

**METODOLOGIA BASEADA EM REDES NEURAS ARTIFICIAIS  
PARA A DETECÇÃO DE DANOS ESTRUTURAIS**

**MARÍLIA MARCY CABRAL DE ARAÚJO**

**ORIENTADORA: GRACIELA NORA DOZ DE CARVALHO**

**CO-ORIENTADOR: ÁLVARO CUNHA**

**TESE DE DOUTORADO EM ESTRUTURAS E CONSTRUÇÃO CIVIL**

**FACULDADE DE TECNOLOGIA**

**UNIVERSIDADE DE BRASÍLIA**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA**

**DEPARTAMENTO DE ENGENHARIA CIVIL**

**METODOLOGIA BASEADA EM REDES NEURAIAS ARTIFICIAIS  
PARA A DETECÇÃO DE DANOS ESTRUTURAIS**

**MARÍLIA MARCY CABRAL DE ARAÚJO**

**TESE SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA  
CIVIL E AMBIENTAL DA FACULDADE DE TECNOLOGIA DA  
UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS  
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTORA  
EM ESTRUTURAS E CONSTRUÇÃO CIVIL.**

**APROVADA POR:**

---

**Prof<sup>ª</sup> Graciela Doz, Dr. Ing. (ENC-UnB)**

**(Orientadora)**

---

**Prof. José Luís Vital de Brito, Dr. (ENC-UnB)**

**(Examinador Interno)**

---

**Prof.<sup>a</sup> Suzana Moreira Ávila, Dr.<sup>a</sup>. (FGA-UnB)**

**(Examinadora Interno)**

---

**Prof. Ney Roitman, Dr. (COPPE/UFRJ)**

---

**BRASÍLIA/DF, 17 DE NOVEMBRO DE 2017**

## FICHA CATALOGRÁFICA

MARCY, MARÍLIA CABRAL DE ARAÚJO

Metodologia Baseada Em Redes Neurais Artificiais para a Detecção De Danos Estruturais [Distrito Federal] 2017.

xxi, 203p., 297 mm (ENC/FT/UnB, Mestre, Estruturas e Construção Civil, 2017). Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia. Departamento de Engenharia Civil e Ambiental.

1. Identificação de danos

2. Propriedades dinâmicas

3. Estruturas

4. Redes Neurais Artificiais

I. ENC/FT/UnB

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

MARCY M., C. A. (2017). Metodologia Baseada Em Redes Neurais Artificiais para a Detecção de Danos Estruturais. Tese de Doutorado em Estruturas e Construção Civil, Publicação, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 203p.

## CESSÃO DE DIREITOS

AUTOR: Marília Marcy Cabral de Araújo.

TÍTULO: Desenvolvimento De Uma Metodologia Baseada Em Redes Neurais Artificiais para a Detecção de Danos Estruturais.

GRAU: DOUTORA

ANO: 2017

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

---

Marília Marcy Cabral de Araújo

CLN 209, Bl C, apto 209.

70847540 Brasília – DF – Brasil.

## AGRADECIMENTOS

Sem nenhuma dúvida, o doutorado é um grande e longo ciclo que começa a se encerrar. Um tempo no qual as emoções mais contrárias caminharam tão próximas, revelando momentos de alegrias, tristezas, dúvidas.... enfim, situações que aproximaram, distanciaram e fizeram surgir pessoas pelas quais não poderia deixar de expressar minha gratidão...

À professora Graciela Doz pela orientação, ensinamentos, sugestões, paciência e confiança ao longo destes 7 anos trabalhando juntas. Além disso, não poderia deixar de agradecer também a pessoa e grande amiga que se tornou, sempre me acolhendo nos piores e melhores momentos vividos em Brasília, a você toda a minha gratidão.

Ao professor Brito pelos ensinamentos e pela convivência agradável neste período.

Ao professor Álvaro Cunha pela oportunidade dada, acolhimento e orientação durante o período na Faculdade de Engenharia da Universidade do Porto. Ao professor Filipe Magalhães pelos dados cedidos e pelas contribuições para este trabalho. À professora Elsa Caetano pela receptividade em Portugal e pelo convite para realizar ensaios junto ao seu grupo de pesquisa. Agradeço também todo apoio dado pelo grupo português do ViBest.

Aos professores e amigos Andrea e Gustavo pelo incentivo que sempre me passaram.

À UnB e ao Programa de Pós-Graduação em Estrutura e Construção Civil (PECC).

Ao CNPq e à CAPES pelo apoio financeiro durante o desenvolvimento da pesquisa no Brasil e em Portugal, respectivamente.

A minha família, em especial, aos meus pais Pereira e Margareth, por todo amor, dedicação e incentivo permanente para que eu conseguisse chegar até o fim deste trabalho, minha eterna gratidão.

A Roberto, André, Bruno e Graciela pelo acolhimento, carinho e cuidados durante todos estes anos que, certamente, me proporcionaram (e continuam proporcionando) sempre a sensação de ter uma família aqui em Brasília;

A minha sempre vizinha e amiga Nicole, por todo apoio e companheirismo nestes anos.

Aos amigos que compartilharam comigo os diversos momentos de alegrias e tristezas vividos dentro e fora da UnB, sem vocês a caminhada e a realização deste trabalho seriam bem mais difíceis.

Às funcionárias do SG12 por sempre proporcionarem momentos de descontração e pelo carinho de sempre;

A todos os que de alguma maneira contribuíram direto ou indiretamente para a realização deste trabalho, meus sinceros agradecimentos.

*Dedico este trabalho aos  
meus pais Pereira e  
Margareth.*

## RESUMO

### DESENVOLVIMENTO DE UMA METODOLOGIA BASEADA EM REDES NEURAIIS ARTIFICIAIS PARA A DETECÇÃO DE DANOS ESTRUTURAIS

**Autor:** Marília Marcy Cabral de Araújo

**Orientador:** Graciela Nora Doz de Carvalho

**Co-Orientador:** Álvaro Cunha

**Programa de Pós-graduação em Estruturas e Construção Civil**

**Brasília, novembro de 2017.**

Durante a vida útil as estruturas sofrem solicitações, desgastes, deteriorações e outros processos que podem causar fissuração, de forma a comprometer seu funcionamento, ou, até mesmo, ser a causa de seu colapso estrutural. Somado a esses fatores, o crescente número de estruturas muito esbeltas, conseqüentemente mais susceptíveis a vibrações excessivas, bem como a preocupação com o desempenho e a degradação de estruturas antigas, têm impulsionado o estudo e o desenvolvimento de novas técnicas capazes de realizar um acompanhamento contínuo da saúde da estrutura. Neste sentido, ferramentas com a capacidade de captar e interpretar confiável e rapidamente as respostas de estruturas de médio e grande porte, sobretudo aquelas baseadas nas propriedades dinâmicas, tornam-se essenciais para complementar um sistema de monitoramento da saúde estrutural. Nos últimos anos, parte da comunidade científica vem adotando a detecção de danos como um problema de reconhecimento de padrões, no qual uma classificação é realizada em função de parâmetros afetados por uma mudança nas propriedades físicas de um sistema. Nesta perspectiva, pode-se citar a existência de ferramentas que, ao serem trabalhadas em conjunto com as propriedades dinâmicas, tornam-se métodos eficientes na detecção de danos, como é o caso das Redes Neurais Artificiais (RNAs) e foco deste trabalho. Foram estudados três tipos de rede (Backpropagation, a Learning Vector Quantization (LVQ) e a Self Organizing Maps (SOM)), aplicadas aos casos de dois tipos de estruturas. A primeira, mais simples e em menor escala foi uma viga produzida em laboratório. Já o segundo caso estudado foi o da Ponte do Infante Dom Henrique, em Portugal. Em ambas as aplicações foram variados alguns parâmetros dos algoritmos para verificar a robustez da ferramenta e os resultados foram bastante animadores, resultando em forte tendência de integrar as RNAs a sistemas de monitoramento de estruturas, inclusive de grande porte.

**Palavras chave:** Propriedades Dinâmicas; Identificação de danos; Redes Neurais Artificiais.

## **ABSTRACT**

### **DEVELOPMENT OF A METHODOLOGY BASED ON ARTIFICIAL NEURAL NETWORKS FOR STRUCTURAL DAMAGES DETECTION**

**Author: Marília Marcy Cabral de Araújo**

**Supervisor: Graciela Nora Doz de Carvalho**

**Supervisor: Álvaro Cunha**

**Programa de Pós-graduação em Estruturas e Construção Civil**

**Brasília, November, 2017.**

During useful life, structures suffer from stress, wear, deterioration and other processes that can cause cracking, so as to compromise their functioning or even cause structural collapse. Added to these factors, the growing number of very slender structures, consequently more susceptible to excessive vibrations, as well as the concern with the performance and the degradation of old structures, have driven the study and the development of new techniques capable of continuous structure health monitoring. In this sense, tools with the ability to capture and interpret reliably and quickly the responses of medium and large structures, especially those based on dynamic properties, are essential to complement a structural health monitoring system. In recent years, part of the scientific community has been adopting damage detection as a pattern recognition problem in which a classification is performed according to parameters affected by a change in the physical properties of a system. In this perspective, it can be mentioned the existence of tools that when worked in conjunction with the dynamic properties become efficient methods in the detection of damages, as is the case of Artificial Neural Networks (ANNs) and focus of this work. Three types of network (Backpropagation, Learning Vector Quantization (LVQ) and Self Organizing Maps (SOM) were studied, applied to cases of two types of structures. The first, simpler and in smaller scale was a beam produced in the laboratory. The second case studied was the Bridge of the Infante Dom Henrique in Portugal. In both applications, some parameters of the algorithms were varied to verify the robustness of the tool and the results were quite encouraging, resulting in a strong tendency to integrate ANNs to structures monitoring systems, even large ones

**Keywords:** Dynamic Characteristics, Damage, Artificial Neural Network.

## SUMÁRIO

1. INTRODUÇÃO .....	22
1.1 Objetivos .....	27
1.2 Metodologia.....	27
1.3 Organização da tese .....	29
2. REVISÃO BIBLIOGRÁFICA .....	31
2.1 Monitoramento estrutural.....	31
2.2 Monitoramento estrutural com Redes Neurais Artificiais (RNAs) .....	39
3. FUNDAMENTOS TEÓRICOS .....	52
3.1 Obtenção das propriedades dinâmicas .....	52
3.2 Redes neurais artificiais .....	54
3.3 Rede Backpropagation .....	61
3.3.1 Treinamento das RNAs <i>Backpropagation</i> .....	62
3.4 Rede Mapa auto-organizável ou <i>Self Organizing Maps</i> (SOM) .....	66
3.4.1 Treinamento dos <i>Self Organizing Maps</i> .....	69
3.5 Learning Vector Quantization (LVQ).....	74
4. FERRAMENTAS COMPUTACIONAIS.....	78
5. ANÁLISES EM MODELO REDUZIDO - VIGA.....	86
5.1 Dados para treinamento e validação das redes neurais.....	86
5.2 Dados para teste das redes neurais.....	91
5.2.1 Ensaios experimentais e características dinâmicas.....	92
5.3 Localização de danos a partir das Redes Neurais Artificiais – considerações iniciais .....	95
5.4 Resultados Rede Backpropagation .....	97
5.4.1 Redes Backpropagation com modos de vibração (RBMV) .....	98
5.4.2 Redes <i>Backpropagation</i> com as frequências de vibração (RBFV) .....	111

5.4.3	Redes Backpropagation com as frequências e os modos de vibração	
(RBFMV)		115
5.4.4	Conclusões parciais das redes Backpropagation aplicadas à viga estudada.	
		123
5.5	Learning Vector Quantization - LVQ.....	125
5.5.1	LVQ com modos de vibração (LVQ-MV).....	126
5.5.2	LVQ com as frequências vibração (LVQ-FV).....	130
5.5.3	LVQ com os modos e as frequências vibração (LVQ-MFV).....	132
5.5.4	Conclusões parciais das redes LVQ aplicadas à viga estudada.....	136
6.	ESTUDO NUMÉRICO DA PONTE INFANTE DOM HENRIQUE.....	139
6.1	Ponte Infante Dom Henrique.....	139
6.1.1	Descrição da ponte.....	139
6.1.2	Características dinâmicas da ponte.....	140
6.1.3	Monitoramento contínuo da ponte.....	142
6.1.4	Modelagem numérica.....	144
6.2	Redes Neurais Artificiais para avaliação de danos na ponte.....	148
6.2.1	Learning Vector Quantization – LVQ.....	149
6.2.1.2.1	Análise 1: Teste do LVQ apenas com dados da ponte.....	155
6.2.1.2.2	Análise 2: Teste do LVQ com dados da ponte e dos modelos	
danificados		156
6.2.2	Redes Self Organizing Maps - SOM.....	161
6.2.2.2.1	Análise 1: Treinamento e teste do SOM com dados do primeiro e	
segundo ano de monitoramento (sem consideração de dano), respectivamente.....		164
6.2.2.2.2	Análise 2: Treinamento do SOM com dados do primeiro ano de	
monitoramento da ponte e teste com dados do segundo ano de modelos danificados.		165
7.	CONCLUSÕES.....	171
7.1	Análises na Viga.....	171
7.2	Análises na Ponte Infante D. Henrique.....	174

7.3	Sugestões para trabalhos futuros .....	177
	REFERÊNCIAS BIBLIOGRÁFICAS.....	178
	APÊNDICES .....	187
	APÊNDICE A – Redes <i>Backpropagation</i> com as frequências de vibração da viga (RBFV) 188	
	APÊNDICE A.1 – LVQ com viga intacta .....	191
	APÊNDICE B – Resultado de análises feitas na ponte com o LVQ.....	193
	LVQ processado com as frequências obtidas nos períodos de 24h e 1 semana.	
	193	
	APÊNDICE B.1 – Resultado de análises feitas na ponte com o SOM .....	198
	Rede SOM processado com as frequências obtidas nos períodos de 24h e 1 semana.	
	198	

## LISTA DE FIGURAS

Figura 1.1 Esquema de um SHM.....	23
Figura 1.2 Benefício econômico do SHM. Chang (2002) apud Balageas, Fritzen e Guemes (2006) - adaptada.....	24
Figura 1.3 Análises realizadas. ....	29
Figura 2.1 Pontes que tiveram um SHM. (a) Golden Gate <i>Bridge</i> , Carder (1937); (b) San Francisco-Oakland Bay <i>Bridge</i> , Carder (1937); (c) Romeo <i>Bridge</i> , Huth <i>et. al</i> (2005).....	33
Figura 2.2 - (a) Cobertura do Estádio do Braga; (b) Ponte Infante D. Henrique. Magalhães (2010). ....	35
Figura 2.3 - (a) Passarela da FEUP; (b) Passarela Parque da Rabada, Santo Tirso. Caetano <i>et. al</i> (2016).....	36
Figura 2.4 – Vista da estrutura ASCE Fase II Dyke (2003).....	44
Figura 2.5 – Vista da ponte Meriden Jin <i>et. al</i> (2016). ....	50
Figura 3.1 (a) Neurônio humano; (b) Modelo do neurônio Booleano.....	55
Figura 3.2 Tipos de RNAs.....	55
Figura 3.3 Funções de Ativação. ....	56
Figura 3.4 Rede de uma única camada. Pádua <i>et. al</i> (2000) - adaptada. ....	57
Figura 3.5 Rede com Múltiplas Camadas (MLP). Pádua <i>et. al</i> (2000) - adaptada.....	58
Figura 3.6 Rede com Recorrência. Pádua <i>et. al</i> (2000) - adaptada.....	59
Figura 3.7 Rede Auto - associativa. Pádua <i>et. al</i> (2000) - adaptada.....	59
Figura 3.8 Representação gráfica da Rede MLP. Genovese (2005).....	62
Figura 3.9 Fases <i>forward</i> e <i>backward</i> do algoritmo backpropagation.....	63
Figura 3.10 - Estrutura de um SOM.....	68
Figura 3.11 - Estrutura do mapa de Kohonen com unidade vencedora. ....	68
Figura 3.12 Vetor vencedor. Haykin (2001) – Adaptada.....	70
Figura 3.13 - Função de vizinhança Gaussiana. ....	71
Figura 3.14 Representações das Etapas Competitiva e Cooperativa de treinamento do Som. -a- Configuração quadrada; - b - Configuração hexagonal (Vesanto, 2000), adaptado. ....	72
Figura 3.15 Esquema do LVQ.....	74
Figura 3.16 – Processo de aprendizagem da rede LVQ (Rocha,2012).....	76

Figura 4.1 – Etapas do algoritmo de uma RNA. ....	80
Figura 4.2 – Função <i>nntool</i> do pacote <i>Neural Network Toolbox</i> .....	81
Figura 4.3 Estrutura da função <i>Newff</i> .....	82
Figura 4.4 Funções <i>Init</i> e <i>Train</i> .....	82
Figura 4.5 Função <i>Sim</i> . ....	83
Figura 4.6 Função <i>lvqnet</i> .....	83
Figura 4.7 Função <i>selforgmap</i> .....	84
Figura 4.8 Gráfico <i>sample-hits</i> .....	84
Figura 4.9 Rotinas computacionais para obtenção das propriedades dinâmicas. ....	85
Figura 5.1 Viga estudada. (Modelo experimental (Brasiliano 2005). (b) Seção transversal dos elementos. (c) Esquema dos modelos numéricos. ....	87
Figura 5.2 - Modos de vibração do modelo numérico. ....	88
Figura 5.3 Esquema da construção dos modelos numéricos danificados. Em vermelho são as regiões com alturas reduziadas. ....	89
Figura 5.4 - Seção transversal dos elementos danificados. (a) h=38mm. (b) h=35mm. (c) h=30mm. (d) h=27mm. (e) h=25mm. (h = altura). ....	89
Figura 5.5 Discretização da viga. Brasiliano (2005).....	91
Figura 5.6 Seções transversais dos elementos. (a) Elemento intacto. (b) Elemento danificado. Brasiliano (2005). ....	91
Figura 5.7 Esquema de ensaio da viga. (a) Sistema completo. (b) Detalhe do apoio das vigas. (c) Detalhe dos acelerômetros. Brasiliano (2005). ....	92
Figura 5.8 Vista superior da viga, posições dos acelerômetros e ponto de aplicação do impacto. Brasiliano(2005) – Adaptada. ....	93
Figura 5.9 Modos de vibração da viga experimental. (Brasiliano, 2005). ....	94
Figura 5.10 Esquema de teste realizados com as redes <i>Backpropagation</i> e <i>LVQ</i> . ....	95
Figura 5.11 Arquitetura das RNAs <i>RBMV</i> . ....	99
Figura 5.12 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs ( <b>RBMV – modo 1</b> ). ....	101
Figura 5.13 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs ( <b>RBMV – modo 2</b> ). ....	103
Figura 5.14 Média e desvio padrão das amostras do primeiro modo de vibração. ....	104
Figura 5.15 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs ( <b>RBMV – modo 3</b> ). ....	106

Figura 5.16 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs ( <b>RBMV – modo 4</b> ). .....	108
Figura 5.17 Funções de ativação. (a) <i>Logsig</i> . (b) <i>Tansig</i> (Matlab, 2016). .....	108
Figura 5.18 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs ( <b>RBMV – modo 5</b> ). .....	110
Figura 5.19 Arquitetura das RNAs - RBFV. ....	112
Figura 5.20 Resultados das rede RBFV – em conjuntos das 5 frequências (Purelin). .	113
Figura 5.21 Resultados das rede RBFV – em conjuntos das 5 frequências (Tansig)..	114
Figura 5.22 Resultados das rede RBFV – em conjuntos das 5 frequências (Logsig)..	114
Figura 5.23 Arquitetura das RNAs RBFMV. ....	116
Figura 5.24 Resultados das rede RBFMV – Frequência e modo 1. ....	117
Figura 5.25 Resultados das rede RBFMV – Frequência e modo 2. ....	119
Figura 5.26 Resultados das rede RBFMV – Frequência e modo 3. ....	120
Figura 5.27 Resultados das rede RBFMV – Frequência e modo 4. ....	121
Figura 5.28 Resultados das rede RBFMV – Frequência e modo 5. ....	122
Figura 5.29 Arquitetura LVQ. ....	126
Figura 5.30 Saídas do LVQ - MV. ....	127
Figura 5.31 LVQ – MV – rede 1. ....	128
Figura 5.32 LVQ – MV – rede 2. ....	128
Figura 5.33 LVQ – MV – rede 3. ....	128
Figura 5.34 LVQ – MV – rede 4. ....	129
Figura 5.35 LVQ – MV – rede 5. ....	129
Figura 5.36 Arquitetura LVQ – FV. ....	131
Figura 5.37 LVQ – FV. ....	132
Figura 5.38 Arquitetura LVQ – MFV. ....	133
Figura 5.39 LVQ – MFV 1. ....	133
Figura 5.40 LVQ – MFV 2. ....	134
Figura 5.41 LVQ – MFV 3. ....	134
Figura 5.42 LVQ – MFV 4. ....	135
Figura 5.43 LVQ – MFV 5. ....	135
Figura 6.1 Ponte Infante Dom Henrique (Magalhães, 2010). ....	139
Figura 6.2 Dimensões gerais da ponte Infante Dom Henrique (Adão da Fonseca e Millanes Mato, 2005). ....	140

Figura 6.3 - Instrumentação da ponte para teste de vibração ambiental (Magalhães,2010). .....	141
Figura 6.4 Frequências e modos de vibração da ponte. (Magalhães 2010). .....	141
Figura 6.5 Esquema do sistema de monitoramento. (Magalhães 2010 - adaptada). ....	143
Figura 6.6 Evolução temporal da média diária das primeiras 12 frequências naturais da ponte de 13/09/2007 até 12/09/2009.....	143
Figura 6.7 Frequências e modos de vibração do modelo numérico da ponte. (Magalhães 2010) - Adaptada. ....	145
Figura 6.8 Localização e extensão dos cenários de danos simulados (Magalhães, 2010). .....	146
Figura 6.9 Porcentagem de variação das frequências naturais de vibração dos modos de flexão vertical (Magalhães, Cunha e Caetano, 2014). .....	147
Figura 6.10 Esquema de teste realizados com as rede SOM e LVQ. ....	149
Figura 6.11 Frequências utilizadas no LVQ.....	150
Figura 6.12 Cenários danificados do modelo da ponte.....	151
Figura 6.13 Sobreposição das frequências utilizadas no estudo.....	152
Figura 6.14 Arquitetura da rede LVQ.....	154
Figura 6.15 (a) Análises realizadas LVQ. ....	155
Figura 6.16 Resultados obtidos na análise 1 - LVQ. ....	156
Figura 6.17 Resultados obtidos na análise 2 (1) - LVQ.....	157
Figura 6.18 Resultados obtidos na análise 2 (2) - LVQ.....	158
Figura 6.19 Resultados obtidos na análise 2 (3) - LVQ.....	159
Figura 6.20 Resultados obtidos na análise 2 (4) - LVQ.....	159
Figura 6.21 Organização dos dados. ....	162
Figura 6.22 Frequências utilizadas no SOM. ....	162
Figura 6.23 Análises realizadas com as redes SOM.....	163
Figura 6.24 (a) Treinamento do SOM (b) Teste do SOM – análise 1 – 1 mês.....	165
Figura 6.25 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 1) – 1 mês. ....	166
Figura 6.26 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 2) – 1 mês. ....	167
Figura 6.27 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 3) – 1 mês. ....	168

Figura 6.28 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 4) – 1 mês. .....	169
---	-----

## Apêndices

### A:

A 1 RNAs formadas com a primeira frequência. ....	188
A 2 RNAs formadas com a segunda frequência. ....	189
A 3 RNAs formadas com a terceira frequência. ....	190

### A1:

A1 1Localização de dano em uma viga intacata. (Modo 1 e modo 2 como dados de entrada). ....	191
A1 2Localização de dano em uma viga intacata. (Modos e frequências 1 e 2 como dados de entrada). ....	192

### B:

B 1. Resultados obtidos na análise 1 – LVQ (24h). ....	193
B 2. Resultados obtidos na análise 2 (1) – LVQ (24h). ....	194
B 3. Resultados obtidos na análise 2 (2) – LVQ (24h). ....	194
B 4. Resultados obtidos na análise 2 (3) – LVQ (24h). ....	195
B 5. Resultados obtidos na análise 2 (4) – LVQ (24h). ....	195
B 6. Resultados obtidos na análise 1 – LVQ (1 semana). ....	196
B 7. Resultados obtidos na análise 2 (3) – LVQ (1 semana). ....	197
B 8. Resultados obtidos na análise 2 (4) – LVQ (1 semana). ....	197

### B1:

B1 1(a)Treinamento do SOM (b) Teste do SOM– análise 1 – 24h. ....	198
B1 2(a)Treinamento do SOM (b) Teste do SOM– análise 1 –1 semana. ....	198
B1 3(a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 1) – 24 horas. .	199
B1 4(a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 2) – 24 horas. .	199
B1 5(a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 3) – 24 horas. .	200
B1 6(a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 4) – 24 horas. .	200

B1 7 (a) Treinamento do SOM. (b). Teste do SOM – análise 2 (cenário 1) – 1 semana. .....	201
B1 8 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 2) – 1 semana. .....	201
B1 9 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 3) – 1 semana. .....	202
B1 10 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 4) – 1 semana. .....	202

## LISTA DE TABELAS

Tabela 5.1 Propriedades das vigas. ....	87
Tabela 5.2 Frequências do modelo numérico intacto. ....	88
Tabela 5.3 Cenários de danos utilizados nos treinamentos das RNAs. ....	90
Tabela 5.4 Posição dos acelerômetros em cada etapa.....	93
Tabela 5.5 Frequências naturais de vibração.....	93
Tabela 5.6 Testes realizados com as RNAs Backpropagation e LVQ. ....	96
Tabela 5.7 Estimativas do número ideal de neurônios na camada intermediária. Sheela e Deepa (2013).....	97
Tabela 5.8 Variações da RBMV. ....	98
Tabela 5.9 Parâmetros de treinamento das redes 1. ....	100
Tabela 5.10 Parâmetros de treinamento das redes 2. ....	102
Tabela 5.11 Parâmetros de treinamento das redes 3. ....	105
Tabela 5.12 Parâmetros de treinamento das redes 4. ....	107
Tabela 5.13 Parâmetros de treinamento das redes 5. ....	109
Tabela 5.14 Variações das RBFV.....	112
Tabela 5.15 Variações das RBFMV. ....	116
Tabela 6.1 Frequências naturais (Hz) dos modelos experimental e numérico. ....	145
Tabela 6.2 Frequências naturais (Hz) obtidas para cada um dos cenários danificados D1, D2, D3 e D4.....	146
Tabela 6.3 $\Delta freq$ de cada uma das frequências, em cada cenário de dano. ....	148
Tabela 6.4 Análises feitas com LVQ. ....	154

## LISTA DE ABREVIÇÕES SÍMBOLOS E NOMECLATURAS

AG	Algoritmos Genéticos
AT	Algoritmo de Treinamento
FRF	<i>Frequency Response Function</i> - Resposta em função de frequência
LVQ	<i>Learning Vector Quantization</i>
LVQ-MV	Redes LVQ com modos de vibração
LVQ-FV	Redes LVQ com as frequências vibração
LVQ-MFV	Redes LVQ com os modos e as frequências vibração
MER	Método do Erro Residual
MLP	Rede Perceptron de Múltiplas Camadas
NNC	Número de Neurônios da Camada
RBMV	Redes Backpropagation com modos de vibração
RBF	Redes Backpropagation com as frequências de vibração
RBFMV	Redes Backpropagation com as frequências e os modos de vibração
RNAs	Redes Neurais Artificiais
SHM	<i>Structural Health Monitorig</i> – Monitoramento da saúde estrutural
SOM	<i>Self Organizing Maps</i>
A	Área da seção transversal
E	Módulo de elasticidade longitudinal
$E^2$	Erro quadrático de todos os neurônios
<b>E</b>	Matriz de erros da equação de movimento da estrutura
<b>F</b>	Força excitadora do sistema
<b>FT</b>	Função de ativação
<b>H</b>	Matriz Hessiana
L	Comprimento do elemento
<b>K</b>	Matriz de rigidez da estrutura
<b>C</b>	Matriz de amortecimento da estrutura
<b>K<sub>EI</sub></b>	Matriz de rigidez de elementos intactos
<b><math>\Lambda</math></b>	Matriz diagonal com as frequências de vibração da estrutura danificada
L	Função de ativação Logsig
<b>M</b>	Matriz de massa da estrutura
P	Função de ativação Purelin

<b>S</b>	Matriz com dados de saída
<b>T</b>	Função de ativação Tansig
$N_e$	Número de neurônios na camada de entrada da RNA
$N_i$	Número de neurônios na camada intermediária da RNA
$N_Y$	Número de neurônios na camada de saída da RNA
$N_{nci}$	Número de neurônios na camada intermediária
$N_{var,pd}$	Número de variáveis em um padrão de entrada
$N_{atr}$	Número de amostras disponíveis para o treinamento
<b>Y</b>	Resposta da RNA
$X_k$	Dado de entrada da rede
$\alpha_{jk}$	Pesos entre as camadas de entrada e intermediária da RNA
$\sigma_j$	Neurônios da camada intermediária da RNA
$\mu$	Coefficiente para melhor convergência da RNA
$\ddot{\mathbf{y}}$	Vetor aceleração
$\mathbf{y}$	Vetor deslocamento
$\dot{\mathbf{y}}$	Vetor velocidade
$\hat{\mathbf{y}}$	Forma de movimento (modo de vibração)
$(t)$	Tempo
$\Phi$	Matriz com os modos de vibração da estrutura
$\Phi'$	Matriz com os modos de vibração da estrutura danificada
$\phi$	Modo de vibração
$i$	Neurônio vencedor
$h_{j,i}$	Vizinhança topológica
$d_{i,j}$	Distância entre neurônios do SOM
$t$	Número de padrões de entrada para uma RNA
$m$	Número de variáveis em um padrão de entrada
$j$	Número de um neurônio
$l$	Número de neurônios de uma grade do SOM
$\sigma$	Largura da vizinhança topológica do SOM
$\varphi$	Peso de uma camada
$\nabla E$	Gradiente do da função erro
$\theta$	Ângulo de fase

$\omega_{ij}$	Pesos entre a camada intermediária e camada de saída da RNA
$\omega$	Frequência natural de vibração
<i>Init</i>	Função para iniciação da RNA no MATLAB
<i>Newff</i>	Função para criação da rede no MATLAB
<i>Sim</i>	Função para simulação da rede no MATLAB
<i>Train</i>	Função para treinamento da RNA no MATLAB
<i>Lvqnet</i>	Função para início de uma rede LVQ no MATLAB

## 1. INTRODUÇÃO

Durante a vida útil as estruturas sofrem solicitações, desgastes, deteriorações e outros processos que podem causar fissuração, de forma a comprometer seu funcionamento, ou, até mesmo, ser a causa de seu colapso estrutural.

Somado a esses fatores, o crescente número de estruturas muito esbeltas, conseqüentemente mais susceptíveis a vibrações excessivas, bem como a preocupação com o desempenho e a degradação de estruturas antigas, têm impulsionado o estudo e o desenvolvimento de novas técnicas capazes de realizar um acompanhamento contínuo da saúde estrutural das construções.

Neste sentido, ferramentas com a capacidade de captar e interpretar confiável e rapidamente as respostas de estruturas de médio e grande porte tornam-se essenciais para complementar um sistema de monitoramento da saúde estrutural (*Structural Health Monitorig – SHM*), podendo este ser definido de diversas formas.

Wenzel (2009) define o SHM, no contexto da engenharia civil, como a implementação de uma estratégia de identificação de danos na estrutura, estes últimos caracterizados por alterações no material e / ou propriedades geométricas do sistema, incluindo mudanças nas condições de contorno e conectividades.

Já para Magalhães (2010), o SHM consiste na combinação de equipamentos para determinar ações e respostas estruturais permanentemente com ferramentas de processamento dos dados e detecção de danos, permitindo a avaliação da estrutura instrumentada.

De maneira mais global, Fiedmann e Kraemer (2016) afirmam que o monitoramento envolve desde a combinação de sensores para a aquisição, transmissão e capacidade de processamento dos dados, até algoritmos capazes de indicar alterações no objeto monitorado, finalizando com tomada de decisões, quando necessárias.

Existem diversas maneiras de monitorar uma estrutura, desde inspeções *in loco* até o acompanhamento por meio das respostas dinâmicas, passando pelos métodos de detecção de danos propriamente ditos. Anteriormente, os mais utilizados eram aqueles baseados no uso de raios-X, ultrassom e ressonância magnética, no entanto, por se

tratarem de métodos de avaliação local, necessitam de uma estimativa prévia do local do dano, além de uma significativa demanda de tempo para sua aplicação (Bandara, 2013).

Neste contexto, tendo em vista os avanços ocorridos na área de processamento computacional, bem como o aperfeiçoamento de sistemas de aquisição de dados e o desenvolvimento de sensores cada vez mais precisos, foi possível criar abordagens mais globais para o monitoramento estrutural.

Estas abordagens são fundamentadas nas vibrações estruturais e partem do princípio de que as características dinâmicas (frequências naturais, modos de vibração e razão de amortecimento), que são propriedades intrínsecas da estrutura, sofrem alterações em função da situação física e geométrica.

Deste modo, um SHM pode ser representado, esquematicamente, por meio da Figura 1.1. É possível observar que, a partir do monitoramento (com todos os pormenores da instrumentação da estrutura, isto é, sensores, ferramentas de transmissão de dados, etc.) gera-se um banco de dados, sendo possível comparar as respostas estruturais, analisá-las com vistas à detecção de danos, construir diagnósticos e, com base nestes, definir ações (prognósticos) para a estrutura. Estas últimas, variando desde a necessidade de reparos, evitando maiores danos, até uma interdição da edificação.

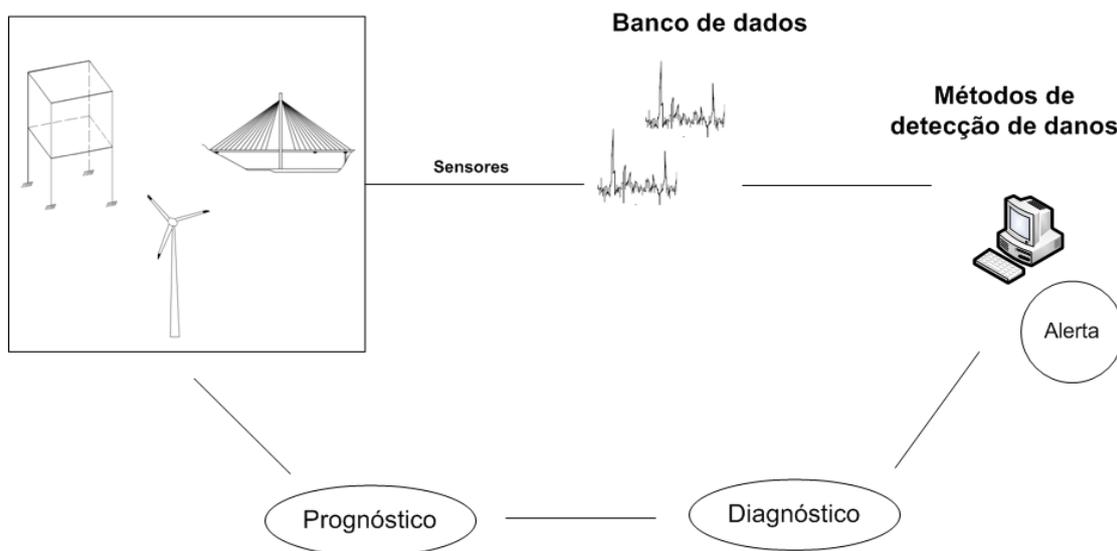


Figura 1.1 Esquema de um SHM.

Além dos fatores citados, o desenvolvimento de um bom SHM tem motivações sociais e econômicas. Annamdas e Soh (2016) afirmam que o SHM pode não ser o objetivo principal em países onde as necessidades básicas ainda não são garantidas; mas é uma metodologia crucial para países em desenvolvimento, sobretudo em cidades muito populosas, nas quais uma falha estrutural possa prejudicar uma sociedade e o seu desenvolvimento econômico.

Para Chang (2002) *apud* Balageas, Fritzen e Guemes (2006), uma estrutura com SHM tende a ser confiável no que diz respeito a sua integridade, além de gerar custos constantes de manutenção. Já nos casos de estruturas nas quais não são adotados sistemas capazes de acompanhar o seu funcionamento, não existem custos relacionados à implementação de um SHM, contudo, tendem a apresentar significativos aumentos no custo da manutenção (quando necessária), além da redução da sua confiabilidade, conforme se observa na Figura 1.2.

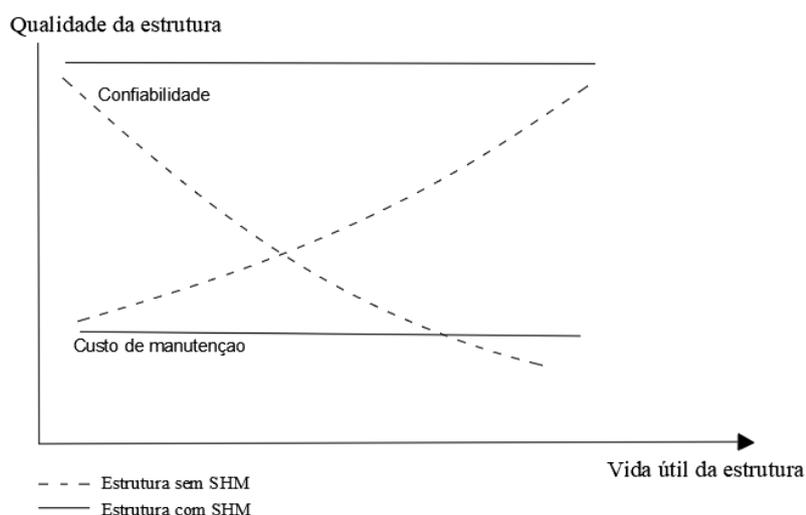


Figura 1.2 Benefício econômico do SHM. Chang (2002) *apud* Balageas, Fritzen e Guemes (2006) - adaptada.

Como mencionado, um SHM também é composto de metodologias capazes de detectar, localizar e/ou quantificar regiões danificadas na estrutura. Deste modo, Lee (2004) propôs 4 grandes grupos para dividir os métodos de detecção de danos existentes, dentre os quais estão:

- Grupo dos parâmetros modais → neste grupo estão os métodos que utilizam as frequências e os modos naturais de vibração, cujas metodologias estão

baseadas nas variações das frequências, modos de vibração, derivadas do modo de vibração e na energia de deformação modal.

- Grupo dos métodos das matrizes → métodos que utilizam as matrizes de rigidez e flexibilidade, cujas metodologias são baseadas nas técnicas de atualização e otimização de modelos.
- Grupo dos métodos de aprendizado de máquina → métodos que utilizam Algoritmos Genéticos (AG) e Redes Neurais Artificiais (RNAs), baseando-se na otimização de parâmetros de rigidez, minimização de funções objetivas e treinamento de sistemas inteligentes.
- Outras técnicas → Métodos que utilizam a avaliação da FRF (*Frequency Response Function*) e a análise de séries temporais.

Além da divisão dos tipos de métodos, Rytter (1993) classificou a detecção de danos em quatro categorias, dependendo do objetivo da aplicação, dentre as quais estão:

- 1 Determinação de alterações que indicam presença de danos;
- 2 Determinação de uma possível localização de danos;
- 3 Determinação da extensão do dano e, por fim,
- 4 Uma estimativa da vida útil da estrutura.

No entanto, ainda não existe uma técnica de SHM aplicável a todas as estruturas e que aborde todas as questões. Deste modo, tendo em vista as limitações, vantagens e desvantagens de alguns métodos em relação à aplicação em alguns tipos de estruturas, busca-se, cada vez mais, aprofundar as pesquisas com vistas ao desenvolvimento e aprimoramento de meios que permitam realizar o monitoramento nas mais diversas formas estruturais.

Nos últimos anos, parte da comunidade científica vem adotando a detecção de danos como um problema de reconhecimento de padrões, no qual uma classificação é realizada em função de parâmetros afetados por uma mudança nas propriedades físicas de um sistema.

Nesta perspectiva, pode-se citar a existência de ferramentas que, ao serem trabalhadas em conjunto com as propriedades dinâmicas, tornam-se métodos eficientes na detecção de danos, como é o caso das Redes Neurais Artificiais (RNAs) nas suas

mais diversas maneiras de processamento (*Backpropagation*, *Self Organizing Maps* (SOM), *Learning Vector Quantization* (LVQ), etc.).

No entanto, por se tratarem de técnicas estritamente matemáticas, para o seu melhor desempenho, faz-se necessário o uso dos parâmetros dinâmicos mais adequados, isto é, dados que possam fornecer a situação real da estrutura, para serem processados pelas referidas técnicas, de modo a indicar a presença de falhas estruturais.

Para Ahmed (2016), as RNAs aplicadas no contexto da detecção de danos, podem proporcionar várias vantagens, dentre as quais estão:

- Diferentes parâmetros de vibração podem ser utilizados como dados de entrada para RNAs, resultando, portanto, em uma liberdade na escolha das entradas e saídas, sem representar complexidade aos algoritmos de treinamento;
- A RNA apresenta tolerância razoável ao ruído, o que representa uma vantagem, sobretudo, quando processada com dados experimentais;
- O processamento da RNA é comparativamente rápido e não há necessidade de ser remodelado ou reconstruído para nova utilização, desde que tenha adquirido bons resultados durante o treinamento.

O principal desafio dessa técnica é o fato que, de maneira geral, no contexto da detecção de danos, a RNA necessita de dados das estruturas intacta e danificada para ser capaz de treinar satisfatoriamente e, posteriormente, ser capaz de classificar a estrutura nas duas principais classes já mencionadas.

No entanto, se a estrutura é considerada não danificada em seu estado atual, as informações da classe danificada estarão indisponíveis, a menos que alguns modelos estruturais detalhados como, por exemplo, modelos baseados no Método de Elementos Finitos (MEF), possam ser usados para gerar tais informações.

Segundo Bandara (2013) em sua tese, os dados utilizados para treinar a rede são dependentes das estruturas e podem ser obtidos à medida que surgem danos na estrutura real. No entanto, esta é uma abordagem bastante demorada e/ou onerosa, apresentando, ainda, incertezas e dificuldades para a sua implementação.

Deste modo, o autor afirma que a geração analítica ou numérica de amostras de treinamento através de um modelo matemático da estrutura a ser monitorada é uma

alternativa lógica, atrativa e aceitável, desde que as redes neurais possam fornecer um diagnóstico correto baseado nessas amostras de treinamento.

Nesta perspectiva, este trabalho tem foco no aperfeiçoamento de métodos de detecção e localização de danos, utilizando para isso a técnica de Redes Neurais Artificiais (RNAs) como ferramenta de aplicação, tendo um banco de dados numérico e experimental como entrada para as fases de treinamentos e testes das RNAs, respectivamente. Dessa forma, se insere nos primeiro e terceiro grupos de métodos definidos por Lee (2004), e nas categorias 1 e 2, segundo os níveis de detecção de danos definidos por Rytter (1993).

## **1.1 Objetivos**

Este trabalho tem como principal objetivo desenvolver uma metodologia baseada no uso das propriedades dinâmicas e das Redes Neurais Artificiais (RNAs) para a detecção e localização de danos em estruturas.

## **1.2 Metodologia**

No decorrer deste trabalho são criadas diversas redes neurais artificiais tendentes a identificar alterações na integridade de uma estrutura. Essas redes são utilizadas em duas análises principais, sendo a primeira em uma viga controlada em laboratório e, portanto, uma estrutura mais simples para que pudesse ser feito um primeiro teste da ferramenta. Já a segunda análise corresponde à aplicação da metodologia a uma estrutura mais complexa, uma ponte localizada em Portugal, a ponte Infante D. Henrique.

Para as duas análises são utilizados dados das estruturas, de caráter numérico e experimental, a fim de se obter parâmetros dinâmicos que contenham informações que traduzam o estado da estrutura, e, portanto, que possam ser usados como “alimentação” do método de identificação de danos, citado acima.

Considerando que as RNAs necessitam passar por uma fase de treinamento para desempenhar uma das suas principais funções, o reconhecimento de padrões, neste

trabalho é realizado um levantamento e mapeamento dos dados estruturais que possam, em conjunto com as RNAs, indicar a real situação de uma estrutura de maneira mais eficiente. Deste modo, o treinamento consiste no processamento de um conjunto de dados (entrada + saída) de modo que a ferramenta possa estabelecer uma relação entre entradas e saídas.

Na busca de uma RNA mais eficiente, a formação e o treinamento das redes apresentam variações nos seguintes aspectos:

- 1 – Tipos de dados dinâmicos como entrada (modos de vibração e frequências);
- 2 – Diferentes cenários de danos, isto é, falhas estruturais com diferentes severidades e posições.
- 3 – Diferentes arquiteturas da rede: número de neurônios na camada intermediária e funções de ativação.
- 4 – Diferentes Tipos de RNAs, podendo ser do tipo *Backpropagation (MLP)*, *Learning Vector Quantization(LVQ)* e *Self Organizing Maps(SOM)*.

Essas variações são testadas de maneira individual e combinada. No primeiro caso, as redes são processadas com cada uma das condições mostradas nos tópicos de 1 a 3, uma por uma, de modo que um dos tópicos será variado e os outros parâmetros permanecerão constantes.

Os testes combinados são realizados da mesma maneira do caso anterior, no entanto, as variações do tópico 1 são realizadas por meio de combinação de dados, isto é, a rede recebe como padrão mais de um tipo de dado, como por exemplo: frequências + modos de vibração (**Erro! Fonte de referência não encontrada.**).

A partir dos resultados obtidos no treinamento, os conjuntos de dados são analisados e avaliados quanto à sensibilidade na presença de danos estruturais e, assim, é iniciada a fase de testes com a formação de diferentes RNAs, na qual serão fornecidos dados ainda desconhecidos do sistema, isto é, informação para quais se deseja uma solução.

Após todos os testes das redes, são escolhidas as melhores performances, de modo a selecionar a/as metodologias mais eficientes para identificar, localizar e quantificar os danos estruturais.

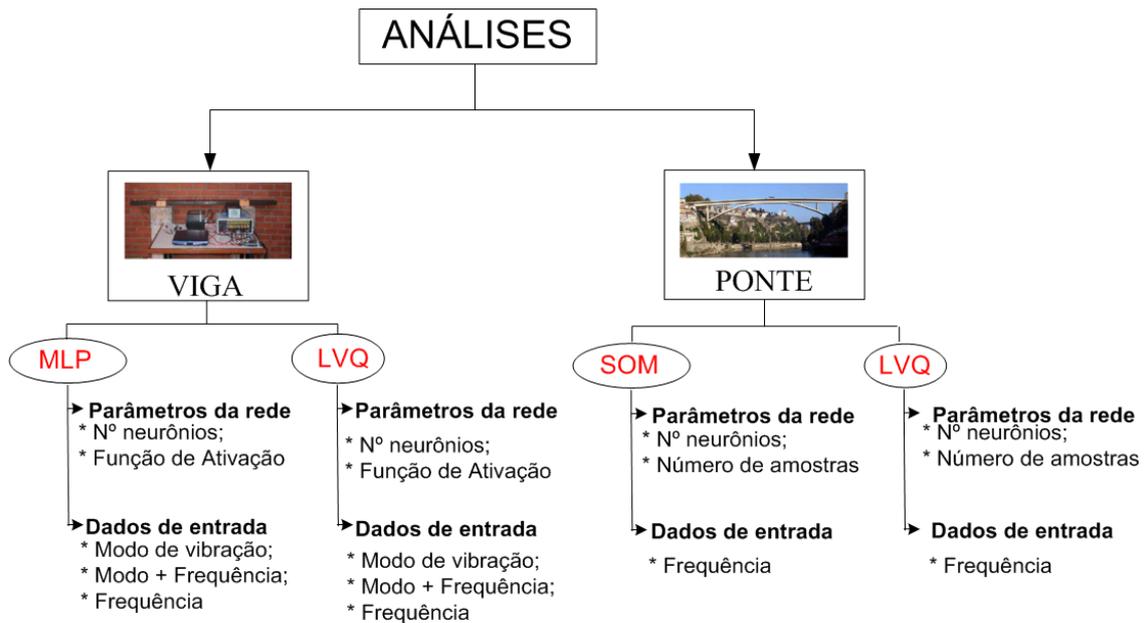


Figura 1.3 Análises realizadas.

O trabalho é realizado com o auxílio do *software* Matlab (2015), uma vez que o mesmo contém um pacote destinado ao uso de Redes Neurais Artificiais em suas mais diversas formas de processamento, seja no algoritmo de treinamento ou na arquitetura da rede.

### 1.3 Organização da tese

Este trabalho está desenvolvido ao decorrer de 7 capítulos sendo este o primeiro, no qual apresenta-se um contexto geral do tema, bem como a sua importância no cenário da engenharia estrutural e a justificativa de estar sendo estudado. Além disso, são pontuados os objetivos e a metodologia utilizada na pesquisa.

O segundo capítulo é composto de uma revisão bibliográfica geral acerca do assunto de sistemas de monitoramento estrutural (SHM), seguido de um levantamento das pesquisas que utilizaram a técnica de RNAs na composição de um SHM.

No terceiro capítulo são descritas as formulações e toda a teoria utilizada para o desenvolvimento das técnicas utilizadas no trabalho. É apresentada uma pequena fundamentação teórica a respeito da dinâmica estrutural, especificamente, a abordagem

relativa à obtenção das características dinâmicas de um sistema com vários graus de liberdade. O capítulo contém, ainda, a teoria e os algoritmos correspondentes aos três tipos de redes neurais artificiais aplicadas nesta pesquisa (*Backpropagation, Self Organizing Maps e Learning Vector Quantization*).

Considerando que o trabalho tem uma abordagem numérica, o capítulo 4 descreve as ferramentas computacionais utilizadas ao longo da pesquisa.

Os capítulos 5 e 6, os mais extensos da tese, descrevem todas as análises realizadas no modelo experimental de uma viga metálica e as análises feitas na ponte Infante D. Henrique, respectivamente. Em cada capítulo é mostrada a avaliação da aplicação dos tipos de redes neurais artificiais estudadas, sob diferentes configurações.

Por fim, o sétimo capítulo contém as considerações finais acerca do estudo desenvolvido. Em sequência sugerem-se alguns tópicos relevantes a serem tratados em trabalhos futuros, finalizando com as principais referências bibliográficas utilizadas no desenvolvimento da pesquisa.

## 2. REVISÃO BIBLIOGRÁFICA

A importância que vem sendo dada ao monitoramento das construções, tanto no que se refere à preocupação com a degradação delas, como também ao conhecimento do comportamento de estruturas mais complexas, têm levado a um maior desenvolvimento do tema nas mais diversas áreas da engenharia civil, marinha, aeroespacial e aeronáutica.

Deste modo, considerando o escopo do trabalho, foi realizado um levantamento de alguns trabalhos no campo do SHM (*Structural Health Monitoring*), e, de maneira mais específica, utilizando as Redes Neurais Artificiais (RNAs) como parte integrante de um sistema de monitoramento estrutural.

### 2.1 Monitoramento estrutural

Muitos pesquisadores vêm estudando, desenvolvendo e aprimorando métodos e ferramentas com vistas ao sistema de monitoramento estrutural (*Structural Health Monitorig* – SHM). Em um contexto histórico, os primeiros sistemas de monitoramento instalados foram os das pontes Golden Gate bridge e San Francisco-Oakland Bay Bridge, Carder (1937) - Figura 2.1 (a e b), segundo Benzoni e Lomiento (2013).

Muitos trabalhos, teorias e conclusões foram e estão sendo usados como base teórica de métodos da atualidade como, por exemplo, Adams (1978), ao afirmar que as características dinâmicas apresentam variações em função da rigidez da estrutura, uma vez que a presença de danos não altera significativamente a sua massa.

Allemang e Brown (1982) e Lieven & Ewins (1988), Pandey (1991) desenvolveram métodos baseados nas diferenças que surgem entre os modos de vibração das estruturas intacta e danificada, os conhecidos índices MAC (*Modal Assurance Criterion*) e COMAC (*Coordinate Modal Assurance Criterion*) e o método da curvatura, respectivamente. Além destes, podem-se citar Hearn e Testa (1991), Wu (1992), Chen (1995) entre tantos outros que contribuíram no desenvolvimento do tema.

Em abordagens mais recentes podem-se citar: Genovese (2000), que propôs o Método do Erro Residual (MER), o qual é capaz de avaliar a integridade estrutural

observando as variações das frequências e de seus respectivos modos de vibração sofridas por vigas que continham danos. Posteriormente, o método foi aprimorado por Brasiliano, Doz e Brito (2004), e por Marcy (2013) a fim de aplicá-lo em pórticos planos e espaciais, respectivamente. Em todos os estudos o MER apresentou um desempenho desejável, uma vez que este foi capaz de localizar e quantificar danos nos modelos estruturais.

Huth *et. al* (2005) analisaram, no contexto da dinâmica estrutural, a sensibilidade de diferentes métodos de detecção, localização e quantificação de danos aplicados a uma ponte de concreto protendido de 40 anos, já apresentando rachaduras, porém com os devidos reparos (ponte Romeo, na Suíça - Figura 2.1 (c)). Antes dos dois cenários de danos feitos por meio de macacos hidráulicos e carregamentos seguidos de descarregamentos, foi realizado um monitoramento contínuo da estrutura durante 8 meses, o que permitiu os autores observarem que, na presença de danos, os modos de vibração apresentavam maiores variações do que as observadas nas frequências.

Além disso, notaram ainda que as frequências apresentaram significativas variações em função da temperatura, inclusive quando comparadas àquelas causadas pela presença de danos. Deste modo, para a detecção de dano, foi proposta uma formulação baseada nas variações apresentadas pelos modos de vibração para a detecção de danos da referida estrutura, esta última denominada de índice de área do modo de vibração (*Mode Shape Area Index*).

Os resultados obtidos permitiram concluir que a detecção de danos por meio da observação do modo de vibração apresentou maior sensibilidade quando comparado ao uso das frequências. No entanto, os autores apontaram para a protensão como causa para a pouca capacidade em detectar, localizar e/ou quantificar danos em estados iniciais da referida estrutura.



(a)



(b)



(c)

Figura 2.1 Pontes que tiveram um SHM. (a) *Golden Gate Bridge*, Carder (1937); (b) *San Francisco-Oakland Bay Bridge*, Carder (1937); (c) *Romeo Bridge*, Huth *et. al* (2005).

Beskyroun (2006) propuseram uma técnica de identificação e localização de danos baseada nas alterações da curvatura e na Densidade Espectral de Potência (PSD – *Power Spectral Density*). Para a validação da técnica foram criados dois modelos em escala reduzida, uma ponte e um pórtico em aço com diferentes cenários de danos, os quais foram simulados pela retirada de parafusos. A partir dos resultados experimentais, pôde-se observar que a técnica apresentou bons resultados, ou seja, identificou e localizou de forma precisa os elementos que continham anomalias.

Kunert e Ambrosini (2007) apresentaram um método capaz de identificar danos estruturais através da variação de frequência entre a estrutura intacta e danificada. O método consiste em variar o módulo de elasticidade do material da estrutura, por meio de três equações. Essas funções são usadas como meio de simular o dano estrutural, de tal forma que, a partir de um fator multiplicativo, o referido módulo varia

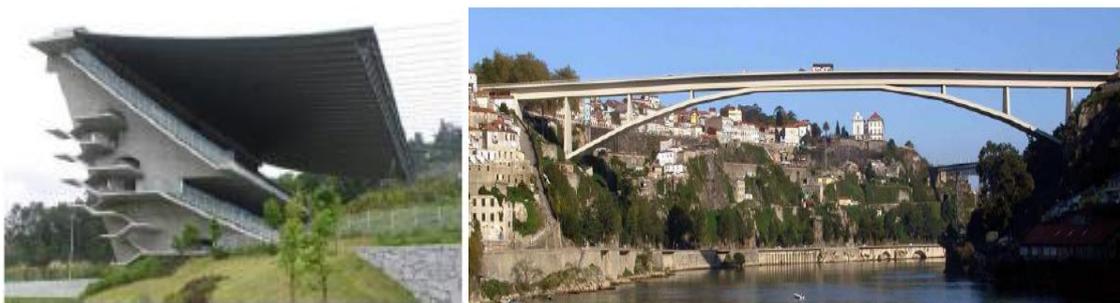
quantitativamente representando, portanto, a variação na rigidez dos elementos, causando, conseqüentemente, alterações nas propriedades dinâmicas da estrutura. A técnica foi testada numericamente por meio de modelos de vigas e apresentou bons resultados.

Curandelli *et. al* (2008) apresentaram um método de identificação de danos por meio da identificação do coeficiente de amortecimento usando transformada de *Wavelet*. Foram realizados estudos numéricos em um pórtico e experimentais em uma viga de concreto e em um pórtico tridimensional de alumínio, os quais indicaram que o amortecimento também pode ser utilizado como indicador da presença de danos estruturais.

Magalhães (2010) aplicou e desenvolveu técnicas e rotinas para obter estimativas precisas de parâmetros modais a partir de dados de ensaios de vibração ambiental em estruturas de grande porte, além de realizar o processamento on-line de dados registrados de maneira contínua. As ferramentas foram testadas na cobertura do estádio do Braga (Figura 2.2 (a)) e na Ponte Infante D. Henrique (Figura 2.2 (b)), ambas as estruturas localizadas em Portugal.

Com as rotinas em funcionamento, o autor ainda desenvolveu um método para detectar danos a partir das variações das 12 primeiras frequências obtidas por meio de registros feitos a cada 30 minutos, durante um ano de monitoramento. Como a ponte não apresentava anomalias em sua estrutura, para validar a técnica foram utilizados quatro modelos desenvolvidos numericamente.

A partir dos resultados, foi possível verificar que as rotinas desenvolvidas apresentaram um funcionamento eficaz, sendo capazes de estimar as características dinâmicas da estrutura a cada meia hora, permitindo, portanto, um acompanhamento regular do desempenho da ponte. Além desta contribuição para o tema de SHM, o método para detecção de danos funcionou satisfatoriamente, apresentando boa sensibilidade à presença de anomalias estruturais.



(a)

(b)

Figura 2.2 - (a) Cobertura do Estádio do Braga; (b) Ponte Infante D. Henrique. Magalhães (2010).

Bonéssio, Lomiento e Benzoni (2011) propõem uma metodologia para identificação de danos em ponte equipadas com isoladores e/ou dispositivos de dissipação de energia. Por meio de índices de localização, severidade de falhas e, baseado nas mudanças nas características modais da resposta da estrutura, o método faz uma avaliação do desempenho de componentes estruturais convencionais, bem como dos isoladores e dissipadores de energia. Neste caso (monitoramento do dispositivo), o método oferece a obtenção do índice de severidade baseado na interpretação das quantidades físicas, estas últimas diretamente associadas às características de desempenho dos dispositivos.

Para validar a técnica, os autores desenvolveram dois modelos numéricos: o primeiro foi uma viga contínua simples, com 10 diferentes cenários de danos. Estes foram simulados por meio da redução do módulo de elasticidade do material dos elementos, considerando diferentes posições e proporções.

O segundo caso de aplicação do método foi em uma ponte com 4 vãos de, no máximo, 12 m em sua superestrutura, equipada com dispositivos de pêndulo de fricção, modelada como estrutura bidimensional por meio de elementos finitos, a fim de obter respostas estruturais dos modelos intacto e danificados desenvolvidos. Os resultados obtidos indicaram a técnica como viável para implementação em estruturas reais, com a vantagem de fornecer indicadores diretos dos estágios iniciais de degradação dos parâmetros de desempenho.

Costa *et al.* (2013) realizaram testes dinâmicos em uma ponte de aço a fim de analisar as variações das propriedades dinâmicas antes e depois da sua reabilitação. Na análise foram também utilizados modelos numéricos da ponte, o que permitiu, em uma comparação com resultados da estrutura, obter boas estimativas nos parâmetros modais após um melhoramento da ponte, bem como propor e avaliar soluções de reabilitação empregadas na estrutura.

Caetano *et. al* (2016) implementaram dois sistemas de monitoramento estrutural em duas passarelas localizadas em Portugal, uma na Universidade do Porto (FEUP) e a segunda em Santo Tirso (Figura 2.3 (a) e (b), respectivamente). Os sensores instalados objetivaram caracterizar os níveis de vibração nas estruturas, uma vez que estas são de uso de pedestres e, portanto, mais sensíveis no que diz respeito aos níveis de conforto. Além do primeiro objetivo, os autores buscaram detectar danos e verificar o desempenho de amortecedores TMDs instalados na segunda ponte.

Com base nas avaliações realizadas, foi possível observar a importância do monitoramento em estruturas que estão em uso, bem como analisar os efeitos ambientais e operacionais na caracterização das vibrações e os efeitos de danos estruturais das edificações.



Figura 2.3 - (a) Passarela da FEUP; (b) Passarela Parque da Rabada, Santo Tirso. Caetano *et. al* (2016).

Comanduci *et. al* (2016) realizaram um estudo sobre a capacidade de detecção de danos em pontes por meio de seis técnicas estatísticas baseadas em modelos dinâmicos de regressão, análise de componentes principais lineares e locais, bem como um método proposto baseado na combinação de regressões lineares múltiplas dinâmicas. O estudo foi realizado em uma ponte em arco e, para isso, utilizaram as doze primeiras frequências e os respectivos modos de vibração, obtidos durante dois anos de

monitoramento contínuo. Além disso, utilizaram o auxílio de modelos numéricos danificados para verificar a influência dos danos nas frequências.

As técnicas analisadas resultaram como eficazes na detecção de danos, sendo capazes de detectar alterações na ordem de 0,1% nas frequências da referida ponte. Os autores indicaram que os resultados obtidos proporcionam confiança nas informações fornecidas pelo SHM, e sugerem o uso de mais de uma metodologia para detectar alterações significativas com relação às condições normais da estrutura. Além disso, mostram que o grau de linearidade ou não linearidade na correlação entre as características dinâmicas e os fatores ambientais / operacionais pode afetar significativamente o monitoramento estrutural.

Oliveira (2016) propôs um sistema de monitoramento estrutural dinâmico em torres eólicas, baseado na análise de vibrações e capaz de estimar com precisão as propriedades modais das estruturas, a partir da sua resposta dinâmica. O sistema foi implementado em uma torre eólica *Senvion MM82* com os objetivos de detectar danos estruturais e de avaliar a condição de fadiga. Os resultados da pesquisa permitiram concluir que o sistema de monitoramento foi capaz de identificar pequenos danos na estrutura de suporte de torres instaladas em terra e fora da costa.

Haeri *et. al* (2017) apresentam uma abordagem para o monitoramento estrutural de plataformas *offshore* utilizando, para isso, as respostas estruturais provocadas por vibrações ambientais. Devido à complexidade estrutural e por estarem sujeitas a cargas de onda e/ou impactos de barco, que excitam apenas os primeiros modos de vibração, foram utilizadas só as primeiras frequências e seus respectivos modos de vibração como informações.

O método baseia-se na utilização de modelos de referência de duas e três dimensões e, a partir destes, realiza-se uma atualização dos coeficientes das matrizes de rigidez para estimar os níveis dos danos. Por fim, os autores fizeram uma análise de sensibilidade acerca do método proposto, abordando as possíveis fontes de erros, de modo que os parâmetros de confiabilidade estatística mostraram que a metodologia é eficiente no contexto da detecção de danos.

Cardoso, Cury e Barbosa (2017) propuseram uma metodologia para obter os parâmetros modais automaticamente, independentemente do método de identificação de

sistema usado para estimar os modos de vibração. Neste trabalho foi utilizado o SSI-DATA.

Baseado em algoritmo de clusterização hierárquico, os autores realizaram testes utilizando os sinais de uma viga, gerados numérico e experimentalmente. Os resultados obtidos foram satisfatórios de modo que, quando comparado a outras metodologias semelhantes, comportou-se com superioridade.

Sun, Zou e Zhang (2017) fizeram uma revisão a respeito da aplicação de sistemas de monitoramento estrutural em pontes de grandes vãos na China, com o objetivo de ilustrar seu valor prático. São feitos três estudos, sendo o primeiro referente ao caso de uma colisão de um navio em uma ponte suspensa e os efeitos causados na estrutura, bem como a importância de se ter um SHM para emitir alarmes referentes às alterações causadas pela colisão. O segundo caso diz respeito às alterações causadas nas respostas de uma ponte suspensa devido à expansão das juntas de dilatação.

O último estudo foi realizado no caso de uma ponte que apresentava vibrações excessivas provocadas pelo vento. Neste caso, os autores fizeram uma abordagem no sentido de demonstrar que o monitoramento não serve apenas para acompanhar o desempenho da estrutura, mas também monitorar o funcionamento dos sistemas de amortecimento de massa sintonizada (TMDs – Tuned Mass Damper) instalados para controlar as vibrações. Além disso, os autores afirmam que o SHM pode embasar o dimensionamento dos TMDs, uma vez que, por meio do monitoramento estrutural, é possível conhecer as acelerações, frequências, modos de vibração, amortecimento da ponte e, portanto, conhecer melhor o comportamento da estrutura diante da ação de ventos.

Como é possível ver, o monitoramento estrutural é um tema que vem sendo abordado nos mais diversos tipos de estruturas, sobretudo naquelas que têm funções ligadas ao desenvolvimento social, econômico e cultural de um determinado lugar. Obviamente, nem todos os métodos apresentados nas pesquisas citadas neste trabalho são testados em estruturas usuais, mas sim em modelos de laboratório, significando, portanto, que este é um tema ainda em evolução e que ainda tem um vasto campo para ser explorado.

Como o foco do trabalho está relacionado com uso das RNAs como parte integrante de sistema de monitoramento estrutural, a seguir são apresentadas algumas

pesquisas que abordam mais diretamente esta ferramenta no contexto da detecção de danos estruturais em construções usuais e de laboratório.

## **2.2 Monitoramento estrutural com Redes Neurais Artificiais (RNAs)**

Como mencionado, o monitoramento estrutural pode ser realizado com o apoio de técnicas de diferentes áreas atuando para o mesmo fim, isto, a busca pelo acompanhamento contínuo de desempenho estrutural. No entanto, particularizando para a técnica das Redes Neurais Artificiais (RNAs), pode-se notar que a capacidade da referida ferramenta no contexto da detecção de danos é bastante promissora e satisfatória, como relatam os trabalhos dos autores a seguir.

Elkordy, Chang e Lee (1993) utilizaram a técnica de RNAs para diagnosticar danos em estruturas apertadas. Os autores utilizaram dois modelos numéricos bidimensionais (modelos com mesmas dimensões, porém o segundo com um maior nível de discretização) e um modelo experimental para obter respostas de vibrações. Foram utilizadas três redes *Backpropagation*, das quais a primeira e a segunda foram utilizadas para detectar danos e, a terceira, além de detectar, tinha o objetivo de mensurar a severidade das anomalias.

Para a fase de treinamento, as redes tiveram como padrões de entrada cenários danificados dos modelos numéricos e, para avaliar o desempenho da rede, esta foi testada com dados do modelo experimental. O estudo obteve bons resultados indicando, portanto, que a detecção de danos através das RNAs pode ser uma boa ferramenta no monitoramento das estruturas. Os autores ressaltam, ainda, que é necessário a aplicação da técnica em modelos estruturais e cenários de danos mais complexos.

Genovese, Brito e Doz (2002) apresentaram um método híbrido baseado no MER e na utilização das RNAs. O método é composto de duas etapas: localização dos danos via MER e, com base nos dados da localização, utiliza-os como parâmetros para a quantificação, através das RNAs. O método foi testado em vigas biapoiadas e os resultados obtidos permitiram concluir que a junção das duas técnicas tem grande potencial no monitoramento estrutural. No entanto, análises feitas sob o efeito de ruído compromete significativamente a avaliação, sobretudo na etapa referente ao uso das RNAs.

Sahin e Sheno (2003) realizaram um estudo numérico e experimental a fim de localizar e quantificar danos em uma viga. Para o estudo, foi utilizada a técnica de RNAs tendo, na etapa do seu treinamento, os modos e as frequências obtidas numericamente, por meio do software ANSYS. Buscando o melhor desempenho das RNAs, os autores criaram três diferentes redes, cada uma com um tipo de dado de entrada, dentre os quais estavam as frequências, diferença máxima entre as curvaturas e os modos de vibração. O treinamento foi realizado com dados de 480 cenários construídos com severidades e posições de danos diferentes.

Para validar a técnica, as RNAs foram testadas com os dados obtidos do modelo experimental e os resultados obtidos permitiram concluir que as diferenças percentuais entre as frequências são dados que podem indicar a existência e a severidade do dano, no entanto, em se tratando de localização, a diferença máxima entre as curvaturas apresentou resultados mais precisos.

Gomes (2004) utilizou a técnica de Redes Neurais Artificiais com Funções de Base Radial para obter informação de possíveis danos em uma viga biapoiada. A rede recebeu como dados de entrada a variação dos quadrados das frequências naturais e, com base no processamento de suas três camadas, forneceu como saída o índice de dano de cada elemento da estrutura. Foi utilizado um modelo numérico de viga com diferentes cenários de danos, do qual se obtiveram os dados de treinamento e de teste da rede.

O autor também analisou o impacto dos resultados da RNA quando processada com dados sob interferência de ruído. Gomes concluiu que à medida que são acrescentados, criteriosamente, parâmetros da estrutura como dados de entrada na fase de treinamento, melhores serão os resultados da rede, sobretudo em estruturas mais complexas. Além disso, observou-se também que a presença de ruídos pode prejudicar significativamente a sensibilidade na avaliação do dano.

Lee *et. al* (2005) propuseram um método baseado no uso de RNAs para localizar danos. Para definir os dados a serem utilizados como padrões de entrada da rede os autores consideraram que as alterações nas frequências naturais provocadas pelas variações da temperatura podem ser mais relevantes quando comparadas com diferenças provocadas pela presença de danos estruturais. Nesse sentido, como padrões de

entradas, foram utilizadas as diferenças e as relações entre os modos de vibração dos modelos intactos e danificados.

Para o estudo, foram usados dois exemplos numéricos de uma viga simples e de uma ponte para testar a eficácia do método. A partir do estudo numérico obtiveram-se as informações necessárias para o treinamento da rede, sendo o teste realizado com os dados de um modelo de ponte construído em laboratório. Neste caso, verificou-se que a presente técnica pode ser eficaz na detecção de danos, uma vez que a maior parte das falhas estruturais foi detectada com sucesso, nos diversos cenários de danos considerados.

Além dos dois estudos indicados, a técnica foi submetida à aplicação em uma ponte já construída, e, portanto, em dimensões usuais. Os resultados mostraram uma boa precisão da ferramenta no que se refere à localização dos danos.

Yeung e Smith (2005) usaram RNAs não supervisionadas para detectar danos em um modelo numérico de ponte. Para o trabalho, foram desenvolvidos modelos com diferentes intensidades de danos e de carregamento (dinâmico), de modo que os seus modos de vibração foram obtidos para serem utilizados como padrões de entrada da rede. Os autores observaram que ao serem utilizadas as formas modais deve-se ter cuidado com os nodos da forma modal, uma vez que não apresentam deslocamentos e podem interferir nos métodos de detecção do dano. Para contornar tal problema, as acelerações dos modelos foram colhidas e os modos foram estimados a partir de dois lugares específicos, sendo um nos pontos de maiores deslocamentos e o outro nos nós, para que quando as formas modais fossem estimadas o nó não ficasse sem representação.

O poder de reconhecimento de padrões foi analisado com e sem a influência de ruídos nos dados e, com base nos resultados, foi observado um índice de acerto foi em volta 70% dos casos, considerando uma razoável quantidade de ruído. Deste modo, pode-se afirmar que as RNAs caracterizaram-se como uma boa ferramenta na detecção de danos estruturais.

Fang *et al.* (2005) utilizaram as Funções de Respostas em Frequência (FRF) como dados de entrada de uma RNA a fim de treiná-la para identificação de danos estruturais. Foi utilizado o algoritmo *Backpropagation* para o treinamento da rede, bem como algumas de suas variações para comparação de resultados. O estudo foi

desenvolvido numericamente em uma viga com diferentes cenários de danos, de modo que suas funções de respostas de frequências foram utilizadas como padrões de entrada das redes. Os resultados mostraram que a técnica funcionou adequadamente, apresentando resultados satisfatórios.

Jeyasehar e Sumangala (2006) testaram cinco diferentes RNAs para avaliar a capacidade de uma rede com vistas à identificação de danos em vigas de concreto protendido. Para o estudo foram selecionadas as frequências naturais, deflexões, largura de trincas, carregamentos e, de maneira combinada, foram usados como padrões de entrada para as RNAs. Após análises, observou-se que as redes treinadas com dados dinâmicos apresentaram resultados com margem de erros menores indicando, portanto, que as características dinâmicas são parâmetros mais adequados para o contexto do monitoramento estrutural.

Haryanto *et al.* (2007) testaram numericamente um método de detecção de danos baseado no uso das RNAs. Foram usados tensões e deslocamentos de uma viga para localizar e quantificar as falhas estruturais, estas últimas simuladas por meio de reduções na rigidez dos elementos. Os resultados encontrados indicaram que, para fins de localização e quantificação, as tensões foram parâmetros mais influentes, uma vez que, a partir destes, os resultados foram mais relevantes.

Mehrjoo *et al.* (2008) apresentaram um método utilizando redes neurais com algoritmo *Backpropagation*, capaz de estimar a intensidade de danos presentes em articulações de pontes treliçadas. Por se tratar de grandes estruturas com muitas articulações, conseqüentemente com muitos parâmetros, o método propõe uma divisão da estrutura em subestruturas que possam representar a ponte completa. A rede recebeu como dados de entrada as frequências e os modos naturais de vibração das estruturas testadas.

O treinamento da rede foi realizado com os dados obtidos de uma subestrutura, e a partir do seu aprendizado pôde-se generalizar a referida rede, a fim de conhecer os dados de saída, ou seja, os danos da estrutura completa. Os resultados indicaram um bom aprendizado da rede mostrando, portanto, boa precisão na identificação dos danos.

Das e Parhi (2009) propuseram uma nova metodologia usando RNA, do tipo *Backpropagation*, para identificar danos em vigas. Foram desenvolvidas expressões teóricas a fim de avaliar os efeitos que a profundidade e a localização de uma trinca

causam nas frequências naturais e nos seus respectivos modos de vibração. Tendo em vista esses parâmetros (frequências e modos de vibração), a RNA foi composta por seis neurônios na camada de entrada, correspondendo ao desvio relativo das três primeiras frequências e aos seus respectivos modos de vibração, dois neurônios na camada de saída, esses últimos com a profundidade da trinca e sua respectiva localização; e 8 camadas ocultas.

Para testar a rede, foram utilizados modelos numéricos e comparados com resultados experimentais, concluindo-se, a partir destes, que a técnica obteve um desempenho aceitável, necessitando, ainda, de novos testes em outros tipos de estrutura, bem como solucionar possíveis falhas.

Rucka e Wilde (2010) combinaram as técnicas de Redes Neurais e ondas *Wavelet* a fim de monitorar e localizar falhas estruturais. A metodologia do trabalho consiste na aplicação da transformada de *Wavelet* sobre os modos de vibração da estrutura, de modo que a RNA tenha como entrada os referidos dados e como saída a detecção e localização dos danos. Para treinar e validar o método, foram utilizados modelos numéricos e experimentais de vigas, placas e cascas. Com base nos resultados, os autores concluíram que a combinação dos métodos pode apresentar boa precisão na detecção de danos, sendo ainda possível o melhoramento por meio da otimização da arquitetura da rede.

Omenzetter e Lautour (2010) desenvolveram um método de detecção e danos baseados no uso de modelos autoregressivos (AR) e de RNAs, especificamente a rede Learning Vector Quantization (LVQ). O método foi aplicado a dados experimentais obtidos de dois modelos: uma estrutura aperturada de três andares, excitada numa mesa vibratória, e uma estrutura mais complexa da ASCE Fase II Dyke (2003), excitada por um *shaker* - Figura 2.4, ambas com cenários intactos e danificados.

No primeiro caso, os danos foram simulados pela redução da seção transversal de alguns elementos. Já no segundo, estrutura de 4 pavimentos, foram retiradas algumas conexões e afrouxados alguns parafusos para simular os danos.

Os ARs foram utilizados no ajuste das séries de acelerações das estruturas, de modo que os seus coeficientes foram escolhidos como características sensíveis a danos, passando, posteriormente, por uma análise para reduzir a dimensão desses dados. Neste último passo foi utilizado a Principal Component Analysis (PCA). As informações

foram utilizadas como dados de entrada do LVQ (*Learning Vector Quantization*) e os resultados mostraram que os coeficientes de AR funcionam bem como informações sensíveis à anomalias estruturais. Além disso, notou-se que o LVQ comportou como uma ferramenta confiável na classificação de danos.



Figura 2.4 – Vista da estrutura ASCE Fase II Dyke (2003).

Borowiec e Ziemian´ski (2011) utilizaram a técnica de Redes Neurais Artificiais para identificar danos em uma viga produzida em laboratório. Para o estudo, foram construídos modelos numéricos, a partir dos quais se obtiveram as características dinâmicas, especificamente, as alterações nas frequências devido à redução de rigidez e adição de massa em determinados pontos da viga e, posteriormente, foram usadas como dados de treinamento da RNA tipo *Backpropagation*.

A rede foi treinada com parâmetros dos modelos numéricos e testada com os dados do modelo experimental. Com base nos resultados, os autores concluíram que a RNA pode ser considerada bastante eficiente na identificação de danos.

Shi e Yu (2012) apresentaram um método híbrido para detectar danos estruturais, composto de duas técnicas, RNAs e Transformada de *Wavelets*. Na etapa referente à extração das propriedades dinâmicas, bem como no tratamento dos sinais obtidos por meios de ensaios dinâmicos, foi usada a técnica de *Wavelet*. Uma vez conhecidos os referidos dados, eles foram usados como entradas da RNA para que esta seja capaz de reconhecer e classificar padrões. Foram testados quatro tipos de redes, com variações nas quantidades de coeficientes de *Wavelet* usados como entrada das

redes, no número de camadas intermediárias, bem como na quantidade de neurônios nestas camadas.

Após as simulações em um pórtico espacial modelado numericamente, os autores concluíram que a técnica apresentou uma performance bastante promissora no caminho do monitoramento estrutural, uma vez que o índice de acertos ficou acima de 95% dos casos testados.

Seleemah *et. al* (2012) apresentaram uma aplicação da técnica de Rede Neural Artificial para a detecção de danos na ponte El-Ferdan, localizada no Egito. Para o estudo foram construídos modelos numéricos da ponte com danos, estes últimos simulados pela redução da área de secção transversal nos valores de 20, 40, 60 e 80 por cento da área dos elementos.

Deste modo, foram obtidas as propriedades estáticas e dinâmicas da ponte a fim de serem utilizadas como dados de entrada da RNAs. Foram criadas várias redes com diferentes arquiteturas, isto é, número de neurônios na camada intermediária, bem como diferentes conjuntos de entradas, incluindo as deflexões estáticas da ponte, características dinâmicas e uma combinação de ambas as características. Em todos os casos a saída de rede consistiu em dois nós, representando a localização e a severidade do dano no elemento.

Os resultados da análise de sensibilidade indicaram a importância das características dinâmicas da ponte no sucesso do desempenho da RNA, resultando na conclusão que a técnica das RNAs é precisa e pode ser considerada uma alternativa extra para a detecção de danos ou monitoramento estrutural de saúde de grandes estruturas.

Du *et. al* (2012) utilizaram a rede do tipo LVQ como técnica integrante de um sistema de monitoramento estrutural de placas de alumínio com os furos rebitados continham possíveis danos, representados por rachadura. Deste modo, considerando a necessidade de se realizar um treinamento (aprendizado) da RNA, foram construídos modelos numéricos em elementos finitos da referida estrutura, a fim de se obter dados de *input* para o aprendizado da rede.

Deste modo, o funcionamento do LVQ estava pautado em ser treinador com informações obtidas numericamente e, para isso classificava os padrões em duas

classes: danificada e intacta. Já a fase de teste da RNA, na qual são fornecidos como dados de entrada as informações do problema a ser resolvido, foram usados os dados das placas físicas.

Após os testes, os autores observaram que dos 10 padrões fornecidos, o LVQ classificou 8 corretamente, resultando em 80% de acertos e caracterizando-se como uma ferramenta promissora para integrar sistemas de monitoramento estrutural.

Tibaduiza, Mujica e Rodellar (2013) propõem uma metodologia baseada na *Principal Component Analysis* (PCA) e na *RNA Self Organizing Maps* (SOM) para detectar danos em uma placa a partir de dados obtidos em testes dinâmicos. A metodologia foi analisada experimentalmente e, para demonstrar a eficiência, foram realizados dois estágios com diferentes cenários de danos e com a estrutura intacta. O primeiro foi o estágio de treinamento e de validação seguido do estágio de teste, usando dados diferentes, tendo como a simulação de danos a adição de massa em diferentes posições e proporções. A primeira etapa demonstrou como os resultados são altamente influenciados pelos *inputs* e o método de normalização aplicado na rede SOM.

A informação do estado da estrutura foi utilizada para verificar a qualidade da classificação e os melhores parâmetros da rede, isto é, o número de padrões de entrada, bem como a arquitetura da rede. A segunda etapa permitiu avaliar a eficácia da metodologia proposta, utilizando novos dados de cada estado da estrutura.

Perez *et. al* (2013) propuseram uma metodologia capaz de identificar e localizar danos em treliças, inclusive de modelos experimentais. A metodologia é composta de três técnicas, RNAs e *Wavelets* e o Modo Empírico de Decomposição, estes dois últimos utilizados no tratamento dos sinais da estrutura. Treinada com índices de danos obtidos ao decompor os sinais da estrutura, a RNA foi criada para localizar e quantificar três tipos de danos: “afrouxamento de parafusos”, redução de rigidez e corrosão dos elementos, ocorrendo de maneira isolada ou combinando os três tipos.

Foram simulados 10 ensaios com o modelo (com cada condição de dano) a fim de obter informações para treinar a RNA, sendo os dados da estrutura (experimental), usados para testar a técnica. Os resultados permitiram à equipe concluir que a metodologia tem grande potencial no monitoramento estrutural, uma vez que esta apresentou resultados bastante confiáveis, conseguindo identificar de forma satisfatória os danos da treliça e, podendo ser aplicados a outros tipos de estruturas.

Karimi *et al.* (2013) também utilizaram as frequências naturais de vigas, modeladas numericamente, para alimentar redes neurais na localização de danos. A rede foi treinada com algoritmos genéticos, e teve como alimentação e resposta os valores das frequências naturais, a previsão da localização e a profundidade das trincas, respectivamente. Após os resultados, os autores concluíram que a técnica apresentou bons resultados, com erros em torno de 4% do esperado.

Kondru e Rao (2013) utilizaram a estrutura de uma viga em balanço para aplicar a técnica de RNAs com vistas à localização e mensuração da profundidade de trincas. Neste trabalho, a rede foi treinada com frequências naturais da estrutura e foi comparada sua performance na localização das trincas com os resultados obtidos por meio do software ANSYS.

Hakim *et al.* (2014) apresentaram um estudo baseado em RNAs com o objetivo de localizar e quantificar danos estruturais em uma viga metálica. Para isso, utilizaram o algoritmo *Backpropagation* para processar 5 diferentes RNAs, correspondendo, cada uma, ao modo de vibração utilizado como dado de entrada. Em uma segunda fase, realizaram a mesma análise, no entanto, dando como inputs para a rede o conjunto da frequência natural de vibração e o seu referido modo. Em ambos os casos, dos 208 conjuntos de dados obtidos por meio de experimentos em 4 vigas danificadas em diferentes posições e proporções por redução na rigidez, 70% foi utilizado para os treinamentos da rede e 30% para a fase de testes, de modo que o estudo apresentou uma abordagem totalmente experimental.

Os resultados mostraram um bom desempenho para todas as análises. No entanto, a avaliação da rede quando o conjunto da frequência e o modo de vibração foram fornecidos como padrões de entrada, foi destacadamente mais precisa, tanto na localização como na quantificação das falhas estruturais.

Chengyin *et al.* (2014) testaram um método híbrido baseado nas ferramentas matemáticas *RS Theory* e RNAs a fim de detectar danos em uma treliça de aço, por meio de dados obtidos em testes de vibração. Inicialmente, a primeira técnica é utilizada para determinar os parâmetros dinâmicos mais adequados a serem usados como alimentação da RNA. Em seguida, é aplicada uma RNA *Backpropagation* para detectar os danos, sendo estes simulados pela redução na inércia de alguns elementos.

A rede é treinada com informações obtidas em modelos numéricos e testada com os dados experimentais da treliça. Os autores observaram que o método não foi eficiente na estimativa da severidade do dano; no entanto apresentou bons resultados na determinação da posição das falhas estruturais.

Meruane e Mahu (2014) propuseram o desenvolvimento de um algoritmo de avaliação de danos em tempo real usando RNAs (*Backpropagation*) e frequências anti-ressonantes, de modo que, como vários trabalhos anteriormente mencionados, as autoras utilizaram dados numéricos e experimentais para as etapas de treinamento e teste, respectivamente. A metodologia foi validada por meio de dois casos estudados: um sistema massa-mola com 8 graus de liberdade e uma viga de aço, sob a condição de contorno livre-livre.

As análises foram feitas variando número de neurônios como também funções de transferência. Além disso, foi introduzido ruído nos dados das frequências, a fim de avaliar o desempenho da rede. Os resultados obtidos foram satisfatórios mostrando que é possível monitorar a presença de danos estruturais usando somente a informação anti-ressonantes obtidas a partir de funções de resposta de frequência pontual.

Nguyen *et. al* (2015) apresentaram uma técnica para identificar e estimar a presença de danos em um protótipo da junta de uma viga em arco que suportam a pista de ônibus da ponte Sydney Harbour. Para isso os autores usaram funções de resposta de frequência combinadas com a análise de componentes principais para determinar características específicas de danos e, por fim, utilizá-las como dados de entrada de uma RNA Backpropagation.

Para validar, os autores fizeram testes experimentais na peça em seu estado saudável e, após a obtenção das respostas, foram realizados cortes com três estágios de severidade (médio, grave e gravíssimo) para simular danos estruturais e, novamente, foram obtidas suas respostas. Estas informações foram divididas para treinar e testar a rede, no entanto observou que o pouco número de exemplos para treinar e rede limitava seus resultados. Deste modo foram desenvolvidos modelos numéricos no *software* ANSYS para obter informações e serem usadas como padrões de entrada do treinamento da RNA. Como era de se esperar, os resultados apresentados mostraram uma significativa melhora, aumentando a precisão de identificação de danos.

Onur e Abdeljaber (2015) apresentaram um novo algoritmo de avaliação de danos baseado em vibrações, utilizando o SOM para extrair índices de danos significativos a partir da resposta de aceleração aleatória no domínio do tempo. O trabalho foi feito com uma abordagem experimental em uma estrutura de maiores dimensões, desenvolvida por Dyke (2003), objetivando demonstrar a sua eficiência no monitoramento da saúde das estruturas civis. Os danos estruturais foram simulados por meio da redução de rigidez nas amarras e nas ligações entre vigas e colunas ou pela exclusão total de alguns elementos estruturais e os resultados indicaram que o algoritmo apresentou boa sensibilidade aos danos estruturais.

Ahmed (2016) em sua tese de doutorado reservou parte da sua pesquisa para avaliar o desempenho das Redes Neurais Artificiais, especificamente a rede *Backpropagation*, na estimativa dos tamanhos dos vazios em lajes de concreto armado.

Para a análise, foram desenvolvidos modelos numéricos no ANSYS, dos quais foram obtidas suas 10 primeiras frequências, a fim de obter as informações necessárias para treinar a RNA. Uma vez que a rede apresentou um bom desempenho, isto é, o erro durante a fase de aprendizado da rede estava por volta de  $10^{-4}$ , passou-se para a segunda etapa, a fase de testes. Deste modo, foram apresentadas as 10 primeiras frequências da estrutura real e, ao final do processamento, observou-se que as regressões dos resultados dos testes mostraram que a RNA proposta foi capaz de prever os tamanhos de vazios com uma precisão consideravelmente alta.

É importante ressaltar que o autor chama a atenção para o número de neurônios de cada simulação, uma vez que foi observado que o aumento das células artificiais melhorou significativamente o poder de generalização da rede neural. Ainda como conclusões da análise, Ahmed (2016) classifica a técnica como uma ferramenta eficiente para detectar o tamanho de vazio em lajes.

Jin *et. al* (2016) propuseram uma metodologia baseada em Redes Neurais Artificiais com filtros *Kalman* para detectar danos em estruturas com sistemas de monitoramento contínuo instalados a longo prazo, de março de 2013 até maio de 2014. Tendo em vista que os parâmetros modais apresentam alterações provocadas pela variação de temperatura, os autores analisaram a correlação entre tais fatores e, assim avaliaram as variáveis mais adequadas para serem utilizadas como inputs para a RNA. Para validar as técnicas, os autores construíram o modelo numérico danificado da ponte

Northbound, construída em 1964, Meriden - Connecticut, EUA (Figura 2.5), para obter fatores de variação das frequências e aplicá-las nos dados obtidos do monitoramento, simulando, assim, danos físicos na referida estrutura.

Com vistas à detecção e com a conclusão que as frequências naturais sofrem decréscimos com o aumento da temperatura, foram usadas as diferenças das frequências e das temperaturas como padrões de entradas das redes e os resultados permitiram concluir que a rede com filtros Kalman apresentou um grande potencial para integrar um sistema de monitoramento em tempo real de grandes estruturas.

No que corresponde ao funcionamento propriamente dito da RNA, os autores observaram que o processo de escolha da arquitetura da rede, especificamente o número de neurônios da camada escondida, deve ser feito observando o desempenho de diversos testes, uma vez que um número reduzido de células artificiais minimizou o desempenho do processo e, um aumento exagerado também apresentou uma baixa na eficiência do algoritmo.



Figura 2.5 – Vista da ponte Meriden Jin *et. al* (2016).

Tan *et. al* (2017) apresentaram uma técnica baseada em RNAs para localizar e mensurar danos em modelos de vigas de aço. A pesquisa foi realizada numericamente de modo que, como dados de entrada, foram fornecidos os índices de dano baseado na energia de deformação modal dos vários cenários simulados. Já como saídas, a rede foi treinada para fornecer a localização e o valor da redução de rigidez dos elementos que continham as anomalias. Baseado nos resultados, os autores afirmaram ser uma metodologia precisa e eficiente, principalmente quando estiver aplicável às estruturas usuais.

Baseado nos vários trabalhos citados além de outros, pode-se notar que, no caso do uso de RNAs para identificar e classificar a intensidade dos danos estruturais, não há um consenso com relação aos parâmetros mais adequados para o reconhecimento de padrões. Assim, os pesquisadores que utilizam a referida ferramenta recorrem aos estudos já realizados, que obtiveram êxito, para determinar os tipos de dados que devem ser considerados de uma determinada estrutura.

Além disso, diante das inúmeras pesquisas abordando e ressaltando a necessidade de se ter um sistema de monitoramento estrutural nas edificações, sobretudo baseado na utilização de técnicas rápidas e confiáveis, este trabalho se insere neste escopo, uma vez que utiliza as RNAs para detectar e/ou localizar danos estruturais em uma viga construída em laboratório e, com base nos resultados, extrapola a abordagem para a aplicação da técnica em uma estrutura mais complexa, uma ponte em uso.

### 3. FUNDAMENTOS TEÓRICOS

Este trabalho tem como objetivo encontrar uma metodologia para identificar, localizar e quantificar danos, baseada no uso das propriedades dinâmicas como parâmetros de reconhecimento de padrões. Neste sentido, a fim de se conhecer o funcionamento dinâmico de um sistema, suas propriedades, bem como os métodos a serem usados no trabalho, neste capítulo são descritas as equações e as respectivas considerações feitas para serem utilizadas.

#### 3.1 Obtenção das propriedades dinâmicas

A obtenção das propriedades dinâmicas de um sistema, isto é, frequências naturais, modos naturais de vibração, razão de amortecimento, é baseada no conhecimento da equação que governa o seu comportamento dinâmico. Deste modo, a equação de movimento para um sistema de  $n$  graus de liberdade é expressa da seguinte forma, Clough & Penzien (1993):

$$\mathbf{M}\ddot{\mathbf{y}}(t) + \mathbf{C}\dot{\mathbf{y}}(t) + \mathbf{K}\mathbf{y}(t) = \mathbf{F}(t) \quad (3.1)$$

Na qual,  $\mathbf{M}$ ,  $\mathbf{C}$  e  $\mathbf{K}$  são, respectivamente, as matrizes de massa, amortecimento e rigidez da estrutura, sendo o número de linhas e colunas correspondente à discretização adotada, ou seja, do número de graus  $n$  de liberdade da estrutura. Os símbolos  $\ddot{\mathbf{y}}(t)$ ,  $\dot{\mathbf{y}}(t)$  e  $\mathbf{y}(t)$  representam os vetores de aceleração, velocidade e deslocamento, respectivamente; e  $\mathbf{F}(t)$ , indica o vetor de forças excitadoras do sistema.

As matrizes de massa e rigidez são obtidas com base na geometria do sistema e nas propriedades dos materiais envolvidos. Já a matriz de amortecimento, por se tratar de uma análise mais complexa, em geral pode ser expressa como uma combinação das matrizes de massa e rigidez do sistema.

Considerando que, para pequenos amortecimentos, a análise modal do sistema é muito semelhante à análise feita do sistema em vibração livre não amortecida, como é o caso das estruturas civis que apresentam valores de amortecimento menores que 15%,

Cardoso e Cury (2017), neste estudo o amortecimento foi desconsiderado. Desta forma, a equação de movimento dos sistemas em vibrações livres é formulada pela seguinte expressão:

$$\mathbf{M} \ddot{\mathbf{y}}(t) + \mathbf{K}\mathbf{y}(t) = \mathbf{0} \quad (3.2)$$

A equação acima tem solução do tipo:

$$\mathbf{y}(t) = \hat{\mathbf{y}}\text{sen}(\omega t + \theta); \quad (3.3)$$

$$\ddot{\mathbf{y}}(t) = -\omega^2 \hat{\mathbf{y}}\text{sen}(\omega t + \theta) = -\omega^2 \mathbf{y} \quad (3.4)$$

Onde  $\hat{\mathbf{y}}$  representa a forma do sistema, que não varia com o tempo e  $\theta$  é o ângulo de fase.

Substituindo as equações (3.3) e (3.4) na equação (3.2):

$$(\mathbf{K} - \omega^2 \mathbf{M})\hat{\mathbf{y}} = \mathbf{0} \quad (3.5)$$

A equação (3.5) é homogênea linear, e para que não se obtenha a resposta trivial, ou seja,  $\mathbf{y} = \mathbf{0}$ , o determinante da matriz entre parênteses deve ser nulo.

$$|(\mathbf{K} - \omega^2 \mathbf{M})|\hat{\mathbf{y}} = 0 \quad (3.6)$$

Esta última equação é conhecida como a equação característica do sistema e equivale ao problema de autovalor e autovetor. Sendo um polinômio característico de grau  $n$ , as  $n$  raízes encontradas correspondem aos quadrados das  $n$  frequências naturais ( $\omega^2$ ) e os  $n$  vetores associados a estas frequências (autovetores) correspondem aos modos de vibração ( $\hat{\mathbf{y}}$ ), respectivamente.

Como pode se observar, as frequências e os modos de vibração são dependentes da rigidez estrutural, de modo que as mudanças na rigidez provocados por um eventual

dano na estrutura implicará em mudanças nas frequências e nos modos de vibração. Dessa forma, é possível, monitorando as variações destes parâmetros, avaliar indiretamente o dano.

Por outro lado, o monitoramento contínuo implica em trabalhar com um número de dados bastante significativo e técnicas adequadas são necessárias para este fim. Nesse sentido, o uso das redes neurais é uma alternativa interessante e, como mencionado antes, é com ela que se desenvolve este trabalho.

### 3.2 Redes neurais artificiais

Redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos, compostos por unidades de processamento simples interligadas, chamadas neurônios artificiais, capazes de armazenar informações, reconhecer e classificar padrões e fazer previsões.

Trata-se de uma técnica inserida dentre as várias metodologias existentes para a solução de problemas de Inteligência Artificial, baseada no ajuste de conjuntos de parâmetros (ajuste de pesos), tornando-a capaz de aprender, por meio de experiências (treinamento), e generalizar o comportamento de um determinado problema.

Considerando a inspiração do comportamento neural dos seres inteligentes, o primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts em 1943, por isso chamado de MCP e mais conhecido por Neurônio Booleano (Figura 3.1). No sistema neural humano, os dendritos são as ramificações responsáveis por receber os impulsos oriundos de outros neurônios e levar os sinais para o soma, ambiente no qual os impulsos são processados e novos impulsos são gerados (Figura 3.1(a)).

O neurônio ainda é composto de uma ramificação única, mas robusta, o axônio. Este tem a função de transmitir para a extremidade da célula os impulsos processados no *soma*, e desta forma, transmiti-los por meio de nervos terminais para outros neurônios. Esta transmissão recebe o nome de sinapse.

Simulando o comportamento dos dendritos, o modelo apresenta  $t$  terminais de entrada acompanhados do viés ( $b=1$ )  $x_1, x_2, \dots, x_t + b$  e um único canal de saída  $Y$ , o qual se assemelha com a ramificação do axônio.  $W_1, W_2, \dots, W_t$  são pesos que se somam às entradas para determinar a ativação ou inibição destas entradas, simulando aí a tarefa das sinapses. Desta forma, a ativação do neurônio depende da função correspondente,

que ativa ou não a saída, representada na Figura 3.1(b) por  $\Sigma$  e  $\Phi$ . Além das entradas mostradas no modelo artificial, o neurônio Booleano conta com o valor unitário, conhecido por viés, e com o objetivo de polarizar as entradas do neurônio.

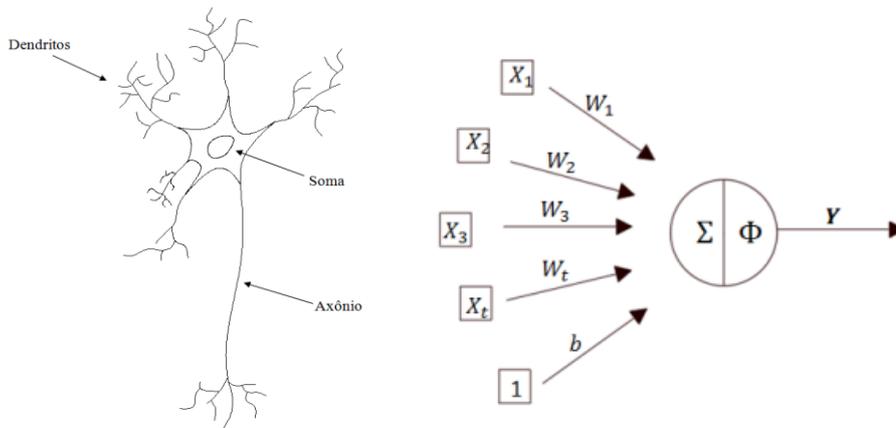


Figura 3.1 (a) Neurônio humano; (b) Modelo do neurônio Booleano.

As redes neurais podem se classificar, de maneira geral e simplificada, quanto às funções de ativação usadas em seu interior (Microestrutura), à arquitetura (Mesoestrutura) e quanto à sua forma de aprendizado (Macroestrutura). A Figura 3.2 mostra um esquema dos diferentes tipos de redes, com alguns destaques que serão explicados posteriormente, já que se tratam da classificação das RNAs utilizadas neste trabalho.

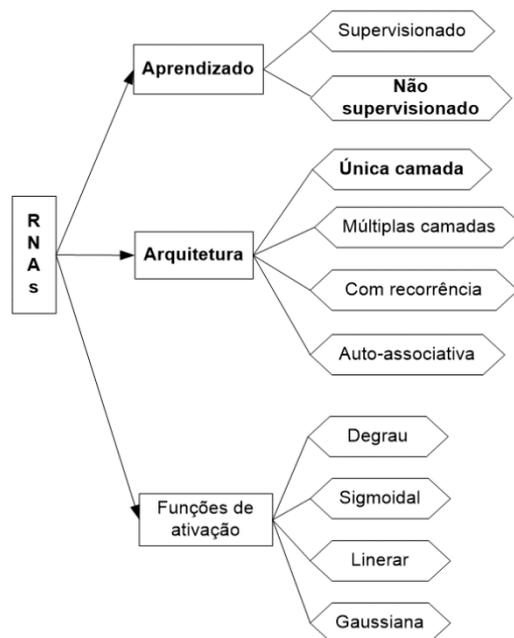
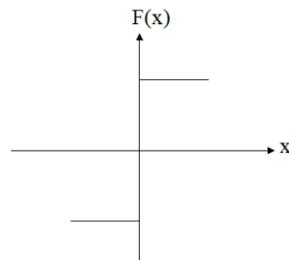


Figura 3.2 Tipos de RNAs

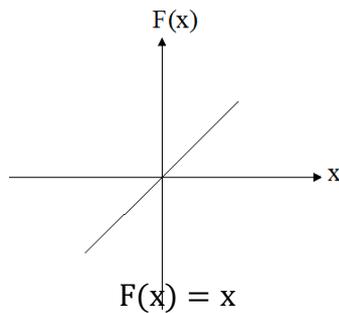
- **Microestrutura**

Define-se pelas características de cada neurônio da rede, especificamente pela sua função de ativação, Bauchspiess (2008). As funções de ativação têm como objetivo principal gerar as saídas dos neurônios e, para tal, fazem uso dos valores dos dados de entrada e dos pesos. Seu uso varia de acordo com o problema a ser resolvido. Dentre as principais funções de ativação, as mais utilizadas são as funções Degrau, Sigmoidal, Linear e a Gaussiana. (Figura 3.3 - (a), (b), (c) e (d), respectivamente).

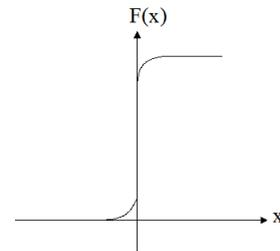


$$F(x) = \begin{cases} +y, & \text{se } x > 0 \\ -y & \text{se } x \leq 0 \end{cases}$$

(a) Função de ativação Degrau  
ativação Sigmoidal



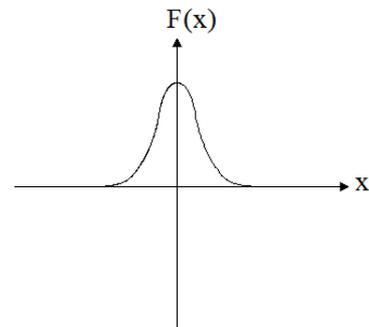
(c) Função de ativação Linear



$$F(x) = \frac{1}{1+e^{-\beta x}}$$

Onde  $\beta$  é a inclinação da função

(b) Função de



$$F(x) = e^{\frac{-(x-\mu)^2}{r^2}}$$

Onde  $\mu$  é o centro (ponto médio) e  $r$  é o raio de abertura da função.

(d) Função de ativação Gaussiana

Figura 3.3 Funções de Ativação.

- **Mesoestrutura - Arquitetura da Rede**

A Mesoestrutura corresponde ao modo em que os neurônios estão organizados, bem como ao tipo de conexão entre eles. O poder de processamento de um neurônio isolado não é aceitável, sobretudo na resolução de problemas mais complexos. Nesse sentido, para um desempenho satisfatório da RNA, os neurônios são agrupados e conectados, dando origem a diferentes arquiteturas e, portanto, redes capazes de resolver problemas com um maior nível de complexidade. A rede pode ser composta de uma ou mais camadas de neurônios, e essa organização independe da função de ativação.

As configurações mais usuais para a conexão dos neurônios são as seguintes: rede *feedforward* de uma única camada, rede *feedforward* de múltiplas camadas (MLP); rede com recorrência entre camada de saída e camada intermediária e rede com recorrência auto associativa.

**Rede *feedforward* de uma única camada:** Composta de apenas uma camada alimentada pela frente (*Feedforward*). As unidades de entrada são neurônios que recebem os sinais externos e, as de saída, os neurônios que apresentam os resultados processados pela rede. A Figura 3.4 mostra a estrutura deste tipo de rede, as unidades azuis ( $X_1, X_2, X_3... X_t$ ) representam os neurônios de entrada, e,  $Y_1, Y_2, Y_3... Y_t$ , as unidades em vermelho, os neurônios de saída. Este tipo de estrutura apresenta algumas restrições quanto a sua eficiência, uma vez que, contar apenas com uma camada pode resultar insuficiente para solucionar problemas de alta complexidade.

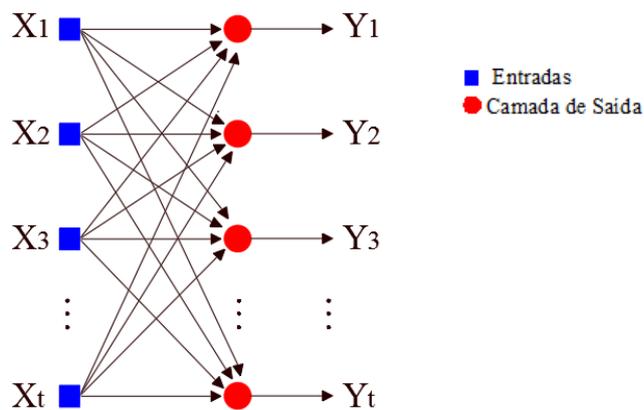


Figura 3.4 Rede de uma única camada. Pádua *et. al* (2000) - adaptada.

**Rede *feedforward* de múltiplas camadas (MLP):** Possui um arranjo muito semelhante às estruturas das Redes *Feedforward* de uma única camada, porém, por dispor de camadas intermediárias (camadas ocultas), este tipo de rede apresenta melhor desempenho quando utilizada na resolução de problemas mais complexos e deve conter entre suas camadas intermediárias ao menos uma função de ativação não linear.

A Figura 3.5 mostra o agrupamento de neurônios em entradas, camada intermediária (unidades verdes) e camada de saída. A quantidade de neurônios pode variar de acordo com o problema a ser resolvido.

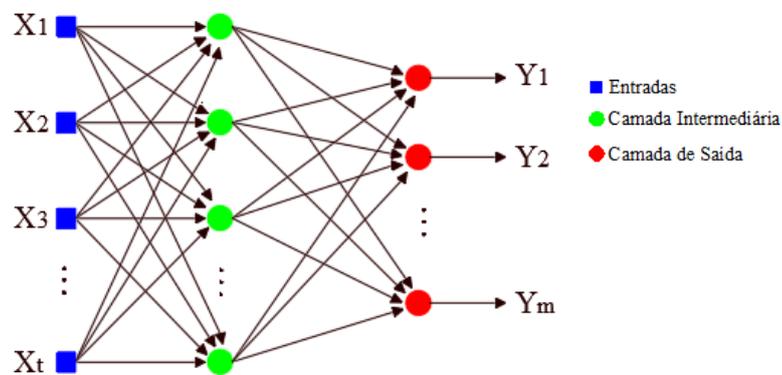


Figura 3.5 Rede com Múltiplas Camadas (MLP). Pádua *et. al* (2000) - adaptada.

**Rede com recorrência entre camada de saída e camada intermediária:** Tipo de estrutura na qual os neurônios dependem não somente das entradas, mas também valores calculados em um passo anterior. Isto ocorre porque as células artificiais podem apresentar recorrência (*feedback*), como observado na Figura 3.6. Essa recorrência consiste na realimentação do neurônio com a saída atual, o que torna as saídas determinadas pelas entradas atuais e pelas saídas anteriores, e pode acontecer com neurônios do mesmo e de diferentes níveis.

Este tipo de rede é, geralmente, utilizado em problemas que envolvem previsões de eventos futuros.

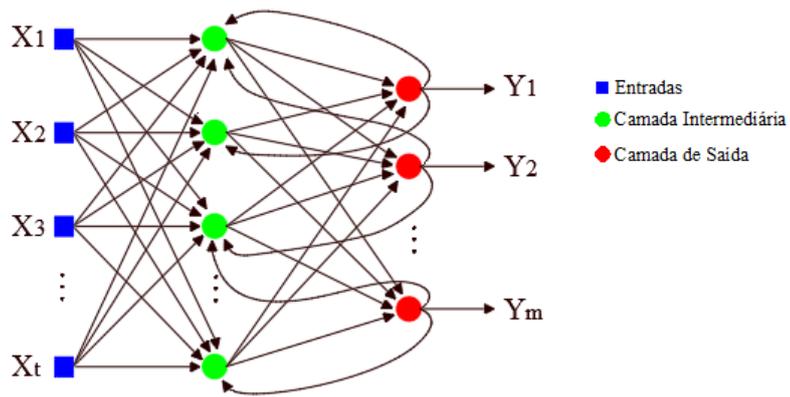


Figura 3.6 Rede com Recorrência. Pádua *et. al* (2000) - adaptada.

**Rede com recorrência auto associativa:** Rede Neural conhecida por rede de Hopfield, é do tipo recorrente e se constitui de neurônios de McCulloch-Pitts agrupados em um só nível e de forma simétrica. Esta organização permite que a saída de cada neurônio se conecte com as entradas de todos os outros. A rede não possui entradas externas, e sua operação se dá em função da dinâmica de mudança de estados de neurônios que operam de forma auto-associativa. A Figura 3.7 mostra este tipo de rede, com os neurônios representados pelas unidades localizadas nas extremidades e pontos de encontros entre as ligações.

As redes Hopfield podem ser utilizadas em problemas de otimização e de controle, entre outros.

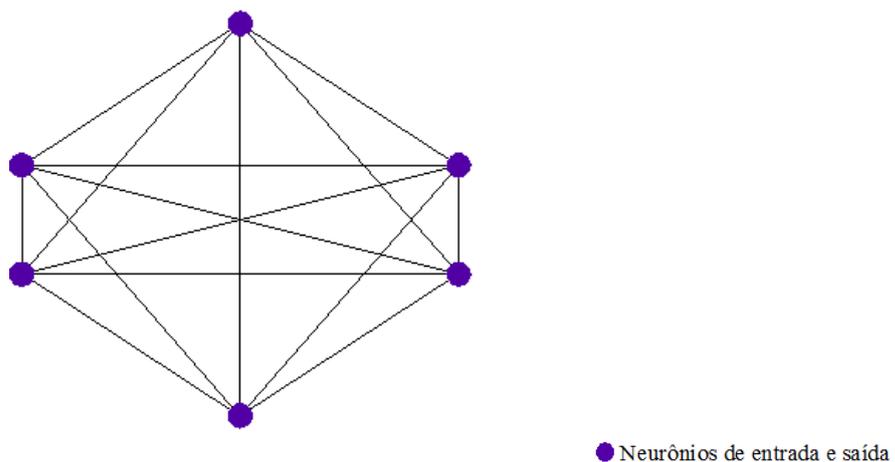


Figura 3.7 Rede Auto - associativa. Pádua *et. al* (2000) - adaptada.

- **Macroestrutura – Tipo de aprendizado**

O treinamento consiste, basicamente, no ajuste dos pesos (parâmetros da rede), através de um processo iterativo. Esse processo ocorre por meio de um critério preestabelecido, mais conhecido por algoritmo, que a partir de dados de entrada, produz conjuntos de saída desejados, ou seja, com erros aceitáveis para o problema em questão.

Existem vários algoritmos de treinamento, e estes são divididos em duas principais classes pelo modo de ajustar os pesos. Estas classes são: Aprendizado Supervisionado e Aprendizado Não Supervisionado.

**Aprendizado Supervisionado:** Neste tipo de treinamento há um supervisor externo que conhece a resposta desejável da rede. Tal supervisor é responsável por estimular as entradas da rede (observando os padrões de entrada) e analisar as saídas, comparando as respostas “atuais” com as desejadas. Com base nesta análise, o supervisor direciona o ajuste de pesos, por meio de um algoritmo, com vistas à minimização do erro e, assim, à finalização do treinamento com uma possível solução.

Os algoritmos de aprendizado supervisionado mais utilizados são a regra Delta e sua generalização para redes de múltiplas camadas, o algoritmo *Backpropagation* (que será detalhado mais adiante) e suas variações (*Levenberg-Marquardt*, *Rprop*, *Quickprop*, etc).

**Aprendizado Não Supervisionado:** Modelo de aprendizagem no qual não se tem o agente conhecedor das entradas e das respectivas saídas da rede. Durante o processo de aprendizagem somente os padrões de entradas são fornecidos à rede, e a existência de regularidades nesses dados faz com que o aprendizado seja possível. Assim, para este tipo de treinamento, faz-se necessária a existência de regularidade e semelhança dos dados de entrada, proporcionando a formação de grupos (clusters).

Os problemas que podem ser resolvidos com este tipo de rede são aqueles que procuram descobertas de características estatisticamente relevantes nos dados de entrada, além de poder ser uma etapa de um problema de classificação de padrões.

Para um funcionamento adequado, a modelagem da rede necessita passar por três etapas: Treinamento – Aprendizagem, Associação ou Validação e Generalização. O

treinamento, que será detalhado adiante, consiste no ajuste dos pesos para que seja mapeada a função que mais se adequa à modelagem do problema em questão.

O processo tem início com a separação dos conjuntos de dados (entradas e saídas desejadas) a serem usados nas etapas citadas. No caso da fase da generalização, apenas os dados de entrada são fornecidos à rede.

O conhecimento ou aprendizado da rede é adquirido por meio de um algoritmo de treinamento e é resultado de várias apresentações de um determinado conjunto de treinamento (dados de entrada + saídas desejadas). Após o processamento, e, no caso de um bom desempenho, no qual os erros tenham convergido para um valor mínimo aceitável, a RNA passa para a validação. Neste passo, são fornecidos outros conjuntos de dados e sua performance é avaliada.

Após o treinamento e a validação, a RNA é testada quanto a sua capacidade de generalização, isto é, ela é aplicada ao problema em questão. Além das três etapas mencionadas, há, ainda, três fatores que podem exercer grande influência no desempenho da RNA: o tamanho do conjunto do treinamento e sua representatividade no problema a ser resolvido; a arquitetura da rede e a complexidade do problema. Deste modo, para desempenhos abaixo do esperado, há maneiras de otimizar a RNA.

### **3.3 Rede Backpropagation**

Após o trabalho de Warren McCulloch e Walter (McCulloch e Pitts ,1943), Rosenblatt (1958) sugeriu um modelo que tinha como unidades básicas neurônios MCP (Neurônio Booleano). O *Perceptron* ou *Perceptron* de uma camada, como ficou conhecido, era composto por três níveis, a Retina (recebe entradas do exterior), a Associação (nível intermediário) e a Resposta (saída), e se limitava a resolver problemas linearmente separáveis. Por este motivo o referido modelo não ficou bem visto pela comunidade científica.

Depois de alguns anos de novos estudos das RNAs, surgiu a ideia de que os neurônios artificiais fossem agrupados em camadas, das quais se destacavam a camada de entrada, a camada de saída e as camadas ocultas ou intermediárias.

Estas camadas foram compostas por quantidades diferentes de neurônios, dependendo apenas das variáveis envolvidas no problema e da quantidade de saídas que se pretende obter. Desta forma, estava concebida a rede neural mais conhecida como *Perceptron* de Múltiplas Camadas. (Figura 3.8).

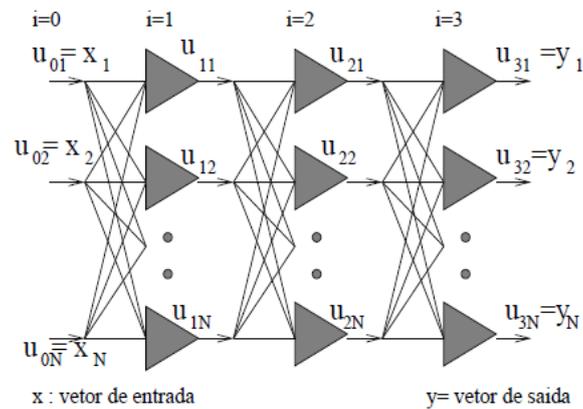


Figura 3.8 Representação gráfica da Rede MLP. Genovese (2005).

A Figura 3.8 representa o comportamento matemático da rede, na qual  $u_{ij}$  são as saídas da  $i$ -ésima camada com seu respectivo  $j$ -ésimo neurônio. No caso mostrado, as entradas ( $x_1, x_2, x_N$ ) da rede são representadas pela camada 0 ( $i=0$ ) e as saídas ( $y_1, y_2, y_n$ ) pela camada 3 ( $i=3$ ).

Este tipo de arquitetura de rede com múltiplas camadas (MLP) apresenta algumas vantagens em relação às redes com uma única camada, uma vez que as MLPs são mais eficientes no desempenho computacional e, por este motivo, são utilizadas neste trabalho como meio de localizar e quantificar danos estruturais.

### 3.3.1 Treinamento das RNAs *Backpropagation*

A grande função das RNAs está na sua capacidade de aprender a partir de informações externas. Sendo assim, para que essa capacidade seja desenvolvida, a rede precisa passar pela etapa de treinamento.

O treinamento consiste, basicamente, no ajuste dos pesos, através de um processo iterativo, para que a rede tenha um aprendizado satisfatório e possa apresentar erros aceitáveis. Sendo assim, para cada tipo de rede, existem vários algoritmos de aprendizado adaptáveis a cada problema a ser resolvido.

Neste trabalho será utilizado um pacote computacional chamado *Neural Network Toolbox* que possui, internamente, o algoritmo de retropropagação ou *Backpropagation*, proposto por Rumelhart *et al.*(1986), bem como suas variações. O *Backpropagation* é uma regra de aprendizado supervisionada, cujo objetivo é minimizar erros até valores mínimos, por meio da correção dos pesos entre as conexões dos neurônios.

A minimização do erro acontece pela execução da descida por gradiente. Este processo pode ser descrito nas etapas *forward* e *backward*. A Figura 3.9 mostra uma rede neural com  $N_e$  neurônios na camada de entrada (chamados de  $X_k$ ),  $N_i$  neurônios na camada oculta (chamados de  $\sigma_j$ ),  $N_y$  neurônios na camada de saída (chamados de  $Y_i$ ) e pesos  $\alpha_{jk}$  (entre a camada de entrada e a camada intermediária) e  $\omega_{ij}$  (entre a camada intermediária e camada de saída).

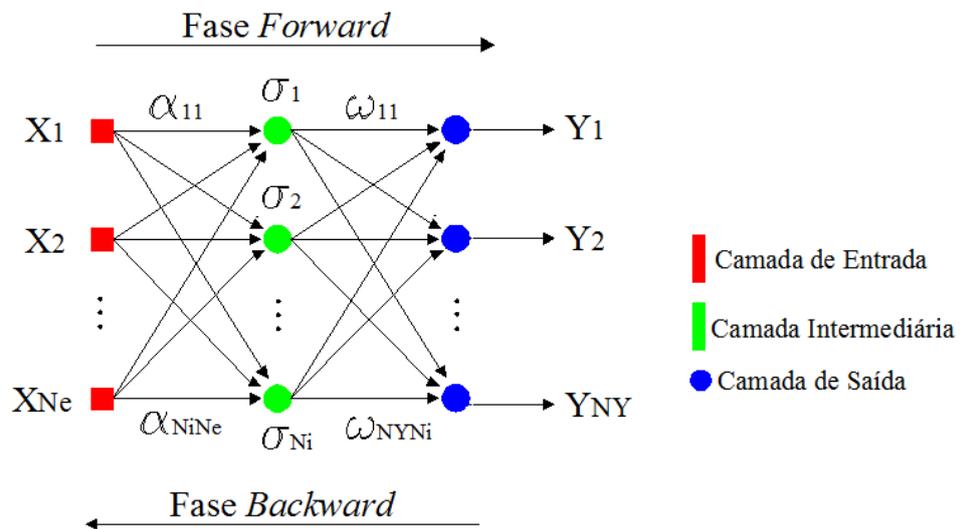


Figura 3.9 Fases *forward* e *backward* do algoritmo *backpropagation*.

Com base na rede da figura 3.9, os passos do *backpropagation* são mostrados a seguir:

**Forward**

- 1) São fornecidos à rede o vetor  $\mathbf{X}$  com  $Z$  conjuntos de entradas (com saídas conhecidas –  $Y_{id}$ ) e, a partir dos pesos  $\alpha_{jk}$ , e da função de ativação, são calculados os neurônios  $\sigma_j$  da primeira camada intermediária.

$$\sigma_j = f(\sum_{k=1}^{Ne} X_k \cdot \alpha_{jk}) \quad (3.7)$$

Os neurônios da camada de saída são calculados da mesma forma, mas com outros pesos ( $\omega_{ij}$ ) e utilizando os neurônios da camada intermediária ( $\sigma_j$ ) como dados de entrada.

$$Y_i = f(\sum_{j=1}^{Ni} \sigma_j \cdot \omega_{ij}) \quad (3.8)$$

O processo se repete até se chegar à última camada da rede, que neste trabalho refere-se à terceira camada, a camada de saída.

- 2) As saídas produzidas pelos neurônios da última camada ( $Y_{NY}$ ) são comparadas com as saídas desejadas ( $Y_{NYd}$ ), estas últimas já conhecidas. A partir dessa comparação é gerado o erro ( $e = Y_{id} - Y_i$ ). O erro quadrático de todos os neurônios ( $E$ ) é dado por:

$$E = \frac{1}{2Z} \sum_{v=1}^Z \sum_{i=1}^{NY} (Y_{id} - Y_i)^2 \quad (3.9)$$

### ***Backward***

- 1) A partir do gradiente decrescente do erro das camadas, chega-se ao ajuste destes pesos. Utilizando a rede mostrada na Figura 3.8, esta etapa se realiza com a correção dos pesos  $\omega_{ij}$  que ligam a última camada (camada de saída) à camada intermediária.

$$\frac{\partial E}{\omega_{ij}} = \frac{1}{Z} \sum_{v=1}^Z \frac{\partial E}{\partial Y_i} \frac{\partial Y_i}{\partial \omega_{ij}} \quad (3.10)$$

$$\frac{\partial E}{\omega_{ij}} = -\frac{1}{Z} \sum_{v=1}^Z (Y_{id} - Y_i) f'(\sum_{j=1}^{Ni} \sigma_j \cdot \omega_{ij}) \sigma_j \quad (3.11)$$

Com base nas derivadas, a correção dos pesos é efetuada pela seguinte expressão:

$$\omega_{ij}^{novo} = \omega_{ij}^{velho} - \mu \frac{\partial E}{\partial \omega_{ij}} \quad (3.12)$$

Onde  $\mu$  é o passo usado para alcançar a melhor convergência.

- 2) Uma vez calculados os novos pesos da última camada (camada de saída), os erros são propagados para camada anterior (camada intermediária), utilizando-se para isso os pesos, das conexões entre as camadas, que serão multiplicados pelos erros correspondentes. Assim, tem-se um valor de erro para cada neurônio da camada escondida que representa uma medida da influência da cada neurônio no erro da camada de saída.
- 3) Os erros da camada intermediária são utilizados para o ajuste dos seus pesos, analogamente ao procedimento descrito anteriormente.

$$\frac{\partial E}{\alpha_{jk}} = \frac{1}{Z} \sum_{v=1}^Z \frac{\partial E}{\partial Y_i} \frac{\partial Y_i}{\partial \sigma_j} \frac{\partial \sigma_j}{\partial \alpha_{jk}} \quad (3.13)$$

Como a correção dos pesos da camada intermediária depende dos novos erros propagados pela última camada, a camada de saída é calculada por:

$$\frac{\partial E}{\alpha_{jk}} = -\frac{1}{Z} \sum_{v=1}^Z (Y_{id} - Y_i) f'(\sum_{j=1}^{N_i} \sigma_j \cdot \omega_{ij}) \omega_{ij} f'(\sum_{k=1}^{N_e} X_k \cdot \alpha_{ij}) X_k \quad (3.14)$$

Com base nas derivadas, a correção dos pesos é efetuada pela seguinte expressão:

$$\alpha_{jk}^{novo} = \alpha_{jk}^{velho} - \mu \frac{\partial E}{\alpha_{jk}} \quad (3.15)$$

Uma vez ajustados os pesos, conclui-se o ajuste dos pesos de toda a rede para o vetor de entrada  $\mathbf{X}$  e sua saída desejada  $Y_{id}$ . Após a fase de treinamento, na qual a variação dos erros é mínima, a rede passa para as etapas de validação e generalização. Na validação a rede é processada com conjuntos de dados já conhecidos.

No caso da generalização, a rede passa a ter os dados de entrada diferentes dos que foram fornecidos em seu treinamento, ou seja, dados ainda desconhecidos, uma vez que esta já "aprendeu" como deve ser seu comportamento. Deste modo, ela está apta a ser aplicada no problema em questão.

As redes de Múltiplas Camadas podem apresentar variações no algoritmo *backpropagation*. Essas variações acontecem na etapa da correção ou ajustes dos pesos, e dão nome a outros algoritmos, como é o caso do algoritmo *Levenberg-Marquardt backpropagation*. Este último desenvolve os passos mostrados anteriormente, substituindo as equações (3.12 e 3.15) pela Equação (3.16), esta última generalizada para todas as camadas.

O *Levenberg-Marquardt backpropagation* é um dos algoritmos de otimização mais utilizados superando outros algoritmos em uma grande variedade de problemas, no entanto demanda grande quantidade de memória computacional para sua realização.

A regra de ajuste de pesos é baseada no método de Newton e se dá pela seguinte equação:

$$\varphi^{Novo} = \varphi^{velho} - (\mathbf{H} + \mu\mathbf{I})^{-1}\nabla E \quad (3.16)$$

Onde  $\varphi$  representa os pesos,  $\mathbf{H}$  a matriz Hessiana,  $\nabla E$  o gradiente do erro (mostrado na Equação 3.9) e  $\mu$  um fator de ajuste.

### **3.4 Rede Mapa auto-organizável ou *Self Organing Maps* (SOM)**

Redes Neurais Artificiais (RNAs) por aprendizado não supervisionado são sistemas formados por algoritmos que buscam associar padrões ou características significativas em conjuntos de dados de entrada, sem a presença de um agente controlador externo.

Dentre os algoritmos auto organizáveis, é descrito neste item os Mapas auto-organizáveis (*Self-Organizing Maps* - SOM) ou mapas de Kohonen, desenvolvidos por Teuvo Kohonen, na década de 1980. Trata-se de um tipo de modelo artificial de rede mais aproximado do comportamento neurofisiológico humano, que possui áreas responsáveis por funções específicas. Baseia-se no mapa topológico do córtex cerebral, uma vez que neurônios localizados em uma determinada área são responsáveis por estímulos semelhantes.

Por terem a capacidade de resolver problemas não lineares de alta dimensão, as redes SOM têm uma vasta área de aplicação como, por exemplo, engenharias, medicina, economia, etc.

Assim como nos outros tipos de redes neurais, o mapa de Kohonen é formado por unidades básicas chamadas de neurônios artificiais. Estas unidades são organizadas de modo que, por meio de ligações entre si, estabelecem uma estrutura em forma de rede (Figura 3.10). De camada única, contendo neurônios totalmente conectados, cujas saídas são organizadas em uma, duas ou três dimensões, este tipo de modelo de rede tem comportamento linear e seu aprendizado é não supervisionado.

A grade bidimensional tem a forma de uma superfície plana, onde os neurônios estão organizados em linhas e colunas. A Figura 3.11 ilustra uma rede SOM típica, na qual os neurônios estão representados pelas unidades verdes, o neurônio que dá início ao processamento (vencedor da competição, o que apresenta maior similaridade com os padrões de entrada) e sua vizinhança estão representados pelas cores amarela e branca, respectivamente. As unidades na cor rosa representam os padrões de entrada da rede e as ligações, em vermelho, simbolizam as conexões entre os neurônios.

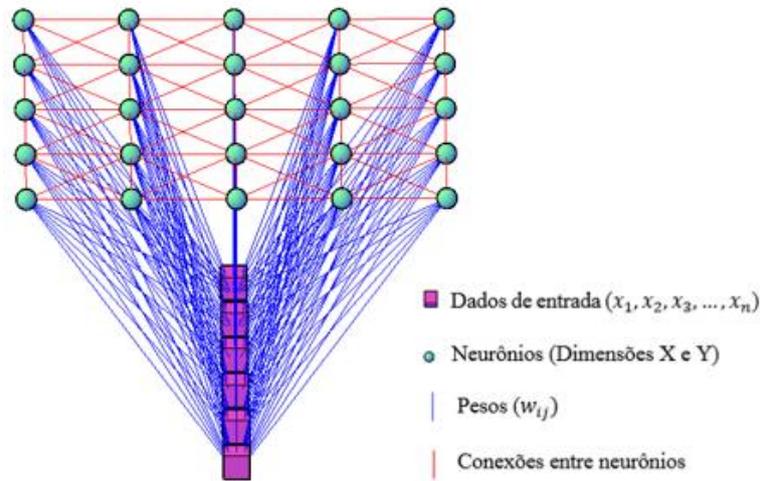


Figura 3.10 - Estrutura de um SOM.

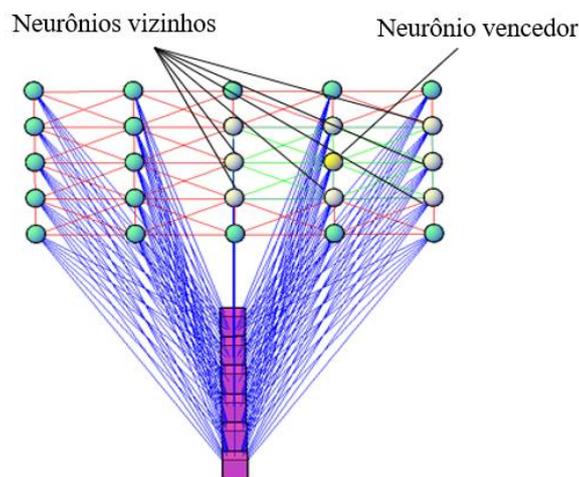


Figura 3.11 - Estrutura do mapa de Kohonen com unidade vencedora.

Por não precisar de saídas preliminares para seu treinamento, um dos princípios da utilização dos modelos auto-organizáveis para problemas de reconhecimento de padrões, é o de que padrões que compartilham características comuns devem ser agrupados nas mesmas ou em regiões próximas. Esse agrupamento é possível devido à redundância dos dados de entrada, uma vez que o algoritmo de treinamento busca encontrar características significativas nos conjuntos de informações de entrada, e, assim, dar origem às classes ou clusters.

### 3.4.1 Treinamento dos *Self Organizing Maps*

Como nos outros tipos de RNAs, para um funcionamento adequado, os algoritmos passam por um treinamento prévio (aprendizado) que pode ser classificado como aprendizado competitivo e Hebbiano, sendo o primeiro foco do estudo. Nestes casos, ele pode ser dividido, basicamente, em quatro etapas: inicialização, processo competitivo, cooperativo (conceito de vizinhança) e a adaptação, Bullinaria (2004).

De início, são atribuídos valores aleatórios aos pesos e a rede é, então, inicializada. A fase de competição consiste em analisar, por meio de uma função predefinida e dos padrões de entrada, as saídas de cada neurônio, de modo que a unidade que apresenta o maior valor de ativação é declarada como o neurônio vencedor.

Uma vez definida a unidade vencedora, o algoritmo passa para os processos de cooperação e adaptação, isto é, para a definição das unidades vizinhas e para atualização dos seus respectivos pesos (Figura 3.11). Na cooperação, a unidade vencedora busca determinar a localização espacial de uma vizinhança topológica dos neurônios excitados, de modo a aumentar os valores individuais do conjunto, e, assim, passar para o ajuste dos seus respectivos pesos sinápticos, a qual é nomeada como a fase de adaptação.

#### **Processo competitivo**

A primeira etapa, propriamente dita do treinamento da rede, tem início com a apresentação de um vetor simbolizando um determinado padrão de entrada  $\mathbf{x}$ , bem como o vetor de pesos sinápticos  $\mathbf{w}$  de um neurônio  $j$ . O vetor de pesos de cada neurônio tem a mesma dimensão do espaço de entrada e  $l$  representa o número de neurônios na grade Haykin (2001). Assim:

$$\mathbf{x} = [x_1, x_2, \dots, x_m]^T \quad (3.16)$$

$$\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, \quad j = 1, 2, \dots, l \quad (3.17)$$

O critério utilizado para determinar o neurônio vencedor  $i(x)$ , isto é, o vetor de entrada  $\mathbf{x}$  que mais se aproxima do vetor de pesos sinápticos, é o cálculo da mínima distância Euclidiana entre os vetores  $\mathbf{x}$  e  $\mathbf{w}_j$ .

$$i(x) = \operatorname{argmin} \|\mathbf{x} - \mathbf{w}_j\|, \text{ para } j = 1, 2, \dots, l \quad (3.18)$$

Deste modo, “um espaço de entrada contínuo de padrões de ativação é mapeado em um espaço de saída discreto de neurônios, por meio de um processo de competição entre neurônios.” Castro e Castro (2013).

Esquemáticamente, este passo pode ser representado como mostra a Figura 3.12. A partir de um vetor de entrada  $x$ , identifica-se o neurônio vencedor  $i(x)$  que apresente uma maior similaridade com o espaço de saída, de acordo com o mapa de características  $\Phi$ . Assim, o vetor de pesos sinápticos  $w_i$  do neurônio vencedor, funciona como um ponteiro do vetor no espaço de entrada  $\mathcal{A}$ , ou seja, os elementos sinápticos do vetor  $w_i$  podem ser vistos como as coordenadas da imagem do neurônio  $i$  projetado no espaço de entrada.

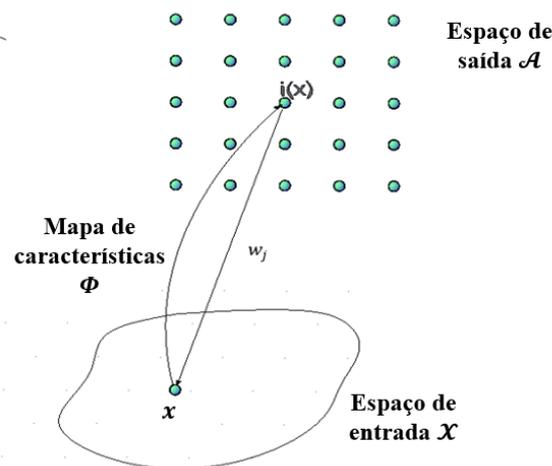


Figura 3.12 Vetor vencedor. Haykin (2001) – Adaptada.

### Processo Cooperativo

Na cooperação, a unidade vencedora ( $i$ ) busca determinar a localização espacial de uma vizinhança topológica de neurônios, uma vez que existem evidências neurobiológicas que há interação lateral entre neurônios biológicos excitados, como também que tal interação diminui com o aumento da distância entre as células do sistema nervoso humano.

Deste modo, para os sistemas artificiais, a vizinhança topológica ( $h_{j,i}$ ) é definida por uma função unimodal que satisfaça dois requisitos (Castro e Castro, s.d.):

1 – A vizinhança topológica ( $h_{j,i}$ ) é simétrica ao redor do ponto máximo definido por  $d_{i,j} = 0$ . Assim, seu valor máximo localiza-se no neurônio vencedor  $i$ .

2 – A amplitude da vizinhança topológica decresce monotonicamente com o aumento da distância lateral ( $d_{i,j}$ ), decaindo para zero quando  $d_{i,j} \rightarrow \infty$ ; condição necessária para a convergência.

Por atender às duas condições mencionadas anteriormente, Haykin (2009) sugere a função gaussiana, definida pela Equação (3.19)

$$h_{i,j}(x) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2}\right) \quad (3.19)$$

Onde  $d_{i,j}$  é a distância entre o neurônio  $j$  e o vencedor  $i$ , e  $\sigma$  é a largura da vizinhança topológica, que encolhe com o tempo (Figura 3.13).

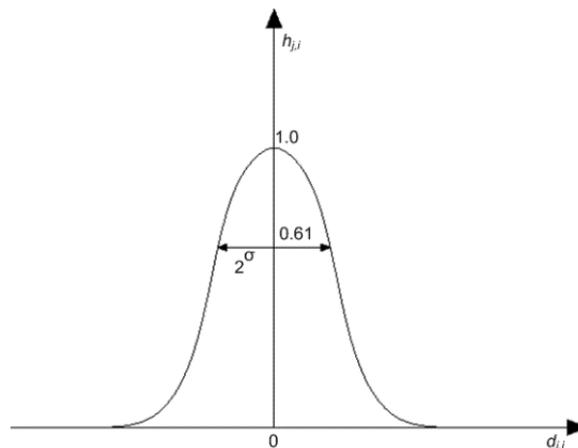


Figura 3.13 - Função de vizinhança Gaussiana.

A vizinhança pode ser definida considerando áreas quadradas, hexagonais ou de largura variável, no entanto, algumas funções têm apresentado convergência mais rápida ou não, dependendo da configuração escolhida (Figura 3.14).

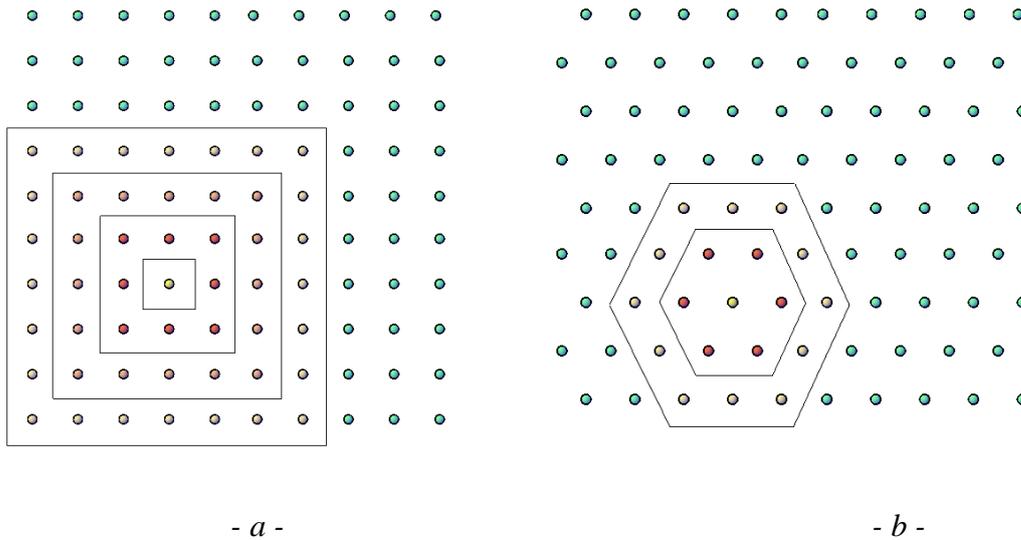


Figura 3.14 Representações das Etapas Competitiva e Cooperativa de treinamento do Som. -a- Configuração quadrada; - b - Configuração hexagonal (Vesanto, 2000), adaptado.

Considerando que o tamanho da vizinhança tende a diminuir com o tempo  $n$  (número de iterações), a largura  $\sigma$  deve decrescer com o tempo. Assim, para estabelecer a dependência de  $\sigma$  com o tempo discreto  $n$ , aplica-se o decaimento exponencial.

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_1}\right); t = 0, 1, 2, \dots \quad (3.20)$$

Onde  $\sigma_0$  é o valor de  $\sigma$  na inicialização do algoritmo SOM e  $\tau_1$  uma constante do tempo. Deste modo, a vizinhança topológica passa a ser definida por uma variante do tempo, Equação 3.21.

$$h_{j,i(x)}(t) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(t)}\right); n = 1, 2, \dots \quad (3.21)$$

Tal formulação leva à interpretação de que à medida que a largura diminui, há também uma redução no número de neurônios cujas direções de atualização estão correlacionadas. Assim, recomenda-se, durante o treinamento do SOM, trabalhar com valores normalizados, a fim de evitar desperdícios dos recursos computacionais.

## Processo adaptativo

A etapa de adaptação consiste na atualização dos pesos sinápticos do neurônio vencedor, bem como da sua vizinhança, de modo a se aproximarem dos valores do padrão de entrada. A atualização baseia-se na seguinte formulação:

$$w_j(t + 1) = w_j(t) + \eta(t)h(t) (x(t) - w_j(t)) \quad (3.22)$$

$$\eta(t) = \eta_0 \exp\left(-\frac{\eta}{\tau_2}\right); t = 1, 2, \dots \quad (3.23)$$

Onde  $\eta(t)$  e  $h(t)$  representam a taxa de aprendizado, que decresce com o tempo, e a função de vizinhança em torno do neurônio vencedor  $i(x)$ , respectivamente.

É possível, ainda, dividir o processo adaptativo em duas fases distintas: a ordenação e a convergência. Durante a primeira, ocorre a ordenação topológica dos pesos sinápticos. Nesta etapa devem-se escolher a taxa de aprendizado e a função de vizinhança observando critérios com:

- Valor inicial de 0,01 para a taxa de aprendizado ( $\eta$ );
- Inicialmente, o raio da função de vizinhança deve se estender por uma grande parte dos neurônios;

Já na fase de convergência, por se tratar de um ajuste fino do mapa, a função de vizinhança deve conter apenas os neurônios vizinhos mais próximos do vencedor.

O algoritmo SOM pode ser resumido em 5 etapas segundo (Haykin, 2009).

1. **Inicialização:** escolha dos pesos sinápticos de todos os neurônios  $w_j(0)$  usualmente a inicialização é feita de modo aleatório;
2. **Amostragem:** Um vetor  $x$  é extraído do espaço de dados de entrada, que representa o padrão de ativação aplicado.
3. **Determinação do neurônio vencedor:** determina-se o neurônio vencedor (*best-matching neuron*) no tempo discreto  $n$ , por meio da mínima distância Euclidiana. Essa etapa corresponde ao processo de competição;

$$i(x) = \operatorname{argmin} \|x - w_j\|, \text{ para } j = 1, 2, \dots, l \quad (3.24)$$

4. **Atualização:** os pesos sinápticos do neurônio vencedor e de seus vizinhos são atualizados. Corresponde ao processo adaptativo;

$$w_j(t + 1) = w_j(t) + \eta(t)h(t) \left( x(t) - w_j(t) \right) \quad (3.25)$$

5. **Continuação:** Retorna-se ao passo 2 e continua-se o procedimento até que não sejam observadas mudanças consideráveis no mapa.

### 3.5 Learning Vector Quantization (LVQ)

O *Learning Vector Quantization* (LVQ) é uma técnica de aprendizado supervisionado e competitivo, subsequente à RNA SOM, também proposta por Kohonen e descrita anteriormente.

A técnica faz uso das informações de cada classe de dados para realizar a movimentação dos vetores de peso, buscando melhorar a qualidade das regiões de decisão do classificador (Haykin, 1999); em outras palavras, o LVQ pode utilizar o mapa auto-organizável treinado pelo algoritmo SOM de modo a delimitar mais claramente as fronteiras das classes de dados (Figura 3.15).

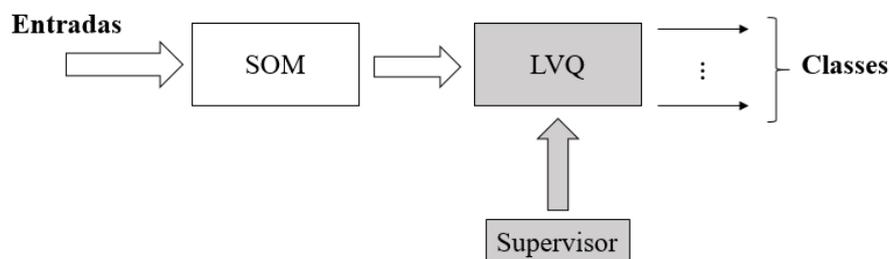


Figura 3.15 Esquema do LVQ.

Assim com a rede SOM, a arquitetura da LVQ é composta por duas camadas principais: formada por duas camadas principais, a competitiva e a linear. Na primeira (competitiva), como o próprio nome já diz, acontece, por competição, a classificação dos padrões de entrada em classes. Esse processo de competição acontece em função da proximidade entre os valores dos vetores contendo os padrões de entrada e o de pesos. Já na segunda parcela do algoritmo, a camada linear, há a transformação das classes da camada competitiva em classificações de destino definidas pelo usuário.

Esta RNA apresenta valor fixo igual a 1 para os pesos das conexões entre a camada competitiva e a camada de linear e valores binários (0 e 1) como saída dos neurônios da camada linear e saída da rede.

Por ser supervisionado, o algoritmo LVQ pode, após o treinamento da rede SOM, avaliar a classificação gerada pela rede para cada padrão. Nesta avaliação, o algoritmo LVQ ajusta os pesos para melhorar a classificação obtida. Assim, os principais passos do algoritmo estão descritos a seguir:

Seja um vetor com padrões de entrada para o treinamento da rede  $x_i$  ( $i = 1, \dots, n$ ) ligado à camada competitiva pelo vetor de pesos aleatórios  $w_i$  ( $i = 1, \dots, m$ ).

Sendo  $y_i$  ( $i = 1, \dots, t$ ) o vetor de classes associadas ao vetor com os dados de entrada  $x_i$ , o algoritmo LVQ é descrito, segundo Haykin (1999) por:

1. **Inicialização:** escolha dos pesos sinápticos de todos os neurônios  $w_j(0)$  usualmente a inicialização é feita de modo aleatório;
2. **Amostragem:** Um vetor  $x$  é extraído do espaço de dados de entrada, que representa o padrão de ativação aplicado.
3. **Determinação do neurônio vencedor:** determina-se o neurônio vencedor (*best-matching neuron*) no tempo discreto  $n$ , por meio da mínima distância Euclidiana. Essa etapa corresponde ao processo de competição;

$$i(x) = \operatorname{argmin} \|x - w_j\|, \text{ para } j = 1, 2, \dots, l \quad (3.26)$$

4. **Atualização:** os pesos sinápticos do neurônio vencedor e de seus vizinhos são atualizados.

$$w_j(t+1) = \begin{cases} w_j(t) + \eta(t)(x(t) - w_j(t)), & \text{classe correta} \\ w_j(t) - \eta(t)(x(t) - w_j(t)), & \text{classe incorreta} \end{cases} \quad (3.27)$$

Durante o processo de aprendizagem, o LVQ atualiza os pesos das sinapses do neurônio vencedor de acordo com sua classificação. Caso o dado de entrada e o neurônio de saída pertençam à mesma classe, então as referidas sinapses são atualizadas

de modo a aproximar o neurônio vencedor do dado de entrada; caso contrário, o neurônio é afastado.

Esquemáticamente, este processo pode ser ilustrado conforme Figura 3.16.

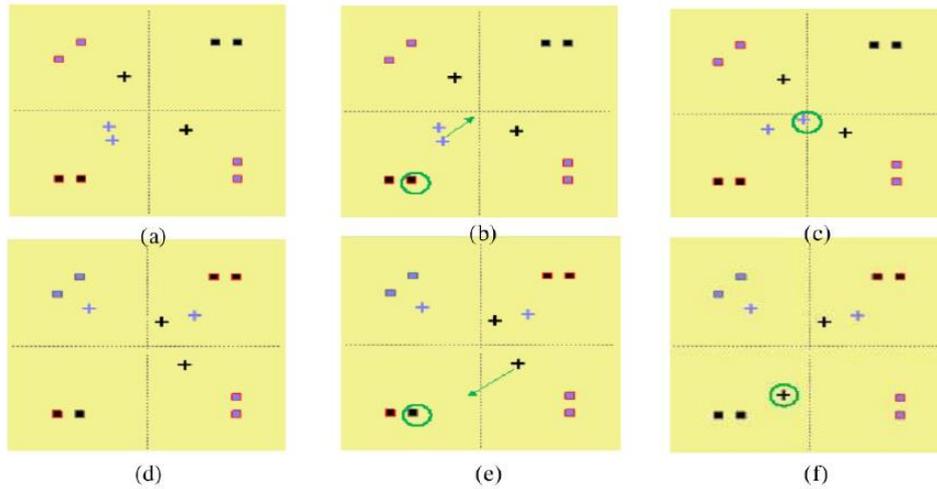


Figura 3.16 – Processo de aprendizagem da rede LVQ (Rocha,2012)

Na Figura 3.16 (a) observa-se a configuração da rede, na qual os quadrados são dados de entrada (vetores de entrada) e as cruzes representam os vetores com unidades de saída, nos quais, as cores preta e azul simbolizam as classes 1 e 2, respectivamente. Na figura (b) o dado circulado é apresentado à rede, de modo que, sendo sua classificação incorreta, a unidade de saída que o classificou é afastada do dado. Após a aprendizagem, o vetor da unidade de saída se coloca em uma nova posição, gerando uma nova configuração da rede, conforme se observa nos quadros (c) e (d), respectivamente, Rocha (2012).

Já os quadros (e) e (f) retratam a classificação correta dos dados seguindo da nova configuração da rede, respectivamente. No primeiro, o dado circulado é apresentado à rede e, sendo correta sua classificação, a unidade de saída que o classificou é atraída na direção e no sentido do dado. No último quadro verifica-se que, uma vez realizada a aprendizagem, o vetor de saída é posicionado próximo ao dado.

Um fator importante no processo de aprendizagem é que as atualizações ocorrem em função da taxa de aprendizado e da distância Euclidiana, deste modo, é desejável que a taxa de aprendizagem decresça monotonamente com o número de iterações, permitindo que no início do treinamento os movimentos dos vetores sejam maiores,

aumentando a exploração do espaço de entrada dos dados e, para o final, os movimentos sejam menores, caracterizando um ajuste melhorado da sua posição.

Como critério de parada para o algoritmo LVQ pode se utilizar o número máximo de iterações, um valor mínimo para a taxa de aprendizagem ou o erro (distância) calculado entre os vetores, entre outros.

Observa-se, portanto que as redes SOM e LVQ têm bastante semelhanças nos passos dos seus algoritmos. O que difere é, essencialmente, a rotulação feita no LVQ pelo “supervisor”, fator este inexistente em aprendizados não supervisionados.

## 4. FERRAMENTAS COMPUTACIONAIS

Este trabalho tem como objetivo a detecção/localização de danos em estruturas. No entanto por utilizar uma ferramenta desenvolvida computacionalmente, para a modelagem das Redes Neurais Artificiais (RNAs) foi utilizado o *software* Matlab (MathWorks, 2015).

Trata-se de um pacote computacional que dispõe de várias bibliotecas ou *toolboxes* para aplicações específicas de diversas áreas do conhecimento como, por exemplo, os pacotes RNAs, Lógica *Fuzzy*, Otimização de Sistemas, *Wavelets*, entre outras. Além dessas vantagens, o programa proporciona uma linguagem de programação de fácil entendimento para o desenvolvimento de códigos computacionais.

Nesse sentido, baseado nas equações e teorias descritas no capítulo anteriores, este capítulo descreve as etapas computacionais desenvolvidas para o uso das RNAs aplicadas no desenvolvimento desta pesquisa.

Dentre os diversos pacotes inseridos no Matlab, o *Neural Network Toolbox*™ fornece ferramentas para execução, visualização e simulação de Redes Neurais Artificiais (RNAs) em diferentes configurações, sejam elas no modo de aprendizado, no algoritmo utilizado para o seu treinamento, na maneira de processar os dados, bem como nas funções de ativação utilizadas.

O pacote suporta diferentes tipos de redes, o que o torna capaz de ser utilizado em diversas áreas da ciência, bem como em diferentes tipos de problemas como, por exemplo, dados de montagem, reconhecimento de padrões, agrupamento de séries temporais, previsão, modelagem do sistema dinâmico e controle, etc.

Como já mencionado anteriormente, a utilização de uma rede neural passa, basicamente, por três processos: o treinamento, a validação e a generalização. Por se tratar de um pacote que contém internamente os algoritmos *Backpropagation*, *Self Organizing Maps* (SOM), *Learning Vector Quantization* (LVQ), entre outros, o *Neural Network Toolbox* realiza as referidas etapas automaticamente, ficando como função do usuário apenas a tarefa de definir e fornecer os dados a serem usados em cada uma das fases (treinamento, validação e generalização), bem como funções, números de neurônios, taxa de aprendizados, entre outros parâmetros das redes.

Para acessar o pacote, é necessário, primeiramente, definir os dados de cada etapa, isto é, declarar quais os conjuntos de informações (padrões) do treinamento e da validação, e, no caso, da generalização, os dados de entrada. As informações devem ser agrupadas em forma de matrizes e, nas etapas de treinamento e validação das redes com aprendizado supervisionado, os dados de entrada devem ser organizados com suas respectivas saídas para que, assim, a rede possa identificar as relações matemáticas existentes entre tais informações.

De maneira geral, por precisarem de entradas e saídas, os algoritmos das RNAs supervisionadas seguem as etapas mostradas no fluxograma da Figura 4.1. É possível observar as fases iniciais já mencionadas, bem como o procedimento de apresentação dos dados.

Após essa primeira fase, são escolhidos os parâmetros da rede, entre os quais estão o tipo de algoritmo, número de neurônios, funções de ativação, taxa de aprendizado e número de iterações etc, e dá-se o início do treinamento.

Durante a fase de treinamento das RNAs, o algoritmo busca estabelecer uma relação entre os dados utilizados como padrões de treinamento, estimar os erros dessa relação e, caso estejam dentro de uma faixa aceitável, passa-se, então, para a fase de validação. Nesta etapa, são fornecidos outros conjuntos de dados (não utilizados no treinamento) para avaliar o comportamento da rede já treinada. Por fim, a rede é testada com as informações do problema ao qual busca-se solução.

Por fim, o pacote oferece possibilidade de gráficos para os resultados do processamento, bem como do acompanhamento de cada etapa, como está sintetizado na Figura 4.1.

No caso das redes não supervisionadas, ao invés do treinamento buscar estabelecer uma relação entre os dados de entrada e saída, o algoritmo da RNA agrupa os padrões fornecidos como *inputs* com base em parâmetros estatísticos e redundâncias das informações.

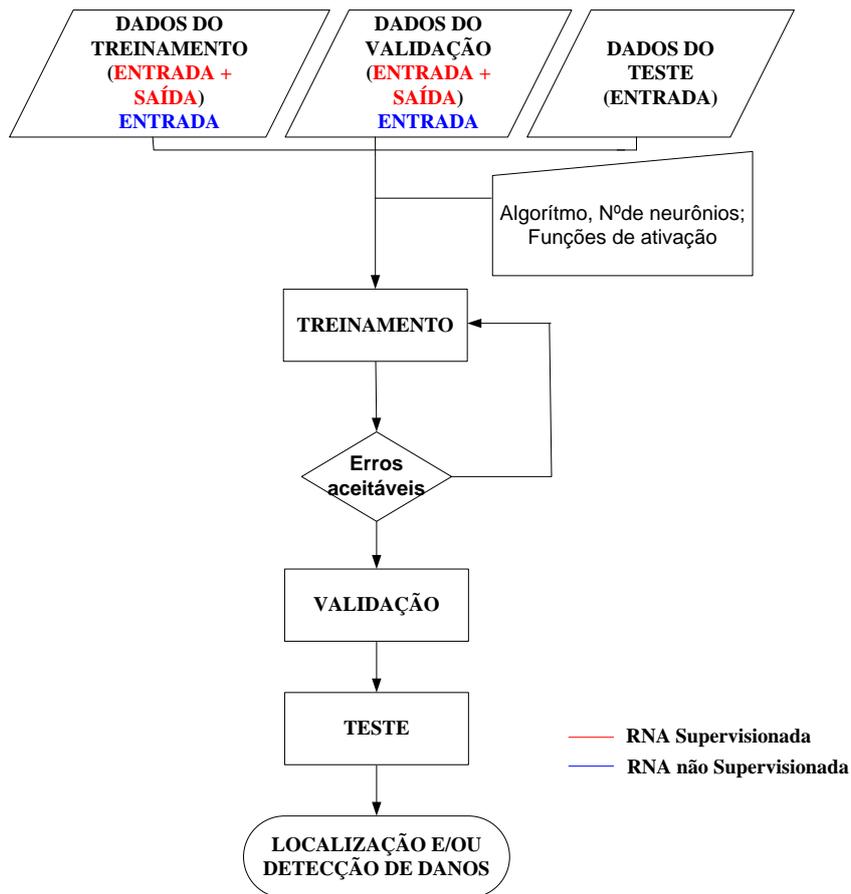


Figura 4.1 – Etapas do algoritmo de uma RNA.

O pacote *Neural Network Toolbox* contém as funções específicas para cada etapa já mencionada, para cada tipo de RNA, podendo ser acessado de duas maneiras distintas: a primeira é utilizando a função *nntool* e permitindo o acesso direto a uma janela com interface gráfica com os diferentes tipos de redes e seus respectivos parâmetros a serem definidos (Figura 4.2). Apesar de apresentar mais facilidades ao usuário, esta maneira utiliza algumas funções internas por *default*, não permitindo a variação de alguns parâmetros da rede (algoritmo interno, funções de ativação, taxa de aprendizado, etc.).

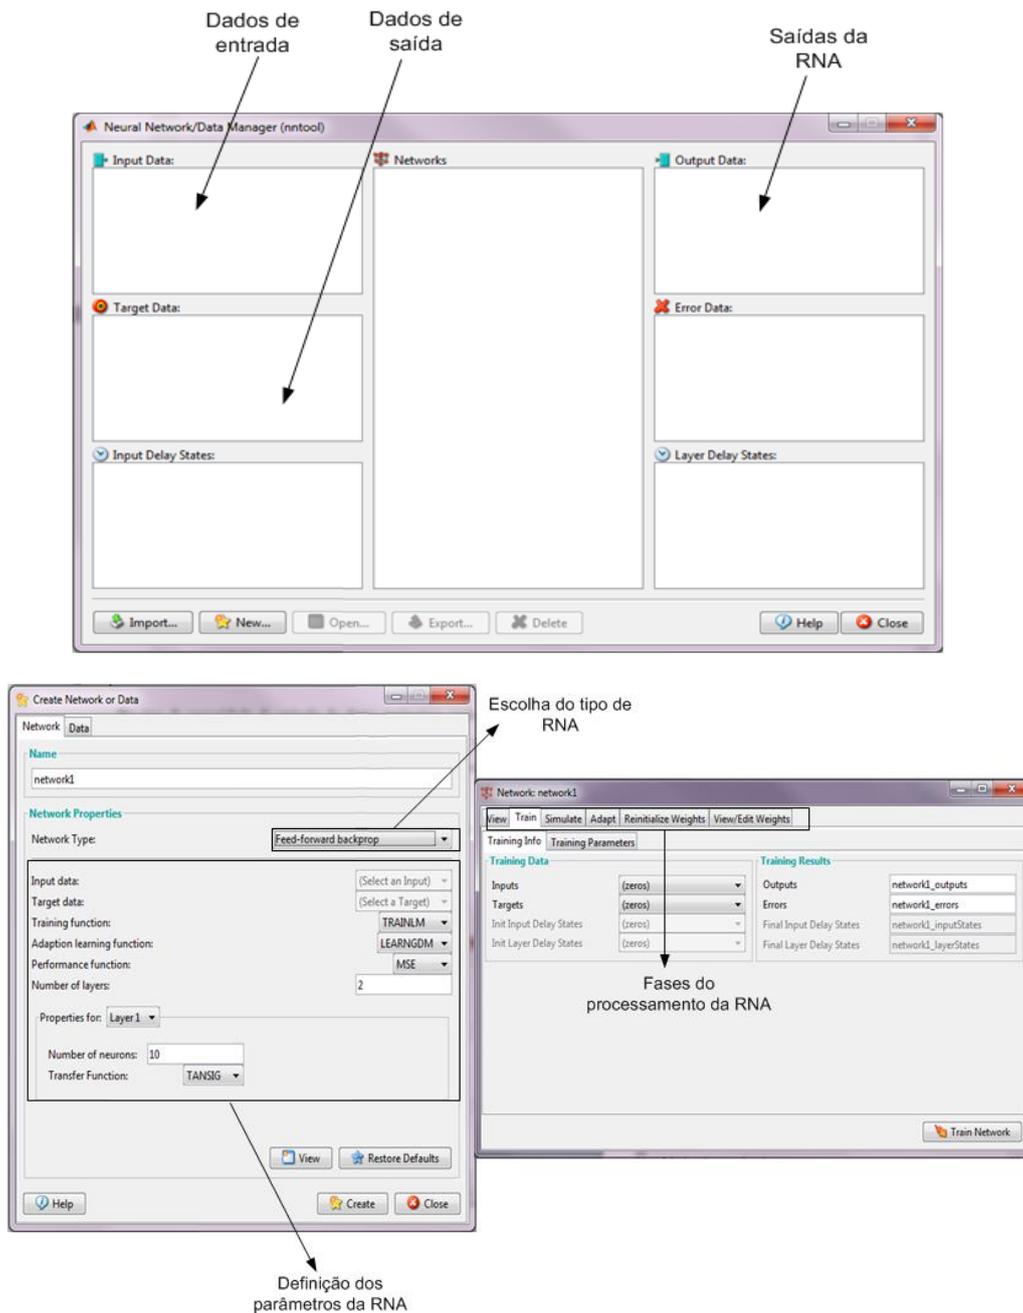


Figura 4.2 – Função *nntool* do pacote *Neural Network Toolbox*.

A referida *toolbox* oferece, ainda, diversas possibilidades de gráficos para as diferentes fases que fazem parte do processamento da RNA, dentre os quais estão: a performance, regressão dos dados, histograma de erros, entre outros.

Diante da necessidade de variação de alguns parâmetros, pode-se optar pela segunda opção de acesso ao pacote. Esta alternativa trata-se da criação do código da rede, isto é, utilizar as funções predefinidas pelo *software* e definir os critérios da rede. Neste trabalho foram utilizadas as duas abordagens, deste modo seguem, nos próximos

parágrafos, algumas explicações acerca das funções específicas para o desenvolvimento das rotinas computacionais.

No caso da *Backpropagation*, a inicialização de uma rede é feita pela função *newff*, segundo a versão do Matlab 2009. Esta função é responsável pela determinação das características da RNA, e é a partir dela que são definidos o tipo de rede, o algoritmo, o número de camadas, de neurônios e as funções de ativação. A Figura 4.3 mostra a estrutura da referida função.

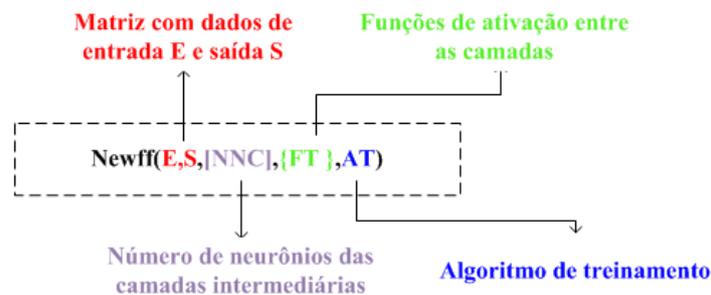


Figura 4.3 Estrutura da função Newff.

A rede é iniciada e treinada através das funções *init* e *train*, respectivamente (Figura 4.4). Nesta etapa o processamento interno do Matlab define, através do algoritmo selecionado, os padrões da rede, bem como a relação existente entre os dados de entrada e saída. Deste modo, por meio de um algoritmo de iteração por tentativa e erros, os pesos são definidos até que as iterações converjam a erros aceitáveis para o problema em questão.

Após o treinamento, com os pesos já estabelecidos, a rede é submetida à validação e à generalização. Para a realização de tais etapas é usada a função *sim*, responsável pela simulação da referida RNA. A Figura 4.5 mostra como é feita sua sintaxe.

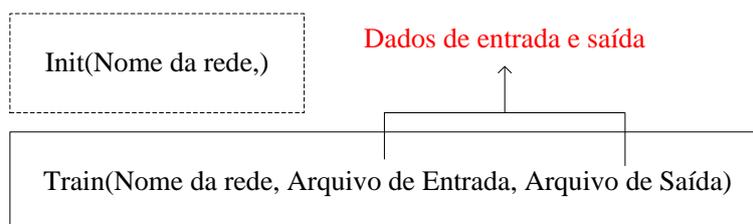


Figura 4.4 Funções Init e Train.

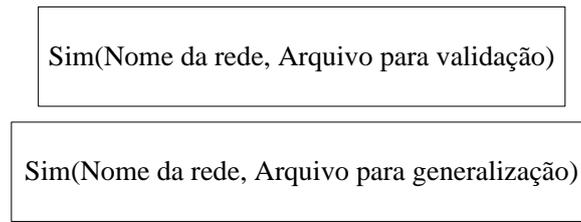


Figura 4.5 Função Sim.

Após todas as tarefas descritas acima, com o final do processamento da RNA, o código computacional encerra-se com a plotagem de gráficos que permitem a visualização da localização e da quantificação dos danos.

No caso da rede LVQ, o pacote contém funções com os mesmos objetivos, no entanto, específicas para este tipo de rede. A inicialização é feita por meio da função *lvqnet*, sendo esta responsável pela determinação de alguns parâmetros da rede como o número de neurônios na camada oculta, a taxa de aprendizado e o algoritmo de aprendizagem. A Figura 4.6 mostra como é a nomenclatura da função utilizando o Matlab 2015.

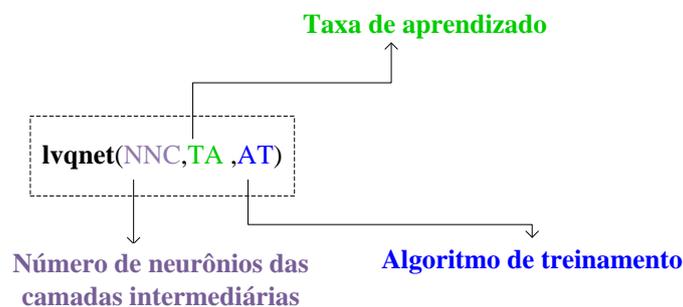


Figura 4.6 Função *lvqnet*.

As funções de treinamento e simulação seguem a mesma nomenclatura apresentada no caso da rede *Backpropagation* e são mostradas nas Figura 4.4 e Figura 4.5, respectivamente. Pela particularidade da rede em definir classes, pode também ser utilizada a função *vec2ind* para se conhecer em qual classe foi classificado cada padrão de entrada fornecido nas três principais etapas do algoritmo da rede.

No caso das redes tipo mapas auto-organizáveis, por terem algoritmos não supervisionados, a rede SOM apresenta algumas particularidades, uma vez que não têm dados de saídas durante o seu treinamento. Deste modo, para a criação deste tipo de

rede, é utilizada a função *selforgmap* e, da mesma maneira demonstrada anteriormente, realiza-se o treinamento e o teste da RNA por meio da função *train* e *sim*, respectivamente. A Figura 4.7 exibe a nomenclatura adotada pelo Matlab (2015).

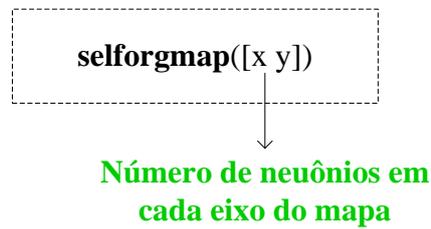


Figura 4.7 Função *selforgmap*.

O *Network Toolbox* fornece várias opções de gráficos para acompanhar o comportamento das etapas do algoritmo SOM. Entre as opções estão a topologia, que exibe o tipo de geometria utilizado no critério de vizinhança que permite identificar o neurônio vencedor.

Um segundo gráfico importante é a *U-matrix*, por representar as distâncias entre os neurônios vizinhos e os vetores de cada variável do padrão. O terceiro gráfico e, talvez o mais significativo, corresponde ao alojamento dos *clusters* no mapa dos SOM. Esta representação tem o nome de “*sample-hits*”, como pode ser observado na Figura 4.8.

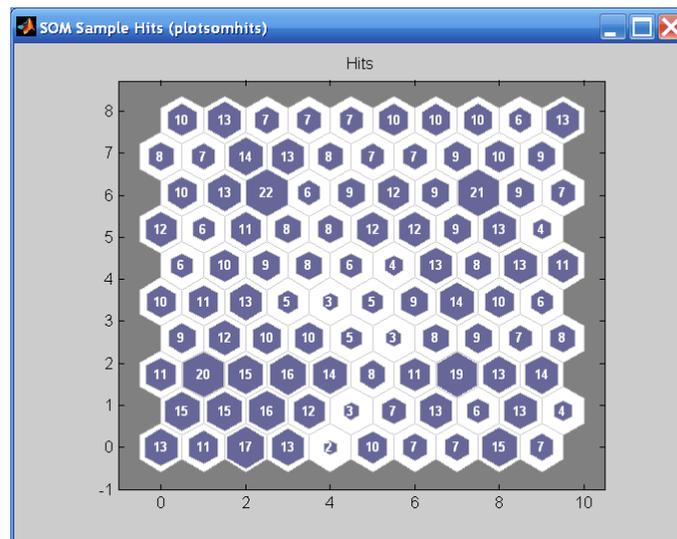


Figura 4.8 Gráfico *sample-hits*

É possível observar números nas figuras geométricas utilizadas como critério de vizinhança). Esses valores correspondem ao número de amostras classificadas com as mesmas características e agrupadas pelo algoritmo. Deste modo, para um conjunto de dados contendo diferentes classes de informações, o SOM agrupará essas informações de modo que serão notadas fronteiras entre esses grupos ou clusters.

Além das abordagens relacionadas ao uso do pacote *Neural Network Toolbox*, foi utilizada uma rotina computacional desenvolvida também no Matlab, a fim de processar os modelos numéricos da viga mencionada na seção 1 e obter suas propriedades dinâmicas.

Deste modo, baseado nas formulações para obtenção das frequências e dos seus respectivos modos de vibração, demonstradas no item 3.1, bem como na teoria de elementos finitos para soluções fundamentais de barras, a rotina é composta das sub-rotinas indicadas na Figura 4.9

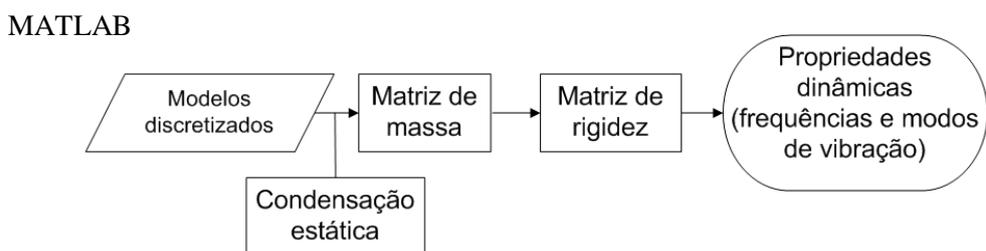


Figura 4.9 Rotinas computacionais para obtenção das propriedades dinâmicas.

A partir da discretização do modelo com todas as propriedades físicas e geométricas, são construídas suas matrizes de massa e rigidez considerando um sistema de coordenadas de referência local. Seguida desta etapa, a rotina passa para a montagem das referidas matrizes considerando um sistema de coordenadas global da estrutura.

A partir daí, por meio da função *eig*, própria do software, é solucionado o problema de autovalores e autovetores obtendo-se as características modais do modelo.

## **5. ANÁLISES EM MODELO REDUZIDO - VIGA**

Como mencionando, este trabalho tem como objetivo construir uma metodologia de identificação de danos estruturais baseada em Redes Neurais Artificiais (RNAs). Deste modo, inicialmente essa técnica foi aplicada a uma estrutura simples, uma viga metálica, construída no laboratório de estruturas da Universidade de Brasília, Brasiliano (2005), da qual se tinham resultados dela intacta e danificada.

Assim, considerando que para o funcionamento adequado das RNAs são necessários conjuntos de dados conhecidos (entradas e saídas) para serem utilizados durante a fase de treinamento da rede, foram desenvolvidos modelos numéricos baseados na viga, a fim de se obterem informações para o treinamento das RNAs. Para testar as redes foram usados os resultados da estrutura experimental danificada estudada por Brasiliano (2005).

### **5.1 Dados para treinamento e validação das redes neurais**

Com a finalidade de se obter as informações necessárias para o treinamento das RNAs, isto é, frequências e modos de vibração correspondentes às vigas com diferentes quadros de danificação, foram criados modelos numéricos baseados na viga de Brasiliano (2005). Essa viga foi construída em aço, com comprimento de 2,155 m e seção transversal U (Perfil U 101,6 x 4,67 – ASTM – A36) em condições de apoio livre-livre.

Inicialmente, foi modelada numericamente uma viga intacta com as mesmas características, servindo de referência. Esta foi discretizada em 33 elementos, cujas propriedades estão descritas na Tabela 5.1. Na Figura 5.1 é possível visualizar a viga experimental (a), as seções transversais dos elementos (b), bem como o modelo numérico construído (c).

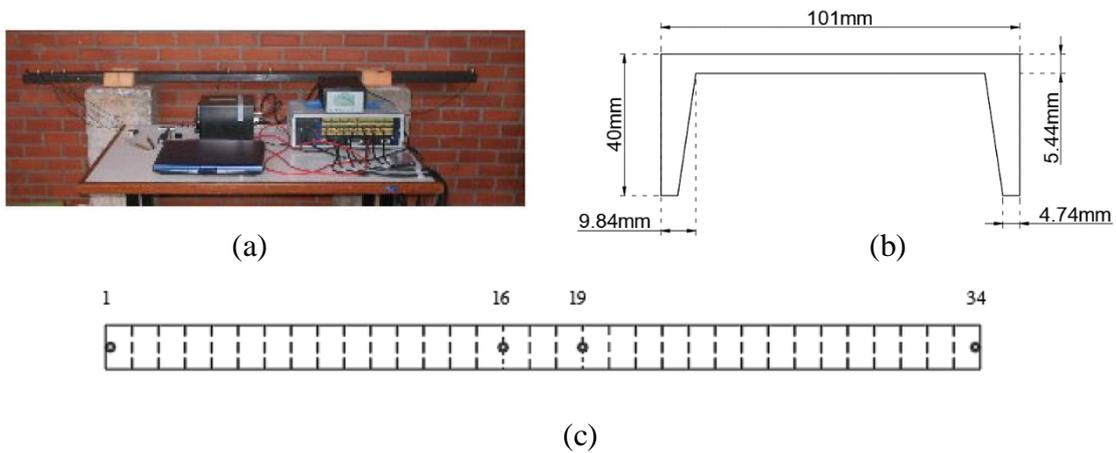


Figura 5.1 Viga estudada. (Modelo experimental (Brasiliano 2005)). (b) Seção transversal dos elementos. (c) Esquema dos modelos numéricos.

Tabela 5.1 Propriedades das vigas.

Propriedades	Valores
Momento de Inércia - I	$1,302 \times 10^{-7} \text{m}^4$
Área da Seção Transversal - A	$1,053 \times 10^{-3} \text{m}^2$
Módulo de Elasticidade Transversal - E	$2,07 \times 10^{11} \text{N/m}^2$
Massa Específica - $\rho$	$7850 \text{Kg/m}^3$
Comprimento - L	2,155m

Para a obtenção numérica das características dinâmicas, foi realizada uma condensação estática, e as matrizes de massa e rigidez de cada elemento foram obtidas através das Equações (5.1) e (5.2), respectivamente.

$$\mathbf{k} = \begin{bmatrix} \frac{12 EI}{L^3} & \frac{6EI}{L^2} & -\frac{12 EI}{L^3} & \frac{6EI}{L^2} \\ \frac{6EI}{L^2} & 4EI & -\frac{6EI}{L^2} & 2EI \\ \frac{12 EI}{L^3} & \frac{6EI}{L^2} & -\frac{12 EI}{L^3} & \frac{6EI}{L^2} \\ -\frac{12 EI}{L^3} & -\frac{6EI}{L^2} & \frac{12 EI}{L^3} & -\frac{6EI}{L^2} \\ \frac{6EI}{L^2} & 2EI & -\frac{6EI}{L^2} & 4EI \\ \frac{12 EI}{L^3} & \frac{6EI}{L^2} & -\frac{12 EI}{L^3} & \frac{6EI}{L^2} \end{bmatrix} \quad (5.1)$$

$$\mathbf{m} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (5.2)$$

Onde,

**k** e **m**: matrizes de rigidez e massa do elemento, respectivamente;

**M** e **K**: matrizes de massa e rigidez da estrutura, respectivamente;

E, I e L: Módulo de elasticidade, Momento de Inércia e comprimento do elemento, respectivamente;

As frequências e os modos de vibração obtidos do modelo estão apresentados na Tabela 5.2 e Figura 5.2, respectivamente.

Tabela 5.2 Frequências do modelo numérico intacto.

Frequências (Hz)	Numérica
1 <sup>a</sup>	43,5738
2 <sup>a</sup>	119,6105
3 <sup>a</sup>	233,3600
4 <sup>a</sup>	383,6388
5 <sup>a</sup>	790,1103

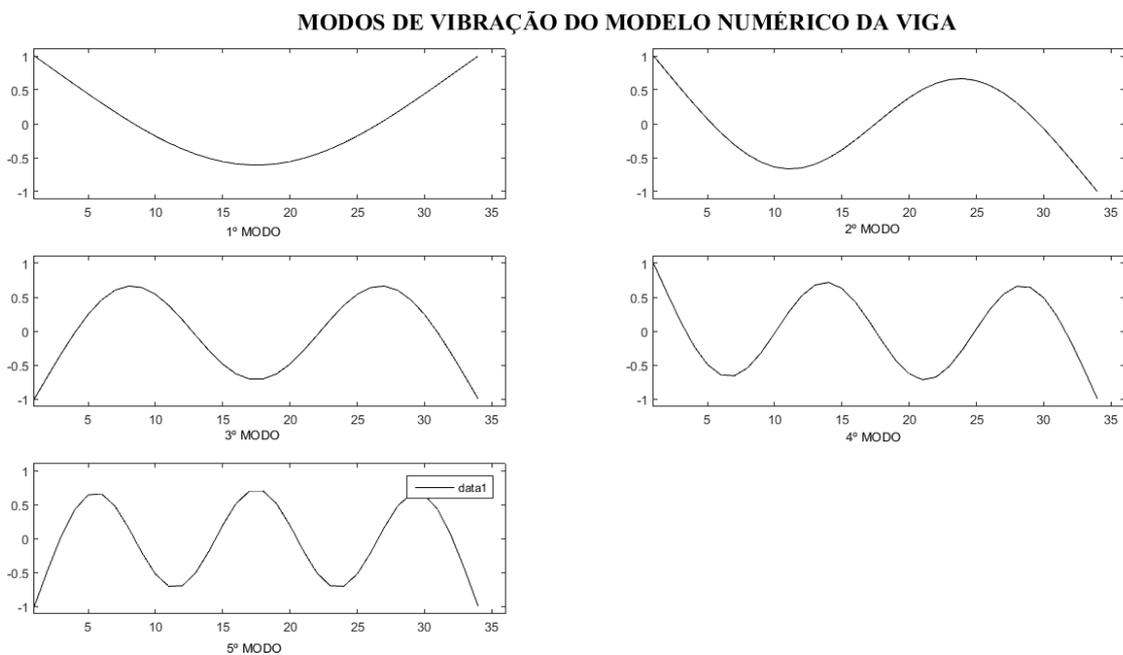


Figura 5.2 - Modos de vibração do modelo numérico.

A partir do modelo numérico intacto foram criados 32 modelos de viga com diferentes cenários de dano, ou seja, o dano estava presente em lugares e com diferentes intensidades, conforme Figura 5.3. Os elementos tinham as mesmas características físicas e geométricas descritas na Tabela 5.1, exceto os elementos danificados que tiveram a altura da sua seção transversal modificada.

Na Tabela 5.3 estão detalhados os 32 cenários danificados, nos quais as alturas das seções transversais foram modificadas para representar o máximo de situações possíveis de danos (Figura 5.4).

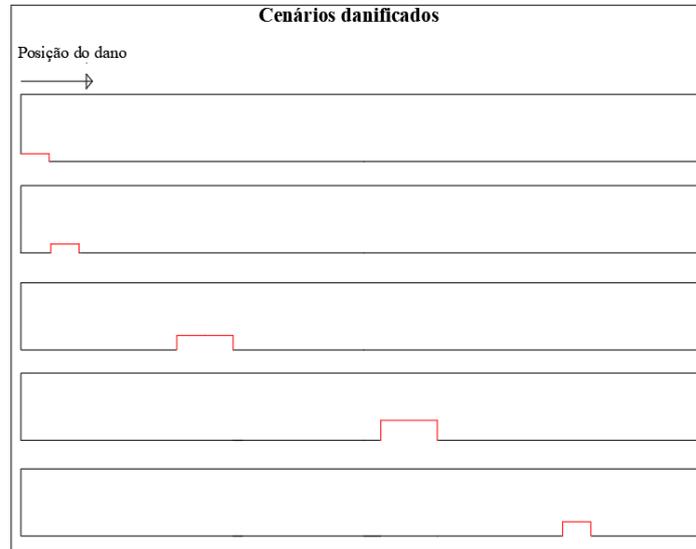


Figura 5.3 Esquema da construção dos modelos numéricos danificados. Em vermelho são as regiões com alturas reduzidas.

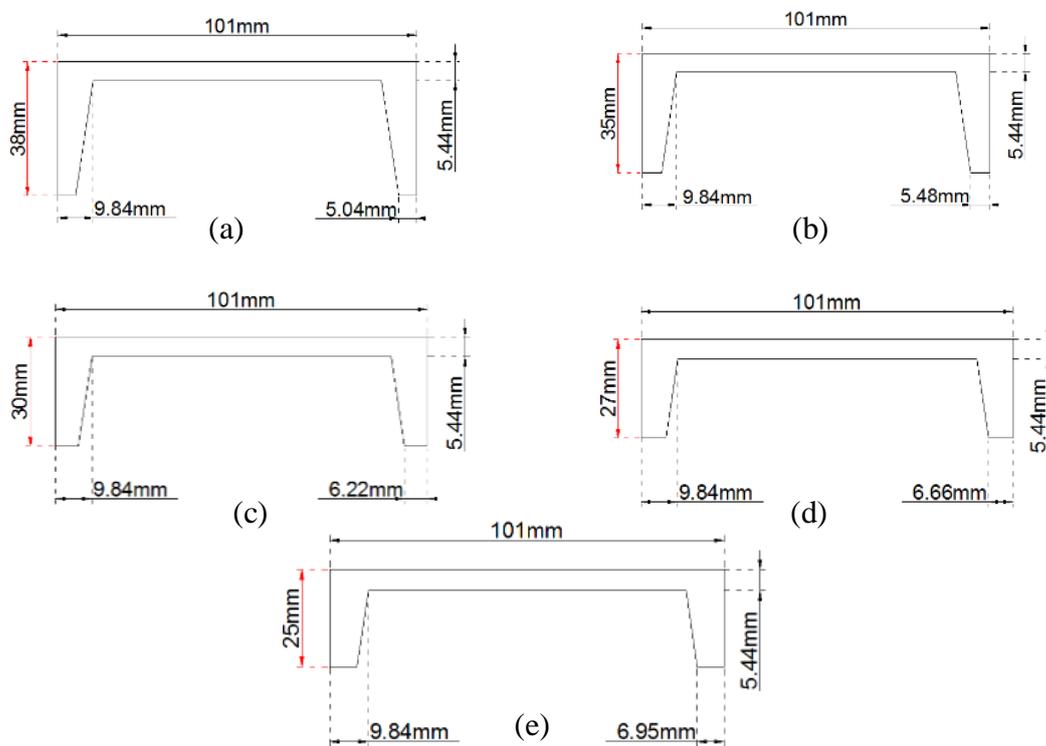


Figura 5.4 - Seção transversal dos elementos danificados. (a)  $h=38\text{mm}$ . (b)  $h=35\text{mm}$ . (c)  $h=30\text{mm}$ . (d)  $h=27\text{mm}$ . (e)  $h=25\text{mm}$ . ( $h$  = altura).

Tabela 5.3 Cenários de danos utilizados nos treinamentos das RNAs.

<i>Cenário</i>	<i>Elementos danificados</i>	<i>Altura da seção transversal do elemento (mm)</i>	<i>Dano (%)</i>
1	1 e 2	27	32,5
2	2 e 3	35	12,5
3	3 e 4	30	25
4	4 e 5	38	5
5	5, 6 e 7	25	37,5
6	7	30	25
7	8	35	12,5
8	9	38	5
9	10 e 11	35	12,5
10	12	25	37,5
11	12 e 13	30	25
12	13, 14 e 15	30	25
13	15 e 16	38	5
14	16	25	37,5
15	16, 17 e 18	27	32,5
16	18	27	32,5
17	18 e 19	35	12,5
18	20 e 21	25	37,5
19	21 e 22	27	32,5
20	22 e 23	38	5
21	24	30	25
22	24, 25 e 26	35	12,5
23	26	25	37,5
24	26 e 27	35	12,5
25	27, 28 e 29	38	5
26	29	30	25
27	29 e 30	35	12,5
28	30	38	5
29	30,31 e 32	25	37,5
30	32	27	32,5
31	32 e 33	30	25
32	33	27	32,5

Como esperado, a partir das simulações numéricas foi observado que as frequências e os modos de vibração dos diferentes modelos apresentaram variações em função da localização e da intensidade do dano, o que permitiu serem utilizados como padrões de entrada para treinar (cenários 1 - 29) e validar (cenários 30, 31 e 32) as redes neurais.

## 5.2 Dados para teste das redes neurais

Para testar as diferentes redes criadas com o objetivo de avaliar danos em estruturas, foram usados os resultados experimentais obtidos por Brasiliano (2005).

Para facilitar o ensaio experimental e compatibilizar resultados numéricos e experimentais, a autora dividiu a viga em 33 elementos, dos quais 31 tinham momento de Inércia ( $I$ ) de  $1,302 \times 10^{-7} \text{ m}^4$ , área da seção transversal ( $A$ ) com  $1,053 \times 10^{-3} \text{ m}^2$ , Módulo de elasticidade longitudinal ( $E$ ) igual a  $2,07 \times 10^{11} \text{ N/m}^2$ , massa específica de  $7850 \text{ kg/m}^3$  e comprimento de  $0,0653 \text{ m}$ .

Os outros dois elementos, numerados por 18 e 19, tinham reduções em suas seções transversais, causando uma diminuição de inércia e, portanto, representavam danos estruturais (Figura 5.5 e Figura 5.6). Estes danos foram simulados por um corte de  $10 \text{ mm}$  nas alturas dos elementos (Figura 5.6 (b)), de modo que o momento de inércia e a área da seção transversal foram reduzidos aos valores de  $6,406 \times 10^{-8} \text{ m}^4$  e  $9,435 \times 10^{-4} \text{ m}^2$ , representando uma redução de  $50,8\%$  e  $10,4\%$  nas inércia e área da seção transversal, respectivamente.

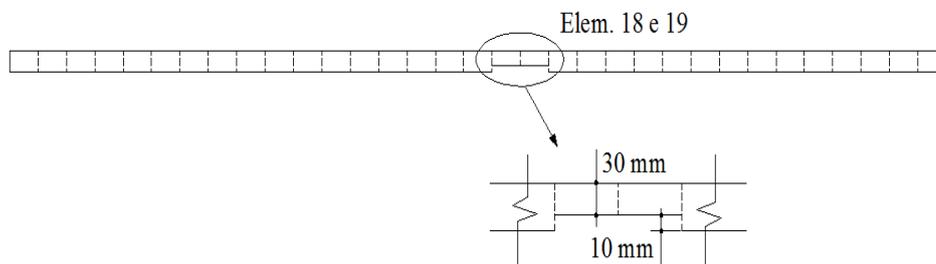


Figura 5.5 Discretização da viga. Brasiliano (2005).

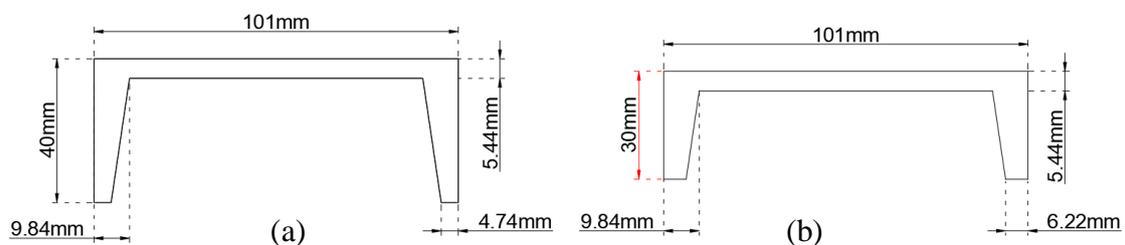


Figura 5.6 Seções transversais dos elementos. (a) Elemento intacto. (b) Elemento danificado. Brasiliano (2005).

### 5.2.1 Ensaios experimentais e características dinâmicas

Para simular a condição de contorno livre-livre, a viga foi posicionada sobre pilares de concreto armado com pesos de aproximadamente 2kN cada, e apoiada sobre espumas fixas de alta densidade nos pontos referentes aos nodos do primeiro modo de vibração (Figura 5.7).

A viga foi instrumentada com 7 acelerômetros, de modo que o ensaio foi dividido em dez etapas (E1, E2, ... E10) (Tabela 5.4), nas quais um conjunto de quatro acelerômetros permaneceu na mesma posição (acelerômetros de referência) e um outro conjunto de três acelerômetros foi movido para cada uma das posições indicadas na Tabela 5.4 (número dos nós nos quais os acelerômetros foram colocados). Por meio de um martelo, a excitação foi aplicada sempre no mesmo ponto, como mostra a Figura 5.8.



(a)



(b)

(c)

Figura 5.7 Esquema de ensaio da viga. (a) Sistema completo. (b) Detalhe do apoio das vigas. (c) Detalhe dos acelerômetros. Brasiliano (2005).

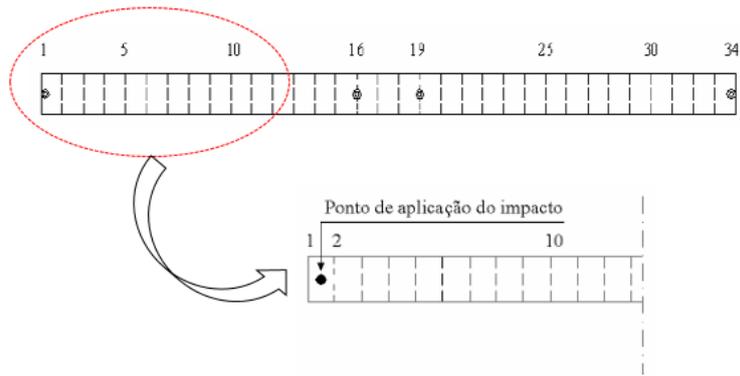


Figura 5.8 Vista superior da viga, posições dos acelerômetros e ponto de aplicação do impacto. Brasiliano(2005) – Adaptada.

Tabela 5.4 Posição dos acelerômetros em cada etapa.

Etapas	Acelerômetros móveis	Acelerômetros de referência
E1	2, 3 e 4	
E2	4, 5 e 7	
E3	8, 9 e 10	
E4	11, 12 e 13	
E5	14, 15 e 17	
E6	18, 20 e 21	1, 16, 19 e 34
E7	22, 23 e 24	
E8	25, 26 e 27	
E9	28, 29 e 30	
E10	31, 32 e 33	

A partir dos registros de aceleração adquiridos nos 34 pontos, determinou-se, por meio do método SSI-COV/ref (Brasiliano, 2005), as frequências (Tabela 5.5) e os respectivos modos de vibração da viga estudada (Figura 5.9).

Tabela 5.5 Frequências naturais de vibração.

Frequência (Hz)	Experimental SSI-COV/ref
1 <sup>a</sup>	40,1419
2 <sup>a</sup>	117,4535
3 <sup>a</sup>	221,4414
4 <sup>a</sup>	369,3117
5 <sup>a</sup>	542,3437

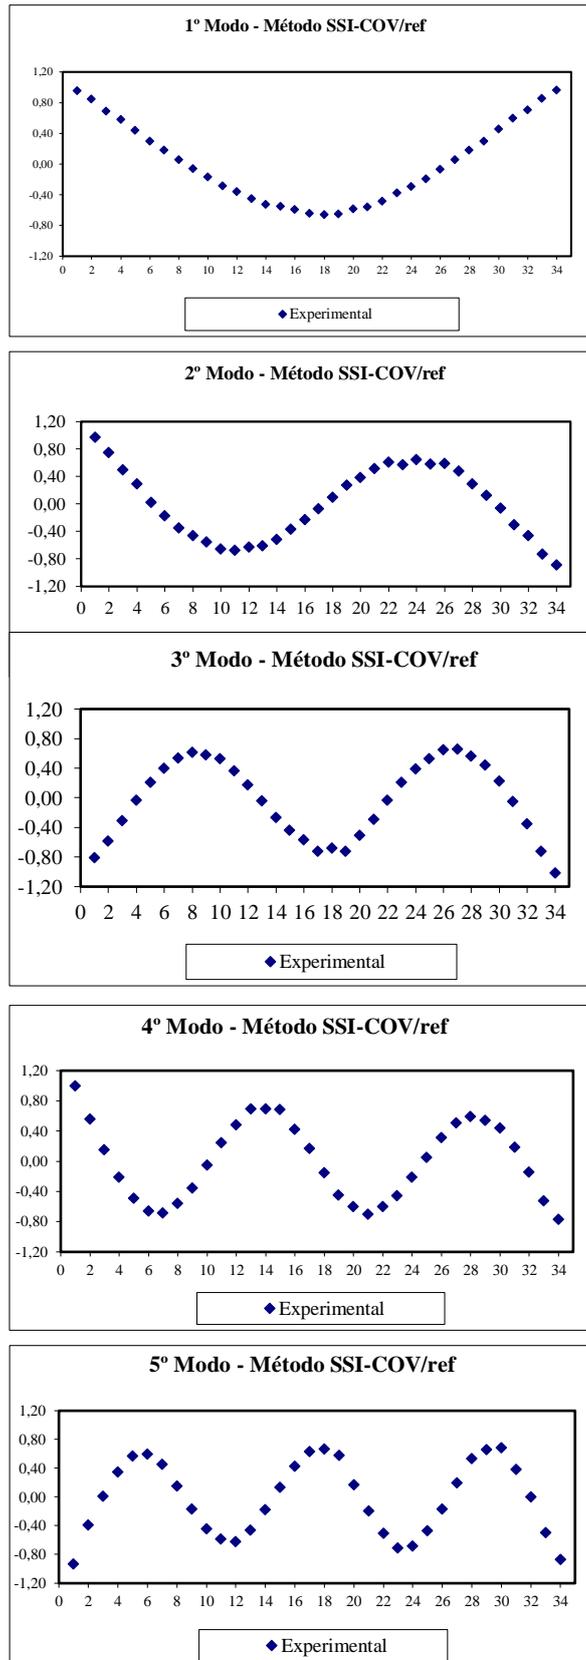


Figura 5.9 Modos de vibração da viga experimental. (Brasiliano, 2005).

### 5.3 Localização de danos a partir das Redes Neurais Artificiais – considerações iniciais

Buscando obter uma metodologia eficiente para o uso de RNAs no monitoramento estrutural, foram estudados dois tipos de redes, a *Backpropagation* e a *LVQ (Learning Vector Quantization)*.

Em ambos os casos os treinamentos das redes foram realizados com o banco de dados obtido nas simulações numéricas (cenários da Tabela 5.3), e nos testes foram usados as frequências e os modos de vibração da viga ensaiada por Brasiliano (2005).

Além dos dois tipos de rede, foram realizadas verificações quando as RNAs estavam modeladas em diferentes configurações, isto é, com diferentes padrões de entrada, bem como diferentes funções de ativação e diferentes números de neurônios envolvidos no processamento do algoritmo. A Figura 5.10 ilustra os dados de entrada usados, bem como as variações dos parâmetros considerados nas análises.

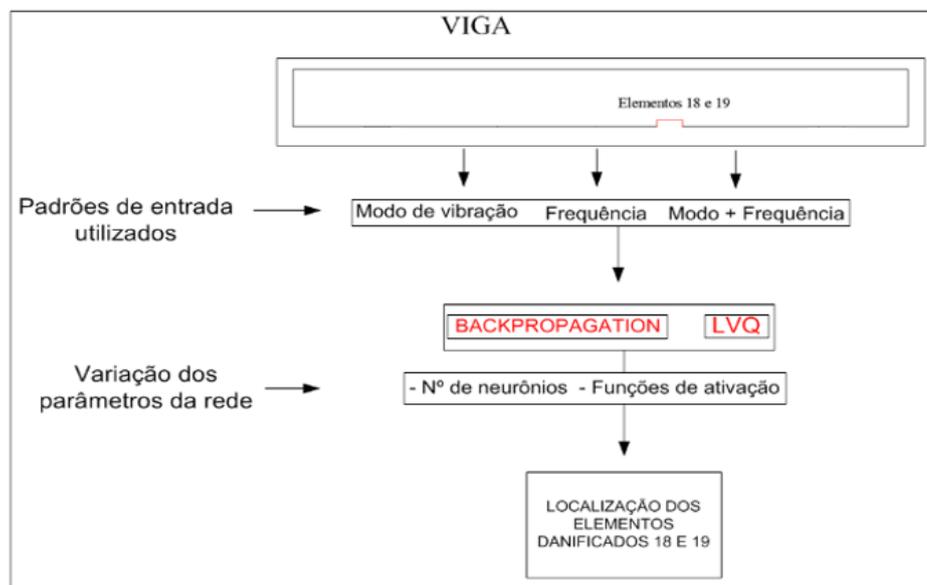


Figura 5.10 Esquema de teste realizados com as redes *Backpropagation* e *LVQ*.

Para cada uma das redes, foram utilizados 10, 15 e 20 neurônios na camada intermediária, passando ainda pela variação de três funções de ativação (no caso das redes *Backpropagation*): Tangente Hiperbólica (*Tansig*), Sigmoide Logarítmica (*Logsig*) e Linear (*Purelin*). Assim, para cada rede, foram realizados 09 testes, de modo que cada análise com seus respectivos resultados está ilustrada a seguir na Tabela 5.6.

Tabela 5.6 Testes realizados com as RNAs Backpropagation e LVQ.

Padrões de entrada	Número de redes	Nº de variáveis	Função de ativação	Nº de Neurônios
Modo de vibração	5 - uma para cada modo considerado	34 coordenadas	<i>Tansig</i>	10, 15 e 20
			<i>Purelin</i>	10, 15 e 20
			<i>Logsig</i>	10, 15 e 20
Frequência	1 - com as 5 frequências	5	<i>Tansig</i>	25, 50, 100 e 150
			<i>Purelin</i>	25, 50, 100 e 150
			<i>Logsig</i>	25, 50, 100 e 150
Modo + Frequência	5 - uma para cada modo / Frequência	35	<i>Tansig</i>	10, 15 e 20
			<i>Purelin</i>	10, 15 e 20
			<i>Logsig</i>	10, 15 e 20

No que diz respeito ao número aconselhável de neurônios, há uma falta de consenso na comunidade científica, uma vez que existem inúmeras teorias para a definição ideal do número de células artificiais na camada intermediária, desde funções estabelecidas em análises estatísticas, até a escolha baseada em tentativa e erros, esta última com uma maior aceitação. Segundo Sheela e Deepa (2013), alguns autores sugeriram as funções da Tabela 5.7 para o cálculo, nas quais  $(N_h)$ ,  $(N_{in}, n)$ ,  $(N_p)$ ,  $(N_0)$ ,  $(L)$  e MSE representam, respectivamente, o número de neurônios na camada escondida (intermediária), número de variáveis em um padrão de entrada, número de *inputs*, número de *padrões*, número de *outputs*, número de camadas intermediárias e o Erro Quadrático Médio (*Mean Squared Error*) obtido ao simular cada uma das configurações.

Apesar de terem sido determinados por um processo de tentativa e erros, os números de neurônios escolhidos para serem utilizados nas camadas intermediárias das análises deste trabalho estão contemplados nos critérios estabelecidos pelas pesquisas 1, 2, 5, 7 e 9 da tabela abaixo de Sheela e Deepa (2013) - Tabela 5.7.

Tabela 5.7 Estimativas do número ideal de neurônios na camada intermediária. Sheela e Deepa (2013).

Pesquisa	Método	Ano	Número de neurônios na camada intermediária (escondida)	MSE
1	Li et al	1995	$N_h = (\sqrt{1 + 8n} - 1)/2$	0,039
2	Método de Tamura e Tateish	1997	$N_h = N - 1$	0,217
3	Método de Fujita	1998	$N_h = K \log \ P_c Z\  / \log S$	0,0723
4	Método de Zhang et. al	2003	$N_h = 2^n / n + 1$	0,217
5	Método de Jinchuan e Xinzhe	2008	$N_h = (N_{in} + \sqrt{N_p}) / L$	0,299
6	Método de Chen e Xu	2008	$N_h = C_f (N / d \log N)^{0,5}$	0,072
7	Método de Shibata e Ikeda	2009	$N_h = \sqrt{N_i N_o}$	0,181
8	Método de Hunter	2012	$N_h = 2^n - 1$	0,072
9	Sheela e Deepa	2013	$N_h = (4n^2 + 3) / (n^2 - 8)$	0,018

#### 5.4 Resultados Rede Backpropagation

Considerando a metodologia exposta anteriormente, na qual foram criadas diferentes RNAs, este tópico descreve as análises feitas com a viga sob a perspectiva da rede *Backpropagation*, cuja regra de aprendizado é supervisionada e, portanto, necessita de um conjunto de dados de entrada e saída para o seu funcionamento.

Nesse sentido, conforme apresentado na Tabela 5.6 foram criados, treinados e testados 3 diferentes grupos de RNAs. O primeiro, refere-se às redes tendo apenas os modos de vibração como dados de entrada (coordenadas dos 34 nós) e, portanto, nomeado por redes *Backpropagation* com modos de vibração (RBMV). O segundo grupo, chamado de redes *Backpropagation* com frequências (RBF), foi formado considerando as 5 primeiras frequências do modelo como informações para a RNA. Já o terceiro grupo foi destinado às redes formadas pela associação das frequências com os respectivos modos de vibração e, portanto, nomeado por Redes *Backpropagation* com frequências e modos de vibração (RBFMV). Os subitens a seguir detalham as análises individuais feitas para cada grupo.

### 5.4.1 Redes Backpropagation com modos de vibração (RBMV)

A fim de localizar os danos presentes na viga experimental (redução de rigidez nos elementos 18 e 19), descrita no item 5.2, bem como verificar a sensibilidade de uma RNA tendo os modos de vibração como dados de entrada, foram criadas, treinadas e testadas cinco grupos de Redes Neurais Artificiais com o algoritmo Levenberg-Marquardt (LM), cada um referente a um modo de vibração.

Deste modo, o grupo da rede 1 teve como entrada os dados do primeiro modo de vibração de cada modelo (34 coordenadas) e como saída as coordenadas do elemento danificado correspondente. No caso da segunda rede trabalhou-se considerando como entrada o segundo modo de vibração de cada modelo.

Além de uma rede para cada um dos modos de vibração, buscando avaliar o desempenho das RNAs sob diferentes configurações na perspectiva de detecção de danos, foram feitas algumas variações nos parâmetros das redes, como, por exemplo, função de ativação e número de neurônios, como mostra a Tabela 5.8

Tabela 5.8 Variações da RBMV.

Rede ( $r=1:5$ )	Padrões de entrada	Nº de variáveis de entrada	Função de ativação	Nº de Neurônios	Padrão de saída
$r$	$r^{\circ}$ modo de vibração	34 coordenadas do modo de vibração	<i>Tansig</i>	10	Coordenada de um dos nós que contém elemento danificado
				15	
				20	
			<i>Purelin</i>	10	
				15	
				20	
	<i>Logsig</i>	10			
			15		
				20	

A partir da Tabela 5.8 é possível observar que para cada modo de vibração foram modelados 3 tipos de redes, usando cada uma das funções de ativação (*Tansig*, *Purelin*, *Logsig*), de modo que cada uma destas foi treinada e testada com diferentes números de neurônios, neste caso, 10, 15 e 20. Além disso, foram realizados, ao menos, 3 processamentos com cada teste a fim de eliminar qualquer possibilidade de *overfitting* (excesso de treinamento), bem como verificar a convergência dos resultados. Dessa forma, realizaram-se 27 testes para cada grupo de RNA composta por um determinado modo de vibração, cujas arquiteturas são representadas como apresentada Figura 5.11.

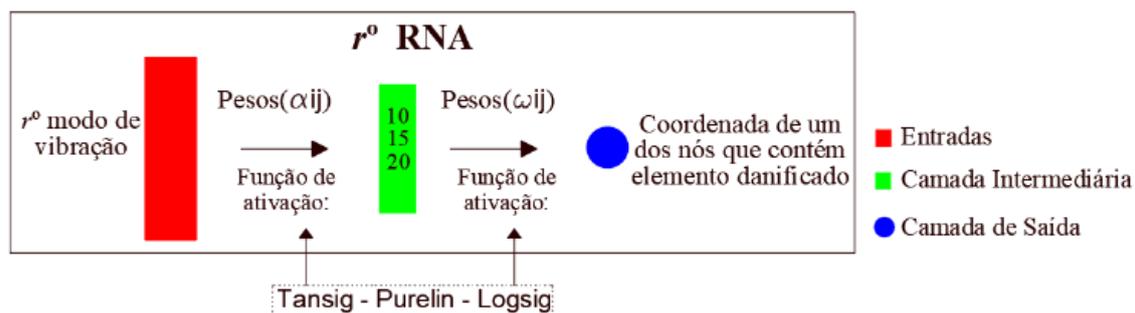


Figura 5.11 Arquitetura das RNAs RBMV.

As arquiteturas são formadas por três elementos principais, dos quais os dois primeiros representam, respectivamente, os vetores de entradas (neste caso as 34 coordenadas dos modos de vibração – em vermelho) e a camada intermediária da RNA (com um número específico de neurônios – em verde). Em azul, simbolizado por um círculo, mostra-se a saída da rede, ou seja, sua resposta após o processamento. Observa-se que entre cada elemento encontram-se os pesos aleatórios, bem como as funções utilizadas em cada teste, estando essas apresentadas no retângulo inferior da figura, uma vez que são utilizadas alternadamente.

## 1 Redes *Backpropagation* com o primeiro modo de vibração.

Com o objetivo de detectar os danos da viga experimental utilizando o primeiro modo de vibração da estrutura, as redes foram treinadas e validadas com as referidas informações dos 29 primeiros e os 3 últimos cenários de danos apresentados na Tabela 5.3, respectivamente.

O número de neurônios nas camadas intermediárias ou escondidas foi definido por um processo de tentativa e erro, em que se aumentou progressivamente a quantidade de neurônios até que o erro obtido no treinamento da rede fosse aceitável. Entre as camadas foram usadas as funções de ativação já mencionadas, contidas no pacote de Redes Neurais Artificiais do Matlab (*Neural Network Toolbox - nntool*) e escolhidas para avaliar o desempenho da rede. A Tabela 5.9 apresenta todos os parâmetros dos treinamentos, na qual MSE representa os erros calculados durante o processamento do

algoritmo na fase de aprendizagem, e no número de iterações estão representadas as médias das 3 rodadas de cada simulação.

Tabela 5.9 Parâmetros de treinamento das redes 1.

Rede	Padrões de entrada	Função de ativação	Nº de Neurônios	Nº de iterações	MSE	
1		<i>Tansig</i>	10	30	$10^{-3}$	
			15	35	$10^{-3}$	
			20	30	$10^{-4}$	
	1º modo de vibração	<i>Purelin</i>	10	75	$10^{-2}$	
			15	70	$10^{-3}$	
			20	67	$10^{-3}$	
			10	70	$10^{-2}$	
			<i>Logsig</i>	15	70	$10^{-3}$
				20	50	$10^{-3}$

A Figura 5.12 apresenta cada análise, cujas representações estão diferenciadas por verde (10 neurônios), magenta (15 neurônios) e cian (10 neurônios). Além disso, conforme apresentado na legenda, X, O e \* representam os resultados das análises feitas com cada uma das funções de ativação, *Tansig*, *Purelin* e *Logsig*, respectivamente.

Para verificar a convergência das saídas processadas pelas redes, cada teste foi realizado três vezes, de modo que os resultados plotados representam cada uma das verificações.

Na Figura 5.12 observa-se a forma do primeiro modo de vibração, com destaque (em vermelho) para a área que continha reduções na altura da seção transversal da viga (dano) – elementos 18 e 19, compreendidos pelos nós 18, 19 e 20. As posições dos danos encontradas pelo algoritmo estão simbolizadas pelos marcadores já mencionados.

É possível observar que mesmo utilizando diferentes funções de ativação os resultados obtidos após o processamento da rede apresentaram grande aproximação da região danificada da viga, uma vez que para quase todos os testes, as saídas das redes se localizaram sobre a região vermelha, indicando, portanto, um bom funcionamento do sistema. Nota-se que, para a rede formada por 10 neurônios com função *Purelin*, a resposta pós processamento não foi exatamente na região do dano. Porém, trata-se de um resultado bastante aceitável, pois acontece no elemento 17 que é circundado pelos nós 17 e 18, podendo, naturalmente, sofrer influência do seu subsequente, o elemento

18. Além disso, os resultados de 2 testes feitos com a rede contendo 20 neurônios ficaram fora da região aceitável. Tal fato pode ser atribuído ao excesso de neurônios, uma vez que o comportamento só foi verificado com a rede formada com o número máximo de neurônios considerados na análise.

No gráfico não é possível verificar os 27 resultados de todas as análises, uma vez que, em vários testes, as redes identificaram a mesma posição para o elemento danificado, resultando em uma sobreposição dos resultados.

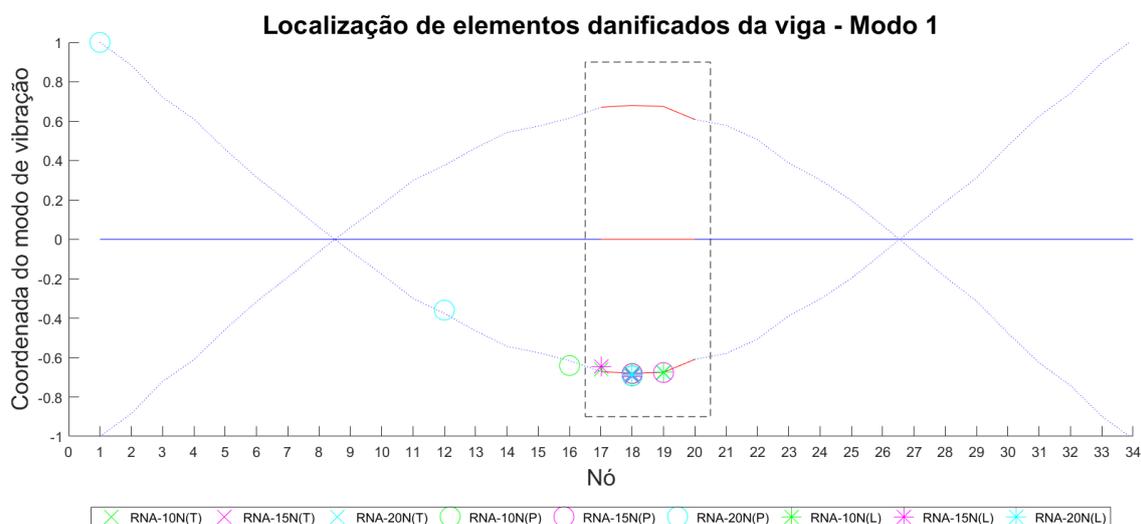


Figura 5.12 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs (**RBMV – modo 1**).

Os resultados mostram que as RNAs se comportaram como esperado. As reduções de rigidez dos elementos 18 e 19 estão localizadas em uma posição da viga que, no primeiro modo de vibração, apresentam os maiores deslocamentos, sendo um fator decisivo para estabelecer diferenças entre os padrões de treinamento, já que o banco de dados continha diferentes situações de danos. Tal fato permitiu à rede reconhecer um maior número de padrões, resultando em uma maior capacidade de detectar o estado danificado da viga experimental.

## 2 Redes Backpropagation com o segundo modo de vibração.

As análises feitas com o segundo modo de vibração da viga seguiram os mesmos critérios mencionados nos casos das redes formadas pelo primeiro modo. Foram utilizados os mesmos cenários para treinar e validar as RNAs, no entanto, fornecendo como padrões de entrada as 34 coordenadas que dão forma segundo modo de vibração dos modelos. Os treinamentos foram feitos conforme parâmetros da Tabela 5.10

Tabela 5.10 Parâmetros de treinamento das redes 2.

Rede	Padrões de entrada	Função de ativação	Nº de Neurônios	Nº de iterações	MSE
2	2º modo de vibração	<i>Tansig</i>	10	50	$10^{-3}$
			15	37	$10^{-4}$
			20	40	$10^{-6}$
		<i>Purelin</i>	10	100	$10^{-1}$
			15	120	$10^{-1}$
			20	110	$10^{-2}$
			10	35	$10^{-4}$
		<i>Logsig</i>	15	27	$10^{-3}$
			20	38	$10^{-4}$

Para testar a rede foram fornecidos o segundo modo de vibração da viga experimental como padrão de entrada, de modo que a saída, foi sempre a coordenada de um dos nós que circundava os elementos danificados 18 e 19.

As redes também foram analisadas com os mesmos números de neurônios, bem como com as três funções de ativação *Purelin*, *Tansig* e *Logsig*. Por meio do gráfico da Figura 5.13, é possível visualizar o agrupamento de todas as análises feitas com o segundo modo de vibração.

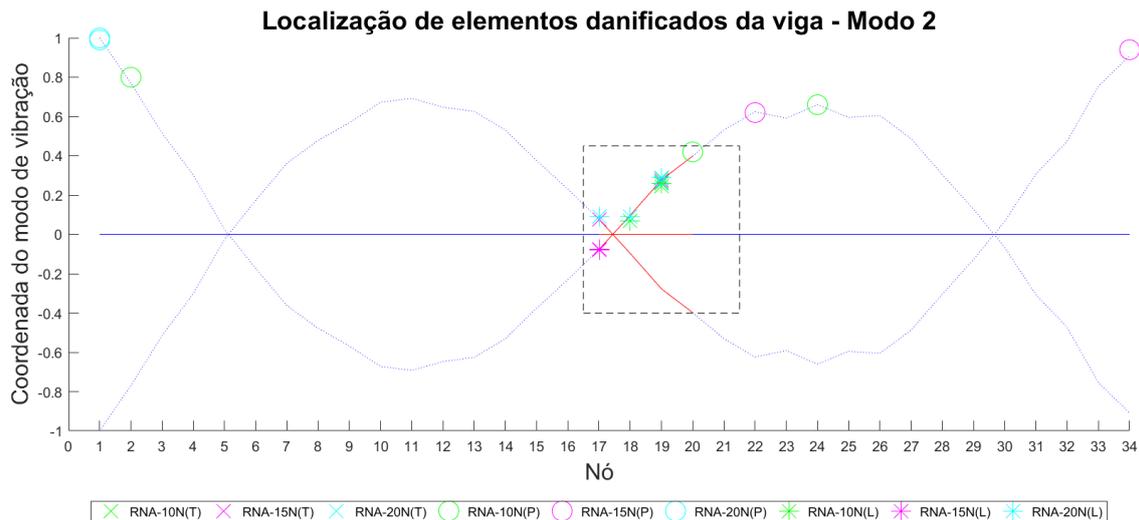


Figura 5.13 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs (**RBMV – modo 2**).

É possível observar que as análises com a função *Tansig* (RNA-10(T), RNA-15(T) e RNA-20(T)) obtiveram resultados precisos, uma vez que, de acordo com o processamento das RNAs, as respostas das redes foram sempre coordenadas compreendidas no intervalo vermelho (região que continha os danos da viga experimental).

Como esperado, o comportamento das redes formadas com a função *Purelin* apresentou um desempenho muito abaixo do desejado, uma vez que o MSE do treinamento destas redes foi muito alto (Tabela 5.10). O baixo desempenho também está comprovado nos testes das redes, como mostram os resultados RNA-10(P), RNA-15(P) e RNA-20(P), não sendo possível localizar corretamente a posição do elemento que apresentava região danificada, fato este verificado mesmo com um aumento significativo de neurônios. Observa-se que em uma das simulações, cuja rede estava composta por 10 neurônios na camada intermediária, o resultado após o processamento do algoritmo foi próximo do esperado, no entanto este pode ser desconsiderado, uma vez que apenas esta simulação foi bem sucedida.

Além disso, verifica-se uma particularidade na função linear que, no primeiro caso proporcionou um bom desempenho às RNAs. Discussões (fóruns de discussões) indicam uma variação de comportamento no processamento de amostras com média diferente de zero e variância unitária. Ao serem processadas um banco de dados com as características mencionadas, o processamento tende a melhorar significativamente.

No caso anterior (RNAs com primeiro modo de vibração), verifica-se que as médias contidas em cada amostra do banco de dados do treinamento diferem de zero (Figura 5.14), resultando em um melhor desempenho.

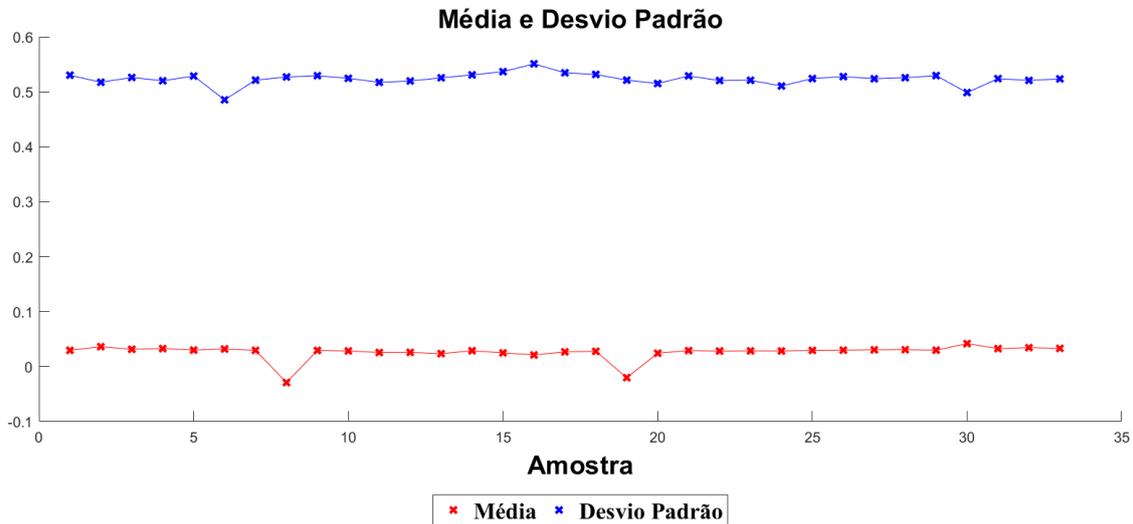


Figura 5.14 Média e desvio padrão das amostras do primeiro modo de vibração.

No caso do segundo modo de vibração, devido à simetria das coordenadas, trata-se de uma amostra cuja média é zero. Deste modo, pode-se indicar que esta é uma das causas para o resultado abaixo do esperado.

### 3 Redes Backpropagation com o terceiro modo de vibração.

Seguindo os mesmos padrões já mencionados para a criação das RNAs, este grupo foi criado para analisar o desempenho das redes tendo como padrões de entrada o terceiro modo de vibração da estrutura.

Neste caso também foram analisadas a influência no desempenho das redes devido a variação do número de neurônios na camada intermediária, bem como do uso dos três tipos de função de ativação envolvidas no processamento. Os parâmetros dos treinamentos estão apresentados na Tabela 5.11

Tabela 5.11 Parâmetros de treinamento das redes 3.

Rede	Padrões de entrada	Função de ativação	Nº de Neurônios	Nº de iterações	MSE
3	3º modo de vibração	<i>Tansig</i>	10	80	$10^{-4}$
			15	100	$10^{-4}$
		<i>Purelin</i>	20	90	$10^{-3}$
			10	100	$10^{-3}$
		<i>Logsig</i>	15	90	$10^{-3}$
			20	80	$10^{-4}$
		<i>Logsig</i>	10	100	$10^{-3}$
			15	120	$10^{-3}$
		20	111	$10^{-3}$	

Os resultados estão apresentados na Figura 5.15. No que diz respeito aos testes feitos com as redes formadas pela função *Tansig*, percebe-se que apenas uma das simulações feitas com a RNA de 10 neurônios não apresentou resultado satisfatório, indicando que o dano da viga experimental, efetivamente posicionado nos nós 18, 19 e 20, se localizava no nó 11. Tal fato pode ser explicado devido à necessidade de mais neurônios e/ou treinamento para um melhor aprendizado do algoritmo.

Nota-se, ainda, que a curva que representa o 3º modo de vibração da viga apresenta, sobretudo no trecho referente aos elementos danificados, uma perturbação significativa e que, mesmo não tendo sido apresentada tal variação na etapa do treinamento, não gerou falhas nos resultados dos testes.

O processamento com as redes formadas pela função *Purelin*, seguiu o mesmo comportamento do caso 1, referente ao primeiro modo de vibração. Conforme discutido, o modo de vibração 3 também apresenta média diferente de 0, o que pode indicar o motivo pelo qual a referida função permitiu um bom desempenho do sistema, fato este não observado na rede neural apresentada anteriormente (a rede formada pelo segundo modo de vibração), uma vez que, neste caso, a média é zero.

Deste modo, diante dessa repetição de resultado, observa-se uma tendência do comportamento, sendo necessário mais análises para comprovar e, assim, indicar a utilização da função linear após uma análise estatística mais profunda do tipo de dado a ser utilizado como dado de entrada da RNA.

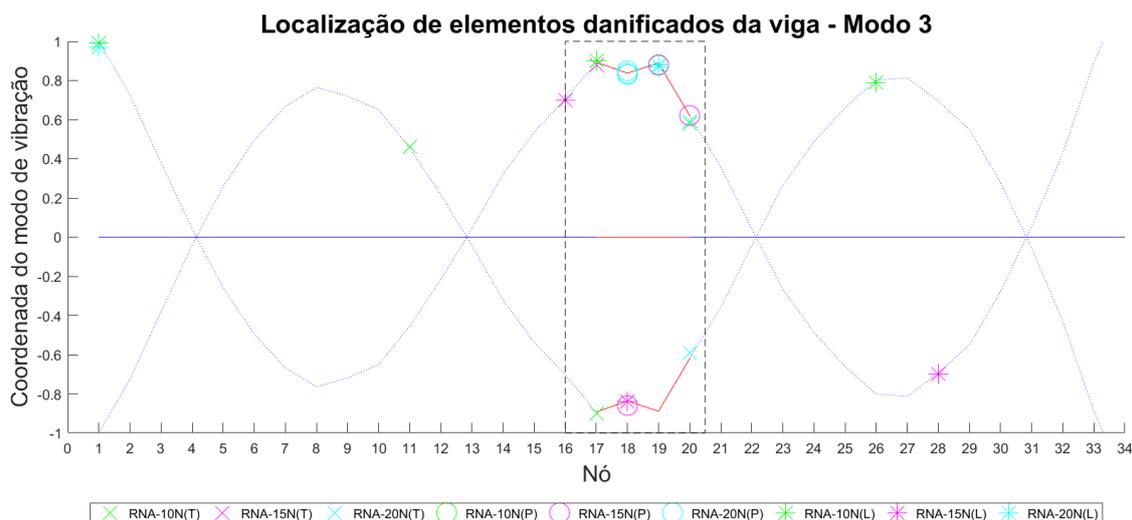


Figura 5.15 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs (RBMV – modo 3).

As redes compostas pela função *Logsig* apresentaram um desempenho satisfatório em algumas simulações, uma vez que, na maioria dos casos, o algoritmo foi capaz de localizar o dano da viga estudada. No entanto, observaram-se comportamentos particulares. O gráfico revela que em alguns testes a rede processou a posição do dano em nós diferentes dos corretos, fato este que chama atenção à similaridade das coordenadas (os nós são diferentes mas têm os mesmos valores de coordenadas).

Em todos os casos, percebe-se que a coordenada é quase a mesma dos elementos danificados, variando a posição do nó em função da simetria do modo. Assim, pode-se indicar que, para evitar tal problemática, pode-se optar por utilizar apenas metade do modo de vibração.

#### 4 Redes Backpropagation com o quarto modo de vibração.

Conforme metodologia apresentada, foram feitos os testes para as coordenadas do quarto modo de vibração. Para fins comparativos, foram utilizadas as mesmas funções mencionadas nos casos anteriores, bem como os mesmos números de neurônios e os critérios dos treinamentos estão mostrados na Tabela 5.12. É possível verificar que os erros obtidos nos treinamentos das redes compostas pela função linear são altos, indicando que os testes, certamente, não são precisos.

Tabela 5.12 Parâmetros de treinamento das redes 4.

Rede	Padrões de entrada	Função de ativação	Nº de Neurônios	Nº de iterações	MSE	
4	4º modo de vibração	<i>Tansig</i>	10	120	$10^{-3}$	
			15	100	$10^{-4}$	
			20	116	$10^{-3}$	
		<i>Purelin</i>	10	110	$10^{-1}$	
			15	120	$10^{-2}$	
			20	115	$10^{-2}$	
			10	180	$10^{-3}$	
			<i>Logsig</i>	15	200	$10^{-3}$
				20	210	$10^{-4}$

Na Figura 5.16 são apresentados os resultados das redes formadas com as funções *Tansig*, *Purelin* e *Logsig*. Conforme se observa no gráfico, as redes formadas pela função *Tansig* foram as que apresentaram desempenho satisfatório, mesmo com a variação do número de neurônios. Como já era esperado, como indicado nos resultados obtidos com as redes formadas pelo 1º modo de vibração, devido às características estatísticas da amostra utilizada como dados de entrada (4º modo), isto é não apresentam média diferente de zero, nem variância unitária, os resultados com função *Purelin* foram todos insatisfatórios.

Já no caso das RNAs com a função *Logsig*, observa-se uma variação do comportamento, isto é, em alguns testes as redes processam corretamente a posição do elemento e, em outra, a resposta do algoritmo apresenta uma coordenada similar a correta, no entanto, em nós diferentes. Deste modo, comparando com os casos anteriores, essa alternância de comportamento apresenta um aumento gradativo no sentido negativo, uma vez que os resultados apresentam uma certa piora.

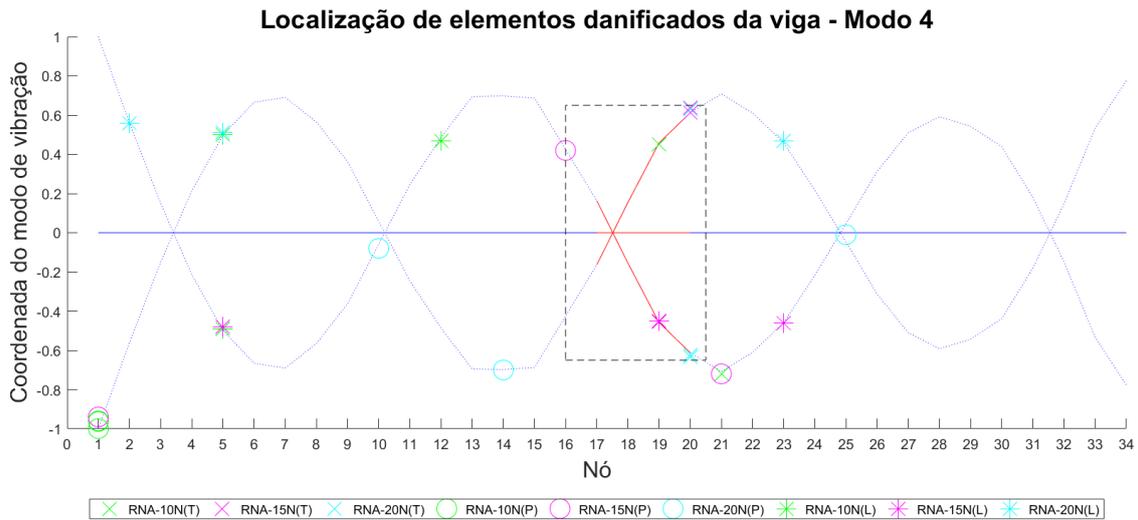


Figura 5.16 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs (RBMV – modo 4).

Sabendo que a função *Logsig* tem domínio entre 0 e 1 e a *Tansig* -1 e 1, conforme mostrado na Figura 5.17, pode-se observar que, à medida que vai aumentando o modo utilizado, resultando em um maior número de “picos simétricos entre (-1 e 1)”, a rede com a função *Logsig* não é capaz de representar adequadamente tal comportamento.

Já no caso da função *Tansig*, talvez por contemplar toda a variação das coordenadas do modo, são obtidos os resultados mais próximos do esperado.

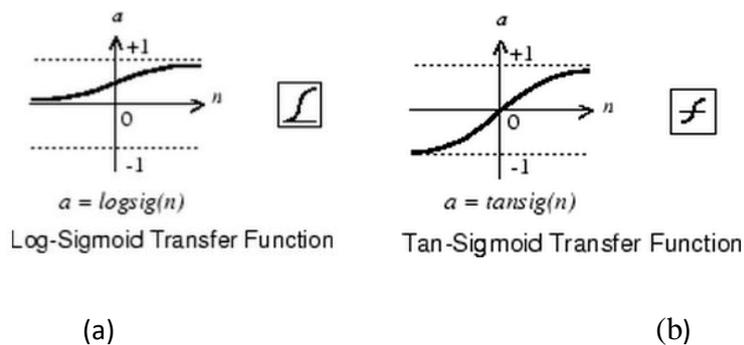


Figura 5.17 Funções de ativação. (a) *Logsig*. (b) *Tansig* (Matlab, 2016).

Vale ressaltar que em todos os testes, foram realizadas mais de 200 iterações e que, para evitar o fator do *overfitting*, foram analisados resultados com retreinamentos, além de terem sido feitas as médias das saídas das redes.

## 5 Redes Backpropagation com o quinto modo de vibração.

Seguindo os mesmos padrões já mencionados para a criação, treino e validação das RNAs, este grupo foi criado para analisar o desempenho das redes com o quinto modo de vibração da estrutura como dados de entrada.

Neste caso também foram testadas 3 redes, de modo que cada uma continha 10, 15 e 20 neurônios na camada intermediária, com três diferentes funções de ativação. Os treinamentos tiveram como padrões de entrada as 34 coordenadas que dão forma ao quinto modo de vibração dos cenários danificados, modelados numericamente. Durante o treinamento foram adotados os parâmetros apresentados na Tabela 5.13, na qual, baseado no MSE, verifica-se um bom desempenho de todas as simulações, indicando, portanto, a tendência para um bom desempenho dos testes.

Nota-se, ainda, um aumento considerável no número de iterações para que fosse possível atingir erros na ordem de  $10^{-3}$ , sobretudo nas redes formadas com a função *Logsig*.

Tabela 5.13 Parâmetros de treinamento das redes 5.

Rede	Padrões de entrada	Função de ativação	Nº de Neurônios	Nº de iterações	MSE
5	5º modo de vibração	<i>Tansig</i>	10	130	$10^{-3}$
			15	110	$10^{-4}$
			20	120	$10^{-4}$
		<i>Purelin</i>	10	100	$10^{-2}$
			15	120	$10^{-3}$
			20	140	$10^{-3}$
		<i>Logsig</i>	10	220	$10^{-3}$
			15	180	$10^{-3}$
			20	220	$10^{-4}$

A partir dos resultados apresentados na Figura 5.18, verifica-se que os resultados dos testes feitos com as redes formadas pela função *Tansig*, mais uma vez foram precisos, indicando corretamente a posição dos elementos danificados na viga experimental

Nota-se, ainda, que a curva que representa o 5º modo de vibração apresenta algumas perturbações e que, certamente, podem interferir nos resultados

O processamento com as redes formadas pela função *Purelin* seguiu o mesmo comportamento dos casos anteriores, isto é, a função linear apresentou desempenho capaz de localizar os danos da viga apenas quando considerados alguns modos de vibração, especificamente, aqueles que apresentaram média diferente de zero, como o 1º, 3º e 5º. Mesmo indicando um resultado ainda com “falhas”, isto é, resultados fora da região danificada, nota-se que as respostas processadas pela RNA são coerentes com a coordenada indicada pela região que continha danos, reafirmando, portanto, que para modos elevados, é melhor trabalhar com parte do modo de vibração para evitar distorções devido a sua simetria.

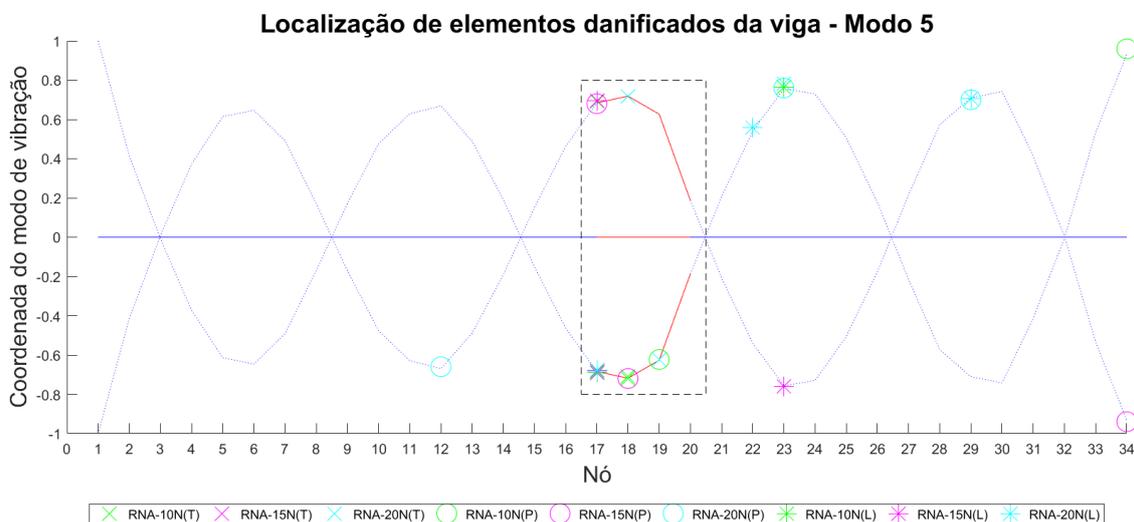


Figura 5.18 Análise dos efeitos das variações das condições estabelecidas na arquitetura das RNAs (**RBMV – modo 5**).

As redes compostas pela função *Logsig* também apresentaram a variação mencionada no caso anterior, isto é, uma piora nos resultados, também pelos mesmos motivos. Conforme visto no terceiro modo, o gráfico ilustra que em alguns testes a rede

processou a posição dos nós diferentes dos corretos. Isto se deu devido a simetria do modo, sendo novamente indicado o uso de apenas a sua metade.

Baseado nos resultados apresentados, verifica-se que, ao serem utilizados as coordenadas dos modos de vibração, há uma forte tendência para o uso das funções não lineares, especificamente a *Tansig*, na composição das RNAs, uma vez que, na maioria dos casos, o algoritmo foi preciso na localização dos danos da viga experimental.

No caso de funções lineares, deve-se realizar, primeiramente, uma análise estatística das amostras que serão fornecidas como dados de entrada.

#### **5.4.2 Redes *Backpropagation* com as frequências de vibração (RBFV)**

Com os mesmos objetivos da seção 5.1.1, a fim de localizar os danos (redução de rigidez nos elementos 18 e 19) presentes no modelo experimental da viga descrita no item 5.2, foram criadas, treinadas e testadas Redes Neurais Artificiais, todas do tipo *Backpropagation* com o algoritmo *Levenberg-Marquardt* (LM), tendo como padrões de entrada frequências dos modelos estruturais.

Neste grupo de RNAs, as fases de treinamento receberam como conjuntos de dados de entrada as cinco primeiras frequências de vibração. Diferentemente do grupo das redes processadas com os modos de vibração, em análises prévias foi verificado que o padrão mais indicado para saída era a distância ao nó que delimitava o elemento danificado, com relação à origem da estrutura. Além disso, notou-se que eram necessários mais neurônios para o processamento. Assim, os critérios de formação das redes foram um pouco diferentes dos estudados anteriormente. A Tabela 5.14 apresenta todos os parâmetros utilizados nesta parte do estudo.

Tabela 5.14 Variações das RBFV.

Padrões de entrada	Nº de variáveis de entrada	Função de ativação	Nº de Neurônios	Padrão de saída
5 primeiras frequências	5	<i>Tansig</i>	25	Distância de um dos nós que contém elemento danificado com relação à origem
			50	
			100	
			150	
		<i>Purelin</i>	25	
			50	
			100	
			150	
		<i>Logsig</i>	25	
			50	
			100	
			150	

É possível observar que para o conjunto das 5 frequências foram modeladas 12 redes, sendo 3 conjuntos, cada um referente a uma função de ativação (*Tansig*, *Purelin*, *Logsig*), de modo que cada uma destas foi treinada e testada com diferentes números de neurônios, neste caso, 25, 50, 100 e 150, cujas arquiteturas estão representadas na Figura 5.19.

As arquiteturas foram formadas por três elementos. Os dois primeiros representam, em vermelho, os vetores de entradas (neste caso as 5 primeiras frequências de vibração) e, em verde, a camada intermediária da RNA. O terceiro elemento, em azul, representa a saída da rede, isto é, sua resposta após o processamento do algoritmo. Observa-se que entre cada elemento encontram-se os pesos aleatórios, bem como as funções utilizadas em cada teste.

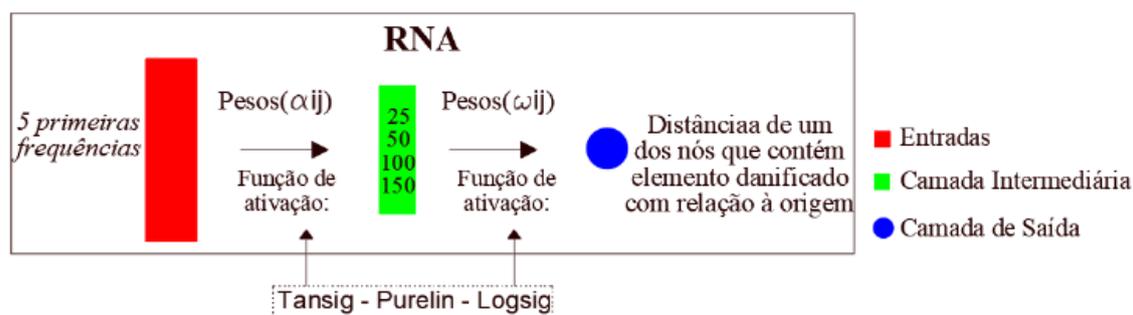


Figura 5.19 Arquitetura das RNAs - RBFV.

As redes foram processadas com uma média de 300 iterações, com erros na ordem de  $10^{-3}$ . Os resultados obtidos estão separados pelos grupos de função de ativação. Na

ocasião, como foi observada uma variação significativa dos resultados quando as funções de ativação estavam alternadas (antes e/ou depois da camada intermediária), também foi feita tal análise.

Estando os elementos danificados (18 e 19) da viga estudada entre as distâncias de 1,2 m e 1,37 da origem, para as redes formada com a *Purelin* como primeira função de ativação, com o auxílio de um *zoom* na região de interesse, verifica-se a perfeita localização em todos os testes realizados (Figura 5.20).

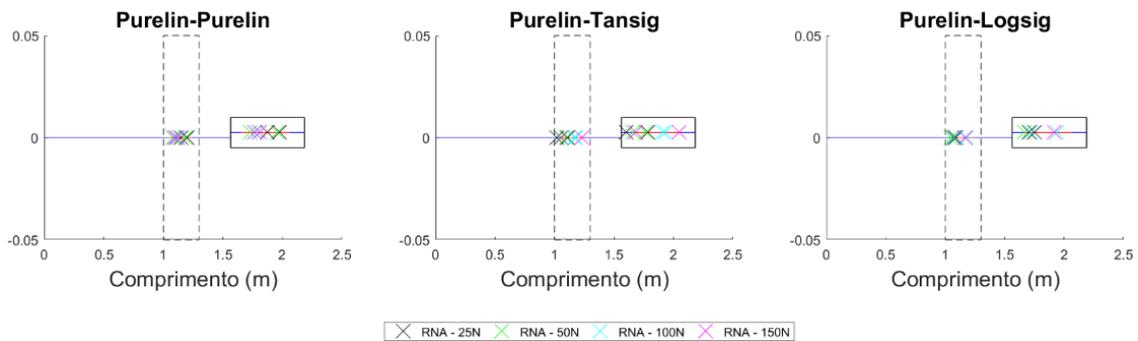


Figura 5.20 Resultados das rede RBFV – em conjuntos das 5 frequências (Purelin).

Neste primeiro grupo, isto é, resultados com a função *Purelin* antes da primeira camada oculta e tendo as demais em sequência, é possível verificar um resultado bastante positivo. Se comparado com os apresentados pelas redes formadas pelos modos de vibração e pela referida função, pode-se dizer que o desempenho foi exatamente o oposto.

Vale ressaltar que, segundo a literatura (Haykin, 2009), o melhor funcionamento do algoritmo *Backpropagation* acontece quando se tem ao menos uma função não linear no interior da rede. Deste modo, os resultados obtidos não seguem o indicado por outros estudos.

No caso das funções *Tansig* e *Logsig* como primeiras funções de ativação, os resultados foram razoáveis, uma vez que os sistemas se comportaram com uma grande variabilidade, isto é, forneceram resultados indicando a correta localização do dano, muito embora tenha processado saídas em outras regiões, conforme apresentado nas

Figura 5.21 e Figura 5.22. Em outras palavras, não houve a repetição de bons resultados observados no caso da função linear como primeira função de ativação.

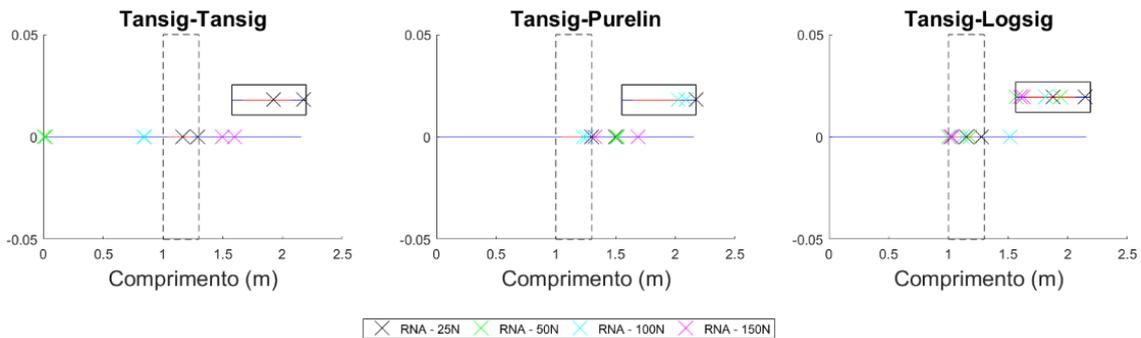


Figura 5.21 Resultados das rede RBFV – em conjuntos das 5 frequências (Tansig).

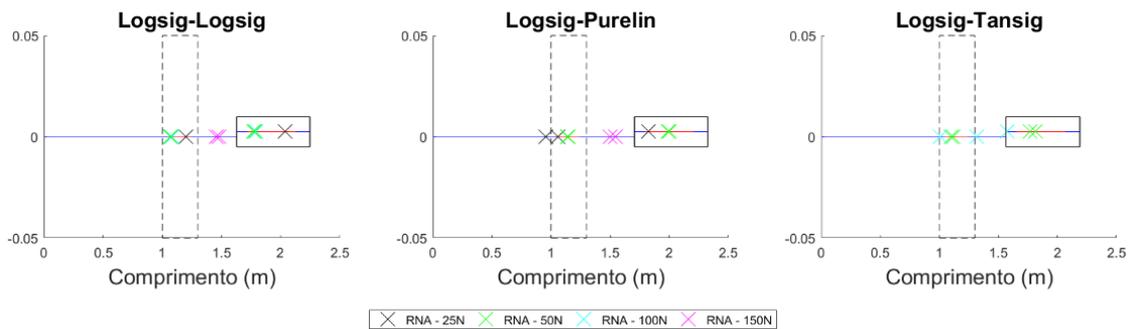


Figura 5.22 Resultados das rede RBFV – em conjuntos das 5 frequências (Logsig).

Além da surpreendente performance das RNAs formadas com a função Linear entre as camadas de entrada e intermediária, verificou-se que o conjunto de frequências como dados de entrada não resultou em desempenho satisfatório ao serem utilizadas as funções *Tansig* e *Logsig* como funções anteriores à camada intermediária, uma vez que em todas as tentativas, apenas poucos testes conseguiram localizar corretamente os elementos danificados.

Observou-se, ainda, que ao modelar as redes tendo a função *Purelin* após a camada intermediária e as demais funções, *Tansig* e *Logsig*, antes da camada oculta, os resultados apresentam uma piora significativa, como se observa nas Figura 5.21 e Figura 5.22.

Como, de maneira geral, os resultados foram um pouco abaixo do esperado, foram feitos testes utilizando as frequências em separado, isto é, foram criadas, treinadas e testadas RNAs tendo só uma frequência como dado de entrada como, por exemplo: a rede 1 foi treinada e testada com a primeira frequência de modelos numéricos e experimental, respectivamente.

Os resultados das redes formadas com as 1<sup>a</sup>, 2<sup>a</sup> e 3<sup>a</sup> foram positivos, no entanto, a partir da 3<sup>a</sup> rede, observou-se uma distorção, de modo que o algoritmo passou a apresentar respostas muito aleatórias e sem sentido físico. É possível observar os gráficos no apêndice A.

#### **5.4.3 Redes Backpropagation com as frequências e os modos de vibração (RBFMV)**

Conforme apresentado no item 5.4, este grupo de análise refere-se aos testes realizados com redes *Backpropagation*, tendo as frequências e os respectivos modos de vibração utilizados como padrões de entrada.

Seguindo os mesmos critérios dos casos anteriores quanto aos cenários utilizados no treinamento, as redes receberam como dados de entrada e saída as cinco primeiras frequências acompanhadas das coordenadas dos respectivos modos de vibração, e a coordenada de um dos nós que delimitava o elemento danificado, respectivamente. Deste modo, a rede 1 teve como entrada os dados da primeira frequência e seu modo de vibração; a rede 2, a segunda frequência e as coordenadas do segundo modo, e, assim, sucessivamente.

Além de uma RNA para cada uma das frequências e modos de vibração, para fins comparativos, foram variadas as funções de ativação e número de neurônios envolvidos no processamento do algoritmo, como ilustrado na Tabela 5.15.

Tabela 5.15 Variações das RBFMV.

Rede ( $r=1:5$ )	Padrões de entrada	Nº de variáveis de entrada	Função de ativação	Nº de Neurônios	Padrão de saída
				10	
			<i>Tansig</i>	15	Coordena
		35		20	da de um
$r$	$r^o$ modo de vibração + $r^o$ frequência	frequência + coordenadas do modo de vibração	<i>Purelin</i>	10	dos nós
				15	que
			<i>Logsig</i>	20	contém
				10	elemento
				15	danificado
				20	

Além disso, cada simulação foi rodada, ao menos, três vezes para avaliar a convergência dos resultados, bem como eliminar qualquer possibilidade de *overfitting*. Assim, verifica-se que cada grupo de RNA teve 27 simulações, sendo 9 com cada uma das funções de ativação. As arquiteturas destas RNAs foram as mesmas utilizadas pelas as redes formadas pelos modos de vibração (RBMV), conforme Figura 5.23, mudando apenas a informação de *input*.

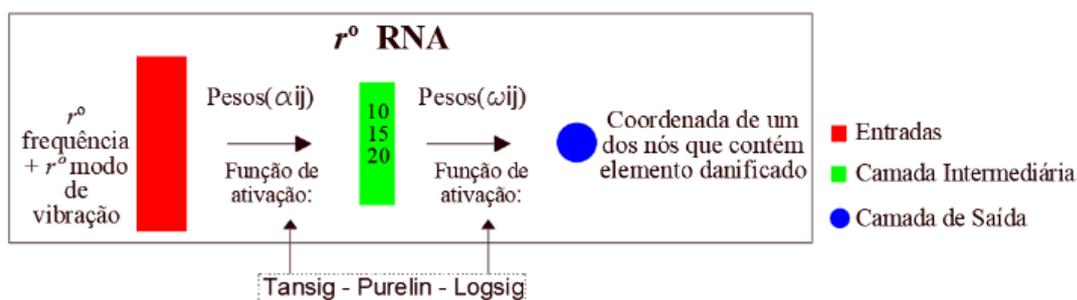


Figura 5.23 Arquitetura das RNAs RBFMV.

## 1 Redes Backpropagation com a primeira frequência e primeiro modo de vibração.

Seguindo os mesmos critérios das análises já relatadas, as redes formadas com a primeira frequência e o respectivo modo de vibração foram formadas por 35 neurônios de entrada (coordenadas dos 34 nós + frequência de vibração) e um neurônio de saída, isto é, a coordenada de um dos nós que circundavam o(s) elemento(s) danificado(s).

As análises foram processadas com uma média de 40 iterações, resultando em erros de treinamento na ordem de  $10^{-3}$ . Para fins comparativos, o número de neurônios

nas camadas intermediárias foi definido em 10, 15 e 20 e entre as camadas também foram testadas as funções de ativação *Tansig*, *Purelin* e *Logsig*. Os resultados estão apresentados na Figura 5.24.

Nos testes feitos com a função *Tansig*, o gráfico exibe resultados bastante precisos, uma vez que todas as saídas processadas pelas redes coincidiram com a região danificada da viga, isto é, intervalo delimitado pelos elementos danificados 18 e 19. Além disso, percebe-se que estes resultados estão em bastante coerência com os das redes processadas apenas com os modos de vibração, na seção 5.5.1, indicando uma positiva tendência de resultados.

No que diz respeito aos resultados obtidos das redes formadas pelas funções *Purelin* e *Logsig*, pode-se dizer que o algoritmo apresentou muita similaridade com as análises feitas com as redes que tinham apenas os modos de vibração como dados de entrada. Percebe-se, ainda, um leve erro de localização nas redes com a função *Logsig*, contudo, pode-se aceitar, já é muito próxima à região danificada.

No último gráfico, nota-se que, independente da configuração utilizada (função de ativação e número de neurônios, o sistema inteligente apresentou um funcionamento desejado, de modo que os danos foram localizados conforme o esperado.

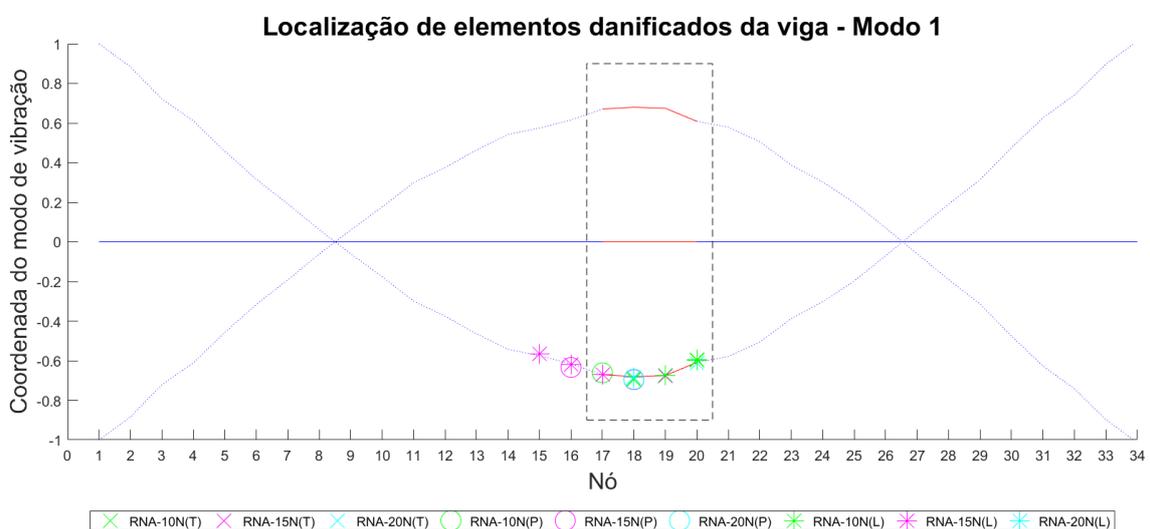


Figura 5.24 Resultados das rede RBFMV – Frequência e modo 1.

Diferentemente do que ocorreu com as redes formadas apenas com as cinco frequências de vibração, neste caso (assim como nas redes só com os modos) o comportamento do sistema não teve variação significativa quando as funções de

ativação mudaram de ordem de execução (antes ou depois da camada oculta). Assim, tais resultados não foram apresentados em gráficos separados.

## **2 Redes Backpropagation com a segunda frequência e segundo modo de vibração.**

As análises feitas com a segunda frequência em conjunto com o segundo modo de vibração da viga seguiram a mesma metodologia já apresentada, isto é, variação das funções e do número de neurônios na camada intermediária.

Os treinamentos tiveram uma média de 70 iterações, resultando em erros na ordem de  $10^{-3}$ , no caso das redes processadas com a função *Tansig*. Com as demais funções esse erro atingiu maiores valores, de  $10^{-1}$  com a função *Purelin*, por exemplo.

Por meio do gráfico da Figura 5.25 verifica-se que os processamentos das redes formadas com a função *Tansig* conseguiram estabelecer uma adequada relação entre os dados de entrada e saída do treinamento, de modo que no teste, a generalização do sistema permitiu localizar corretamente a posição dos danos da viga experimental, com a exceção de uma simulação.

No entanto, com relação às demais funções de ativação em estudo, *Purelin* e *Logsig*, observa-se que o desempenho não foi o desejado, mesmo quando variado o número de neurônios, de modo que a localização dos danos ficou muito distante da região previamente estabelecida pelo modelo experimental.

Deste modo, fazendo uma análise dos resultados encontrados, sobretudo com relação a função linear, verifica-se, de maneira geral, um comportamento inconstante, sobretudo na análise com os modos de vibração, o que indica a não utilização da função linear na formação de RNAs cujo objetivo seja o monitoramento estrutural de modelos reduzidos.

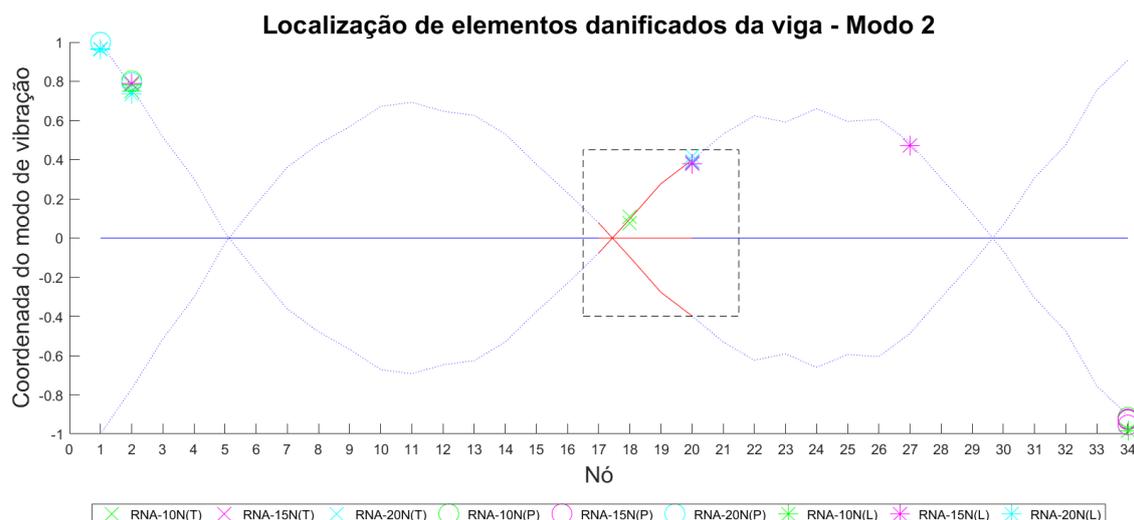


Figura 5.25 Resultados das rede RBFMV – Frequência e modo 2.

### 3 Redes Backpropagation com a terceira frequência e o terceiro modo de vibração.

As redes que tiveram a terceira frequência em conjunto do respectivo modo de vibração como dados de entrada também foram analisadas segundo a metodologia apresentada no trabalho.

Também foram variadas as funções de ativação, bem como o número de neurônios envolvidos no processamento do algoritmo. Com uma média mais alta de iterações (100), as redes passaram para as fases de testes após atingir erros mínimos na ordem de  $10^{-2}$ .

Os resultados estão mostrados a seguir na Figura 5.26, na qual é possível observar que, no caso da *Tansig*, o desempenho do sistema foi satisfatório independentemente do número de neurônios na camada intermediária. Pode-se dizer que a referida função continua apresentando bom desempenho neste tipo de aplicação, ou seja, em problemas cujo foco é localizar danos em vigas.

Os testes com *Purelin* revelam um bom comportamento perante a região de localização dos danos. No entanto, quando se avalia o desempenho da rede formada por 20 neurônios, verifica-se uma distorção dos resultados. Tal fato pode ter duas interpretações: a primeira refere-se a um possível excesso de neurônios, caracterizando um supertreinamento. Porém, em função do desempenho observado ao longo do

trabalho, tal possibilidade parece não ser correta, uma vez que, em análises com as mesmas características, os resultados foram positivos, inclusive com um maior número de neurônios;

A outra interpretação é uma possível instabilidade do sistema. Essa ocorrência acontece, pois o tipo de amostra utilizada apresenta uma simetria, de modo que, se observado mais cuidadosamente, nota-se que a localização “errônea” do sistema se deu em uma coordenada muito próxima da correta, no entanto em outro pico. Esse fenômeno pode ser evitado se, ao invés de se utilizar o modo completo da viga, se fornece no treinamento apenas o modo referente à metade da estrutura.

Com exceção da rede modelada com a primeira frequência o respectivo modo de vibração, a função *Logsig* não vem apresentando bom desempenho neste tipo de análise uma vez que, como se verifica no gráfico, os resultados observados em todas as configurações de neurônios, ficaram distantes da zona destacada como a região danificada da viga em estudo.

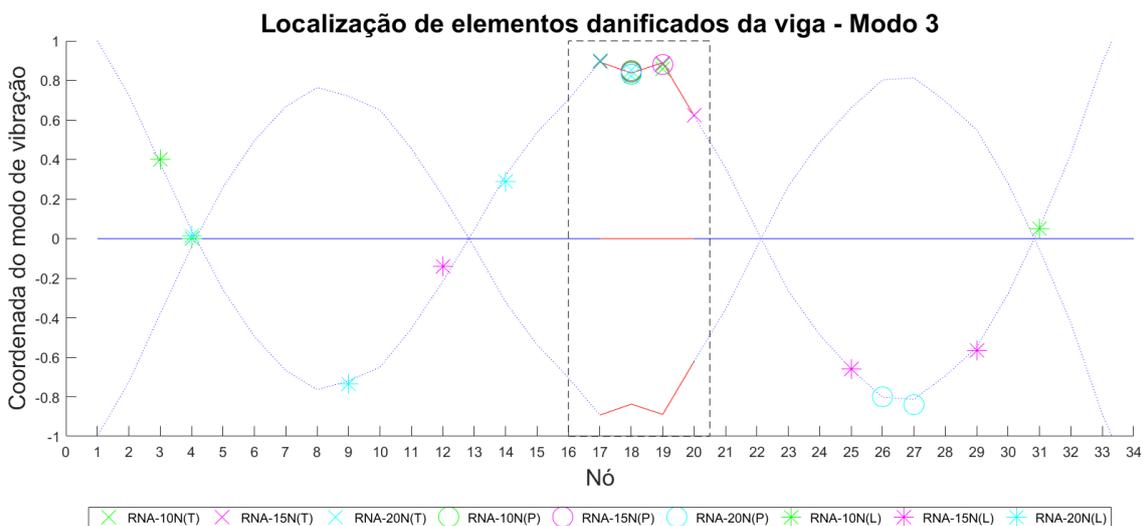


Figura 5.26 Resultados das rede RBFMV – Frequência e modo 3.

Vale ressaltar que as amostras fornecidas tanto nos treinamentos quanto nos testes foram normalizadas pelo valor máximo dos elementos da amostra, a fim de evitar possíveis distorções em função das diferenças de grandezas entre frequências e modos de vibração.

#### 4 Redes Backpropagation com a quarta frequência e o quarto modo de vibração.

Conforme metodologia apresentada, foram feitos os testes para as coordenadas do quarto modo de vibração. Para fins comparativos, foram utilizadas as mesmas funções mencionadas nos casos anteriores, bem como os mesmos números de neurônios, cujos resultados estão apresentados na Figura 5.27.

O processamento foi realizado com 1000 iterações e, conforme se observa nos gráficos, as redes formadas pela função *Tansig* foram as que apresentaram um desempenho mais aceitável, tendo em vista que algumas simulações falharam.

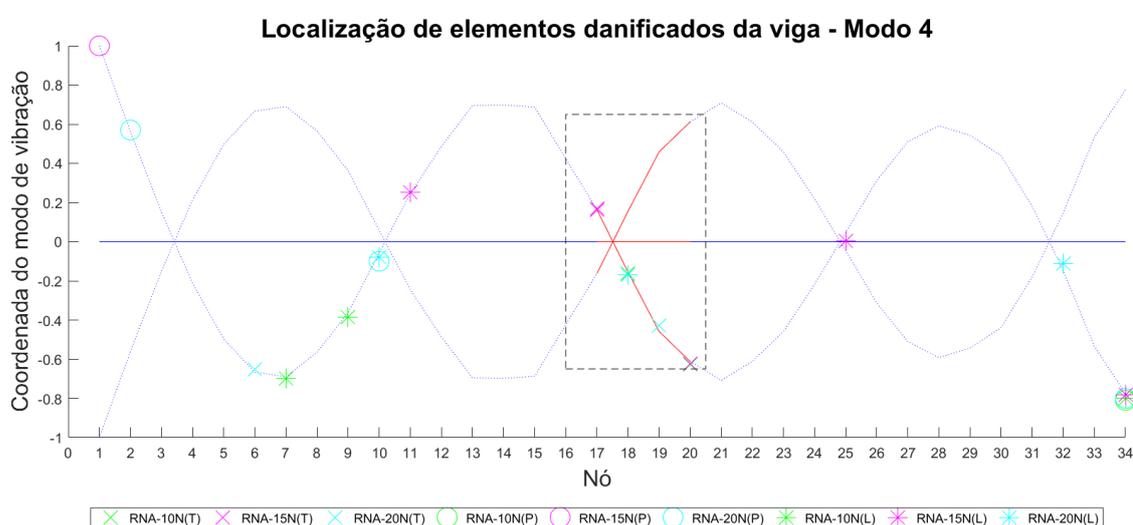


Figura 5.27 Resultados das rede RBFMV – Frequência e modo 4.

Como já era esperado, devido à sequência de resultados insatisfatórios relacionados às funções de ativação *Purelin* e *Logsig*, comprova-se, mais uma vez, que as referidas funções apresentam desempenho abaixo do esperado.

#### 5 Redes Backpropagation com a quinta frequência e o quinto modo de vibração.

Finalmente, as últimas RNAs *Backpropagation* analisadas também foram testadas com diferentes números de neurônios na camada intermediária, bem como com diferentes funções de ativação. As entradas corresponderam às coordenadas dos 34 nós

discretizados nas vigas em conjunto com a quinta frequência e, as saídas, foram sempre as coordenadas dos nós que circundavam os elementos que continham danos.

Assim, a partir dos resultados apresentados na Figura 5.28, no que diz respeito aos resultados dos testes feitos com as redes formadas pela função *Tansig*, percebe-se que algumas simulações não apresentaram resultado satisfatório, indicando que o dano da viga experimental, efetivamente posicionado nos nós 18, 19 e 20, se localizava em outros nós.

O processamento com as redes formadas pela função *Purelin* seguiu o comportamento de alguns casos anteriores, isto é, a função linear não apresentou desempenho capaz de localizar os danos da viga. Além da instabilidade da função, neste caso, trata-se de um modo “mais elevado”, o que resulta em um maior distanciamento entre dados numéricos e experimentais e, portanto, influenciando negativamente no desempenho da RNA.

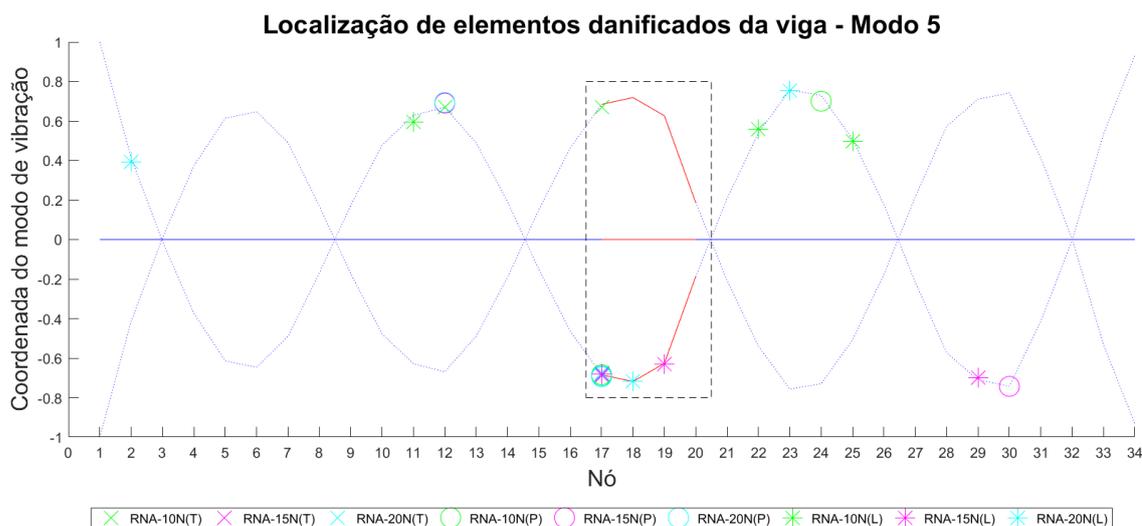


Figura 5.28 Resultados das rede RBFMV – Frequência e modo 5.

As redes compostas pela função *Logsig* também apresentaram a variação mencionada no caso anterior, isto é, uma piora nos resultados, também pelos mesmos motivos.

Conforme visto em alguns testes, a rede processou a posição dos nós diferentes dos corretos. Isto se deu devido a simetria do modo, sendo novamente indicado o uso de apenas a sua metade.

#### **5.4.4 Conclusões parciais das redes Backpropagation aplicadas à viga estudada.**

As RNAs *Backpropagation* foram aplicadas ao contexto de detecção de danos em um modelo experimental de viga sob algumas variações, desde o tipo de dado utilizado como entrada a aspectos relacionados à natureza da ferramenta. Assim, após todas as análises foram verificados os seguintes aspectos:

- Tipo de dado analisado:

Foram testados três grupos de dados, dentre os quais, o melhor desempenho da ferramenta ocorreu com o conjunto de modos de vibração. Naturalmente, tal fato já era esperado, uma vez que, segundo a literatura, quanto maior o universo de informações nos padrões de entrada, mais o algoritmo estabelece relações válidas entre os padrões de entrada e saída.

Contudo, foi observado que a rede apresenta dificuldades para alcançar seu objetivo, sobretudo quando trabalha com um modo mais elevado. Tal fato pode ser explicado pois quanto maior o grau do modo de vibração, mais distorções existem entre modos numéricos e experimentais. Assim, tendo em vista que a rede é treinada com informações obtidas por meio de modelagens numéricas e os testes são baseados nas informações dos modelos experimentais, o processamento do sistema inteligente pode não conseguir generalizar adequadamente o aprendizado, tendendo a apresentar divergências na fase de testes.

Além disso, observou-se ainda que, devido à simetria do modo, quanto mais fases tiver o modo de vibração, mais dificuldade o sistema apresenta, pois as coordenadas se repetem, dificultando o reconhecimento dos padrões. Para contornar tal fator, indica-se a utilização do modo obtido na metade da viga.

Outra observação importante está relacionada com regiões danificadas que coincidam com as zonas de menor deslocamento modal. Em todos os casos foi observado que a RNA tende a apresentar mais distorções.

Um fator curioso está relacionado às redes formadas pelas frequências de vibração. Foi notado que, por terem apenas 5 informações, supõe-se que a pequena quantidade influenciou nos resultados negativos. Deste modo, se os modelos numérico e experimental estiverem em total conformidade, a sugestão é realizar mais testes com um maior número de frequências ou alterar a maneira como a rede deve fornecer o resultado, ou seja, mudar o padrão de saída.

Vale ressaltar que as informações utilizadas como dados de entrada devem ser normalizadas, sobretudo quando se utilizam frequências e modos, uma vez que a discrepância entre os valores das informações pode resultar em mal desempenhos das redes neurais.

- Parâmetros da rede (funções de ativação e número de neurônios):

Em relação ao número de neurônios, foram seguidos alguns critérios de escolha já apresentados na comunidade científica, no entanto, na maioria dos casos, foi por tentativa e erro. O número de neurônios tem grande fator de decisão no processamento da rede, uma vez que quanto maior o número, melhor foi o desempenho. No entanto, como esperado, em alguns casos, o aumento exagerado acarretou na divergência dos resultados.

Embora indique-se que esta lacuna (o melhor número de neurônios a ser utilizado) deva ser respondida por tentativa e erro, uma vez que cada problema apresenta um nível particular de complexidade, poderia se recomendar uma aproximação calculando o número de neurônios na camada intermediária pela média do conjunto das variáveis de entrada de uma amostra e o número de amostras disponíveis para o treinamento. Tal critério foi verificado que atende tanto às RNAs formadas pelos modos de vibração, como às redes que foram treinadas com as frequências.

$$N_{nci} = \frac{N_{var,pe} + N_{atr}}{2} \quad (5.1)$$

Onde,

$N_{nci}$  → Número de neurônios na camada intermediária;

$N_{var,pe}$  → Número de variáveis em um padrão de entrada;

$N_{atr}$  → Número de amostras disponíveis para o treinamento.

Com relação às funções de ativação, como esperado, a função *Tansig* apresentou os melhores resultados. No entanto, o comportamento da função linear *Purelin* causou um certo destaque quando utilizada com as redes das frequências de vibração. Este grupo de redes, de maneira geral, não apresentou resultado satisfatório, porém com a referida função, mostrou-se bastante eficiente. Além disso, os resultados obtidos contrariaram um aspecto que a literatura coloca no sentido de ter sempre a necessidade de uma função não linear no sistema Haykin (2001). Como apresentado, em uma das análises foi utilizada a função linear duas vezes e o desempenho foi um dos melhores.

Diante do exposto, sugere-se que sejam feitos novos testes em outras estruturas para comprovar tal comportamento.

Com relação à função *Logsig*, observou-se que, para os primeiros modos, a função se comporta adequadamente. No entanto, tal desempenho reverte a partir do terceiro modo de vibração. Tal fato pode ser explicado pela natureza da função. Como seu domínio vai de 0 até 1, e as amostras utilizadas neste estudo vão de -1 até 1, sobretudo quando o modo é mais elevado, a função não se adequa ao tipo de dado utilizado como padrão de entrada. Assim, supõe-se que a função é eficiente para padrões que sejam compreendidos no intervalo de 0 a 1.

## **5.5 Learning Vector Quantization - LVQ**

Conforme metodologia apresentada, na qual foram indicadas as RNAs a serem estudadas, este tópico descreve as análises feitas com a viga sob a perspectiva do *Learning Vector Quantization* (LVQ), cuja regra de aprendizado é supervisionada e, portanto, necessita de um conjunto dados de entrada e saída para o seu funcionamento.

Assim como no caso das redes *Backpropagation*, neste caso também foram criados e testados 3 diferentes grupos de RNAs. O primeiro, referindo-se às redes tendo apenas os modos de vibração como dados de entrada, foi nomeado por LVQ-MV.

O segundo grupo, chamado de redes LVQ com frequências (LVQ-FV), foi formado considerando as 5 primeiras frequências do modelo como informações para a RNA. Já o terceiro grupo foi destinado às redes formadas pela associação das frequências com os respectivos modos de vibração e, portanto, nomeada por LVQ -

MFV. Os tópicos seguintes detalham as análises individuais feitas para cada grupo, cujas arquiteturas utilizadas estão apresentadas na Figura 5.29.

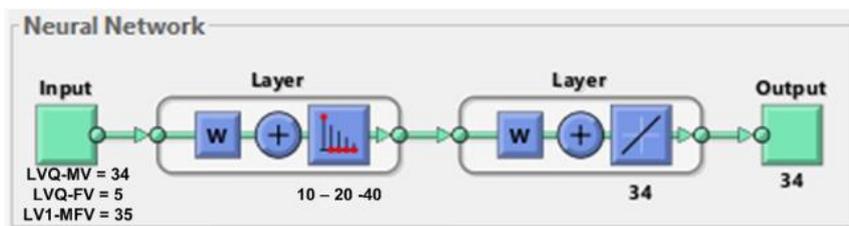


Figura 5.29 Arquitetura LVQ.

Para a obtenção dos dados usados na fase de treinamento foram criados além dos 32 modelos numéricos com diferentes cenários de danos (danos em diferentes posições e severidades), mostrados na Tabela 5.3, 4 modelos intactos, isto é, sem redução nas inercias, no entanto, sob efeito de variação na temperatura. Esses novos modelos foram gerados a fim de acrescentar padrões intactos para o sistema ter como referência, uma vez que a variação da temperatura não altera os modos de vibração, mas sim as frequências. Já na fase de testes foram utilizadas as informações do modelo experimental estudado, a viga de Brasiliano (2005).

### 5.5.1 LVQ com modos de vibração (LVQ-MV)

No objetivo de avaliar o desempenho do LVQ na detecção de danos na viga experimental estudada e apresentada na seção 5.2, foram criadas, treinadas e testadas cinco Redes Neurais Artificiais tendo o algoritmo LVQ.

Considerando as três fases que uma RNA necessita passar para apresentar um bom desempenho, na fase de treinamento as redes receberam como conjuntos de dados de entrada as coordenadas dos cinco primeiros modos de vibração dos cenários modelados numericamente (cada modo com as coordenadas dos 34 nós das vigas). As saídas foram vetores de 34 coordenadas numeradas com “0” e apenas aquela que continha o elemento danificado, continha a numeração 1, conforme ilustrado na Figura 5.30.

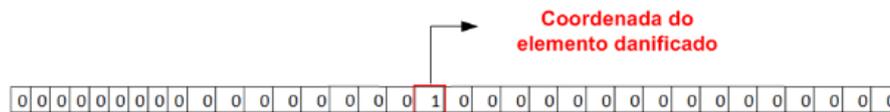


Figura 5.30 Saídas do LVQ - MV.

Deste modo, a rede 1 teve como entrada os dados do primeiro modo de vibração, a segunda rede, as coordenadas do segundo modo, e, assim, sucessivamente.

As redes formadas pelos primeiros modos de vibração tiveram como entrada apenas as 34 coordenadas da primeira forma de vibrar da viga. Para verificar o desempenho da RNA, foram simulados sistemas com 10, 20 e 40 neurônios, valores estes definidos pelo processo de tentativa e erro, bem como baseado no critério definido para RNAs *Backpropagation* (equação 5.1).

Vale ressaltar que, conforme apresentado na revisão da bibliografia, existem várias teorias para a escolha do número de neurônios, no entanto, a tentativa e erro é ainda o critério mais utilizado para essa tarefa. Deste modo, tais valores foram escolhidos ao serem observados os erros durante o treinamento de 1000 iterações, ficando na ordem de  $10^{-3}$ . Além disso, a taxa de aprendizado foi o *default* do Matlab: 0,01.

Para verificar a convergência das saídas processadas pelas redes, cada teste foi realizado três vezes, de modo que os resultados plotados representam cada uma das verificações, conforme observa-se nas Figura 5.31 (rede formada pelo primeiro modo de vibração), Figura 5.32 (rede formada pelo segundo modo de vibração), Figura 5.33 (rede formada pelo terceiro modo de vibração), Figura 5.34 (rede formada pelo quarto modo de vibração) e Figura 5.35 (rede formada pelo quinto modo de vibração).

Nos gráficos, observam-se que existem 3 níveis de marcação, um para cada rede, dependendo do número de neurônios utilizados. Na cor magenta estão os resultados obtidos pelas redes formadas por 10 neurônios; já as cores cian e verde referem-se, respectivamente, àquelas RNAs compostas por 20 e 40 células artificiais. Além disso, existe uma região delimitada, representando o intervalo onde existem elementos danificados no modelo experimental que, neste caso, são os elementos 18 e 19, circundados pelos nos 18, 19 e 20.

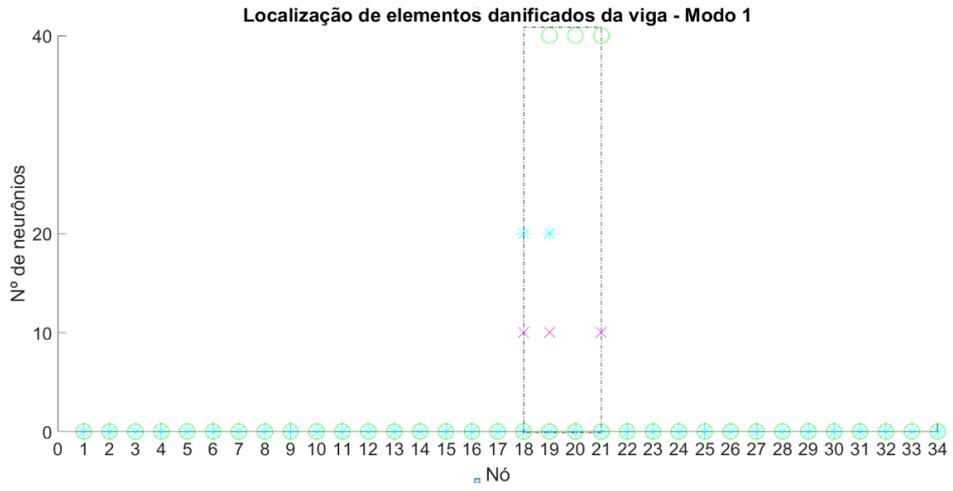


Figura 5.31 LVQ – MV – rede 1.

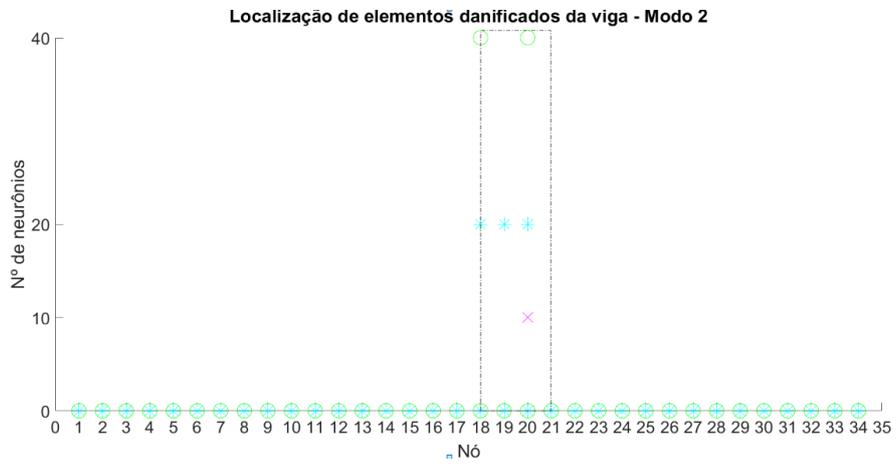


Figura 5.32 LVQ – MV – rede 2.

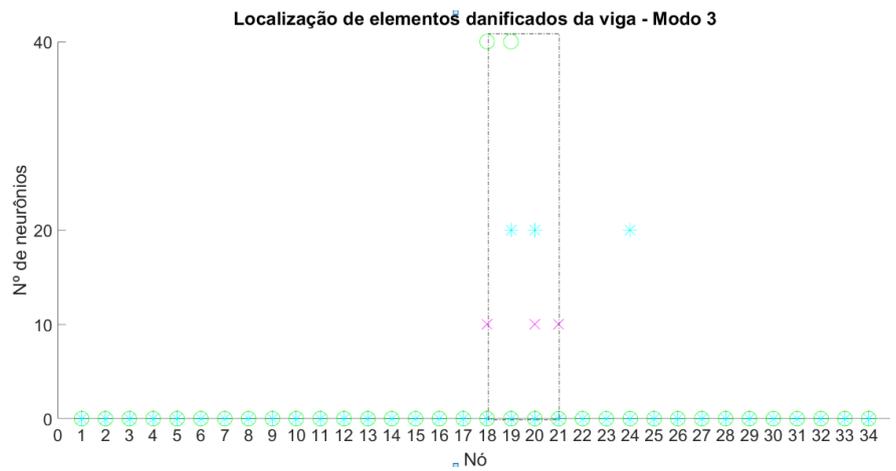


Figura 5.33 LVQ – MV – rede 3.

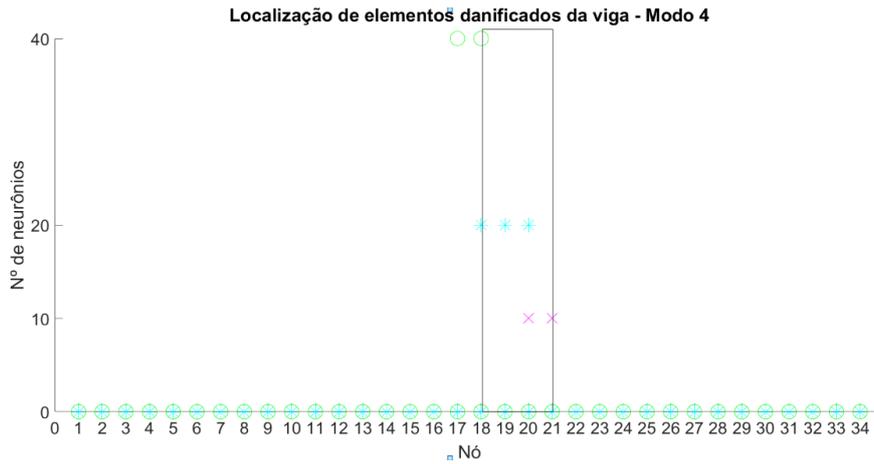


Figura 5.34 LVQ – MV – rede 4.

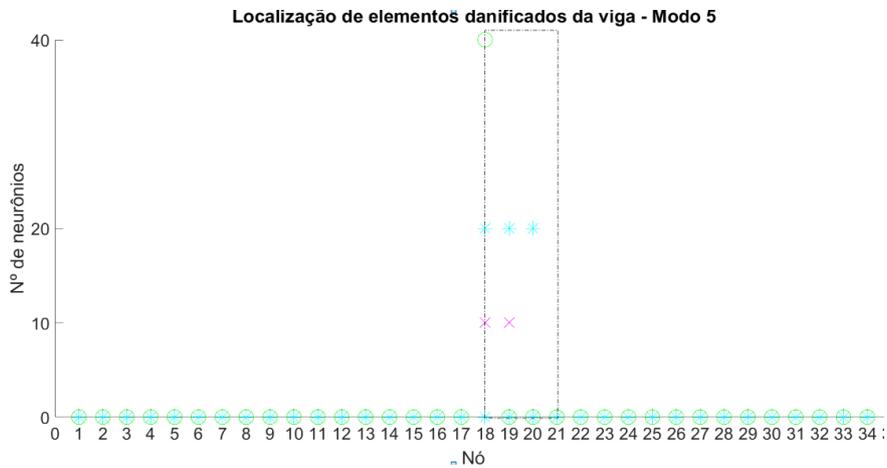


Figura 5.35 LVQ – MV – rede 5.

Em todos os casos observa-se que, de maneira geral, o algoritmo foi capaz de identificar o elemento que tinha dano correntemente. Chama-se atenção para algumas simulações cujos resultados estão ilustrados só por duas marcações. Como os *outputs* da rede correspondem a valores binários (1 ou 0), o fato de a rede processar saídas iguais resulta na percepção de apenas um resultado.

Diferentemente dos resultados obtidos com a rede *Backpropagation*, nestes casos são eliminadas as possíveis associações devido à simetria do modo e, além deste fator, há sempre uma resposta objetiva, de modo que não há intervalos para a classificação entre intacto e danificado.

É possível notar que os resultados obtidos após o processamento da rede apresentaram grande aproximação da região danificada da viga, uma vez que para todos

os testes, as saídas das redes se localizaram dentro da região em destaque, indicando, portanto, um bom funcionamento do sistema.

Especificamente nos resultados das redes formadas pelos terceiro e quarto modos de vibração (Figura 5.33 e Figura 5.34), verificam-se algumas respostas fora da zona designada como danificada. Porém, tal resultado pode ser aceito, uma vez que as respostas processadas pelas RNAs foram sempre nós adjacentes à referida zona e, certamente, podem ser perturbadas devido à presença de danos estruturais.

Neste sentido, com base nos resultados apresentados, pode-se afirmar que o desempenho deste tipo de rede foi satisfatório, sendo, inclusive, mais preciso se comparados aos resultados obtidos com a rede *Backpropagation*. Assim, indica-se também esse tipo de sistema inteligente no contexto do monitoramento estrutural, especificamente, na detecção de danos estruturais.

### **5.5.2 LVQ com as frequências vibração (LVQ-FV)**

Com os mesmos objetivos da seção 5.5.1 (localizar os danos da viga experimental), foram criadas, treinadas e testadas Redes Neurais Artificiais com o LVQ LVQ, tendo como dados de entrada as 5 primeiras frequências de vibração da estrutura e nomeadas como LVQ-FV.

Nestes casos, nas fases de treinamento, as redes receberam como conjuntos de dados (entrada e saída) as cinco primeiras frequências de vibração e o padrão danificado, respectivamente, conforme apresentado na Figura 5.30.

Neste caso também foram feitas algumas variações no número de neurônios utilizados no sistema, de modo que as análises apresentadas estão com 10, 20, 40, 390 e 400 células artificiais. Para fins comparativos, inicialmente foram consideradas as mesmas quantidades verificadas nas análises anteriores (10 e 20 neurônios), no entanto, como os resultados não foram satisfatórios, optou-se por aumentar o número de unidades até que fosse verificado um bom desempenho, que obteve-se a partir de 390 neurônios.

Assim, as arquiteturas das RNAs ficaram definidas conforme esquema da Figura 5.36, de modo que os treinamentos aconteceram em 100 iterações, obtendo erros quadráticos (MSE) na ordem de  $10^{-3}$ .

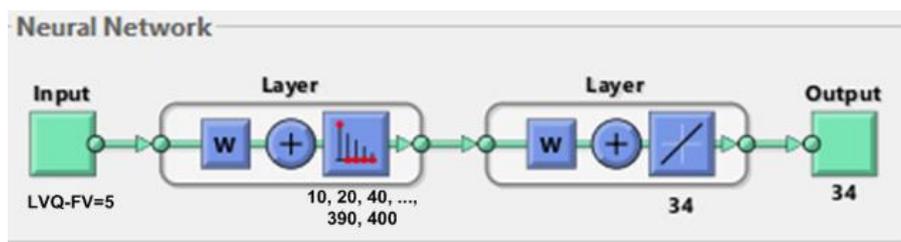


Figura 5.36 Arquitetura LVQ – FV.

Os resultados obtidos estão apresentados na Figura 5.37, na qual verifica-se que, para redes formadas com poucos neurônios, o sistema não funciona adequadamente, uma vez que as saídas processadas pelo algoritmo foram todas fora da região caracterizada por elementos que continham reduções nas suas seções transversais (elementos 18 e 19). Porém, ao ser aumentada a quantidade das unidades artificiais, o desempenho melhora significativamente. Tal fato pode ser explicado pois, sendo um tipo de rede que trabalha com padrões binários, quando maior for o banco de informações nos dados entrada, maior a probabilidade de acertos do sistema.

Neste caso, como se trabalhou apenas com as cinco primeiras frequências, supõe-se que seriam necessárias mais informações pertinentes aos padrões. No entanto, para contornar a falta informações, foram acrescentados neurônios, de modo que a rede passou a representar uma boa relação entre entradas e saídas, sendo capaz de localizar corretamente a região onde estavam os danos da viga experimental. Vale ressaltar que, apesar de haver aumento significativo nas unidades artificiais, isto não interferiu no tempo de processamento do algoritmo, não representando, efetivamente, uma desvantagem deste tipo de rede.

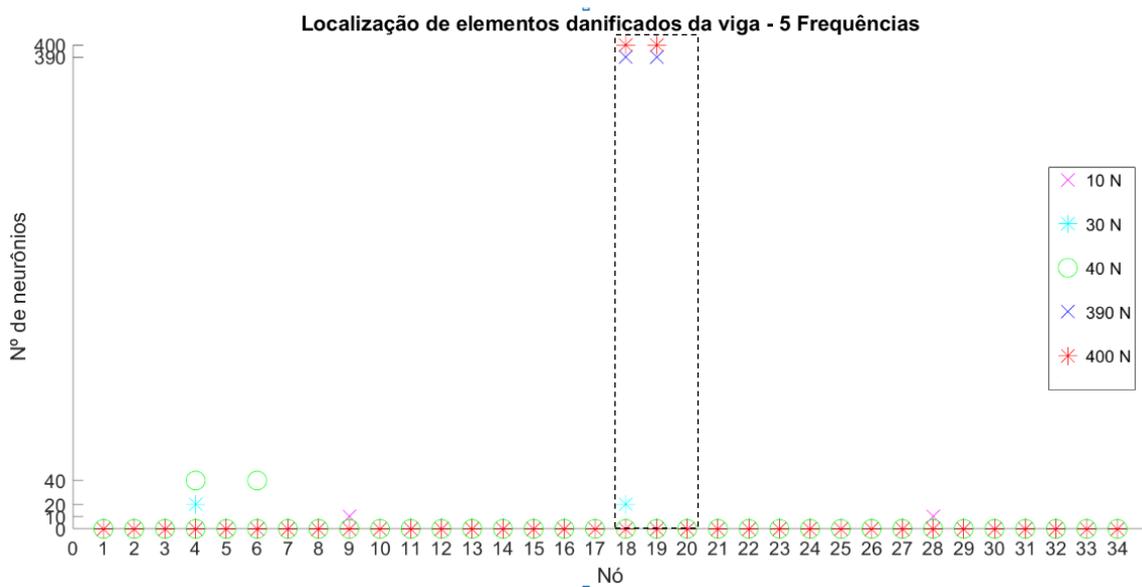


Figura 5.37 LVQ – FV.

### 5.5.3 LVQ com os modos e as frequências vibração (LVQ-MFV)

Nesta modalidade foram criadas cinco redes, cada uma referente a um modo de vibração da viga, por exemplo, a primeira rede foi treinada e testada com a primeira frequência e o respectivo modo de vibração dos modelos. Neste contexto, para fins comparativos, foram feitos testes com 10, 20 e 40, e os erros encontrados foram da ordem de  $10^{-3}$ .

A fim de avaliar a performance das RNAs, aos testes foram fornecidos as frequências e os modos de vibração do modelo experimental da viga danificada (redução na seção transversal dos elementos 18 e 19) para as redes 1 (primeira frequência e respectivo modo de vibração), 2 (segunda frequência e respectivo modo de vibração), 3 (terceira frequência e respectivo modo de vibração), 4 (quarta frequência e respectivo modo de vibração) e 5 (quinta frequência e respectivo modo de vibração).

Deste modo, os vetores de entrada corresponderam às frequências seguidas das coordenadas 34 coordenadas dos respectivos modos de vibração, gerando um vetor de 35 elementos, como mostra a Figura 5.38.

Já as saídas foram fornecidas conforme o padrão já apresentado na Figura 5.30.

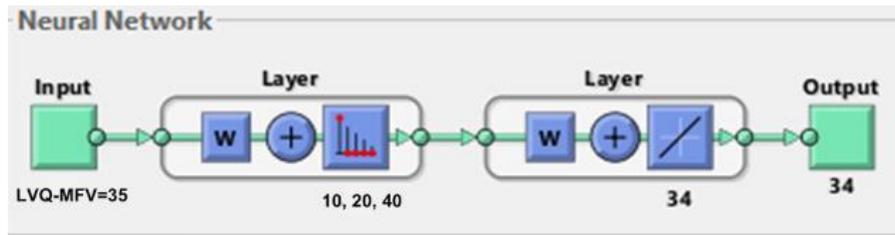


Figura 5.38 Arquitetura LVQ – MFV.

Com os resultados encontrados pelas RNAs, é possível observar que as redes foram capazes de identificar com uma boa precisão a posição dos elementos danificados. De maneira geral, da rede 1 a 5, os nós apontados corresponderam às posições 18, 19 ou 20. Especificamente nas redes 2 e 3 (Figura 5.40 e Figura 5.41) observaram-se que duas simulações aconteceram fora do esperado, no entanto, seguindo a mesma justificativa referente à proximidade dos nós, tais resultados podem ser aceitos.

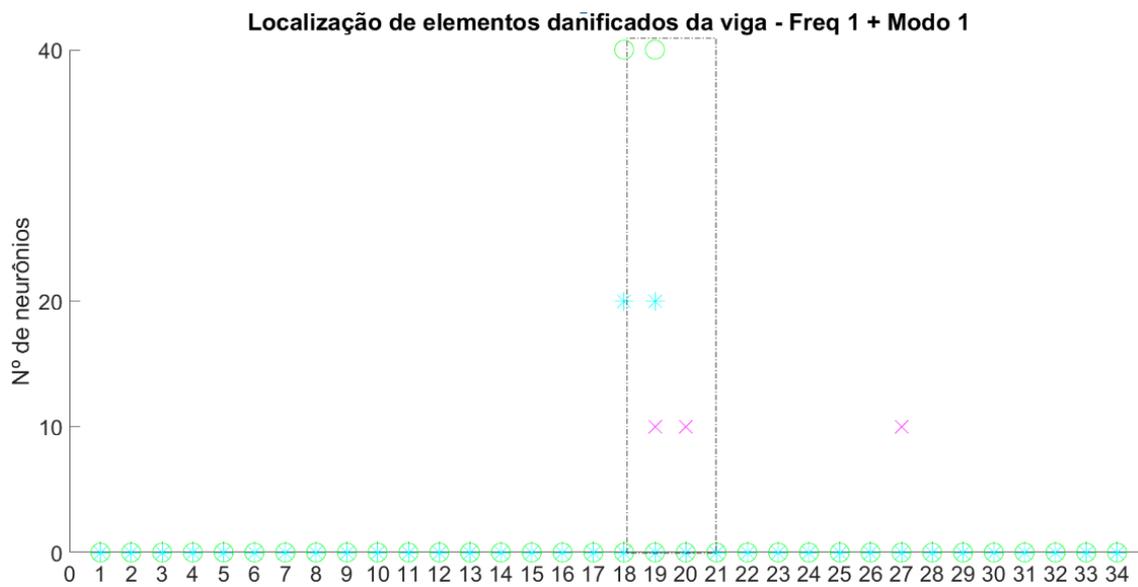


Figura 5.39 LVQ – MFV 1.

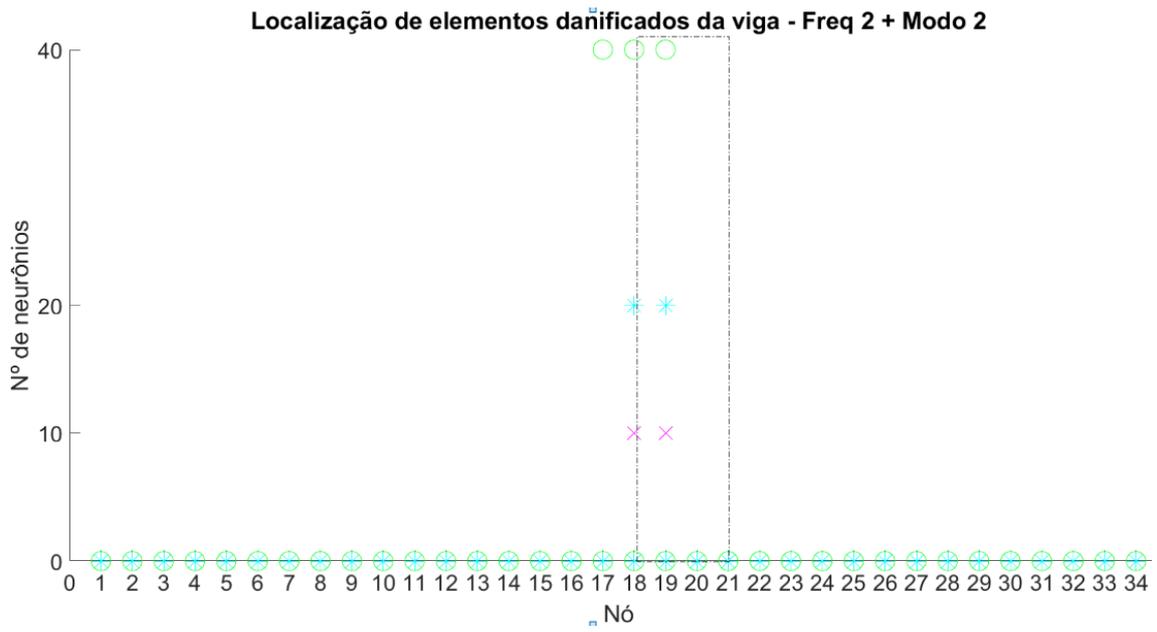


Figura 5.40 LVQ – MFV 2.

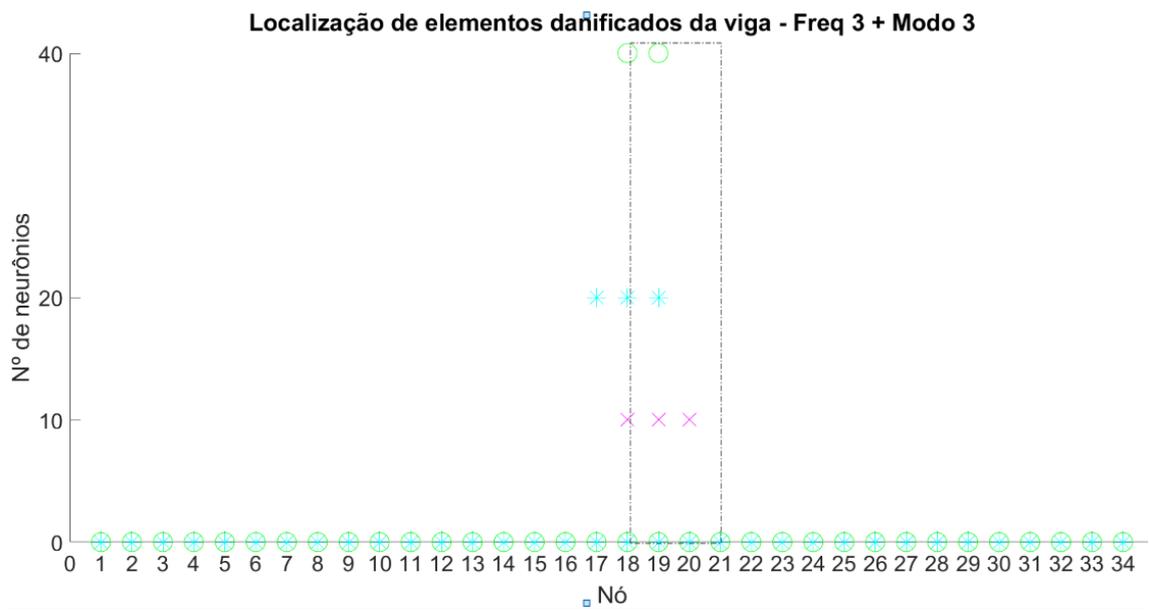


Figura 5.41 LVQ – MFV 3.

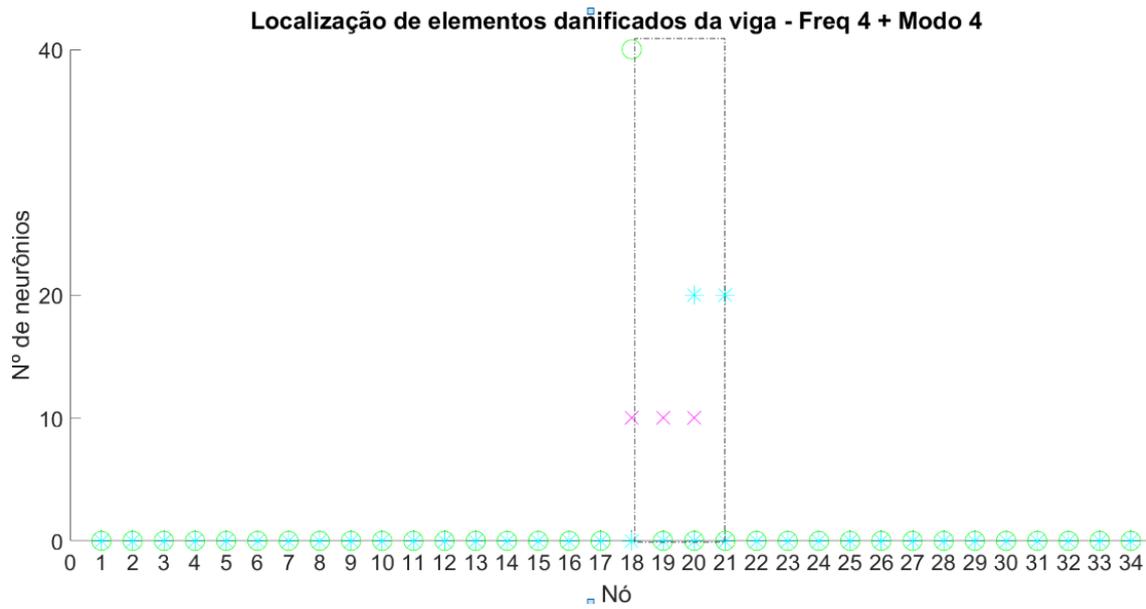


Figura 5.42 LVQ – MFV 4.

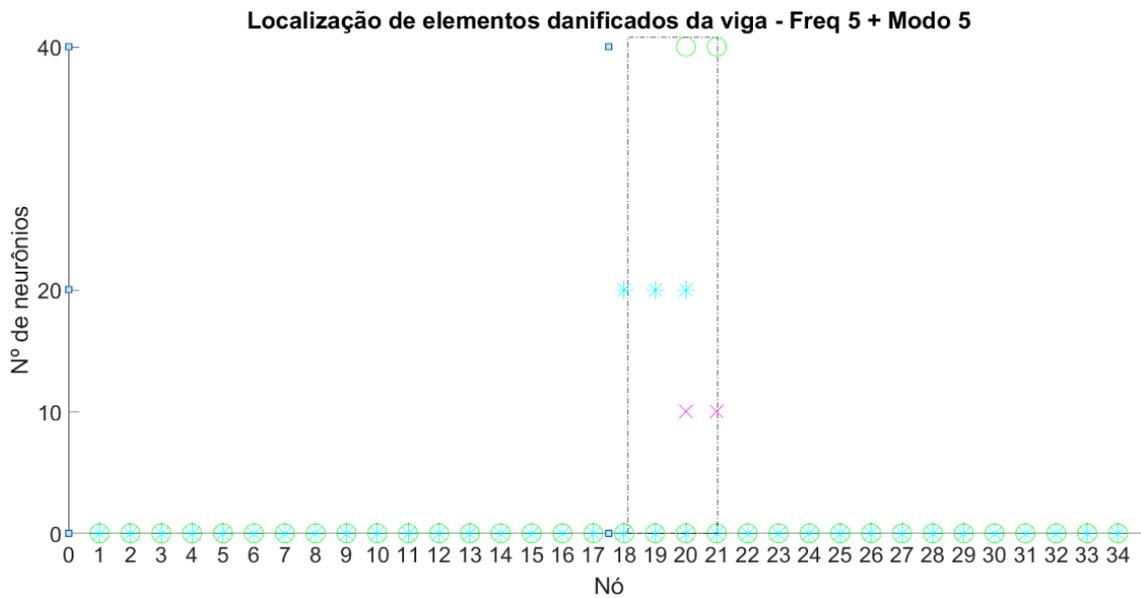


Figura 5.43 LVQ – MFV 5.

Pelo bom desempenho apresentado em todos os casos, pode-se indicar que esta configuração (frequência + modos de vibração) de RNA LVQ apresenta uma tendência para ser utilizada no contexto do monitoramento estrutura, sobretudo na área de detecção de danos.

É importante ressaltar que os testes feitos aqui foram em uma viga experimental, desenvolvida em laboratório e, portanto, com todos os testes de vibração sob controle da equipe. Assim, antes de extrapolar tais análises para um sistema usual é necessário, ainda, testar a metodologia em situações com menor índice de supervisão, inclusive, sob efeitos de ruídos.

#### **5.5.4 Conclusões parciais das redes LVQ aplicadas à viga estudada.**

As RNAs com o algoritmo LVQ aplicadas ao contexto de detecção de danos em um modelo experimental de viga apresentaram algumas variações que vão, desde o tipo de dado utilizado como entrada a aspectos relacionados à natureza da ferramenta. Assim, após todas as análises foi possível elaborar algumas conclusões parciais sobre:

- Tipo de dado analisado:

Foram testados três grupos de dados, dentre os quais, o melhor desempenho da ferramenta ocorreu com as redes formadas pelos modos de vibração ou pela associação da frequência com o respectivo modo de vibração. Naturalmente, tal fato já era esperado, uma vez que, segundo a literatura, quanto maior o universo de informações nos padrões de entrada, mais o algoritmo estabelece relações válidas entre as informações fornecidas e as processadas.

Diferentemente das RNAs *Backpropagation*, devido ao padrão binário de treinamento deste tipo de rede, foi excluído o fator duvidoso relacionado com a simetria do modo, eliminando a problemática de quanto mais fases tiver o modo de vibração, mais dificuldade o sistema apresenta.

Vale ressaltar que as informações utilizadas como dados de entrada devem ser normalizadas, sobretudo quando se utiliza frequência e modos, uma vez que a discrepância entre os valores das informações pode resultar em mal desempenhos das redes neurais.

- Parâmetros da rede (número de neurônios):

Pode-se dizer que o número de neurônios pouco influenciou nos resultados das redes que tinham os modos de vibração como dados de entrada, uma vez que os resultados foram, na maioria das simulações, satisfatórios. No entanto, observando o

caso dos sistemas formados pelo conjunto das frequências, é possível verificar que a quantidade de células artificiais foi determinante.

Inicialmente, foi utilizada a mesma quantidade de neurônios em outros tipos de rede para que fosse possível estabelecer uma comparação. Contudo, como os resultados foram muito abaixo do esperado, foram adicionados mais neurônios, de modo que o primeiro resultado positivo só foi possível com a utilização de 390 unidades artificiais. Vale ressaltar que, apesar de ser um número alto quando comparado com as demais análises, do ponto de vista de processamento tal fator não representa um problema, já que, computacionalmente, o tempo gasto é em torno de 2 minutos para mil iterações.

Assim, como ponto de partida para formação de uma rede LVQ com este tipo de aplicação e utilizando modos de vibração como padrão de entrada, sugere-se a mesma formulação considerada para as redes *Backpropagation*, isto é:

$$N_{nci} = \frac{N_{var,pe} + N_{atr}}{2} \quad (5.1)$$

Onde,

$N_{nci}$  → Número de neurônios na camada intermediária;

$N_{var,pe}$  → Número de variáveis em um padrão de entrada;

$N_{atr}$  → Número de amostras disponíveis para o treinamento.

Já no caso dos sistemas formados pelo conjunto das frequências, como uma estimativa inicial para o número de neurônios na camada intermediária, os resultados apresentaram uma tendência para a seguinte formulação:

$$N_{nci} = \frac{1,2 \times N_{var,pe} + 1,2 N_{atr}}{2} \times 10 \quad (5.1)$$

Além da localização dos danos, a fim de verificar a robustez do sistema, foram testados padrões intactos no sentido de verificar se o sistema era capaz de diferenciar uma estrutura intacta e outra com zonas danificadas. Os resultados estão mostrados no apêndice A.1 e foram bastante favoráveis, indicando, portanto, que o LVQ apresentou não só o melhor desempenho, mas também o mais confiável, uma vez que não deixa margens para incertezas.

Salienta-se que os testes foram feitos com dados controlados em laboratório e, portanto, é de grande importância testar a ferramenta em situações de maiores incertezas.

## 6. ESTUDO NUMÉRICO DA PONTE INFANTE DOM HENRIQUE

### 6.1 Ponte Infante Dom Henrique

Este capítulo descreve a aplicação das Redes Neurais Artificiais (RNAs) no contexto de monitoramento estrutural de obras de arte. Deste modo, são apresentadas as características físicas da estrutura estudada, a Ponte Infante Dom Henrique, em Portugal, bem como as análises feitas com base em um banco de dados obtidos por meio de um monitoramento contínuo e os resultados obtidos a partir de dois tipos de redes neurais: as *Self Organizing Maps* (SOM) e a *Learning Vector Quantization* (LVQ), com vistas à detecção de danos estruturais.

#### 6.1.1 Descrição da ponte

Localizada sobre o rio Douro, ligando as cidades do Porto e de Gaia, no Norte de Portugal, a Ponte Infante Dom Henrique (Figura 6.1) tem 371 m de comprimento, com um arco ao longo de 280 m de sua parte central. A estrutura da ponte é constituída por dois elementos principais: uma viga caixão rígida, de concreto protendido de 4,50 m de altura, apoiada sobre um arco de concreto com 1,50 m de espessura.

O vão entre os arranques do arco é de 280 m e a flecha entre o fecho e os arranques é de 25 m, apresentando uma relação de abatimento superior a 11. Ao longo dos 70 m centrais, o arco une-se ao tabuleiro formando uma seção em caixão com 6 m de altura, cujas faces laterais apresentam um recorte que mantém a continuidade dos volumes correspondentes ao tabuleiro e ao arco, Fonseca e Mato (2005) - Figura 6.2.



Figura 6.1 Ponte Infante Dom Henrique (Magalhães, 2010).

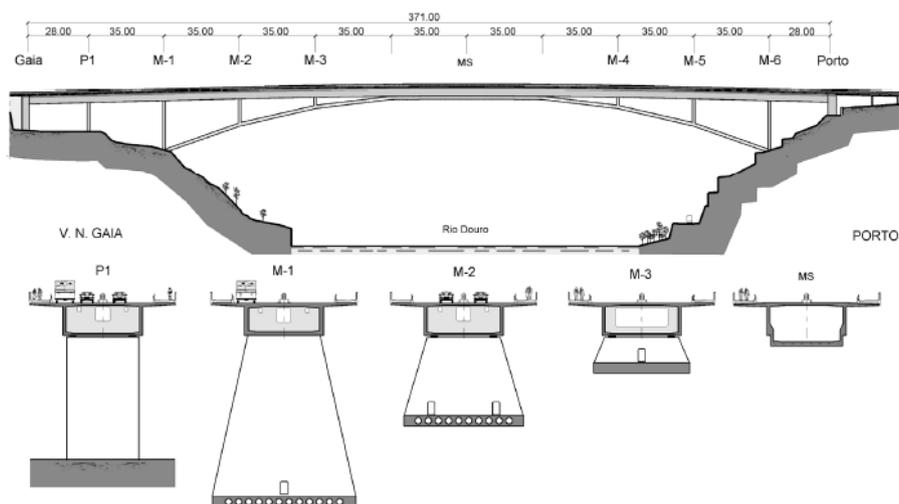


Figura 6.2 Dimensões gerais da ponte Infante Dom Henrique (Adão da Fonseca e Millanes Mato, 2005).

Devido à grande rigidez do tabuleiro em comparação com a do arco, aliada ao forte abatimento deste, o funcionamento da estrutura se assemelha ao de uma ponte em que o tabuleiro trabalha a flexão, tal como numa ponte contínua convencional, mas proporcionando ao arco vários apoios elásticos intermédios através dos montantes afastados de 35 m entre si, conforme se observa na Figura 6.1.

### 6.1.2 Características dinâmicas da ponte

A fim de se conhecer os parâmetros modais da ponte, antes da instalação de um sistema de monitoramento contínuo dinâmico, o *Vibest (Laboratory of Vibrations and Monitoring)* da Faculdade de Engenharia da Universidade do Porto (FEUP) realizou alguns testes de vibração ambiental.

Durante os testes foram colocados dois sismógrafos de referência localizados na seção transversal da plataforma, ambos na posição indicada na Figura 6.3. Além dos sismógrafos de referência, foram utilizados outros dois aparelhos móveis, percorrendo as 15 seções transversais restantes, de modo a coletar acelerações da estrutura nas três direções ortogonais: vertical, transversal e longitudinal, em ambos os lados da ponte.

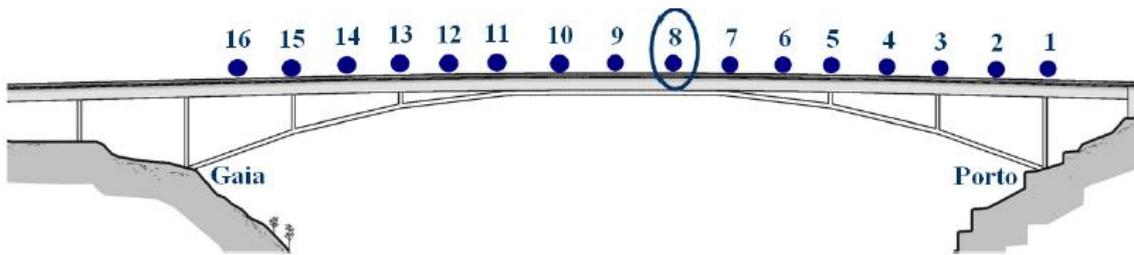


Figura 6.3 - Instrumentação da ponte para teste de vibração ambiental (Magalhães,2010).

Cada aquisição foi realizada durante 16 minutos a uma frequência de amostragem de 100Hz e, posteriormente, passando a 20Hz. No ensaio foram coletadas acelerações verticais, transversais e longitudinais, ao longo de 32 pontos, sendo as principais frequências e seus respectivos modos de vibração identificados por meio dos métodos *Frequency Domain Decomposition* (FDD) e *Data-driven Stochastic Subspace Identification* (SSI-Data), conforme ilustrado na Figura 6.4.

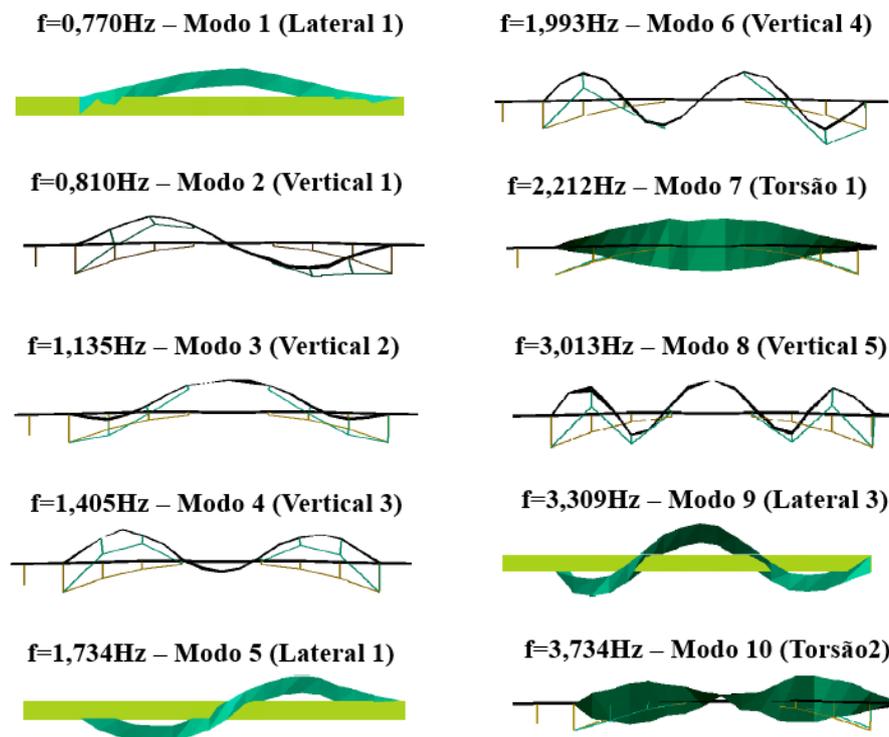


Figura 6.4 Frequências e modos de vibração da ponte. (Magalhães 2010).

A partir dos resultados obtidos dos testes, a ponte passou a ser monitorada experimentalmente ao longo do período compreendido entre 2007 e 2014, além de possibilitar o desenvolvimento e calibração de um modelo numérico da estrutura.

### 6.1.3 Monitoramento contínuo da ponte

O sistema de monitoramento contínuo foi instalado até a metade da estrutura, uma vez que, a partir dos testes de vibração ambiental, verificou-se que os modos de vibração da estrutura apresentavam simetria (Magalhães 2010). Basicamente, o sistema foi composto por 2 digitalizadores (localizados nas seções S2 e S4) que recebiam sinais dos 12 acelerômetros distribuídos, conforme o esquema da Figura 6.5.

Os acelerômetros foram igualmente distribuídos nas quatro seções a fim de se obter uma adequada caracterização de flexões vertical, lateral e modos de torção. Por meio dos digitalizadores, os dados eram produzidos e transferidos para FEUP (Faculdade de Engenharia da Universidade do Porto), onde um software obtinha o histórico de aceleração com uma taxa de amostragem de 50Hz e comprimento de 30 minutos e eram processados pelo *software* de monitoramento dinâmico DynaMo (Magalhães, 2010, ViBest).

Este *software* foi desenvolvido no ambiente do Matlab e, por meio de uma conexão com a internet, recebia as informações da estrutura instrumentada, gerando um banco de dados com registros dos 12 acelerômetros e, caso necessário, tratava-o com vistas à eliminação dos efeitos ambientais e de frequências acima de 12,5 HZ, utilizando ferramentas estatísticas e o método da Regressão Múltipla Linear. Além disso, o programa também é capaz de identificar automaticamente os parâmetros modais da ponte (Magalhaes *et. al* 2014).

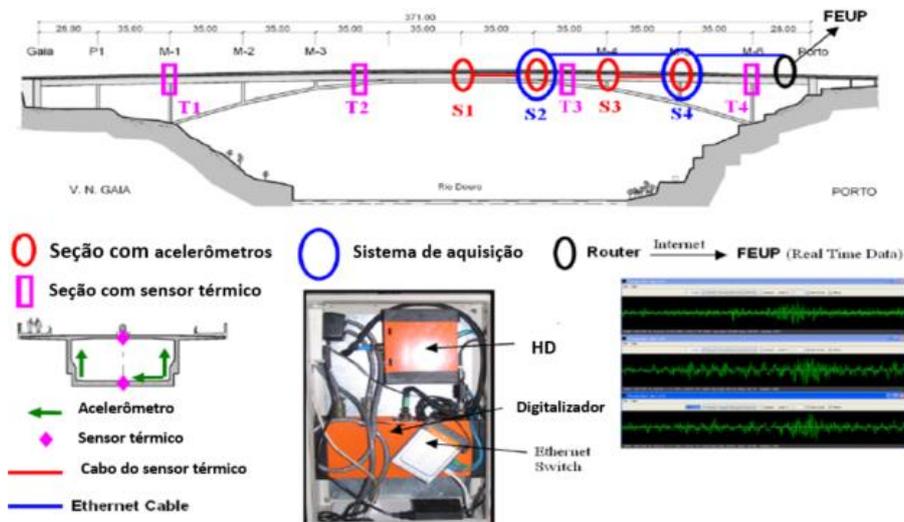


Figura 6.5 Esquema do sistema de monitoramento. (Magalhães 2010 - adaptada).

O monitoramento contínuo da ponte Infante D. Henrique teve início em 13/09/2007, se estendendo até 12/09/2014, no entanto, para este trabalho foi utilizado o banco de dados entre 2007 e 2009, sendo, portanto, parâmetros modais da estrutura referentes a dois anos, em um total de 17568 aquisições (cada uma contendo as 12 primeiras frequências), em cada ano.

A Figura 6.6 mostra a evolução temporal da média diária das primeiras 12 frequências naturais da ponte, obtidas durante o período de monitoramento considerado neste trabalho (primeiro ano 13/09/07 a 12/09/08 e o segundo ano 13/09/08 a 13/09/09), as quais são utilizadas para as análises com vistas à detecção de danos estruturais.

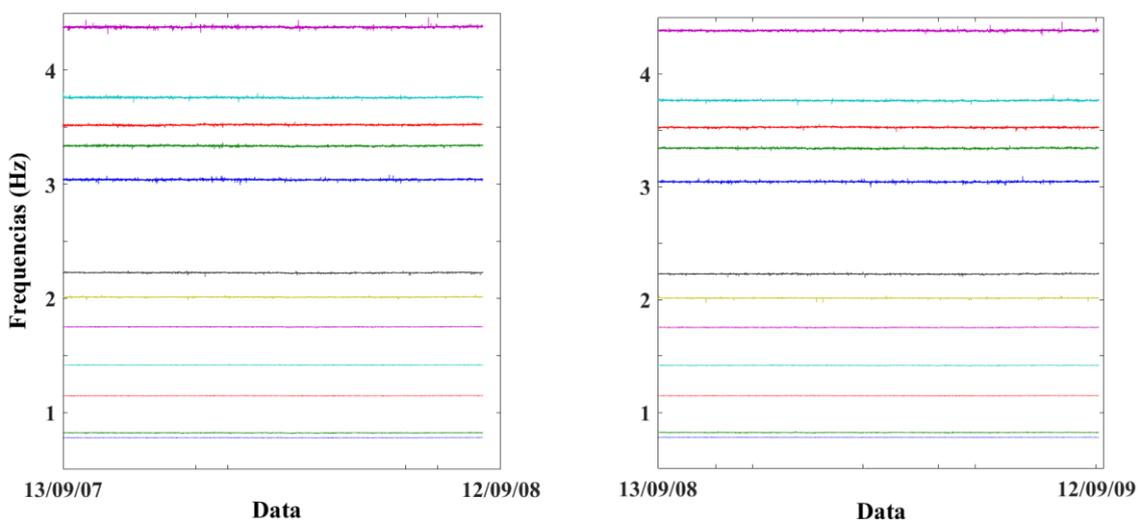


Figura 6.6 Evolução temporal da média diária das primeiras 12 frequências naturais da ponte de 13/09/2007 até 12/09/2009.

Em análises realizadas por Magalhães (2014) foi possível observar que, durante o segundo ano de acompanhamento, as frequências apresentaram uma variação máxima relativa de 2,6%. Como essa diferença foi atribuída, em parte, aos efeitos das variações grandes de temperatura observadas na cidade, foi necessária a utilização do Dynamo para a mitigação dos efeitos da temperatura. Além disso, o autor verificou que a estrutura não continha danos significativos e capazes de provocar variações significativas nas frequências.

#### **6.1.4 Modelagem numérica**

A ponte Infante Dom Henrique foi simulada também numericamente e, a partir desse modelo, desenvolvido por Magalhães (2010), surgiram dados que alimentaram as RNAs aplicadas na detecção de danos estruturais, estes últimos necessários para o funcionamento da ferramenta.

A modelagem “Espinha de Peixe” foi realizada no *software* ANSYS, utilizando elementos de barra 3D, tendo como características geométricas e físicas as mesmas associadas à estrutura projetada (módulo de elasticidade de 37GPa adotado para os concretos do tabuleiro e do arco e 34GPa para o concreto das colunas).

As ligações entre o tabuleiro e os pilares das extremidades (Figura 6.2) foram consideradas livres. Já nos aparelhos de apoio dos outros pilares os graus de liberdade referentes aos deslocamentos longitudinais e as rotações foram considerados fixos, além de serem acrescentadas molas horizontais para simular a rigidez adicional fornecida pelos pilares (Magalhães, 2010).

As características dinâmicas do modelo numérico estão indicadas na Figura 6.7 e as comparações com os resultados experimentais obtidas nos testes de vibração ambiental na Tabela 6.1. A correlação entre os parâmetros modais foi boa, com erros relativos em frequências naturais inferiores a 5% e valores MAC (*Modal Assurance Criterion*) sempre maiores que 0,95.

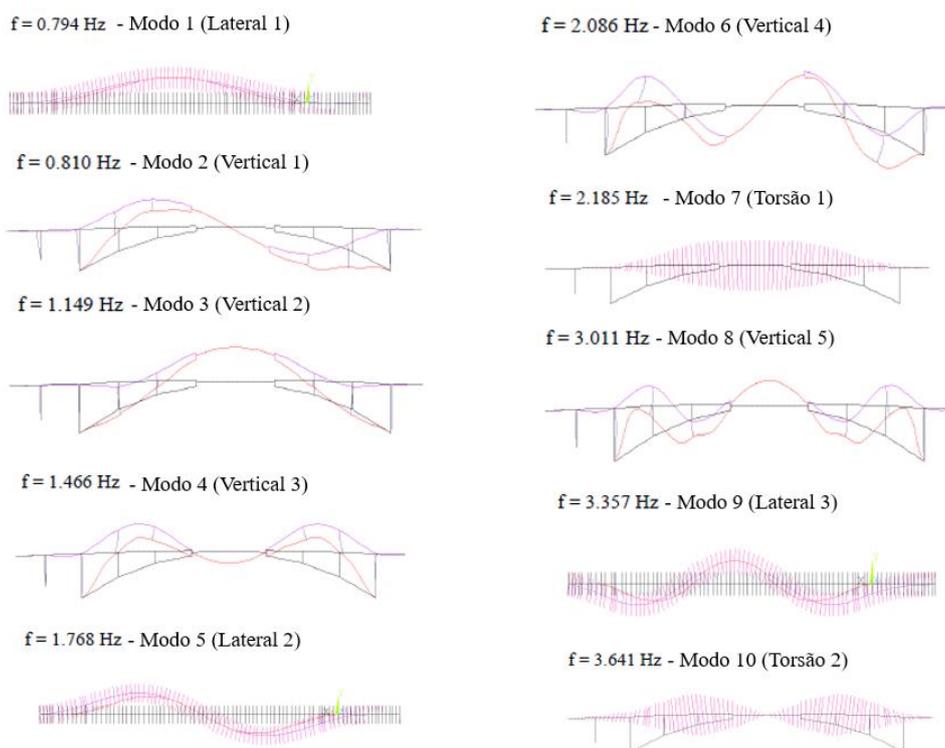


Figura 6.7 Frequências e modos de vibração do modelo numérico da ponte. (Magalhães 2010) - Adaptada.

Tabela 6.1 Frequências naturais (Hz) dos modelos experimental e numérico.

Modo	Frequência Ponte (Hz)	Numérica (Intacta-Hz)	Erro (%)	MAC
Lateral 1	0,770	0,794	3,12	0,996
Vertical 1	0,810	0,810	-0,12	0,995
Vertical 2	1,135	1,149	1,23	0,994
Vertical 3	1,405	1,467	4,34	0,992
Lateral 2	1,734	1,768	1,96	0,989
Vertical 4	1,993	2,086	4,72	0,994
Torsão 1	2,212	2,185	-1,18	0,956
Lateral 3	3,309	3,357	1,42	0,956
Torsão 2	3,734	3,641	-2,49	0,952

A partir do modelo numérico, Magalhães (2010) desenvolveu e simulou cenários danificados para a ponte que serviram para fornecer o banco de dados utilizado junto às RNAs deste trabalho.

Danos em pontes podem se manifestar de diversas maneiras como, por exemplo, recalque de fundação, a ruptura dos cabos causados pela corrosão, patologias do

concreto motivadas pela corrosão da armadura, entre outros, sendo, portanto, uma difícil tarefa quando se trata de representá-los numericamente. Desta forma, foi seguida uma abordagem simples para a simulação de regiões danificadas, considerando que os danos são de pequena dimensão, no sentido de não comprometer a segurança da ponte.

Os danos foram simulados por uma redução de inércia de 10% ao longo de alguns segmentos da ponte que estão em destaque na Figura 6.8. D1, D2, D3 e D4 representam os segmentos danificados, de modo que as reduções de inércia foram consideradas ao longo de 8,75 m, 10,0 m, 3,0 m; e 5,0 m, de comprimento, respectivamente.

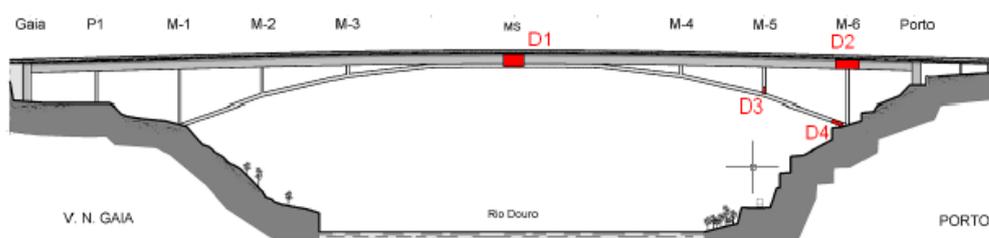


Figura 6.8 Localização e extensão dos cenários de danos simulados (Magalhães, 2010).

As frequências obtidas em cada cenário danificado estão apresentadas na Tabela 6.2. Nota-se que a variação entre as frequências da ponte e dos modelos danificados é muito pequena, na ordem de 0,4% (Figura 6.9). Além disso, observou-se que as diferenças entre as frequências dos modelos numéricos (intacto e danificados) foram menores do que as observadas entre as frequências obtidas no teste de vibração ambiental (da ponte) e do modelo numérico, dificultando, portanto, o funcionamento adequado dos métodos de detecção de danos.

Tabela 6.2 Frequências naturais (Hz) obtidas para cada um dos cenários danificados D1, D2, D3 e D4.

Modo	Frequência	Freq. Ponte (Hz)	Numérica (Intacta-Hz)	Cenários de danos			
				Frequência D1 (Hz)	Frequência D2 (Hz)	Frequência D3(Hz)	Frequência D4(Hz)
Lateral 1	1	0,770	0,794	0,794	0,794	0,794	0,794
Vertical 1	2	0,810	0,810	0,810	0,809	0,809	0,810
Vertical 2	3	1,135	1,149	1,147	1,148	1,149	1,148
Vertical 3	4	1,405	1,467	1,465	1,464	1,465	1,466
Lateral 2	5	1,734	1,768	1,768	1,768	1,768	1,768
Vertical 4	6	1,993	2,086	2,086	2,083	2,086	2,084
Torsão 1	7	2,212	2,185	2,185	2,185	2,185	2,185
Vertical 5	8	3,013	3,011	3,011	3,008	3,009	3,003
Lateral 3	9	3,309	3,357	3,357	3,357	3,357	3,357
Vertical - arco	10	3,490	3,287	3,287	3,287	3,279	3,276
Torsão 2	11	3,734	3,641	3,641	3,641	3,641	3,641
Vertical 6	12	4,339	4,129	4,129	4,129	4,129	4,128

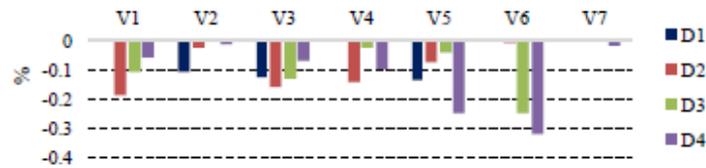


Figura 6.9 Porcentagem de variação das frequências naturais de vibração dos modos de flexão vertical (Magalhães, Cunha e Caetano, 2014).

Desta maneira, para contornar esse desajuste, foi criado um coeficiente de dano para simular a variação da frequência sempre que fosse considerada a presença de um dano na estrutura.

O coeficiente consiste na diferença entre uma frequência obtida a partir do modelo numérico intacto e a frequência de um dos cenários danificados apresentados. Assim, para considerar que uma frequência da estrutura foi obtida de um dos cenários danificados, basta multiplica-lo pelo seguinte coeficiente:

$$\text{Coef. de dano} = 1 + \frac{\Delta \text{freq}}{100} \quad (6.1)$$

Onde,

$\Delta \text{freq} \rightarrow$  Diferença entre uma frequência do modelo numérico intacto e a frequência de um dos cenários danificados considerados.

Como a aplicação das RNAs no contexto de detecção de danos requer padrões que indiquem modelos intactos e danificados, todas as considerações de modelo danificado foram feitas a partir desse coeficiente.

Desta forma, como a estrutura da ponte não tem danos significativos, para a consideração da ponte danificada, parte das frequências obtidas por meio do monitoramento contínuo foram multiplicadas pelo coeficiente de dano (Tabela 6.3), passando a ser consideradas como informações obtidas da ponte danificada. O detalhamento dessa consideração está nas próximas seções.

Tabela 6.3  $\Delta freq$  de cada uma das frequências, em cada cenário de dano.

Modo	Frequência	D1	D2	D3	D4
		$\Delta Freq$ (%)	$\Delta Freq$ (%)	$\Delta Freq$ (%)	$\Delta Freq$ (%)
Lateral 1	1	0,000	0,000	0,000	0,000
Vertical 1	2	0,000	-0,190	-0,108	-0,059
Vertical 2	3	-0,112	-0,025	-0,007	-0,014
Vertical 3	4	-0,126	-0,160	-0,133	-0,072
Lateral 2	5	0,000	0,000	0,000	0,000
Vertical 4	6	-0,001	-0,141	-0,028	-0,100
Torsão 1	7	0,038	0,000	0,000	0,000
Vertical 5	8	-0,137	-0,079	-0,045	-0,248
Lateral 3	9	0,009	0,000	0,000	0,000
Vertical - arco	10	-0,001	-0,011	-0,251	-0,323
Torsão 2	11	0,000	0,001	0,000	0,000
Vertical 6	12	-0,001	-0,006	-0,001	-0,022

## 6.2 Redes Neurais Artificiais para avaliação de danos na ponte

Considerando as fases de treinamento e teste que uma rede precisa passar para ter um funcionamento adequado, por se tratarem de redes com diferentes algoritmos de treinamento (aprendizado), isto é, o LVQ é supervisionado e o SOM é não supervisionado, os critérios para escolha dos conjuntos de dados utilizados em cada abordagem são tratados em seções específicas para cada aplicação. Contudo, em ambos os casos foram usadas as 12 primeiras frequências obtidas por meio de um monitoramento contínuo realizado na ponte durante os 2 anos, bem como estas mesmas frequências modificadas por meio de simulações numéricas (consideração de dano).

Para verificar o desempenho, cada uma das redes foi analisada a partir da variação de alguns parâmetros, dentre os quais estão: número de neurônios e o número de padrões de entrada fornecidos para o processamento.

Particularmente com relação ao número de amostras fornecidas para as etapas de treinamento e de teste, pode-se dizer que esta variação tem o objetivo de verificar a robustez da técnica mesmo com um pequeno grupo de informações. Como a ponte em questão passou por monitoramento contínuo, existem informações que permitem trabalhar com dados obtidos durante:

- 24 h de monitoramento;
- 1 semana de monitoramento, e
- 1 mês de monitoramento.

Desta forma, o esquema da utilização das RNAs na detecção de danos da Ponte Infante Dom Henrique está ilustrado na Figura 6.10, de modo que o objetivo destas análises se foca em detectar se há dano na estrutura e não em localizar, como foi o caso da viga estudada anteriormente.

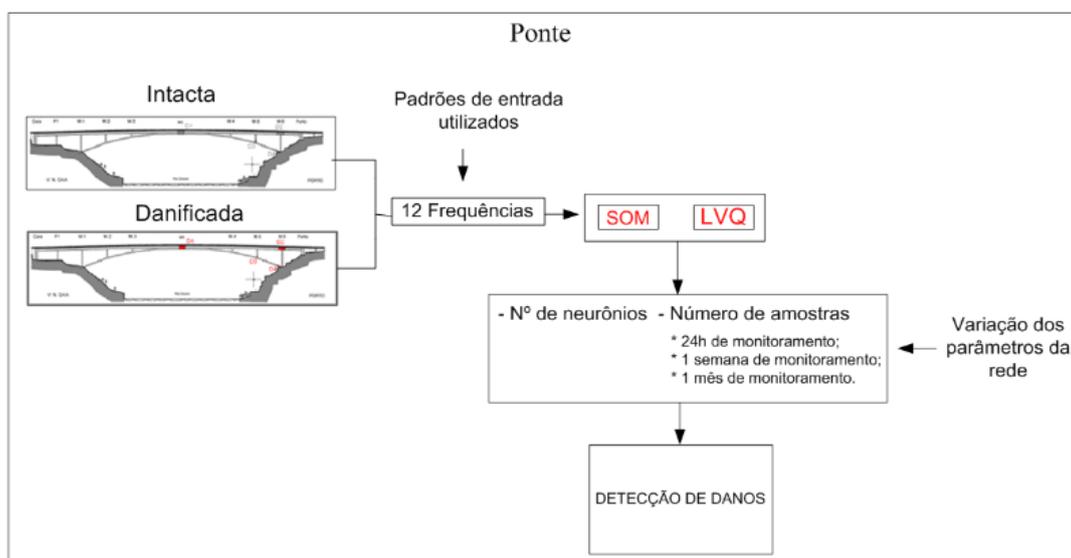


Figura 6.10 Esquema de teste realizados com as rede SOM e LVQ.

## 6.2.1 Learning Vector Quantization – LVQ

A detecção de danos utilizando LVQ foi realizada no ambiente do Matlab, especificamente o *Neural Network Toolbox (Nntool)*, que é um pacote destinado ao uso das RNAs, em seus mais diversos tipos. Por possuir uma interface gráfica interativa, o Nntool é uma ferramenta de fácil acesso, capaz de fornecer a visualização e simulação de diferentes tipos de RNAs, em diferentes configurações, sejam elas no modo de aprendizado, no algoritmo utilizado para o seu treinamento, na maneira de processar dos dados, bem como nas funções de ativação utilizadas.

### 6.2.1.1 Dados de entrada - LVQ

Por ser um algoritmo de treinamento supervisionado, o processamento do LVQ tem início com a indicação dos dados a serem utilizados em cada etapa. Em outras palavras, no caso do treinamento devem ser dados padrões de entrada e saída e, na fase

de teste devem ser fornecidas como entradas as variáveis (padrão) do problema que se deseja resolver.

Estas informações devem seguir uma organização, de modo que as amostras de dados (cada aquisição de frequências) devem compor as colunas e, nas linhas, devem conter as variáveis do padrão. Neste trabalho, as amostras correspondem a cada conjunto de 12 frequências obtidas no monitoramento da estrutura com e sem modificação e, as variáveis, correspondem desde a 1ª até 12ª frequência identificada.

Para a detecção de danos foi assumido que a partir de setembro de 2008 a ponte passou a ter as frequências alteradas pelos danos artificiais (Figura 6.11). Desta forma, a partir da referida data, as frequências obtidas por meio do monitoramento contínuo foram multiplicadas pelo coeficiente de dano (Equação 6.1 e Tabela 6.3), passando a ser consideradas como informações obtidas da ponte danificada.

Como em Portugal existem variações significativas de temperatura e, mesmo com a minimização dos seus efeitos (software Dynamo – Magalhães 2010) podem existir variações de frequências decorrentes do fenômeno, foram escolhidos 4 meses de referência para o estudo, janeiro e julho do primeiro ano de monitoramento (linhas em vermelho simbolizando frequências da estrutura intacta), e novembro e maio (linhas verticais em azul simbolizando frequências da “estrutura danificada”, Figura 6.11).

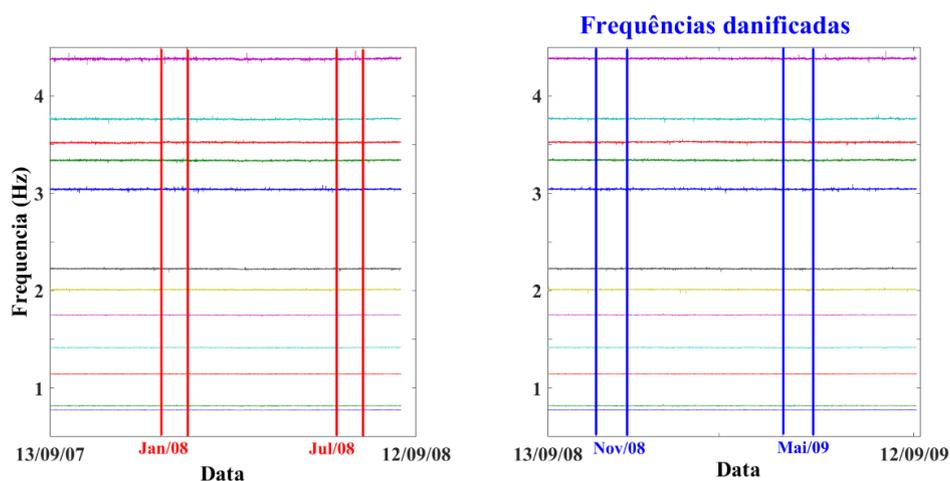


Figura 6.11 Frequências utilizadas no LVQ.

Foram utilizados 4 padrões de frequências obtidas dos modelos danificados (1 de cada cenário - Figura 6.12), bem como 2 padrões de frequências assumidas como intactas (referentes às informações colhidas nos primeiro ano de monitoramento e no segundo – sem modificação), de modo que cada um é composto por 12 frequências (em cada aquisição) que podem apresentar alteração ou não em função da presença, posição e intensidade do dano.

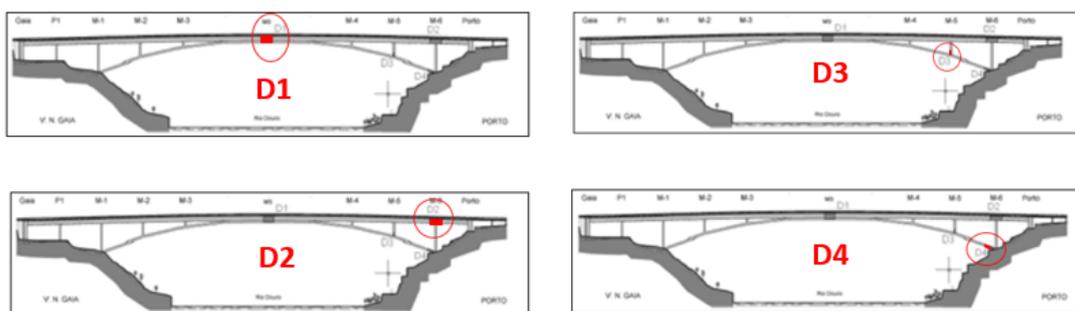


Figura 6.12 Cenários danificados do modelo da ponte.

Como as variações entre esses padrões são muito pequenas e, a fim de definir a melhor maneira de treinar a RNA, o histórico das frequências de cada cenário danificado e da estrutura intacta foram analisadas e estão apresentadas na Figura 6.13. O padrão “fIntacta” refere-se às frequências obtidas nos meses de janeiro e julho do primeiro ano de monitoramento e, portanto, intactas (2880 aquisições). Já os padrões “fd1”, “fd2”, “fd3” e “fd4” são as frequências obtidas nos meses de novembro e maio do segundo ano de monitoramento e, portanto, multiplicadas pelos coeficientes de dano de cada um dos cenários já apresentados.

Nota-se que os valores são muito próximos, no entanto, em alguns casos essas diferenças são ligeiramente mais acentuadas. É o que acontece nos gráficos referentes às frequências dos modos vertical do tabuleiro 2, 3, 5 e da frequência referente ao modo vertical do arco.

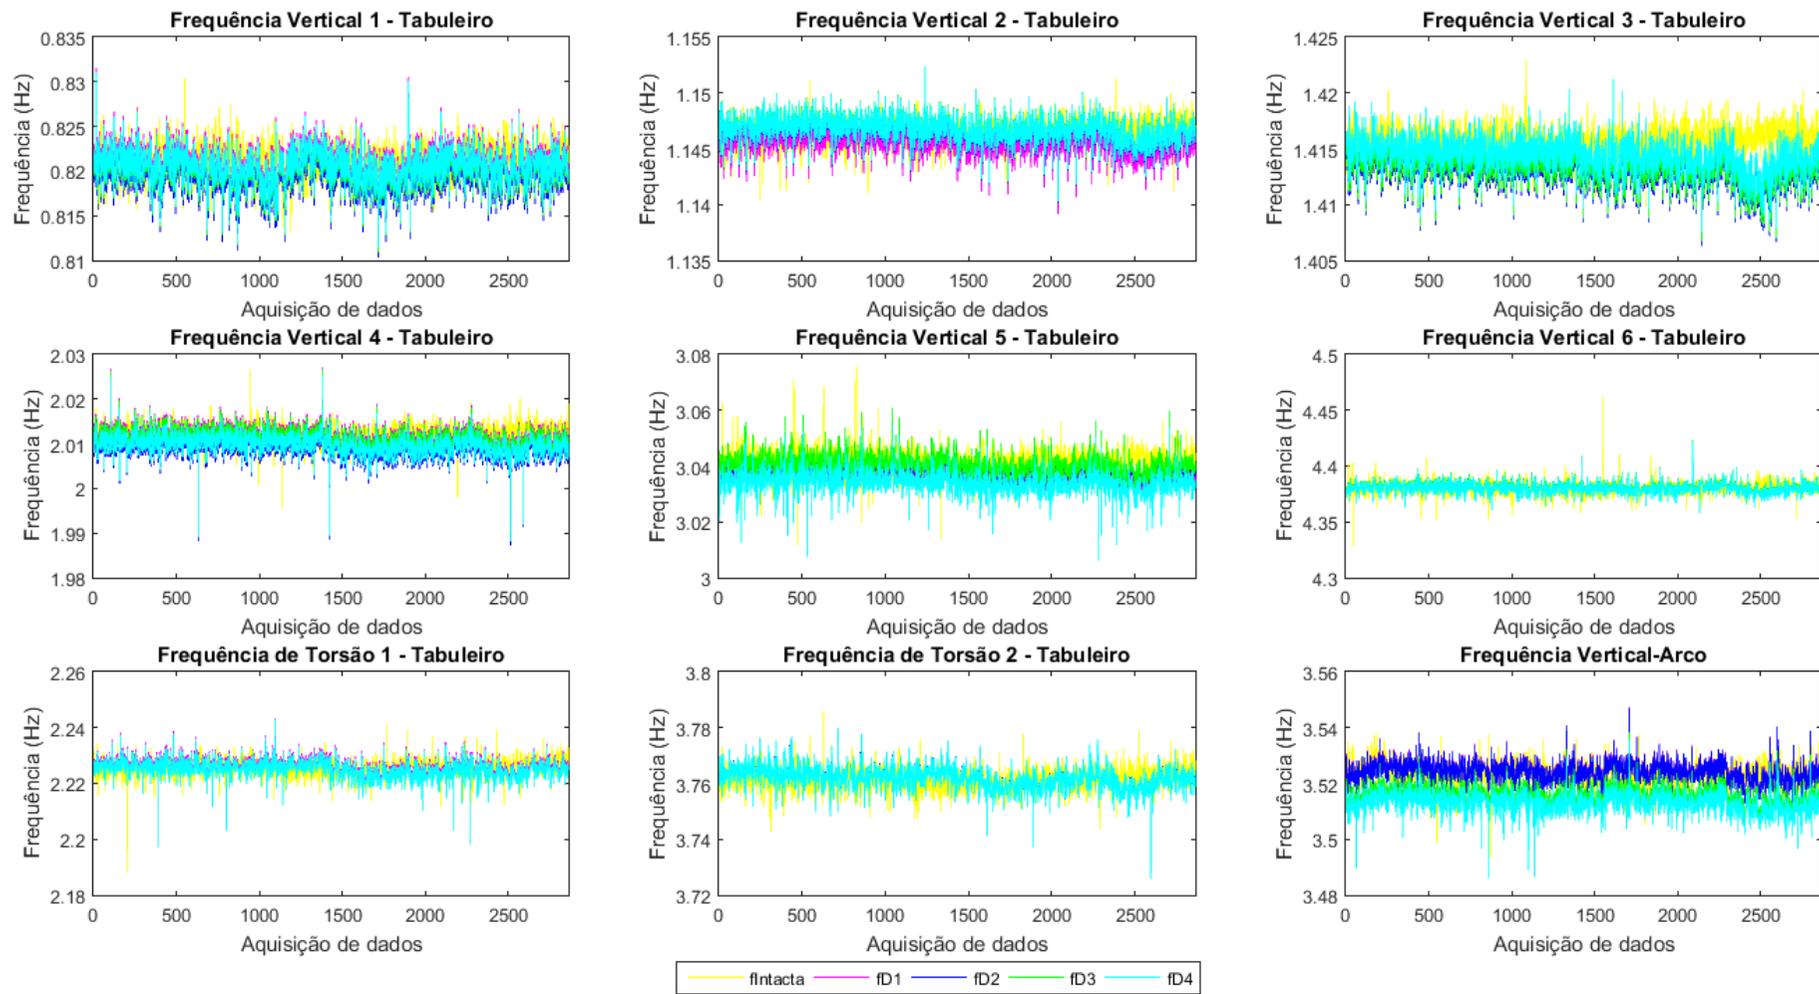


Figura 6.13 Sobreposição das frequências utilizadas no estudo.

Observa-se, ainda, que os padrões referentes aos modelos com danos D1(fD1) e D2(fD2) apresentam variações semelhantes, comportamento este que se repete ao serem observados os padrões D3(fD3), D4(fD4), sobretudo no gráfico referente às frequências verticais do arco, fatos explicados, provavelmente, pelas posições e intensidades dos danos.

Considerando que a rede apresenta um funcionamento mais adequado quando o seu treinamento é realizado com um maior número de padrões, concluiu-se que a rede deveria ser treinada com frequências de 3 padrões diferentes. Deste modo, estabeleceu-se o treinamento tendo como entradas um padrão intacto, um padrão referente aos cenários danificados D1 ou D2, somado ao terceiro padrão, referente aos modelos danificados D3 ou D4.

#### **6.2.1.2 Redes e resultados - LVQ**

Foram realizados dois tipos de análises, sendo a primeira relativa ao uso dos padrões de treinamento indicados (frequências do primeiro ano de monitoramento, assumidas como intactas + frequências de dois padrões danificados) e, na fase de teste, foram fornecidas como entradas as frequências obtidas no segundo ano de monitoramento da estrutura, sem considerar nenhum tipo de modificação causada por dano.

O segundo tipo de análise foi realizado utilizando no treinamento o já mencionado conjunto de padrões, e os testes foram realizados com as informações dos outros modelos danificados, excluindo os utilizados no treinamento. Assim, o diagnóstico a respeito da saúde da estrutura é construído sob o prisma das duas análises, conforme apresentado na Tabela 6.4

Tabela 6.4 Análises feitas com LVQ.

Análise	Rede	Treinamento	Teste
1	1	Frequências 1º ano (Intacta)	Frequências 2º ano (Intacta)
		Frequências D1	
		Frequências D3	
	2	Frequências 1º ano (Intacta)	Frequências 2º ano (Intacta)
		Frequências D1	
		Frequências D4	
	3	Frequências 1º ano (Intacta)	Frequências 2º ano (Intacta)
		Frequências D2	
		Frequências D3	
	4	Frequências 1º ano (Intacta)	Frequências 2º ano (Intacta)
		Frequências D2	
		Frequências D4	
2	1	Frequências 1º ano (Intacta)	1 - Frequências D2 2 - Frequências D4
		Frequências D1	
		Frequências D3	
	2	Frequências 1º ano (Intacta)	1 - Frequências D2 2 - Frequências D3
		Frequências D1	
		Frequências D4	
	3	Frequências 1º ano (Intacta)	1 - Frequências D1 2 - Frequências D4
		Frequências D2	
		Frequências D3	
	4	Frequências 1º ano (Intacta)	1 - Frequências D2 2 - Frequências D3
		Frequências D2	
		Frequências D4	

Por se tratar de uma rede com aprendizado supervisionado, a saída da rede foi estruturada como matriz de duas linhas, contendo algarismos 1 e 0, representando os padrões de “frequências danificada” e “frequências intactas”, respectivamente. A Figura 6.14 mostra a arquitetura da rede LVQ que foi utilizada no estudo.

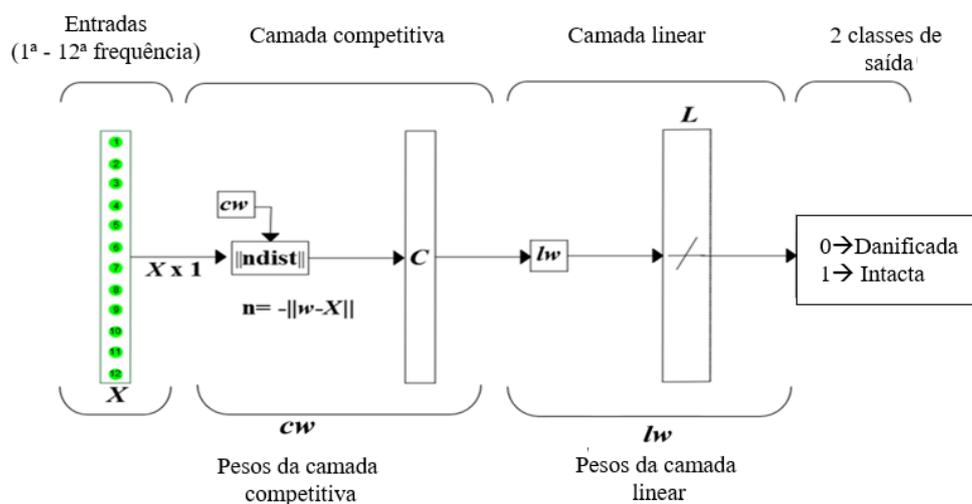


Figura 6.14 Arquitetura da rede LVQ.

Assim, o esquema das análises feitas com a rede LVQ está apresentado na Figura 6.15.

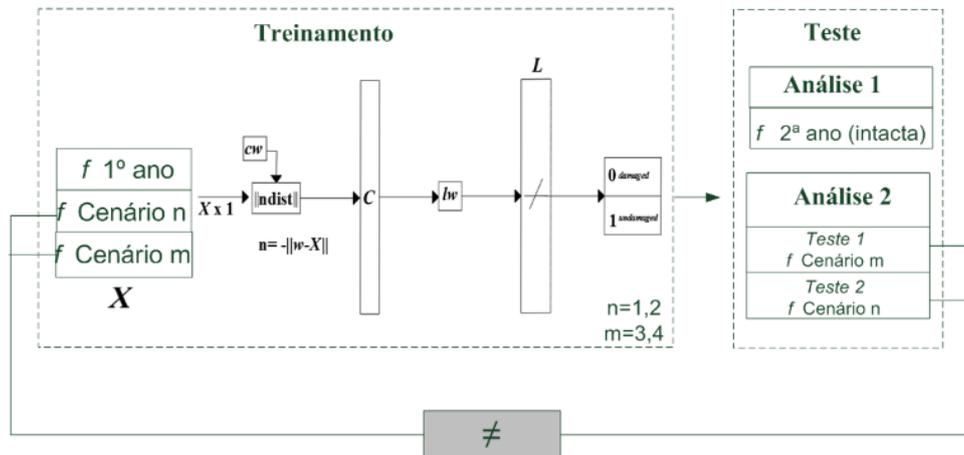


Figura 6.15 (a) Análises realizadas LVQ.

O período escolhido para as análises seguiu os critérios apresentados na Figura 6.10, isto é, nos períodos de 24h, 1 semana e 1 mês. No entanto, aqui estão apresentados apenas os resultados obtidos nas análises de 30 dias de monitoramento, estando as demais análises no apêndice B.

#### 6.2.1.2.1 Análise 1: Teste do LVQ apenas com dados da ponte

Nesta primeira análise, para treinar as redes foram utilizadas as 12 primeiras frequências estimadas durante o primeiro ano de monitoramento da referida estrutura, bem como as frequências da ponte modificadas artificialmente pelas presenças dos danos D1, D2, D3 e D4. Já aos testes foram fornecidas as frequências do segundo ano de monitoramento da ponte, sem considerar modificações causadas por danos artificiais, portanto consideradas como intactas.

As redes foram construídas com 5, 10 e 15 neurônios (embora só estejam apresentados aqui os resultados das RNAs formadas por 15 unidades artificiais, estando as demais no apêndice B) e tiveram seus processamentos realizados em uma média de 100 iterações e erros na ordem de  $10^{-2}$ .

Como mencionado, o LVQ classifica em grupos os dados fornecidos como entrada. Neste caso, como ele foi treinado para classificar os padrões em duas classes,

danificada e intacta, os gráficos que seguem exibem os resultados obtidos, de modo que os acertos se referem ao número de amostras (conjunto de frequências obtidas no segundo ano de monitoramento) classificadas como intactas.

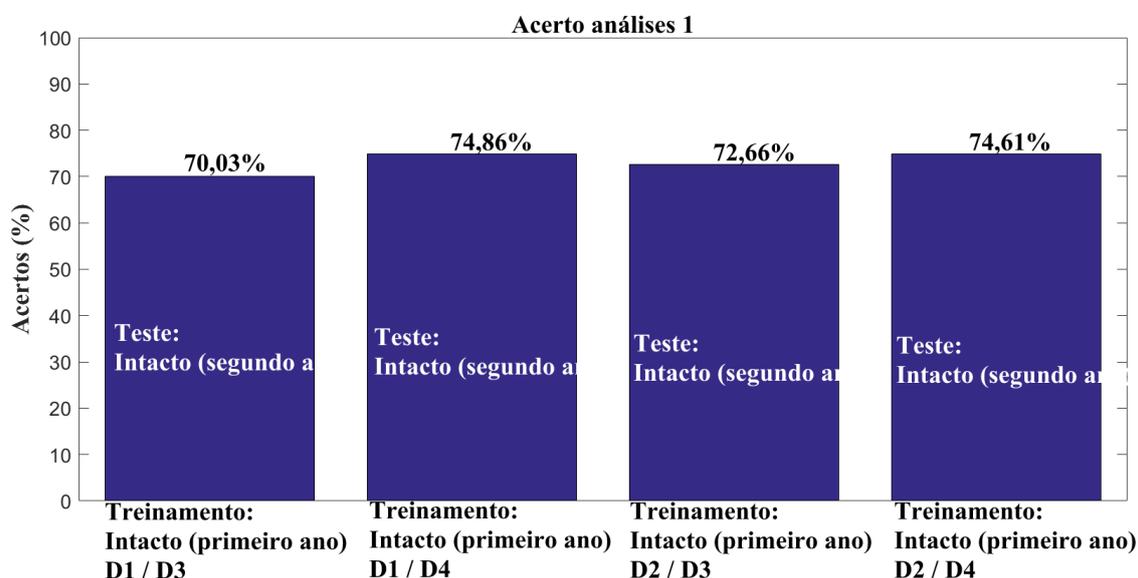


Figura 6.16 Resultados obtidos na análise 1 - LVQ.

É possível observar que em todas as análises o LVQ apresentou um bom índice de acertos, uma vez que em todos os testes foram obtidos acertos acima de 70% quando as frequências de testes eram intactas, isto é, sem alterações que permitissem indicar a existência de danos estruturais na ponte.

#### 6.2.1.2.2 Análise 2: Teste do LVQ com dados da ponte e dos modelos danificados

Para avaliar a sensibilidade do LVQ aos diferentes cenários danificados, a segunda análise foi dividida em 2 grupos, de modo que a cada dois padrões de modelos danificados utilizados no treinamento, as redes foram testadas com as frequências dos outros dois cenários danificados. Todas as redes tiveram 15 neurônios e foram processadas com uma média de 150 iterações, obtendo erros na ordem de  $10^{-2}$ .

Deste modo, as configurações das redes estão organizadas da seguinte forma (também apresentadas na Tabela 6.4):

- 1) Treinamento: Intacto 1º ano + D1 + D3

Teste 1: D2. Teste 2: D4

2) Treinamento: Intacto 1º ano + D1 + D4

Teste 1: D2. Teste 2: D3

3) Treinamento: Intacto 1º ano + D2 + D3

Teste 1: D1. Teste 2: D4

4) Treinamento: Intacto 1º ano + D2 + D4

Teste 1: D1. Teste 2: D3

Os resultados da primeira rede podem ser vistos nos gráficos da Figura 6.17. É possível observar que, ao ser treinada com padrões das frequências intactas (do primeiro ano) e dos modelos com danos D1 e D3, a rede conseguiu classificar corretamente os testes realizados com frequências dos modelos contendo os danos D2 e D4, obtendo acertos de 79,81% e 99,65%, respectivamente.

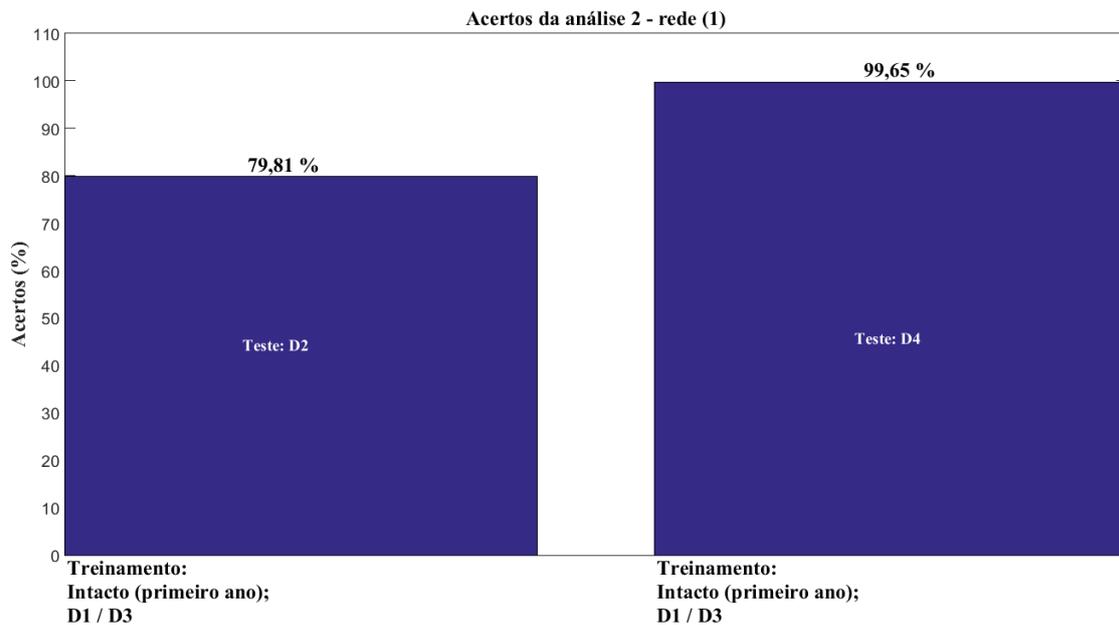


Figura 6.17 Resultados obtidos na análise 2 (1) - LVQ.

No caso da rede 2 (Figura 6.18) o comportamento do algoritmo também se mostrou satisfatório, uma vez que os resultados apontaram para acertos de 71,89% no teste com D3, isto é, a rede treinada com frequências estimadas no primeiro ano de monitoramento (intactas) em conjunto com as dos modelos com danos D1 e D4

conseguiram diferenciar as frequências do cenário que continha o dano 3 (D3) das frequências estimadas no segundo do monitoramento contínuo da ponte.

No caso do segundo teste, ou seja, avaliação do desempenho do LVQ quando submetido ao teste com frequências do modelo com danos referentes ao D2, o algoritmo também funcionou adequadamente, com um rendimento de 75% de acertos.

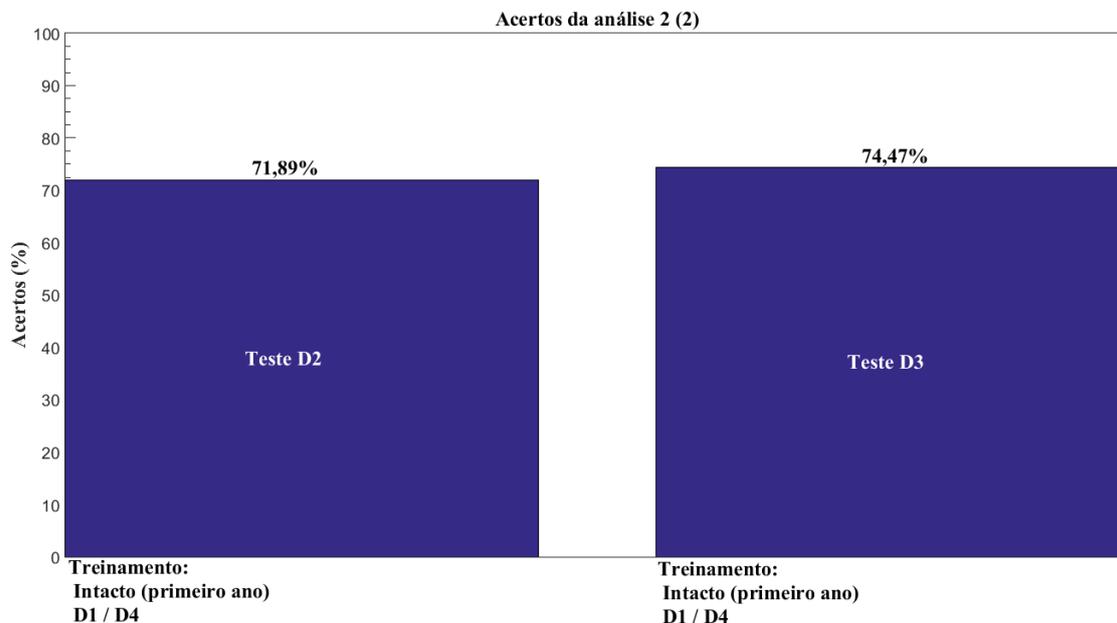


Figura 6.18 Resultados obtidos na análise 2 (2) - LVQ.

A rede 3, configurada para ser treinada com as frequências alteradas pelos danos D2 e D3, além das frequências obtidas no primeiro de monitoramento da ponte (intactas), também se mostrou eficiente. No teste 1, cujas informações fornecidas como inputs do teste da RNA corresponderam às frequências relativas ao modelo danificado pela redução de inércia D4, o LVQ apresentou uma performance dentro do desejado, com um nível de 99% de acertos (Figura 6.19). Em outras palavras, ao serem fornecidas as frequências danificadas com o modelo D4, quase todos os conjuntos das 12 frequências foram classificados no grupo das frequências danificadas.

Observa-se que ao ser fornecido o padrão D4 os resultados foram iguais e acima de 90%. Tal fato pode ser explicado pois o dano se localiza no arco, resultando, principalmente, na alteração das frequências vertical 5 (do tabuleiro) e na vertical do arco (Tabela 6.3) e, portanto, diferenciando bastante dos demais padrões.

O mesmo comportamento foi observado no teste 2 (teste com as frequências do modelo danificado D1), no entanto o nível de acerto foi um pouco mais baixo, com um nível de acertos de 80%.

A última rede, treinada com as frequências referentes aos modelos com danos D2 e D4 além das intactas, também seguiu o desempenho observado nas primeiras rodadas já mostradas, isto é, nos dois testes conseguiu classificar corretamente 77,35% das frequências do modelo danificado com D1 (primeiro teste), e 74,05% com o modelo danificado com D3 (Figura 6.20).

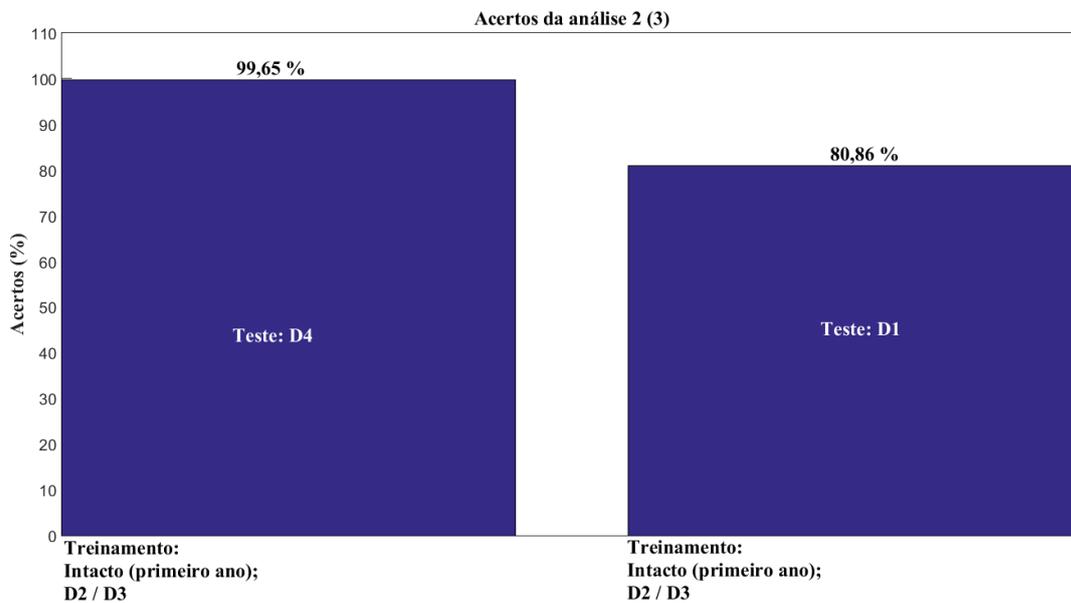


Figura 6.19 Resultados obtidos na análise 2 (3) - LVQ.

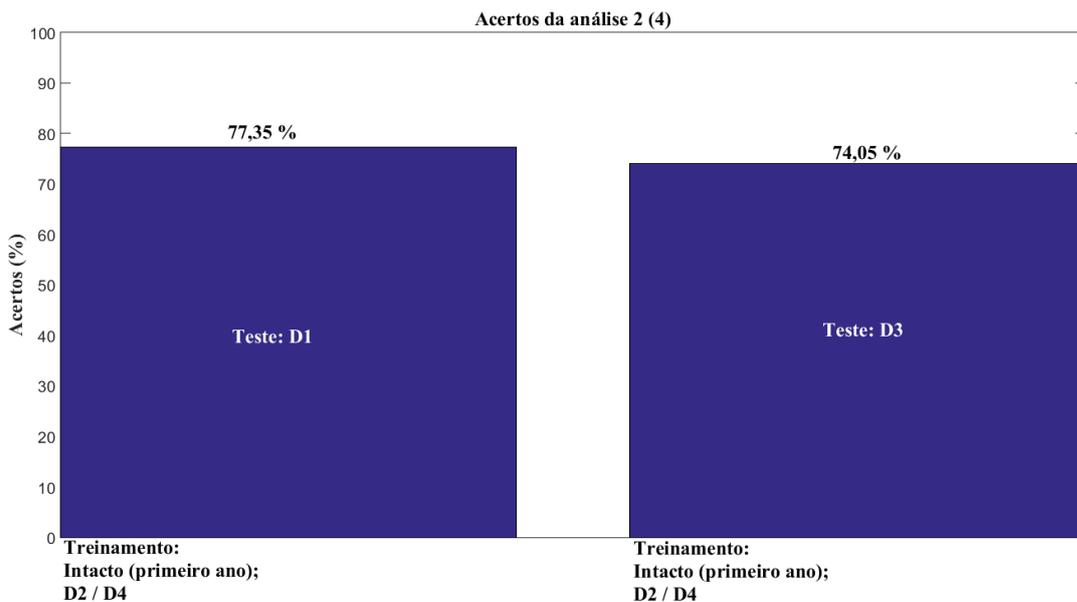


Figura 6.20 Resultados obtidos na análise 2 (4) - LVQ.

Como o objetivo da aplicação é indicar uma metodologia baseada no uso de RNA para detectar danos estruturais e, como este tipo de rede foi analisada sob diferentes aspectos, pode-se dizer que a configuração utilizada (três padrões de entrada, sendo um intacto e outros dois danificados - desde que sejam diferentes) se mostrou adequada. Além disso, esses resultados foram obtidos utilizando mais de 15 células artificiais.

Com relação ao número de amostras (tempo de monitoramento), sugere-se a utilização de um mês como referência, uma vez que os resultados obtidos foram mais confiáveis, no sentido da repetição dos bons desempenhos das RNAs.

### **6.2.1.3 Conclusões parciais das redes LVQ aplicadas à ponte estudada.**

Com base nos resultados apresentados, de uma maneira geral, observa-se um bom desempenho do algoritmo, mesmo com as mínimas variações das frequências apresentadas na pesquisa.

Neste contexto, seguem algumas considerações a respeito do funcionamento da técnica:

1) As frequências apresentaram variações muito pequenas em presença dos diferentes danos estruturais quando comparadas com as intactas e entre si (em função do posicionamento dos danos). É possível verificar no gráfico das sobreposições (Figura 6.13) que são poucas as frequências que apresentam uma diferença mais acentuada. Deste modo, fica claro que o desempenho da rede é sempre melhor quando se tem um maior número de variáveis no padrão. Neste caso, se só tivesse sido possível utilizar as 4 primeiras frequências, provavelmente, o LVQ não teria sido capaz de apontar variações significativas a ponto de classificar o conjunto de dados de testes em intactas ou danificadas, já que o  $\Delta freq$  é quase 0% (Tabela 6.3).

2) Chama-se a atenção para a necessidade de se treinar a rede com os mais diversos padrões de dados existentes das estruturas. Neste trabalho, os padrões danificados (cenários) foram assumidos por reduções inerciais em locais estratégicos, isto é, os danos foram simulados em regiões da ponte que apresentam diferentes comportamentos (tabuleiro e arco). Deste modo fica claro que a rede conseguiu estabelecer boa relação entre *inputs* e *outputs* (frequências e classes intacta e danificada) de uma maior varredura dos casos que poderão vir a acontecer. Assim, pode-se observar

que, para este caso, os padrões danificados foram suficientes para representar o problema. Como a estrutura da ponte é simétrica, sabe-se que, no caso de um dano ocorrendo no outro lado da ponte, as frequências se comportam de maneira similar.

3) Com a proximidade entre os valores dos padrões de frequências (frequências de cada um dos cenários), neste caso, o número de iterações no processamento fez uma significativa diferença nos níveis de acertos, de modo que o desempenho apresentou melhores resultados com uma média de 50 passos.

4) A falta de dados contendo alterações nas frequências causadas por anomalias substanciais na ponte não foi classificada como um fator negativo para avaliar o desempenho da técnica, pois, no trabalho, mesmo que ligeiramente alterados artificialmente, os testes foram realizados com os dados do monitoramento do segundo ano. Vale salientar que estas alterações foram provocadas por danos muito pequenos, a fim de não comprometer o funcionamento da estrutura.

Por fim, observa-se um adequado desempenho da técnica, o que pode indicá-la como uma possível ferramenta para complementar sistemas de monitoramento estrutural, sobretudo quando este fornecer um grande volume de dados que necessite de uma interpretação mais rápida com vistas à detecção de danos estruturais.

## **6.2.2 Redes Self Organizing Maps - SOM**

A detecção de danos utilizando a rede SOM também foi realizada no ambiente do *Neural Network Toolbox* (Nntool) e com os mesmos meses de referência das análises anteriores. No entanto, devido ao tipo de aprendizagem do algoritmo não supervisionado (não necessita de dados de saída no treinamento), os dados de cada fase da RNA (treinamento e teste) tiveram uma aplicação diferenciada.

### **6.2.2.1 Dados de entrada - SOM**

O processamento é iniciado com a indicação dos dados a serem utilizados em cada etapa (padrões de entrada), isto é, no treinamento e teste da rede. Esses padrões devem seguir uma organização, de modo que todas as amostras tenham as mesmas quantidades de variáveis.

Neste trabalho, as amostras correspondem às aquisições e, as variáveis correspondem às 12 frequências identificadas, conforme a Figura 6.21.

	Var 1	Var 2	...	Var $n$
S1	Freq 1	Freq 2		Freq 12
S2				
⋮				
$S_m$				

Figura 6.21 Organização dos dados.

Nestas análises, foi assumido que a partir de março de 2009 (linha tracejada em verde da Figura 6.22) a ponte passou a ter as frequências alteradas pelos danos artificiais e, portanto, a partir desta data as frequências obtidas por meio do monitoramento contínuo foram multiplicadas pelo coeficiente de dano (Equação 6.1, Tabela 6.3) passando a ser consideradas como informações obtidas da ponte danificada.

Assim, a fim de detectar alterações nas frequências da ponte que possam indicar a presença de danos, para o treinamento do SOM foram utilizadas sempre as frequências intactas obtidas no primeiro ano de treinamento (linhas em vermelho da Figura 6.22) e, para o teste, foram utilizadas as frequências do segundo ano de monitoramento com e sem alteração artificial de dano (linhas azuis da Figura 6.22).

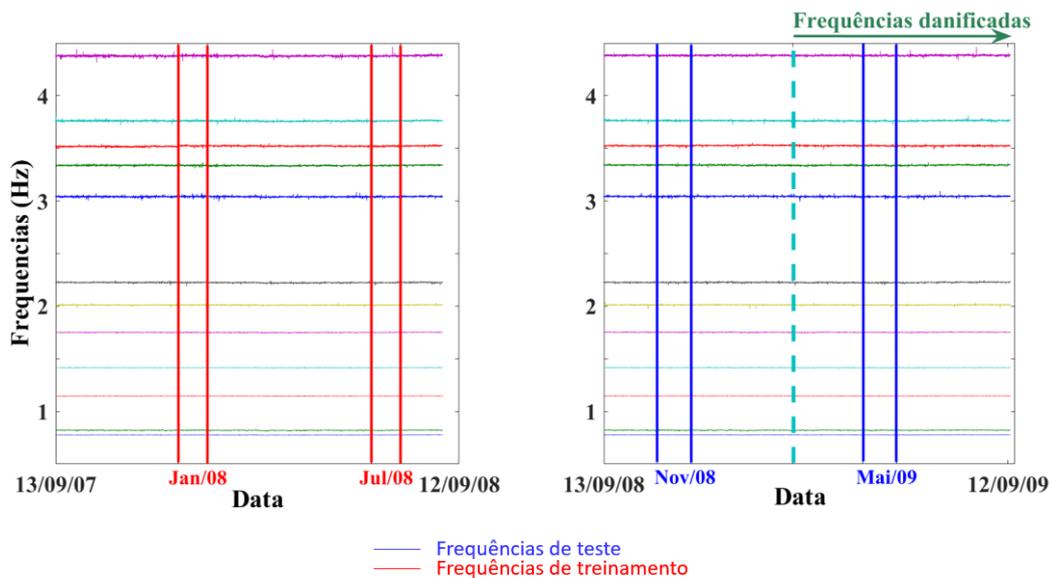


Figura 6.22 Frequências utilizadas no SOM.

### 6.2.2.2 Redes e resultados - SOM

Foram realizados dois tipos de análises, sendo a primeira relativa ao uso das frequências da ponte, tanto na fase do treinamento (frequências do primeiro ano) como na fase de teste (frequências do segundo ano sem modificação).

Como não há evidências de anomalias estruturais na ponte e, para avaliar o funcionamento do algoritmo, o segundo tipo de análise foi realizado utilizando dados da ponte para o treinamento (frequências dos meses de janeiro e julho do primeiro ano – linhas vermelhas da Figura 6.22), e, para o teste, foram fornecidas as frequências dos meses de novembro e maio do segundo ano de monitoramento (entre as linhas azuis da Figura 6.22).

Nesta consideração, para avaliar a capacidade de detectar mais de uma classe de informações (intacta e danificada), as frequências de novembro foram fornecidas sem modificação e as de maio foram numericamente danificadas, isto é, com a consideração de danos (Figura 6.22).

O esquema das análises realizadas com este tipo de rede está mostrado na Figura 6.23.

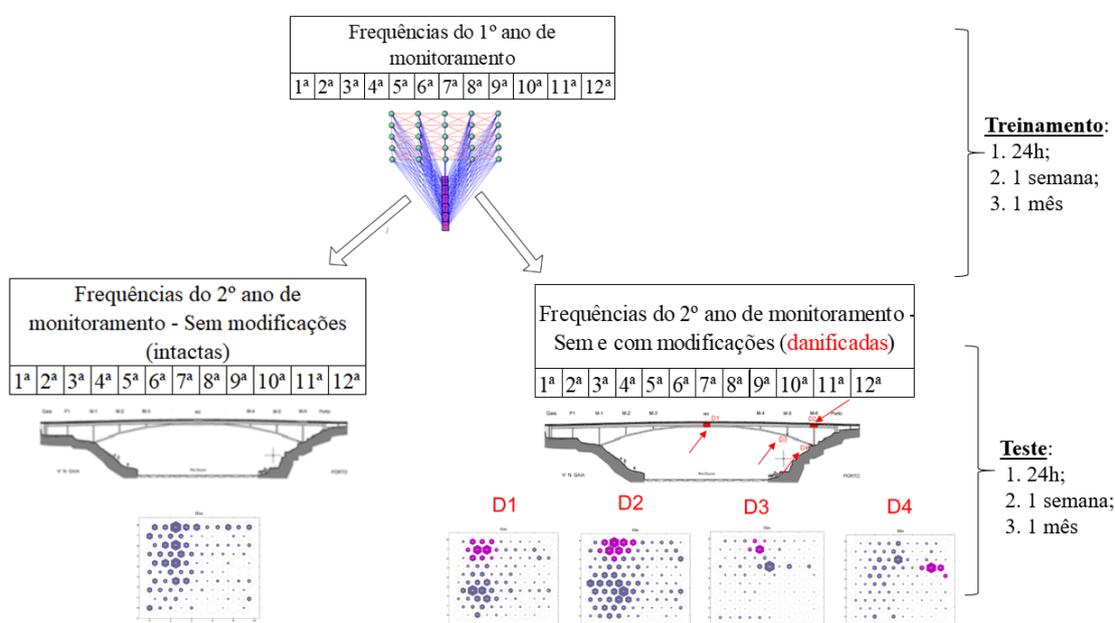


Figura 6.23 Análises realizadas com as redes SOM.

Além das duas análises, o desempenho do SOM foi verificado com diferentes quantidades de dados, isto é, com as frequências colhidas durante 1 dia, uma semana e um mês de monitoramento.

As redes foram construídas segundo os seguintes critérios:

- Topologia: Hexagonal;
- Função de vizinhança: “linkdist”;
- Mapa bidimensional com 100 neurônios.

Os resultados estão a seguir, divididos nos dois grupos de análises indicados. É importante ressaltar que foram feitos, ao menos 3 retreinamentos, a fim de verificar a convergência dos resultados obtidos. Além disso, os resultados apresentados aqui referem-se às análises baseadas em 1 mês de monitoramento, estando as demais (24h e 1 semana) no apêndice B.1.

#### **6.2.2.2.1 Análise 1: Treinamento e teste do SOM com dados do primeiro e segundo ano de monitoramento (sem consideração de dano), respectivamente**

Nesta primeira análise foram utilizados apenas dados da ponte, de modo que para treinar e testar o SOM, foram selecionadas as 12 primeiras frequências dos meses de janeiro e julho do primeiro e do segundo ano de monitoramento sem modificação, respectivamente.

##### *1. 1 mês de monitoramento*

Por se tratar da detecção de danos baseada nas frequências obtidas durante 1 mês de monitoramento, o banco de dados fornecido tanto no treinamento quanto no teste foi formado por cerca de 2880 amostras, sendo cada uma obtida a cada 30 minutos. O processamento foi realizado com 100 neurônios, 10 em cada eixo, gerando o mapa bidimensional da Figura 6.24, em um total de 41 iterações.

Sabendo que este tipo de rede reconhece padrões e tende a agrupá-los em função da proximidade das suas características estatísticas, na Figura 6.24, na qual estão representados os *clusters*, isto é, o agrupamento dos dados, é possível observar que há

um espalhamento dos clusters, não sendo possível identificar mais de uma classe de informações.

Ao ser executado o teste do SOM, no qual estão contidas as 12 primeiras frequências da ponte, obtidas nos meses de novembro (2008) e maio de 2009 (segundo ano de monitoramento sem modificação), o comportamento foi semelhante ao do treinamento, como já se esperava, uma vez que os padrões de entrada só continham uma classe de dados.

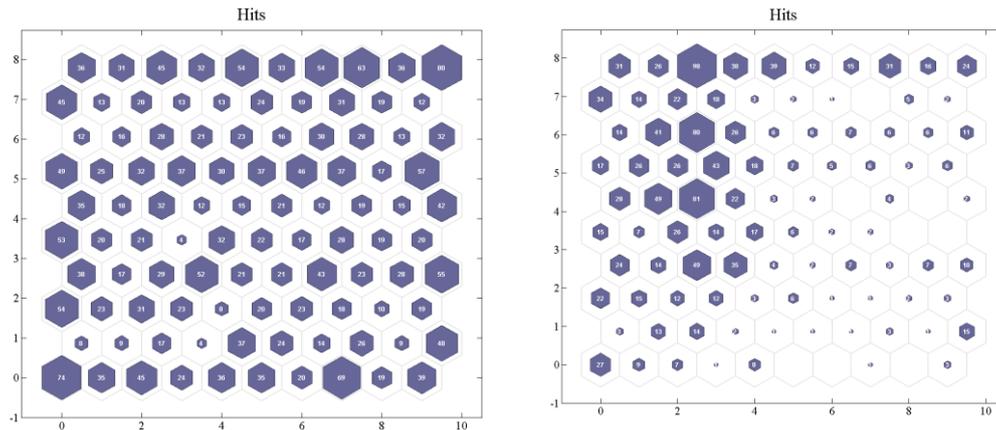


Figura 6.24 (a) Treinamento do SOM (b) Teste do SOM – análise 1 – 1 mês.

É possível observar na Figura 6.24(b) a presença de um núcleo principal de dados, indicando, portanto, que as frequências do segundo ano, apresentadas como padrões para o teste não apresentavam alterações significativas, capazes de indicar a presença de danos estruturais.

#### 6.2.2.2.2 Análise 2: Treinamento do SOM com dados do primeiro ano de monitoramento da ponte e teste com dados do segundo ano de modelos danificados

A segunda fase de análises foi dividida em 4 etapas, cada uma correspondendo à consideração de um dos cenários danificados do modelo numérico da ponte, mostrado na Figura 6.23.

Nestes casos, as redes SOMs tiveram a mesma base de dados para o treinamento, as frequências identificadas nos meses janeiro e julho do primeiro ano de monitoramento da ponte e, para analisar o funcionamento da rede, aos testes foram fornecidos padrões de frequências da ponte (nov. de 2008 – frequências sem

modificação), juntamente com as frequências associadas aos modelos danificados (maio de 2009 - padrões com modificação)

Para a obtenção das frequências dos modelos danificados foi usada a Tabela 6.3 de modo que pôde-se obter um banco de dados semelhante ao da ponte e, assim, realizar a análise com vistas ao funcionamento do SOM. Os resultados das verificações referentes a um mês de monitoramento estão a seguir e, como mencionado, as redes processadas com as frequências obtidas durante 24 h e 1 semana encontram-se no apêndice B.1.

### 1. 1 mês de monitoramento

#### Cenário 1:

Com o mesmo número de padrões de entrada comentado na análise 1, para o treinamento do SOM da análise 2, referente ao cenário danificado D1, também foram utilizados 100 neurônios, em um total de 110 iterações.

A partir da Figura 6.25 é possível observar que não há divisão de classes, uma vez que os padrões de entrada fornecidos para o treinamento corresponderam às frequências identificadas nos meses janeiro e julho do primeiro ano de monitoramento da ponte e, portanto, pertencentes a uma única classe (frequências intactas).

Já no teste da rede, isto é, na fase a qual foram fornecidas as frequências naturais baseadas no modelo numérico com dano 1 (D1) em conjunto com os dados do segundo ano da ponte (sem modificações), pode-se visualizar a existência de dois núcleos principais de clusters, indicando, portanto, haver mais de uma classe de dados.

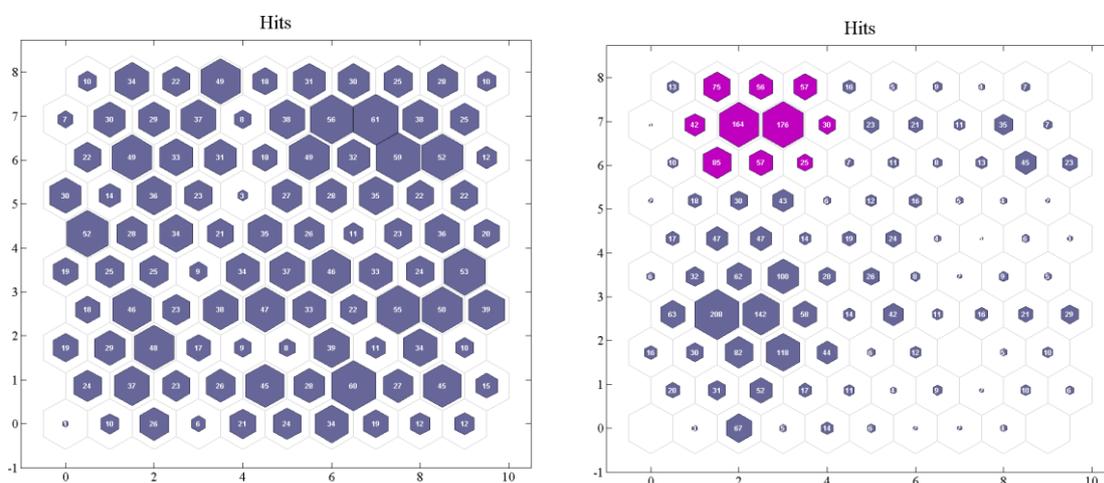


Figura 6.25 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 1) – 1 mês.

Esta observação é pertinente, pois como nos padrões fornecidos para os testes haviam frequências da ponte, bem como frequências associadas ao modelo danificado, o algoritmo foi capaz de detectar diferentes classes de frequências.

### Cenário 2

Semelhante ao caso do cenário 1, o treinamento do caso dois (cenário D2) foi realizado com o mesmo banco de dados e a mesma quantidade de neurônios, no entanto, com 96 iterações para obter o resultado a seguir. O treinamento apresentou um comportamento semelhante ao dos casos anteriores (Figura 6.26), indicando apenas uma única classe de dados; já no teste é possível observar a presença de mais de uma classe de dados, fato este esperado (Figura 6.26 (b)).

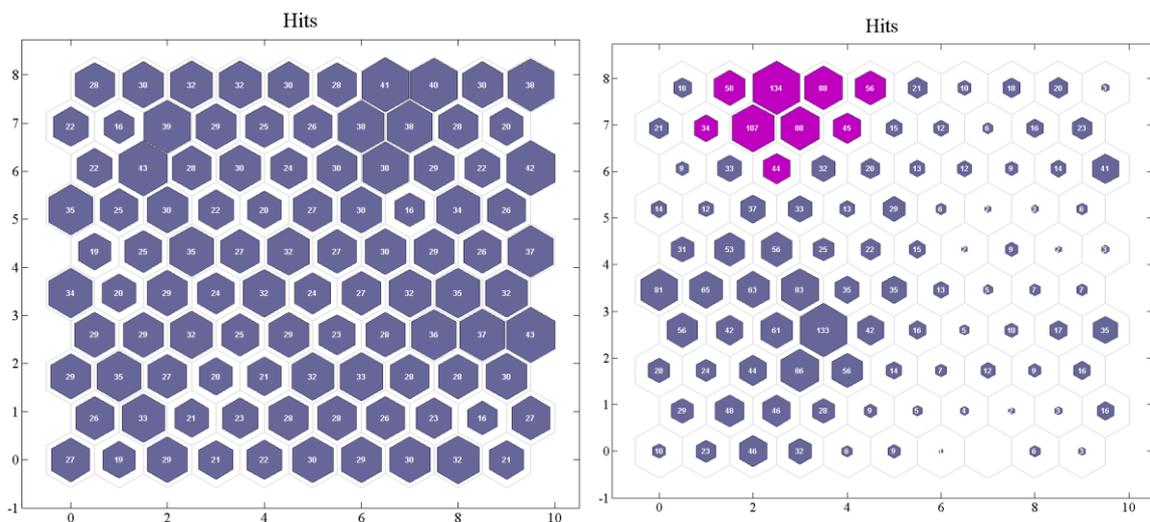


Figura 6.26 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 2) – 1 mês.

### Cenário 3

Seguindo o mesmo procedimento dos casos anteriores, para o cenário, os dados usados no treinamento foram os mesmos já mencionados. No entanto, para o teste do SOM foram utilizadas as frequências referentes ao modelo numérico com o dano 3 (D3). O SOM foi formado por 100 neurônios e seu processamento foi realizado em 125 épocas.

Os mapas do treinamento (Figura 6.27) revelam apenas uma classe de dados, fato este não observado na fase de teste do SOM. A partir da Figura 6.27 é possível observar dois núcleos principais de dados localizados em regiões próximas, no entanto,

considerando a quantidade de clusters, pode-se indicar a presença de, pelo menos, duas classes de dados.

Diferentemente dos casos anteriores, no teste deste caso, os clusters se concentraram em regiões mais próximas, porém mais pontualmente.

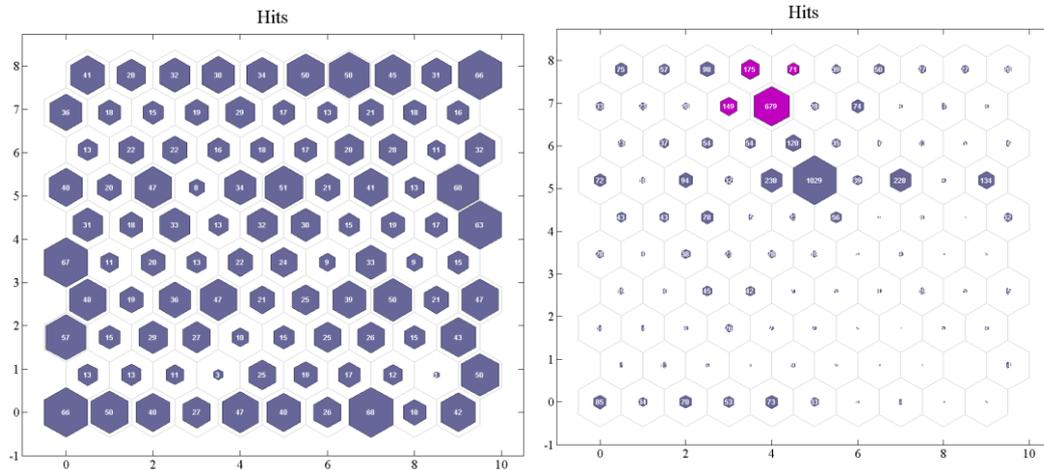


Figura 6.27 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 3) – 1 mês.

#### Cenário 4

Neste último cenário seguiu-se os mesmos procedimentos já indicados, tanto para o treinamento como para o teste. Com 100 neurônios formando o mapa bidimensional, o treinamento contou com 57 iterações, revelando apenas uma classe de dado, uma vez que não foi possível visualizar diferentes núcleos. (Figura 6.28).

Já na fase do teste do SOM, na qual foram fornecidos como dados de entrada as frequências obtidas do modelo numérico danificado com o dano 4 (D4) e da estrutura real, especificamente os dados do mês de novembro de 2008, foi possível visualizar uma certa separação dos clusters, indicando, portanto, a presença de duas classes de dados (Figura 6.28).

É importante ressaltar que, no caso do cenário 4, algumas vezes a separação não foi tão clara, necessitando de um novo treinamento para o bom funcionamento do SOM, uma vez que o processo é aleatório.

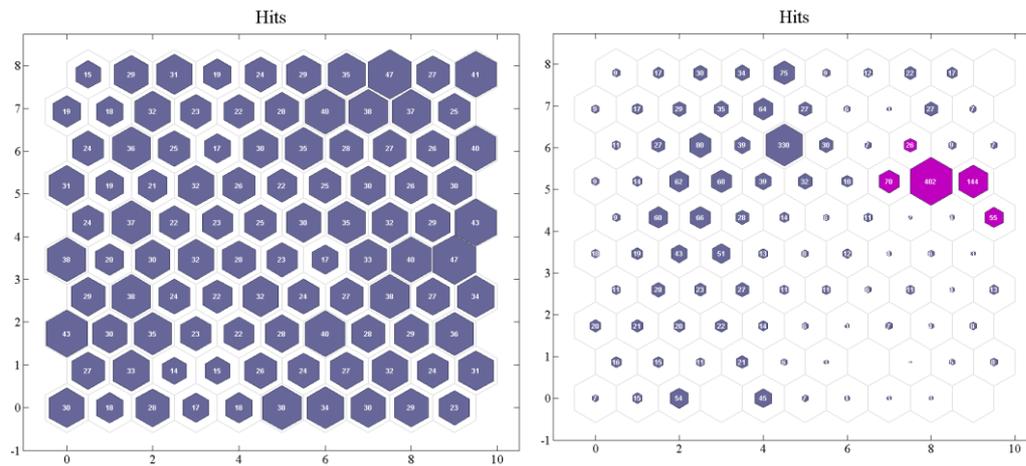


Figura 6.28 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 4) – 1 mês.

### 6.2.2.3 Conclusões parciais das redes SOM aplicadas à ponte estudada.

Em uma primeira análise na qual treinou-se e testou-se o SOM com dados dos primeiro e segundo ano, respectivamente, foi possível visualizar apenas uma classe de dados, ou seja, a partir do mapa do SOM, pode-se indicar que as frequências do segundo ano da ponte estão em conformidade com as do primeiro ano, não havendo alterações que possam indicar a presença de danos estruturais.

No grupo da segunda análise estão concentrados os processamentos realizados com dados de modelos numéricos e do segundo ano de monitoramento da ponte. Em todos os casos, durante a fase de treinamento, não foi observada uma separação entre os padrões de entrada, ao contrário do que aconteceu nos testes do SOM. Nos quatro exemplos mostrados, é possível visualizar, nos mapas das figuras, que o SOM foi capaz de detectar alterações entre as frequências dos modelos danificados e da estrutura, separando em diferentes classes tais informações.

Uma outra observação feita se dá no caso da obtenção de bons resultados por parte das RNAs, sobretudo quando o tempo de monitoramento foi pequeno, resultando em poucas amostras fornecidas como padrão de treinamento. Ainda que seja uma análise mais qualitativa do que quantitativa, a técnica respondeu bem ao proposto, se enquadrando, segundo Rytter (1993) no nível 1 dos métodos de detecção de danos.

Com relação aos parâmetros da rede, especificamente com relação número de neurônios envolvidos no processamento, apesar de não terem sido apresentados os

resultados, foram feitas avaliações com números reduzidos de células artificiais e os resultados foram, algumas vezes, insatisfatórios.

Assim, destaca-se a importância do monitoramento contínuo da saúde das estruturas, uma vez que a detecção prévia de anomalias, além de evitar acidentes, pode representar a redução de custos com reparos.

## 7. CONCLUSÕES

Neste trabalho buscou-se desenvolver uma metodologia baseada em Redes Neurais Artificiais (RNAs) para detectar e/ou localizar danos estruturais. Para isso, como forma de avaliar a técnica como parte integrante de um sistema de monitoramento estrutural, as RNAs foram aplicadas em dois tipos de estruturas, uma viga construída em laboratório e uma ponte em uso.

Conforme metodologia apresentada, foram estudados três tipos de redes, a *Backpropagation* (MLP), a *Self Organizing Maps* (SOM) e a *Learning Vector Quantization* (LVQ), cada uma aplicada sob diferentes condições, desde os parâmetros específicos para cada tipo de arquitetura, até o tipo de dado utilizado como *inputs*.

Neste sentido, este capítulo descreve as principais conclusões retiradas em cada análise do trabalho, bem como as sugestões para futuros trabalhos.

### 7.1 Análises na Viga

A aplicação das RNAs na viga estudada foi realizada com o objetivo de indicar parâmetros e características dinâmicas mais influentes no contexto da localização de danos em modelos construídos em laboratório. Deste modo, como foi possível obter dados variados, bem como construir diferentes modelos numéricos, foram estudadas as RNAs de aprendizado supervisionado *Backpropagation* e LVQ. Assim, foram verificados os seguintes aspectos:

- Tipo de dado analisado:

Foram testados três grupos de dados, dentre os quais, os melhores desempenhos das ferramentas ocorreram com os modos de vibração (na rede *Backpropagation*) ou pela associação da frequência com o respectivo modo de vibração (na rede LVQ), seguindo indicações da literatura, especificamente ao fato de que quanto maior o universo de informações nos padrões de entrada, mais o algoritmo estabelece relações válidas entre as informações fornecidas e as processadas.

Contudo, foi observado que a rede *Backpropagation* pode apresentar dificuldades em localizar a posição exata do dano quando se trata de um modo superior, uma vez que

frequências e modos mais elevados podem apresentar divergências entre modelos experimental e numérico.

Além disso, observou-se ainda que, devido à simetria do modo, a RNA pode apresentar variações na localização do elemento danificado. Para contornar tal fator, sugere-se que, ao ser usado o modo de vibração como padrão de entrada, seja utilizada apenas a metade das coordenadas que dão a forma ao modo de vibrar.

No caso das redes LVQ formadas com os modos de vibração, foi verificado que, diferentemente das RNAs *Backpropagation*, devido ao padrão binário das saídas do treinamento deste tipo de rede, foi excluído o fator duvidoso devido à simetria do modo, uma vez que a rede dá como resposta o nó e não a coordenada do elemento danificado.

Outra observação, também pontuada por Yeung e Smith (2005), se dá na localização de elementos cujo nodo do modo de vibração passa por ele. Tal fato se dá pois, uma vez que o nodo não se desloca, o algoritmo pode associar com uma perturbação causada pela presença de danos.

Com relação às redes tendo como dados de entrada as frequências de vibração, foi observado que o comportamento foi satisfatório apenas com a rede LVQ. Deste modo, a sugestão é realizar mais testes com a rede *Backpropagation* utilizando um maior número de variáveis por padrão, isto é, utilizar, ao menos, mais de cinco frequências em cada amostra

- Parâmetros da rede (número de neurônios e funções de ativação):

Com relação ao número de neurônios, foram seguidos alguns critérios de escolha já apresentados pela comunidade científica, no entanto, na maioria dos casos, foi por tentativa e erro. De fato, o número de neurônios tem grande influência no processamento da rede, uma vez que quanto maior o número, melhor foi o desempenho. No entanto, como esperado, em alguns casos, o aumento exagerado de neurônios acarretou na divergência dos resultados.

Deste modo, indica-se que esta lacuna (o melhor número de neurônios a ser utilizado) deve ser respondida por tentativa e erro. Contudo, como uma estimativa inicial, sugerem-se as funções seguintes, a depender do tipo de dado considerado como padrão de entrada, do número de padrões e das variáveis envolvidas no treinamento das RNAs.

\*Modo de vibração:

$$N_{nci} = \frac{N_{var,pe} + N_{atr}}{2}$$

\*Frequências naturais de vibração:

$$N_{nci} = \frac{1,2xN_{var,pe} + 1,2N_{atr}}{2} x 10$$

Onde,

$N_{nci}$  → Número de neurônios na camada intermediária;

$N_{var,pe}$  → Número de variáveis em um padrão de entrada;

$N_{atr}$  → Número de amostras disponíveis para o treinamento.

Com relação às funções de ativação da rede *Backpropagation*, como esperado, a função *Tansig* apresentou os melhores resultados. No entanto, o comportamento da função linear *Purelin* causou um certo destaque quando utilizada com as redes formadas pelas frequências de vibração.

Este grupo de redes (formado pelas frequências), de maneira geral, não apresentou resultado satisfatório, porém ao ser formada pela função linear, mostrou-se bastante eficiente. Além disso, o desempenho do referido grupo de RNAs contrariou um aspecto que a literatura coloca, no sentido de ter sempre a necessidade de uma função não linear no sistema. Como apresentado, em uma das análises foi utilizada a função linear entre as camadas e o desempenho foi um dos melhores. Diante do exposto, sugere-se que sejam feitos novos testes em outras estruturas para comprovar tal comportamento.

Com relação a função *Logsig*, observou-se que nas redes cujos dados de entrada eram os primeiros modos de vibração, a função se comporta adequadamente. No entanto, tal desempenho reverte, sobretudo, a partir das redes treinadas com o terceiro modo de vibração.

Assim, supõe-se que a escolha da função adequada para cada rede tenha forte relação com a complexidade do problema para o qual se procura solução. Outro fator que pode explicar o comportamento da *Logsig* diz respeito aos valores assumidos pelas variáveis dos padrões de entrada, já que as coordenadas dos modos variam entre -1 e 1 e a função *Logsig* tem domínio compreendido entre 0 e 1.

No contexto geral das RNAs aplicadas em modelos controlados em laboratório, pode-se dizer que, baseado nos resultados obtidos, a ferramenta apresenta grande potencial para ser parte integrante de um sistema de monitoramento estrutural, uma vez que além de localizar (caso deste trabalho), pode indicar a extensão dos danos existentes na estrutura (verificado em outros trabalhos), alcançando, portanto, 3 das 4 categorias de detecção de danos indicadas por Rytter (1993).

Uma outra vantagem está na velocidade de resposta do sistema. Uma vez que a RNA está treinada, isto é, bem adequada à análise que se propõe, basta apenas fornecer as informações pertinentes cuja solução se deseja encontrar. Em outras palavras, não é necessária uma nova modelagem, nem tampouco um novo treinamento.

## 7.2 Análises na Ponte Infante D. Henrique

Diferentemente das análises realizadas na viga, a aplicação das RNAs ao caso da Ponte Infante D. Henrique focou-se na detecção de danos. Deste modo, de posse do vasto banco de dados obtido por Magalhães (2010), foram analisados dois tipos de rede, a LVQ e a SOM, ambas tendo as 12 primeiras frequências como dados de entrada.

Baseado nos resultados obtidos nas análises feitas com a rede LVQ, observa-se um bom desempenho do algoritmo, mesmo com as mínimas variações das frequências existentes entre estrutura e modelos danificados. Contudo, seguem algumas considerações a respeito do funcionamento da técnica:

- As frequências apresentaram variações muito pequenas em presença dos diferentes danos estruturais quando comparadas com as intactas e entre si (em função do posicionamento dos danos). Deste modo, fica claro que o desempenho da rede é sempre melhor quando se tem um maior número de variáveis no padrão. Este fato foi observado, uma vez que, tomando como exemplo o padrão D4, se só fosse possível utilizar as 5 primeiras frequências cujas variações ( $\Delta freq$ ) são quase 0% (**Erro! Fonte e referência não encontrada.**), o LVQ não teria sido capaz de indicar variações significativas, a ponto de classificar o conjunto de dados de testes em intactas ou danificadas.

- Além de um número considerável de variáveis em cada padrão de entrada (neste caso 12 primeiras frequências), chama-se atenção para a necessidade de

se treinar a rede com os mais diversos tipos de padrões de dados existentes das estruturas, já que a rede fica apta a classificar qualquer caso de dano;

- Com a proximidade entre os valores dos padrões, neste caso, o número de iterações no processamento fez uma significativa diferença nos níveis de acertos;

- A falta de dados contendo alterações nas frequências causadas por anomalias substanciais na ponte não foi classificada como um fator negativo para avaliar o desempenho da técnica pois, mesmo que ligeiramente alterados artificialmente, os testes foram realizados com os dados do monitoramento do segundo ano. Vale salientar que estas alterações foram oriundas de coeficientes obtidos por meio de danos muito pequenos, a fim de não comprometer o funcionamento da estrutura.

- Por fim, observa-se um adequado desempenho da técnica, o que permite indicá-la como uma possível ferramenta para complementar sistemas de monitoramento estrutural, sobretudo quando este fornecer um grande volume de dados que necessite de uma interpretação mais rápida com vistas à detecção de danos estruturais. O nível de acerto foi sempre superior a 70%, resultados estes encontrados por Yeung e Smith (2005) em uma análise realizada com dados de modelos construídos computacionalmente.

Com relação à rede SOM, por ser um sistema com aprendizado não supervisionado, baseado no agrupamento dos dados por meio das semelhanças estatísticas, entende-se que no contexto do monitoramento estrutural é importante realizar dois tipos de análises, uma com informações da estrutura saudável e outra com dados artificialmente modificados.

Neste sentido, em uma primeira análise na qual treinou-se e testou-se o SOM com dados do primeiro e segundo ano, respectivamente, foi possível visualizar apenas uma classe de dados, ou seja, a partir do mapa do SOM, pode-se indicar que as frequências do segundo ano da ponte estão em conformidade com as do primeiro ano, não havendo alterações que possam indicar a presença de danos estruturais.

Já no grupo da segunda análise foram concentrados os processamentos realizados com dados de modelos numéricos, isto é, estruturas artificialmente danificadas. Em todos os casos, durante a fase de treinamento, não foi observado separação entre os padrões de entrada, ao contrário do que aconteceu nos testes. Nos quatro exemplos

mostrados, é possível visualizar nos mapas que o SOM foi capaz de detectar alterações entre as frequências dos modelos danificados e da estrutura real, separando em diferentes classes tais informações.

Especificamente com relação a este tipo de rede, podem-se destacar os seguintes pontos:

- Do ponto de vista dos parâmetros da rede, o número de neurônios foi decisivo na análise. Foram feitos vários testes variando a dimensão do mapa, no entanto, só foram apresentados os resultados obtidos na grade 10 x10. Foi observado para um grande volume de dados (muitas amostras), um mapa pequeno (poucos neurônios) pode dificultar a separação das classes. Deste modo, neste tipo de avaliação indica-se uma análise prévia no sentido de encontrar o número mais adequado de neurônios;
- O tempo de monitoramento (número de amostras colhidas para o desempenho da rede) não representou resultado negativo, mesmo no caso de um dia de monitoramento, uma vez que a rede foi capaz de detectar, ao menos, duas classes de dados em todos os casos. Tal fator pode ser considerado uma grande e positiva vantagem da ferramenta, considerando que, no caso de grandes estruturas, uma estimativa rápida de avaliação de danos pode representar não só redução de gastos com reabilitação estrutural, mas também que se evitem acidentes fatais.

Finalmente, com base no exposto, fica claro que para incorporação e consolidação das RNAs em um SHM (*Structural Health Monitorig*) são necessárias avaliações em outras estruturas, muito embora nesta avaliação de uma ponte em uso, já tenha apresentado valiosos resultados.

Ressalta-se, ainda que, de maneira comparativa a outros métodos, as RNAs permitem uma avaliação rápida da integridade de grandes estruturas, mesmo com “poucas” informações, isto é, com dados obtidos em pouco tempo de monitoramento estrutural.

No contexto geral do trabalho, verifica-se um adequado funcionamento da metodologia de trabalho apresentada, seja em estruturas controladas em laboratórios, seja em estruturas que estão em pleno funcionamento, o que permite concluir a avaliação de danos com o uso de RNAs é uma técnica robusta, com grande potencial

para ser, efetivamente, utilizada no contexto do monitoramento estrutural das edificações.

Ressalta-se, contudo, que no caso das análises de estruturas usuais, um fator que deve ser verificado é a necessidade da eliminação/mitigação de ruído nos dados, uma vez que, em análises prévias utilizando os dados na forma “bruta” (sem a minimização dos ruídos e dos efeitos da temperatura), as RNAs não conseguiram o desempenho apresentado neste estudo.

### **7.3 Sugestões para trabalhos futuros**

Como continuidade do trabalho, são necessários além de estudos semelhantes para a verificação se há tendência de repetição dos resultados apresentados, algumas análises que abordem os seguintes aspectos:

- Avaliação estatística dos dados de entrada da rede com vistas a utilização das funções de ativação;
- Localização de danos tendo como dados de entrada a metade do modo de vibração, no caso de estruturas controladas em laboratórios;
- Detecção de danos em estruturas usuais considerando os efeitos da temperatura;
- Detecção de danos em estruturas usuais com a RNA *Backpropagation*, etc;
- Detecção de danos em estruturas usuais com os modos de vibração;
- Aplicação da metodologia em estruturas usuais já danificadas.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMS, R. D. (1978). A vibration technique for nondestructively assessing the integrity of structures. *of Mechanical Engineering, Science*, 20(2), 93-100.
- AHMED, M. S. (2016). *Damage Detection in Reinforced Concrete Square Slabs Using Modal Analysis and Artificial Neural Network*. Nottingham, Reino Unido: Thesis of Doctor of Philosophy from Nottingham Trent University.
- ALLEMANG, R. J., & BROWN, D. L. (1982). A correlation coefficient for modal vector analysis. *Proc. 1st Int. Modal Analysis Conference*, (pp. 110 - 116).
- ANNAMDAS, V. G., & SOH, S. B. (2016). Applications of structural health monitoring technology in Asia. *Structural Health Monitoring*, p. 23. doi:DOI: 10.1177/1475921716653278
- BALAGEAS, D., FRITZEN, C.-P., & GUEMES, A. (2006). *Structural Health*. Londres: ISTE Ltd.
- BANDARA, R. P. (2013). *Damage Identification And Concition Assessment Of Building Structures Using Frequency Response Functions And Neural Networks*. Austrália: Thesis Of The Degree Of Doctor Of Phylosophy, School Of Civil Engineering And Built Environment, Queensland University Of Technology.
- BAUCHSPIESS, A. (2008). *Introdução aos Sistemas Inteligentes - Aplicações em Engenharia de Redes Neurais Artificiais, Lógica Fuzzy e Sistemas Neuro-Fuzzy*. (UnB, Ed.)
- BENZONI, G., BONESSIO, N., & LOMIENTO, G. (2013). *Structural Health Monitoring of Bridges with Seismic Response Modification Devices*. Department of Structural Engineering, University of California, San Diego La Jolla, California 92093-0085.
- BESKHYROUN S., T. O. (2006). Damage identification of steel structures based on changes in the curvature of power spectral density. *2nd International Conference on Structural Health Monitoring of Intelligent Infrastructure*, Shenzhen,

- PEOPLE. Editors: Ou JP, Li H, Duan ZD. Structural Health Monitoring and Intelligent Infrastructure, Vols 1 and 2. Taylor & Francis Ltd. 791-797. 2006.
- BONESSIO, N., LOMIENTO, G., & BENZONI, G. (2011). Damage identification procedure for seismically isolated bridges. *Structural Control And Health Monitoring*, 19, pp. 565 – 578.
- BOROWIEC, A., ZIEMIAN´SKI, L. (2011). Damage identification in laboratory cantilever beam using neural networks. *Computer Methods in Mechanics*.
- BRASILIANO, A., G. DOZ, J. L. V. BRITO (2004). Damage identification in continuous beams and frame structures using the Residual Error Method in the Movement Equation. *Nuclear Engineering Design*.
- BRASILIANO, A. (2005). Identificação de Sistemas e Atualização de Modelos Numéricos com Vistas à Avaliação. Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia.
- BULLINARIA, J. A. (2004). <http://www.cs.bham.ac.uk/~jxb/NN/l16.pdf>. Acesso em 2017, disponível em <http://www.cs.bham.ac.uk/~jxb/NN/l16.pdf>
- CAETANO, E., CUNHA, A., MOUTINHO, C., & HU, W.-H. (2016). Continuous Dynamic Monitoring of Lively Footbridges. *iJOE*, 12.
- CARDER, D. S. (1937). Observed vibrations of bridges. *Bull. Seismol. Soc. Am*, 27, 267–303.
- CARDOSO, R. A., CURY, A., & BARBOSA, F. (2017). A clustering-based strategy for automated structural modal identification. *Structural Health Monitoring*.
- CASTRO E CASTRO, P. (2013). PUC-RS. Fonte: PUC-RS: [http://www.feng.pucrs.br/~decastro/pdf/RNA\\_C6.pdf](http://www.feng.pucrs.br/~decastro/pdf/RNA_C6.pdf).
- CHANG, F. K. (2002). Ultra reliable and super safe structures for the new century. Cachan, França: *Structural Health Monitoring 2002, Proceedings of the First European Workshop on Structural Health Monitoring*.
- CHEN, H. L. (1995). Evaluating structural deterioration by dynamic response. *Journal of Structural Engineering*, 121, pp. 1197 - 1203.

- CHENGYIN, L., WU, X., WU, N., LIU, C. (2014). “Structural Damage Identification Based on Rough Sets and Artificial Neural Network,” *The Scientific World Journal*, vol. 2014, Article ID 193284, 9 pages.
- CLOUGH, R. W., & PENZIEN, J. (1993). *Dynamics of Structures*. New York: McGraw-Hill.
- COMANDUCCI, G., MAGALHÃES, F., UBERTINO, F., & CUNHA, Á. (2016). On vibration-based damage detection by multivariate statistical techniques: Application to a long-span arch bridge. *Structural Health Monitoring*, 15(5), pp. 505 - 524.
- COSTA, J. A. B., MAGALHÃES, F., CUNHA, A. e FIGUEIRAS, J. (2013) ‘Rehabilitation assessment of centenary steel bridge based on modal analysis’, *Engineering Structures*, Vol. 56, No. 1, pp.260–272.
- CURADELLI, R. O., RIERA, J. D., AMBROSINI, D., & AMANIA, M. G. (2008). Damage detection by means of structural damping identification. *Engineering Structures*, pp. 3497 - 3504.
- DU, C., MOU, J., MARTUA, L., LIU, S., CHEN, B., ZHANG, J., & LEWIS, F. L. (2012). Structure Crack Identification Based on Surface-mounted Active Sensor Network with Time-Domain Feature Extraction and Neural Network. *Sensors & Transducers Journal*, pp. 283 - 296.
- DAS, H.C., PARHI, D.R. (2009), Application of neural network for fault diagnosis of cracked cantilever beam, *World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*, Coimbatore, India, Article No. 5393733, 1303-1308.
- DYKE, S. J.-F. (2003). Phase II of The Asce Benchmark Study On Shm. 15th Asce Engineering Mechanics Conference. New York: Columbia University.
- ELKORDY, M. F., CHANG, K. C., & LEE, G. C. (1993). Neural Networks Trained by Analytically Simulated Damage States. *Journal of Computing in Civil Engineering*, 7, pp. 130 - 145.

- FANG, X., LUO, H., TANG, J. (2005). "Structural Damage Detection Using Neural Network with Learning Rate Improvement." *Computers and Structures*, 83 21-50.
- FAYYADH, M. M., RAZAK, H. A., & ISMAIL, Z. (s.d.). Combined modal parameters-based index for damage identification in a beamlike structure: theoretical development and verification.
- FIEDMANN, H., & KRAEMER, P. (2016). Vibration-based condition monitoring, structural health monitoring, population monitoring – Approach to a definition of the different concepts by means of practical examples from the field of wind energy. 8th European Workshop on Structural Health Monitoring (EWSHM 2016).
- FONSECA, A.; MATO, F. M. (2005) "Infant Henrique Bridge over the River Douro, Porto", SEI, Journal of the International Association for Bridge and Structural Engineering (IABSE), Vol. 15, Nº 2, May 2005: 85-87.
- GENOVESE, M. (2000). Localização e quantificação de danos em estruturas por meio das suas características dinâmicas. Dissertação de Mestrado da Universidade de Brasília, Faculdade de Tecnologia, Estruturas e Construção Civil.
- GENOVESE, M. (2005). Avaliação estrutural: Influência do Ruído nos Métodos de Detecção de Danos Baseados na Análise das Propriedades Dinâmicas. (Tese de Doutorado, Ed.) Brasília, Distrito Federal, Brasil: Tese de Doutorado, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília.
- GENOVESE, M., BRITO, J. L., & DOZ, G. (2002). Identificação de Danos por Meio das suas Características Dinâmicas Mediante a Atualização de um Método Híbrido entre o Método do Erro e a Técnica De Redes Neurais Artificiais. XXX Jornadas Sul-Americanas de Engenharia Estrutural. Brasília.
- GOMES, H. M. (2004). Redes Neurais Artificias para Detecção de Danos. Mecânica Computacional Vol. XXIII. Bariloche, Argentina.
- HAERI, M. H., LOTFI, A., DOLATSHAHI, K. M., & GOLAFSHANI, A. A. (2017). Inverse Vibration Technique for Structural Health Monitoring of Offshore Jacket Platforms. *Applied Ocean Research*, pp. 181 - 198.

- HAKIM, S., ABDUL RAZAK, H., RAVANFAR, S., & M., M. (2014). Structural Damage Detection Using Soft Computing Method. *Structural Health Monitoring*, 5.
- HARYANTO, I., SETIAWAN, J. D., BUDIYONO, A. (2007). Structural Damage Detection Using Randomized Trained Neural Networks. ICIUS, Bali, Indonesia, October 24-25.
- HAYKIN, S. (2001). *Redes Neurais - Princípios e Prática*. (T. P. Engel, Ed.) Porto Alegre: Bookman - 2ª edição.
- HAYKIN, S. (2009). *Neural Networks and Machine Learning*.
- HEARN, G., & TESTA, R. B. (1991). Modal Analysis for Damage Detection in Structure. *Journal of Structural Engineering*, 117, pp. 3042 - 3063.
- HUTH, O., FELTRIN, G., MAECK, J., KILIC, N., & MOTAVALLI, M. (2005). Damage Identification Using Modal Data: Experiences on a Prestressed Concrete Bridge. *JOURNAL OF STRUCTURAL ENGINEERING*.
- JEYASEHAR C. A., SUMANGALA, K. (2006). Damage Assessment of Prestressed Concrete Beams Using Artificial Neural Network (ANN) Approach. *Computers and Structures*, pp. 1709 - 1718.
- JIN, C., JANG, S., SUN, X., J., & CHRISTENSON, R. (2016). Damage Detection Of A Highway Bridge Under Severe Temperature Changes Using Extended Kalman Filter Trained Neural Network. *Civil Structure Health Monitoring*, pp. 545 - 560.
- KARIMI, M., HAGHSHENAS, N., SAHEBIADIB, A., JAHANBAKHS, M. (2013). Crack identification in beams. *Technical Journal of Engineering and Applied Sciences*. TJEAS Journal-2013-3-16/1733-1737.
- KONDRU, L., RAO, N. M. R. (2013). "Damage Detection In Cantilever Beams Using Artificial Neural Networks", *International Journal of Mechanical and Production Engineering Research and Development (IJMPERD)*. Vol. 3, Issue 1, Mar 2013, 259-268.
- KUNERT, H., & AMBROSINI, D. (2007). Determinación De La Distribución Del Daño en Vigas Mediante El Cambio en sus Frecuencias Naturales. *Mecánica Computacional*, Xxvi2007, 2623 - 2645.

- LEE, J. J., LEE, J. W., YI, J. H., YUN, C. B., & JUNG, H. Y. (2005). Neural networks-based damage detection for bridges considering errors in baseline finite element models. *Journal of Sound and Vibration*, pp. 555 - 578.
- LEE, L. S. (2004). Investigation of Integrity and Effectiveness of RC Bridge Deck Rehabilitation With CFRP Composites. San Diego: Report no. SSRP-2004/08, department of structural engineering, university of California.
- LIEVEN, N. A., & EWINS, D. J. (1988). Spatial Correlation of Mode Shapes, the Coordinate Modal Assurance Criterion (COMAC). *Proc. 6th Int. Modal Analysis Conference*, pp. 690-695.
- LINK, R. J. (2008). Structural Damage Detection Using Frequency Response Functions and Orthogonal Matching Pursuit.
- MAGALHÃES, F. (2010). Operational Modal Analysis for Testing and Monitoring Of Bridges And Special Structures. Porto, Portugal.
- MAGALHÃES, F., CUNHA, A., CAETANO, E. (2014). “Five years of continuous dynamic monitoring of Infante D. Henrique Bridge”. *Proceedings of the 9th International Conference on Structural Dynamics, EURODDYN 2014*, 978-972-752-165-4.
- MARCY, M. (2013). Identificação E Quantificação De Danos Em Pórticos Espaciais Via Método Do Erro Residual E Redes NEURAIS ARTIFICIAIS. Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia. Estruturas e Construção Civil.
- MATLAB. Matrix Laboratory - R2015b. MathWorks - MATLAB and Simulink for Technical Computing. Massachusetts, U.S.A, 2015.
- McCULLOCH, W. S., & PITTS, W. (1943). A Logical Calculus of The Ideas Immanent In Nervous Activity. *Bulletin of Mathematical Biophysics*, 5, 115 - 133.
- MEHRJOO, M., KHAJI, N., MOHARRAMI, H., BAHREININEJAD, A. (2008). Damage Detection of Truss Bridge Joints Using Artificial Neural Networks. *Expert Systems with Applications* 35, pp. 1122–1131

- MERUANE, V., & MAHU, J. (2014). Real-Time Structural Damage Assessment Using Artificial Neural Networks and Antiresonant Frequencies. *Shock and Vibration*.
- NGUYEN, V. V., DACKERMANN, U., LI, J., MAKKI ALAMDARI, M., MUSTAPHA, S., RUNCIE, P., & YE, L. (2015). Damage Identification of a Concrete Arch Beam Based on Frequency Response Functions and Artificial Neural Networks. *Electronic Journal of Structural Engineering*.
- OLIVEIRA, G. M. (2016). Health Monitoring Of Wind Vibration-Based Structural Turbines. Porto: A dissertation presented to the Faculty of Engineering of the University of Porto.
- OMENZETTER, P., & LAUTOUR, O. L. (2010). Nearest neighbor and learning vector quantization classification for damage detection using time series analysis. *STRUCTURAL CONTROL AND HEALTH MONITORING*, 17, pp. 614-631.
- ONUR AVCI, P. O., & ABDELJABER, A. O. (2015). Self-Organizing Maps for Structural Damage Detection: A Novel Unsupervised Vibration-Based Algorithm. *Journal of Performance of Constructed*, p. 11.
- PÁDUA, B. A., LUDEMIR, T. B., PONCE DE LEON, A. F. C (2000). *Redes Neurais Artificiais Teoria e Aplicações*, LTC, Rio de Janeiro.
- PANDEY, A. K. (1991). "Damage detection from changes in curvature mode shapes. *Journal of Sound and Vibration*, 145, pp. 321 - 332.
- PEREZ, G. A., SANCHEZ, J. P., GONZALEZ, A. D., R., S., RIOS, R. O., & TRONCOSO, R. J. (2013). Fused empirical mode decomposition and wavelets for locating combined damage in a truss-type structure through vibration analysis. *Journal of Zhejiang University-SCIENCE A (Applied Physics & Engineering)*.
- ROCHA, T (2012). Uma proposta para a classificação de ações humanas baseada nas características do movimento e em redes neurais artificiais. *Dissertação de Mestrado em Engenharia de Sistemas Eletrônicos e de Automação*. Departamento de Engenharia Elétrica, Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, 83.p.

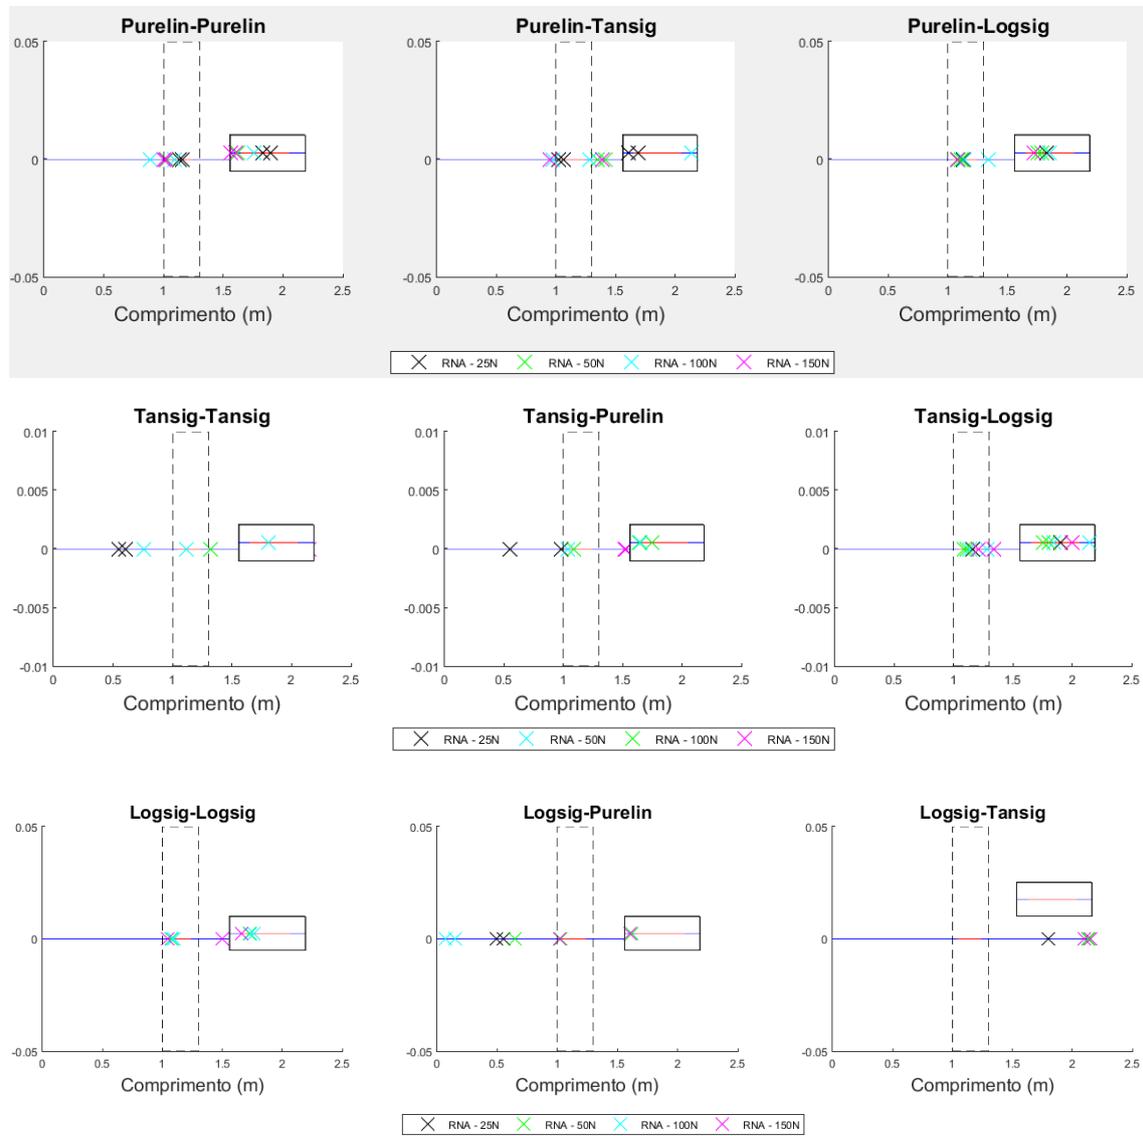
- ROSEBNBLANTT, F. (1958). The Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 386-408.
- RUCKA, W., WILDE, K. (2010). “Neuro-Wavelet Damage Detection Technique In Beam, Plate And Shell Structures With Experimental Validation”, *Journal of Theoretical and Applied Mechanics*, 48, 3, pp. 579-604
- RUMELHART, D.E., HINTON, G.E., & WILLIAMS, R.J. (1986). Learning internal representations by backpropagating errors. *Nature*, 323:533–536.
- RYTTER, A. (1993). *Vibrational Based Inspection of Civil Engineering Structures*. Aalborg: Dept. of Building Technology and Structural Engineering, Aalborg University.
- SAHIN, M., & SHENOI, R. A. (2003). Quantification and localisation of damage in beam-like structures. *Engineering Structures*, pp. 1785 - 1802.
- SALAWU, O. S. (1997). Detection of structural damage through changes in frequency: a review. *Engineering Structures*, 19, pp. 718 - 723.
- SELEEMAH, A. A., ABOU-RAYAN, A. M., & SAMY, M. (2012). A Neural Network Model for Damage Detection Of El-Ferdan Bridge. *Fourth International Conference on Structural Stability and Dynamics (ICSSD 2012)*. Texas, USA.
- SHEELA, K. G., & DEEPA, S. N. (2013). Review on Methods to Fix Number of Hidden. *Mathematical Problems in Engineering*, 2013.
- SHI, A., YU, X. H. (2012). Structural damage detection using artificial neural networks and wavelet transform. *2012 IEEE Int Conf Comput Intell Meas Syst Appl Proc 2012* 7-11.
- SUN, Z., ZOU, Z., & ZHANG, Y. (2017). Utilization of structural health monitoring in long-span bridges:Case studies. *Structural Control Health Monitoring*.
- TAN, Z. X., THAMBIRATNAM, D., CHAN, T. H., & RAZAK, H. A. (2017). Detecting damage in steel beams using modal strain energy based. *Engineering Failure Analysis*, 253 - 262.

- TIBADUIZA, D. A., MUJICA, L. E., RODELLAR, J. (2013). Damage classification in structural health monitoring using principal component analysis and self-organizing maps. *Structural Control And Health Monitoring*, 20:1303–1316.
- VESANTO, J. (2000). SOM implementation in SOOM Toolbox. Fonte: <http://www.cis.hut.fi/projects/somtoolbox/download/>
- WENZEL, H. (2009). *Health Monitoring of Bridges*. Viena, Austria: John Wiley & Sons Ltd.
- WU X., G. G. (1992). Use of Neural network for Damage detection in structures. *Computers and Structures*, 42, pp. 649 - 659.
- YENUNG, W. T., SMITH, W. J. (2005). Damage detection in bridges using neural networks for pattern recognition of vibration signatures. *Engineering Structures*, 27, pp 685 – 698.

## **APÊNDICES**

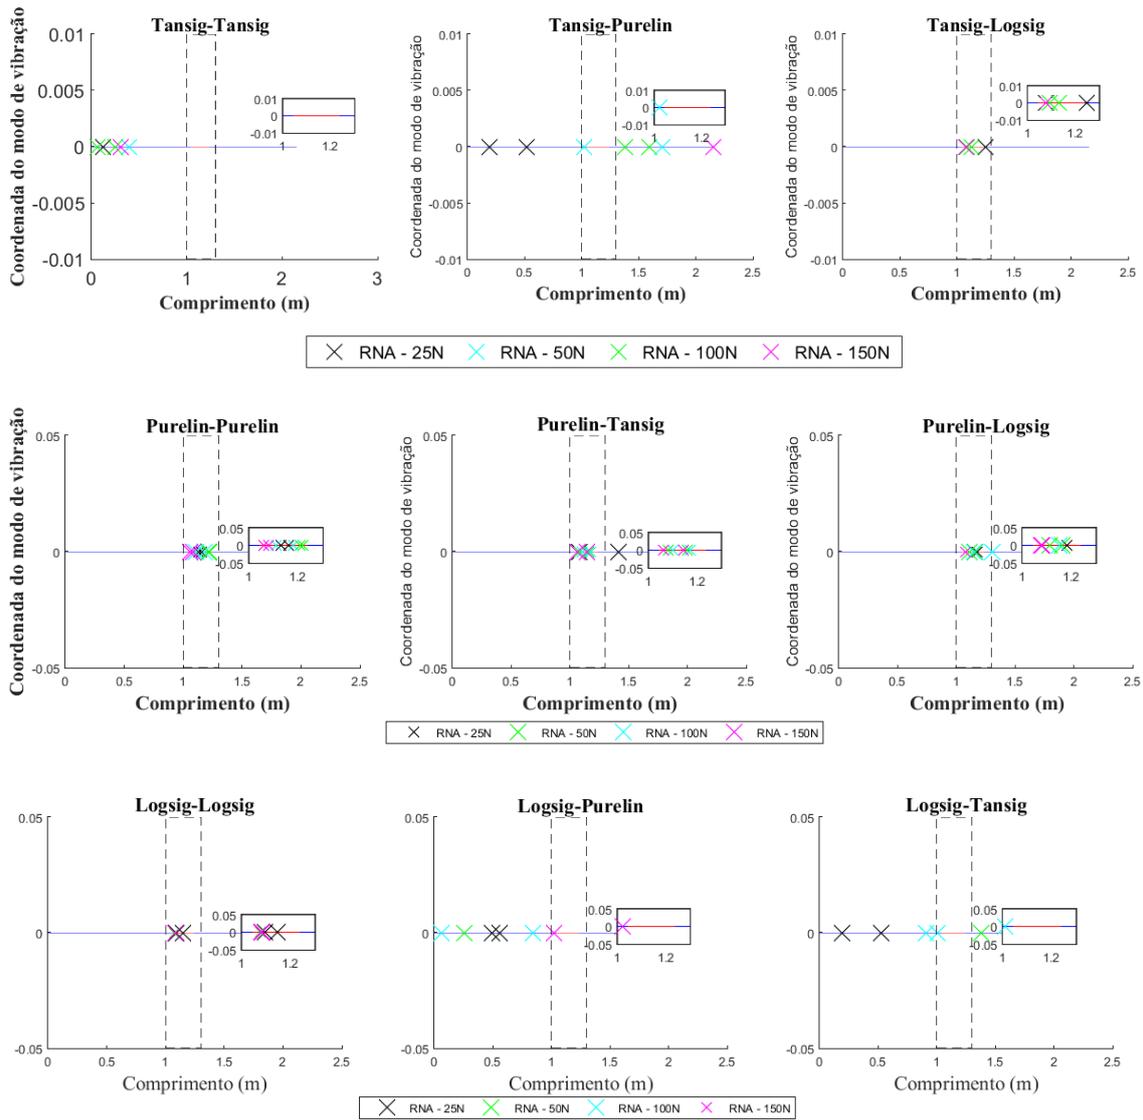
# APÊNDICE A – Redes *Backpropagation* com as frequências de vibração da viga (RBFV)

## 1ª frequência



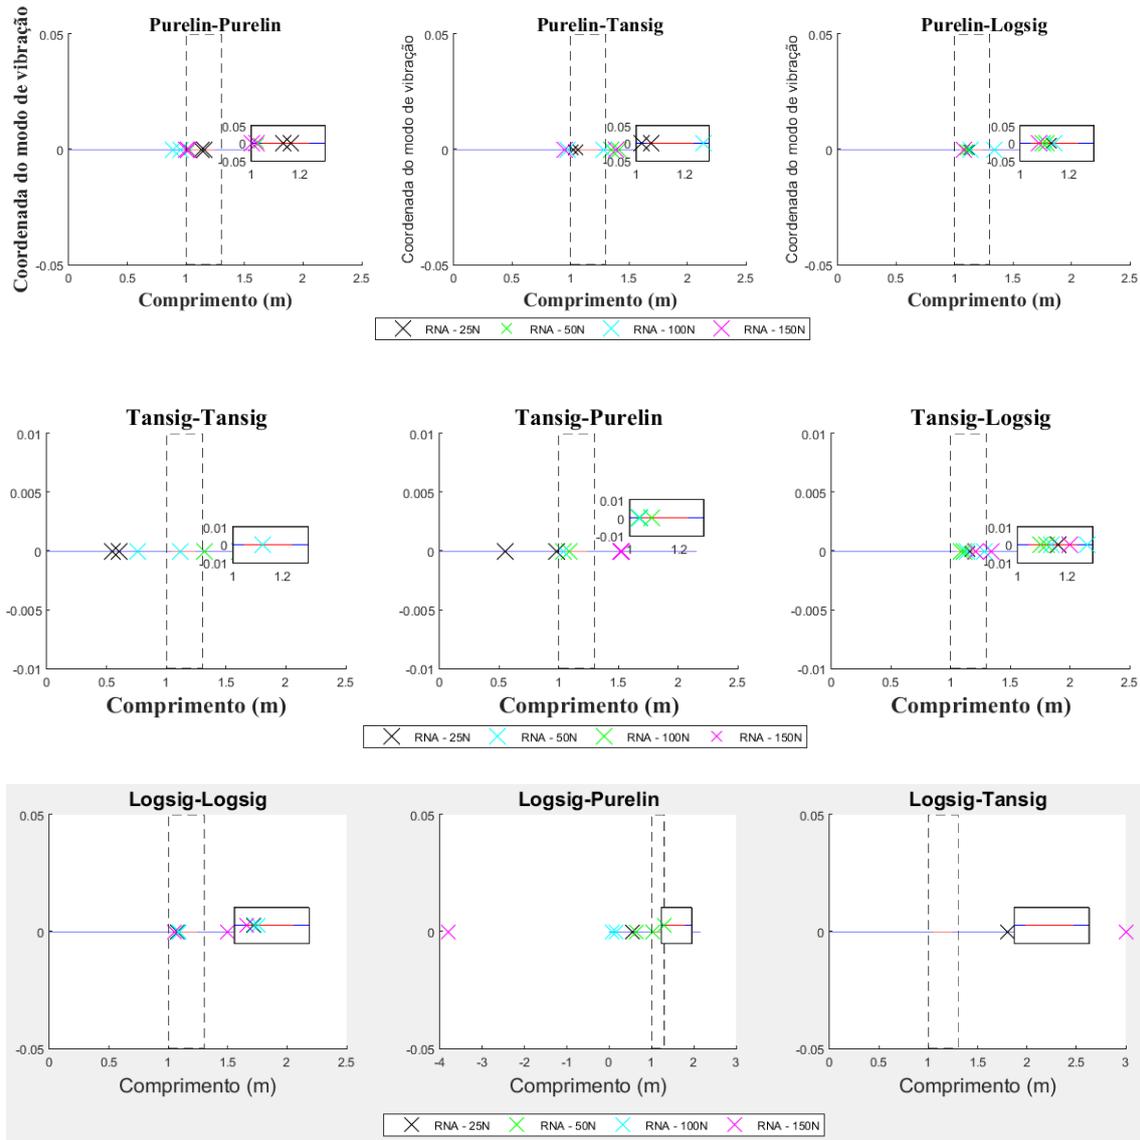
A 1 RNAs formadas com a primeira frequência.

## 2ª frequência



A 2 RNAs formadas com a segunda frequência.

### 3ª frequência



A 3 RNAs formadas com a terceira frequência.

## APÊNDICE A.1 – LVQ com viga intacta

### Modo de vibração como dado de entrada



A1 1Localização de dano em uma viga intacta. (Modo 1 e modo 2 como dados de entrada).

### Frequência e modos de vibração como dado de entrada



A1 2Localização de dano em uma viga intacta. (Modos e frequências 1 e 2 como dados de entrada).

## APÊNDICE B – Resultado de análises feitas na ponte com o LVQ LVQ processado com as frequências obtidas nos períodos de 24h e 1 semana.

### Análise 1 (24h)

1) Treinamento: Intacto 1º ano + D1 + D3

Teste: Intacto 2º ano.

2) Treinamento: Intacto 1º ano + D1 + D4

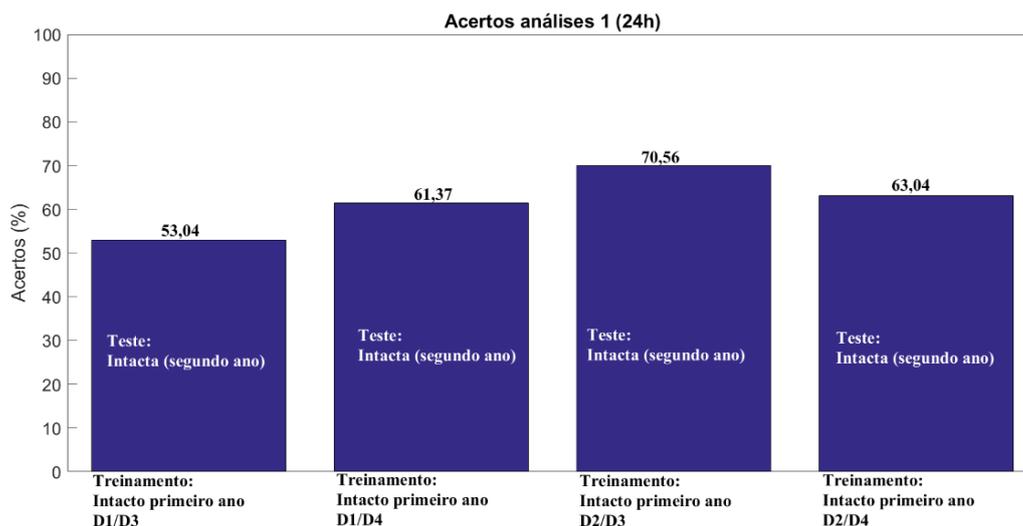
Teste: Intacto 2º ano

3) Treinamento: Intacto 1º ano + D2 + D3

Teste: Intacto 2º ano

4) Treinamento: Intacto 1º ano + D2 + D4

Teste: Intacto 2º ano



B 1. Resultados obtidos na análise 1 – LVQ (24h).

### Análise 2 (24h)

1) Treinamento: Intacto 1º ano + D1 + D3

Teste 1: D2. Teste 2: D4

2) Treinamento: Intacto 1º ano + D1 + D4

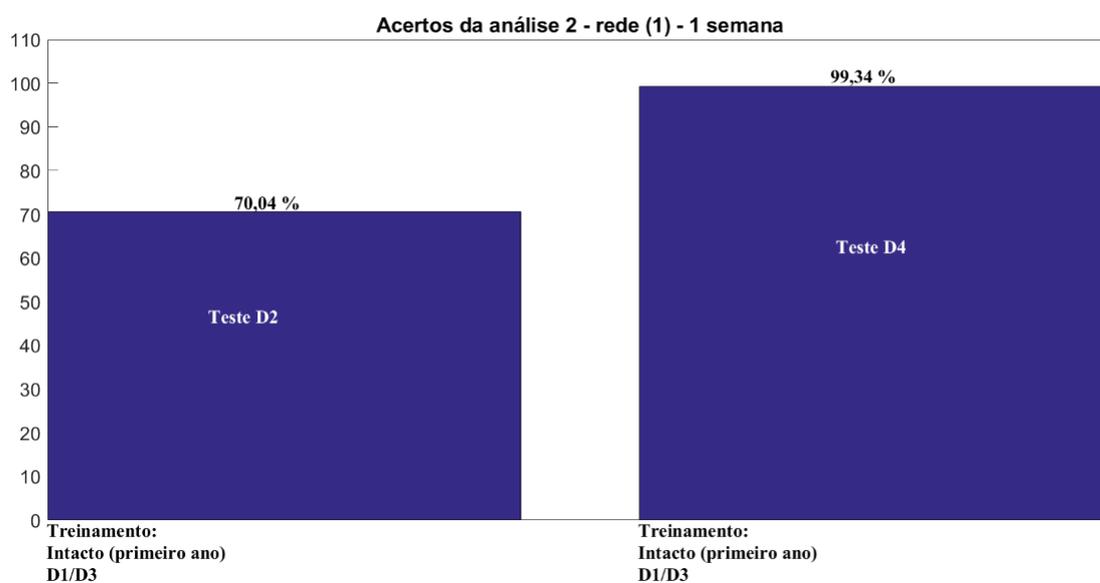
Teste 1: D2. Teste 2: D3

3) Treinamento: Intacto 1º ano + D2 + D3

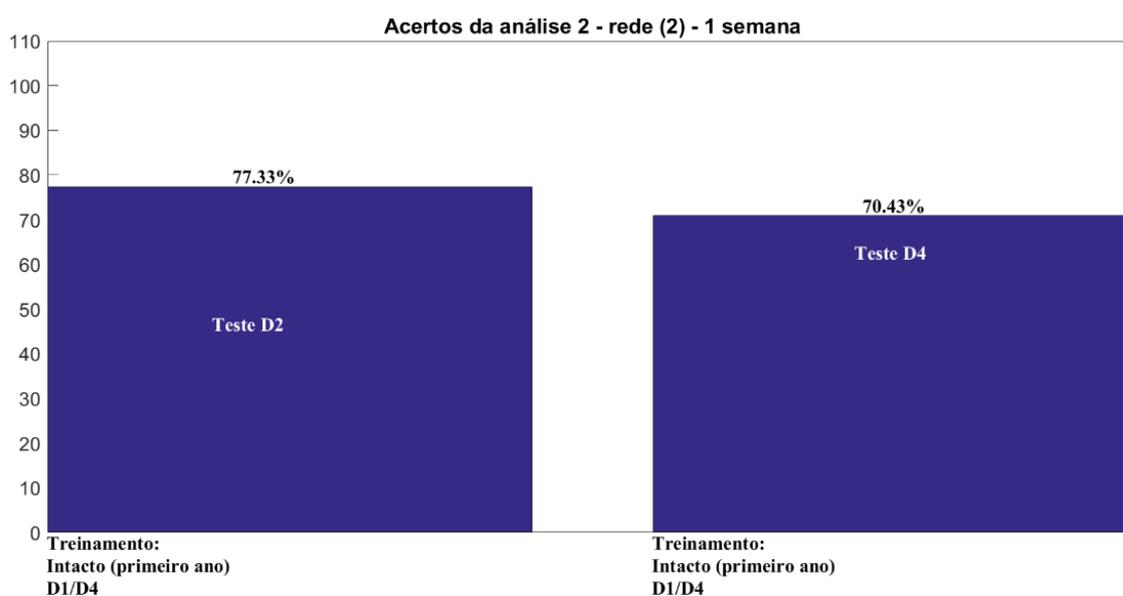
Teste 1: D1. Teste 2: D4

4) Treinamento: Intacto 1º ano + D2 + D4

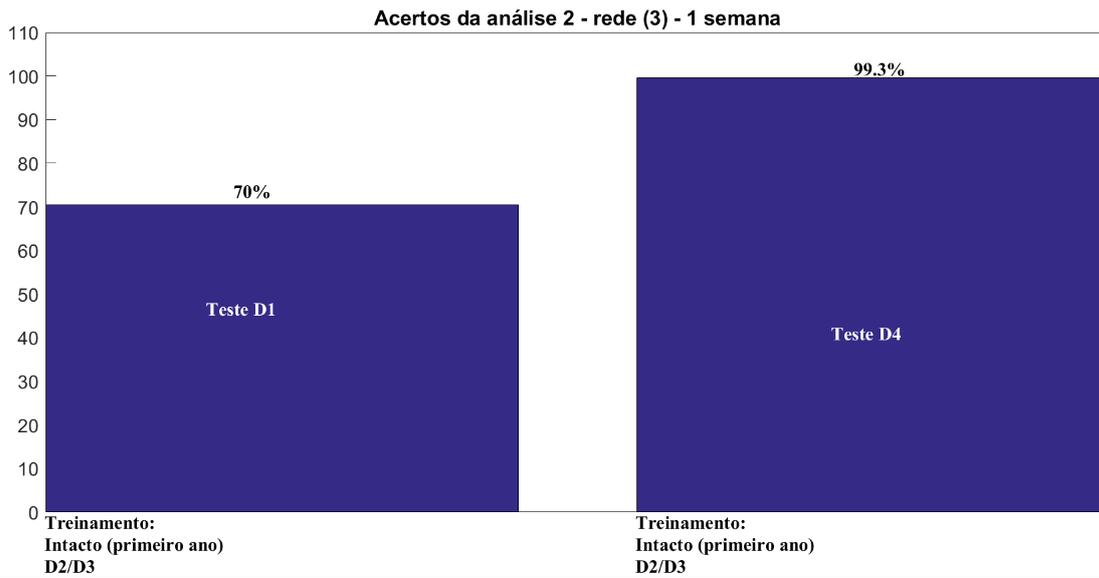
Teste 1: D1. Teste 2: D3



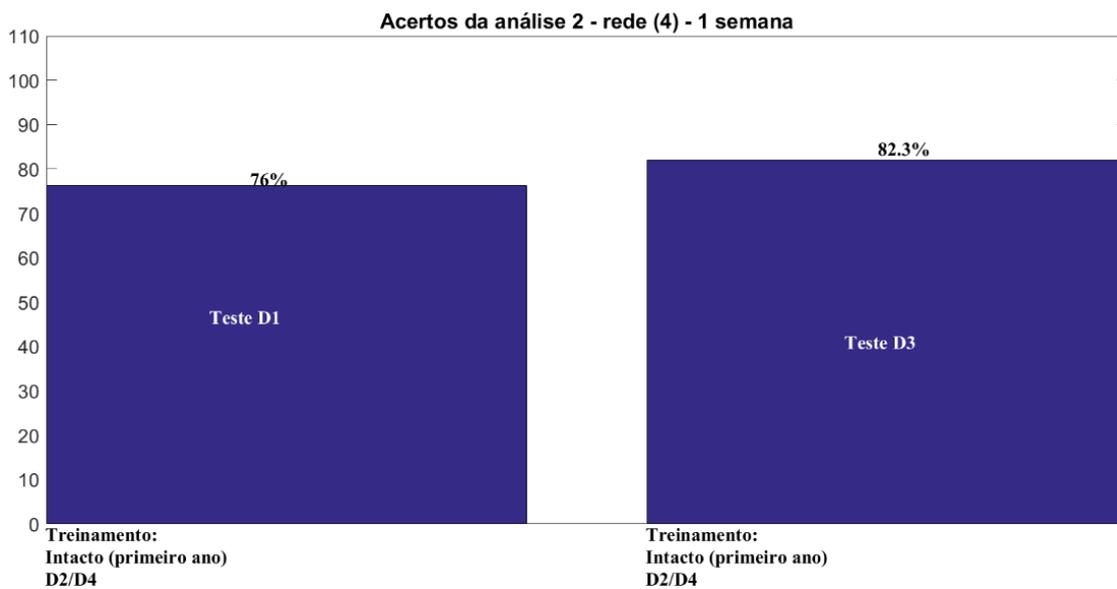
B 2. Resultados obtidos na análise 2 (1) – LVQ (24h).



B 3. Resultados obtidos na análise 2 (2) – LVQ (24h).



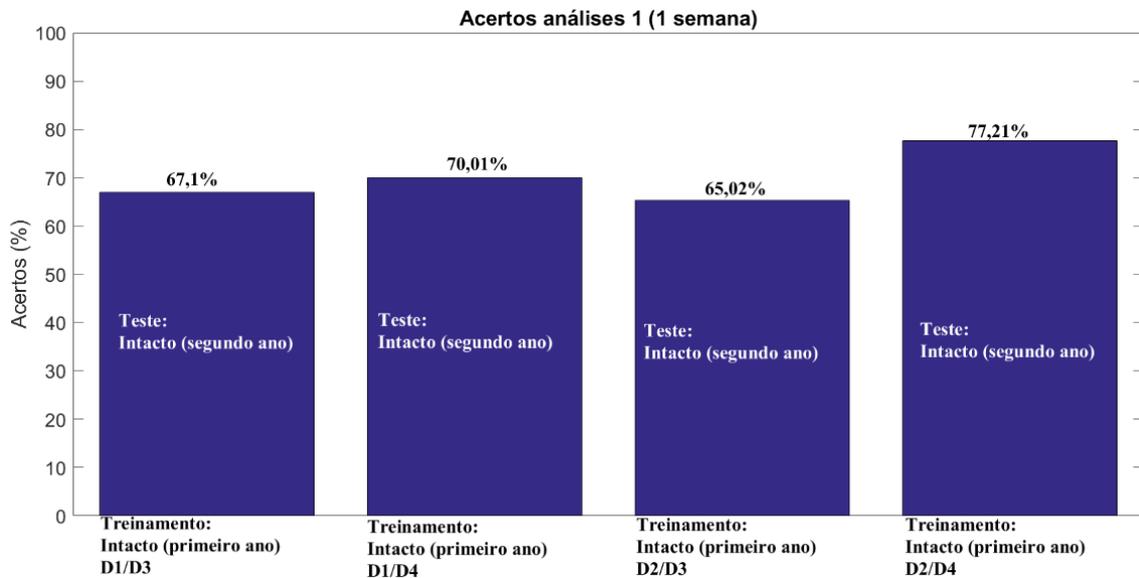
B 4. Resultados obtidos na análise 2 (3) – LVQ (24h).



B 5. Resultados obtidos na análise 2 (4) – LVQ (24h).

### Análise 1 (1 semana)

- 1) Treinamento: Intacto 1º ano + D1 + D3  
Teste: Intacto 2º ano.
- 2) Treinamento: Intacto 1º ano + D1 + D4  
Teste: Intacto 2º ano
- 3) Treinamento: Intacto 1º ano + D2 + D3  
Teste: Intacto 2º ano
- 4) Treinamento: Intacto 1º ano + D2 + D4  
Teste: Intacto 2º ano



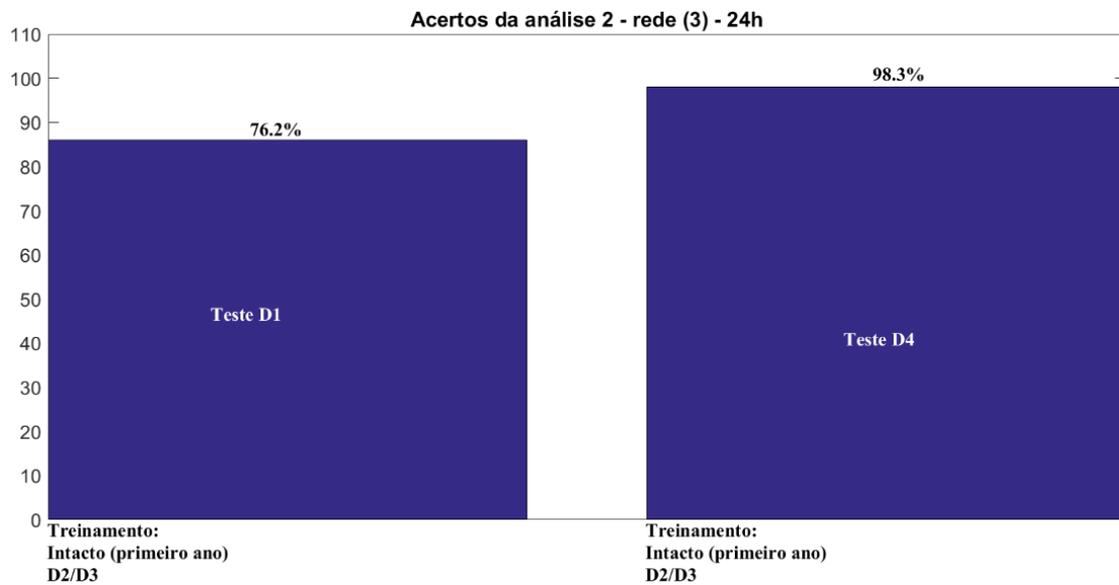
B 6. Resultados obtidos na análise 1 – LVQ (1 semana).

### Análise 2 (1 semana)

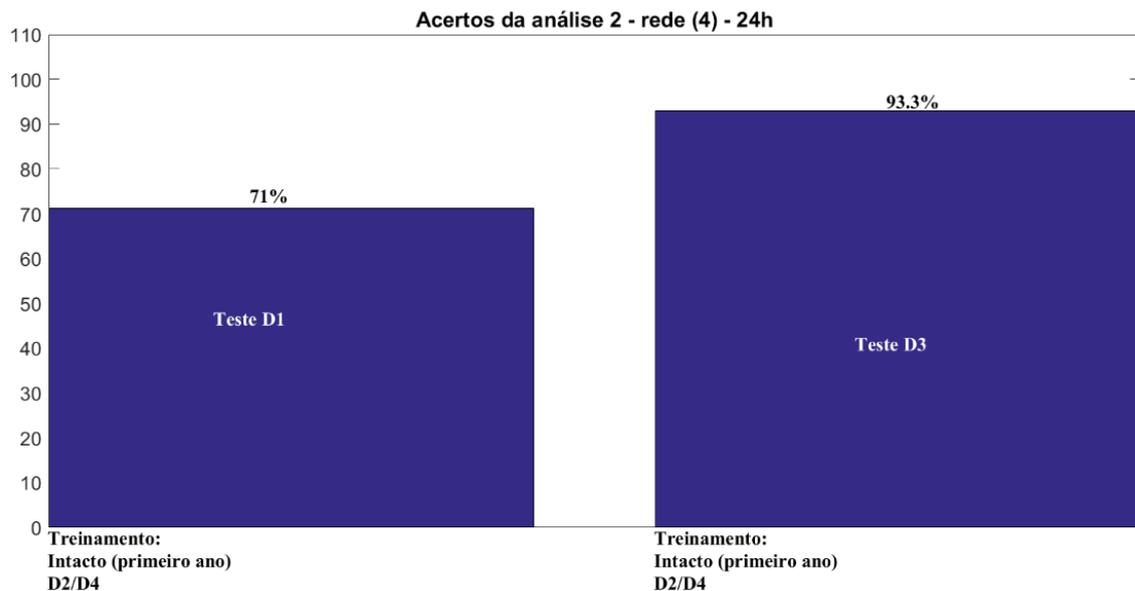
- 1) Treinamento: Intacto 1º ano + D1 + D3  
Teste 1: D2. Teste 2: D4
- 2) Treinamento: Intacto 1º ano + D1 + D4  
Teste 1: D2. Teste 2: D3
- 3) Treinamento: Intacto 1º ano + D2 + D3  
Teste 1: D1. Teste 2: D4

4) Treinamento: Intacto 1º ano + D2 + D4

Teste 1: D1. Teste 2: D3



B 7. Resultados obtidos na análise 2 (3) – LVQ (1 semana).

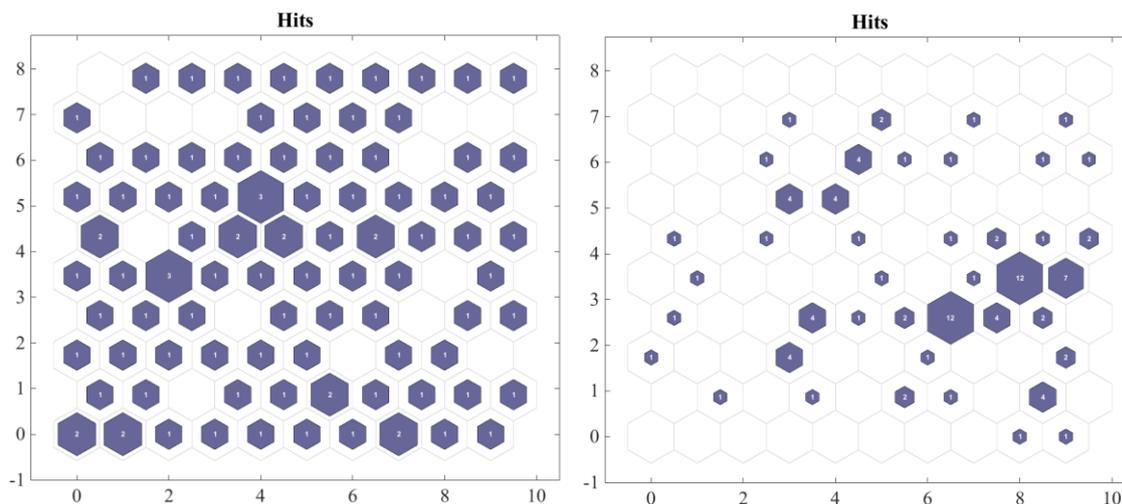


B 8. Resultados obtidos na análise 2 (4) – LVQ (1 semana).

**APÊNDICE B.1 – Resultado de análises feitas na ponte com o SOM**  
**Rede SOM processado com as frequências obtidas nos períodos de 24h e 1 semana.**

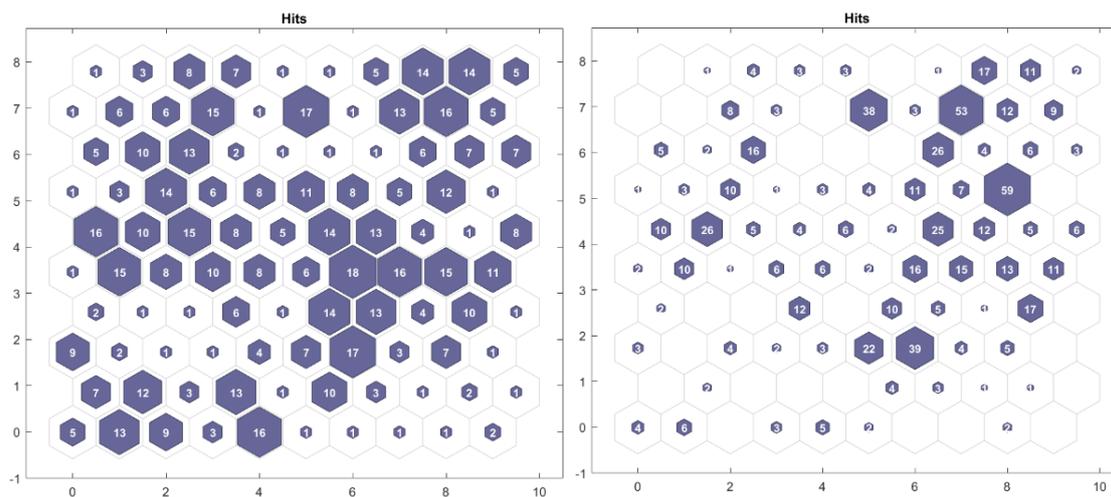
**Análise 1:**

24h de monitoramento



B1 1(a)Treinamento do SOM (b) Teste do SOM– análise 1 – 24h.

1 semana de monitoramento

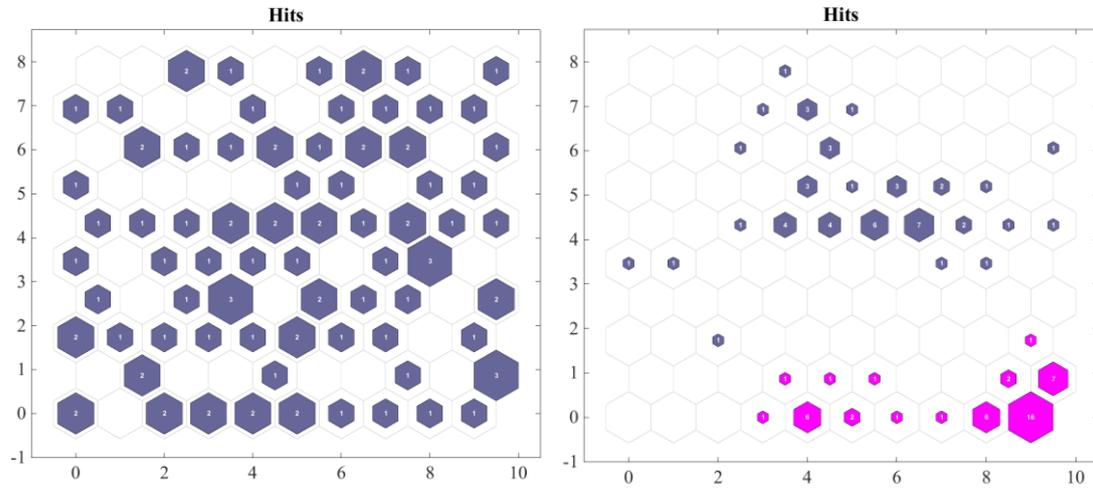


B1 2(a)Treinamento do SOM (b) Teste do SOM– análise 1 –1 semana.

**Análise 2:**

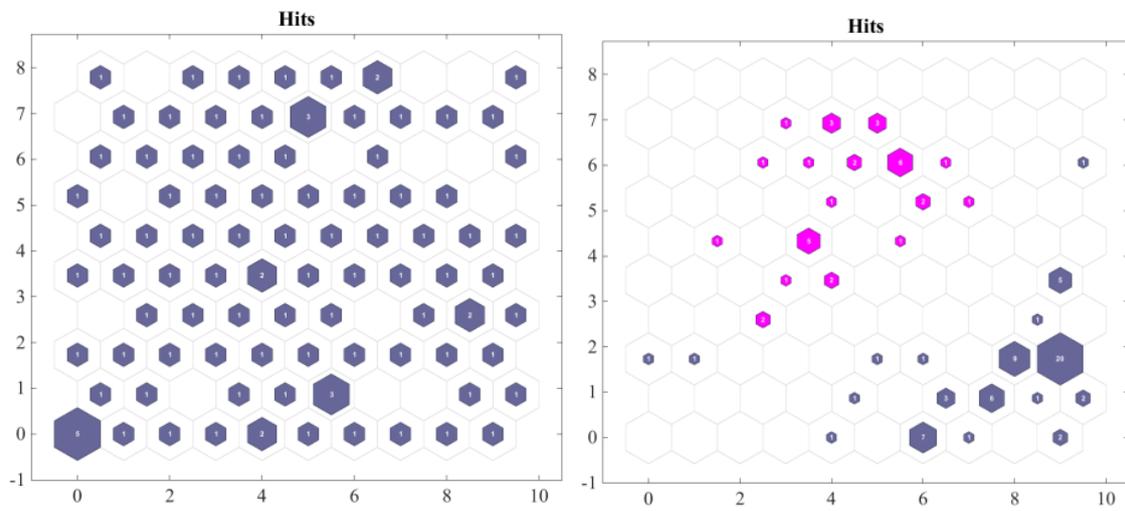
**24h de monitoramento**

**Cenário 1**



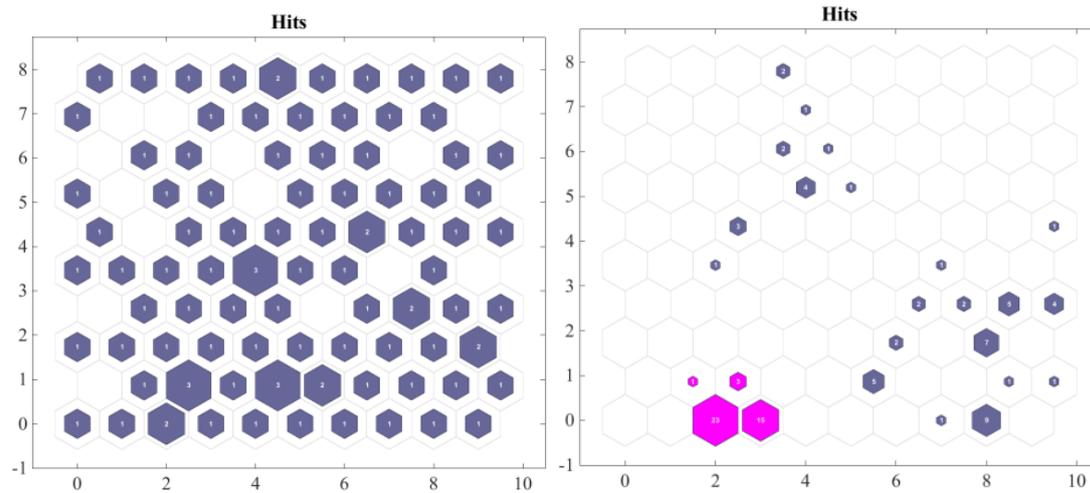
B1 3(a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 1) – 24 horas.

**Cenário 2**



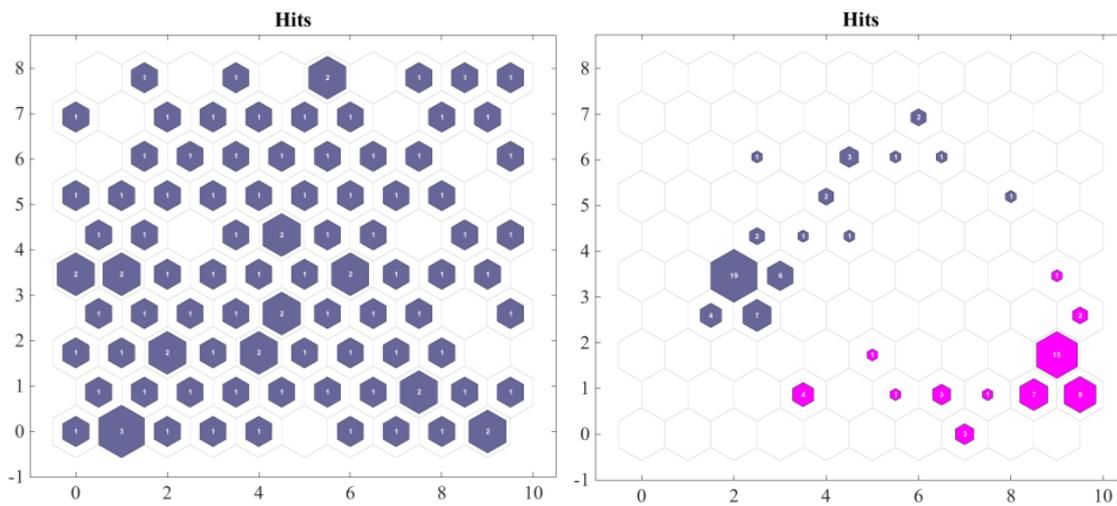
B1 4(a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 2) – 24 horas.

### Cenário 3



B1 5(a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 3) – 24 horas.

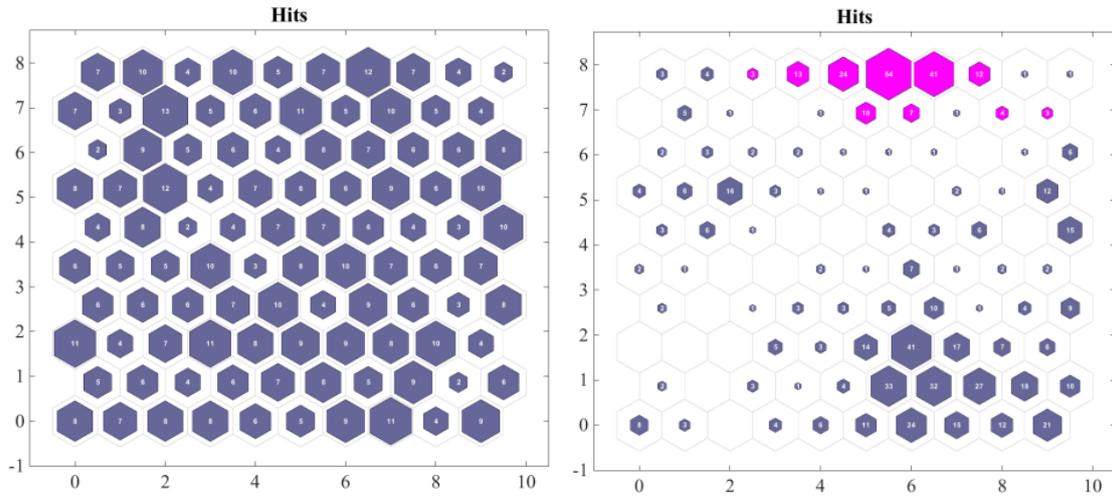
### Cenário 4



B1 6(a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 4) – 24 horas.

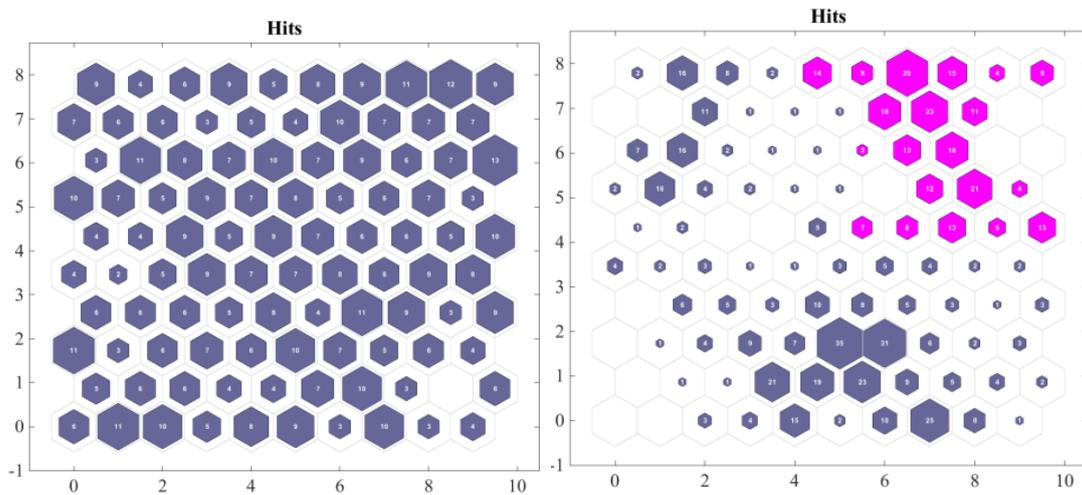
1 semana de monitoramento

Cenário 1



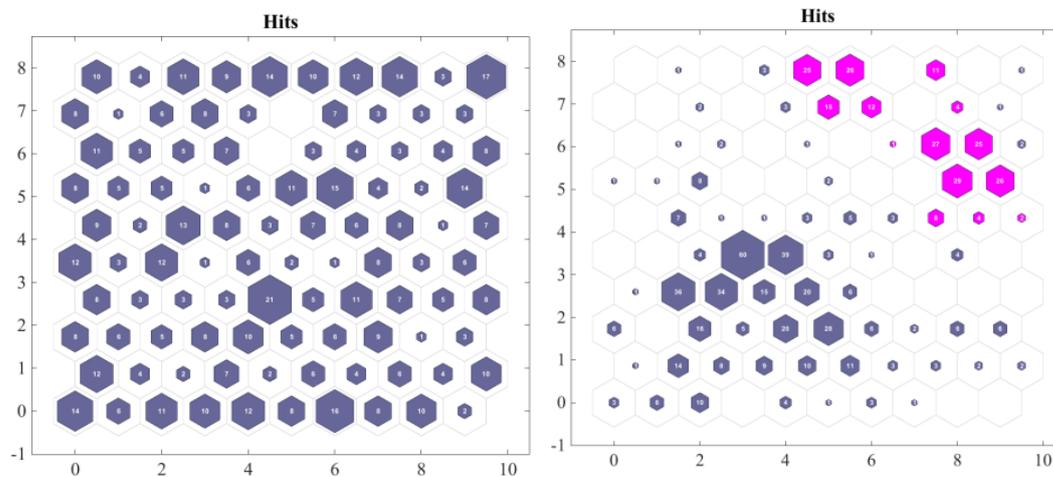
B1 7 (a) Treinamento do SOM. (b). Teste do SOM – análise 2 (cenário 1) – 1 semana.

Cenário 2



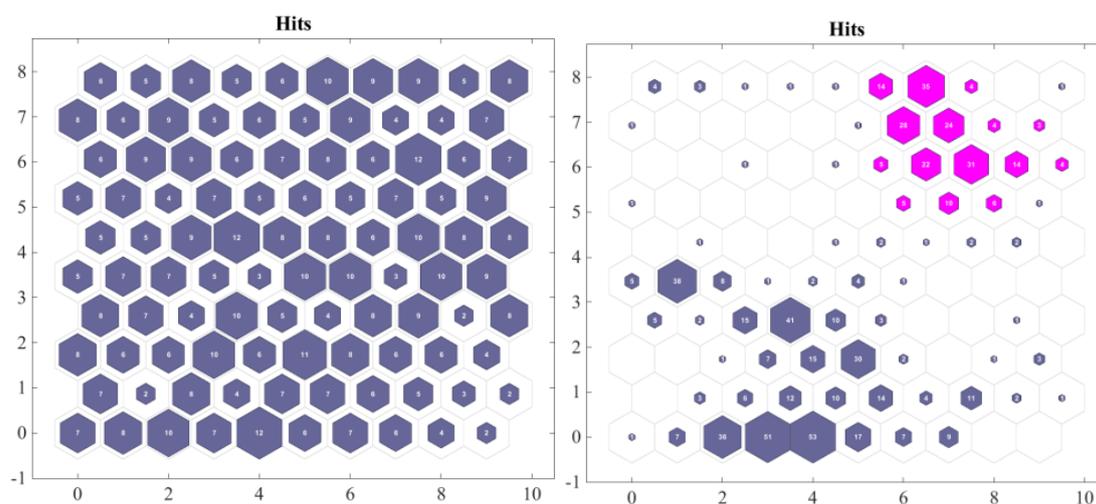
B1 8 (a) Treinamento do SOM. (b)Teste do SOM – análise 2 (cenário 2) – 1 semana.

### Cenário 3



B1 9 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 3) – 1 semana.

### Cenário 4



B1 10 (a) Treinamento do SOM. (b) Teste do SOM – análise 2 (cenário 4) – 1 semana.

