. B.; JUNG, H. Y. Neural networks-based damage detection for bridges considering errors in baseline finite element models. **Journal of Sound and Vibration**, v.280, p. 555-578, 2005.

LI, F.; MENG, G.; YE, L.; CHEN, P. Wavelet transform-based higher-order statistic for fault diagnosis in rolling element bearings. **Journal of Vibration and Control**, v. 14, n. 11, p. 1691-1709, 2008.

MCCANN, D.; FORDE, M. Review of NDT methods in the assessment of concrete and masonry structures. **NDTeE International**, v. 34, n. 2, p. 71-84, 2001.

MEHJRJOO, M.; KHAJI, N.; MOHARRAMI, H.; BAHREININEJAD, A. Damage Detection of Truss Bridge Joints Using Artificial Neural Networks. **Expert Systems with Applications**, v. 35, p. 1122-1131, 2008.

NGUYEN, V. V.; DACKERMANN, U., LI, J.; MAKKI ALAMDARI, M.; MUSTAPHA, S.; RUNCIE, P.; YE, L. Damage Identification of a Concrete Arch Beam Based on Frequency Response Functions and Artificial Neural Networks. **Electronic Journal of Structural Engineering**, 2015.

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, p. 876-885, 2011.

PANCHAL, G.; GANATRA, A.; KOSTA, Y. P.; PANCHAL, D. Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. **International Journal of Computer Theory and Engineering**, v. 3, n. 2, p. 332-337, 2011.

PARK, S.; LEE, J. J.; YUN, C.B.; INMAN, D. J. Electro-Mechanical Impedance-Based Wireless Structural Health Monitoring Using PCA-Data Compression and k-means Clustering Algorithms. **Journal of Intelligent Material Systems and Structures**, v. 19, n. 4, p. 509-520, 2008.

PIMENTEL, P. P.; FRANÇA, F.; OMAR, N. A identificação de grupos de aprendizes no ensino presencial utilizando técnicas de clusterização. **Anais do Simpósio Brasileiro de Informática na Educação**, Rio de Janeiro , 2003.

PRÍNCIPE, J.; EULIANO, N.; LEFEBVRE, W. **Neural and adaptive systems: fundamentals through simulations**. [S.I.]: Wiley: London, 2000.

REHMAN, S.; IBRAHIM, Z.; MEMON, S.; JAMEEL, M. Nondestructive test methods for concrete bridges: A review. **Construction and Building Materials**, v. 107, p. 58-86, 2016.

RUCKA, W.; WILDE, K. Neuro-Wavelet Damage Detection Technique In Beam, Plate And Shell Structures With Experimental Validation, **Journal of Theoretical and Applied Mechanics**, v. 48, n. 3, p. 579-604, 2010.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature Publishing Group**, v.323, p. 533-536, 1986.

RYTTER, A. **Vibrational based inspection of civil engineering structures**. 1993. Ph.D. Thesis – Denmark: Department of Building Technology and Structural, Aalborg University, Aalborg, 1993.

SAHIN, M.; SHENOI, R. A. Quantification and localisation of damage in beam-like structures. **Engineering Structures**, v.25, p. 1785-1802, 2003.

SANTOS, A. O que causou a queda da ponte em Gênova, na Itália? **Portal Cimento Itambé**. 22 ago. 2018. Disponível em: <https://www.cimentoitambe.com.br/o-que-causou-a-queda-da-ponte-em-genova-na-italia/>. Acesso em: 23 out. 2019.

- 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, p. 1271-1290, 2013.
- SINGH, A.; YADAV, A.; RANA, A. K-means with Three different Distance Metrics. **International Journal of Computer Applications**, v. 67, n. 10, p. 13-17, 2013.
- TAN, Z. X.; THAMBIRATNAM, D.; CHAN, T. H.; RAZAK, H. A. Detecting damage in steel beams using modal strain energy based. **Engineering Failure Analysis**, v.79, p. 253-262, 2017.
- TORRES, A. S.; ALVES, V. N.; CURY, A. A.; BARBOSA, F. S. Advanced Statistical Techniques Applied to Raw Data for Structural Damage Detection. **Experimental Vibration Analysis for Civil Structures**, v.5, p. 94-103, 2018.
- XU, YOU-LIN; XIA, YONG. **Structural Health Monitoring of Long-Span Suspension Bridges**. Taylor e Francis Group, 2012.
- YAN A.M.; KERSCHN G.; DE BOE, P.; GOLINVAL, J.C. Structural damage diagnosis under varying environmental conditions – Part I: A linear analysis. **Mechanical Systems and Signal Processing**, v. 19, n. 4, 847-864, 2005.
- YU, L.; ZHUL, J.; YU, L. Structural Damage Detection in a Truss Bridge Model Using Fuzzy Clustering and Measured FRF Data Reduced by Principal Component Projection. **Advances in Structural Engineering**, v. 16, n. 1, p. 207-217, 2013.
- ZANG, C.; FRISWELL, M. I.; IMREGUN, M. Structural Damage Detection using Independent Component Analysis. **Structural Health Monitoring**, v. 3, n. 1, p. 69-83, 2004.
- ZHOU, Y.; MAIA, N. M.; SAMPAIO, R. P. C.; WAHAB, M. A. Structural damage detection using transmissibility together with hierarchical clustering analysis and similarity measure. **Structural Health Monitoring**, v.16, p. 711-731, 2016.

APÊNDICE A – Comparação das métricas e formas de inicialização dos centroides do algoritmo *k-means* no método híbrido

Tabela A.1 – Comparação das métricas de distância com as formas de inicialização dos centroides para os dados organizados por “ensaio” (em %)

			<i>Plus</i>			<i>Sample</i>			<i>Uniform</i>			<i>Cluster</i>		
			R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2
<i>Sqeclidean</i>	D0	Média	-(2)	90	80	-	90	80	-	90	80	-	90	80
		DP (1)	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71
	D1	Média	-	91	97	-	91	97	-	91	97	-	91	97
		DP	-	9,94	6,75	-	9,94	6,75	-	9,94	6,75	-	9,94	6,75
	D2	Média	51	41	36	51	41	36	51	41	36	51	41	36
		DP	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5
<i>Cityblock</i>	D0	R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2	
		Média	-	90	80	-	90	80	-	90	80	-	90	80
		DP	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71
	D1	Média	-	91	96	-	91	96	-	91	96	-	91	96
		DP	-	9,94	9,66	-	9,94	9,66	-	9,94	9,66	-	9,94	9,66
	D2	Média	51	41	36	51	41	36	51	41	36	51	41	36
		DP	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5
<i>Cosine</i>	D0	R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2	
		Média	-	90	80	-	90	80	-	90	80	-	90	80
		DP	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71	-	9,43	4,71
	D1	Média	-	91	97	-	91	97	-	91	97	-	91	97
		DP	-	9,94	6,75	-	9,94	6,75	-	9,94	6,75	-	9,94	6,75
	D2	Média	51	41	36	51	41	36	51	41	36	51	41	36
		DP	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5	12	16,6	13,5

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

Na Tabela A.1, o número de neurônios utilizados na camada oculta da rede neural no método híbrido é igual a 25 e a probabilidade de um novo ensaio pertencer aos *clusters* existentes considerada é igual a 97,5%.

Tabela A.2 – Comparação das métricas de distância com as formas de inicialização dos centroides para os dados organizados por “sensores” (em %)

			<i>Plus</i>			<i>Sample</i>			<i>Uniform</i>			<i>Cluster</i>		
			R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2
<i>Sqeclidean</i>	D0	Média	-(2)	90	90	-	90	90	-	90	90	-	90	90
		DP (1)	-	0	0	-	0	0	-	0	0	-	0	0
	D1	Média	-	90	90	-	90	90	-	90	90	-	90	90
		DP	-	0	0	-	0	0	-	0	0	-	0	0
	D2	Média	100	100	100	100	100	100	100	100	100	100	100	100
		DP	0	0	0	0	0	0	0	0	0	0	0	0
<i>Cityblock</i>			R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2
	D0	Média	-	90	90	-	90	90	-	90	90	-	90	90
		DP	-	0	0	-	0	0	-	0	0	-	0	0
	D1	Média	-	90	90	-	90	90	-	90	90	-	90	90
		DP	-	0	0	-	0	0	-	0	0	-	0	0
	D2	Média	100	100	100	100	100	100	100	100	100	100	100	100
		DP	0	0	0	0	0	0	0	0	0	0	0	0
<i>Cosine</i>			R0	R1	R2	R0	R1	R2	R0	R1	R2	R0	R1	R2
	D0	Média	-	90	90	-	90	90	-	90	90	-	90	90
		DP	-	0	0	-	0	0	-	0	0	-	0	0
	D1	Média	-	90	90	-	90	90	-	90	90	-	90	90
		DP	-	0	0	-	0	0	-	0	0	-	0	0
	D2	Média	100	100	100	100	100	100	100	100	100	100	100	100
		DP	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

Na Tabela A.2, o número de neurônios utilizados na camada oculta da rede neural no método híbrido é igual a 50 e a probabilidade de um novo ensaio pertencer aos *clusters* existentes considerada é igual a 97,5%.

APÊNDICE B – Resultados obtidos com o método híbrido considerando a probabilidade igual a 90%

Tabela B.1 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)

		25			35			50			
		R0	R1	R2	R0	R1	R2	R0	R1	R2	
Método híbrido	D0	Média	-(2)	90	90	-	80	90	-	100	100
	DP(1)	-	0	0	-	0	0	-	0	0	
	D1	Média	0	0	10	70	70	80	80	80	80
		DP	0	0	0	0	0	0	0	0	0
RNA	D2	Média	0	0	10	30	30	20	100	100	90
		DP	0	0	0	0	0	0	0	0	0
	D0	Média	-(3)	100	100	-	100	100	-	100	100
		DP	-	0	0	-	0	0	-	0	0
	D1/D2	Média	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
		DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificações com a rede neural.

Na Tabela B.1 a rede neural no método híbrido foi treinada com o estado de dano fictício e o estado sem danos, ambos sem ruído.

Tabela B.2 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em%)

		15			25			35			
		R0	R1	R2	R0	R1	R2	R0	R1	R2	
Método híbrido	D0	Média	-(2)	80	70	-	90	90	-	80	80
		DP(1)	-	0	0	-	0	0	-	0	0
	D1	Média	50	60	60	70	80	80	50	50	50
		DP	0	0	0	0	0	0	0	0	0
RNA	D2	Média	60	60	60	30	40	40	50	50	50
		DP	0	0	0	0	0	0	0	0	0
	D0	Média	-	100	100	-	100	100	-	100	100
		DP	-	0	0	-	0	0	-	0	0
D1/D2		Média	N/A(3)	N/A							
		DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificações com a rede neural.

Na Tabela B.2 a rede neural no método híbrido foi treinada com o estado de dano fictício e o estado sem danos, ambos sem ruído.

Tabela B.3 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por sensores (em%)

		25			35			50			
		R0	R1	R2	R0	R1	R2	R0	R1	R2	
Método híbrido	D0	Média	-(2)	90	90	-	80	60	-	80	90
	D0	DP(1)	-	0	0	-	0	0	-	0	0
	D1	Média	-	64	64	-	80	60	-	90	80
	D1	DP	-	8,43	8,43	-	0	0	-	0	0
RNA	D2	Média	100	100	100	100	100	100	100	100	100
	D2	DP	0	0	0	0	0	0	0	0	0
	D0	Média	-	100	100	-	100	100	-	100	100
	D0	DP	-	0	0	-	0	0	-	0	0
RNA	D1	Média	-	100	100	-	100	100	-	100	100
	D1	DP	-	0	0	-	0	0	-	0	0
	D2	Média	N/A(3)	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
	D2	DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificações com a rede neural.

Na Tabela B.3 a rede neural no método híbrido foi treinada com o estado sem danos e o estado de dano 1, ambos sem ruído.

Tabela B.4 – Média de classificações corretas dos classificadores híbridos e das RNAs quando os dados de entrada são organizados por ensaios (em%)

			15			25			35		
						R0	R1	R2	R0	R1	R2
			Média	-	(2)	68	62	-	78	73	-
Método híbrido	D0	DP(1)	-	9,2	7,89	-	10,33	9,49	-	7,89	5,16
		Média	-	78	81	-	69	95	-	77	86
	D1	DP	-	15,5	14,49	-	3,16	9,72	-	6,75	12,65
	D2	Média	63	61	67	57	54	47	44	41	42
	D2	DP	4,83	11	11,6	14,94	15,06	13,37	16,47	9,94	7,89
RNA	D0	Média	-	100	92	-	96	96	-	92	92
		DP	-	0	4,22	-	5,16	5,16	-	7,89	7,89
	D1	Média	-	100	100	-	97	100	-	93	94
	D1	DP	-	0	0	-	6,75	0	-	14,94	12,65
	D2	Média	N/A(3)	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
		DP	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Desvio-padrão

(2) Dados utilizados na fase de treinamento da rede neural.

(3) Não se aplica a classificações com a rede neural.

Na Tabela B.4 a rede neural no método híbrido foi treinada com o estado sem danos e o estado de dano 1, ambos sem ruído.

APÊNDICE C – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 97,5% e a 85%

Tabela C.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 97,5% (em%)

		Número de neurônios		
		10	15	20
Método híbrido	D1	Média	100	93,33
		Desvio-padrão	0	0
	D2/1(1)	Média	6,67	26,67
		Desvio-padrão	0	0
	D2/2(2)	Média	0	33,33
		Desvio-padrão	0	0
	D3/1	Média	33,33	53,33
		Desvio-padrão	0	0
RNA	D3/2	Média	6,67	20
		Desvio-padrão	0	0
	D4/1	Média	20	53,33
		Desvio-padrão	0	0
	D4/2	Média	0	6,67
		Desvio-padrão	0	0
	D5/1	Média	13,33	13,33
		Desvio-padrão	0	0
	D5/2	Média	0	0
		Desvio-padrão	0	0
	D1	Média	100	100
		Desvio-padrão	0	0
	D2/D3/D4/D5	Média	N/A(3)	N/A
		Desvio-padrão	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

Tabela C.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			10	15	20
Método híbrido	D1	Média	100	60	40
		Desvio-padrão	0	0	0
	D2/1(1)	Média	13,33	60	33,33
		Desvio-padrão	0	0	0
	D2/2(2)	Média	6,67	73,33	60
		Desvio-padrão	0	0	0
	D3/1	Média	60	60	73,33
		Desvio-padrão	0	0	0
	D3/2	Média	6,67	93,33	80
		Desvio-padrão	0	0	0
	D4/1	Média	20	80	60
		Desvio-padrão	0	0	0
	D4/2	Média	0	73,33	26,67
		Desvio-padrão	0	0	0
	D5/1	Média	33,33	13,33	46,67
		Desvio-padrão	0	0	0
	D5/2	Média	6,67	40	33,33
		Desvio-padrão	0	0	0
RNA	D1	Média	100	100	100
		Desvio-padrão	0	0	0
	D2/D3/D4/D5	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

APÊNDICE D – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 97,5% e a 85%

Tabela D.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 97,5% (em%)

			Número de neurônios		
			15	25	55
Método híbrido	DT	Média	66,67	83,33	66,67
		Desvio-padrão	40,82483	40,82483	40,82483
	D3	Média	100	100	100
		Desvio-padrão	0	0	0
RNA	D4	Média	100	83,33	66,67
		Desvio-padrão	0	0	0
	D5	Média	33,333	50	66,67
		Desvio-padrão	0	0	0
D3/D4/D5	DT	Média	100	100	100
		Desvio-padrão	0	0	0
	Média		N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

Tabela D.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

		Número de neurônios			
		15	25	55	
Método híbrido	DT	Média	58,33	33,33	41,67
		Desvio-padrão	49,1596	51,63978	49,1596
	D3	Média	100	100	100
		Desvio-padrão	0	0	0
	D4	Média	100	100	66,67
		Desvio-padrão	0	0	0
	D5	Média	66,67	83,33	100
		Desvio-padrão	0	0	0
	DT	Média	100	100	100
		Desvio-padrão	0	0	0
RNA	D3/D4/D5	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

APÊNDICE E – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85%

Tabela E.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 90% (em%)

			Número de neurônios		
			10	15	20
Método híbrido	D1	Média	67,34	42,67	58,67
		Desvio-padrão	4,92	12,25	13,98
	D2	Média	46	48,67	43,34
		Desvio-padrão	10,16	12,59	4,72
D3/1(1)	D3/1(1)	Média	27,33	32,67	26
		Desvio-padrão	11,53	18,18	21,65
	D3/2(2)	Média	24	36,67	32,67
		Desvio-padrão	12,65	4,71	11,09
D4/1	D4/1	Média	23,33	48,67	37,33
		Desvio-padrão	13,05	11,35	16,09
	D4/2	Média	32,67	39,33	33,33
		Desvio-padrão	18,97	7,98	14,74
D5/1	D5/1	Média	16	24,67	26
		Desvio-padrão	7,17	13,35	13,86
	D5/2	Média	15,33	32,67	22,67
		Desvio-padrão	6,32	4,92	19,68
RNA	D1	Média	76	69,33	72,67
		Desvio-padrão	10,04	4,66	7,98
	D2	Média	73,33	68,67	65,99
		Desvio-padrão	7,70	3,22	7,98
	D3/D4/D5	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

Tabela E.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			10	15	20
Método híbrido	D1	Média	63,33	42,67	54
		Desvio-padrão	7,20	12,25	13,86
	D2	Média	46	48	34,67
		Desvio-padrão	10,16	13,26	5,26
	D3/1(1)	Média	31,33	34	35,99
		Desvio-padrão	13,35	18,97	21,36
	D3/2(2)	Média	25,33	38,67	39,33
		Desvio-padrão	12,88	7,57	5,84
	D4/1	Média	24,67	51,99	40,67
		Desvio-padrão	12,59	9,84	16,16
RNA	D4/2	Média	36	40,67	46,66
		Desvio-padrão	21,82	7,34	11,76
	D5/1	Média	17,34	29,33	28,67
		Desvio-padrão	7,82	11,84	14,07
	D5/2	Média	16	38,67	32
		Desvio-padrão	7,17	6,13	10,33
	D1	Média	76	69,33	72,67
		Desvio-padrão	10,04	4,66	7,98
	D2	Média	73,33	68,67	65,99
		Desvio-padrão	7,70	3,22	7,98
	D3/D4/D5	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

APÊNDICE F – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 97,5% e a 85%

Tabela F.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 97,5% (em%)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço	Média	0	0	0
		Desvio-padrão	0	0	0
	Depois do reforço	Média	15,38	38,46	38,46
		Desvio-padrão	0	0	0
RNA	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço/Depois do reforço	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

Tabela F.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	100	80	40
		Desvio-padrão	0	0	0
	Durante o reforço	Média	7,69	38,46	23,08
		Desvio-padrão	0	0	0
	Depois do reforço	Média	15,38	84,61	69,23
		Desvio-padrão	0	0	0
RNA	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço/Depois do reforço	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

APÊNDICE G – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85%

Tabela G.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 90% (em%)

		Número de neurônios			
		20	25	30	
Método híbrido	Antes do reforço	Média	90	40	80
		Desvio-padrão	0	0	0
	Durante o reforço 1(1)	Média	10	10	0
		Desvio-padrão	0	0	0
	Durante o reforço 2(2)	Média	10	30	10
		Desvio-padrão	0	0	0
	Depois do reforço 1	Média	10	40	0
		Desvio-padrão	0	0	0
RNA	Depois do reforço 2	Média	10	10	10
		Desvio-padrão	0	0	0
	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço/ Depois do reforço	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

Tabela G.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			20	25	30
Método híbrido	Antes do reforço	Média	80	40	70
		Desvio-padrão	0	0	0
	Durante o reforço 1(1)	Média	30	10	30
		Desvio-padrão	0	0	0
	Durante o reforço 2(2)	Média	30	30	30
		Desvio-padrão	0	0	0
	Depois do reforço 1	Média	30	40	10
		Desvio-padrão	0	0	0
RNA	Depois do reforço 2	Média	50	10	20
		Desvio-padrão	0	0	0
	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço/ Depois do reforço	Média	N/A(3)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

APÊNDICE H – Resultados obtidos com o método híbrido para os dados organizados por “ensaios” considerando a probabilidade igual a 90% e a 85%

Tabela H.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 90% (em%)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	80	80	74
		Desvio-padrão	0	0	13,5
	Durante o reforço	Média	33,33	33,33	63,34
		Desvio-padrão	0	0	10,54
	Depois do reforço	Média	56,93	40	38,46
		Desvio-padrão	6,48	4,87	0
RNA	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Depois do reforço	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

Tabela H.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			15	25	50
Método híbrido	Antes do reforço	Média	64	80	74
		Desvio-padrão	33,73	0	13,5
	Durante o reforço	Média	26,66	33,33	63,34
		Desvio-padrão	14,05	0	10,54
	Depois do reforço	Média	63,08	63,08	43,08
		Desvio-padrão	3,24	4,86	14,5
RNA	Antes do reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Durante o reforço	Média	100	100	100
		Desvio-padrão	0	0	0
	Depois do reforço	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Não se aplica a classificações com a rede neural.

APÊNDICE I – Resultados obtidos com o método híbrido para os dados organizados por “sensores” considerando a probabilidade igual a 90% e a 85%

Tabela I.1 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 90% (em%)

		Número de neurônios		
		20	25	30
Método híbrido	Antes do reforço	Média	16	4
		Desvio-padrão	11,7379	5,16398
	Durante o reforço	Média	51	62
		Desvio-padrão	31,0734	33,5989
	Depois do reforço 1(1)	Média	26	18
		Desvio-padrão	14,2984	15,4919
RNA	Depois do reforço 2(2)	Média	25	27
		Desvio-padrão	20,6828	16,3299
	Antes do reforço	Média	67	46
		Desvio-padrão	22,63	12,65
	Durante o reforço	Média	91	98
		Desvio-padrão	5,68	4,21
	Depois do reforço	Média	N/A(3)	N/A
		Desvio-padrão	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.

Tabela I.2 – Média de classificações corretas dos classificadores híbridos e das RNAs, probabilidade igual a 85% (em%)

			Número de neurônios		
			20	25	30
Método híbrido	Antes do reforço	Média	5	0	5
		Desvio-padrão	5,27046	0	8,49837
	Durante o reforço	Média	31	18	4
		Desvio-padrão	28,0674	10,328	6,99206
	Depois do reforço 1(1)	Média	34	40	69
		Desvio-padrão	12,6491	0	14,4914
RNA	Depois do reforço 2(2)	Média	33	36	51
		Desvio-padrão	16,3639	12,6491	9,94429
	Antes do reforço	Média	67	46	66
		Desvio-padrão	22,63	12,65	13,499
	Durante o reforço	Média	91	98	85
		Desvio-padrão	5,68	4,21	8,49837
	Depois do reforço	Média	N/A(1)	N/A	N/A
		Desvio-padrão	N/A	N/A	N/A

Fonte: Elaborado pelo autor.

(1) Matriz 1.

(2) Matriz 2.

(3) Não se aplica a classificações com a rede neural.