

Universidade Federal de Juiz de Fora  
Instituto de Ciências Exatas/Faculdade de Engenharia  
Programa de Pós-Graduação em Modelagem Computacional

**Rafaelle Piazzaroli Finotti Amaral**

**Inteligência artificial aplicada ao monitoramento de estruturas: detecção de  
alterações mecânico-estruturais baseada no uso de redes neurais  
autocodificadoras esparsas para a caracterização de respostas dinâmicas**

Juiz de Fora  
2022

**Rafaelle Piazzaroli Finotti Amaral**

**Inteligência artificial aplicada ao monitoramento de estruturas: detecção de alterações mecânico-estruturais baseada no uso de redes neurais autocodificadoras esparsas para a caracterização de respostas dinâmicas**

Tese apresentada ao Programa de Pós-Graduação em Modelagem Computacional da Universidade Federal de Juiz de Fora, como requisito parcial para obtenção do título de Doutora em Modelagem Computacional.

Orientador: Prof. D.Sc Flávio de Souza Barbosa

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

Juiz de Fora

2022

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Amaral, Rafaelle Piazzaroli Finotti.

Inteligência artificial aplicada ao monitoramento de estruturas: detecção de alterações mecânico-estruturais baseada no uso de redes neurais autocodificadoras esparsas para a caracterização de respostas dinâmicas / Rafaelle Piazzaroli Finotti Amaral. – 2022.

167 f. : il.

Orientador: Prof. D.Sc Flávio de Souza Barbosa

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

Tese (Doutorado) – Universidade Federal de Juiz de Fora, Instituto de Ciências Exatas/Faculdade de Engenharia. Programa de Pós-Graduação em Modelagem Computacional, 2022.

1. Inteligência artificial. 2. Detecção de danos. 3. Monitoramento da saúde estrutural. 4. Dinâmica das estruturas. 5. Autocodificador esparsos.  
I. Barbosa, Flávio, orient. II. Cury, Alexandre, coorient. III. Título

**Rafaelle Piazzaroli Finotti Amaral**

**Inteligência Artificial Aplicada ao Monitoramento de Estruturas:** Detecção de Alterações Mecânico-Estruturais Baseada no Uso de Redes Neurais Autocodificadoras Esparsas para a Caracterização de Respostas Dinâmicas

Tese apresentada ao Programa de Pós-Graduação em Modelagem Computacional da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutora em Modelagem Computacional. Área de concentração: Modelagem Computacional.

Aprovada em 06 de maio de 2022.

BANCA EXAMINADORA

**Prof(a)Dr(a). Flávio de Souza Barbosa** - Orientador  
Universidade Federal de Juiz de Fora

**Prof(a)Dr(a). Alexandre Abrahão Cury** - Coorientador  
Universidade Federal de Juiz de Fora

**Prof(a)Dr(a). Graciela Nora Doz de Carvalho**  
Universidade de Brasília

**Prof(a)Dr(a). Samuel da Silva**  
Universidade Estadual Paulista

**Dr(a). João Pedro de Oliveira Dias Prudente dos Santos**  
Companhia Ventient Energy Limited (Portugal)

**Prof(a)Dr(a). Carlos Cristiano Hasenclever Borges**

Universidade Federal de Juiz de Fora

**Prof(a)Dr(a). Leonardo Goliatt da Fonseca**

Universidade Federal de Juiz de Fora

Juiz de Fora, 02/05/2022.



Documento assinado eletronicamente por **João Pedro de Oliveira Dias Prudente dos Santos, Usuário Externo**, em 06/05/2022, às 17:56, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alexandre Abrahao Cury, Professor(a)**, em 06/05/2022, às 18:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Samuel da Silva, Usuário Externo**, em 06/05/2022, às 18:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Goliatt da Fonseca, Professor(a)**, em 06/05/2022, às 18:17, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Flavio de Souza Barbosa, Professor(a)**, em 06/05/2022, às 18:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Carlos Cristiano Hasenclever Borges, Professor(a)**, em 06/05/2022, às 18:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **GRACIELA NORA DOZ DE CARVALHO, Usuário Externo**, em 06/05/2022, às 18:27, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf ([www2.ufjf.br/SEI](http://www2.ufjf.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **0760804** e o código CRC **D3A9B254**.

*Dedicado aos meus pais.*

## AGRADECIMENTOS

Dedico os meus sinceros agradecimentos:

- Aos meus orientadores, Flávio e Alexandre, pelos ensinamentos, disponibilidade e paciência ao longo de todos esses anos de trabalho. O professor é a ponte entre o aluno e universidade e, para mim, vocês dois cumprem esse papel magnificamente bem. Muito obrigada por todas as oportunidades!
- Aos professores Roberto Pimentel e Carmelo Gentile pela colaboração, recepção e ajuda durante o período que passei nas suas respectivas instituições de ensino - Universidade Federal da Paraíba e Politecnico di Milano.
- A todos os professores do Programa de Pós-Graduação em Modelagem Computacional que participaram direta ou indiretamente da minha formação, e aos demais funcionários, por serem sempre tão prestativos.
- Aos amigos que fiz no programa, em especial à galera da Sala 11 e ao Aldemon, por toda ajuda, motivação e companhia.
- À Universidade Federal de Juiz de Fora, pelo ensino público, gratuito e de qualidade.
- À CAPES, FAPEMIG e CNPq pelo suporte financeiro.

Por fim, gostaria de fazer um agradecimento mais que especial aos meus amados pais, que me incentivam e apoiam desde sempre, e aos meus irmãos, em particular ao Renan, pelo afeto, amizade e ajuda - não só no que diz respeito à tese, mas nas mais variadas situações. Agradeço também aos demais familiares e amigos que me acompanham, auxiliam e vibram com as minhas conquistas. Muito obrigada a todos!

## RESUMO

Com a rápida evolução da tecnologia computacional e de informação, notáveis avanços foram alcançados nos sistemas de Monitoramento da Saúde Estrutural (SHM, do inglês “*Structural Health Monitoring*”), fazendo com que o desenvolvimento de estratégias mais automatizadas de detecção de comportamentos estruturais anômalos por meio da caracterização adequada das respostas dinâmicas ocupem um espaço considerável nas pesquisas atuais sobre o assunto. Nos últimos anos, algoritmos de inteligência artificial focados no aprendizado profundo têm se tornado cada vez mais populares como ferramentas para a detecção de alterações em estruturas. O conceito de aprendizado profundo tem origem na teoria de redes neurais e compreende diversas abordagens que, devido à grande capacidade de processamento de dados, foram principalmente formuladas para tratar problemas não-lineares e de alta dimensão. Embora os fundamentos básicos de tais algoritmos tenham sido estabelecidos na década de 60, seu uso em estratégias SHM ainda é relativamente novo. Diante deste cenário, o presente trabalho se debruça sobre a avaliação do algoritmo de aprendizado profundo denominado Autocodificador Esperso (SAE, do inglês “*Sparse AutoEncoder*”) quando utilizado como extrator de parâmetros de dados dinâmicos. Mais especificamente, avalia-se a capacidade dos modelos SAE de fornecer conjuntos de variáveis representativas, determinados através do processamento de sinais no domínio do tempo, que viabilizem a detecção de um comportamento considerado anormal para uma dada estrutura. Primeiramente, uma análise de sensibilidade é realizada, visando verificar a influência que as variáveis que definem o funcionamento do SAE exercem sobre a sua habilidade de representar as respostas vibracionais. Em seguida, com o intuito de investigar se os parâmetros modelados pelo SAE permitem de fato distinguir diferentes estados estruturais, uma estratégia supervisionada que utiliza o SAE como seletor de características e o algoritmo de Máquina de Vetor Suporte (SVM, do inglês “*Support Vector Machine*”) como classificador é apresentada e aplicada a um modelo numérico de viga e a uma ponte monitorada em João Pessoa no estado da Paraíba. Por fim, na tentativa de explorar a capacidade do SAE em situações mais próximas àquelas encontradas em sistemas SHM reais, propõe-se uma metodologia de detecção de alterações estruturais não-supervisionada. A ideia é caracterizar as respostas dinâmicas através de modelos SAE e, posteriormente, detectar o início do comportamento anormal por meio de cartas de controle  $T^2$  de *Hotelling*, calculada com os parâmetros extraídos pelo SAE. Além disso, apresenta-se aqui um critério automatizado para a definição dos modelos a serem aplicados em problemas SHM baseado na associação do erro de reconstrução dos dados dos modelos a um índice de generalização dos pontos  $T^2$  proposto. A maioria dos estudos que vêm sendo feitos na área classicamente definem como os modelos SAE mais adequados àqueles com menor erro de reconstrução dos sinais dinâmicos, o que não garante o bom desempenho quanto à detecção de alterações estruturais, conforme aqui constatado. A abordagem não-supervisionada é analisada e exemplificada em três casos: um pórtico

monitorado em laboratório; o caso clássico da ponte Z24; e uma torre instrumentada na Itália. Ressalta-se que para as duas últimas estruturas citadas, a influência da temperatura também foi avaliada. Em todos os casos estudados, seja na abordagem supervisionada ou na não-supervisionada, chegou-se a resultados satisfatórios, mesmo sob influência de variações de temperatura, deixando claro que o SAE se apresenta como uma ferramenta eficaz e robusta quando aplicada a problemas SHM.

Palavras-chave: Inteligência artificial. Detecção de danos. Monitoramento da saúde estrutural. Dinâmica das estruturas. Autocodificador esparso.

## ABSTRACT

The evolution of computational technologies has brought remarkable advances in Structural Health Monitoring (SHM) systems, making the development of more automated strategies for detecting anomalous structural behaviors, through the adequate characterization of dynamic responses, plays an important role in this field of research. In the last few years, artificial intelligence algorithms focused on deep learning have become increasingly popular as tools for detecting changes in structures. The concept of deep learning has its origins in the theory of neural networks and comprises several approaches mainly formulated to deal with non-linear and high-dimensional problems. Although the basic foundations of such algorithms were established in the 1960s, their use in SHM strategies is still relatively new. In this context, the present work evaluates the deep learning algorithm called Sparse AutoEncoder (SAE) when used as an extractor of parameters from dynamic data. More specifically, the ability of SAE models to provide sets of representative variables is studied to detect abnormal structural behaviors through dynamic signal processing directly in the time domain. Firstly, a sensitivity analysis is performed, aiming to verify the influence of the variables that define the functioning of the SAE exert on its ability to represent vibrational responses. Then, in order to investigate whether the parameters modeled by SAE allow different structural states to be distinguished, a supervised strategy that uses SAE as a feature selector and the Support Vector Machine (SVM) algorithm as a classifier is applied to a numerical beam model and a monitored bridge in João Pessoa, Brasil. Finally, in an attempt to explore the capacity of the SAE in situations closer to those found in actual SHM systems, an unsupervised methodology for detecting structural alterations is proposed. The fundamental idea is to characterize the structural dynamic responses via SAE models and, subsequently, to detect the onset of abnormal behavior through the well-known  $T^2$  Hotelling's control chart, calculated with SAE extracted features. An automated criterion for models' definition to be applied in SHM problems is also presented, based on the association of the model data reconstruction error and a proposed generalization index of the points  $T^2$ . Most studies that have been carried out in the area classically define the SAE models most suitable as those with the lowest reconstruction error of dynamic signals, which does not guarantee a good performance in terms of structural alteration detection, as found here. The unsupervised approach is analyzed and exemplified in three cases: a laboratory steel frame, the classic case of the Z24 bridge, and an instrumented tower in Italy. It is noteworthy that the influence of temperature was also evaluated for the last two mentioned structures. In all cases studied, whether, in the supervised or unsupervised approach, satisfactory results were achieved, even under the influence of temperature variations, making it clear that the SAE presents itself as an effective and robust tool when applied to SHM problems.

Key-words: Artificial intelligence. Damage detection. Structural health monitoring. Structural dynamic. Sparse autoencoder.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>12</b>
1.1	CONTEXTO E MOTIVAÇÃO . . . . .	12
1.2	OBJETIVOS E CONTRIBUIÇÕES DO PRESENTE TRABALHO . .	19
1.3	ORGANIZAÇÃO DO TEXTO . . . . .	20
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA - MÉTODOS DE DETECÇÃO DE DANO . . . . .</b>	<b>21</b>
<b>3</b>	<b>APRENDIZADO DE MÁQUINAS APLICADO AO PROBLEMA DE DETECÇÃO DE DANOS E ALTERAÇÕES ESTRUTURAIS . . . . .</b>	<b>31</b>
3.1	REDE NEURAL ARTIFICIAL . . . . .	32
3.2	AUTOCODIFICADOR ESPARSO . . . . .	36
3.3	MÁQUINA DE VETOR SUPORTE . . . . .	39
<b>4</b>	<b>ANÁLISE DE SENSIBILIDADE: AUTOCODIFICADOR ESPARSO APLICADO AOS SINAIS TÍPICAMENTE ESTRUTURAIS . . . . .</b>	<b>43</b>
4.1	FUNÇÕES DE ATIVAÇÃO . . . . .	46
4.2	HIPERPARÂMETROS $\rho$ , $\lambda$ e $\beta$ . . . . .	48
4.3	QUANTIDADE DE SINAIS PARA O TREINAMENTO . . . . .	51
4.4	NÚMERO DE NEURÔNIOS NA CAMADA INTERNA . . . . .	54
4.5	TAMANHO DOS SINAIS . . . . .	55
4.6	CONCLUSÕES DO CAPÍTULO . . . . .	55
<b>5</b>	<b>METODOLOGIA SHM SUPERVISIONADA . . . . .</b>	<b>58</b>
5.1	APLICAÇÃO I - MODELO NUMÉRICO DE VIGA BIPOIADA . . .	59
5.1.1	<b>Resultados</b> . . . . .	62
5.2	APLICAÇÃO II - VIADUTO VÁRZEA NOVA . . . . .	68
5.2.1	<b>Resultados</b> . . . . .	70
<b>6</b>	<b>METODOLOGIA SHM NÃO-SUPERVISIONADA . . . . .</b>	<b>75</b>
6.1	APLICAÇÃO I - PÓRTICO DE ALUMÍNIO CONSTRUÍDO EM LABORATÓRIO . . . . .	81
6.1.1	<b>Resultados</b> . . . . .	85
6.2	APLICAÇÃO II - PONTE Z24 . . . . .	100
6.2.1	<b>Resultados</b> . . . . .	103

6.3	APLICAÇÃO III - CAMPANÁRIO DA IGREJA <i>SAN VITTORE</i> . . .	125
6.3.1	<b>Resultados</b> . . . . .	127
7	<b>CONCLUSÕES</b> . . . . .	130
	<b>REFERÊNCIAS</b> . . . . .	135
	<b>ANEXO A</b> – Metodologia não-supervisionada de detecção de dano $SAE/T^2$ : Resultados complementares da ponte Z24 - 5 melhores modelos segundo o critério IG e $\tilde{\zeta}^{def}$ . . . . .	144
	<b>ANEXO B</b> – Metodologia não-supervisionada de detecção de dano $SAE/T^2$ : Resultados complementares da ponte Z24 - 5 melhores modelos segundo o critério menor $\tilde{\zeta}^{def}$ . . . . .	154
	<b>ANEXO C</b> – Metodologia não-supervisionada de detecção de dano $SAE/T^2$ : Resultados complementares da ponte Z24 - Erros de reconstrução dos sinais e hiperparâmetros associados às cartas de controle dos anexos A e B. . . . .	164

# 1 INTRODUÇÃO

## 1.1 CONTEXTO E MOTIVAÇÃO

O bom funcionamento dos sistemas estruturais e a segurança de seus usuários estão entre as principais preocupações dos engenheiros ao longo do ciclo de vida de qualquer construção civil. Erros na concepção do projeto, falhas durante a execução, efeitos ambientais e/ou operacionais (ventos, tráfego intenso, tempestades, terremotos) e, até mesmo, o próprio desgaste natural, são alguns dos fatores que contribuem para a deterioração das estruturas. Tais situações causam mudanças que, em muitos casos, podem estar associadas ao surgimento de danos, tornando a identificação de comportamentos estruturais “anormais” um tópico de grande importância para cientistas e profissionais da área.

O monitoramento da integridade estrutural - usualmente definido pela sigla em inglês SHM (“*Structural Health Monitoring*”) - engloba o conjunto de equipamentos e técnicas voltadas para a investigação e análise de alterações em estruturas. Utilizados como meios auxiliares na elaboração de planos de manutenção e na prevenção de danos e acidentes, sistemas SHM permitem a extração, o processamento e o acompanhamento de características relativas ao comportamento mecânico da estrutura com o objetivo de inferir sobre a sua confiabilidade. Aponta-se que a principal vantagem de se implementar um programa de monitoramento é a possibilidade de detecção e acompanhamento do dano desde o seu estágio inicial, evitando assim falhas catastróficas e custos adicionais com medidas corretivas extremas ou com ações preventivas desnecessárias. Embora o dano seja definido como uma alteração que comprometa de forma desfavorável o desempenho original de um sistema mecânico-estrutural - modificação do material, das propriedades geométricas e/ou das condições de apoio -, a sua ocorrência não é, necessariamente, capaz de causar grandes prejuízos. Na maioria das vezes, este fato só faz com que a estrutura não opere mais em condições ideais. No entanto, o aumento do dano leva a uma perda progressiva da funcionalidade do sistema, situação que pode atingir níveis críticos de segurança, provocando colapsos e falhas estruturais [1]. Desta forma, o diagnóstico eficaz de danos em estruturas tem sido tema relevante em pesquisas nas mais diversas aplicações de engenharia, como em usinas de energia, em plataformas de petróleo, na indústria aeroespacial, na indústria metalúrgica e mecânica, entre outras [2, 3, 4].

Em virtude da complexidade estrutural, da existência de elementos de acesso restrito ou de difícil manutenção, e de condições de operação praticamente ininterruptas, o uso de sistemas de monitoramento tem se tornado frequente, principalmente no gerenciamento de construções civis de grande porte, tais como viadutos, pontes, edifícios, etc. Em todo o mundo já existem diversas aplicações avançadas de monitoramento da integridade desse tipo de estrutura. Entre as mais conhecidas estão: a ponte Stonecutters, na China [5], o viaduto

de Millau, na França [6] e, o edifício Burj Khalifa, nos Emirados Árabes [7]. Entretanto, o emprego de sistemas de monitoramento sem a implementação de metodologias eficazes e contínuas de detecção de comportamentos estruturais “anormais” não é suficiente para evitar eventuais acidentes.

Um exemplo que teve grande repercussão mundial na época e chamou a atenção para a importância de se dispor de ferramentas de monitoramento estrutural foi o colapso de parte da ponte Morandi, em 2018, na cidade de Gênova – Itália. Conforme ilustrado na Figura 1(a), um trecho de cerca de 200m desabou sobre casas e indústrias da região, deixando prejuízo financeiro e vítimas fatais. Embora não houvesse um sistema SHM permanentemente instalado nesta ponte, ainda antes do incidente, foram obtidos, através de testes dinâmicos, indícios sobre possíveis falhas de alguns de seus elementos [8]. Mais recentemente, em meados de 2021, a queda de um viaduto metroviário na Cidade do México, mostrado na Figura 1(b), também voltou a expor a relevância de tal assunto. Uma viga cedeu no momento em que o trem passava e desabou sobre uma das principais vias arteriais da capital, sendo considerada um dos maiores desastres ocorridos na cidade desde o terremoto de 2017 [9]. Assim como no caso da ponte Morandi, danos e oscilações “anormais” já haviam sido detectados anteriormente. Apesar das advertências feitas pelos engenheiros que realizaram as inspeções de tais estruturas terem sido ignoradas pelas respectivas autoridades locais, ambos os casos demonstram claramente que o monitoramento dinâmico estrutural, mesmo não tendo um caráter contínuo, é capaz de emitir alertas de dano que podem evitar tragédias.

No Brasil, embora existam programas de investigação e manutenção, o uso de ferramentas SHM em aplicações práticas ainda é incipiente e a inspeção visual continua sendo um dos principais instrumentos de análise, pois poucas são as estruturas que possuem algum tipo de monitoramento frequente relacionado à sua integridade. A ponte Rio-Niterói, no Rio de Janeiro [12], a ponte Juscelino Kubitschek, em Brasília [13] e a ponte do Rio Jaguari (viaduto integrante da Rodovia Fernão Dias - BR 381) [14], na divisa entre os estados de São Paulo e Minas Gerais, mostradas na Figura 2, são algumas delas. Estudos indicam que muitas das construções de infraestrutura brasileiras estão chegando à sua idade crítica. Além do envelhecimento, a falta de recursos para restauração e manutenção apropriadas faz com que tais estruturas necessitem de acompanhamento e inspeções regulares. O caso do viaduto que cedeu cerca de 2m em São Paulo e a queda de parte de outro viaduto em Brasília, exibidos na Figura 3 - ambos ocorridos em 2018, em vias importantes das duas capitais -, são alguns dos exemplos atuais de incidentes relacionados à falha de componentes estruturais encontrados no país. Outros dois fatos emblemáticos foram os rompimentos da barragem de rejeitos de minério de ferro em Mariana e Brumadinho, em Minas Gerais (nos anos de 2016 e 2019, respectivamente), responsáveis pela morte de centenas de pessoas e completa destruição da fauna e flora da região.

Figura 1 – Exemplos de estruturas que colapsaram.

(a) Desabamento da Ponte Morandi na Itália.



Fonte: G1 [10].

(b) Queda de viaduto metroviário na Cidade do México.



Fonte: G1 [11].

Deste modo, fica evidente a importância de se validar e desenvolver sistemas de monitoramento associados a algum tipo de técnica de identificação de alterações em estruturas. Após uma extensa revisão da literatura atual, Avci *et al.* (2021) [20] afirma que o componente mais crítico de um programa SHM é a detecção de danos, definida como um processo sistemático e automático de identificação da existência de danos e, em seguida, a localização e avaliação de sua gravidade. Artigos recentes focados especificamente na detecção de danos reforçam esta afirmação [21, 22, 23, 24]. Tal ideia parece lógica uma vez que a localização e a quantificação da extensão do dano pressupõem a correta identificação

Figura 2 – Estruturas com monitoramento estrutural no Brasil.

(a) Ponte Rio-Niterói.



Fonte: Marinha do Brasil [15].

(b) Ponte Juscelino Kubitschek.



Fonte: Wikipedia [16].

(c) Ponte do Rio Jaguari.



Fonte: ANTT [17].

de sua ocorrência. Além disso, o uso de técnicas apropriadas para detectar eventuais alterações pode alertar o operador da estrutura para que ele possa providenciar vistorias *in loco* e, caso seja necessário, promover possíveis reparos ou até mesmo, em último caso, interromper o seu funcionamento.

É conhecido que o processo de degradação modifica as propriedades físicas da estrutura, como massa e rigidez, e que essas modificações influenciam o comportamento dinâmico estrutural. Por este motivo, entre as diferentes metodologias disponíveis para

Figura 3 – Acidentes relacionados à falha de componentes estruturais no Brasil.

(a) Viaduto que cedeu em São Paulo.



Fonte: G1 [18].

(b) Queda de parte de um viaduto em Brasília.



Fonte: Portal Mais Goiás [19].

identificar a ocorrência de anomalias estruturais, as baseadas em vibração têm sido amplamente investigadas [25, 26, 27, 28]. A partir de históricos temporais dinâmicos obtidos por meio de sistemas SHM, essas abordagens são aplicadas para investigar novidades em termos de comportamentos estruturais. Em resumo, características essenciais são extraídas dos dados medidos e comparadas sucessivamente para deduzir se ocorreu uma mudança estrutural. Em vista disso, diversas técnicas e estratégias para detecção de danos e de alterações foram estudadas nas últimas décadas, baseadas principalmente nas variações das características modais ou em indicadores construídos a partir desses parâmetros. Existem muitos artigos na literatura relatando a efetividade dessas técnicas, conforme será detalhado no próximo capítulo. Contudo, é difícil determinar a ocorrência do dano a partir apenas dos dados dinâmicos ao lidar com sinais advindos de um monitoramento de uma estrutura real. Neste tipo de análise as medidas de vibração são usualmente interpretadas em função de seus parâmetros modais, o que pode gerar incertezas com relação aos dados, já que o efeito de fatores ambientais, principalmente variações de temperatura, também pode alterar as características dinâmicas, impactando negativamente no diagnóstico de dano. Cabe destacar que em métodos de detecção baseados na análise modal são necessárias medições mais precisas ou altos níveis de degradação para que as alterações causadas por danos não se misturem com efeitos externos ou vice-versa (alarmes falsos). Apesar dos muitos procedimentos que visam reduzir a influência dos efeitos ambientais, ainda são necessários mais esforços para melhorar as ferramentas de avaliação de danos em aplicações práticas [29, 30, 31, 32, 33]. Portanto, muitas contribuições têm sido propostas por pesquisadores, incluindo diferentes técnicas de processamento de sinal para análise de dados dinâmicos [34].

Nos últimos anos, com a evolução da tecnologia computacional e de informação, notáveis avanços foram alcançados nos sistemas de aquisição de dados, tornando necessário o aprimoramento das ferramentas e técnicas de SHM para lidar com o grande volume de dados gerados [35]. Assim, o que antes era feito com um número reduzido de variáveis por

meio de análise modal, probabilidade e técnicas estatísticas agora pode ser identificado automaticamente com métodos de aprendizado de máquina, como as populares Redes Neurais Artificiais (RNAs), Máquinas de Vetor Suporte (SVMs, do inglês “*Support Vector Machine*”), Árvores de Decisão, algoritmos de agrupamento, (“*Clustering*”), entre outros. Os trabalhos de Salehi & Burgueno (2018) [36], Finotti *et al.* (2019) [37], Cardoso *et al.* (2019) [38], Nguyen *et al.* (2019) [39] e Umar *et al.* (2021) [40] são bons exemplos associados a este tipo de estratégia SHM. Nestas abordagens, características relevantes são extraídas das respostas dinâmicas por técnicas de processamento de sinais e são transferidas como parâmetros de entrada para algoritmos de inteligência computacional. Estes, por sua vez, tentam reconhecer padrões semelhantes entre os dados e atribuí-los a condições estruturais distintas ou estados de dano.

Fato é que os métodos de aprendizado de máquina vêm desempenhando um papel cada vez mais importante nas estratégias SHM. No entanto, a alta dimensionalidade das variáveis envolvidas em sistemas reais monitorados e a complexidade da estrutura em questão podem comprometer significativamente o desempenho dos algoritmos de detecção de danos. Existem algumas técnicas para reduzir a dimensão de grandes conjuntos de dados, como por exemplo Análise de Componentes Principais (PCA, do inglês “*Principal Component Analysis*”), Análise de Componentes Independentes (ICA, do inglês “*Independent Component Analysis*”), Incorporação Estocástica de Vizinhos de Distribuição  $t$  ( $t$ -SNE, do inglês “*t-Distributed Stochastic Neighbor Embedding*”), entre outras [41, 42, 43]. No entanto, segundo Anowar *et al.* (2021) [41], uma vez que o sucesso de tais técnicas depende principalmente da natureza e qualidade dos dados, a análise empírica ainda é essencial para determinar a mais adequada - o que pode ser demorado dentro de um contexto prático de SHM. Desta forma, desenvolver uma abordagem mais autônoma, precisa e robusta para identificar alterações estruturais continua sendo um desafio. Com isso em mente, muitas metodologias SHM vêm sendo propostas baseadas em aprendizado profundo (DL, do inglês “*Deep Learning*”), algoritmos conhecidos por sua alta capacidade de lidar com grandes conjuntos de dados, o que pode conferir uma maior autonomia e precisão aos métodos de monitoramento estrutural fundamentados em inteligência artificial. Os algoritmos DL buscam modelar de forma robusta informações representativas dos dados por meio de aproximações mais complexas de funções e de transformações lineares e não-lineares, normalmente utilizando múltiplas camadas de processamento. Muitos são os algoritmos DL possíveis para lidar com os sinais dinâmicos estruturais, tais como a Rede Neural Convolutiva (CNN, de *Convolutional Neural Network*), Rede Neural Recorrente (RNN, de *Recurrent Neural Network*), Rede de Memória de Longo Prazo (LSTM, de *Long Short Term Memory*), Autocodificador (AE, de *AutoEncoder*) e suas variantes [44], dentre elas, o Autocodificador Esparsa (SAE - “*Sparse AutoEncoder*”), visto como uma alternativa promissora pela comunidade SHM. Este último método tenta reduzir e aprender as características de maneira autossuficiente. De modo geral, o algoritmo SAE

pode ser interpretado como um tipo de RNA de aprendizado não-supervisionado, isto é, que não faz uso de observações previamente rotuladas. O objetivo do SAE é retornar, como saída da rede, a reprodução aproximada dos seus dados de entrada, através de uma codificação interna que transforma esse conjunto de variáveis de entrada - teoricamente de alta dimensão - em um “novo” grupo de variáveis (espaço de variáveis latentes), porém, de menor dimensão [45]. Devido à autonomia de aprendizado de seus modelos, as técnicas baseadas em SAE podem extrair atributos dos dados de forma mais robusta do que as técnicas tradicionais de processamento e se adaptar a diferentes tipos de problemas. Tais fatores facilitam o processamento automático de sinais dinâmicos, incentivando sua aplicação dentro de uma abordagem SHM.

Levando em consideração que os algoritmos SAE são ferramentas relativamente recentes na área SHM, estudos focados em avaliá-los para resolver problemas de detecção de danos ainda são bem-vindos, como poderá ser constatado no capítulo “Revisão Bibliográfica”, onde foi exposto um número significativo de trabalhos recentes que abordam esse tema. No entanto, em muitas das pesquisas, o SAE é aplicado somente a modelos de elementos finitos ou testes de laboratório, geralmente com o intuito de validar possíveis metodologias [46, 47, 48]. Neste contexto, o presente trabalho se debruça sobre uma avaliação mais abrangente do SAE quando utilizado como extrator de parâmetros de dados dinâmicos dentro de abordagens de detecção de danos supervisionadas e não-supervisionadas. Para tanto, inicialmente é realizada uma análise de sensibilidade, visando verificar a influência que as variáveis que definem o funcionamento do SAE exercem sobre a sua habilidade de representar as respostas vibracionais. Posteriormente, com o intuito de investigar se os parâmetros modelados pelo SAE permitem de fato distinguir os diferentes estados estruturais, diversos exemplos são analisados, entre os quais têm-se casos de modelos numéricos, de protótipos de laboratório e de monitoramento reais, sendo que, em alguns deles, a influência da variação de temperatura também é considerada. A ideia fundamental consiste em caracterizar as respostas dinâmicas estruturais diretamente no domínio do tempo por meio de modelos SAE e, em seguida, detectar o início de comportamentos anormais através do clássico algoritmo SVM, na abordagem supervisionada, e de cartas de controle  $T^2$  de *Hotelling* [49], na investigação da abordagem não-supervisionada, esta última proposta originalmente pela autora desta tese. A carta  $T^2$  de *Hotelling* é uma técnica estatística de controle de processos, de análise multivariada, baseada em estimativas amostrais da média e da matriz de covariância dos dados de um determinado problema. Tal ferramenta é frequentemente utilizada em estratégias SHM, normalmente aplicada aos resíduos entre as quantidades mensuradas e preditas (via análise de regressão) [50, 51, 52]. Devido à sua implementação relativamente simples, as cartas de controle são consideradas ferramentas adequadas dentro de programas de monitoramento. Ressalta-se que, neste trabalho, todos os algoritmos de aprendizado de máquina, assim como a estatística  $T^2$  e demais análises, foram desenvolvidos utilizando *toolboxes* e funções *built-in* disponíveis no

*MatlabR2017a.*

Uma vantagem das metodologias abordadas aqui é que os dados são processados diretamente no domínio do tempo, evitando a constante necessidade de estimativas de parâmetros modais. Além disso, conforme será exposto no decorrer deste texto, a influência de fatores externos (como temperatura) é implicitamente modelada pelo SAE. Diferentemente dos métodos de detecção baseados em características modais, as abordagens fundamentadas nos modelos autocodificadores se mostraram menos suscetíveis a incertezas e erros relacionados ao processamento de dados, uma vez que nenhum outro algoritmo é utilizado para eliminar os efeitos operacionais e ambientais. Tais fatores representam uma grande vantagem em termos de custo computacional e tempo de análise. Um outro aspecto interessante deste trabalho é o uso do SAE em uma metodologia de análise de dano não-supervisionada, visto que muitos métodos na literatura se baseiam no pré-estabelecimento de diferentes níveis de degradação, a chamada análise supervisionada. Diferentemente do que ocorre nos métodos supervisionados, a detecção de danos não-supervisionada não depende de respostas dinâmicas decorrentes de qualquer cenário de deterioração estrutural, situação recorrente em estruturas civis.

## 1.2 OBJETIVOS E CONTRIBUIÇÕES DO PRESENTE TRABALHO

Frente ao exposto, esta tese de doutorado tem por objetivo realizar uma abordagem detalhada sobre o SAE em problemas de SHM aplicados a estruturas civis, percorrendo etapas de estudos que vão desde a análise paramétrica das variáveis que definem o comportamento do SAE frente à sua capacidade de reproduzir sinais dinâmicos, passando por uma proposta de uso supervisionada, onde é testada sua aptidão para fornecer dados eficazes para a avaliação do estado de integridade de uma dada estrutura, chegando, finalmente, à proposição de uma estratégia não-supervisionada que se apresente como uma alternativa viável para sistemas SHM adotados em estruturas reais.

De uma forma mais detalhada, tem-se como principais contribuições deste trabalho:

- Avaliar se o SAE é capaz de reproduzir de forma consistente sinais tipicamente obtidos através de medições dinâmicas estruturais. Observa-se que esta resposta não é evidente, tendo em vista a escassez de trabalhos publicados sobre este tema específico. Adianta-se que o desempenho do SAE neste sentido é fortemente afetado pelos parâmetros que definem seu funcionamento.
- Apresentar uma abordagem supervisionada baseada no SAE e no algoritmo de classificação SVM para detecção de danos em estruturas. Embora esta análise seja de difícil aplicabilidade em sistemas instalados em estruturas civis, o uso desta estratégia em problemas advindos de situações mais controladas, como por exemplo aquelas que envolvem o uso de SHM para se avaliar o funcionamento de máquinas

de comportamento mecânico bem conhecido, poderia alcançar bons resultados. Entretanto estas últimas estruturas não são o foco do presente trabalho. Destaca-se que, apesar das dificuldades inerentes a sistemas supervisionados, esta etapa é fundamental para subsidiar o uso do SAE dentro do escopo de uma estratégia SHM não-supervisionada, objetivo final deste trabalho.

- Propor uma abordagem não-supervisionada de detecção de alterações estruturais baseada no SAE e em cartas de controle construídas através da métrica  $T^2$  de *Hotelling*. Esta estratégia é definida através de uma mescla entre o critério clássico para avaliação de desempenho do SAE - o erro de reconstrução - e um índice de generalização proposto e definido a partir dos valores do  $T^2$ . Observou-se que o uso apenas do erro de reconstrução leva sistematicamente a problemas de “*overfitting*”, prejudicando sensivelmente o desempenho do SAE em problemas SHM. Nos casos analisados, a estratégia proposta se mostrou eficaz.

### 1.3 ORGANIZAÇÃO DO TEXTO

O presente capítulo apresenta o tema abordado, sua importância e motivação. Além disso, apontam-se ainda os objetivos pretendidos nesta tese de doutorado.

Uma breve revisão dos métodos de detecção de danos e alterações estruturais é realizada no capítulo 2.

O terceiro capítulo versa sobre as teorias de Redes Neurais Artificiais, Redes Autocodificadoras Esparsas, Máquinas de Vetores Suporte, passando pelos fundamentos e conceitos utilizados na concepção dos algoritmos.

O capítulo 4 traz uma breve análise da influência de vários parâmetros do algoritmo Autocodificador Esparso quando aplicado a sinais tipicamente estruturais.

As metodologias SHM de detecção de danos supervisionada e não-supervisionada, bem como suas aplicações e resultados, são apresentadas nos capítulos 5 e 6, respectivamente.

Por fim, no sétimo e último capítulo, são expostas as conclusões e considerações relacionadas ao presente estudo, além de descrever os próximos passos e mencionar os trabalhos já publicados pela autora acerca do assunto.

## 2 REVISÃO BIBLIOGRÁFICA - MÉTODOS DE DETECÇÃO DE DANO

Não é de hoje que os métodos de identificação de dano são considerados ferramentas importantes quando o tema é monitoramento das estruturas, e diversos são os estudos encontrados na literatura clássica da área dedicados a esse problema. Deste modo, o presente capítulo busca abordar de forma concisa as principais estratégias e técnicas adotadas ao longo dos anos para a detecção de danos e alterações estruturais.

Tradicionalmente as técnicas de inspeção estrutural são divididas em destrutivas e não-destrutivas, a considerar se o método de monitoramento empregado danifica ou não a estrutura em questão. Por não causar prejuízos ao sistema estrutural, as técnicas não-destrutivas são as mais empregadas, podendo ser classificadas, em um primeiro momento, em dois grandes grupos: local e global. As técnicas locais, como o próprio nome sugere, realizam investigações pontuais ou em pequenas regiões da estrutura, enquanto que as técnicas globais analisam o comportamento estrutural como um todo. O primeiro grupo normalmente engloba as abordagens baseadas em ensaios com emissão de sinais em alta frequência, tais como os testes de emissão acústica, ondas ultrassônicas, raios-X, análise térmica, entre outras [53]. Apesar de serem bastante sensíveis à presença de mínimas fissuras, existem alguns fatores inerentes a esses métodos que em muitos casos tornam laboriosa a sua aplicação em sistemas estruturais reais, como por exemplo, a necessidade em saber previamente a localização do dano, a garantia de acesso dos técnicos à região para a execução do respectivo ensaio e/ou a interrupção do funcionamento da estrutura durante as inspeções. Em contrapartida, tem-se o grupo das técnicas globais, que se baseiam em sua grande maioria na relação entre a resposta vibratória do sistema e suas características mecânicas. Essas técnicas partem da premissa de que alterações no comportamento dinâmico estrutural, como variações nas frequências naturais, modos de vibração e taxas de amortecimento, podem estar associadas à presença de danos, uma vez que o processo de degradação causa mudanças nas propriedades físicas da estrutura (massa, rigidez e flexibilidade). Por se tratarem de estratégias que inferem sobre a condição estrutural a partir dos dados de vibração, normalmente não é necessário paralisar o funcionamento do sistema para se realizar as investigações. Além disso, a sua capacidade de análise global faz com que não seja obrigatória a avaliação de pontos próximos à região danificada. Dessa forma, as metodologias baseadas em indicadores construídos a partir das respostas dinâmicas estruturais são vistas pelos pesquisadores e engenheiros como sendo mais adequadas ao se idealizar um programa de monitoramento. Assim, durante as últimas décadas, diversos estudos foram conduzidos nesta linha e muitos foram os métodos de identificação de danos desenvolvidos com base nos sinais de vibração.

Em meados dos anos 70 surgiram os primeiros trabalhos realizados em vista dessa abordagem, fundamentados principalmente na variação direta das propriedades modais. Por serem características sensíveis à integridade de uma estrutura, o uso das variações

nas frequências de vibração sempre foi bastante atrativo no problema de identificação de alterações estruturais, fato que parece ser intuitivo, já que o dano conduz à perda de rigidez. Além disso, é um parâmetro relativamente fácil de se aferir e que pode ser obtido através de apenas alguns pontos estrategicamente selecionados e monitorados. Cawley & Adams (1979) [54] foram um dos precursores na avaliação da integridade de estruturas utilizando a variação das frequências naturais como indicador de dano. Os autores tentaram localizar os defeitos estruturais a partir da comparação entre as frequências de um modelo construído via Método dos Elementos Finitos (MEF) e as frequências extraídas de uma análise dinâmica real, considerando o surgimento de dano em posições preestabelecidas de pequenas placas. Na pesquisa de Kato & Shimada (1986) [55], a sensibilidade das frequências naturais de uma ponte de concreto protendido foi avaliada quando submetida a diferentes estágios de carregamento estático. Tal estudo constatou a tendência de redução das frequências na presença de danos que, naquele caso, foram determinados pelo aumento progressivo da carga. O trabalho de Mazurek & DeWolf (1990) [56] investigou a influência da degradação estrutural e de possíveis fatores operacionais nas frequências naturais de um protótipo simplificado de ponte rodoviária construída em laboratório. Diversas análises foram feitas simulando o surgimento de danos e de diferentes níveis de rugosidade da pista, de velocidade e de massa dos veículos. Os resultados obtidos a partir de ensaios experimentais mostraram que estágios avançados de deterioração, assim como variações nas massas dos veículos, causavam mudanças significativas nas frequências, enquanto que a rugosidade e a velocidade não interferiam nesses valores. Messina *et al.* (1998) [57] desenvolveram uma técnica capaz de detectar, localizar e quantificar danos baseada em um coeficiente de correlação chamado MDLAC (do inglês “*Multiple Damage Location Assurance Criterion*”). Assumindo mudanças apenas na rigidez da estrutura, este coeficiente utiliza a variação de algumas das frequências naturais para obter uma correlação estatística entre as previsões analíticas de suas alterações e os valores realmente medidos para os diferentes estados estruturais (danificados e não danificados). A abordagem apresentada pelos autores foi validada numericamente em dois modelos de treliça (MEF) e em uma estrutura de laboratório composta por pequenas barras de alumínio. Peeters *et al.* (2001) [58] estudaram a influência da variação térmica sobre o comportamento dinâmico da ponte Z24, na Suíça, e seus respectivos efeitos no processo de identificação de danos. Após constatar tal influência, os pesquisadores propuseram o uso de modelos de regressão linear multivariada para descrever a relação existente entre as alterações nas frequências naturais dos quatro primeiros modos e a temperatura da estrutura. Esses modelos, relativos à estrutura sã, eram posteriormente utilizados para analisar e comparar as frequências obtidas em diferentes cenários de dano.

Encontra-se também na literatura trabalhos focados no desenvolvimento de técnicas baseadas nas mudanças dos modos de vibração. Um método clássico é o uso do índice MAC (do inglês “*Modal Assurance Criterion*”), proposto por Allemang & Brown (1982)

[59], para calcular a similaridade entre formas modais. O coeficiente MAC é definido como uma constante escalar que varia entre 0 e 1, onde 0 representa a inexistência de correlação linear entre os modos e 1 uma correlação perfeita. Um outro índice derivado do MAC, denominado COMAC (do inglês “*Coordinate Modal Assurance Criterion*”) foi apresentado por Lieven & Ewins (1988) [60]. O COMAC mede a correlação linear entre os modos para cada grau de liberdade, o que facilita na identificação do local onde ocorreu o dano, uma vez que as formas modais são comparadas de maneira pontual. Assim como o MAC, o COMAC possui valores que variam de 0 a 1, sendo que COMAC com valor igual a 1 significa uma correlação perfeita entre amplitudes daquela coordenada. Wolff & Richardson (1989) [61] examinaram a sensibilidade dos modos de vibração a mudanças causadas por defeitos estruturais aplicando o coeficiente MAC como indicador de danos. Casos de alterações estruturais foram simulados experimentalmente em laboratório considerando uma placa de alumínio parafusada à uma viga ao longo de sua linha central. A estrutura foi testada com todos os parafusos devidamente apertados e, logo em seguida, com alguns parafusos removidos. Por fim, algumas das mudanças ocorridas entre os modos de vibração para as diferentes configurações de dano puderam ser observadas nos valores do MAC. Testes conduzidos por Alampalli (2000) [62] demonstraram a utilidade dos índices MAC e COMAC no monitoramento da integridade estrutural. O artigo descreve as análises realizadas em um protótipo de ponte e em uma ponte rodoviária desativada. Ambas as pontes foram ensaiadas antes e depois da introdução artificial de danos. Os resultados indicaram que os modos de vibração em conjunto com as frequências naturais poderiam ser usados de forma favorável na identificação de danos e alterações, e que tais parâmetros eram afetados significativamente pelas diversas condições de operação das estruturas.

Além dos métodos citados anteriormente, pode-se destacar ainda outras abordagens que usam a variação de características provenientes dos parâmetros modais. Valendo-se de modelos analíticos de viga, Pandey *et al.* (1991) [63] apresentaram um novo indicador baseado na variação da curvatura dos modos naturais para detectar e localizar danos. O método, que consiste na associação da mudança na rigidez de flexão à mudança na curvatura, demonstrou ser útil na identificação de estados estruturais saudáveis e danificados. Alguns anos depois, Stubbs *et al.* (1995) [64] desenvolveram uma estratégia de detecção utilizando a variação da energia de deformação modal antes e depois da ocorrência de danos. Resultados satisfatórios foram obtidos aplicando-se a técnica a dados de um modelo numérico de viga e de uma ponte real. Outro método muito empregado é a análise de alterações da matriz de flexibilidade, proposto por Pandey & Biswas (1994) [65]. Basicamente, os autores buscaram associar a presença de danos à redução de rigidez e ao aumento da flexibilidade. Para os casos de viga estudados, tal metodologia revelou ser eficaz não apenas na identificação do dano, mas também em sua localização. Ndambi *et al.* (2002) [66] avaliaram o desempenho de diversos desses métodos através de ensaios experimentais conduzidos em vigas de concreto armado, construídas em laboratório e

submetidas a um processo progressivo de fissuração. De uma maneira geral, todas as abordagens consideradas (variação direta das frequências naturais, índices MAC e COMAC, mudanças na matriz de flexibilidade e alterações na energia de deformação) foram capazes de detectar os danos impostos às estruturas. Entretanto, os métodos baseados na evolução das frequências e no acompanhamento da energia de deformação mostraram ser os mais precisos em refletir a gravidade da deterioração estrutural e em indicar a sua localização. Alvandi & Crémona (2006) [67] também elaboraram um estudo comparativo no qual os principais métodos baseados em indicadores derivados dos parâmetros modais foram analisados com a ajuda de um modelo numérico de viga biapoiada. Neste caso, as mudanças nas curvaturas dos modos e as variações dos valores de flexibilidade permitiram quantificar os diferentes níveis de degradação, o que não foi possível com o método da energia de deformação. Todavia, assim como em Ndambi *et al.* (2002) [66], o uso da variação da energia de deformação dos modos foi apontada como a melhor estratégia para se localizar os danos simulados. Mais recentemente, Shih *et al.* (2009) [68] e Cury *et al.* (2011) [69] relataram a eficácia de métodos baseados na aplicação conjunta de parâmetros advindos das características modais. Shih *et al.* (2009) [68] apresentaram um método misto que utiliza como base as mudanças na matriz de flexibilidade e na energia de deformação para avaliação da saúde estrutural de vigas e placas criadas computacionalmente, enquanto que Cury *et al.* (2011) [69] desenvolveram uma estratégia híbrida utilizando a variação da energia de deformação e das frequências naturais para detectar e localizar danos. Neste último trabalho, os autores validaram a técnica através de testes experimentais e simulações numéricas realizados em uma viga com vários cenários de dano. No que refere ao uso das taxas de amortecimento para a identificação de alterações e danos estruturais, não existem muitos estudos que estimulem a sua aplicação. No entanto, os resultados dos trabalhos de Modena *et al.* (1999) [70] e Kawiecki (2001) [71] e Curadelli *et al.* (2008) [72] sugerem essas taxas como parâmetros úteis.

Embora seja possível detectar danos diretamente a partir de desvios nas frequências e modos, esse tipo de técnica possui limitações práticas relevantes, uma vez que requer medições mais precisas ou níveis elevados de degradação para que as mudanças provocadas pelos danos não sejam confundidas com efeitos ambientais/operacionais ou vice-versa (falsos alarmes) [73, 74]. Assim sendo, muitas contribuições foram propostas incluindo diversas outras técnicas de processamento de sinais para análise dos dados dinâmicos. Hou *et al.* (2000) [75] utilizaram transformadas Wavelet para identificar comportamentos estruturais anômalos em um sistema massa-mola-amortecedor, modelado numericamente simulando diversos níveis de dano, e em um edifício real, durante a ocorrência de um terremoto. Os resultados alcançados pelos autores sinalizaram como promissoras as técnicas de detecção desenvolvidas com base na teoria Wavelet. Ainda no mesmo ano, Vanik *et al.* (2000) [76] discutiram uma metodologia SHM baseada em inferência bayesiana que usa os parâmetros modais para definir um modelo probabilístico de danos continuamente atualizado. O

método foi validado em uma simulação de monitoramento *on-line*, mostrando ser uma boa ferramenta para lidar com esse tipo de problema. Uma outra abordagem possível é a que envolve a análise de séries temporais, onde as respostas estruturais são caracterizadas por modelos estatísticos autoregressivos (AR), conforme tratado em Nair *et al.* (2006) [77]. Neste trabalho, testes numéricos e experimentais são conduzidos em um pórtico tridimensional de aço com o intuito de classificar os sinais em situações danificadas e não danificadas do sistema através de mudanças nos componentes de seu modelo autoregressivo de média móvel (ARMA - “*AutoRegressive Moving Average*”). Um teste de hipótese é utilizado para a tomada de decisão a respeito da existência ou não de dano. Os resultados obtidos indicam a capacidade da técnica em detectar e localizar os padrões de dano da referida estrutura. No estudo de Esfandiari *et al.* (2010) [78] é apresentado um método de identificação de dano baseado na atualização de um modelo de elementos finitos da estrutura utilizando os dados decompostos da Função de Resposta em Frequência (FRF) para avaliar alterações de massa e rigidez. A aplicação em um modelo de estrutura treliçada aponta o método como uma alternativa às técnicas convencionais de atualização de modelos de elementos finitos para identificar e detectar alterações estruturais.

Contudo, grande parte das pesquisas dedicadas ao assunto se concentrava, até então, apenas em modelos numéricos/analíticos ou em estruturas simplificadas de laboratório. A aplicação das técnicas de detecção em um sistema de monitoramento real normalmente gera um enorme conjunto de dados, fator que dificulta o processamento das informações. Neste contexto, e diante do avanço das plataformas computacionais, estratégias baseadas no aprendizado de máquinas e no reconhecimento de padrões começaram a ser mais amplamente utilizadas na identificação de danos estruturais. Em tais abordagens, características são extraídas das respostas dinâmicas por meio de técnicas de processamento de sinais (análise modal, estatística, etc) e repassadas, como parâmetros de entrada, aos algoritmos de inteligência computacional (IC). Estes, por sua vez, tentam “aprender” a reconhecer padrões similares entre os dados e atribuí-los a um estado de dano distinto, automatizando o processo de SHM. Existem muitos estudos relatando a efetividade e utilidade dessas estratégias na avaliação da integridade de estruturas. Marwala (2000) [79] implementou um comitê<sup>1</sup> de RNAs para identificar danos estruturais em uma casca cilíndrica a partir de modelos de classificação que tinham como dados de entrada características obtidas por FRFs, propriedades modais (frequências e modos) e transformada Wavelet. Os resultados alcançados no artigo provaram a eficácia do método, principalmente quando utilizado em dados experimentais. Já a pesquisa de Worden & Lane (2001) [80] teve como foco a utilização de SVMs para o diagnóstico de danos em estruturas através de mudanças nos espectros de frequência. Testes conduzidos com dados de um modelo numérico de treliça mostraram

---

<sup>1</sup> Conjunto de máquinas de aprendizado que combina o resultado obtido separadamente por cada uma das técnicas ou modelos de inteligência computacional para produzir a saída final de determinado problema.

o SVM como um algoritmo promissor para esse tipo de problema. Ni *et al.* (2005) [81] obtiveram sucesso ao aplicar a técnica SVM na elaboração de modelos de regressão para mapear a influência da temperatura sobre as frequências naturais da Ponte Ting Kau, em Hong Kong, submetida a um sistema de monitoramento estrutural contínuo. Um estudo realizado por Wen *et al.* (2007) [82] apresentou uma estratégia para detecção desenvolvida a partir da teoria de lógica nebulosa (*Fuzzy*) e RNA, na qual um bom desempenho de classificação foi verificado para uma estrutura numérica. Cury *et al.* (2010) [83] fizeram o uso de algoritmos de agrupamento em conjunto com a técnica estatística de Análise dos Dados Simbólicos (ADS) para identificar alterações no comportamento estrutural de um viaduto ferroviário francês submetido a um procedimento de reforço. A estratégia empregada se mostrou útil na compressão, representação e classificação dos sinais. Em uma pesquisa similar, Cury & Crémona (2012) [84] compararam o desempenho de três métodos de IC utilizando ADS para extrair informações dos dados vibracionais da mesma ponte. Os resultados obtidos por Árvores de Decisão Bayesiana, RNA e SVM mostraram a eficiência da abordagem na discriminação das modificações estruturais. Em ambas as análises (Cury *et al.* (2010) [83] e Cury & Crémona (2012) [84]) foram considerados tanto os sinais no domínio do tempo, quanto os parâmetros modais. Além das abordagens até aqui citadas, pode-se destacar também aquelas que lançam mão de algoritmos de otimização do ramo da computação evolucionista, como por exemplo, a estratégia apresentada por Meruane & Hey (2011) [85], que utilizaram Algoritmo Genético (AG) e dados modais para detectar danos em uma estrutura treliçada, ou a técnica empregada em Shirazi *et al.* (2014) [86], onde adotou-se o Método de Enxame de Partículas e algumas frequências para detectar avarias em um sistema estrutural tridimensional.

Ainda que grandes progressos tenham sido alcançados ao incorporar os algoritmos tradicionais de reconhecimento de padrões nos sistemas SHM, alguns fatores intrínsecos ao problema podem comprometer significativamente a capacidade de generalização dos modelos de detecção de dano, especialmente ao lidar com estruturas reais. Entre esses fatores, destacam-se dois diretamente interligados: a complexidade das estruturas em questão e a alta dimensionalidade das variáveis envolvidas. No contexto do presente trabalho, entende-se por estruturas complexas aquelas compostas por diversos tipos elementos (barras, placas, cabos, etc), geralmente de grande porte, como por exemplo pontes, túneis, torres, entre outras. Frente a isso, é essencial um monitoramento eficiente a nível global da estrutura para que o seu comportamento seja bem caracterizado. Em meio a tal situação, surge a necessidade de sistemas SHM com maior número de sensores, o que conseqüentemente gera um maior volume de dados e variáveis a serem processadas (alta dimensionalidade). Teoricamente, os algoritmos de aprendizado de máquina podem alcançar melhores resultados ao utilizar dados com altas dimensões, uma vez que mais informações são armazenadas. Entretanto, é possível que um aumento na dimensionalidade resulte na esparsidade dos dados dentro do espaço no qual o modelo é válido, o que exige um

aumento exponencial na quantidade de dados e também no tempo de execução (memória computacional). Este fato é conhecido como maldição da dimensionalidade. Em outras palavras, se refere ao problema de ajuste do modelos computacionais e a relação número de dados *versus* dimensão das variáveis, que pode levar a produção de padrões enganosos devido a grande quantidade de dados [87].

Na tentativa de contornar tal obstáculo, técnicas que visam reduzir as dimensões das variáveis preservando informações fundamentais do conjunto de dados são comumente empregadas [41]. Uma das mais populares é a Análise de Componentes Principais (PCA, do inglês “*Principal Component Analysis*”). Basicamente, a PCA projeta os dados originais em um outro subespaço, onde “novas” características são determinadas pelas direções de máxima variação dos dados (componentes principais). Uma investigação experimental conduzida por Ni *et al.* (2006) [88] avaliou a PCA quando aplicada à FRFs para redução de dimensionalidade e eliminação de ruído em um problema de identificação de danos sísmicos em um protótipo de edifício. Os resultados das classificações, realizadas por modelos RNA, mostraram que a identificação de dano com base em apenas alguns componentes principais obteve melhor desempenho do que quando utilizado diretamente os dados FRF medidos. No trabalho de Santos *et al.* (2015) [89], uma estratégia baseada em PCA, ADS e “*Clustering*” foi proposta para detectar danos, ainda em estágio inicial, nos cabos de sustentação de um modelo numérico de ponte estaiada (calibrado com dados experimentais da estrutura real). Os autores relataram que a PCA foi eficaz em distinguir os efeitos relacionados ao ambiente daqueles gerados pelos danos e que, com isso, a estratégia estudada por eles chegou a detectar redução de rigidez de 1%. Uma outra técnica possível para reduzir a dimensão das variáveis é a de Análise de Componentes Independentes (ICA, do inglês “*Independent Component Analysis*”). Na ICA, os componentes são definidos pelas direções de máximo grau de independência entre as variáveis. Diferentemente da PCA, que busca componentes não correlacionados através de uma transformação linear de base ortonormal, a ICA procura uma transformação linear na qual os vetores de base são estatisticamente independentes e não gaussianos, sem restrição de ortogonalidade. Assim, Zang *et al.* (2004) [90] propuseram o uso de RNA para avaliar danos em conjunto com ICA. A estratégia dos autores demonstrou boa precisão na classificação de estados estruturais danificados e não danificados de um modelo numérico de treliça e de um pórtico experimental. No estudo de Song *et al.* (2006) [91], optou-se por utilizar os componentes independentes de sinais temporais como entrada de um classificador SVM. Os resultados dos testes - realizados com dados medidos experimentalmente em um pórtico de 4 andares - mostraram que a abordagem sugerida atingiu altas taxas de detecção de dano. O PCA e o ICA, contudo, são limitados a projeções lineares e, portanto, grande parte das vezes não funcionam bem quando aplicados a dados não lineares (caso de muitos problemas estruturais reais). Levando isto em consideração, métodos não lineares de redução de dimensionalidade também foram investigados em estudos subsequentes. Santos *et al.*

(2016) [92] empregaram uma abordagem baseada na técnica Kernel PCA (KPCA), uma extensão não linear da PCA, para detectar mudanças estruturais em um pórtico construído em laboratório. O algoritmo KPCA recorre ao “truque de kernel” para projetar os dados em um espaço dimensional superior antes serem analisados linearmente por uma PCA tradicional. A técnica, confrontada com alguns outros algoritmos baseados em kernel, se mostrou uma ferramenta confiável no desenvolvimento de indicadores de danos. A pesquisa de Jeong *et al.* (2014) [93], por sua vez, comparou o desempenho das técnicas PCA e Isomap na classificação e localização de danos em um modelo numérico de viga através de alterações nas frequências modais. Pertencente também ao grupo de técnicas não lineares, o Mapeamento Isométrico ou Isomap (abreviação do termo em inglês “*Isometric Mapping*”) tenta encontrar uma representação mais compacta dos dados preservando as distâncias mais curtas entre eles (distância geodésica <sup>2</sup>), de forma a evitar a distorção da geometria original dos problema antes de projetá-lo em um espaço de dimensão inferior. Para a estrutura analisada em Jeong *et al.* (2014) [93], o algoritmo Isomap foi capaz de alcançar bons resultados de detecção, fornecendo taxas de classificação superiores àquelas obtidas com o PCA, como esperado. Ainda entre as técnicas não lineares de redução de variáveis, pode-se mencionar também a t-SNE. Em linhas gerais, o objetivo desta técnica é converter para um espaço bi ou tridimensional cada ponto do conjunto de variáveis com a ajuda de modelos de distribuição de probabilidade, construídos para melhor evidenciar a similaridade entre os dados no espaço de baixa dimensão. Uma abordagem de detecção de dano baseada em frequência, unindo as técnicas PCA e t-SNE para a transformação e redução de parâmetros, foi proposta por Agis & Pozo (2019) [43]. A abordagem dos autores, avaliada por meio de dados experimentais de uma placa de alumínio, atingiu altas taxas de classificação, indicando que a combinação de PCA e t-SNE melhorou a qualidade dos “*clusters*” e, portanto, facilitou a identificação dos diferentes estados estruturais.

Apesar do bom desempenho alcançado pelas técnicas de redução de características, nenhuma se destaca como sendo superior às demais. Tanto é que, conforme afirmado por Anowar *et al.* (2021) [41], a análise empírica ainda é considerada fundamental para a determinação da técnica mais apropriada, a depender principalmente da natureza e qualidade dos dados em questão. A partir disso, muitas metodologias SHM vêm sendo desenvolvidas, com sucesso, baseadas no aprendizado de máquinas profundo - o famoso “*Deep Learning*” (DL). O aprendizado profundo se refere mais especificamente a uma série de redes neurais com mais de três camadas de processamento. Os algoritmos DL são conhecidos pela sua habilidade em lidar com grandes conjuntos de dados e representá-los em alto nível de abstração, isto é, decifrar as relações complexas existentes nos dados através da associação de soluções mais simples do problema (processado por partes, através das múltiplas camadas). Além de sofrerem menos com os efeitos adversos da

---

<sup>2</sup> O termo vem da teoria dos grafos e refere-se ao comprimento do menor caminho entre dois nós de um grafo.

alta dimensionalidade, estes métodos têm a vantagem de se adaptar a diferentes tipos de problemas. Devido à autonomia de aprendizados dos seus modelos, com um treinamento adequado, as redes DL não só aprendem a correlacionar os dados à saída desejada, como são também capazes de executar todo o processo de extração de parâmetros, de forma mais robusta que as técnicas tradicionais de caracterização das respostas estruturais, sem a necessidade de processamento prévios. Tais fatores incentivam a sua aplicação em um sistema de monitoramento estrutural, uma vez que facilitam o processamento automático dos sinais dinâmicos.

Dentre todos os algoritmos DL possíveis, a Rede Neural Convolutiva (CNN, do inglês “*Convolutional Neural Network*” e o Autocodificador Esparsa, o SAE, são até agora, as ferramentas mais utilizadas em métodos de detecção de alterações estruturais baseados em vibração [20]. Em linhas gerais, pode-se dizer que uma CNN é um tipo de rede neural de aprendizado supervisionado que utiliza operações de convolução e agrupamento para sintetizar e extrair informações dos dados a ela apresentados, para uma posterior identificação de padrões, como a classificação de danos por exemplo. Desta forma, Abdeljaber *et al.* (2017) [94] analisaram o uso de Redes Neurais Convolutivas, unidimensional e adaptativa (1D-CNN), na extração e classificação das características de sinais brutos (acelerações) de um protótipo de arquibancada para detectar danos associados ao afrouxamento de parafusos. Mais recentemente, Teng *et al.* (2020) [95] avaliaram uma estratégia de detecção baseada no algoritmo CNN e na combinação de dados de simulações numéricas e medidas experimentais de uma treliça de aço. A abordagem apresentada pelos autores atingiu altas taxas de classificação. Assim como nos dois estudos anteriores, Chen *et al.* (2021) [96] também obtiveram êxito ao aplicar o CNN na identificação de alterações estruturais. Neste artigo, os pesquisadores utilizaram uma rede convolutiva em conjunto com a transformada wavelet contínua para extrair características de sinais no domínio do tempo e distinguir diferentes condições de dano em dois protótipos de laboratório (pórticos de aço). Resultados interessantes também foram alcançados ao utilizar as redes autocodificadoras. Pathirage *et al.* (2019) [47] estudaram no diagnóstico da presença de danos a partir de parâmetros modais das estruturas. Estudos numéricos e experimentais foram realizados considerando as incertezas na modelagem de elementos finitos de um pórtico de aço e os efeitos dos ruídos nos sinais medidos em um protótipo de ponte de concreto protendido, respectivamente. No trabalho de Wang & Cha (2021) [48], um método baseado em Auto-Codificador e Máquina de Vetor Suporte de Uma Classe (OC-SVM, do inglês “*One-Class Support Vector Machine*”) para descobrir alterações estruturais, diretamente das medidas de aceleração, foi proposto. O desempenho do método foi avaliado em um modelo numérico de prédio de 12 andares e em uma ponte de aço de escala reduzida construída em laboratório. Em uma situação mais real e de monitoramento contínuo, Bao *et al.* (2019) [97] investigaram uma estratégia de detecção na qual dados de aceleração uma ponte estaiada são transformadas em vetores de imagem, e depois, são

analisadas por um Auto-Codificador e classificadas por uma RNA. Silva *et al.* (2021) [98], por sua vez, adotaram parâmetros modais como atributos de entrada do Auto-Codificador para distinguir diferentes cenários estruturais em um viaduto rodoviário. Metodologias SHM com outras duas variações do algoritmo Auto-Codificador são abordadas em Ma *et al.* (2020) [99] e Shang *et al.* (2021) [100]. Ambos os trabalhos focaram na extração de características dos sinais no domínio do tempo. Entretanto, Ma *et al.* (2020) [99] apresentaram um método de detecção de danos fundamentado em um Auto-Codificador Variacional (VAE, do inglês “*Variational Auto-Encoder*”), enquanto que Shang *et al.* (2021) [100] apostaram na teoria do Auto-Codificador Convolutivo com eliminação de ruído (DCDAE, do inglês “*Deep Convolutional Denoising Auto-Encoder*”). A primeira estratégia foi avaliada para o caso de uma ponte submetida a veículos em movimento (simulação numérica e experimento de laboratório), e a segunda considerando uma estrutura de viga (simulação numérica e experimento de laboratório).

Face aos resultados promissores de ambas as técnicas (CNN e SAE), alguns deles supracitados e que ratificam suas posições como grandes protagonistas dentre métodos DL aplicados à detecção de alterações estruturais baseados em vibrações, e às restrições relativas ao prazo regulamentar para o desenvolvimento e conclusão deste trabalho de doutorado, optou-se por adotar apenas o SAE como foco de pesquisas. Reforça-se que sobre esta escolha não pesa qualquer juízo de valores acerca de comparações entre estas duas técnicas, ressaltando-se a importância de se fazer um estudo sobre CNN similar ao ora apresentado, algo que, desde já, a autora sugere como trabalho futuro. Desta forma, visando contribuir para melhoria dos sistemas de monitoramento da integridade de estruturas fundamentados em técnicas baseadas em sinais, a presente tese de doutorado estuda o SAE como ferramenta de extração de parâmetros de dados dinâmicos dentro de abordagens de detecção de dados supervisionada e não-supervisionada, a partir exclusivamente de sinais expressos diretamente no domínio do tempo. A detecção das alterações estruturais em si é realizada pelo algoritmo SVM (na abordagem supervisionada) e por gráficos de controle  $T^2$  de Hotelling (na abordagem não supervisionada), este escolhido por ser frequentemente utilizado em estratégias SHM e aquele por ter apresentado bons resultados em trabalhos anteriores da autora [101]. A teoria e os conceitos dos métodos de aprendizado de máquina empregados são apresentados no capítulo a seguir.

### 3 APRENDIZADO DE MÁQUINAS APLICADO AO PROBLEMA DE DETECÇÃO DE DANOS E ALTERAÇÕES ESTRUTURAIS

Conforme exposto anteriormente, várias são as abordagens possíveis quando o assunto é identificação de danos e alterações estruturais. Devido à sua poderosa habilidade de processamento dos dados, nas últimas décadas, os algoritmos de aprendizado de máquinas vêm ganhando espaço e importância no desenvolvimento e aperfeiçoamento de técnicas de monitoramento da integridade e desempenho de sistemas estruturais, seja na caracterização ou na interpretação dos sinais de vibração.

Em sistemas de monitoramento estrutural baseado em vibrações, a caracterização das respostas dinâmicas desempenha papel fundamental nas estratégias de detecção de danos. Em função de os métodos de classificação aprenderem através da correta interpretação do conjunto de dados, a determinação das variáveis de entrada do modelo de detecção é de fato muito importante. No entanto, a complexidade e a origem dos sinais dinâmicos, que em muitos casos, é ruidosa e influenciada pelos efeitos dos fenômenos ambientais e/ou das ações operacionais sofridos pela estrutura, tornam esta etapa a mais desafiadora do processo de identificação de danos. Posto isto, o uso de ferramentas de processamento capazes de extrair características suficientes e representativas dos dados de vibração é crucial para que as diferentes condições da estrutura sejam reconhecidas e classificadas com sucesso.

O processamento das respostas dinâmicas pode ser realizado por meio de métricas ou parâmetros extraídos dos sinais no domínio do tempo ou em qualquer outro domínio transformado. Uma das maneiras mais clássicas e conhecidas de se caracterizar um sinal advindo de monitoramento estrutural é através da identificação modal, onde frequências naturais, modos de vibração e taxas de amortecimento são extraídas dos dados vibracionais. Conforme já destacado no capítulo 2, durante muito tempo acreditou-se que avaliação e acompanhamento da evolução dos parâmetros modais seria suficiente para que o grau de deterioração estrutural fosse determinado. Todavia, dada a influência de diversos fatores extrínsecos sobre o comportamento modal, essas expectativas não se confirmaram para estruturas reais. Desta forma, atualmente buscam-se ainda alternativas eficientes e robustas para a caracterização dos dados vibracionais.

Como já enfatizado, o presente trabalho concentra-se na avaliação do Autocodificador Esparsos como ferramenta de caracterização dos sinais dinâmicos dentro de estratégias de detecção de danos em estruturas. O SAE é aqui utilizado para determinar/extrair parâmetros diretamente dos históricos das acelerações estruturais. Uma vez estabelecidas as características representativas dos sinais, é preciso mapeá-las e separá-las de acordo com a ocorrência ou não de danos e alterações. Reitera-se que, neste estudo, o diagnóstico de dano na abordagem supervisionada é feito através de classificadores SVM. Os princípios de ambas as técnicas de aprendizado de máquina (SAE e SVM), necessários para a

compreensão das abordagens SHM propostas nos capítulos subsequentes, serão discutidas nas próximas seções. Tendo em vista que o SAE se trata de um algoritmo derivado da teoria de Redes Neurais, os conceitos e fundamentos deste último método serão abordados na parte inicial deste capítulo.

### 3.1 REDE NEURAL ARTIFICIAL

Rede Neural Artificial é uma consagrada técnica computacional de aprendizado adaptativo, muito utilizada na concepção de modelos para a solução de diversos tipos de problemas, como os de reconhecimento de padrões, os de aproximação de funções, os de previsão de séries temporais, entre outros. Visando explicitar os conceitos deste algoritmo de inteligência artificial, essenciais no contexto do presente trabalho, apresenta-se um resumo teórico sobre RNA focado num cenário de classificação de dados em problemas de SHM.

Segundo Principe *et al.* (2000) [102], a classificação realizada por uma RNA é de natureza estatística, onde as classes são representadas por pontos em um espaço de decisão multidimensional dividido em regiões que estão associadas a cada tipo de saída. Os limites de decisão são estimados pelo processo de treinamento e suas construções são feitas pela variabilidade estatística existente entre as classes, através de um esquema de otimização baseado na avaliação do erro de saída da rede, conforme será descrito mais adiante. Um dos tipos de RNA mais empregados é o “*perceptron*” de múltiplas camadas (MLP - “*Multilayer Perceptron*”), uma rede neural “*feedforward*”<sup>2</sup> composta por uma camada de entrada, uma ou mais camadas ocultas (intermediárias) e a camada de saída, nas quais os elementos de processamento (neurônios) trabalham com as chamadas funções de ativação ou de transferência [102]. Essas funções têm por objetivo inserir uma não-linearidade no modelo, proporcionando propriedades analíticas mais complexas.

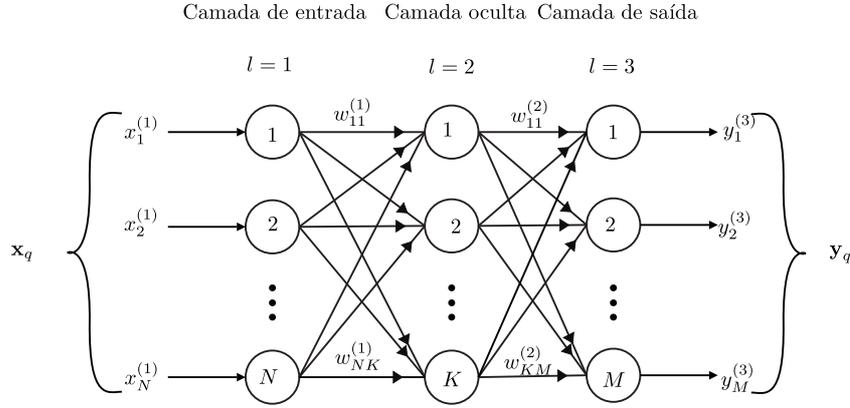
Dentre as várias técnicas de aprendizado existentes para as redes MLP, a mais popular é a “*backpropagation*”. Nesta técnica de aprendizado supervisionado, a saída fornecida pela rede é comparada com a resposta “alvo”, conhecida de antemão, a fim de se obter um valor aceitável de erro estipulado por uma métrica ou função predefinida. A partir disto, a técnica propaga o valor do erro obtido na camada de saída para as demais camadas, atualizando os pesos relacionados a cada conexão da MLP [87]. Esse processo é repetido até que a diferença entre as respostas alcançadas pela rede e seus respectivos “alvos”, convirja para um valor de erro que foi previamente especificado. Nesta situação, diz-se que a rede está treinada.

As informações de entrada da rede neural são organizadas em uma matriz  $\mathbf{X}_{N \times Q}$ , onde  $N$  representa o número de parâmetros a serem analisados e  $Q$  a quantidade total de

<sup>2</sup> Modelo RNA que propaga as informações entre as conexões dos neurônios de forma unidirecional - da camada de entrada para a camada de saída.

dados da amostra. Como trata-se de uma técnica cujo aprendizado é supervisionado, a matriz de entrada  $\mathbf{X}_{N \times Q}$  precisa estar associada a uma matriz “alvo”  $\mathbf{T}_{M \times Q}$  predefinida, responsável por indicar as  $M$  classes dos  $Q$  dados, isto é, as saídas desejáveis utilizadas no cálculo do erro. Apesar de os dados serem fornecidos à rede em formato de matriz, eles são processados um de cada vez, conforme ilustrado na MLP com  $N$  parâmetros de entrada,  $K$  neurônios na camada oculta e  $M$  saídas possíveis, apresentada na Figura 4, na qual  $\mathbf{x}_q$  ( $q = 1, 2, \dots, Q$ ) é o vetor de parâmetros da  $q$ -ésima coluna da matriz de entrada  $\mathbf{X}_{N \times Q}$  e  $\mathbf{y}_q$  ( $q = 1, 2, \dots, Q$ ) o vetor saída gerado pela RNA, correspondente à entrada  $\mathbf{x}_q$ .

Figura 4 – Exemplo de uma rede MLP com uma camada oculta.



Desta forma, sob o ponto de vista SHM, o valor de entrada  $x_n$  ( $n = 1, 2, \dots, N$ ) corresponde à  $n$ -ésima característica extraída do sinal dinâmico  $q$  e o valor  $y_m$  ( $m = 1, 2, \dots, M$ ) corresponde ao  $m$ -ésimo elemento do vetor de saída  $\mathbf{y}$ , que representa, através de uma codificação binária, a classe do sinal  $q$  encontrada pela rede (e.g. para um problema com três classes de dano:  $m = 3 \therefore \mathbf{y}_q = \{y_1 \ y_2 \ y_3\} \Rightarrow$  se  $\mathbf{y}_q = \{1 \ 0 \ 0\}$ , sem dano; se  $\mathbf{y}_q = \{0 \ 1 \ 0\}$ , dano 1; se  $\mathbf{y}_q = \{0 \ 0 \ 1\}$ , dano 2).

Embora não tenha sido retratado na Figura 4, é importante destacar que todas as ligações entre os neurônios possuem um peso  $w_{ij}$ , relativo à conexão entre o neurônio de origem  $i$  e o neurônio de destino  $j$ , indicando a influência que cada entrada possui. Assim, para a rede MLP de três camadas ilustrada acima, cada ensaio  $\mathbf{x}_q$  a ser classificado tem as suas  $N$  entradas, ou características, ponderadas pelos pesos  $w_{ij}$  antes de serem processadas pelos neurônios da camada  $l$  ( $l = 2, 3$ ). A soma ponderada dessas entradas forma um valor para a variável da função de transferência  $f$ , resultando nas saídas  $y_j$  de cada camada, de acordo com a Eq.(3.1):

$$y_j^{(l)} = f \left( \sum_i w_{ij}^{(l-1)} x_i^{(l-1)} + b_j^{(l-1)} \right) \Rightarrow \begin{cases} \text{para } l = 2, i = 1, 2, \dots, N \text{ e } j = 1, 2, \dots, K \\ \text{para } l = 3, i = 1, 2, \dots, K \text{ e } j = 1, 2, \dots, M \end{cases} \quad (3.1)$$

onde  $b$  é o *bias* associado às camadas.

O processo de ajuste de pesos explicado anteriormente é fundamentado na avaliação das derivadas da função de erro em relação aos pesos, e se dá através de métodos de

otimização não-lineares, tais como o método do gradiente descendente, gradiente conjugados, método de Newton, Levenberg-Marquardt, entre outros [102]. O método de Levenberg-Marquadt (LM) é considerado um dos algoritmos mais precisos, e é particularmente indicado para redes que contenham uma quantidade relativamente pequena de pesos a serem ajustados. Resumidamente, calcula-se a matriz jacobiana da função de erro em relação aos respectivos pesos e estes são então calibrados de modo que o erro diminua [103]. Cada linha da matriz Jacobiana refere-se à análise do vetor de características  $\mathbf{x}_q$ , e o processo de ajuste de pesos só é realizado após toda a amostra  $\mathbf{X}_{N \times Q}$  ter sido apresentada à RNA (época de treinamento). A expressão que avalia os pesos atualizados da rede é dada pela Eq.(3.2):

$$\mathbf{w}_{(p+1)} = \mathbf{w}_{(p)} - [\mathbf{J}(\mathbf{w}_{(p)})^T \mathbf{J}(\mathbf{w}_{(p)}) + \mu \mathbf{I}]^{-1} \mathbf{J}(\mathbf{w}_{(p)})^T \mathbf{e}(\mathbf{w}_{(p)}) \quad (3.2)$$

onde, tomando como base a rede MLP de três camadas da Figura 4, e admitindo  $S = K(N + 1) + M(K + 1)$  e  $R = Q \times M$ , tem-se que:  $\mathbf{w}$  é o vetor de pesos da rede, com  $S$  posições, dado na Eq.(3.3);  $\mu$  é a taxa de aprendizado;  $p$  é a época de treinamento;  $\mathbf{I}$  é a matriz identidade;  $\mathbf{e}$  é o vetor de erros, com  $R$  elementos  $e_{mq}$  - relativo ao erro entre a saída  $y_m$  e alvo  $t_m$  para o sinal  $q$  - ordenados como na Eq. (3.4) e definidos pelo erro médio quadrático entre os valores dos vetores alvos  $\mathbf{t}_q$  e os vetores de saída obtidos pela rede  $\mathbf{y}_q$ , conforme Eq.(3.5); e  $\mathbf{J}$  é a matriz jacobiana representada na Eq.(3.6).

$$\mathbf{w}^T = [w_{11}^{(1)} \quad w_{12}^{(1)} \quad \cdots \quad w_{NK}^{(1)} \quad b_1^{(1)} \quad \cdots \quad b_K^{(1)} \quad w_{11}^{(2)} \quad w_{12}^{(2)} \quad \cdots \quad w_{KM}^{(2)} \quad b_1^{(2)} \quad \cdots \quad b_M^{(2)}] \quad (3.3)$$

$$\mathbf{e}^T = [e_{11} \quad e_{21} \quad e_{31} \quad e_{12} \quad e_{22} \quad e_{32} \quad \cdots \quad e_{MQ}] \quad (3.4)$$

$$\mathbf{e}(\mathbf{w}) = \frac{1}{R} \sum_{r=1}^R e_r^2(\mathbf{w}) = \frac{1}{Q} \sum_{q=1}^Q (\mathbf{t}_q - \mathbf{y}_q)^T (\mathbf{t}_q - \mathbf{y}_q) \quad (3.5)$$

$$\mathbf{J}(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{w})}{\partial w_1} & \frac{\partial e_1(\mathbf{w})}{\partial w_2} & \cdots & \frac{\partial e_1(\mathbf{w})}{\partial w_S} \\ \frac{\partial e_2(\mathbf{w})}{\partial w_1} & \frac{\partial e_2(\mathbf{w})}{\partial w_2} & \cdots & \frac{\partial e_2(\mathbf{w})}{\partial w_S} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_R(\mathbf{w})}{\partial w_1} & \frac{\partial e_R(\mathbf{w})}{\partial w_2} & \cdots & \frac{\partial e_R(\mathbf{w})}{\partial w_S} \end{bmatrix} \quad (3.6)$$

Devido à sua eficiência e ao bom desempenho em uma variedade de problemas, um outro método muito empregado é o de Gradiente Conjugado Escalonado (SCG, do inglês *Scaled Conjugate Gradient*). Assim como em qualquer algoritmo de gradiente conjugado, o SCG obtém em cada iteração  $p$  um vetor de direção  $\mathbf{d}_{(p)}$ , ortogonal à todas as direções anteriores ( $\mathbf{d}_{(1)}, \dots, \mathbf{d}_{(p-1)}$ ), de modo que  $\mathbf{w}_{(p+1)}$  minimiza  $\mathbf{e}_{\mathbf{w}}$ , tal como na Eq.(3.7):

$$\mathbf{w}_{(p+1)} = \mathbf{w}_{(p)} + \mu_{(p)} \mathbf{d}_{(p)} \quad (3.7)$$

Entretanto, este procedimento, em especial, determina a taxa de aprendizado  $\mu_{(p)}$ , dada na Eq.(3.8), baseando-se na avaliação das derivadas de segunda ordem - matriz Hessiana  $\mathbf{H}$ , representada na Eq.(3.9) - através de um cálculo aproximado do vetor  $\mathbf{s}_{(p)}$ , conforme a Eq.(3.10), onde  $\sigma$  designa o tamanho do passo de discretização [104]. Desse modo, o algoritmo SCG é adequado para RNAs com um grande número de pesos, pois, do ponto de vista computacional, é pouco custoso quando comparado aos demais métodos, uma vez que não se faz necessária a inversão Hessiana.

$$\mu_{(p)} = \frac{\mathbf{d}_{(p)}^T \mathbf{J}(\mathbf{w}_{(p)})}{\mathbf{d}_{(p)}^T \mathbf{H}(\mathbf{w}_{(p)}) \mathbf{d}_{(p)}} = \frac{\mathbf{d}_{(p)}^T \mathbf{J}(\mathbf{w}_{(p)})}{\mathbf{d}_{(p)}^T \mathbf{s}_{(p)}} \quad (3.8)$$

$$\mathbf{H}(\mathbf{w}) = \begin{bmatrix} \frac{\partial^2 e_1(\mathbf{w})}{\partial w_1^2} & \frac{\partial^2 e_1(\mathbf{w})}{\partial w_1 \partial w_2} & \cdots & \frac{\partial^2 e_1(\mathbf{w})}{\partial w_1 \partial w_S} \\ \frac{\partial^2 e_2(\mathbf{w})}{\partial w_2 \partial w_1} & \frac{\partial^2 e_2(\mathbf{w})}{\partial w_2^2} & \cdots & \frac{\partial^2 e_2(\mathbf{w})}{\partial w_2 \partial w_S} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 e_R(\mathbf{w})}{\partial w_S \partial w_1} & \frac{\partial^2 e_R(\mathbf{w})}{\partial w_S \partial w_2} & \cdots & \frac{\partial^2 e_R(\mathbf{w})}{\partial w_S^2} \end{bmatrix} \quad (3.9)$$

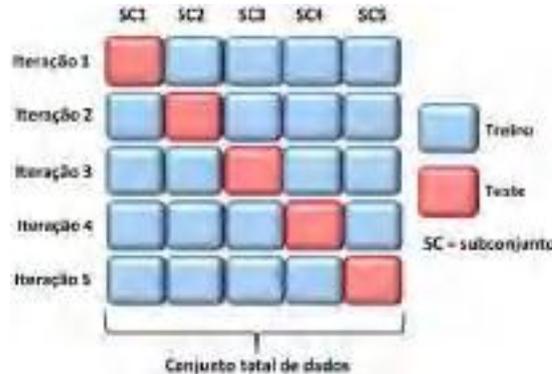
$$\mathbf{s}_{(p)} \approx \frac{\mathbf{J}(\mathbf{w}_{(p)} + \sigma_{(p)} \mathbf{d}_{(p)}) - \mathbf{J}(\mathbf{w}_{(p)})}{\sigma_{(p)}}, \quad 0 < \sigma_{(p)} \ll 1 \quad (3.10)$$

Ao término do treinamento a rede deverá ter adquirido a capacidade de generalizar resultados para o respectivo problema com base nos parâmetros extraídos. Para avaliar o desempenho do modelo neural, dados do sinal que não foram classificados são utilizados afim de testar a capacidade de generalização da rede. Convém salientar, entretanto, que um dos problemas mais comuns durante o treinamento de uma rede neural é o de “*overfitting*”, caracterizado pela construção de um modelo que se ajusta perfeitamente aos exemplos utilizados no treino (alta precisão e baixo erro de predição), mas que não é capaz de alcançar bom desempenho quando avaliado para novos conjuntos daquele mesmo tipo de dado. Em outras palavras, o modelo não consegue generalizar bem. Levando isso em consideração, surgiram as técnicas de validação cruzada, que visam garantir a capacidade de generalização dos modelos computacionais quando submetidos a dados do conjunto não utilizados na fase de treino.

Existem vários métodos de validação, porém este estudo concentra-se apenas na validação “*k-fold*”. Nesta técnica, o conjunto original de dados é dividido aleatoriamente em  $k$  subconjuntos (no caso deste trabalho optou-se por  $k = 5$ , logo “*5-fold*”), com aproximadamente a mesma quantidade de dados, contendo exemplo de todas as classes e, a cada iteração, um subconjunto distinto é utilizado para teste e os outros  $k - 1$  conjuntos para treino. O processo de treinamento e teste é repetido  $k$  vezes e a estimativa de precisão é o número total de classificações corretas dividido pelo número total de dados (conjunto original). Ao fim dessa validação, cada subamostra foi testada apenas uma vez pelos algoritmos, não havendo sobreposição de dados. O desempenho final do modelo é

calculado através da média de acerto de todas  $k$  classificações da validação “ $k$ -fold”. A Figura 5 exemplifica o esquema de validação “5-fold”. Para maiores informações, consultar o trabalho de Kohavi (1995) [105].

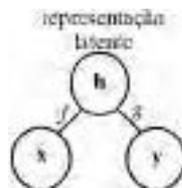
Figura 5 – Esquema de validação cruzada 5-fold.



### 3.2 AUTOCODIFICADOR ESPARSO

O entendimento do Autocodificador Esparsos, passa, primeiramente, pela compreensão do que vem a ser um Autocodificador “(AE - *AutoEncoder*)”. Em linhas gerais, o autocodificador pode ser interpretado como uma RNA de treinamento não-supervisionado, construída para retornar como saída uma aproximação da sua respectiva entrada [106]. O aprendizado de um modelo AE é denominado não-supervisionado porque não é necessário fornecer, junto com os dados de entrada, a saída “alvo”, uma vez que a função custo, neste caso, avalia a diferença entre a entrada  $\mathbf{x}$  e a sua própria saída  $\mathbf{y} \approx \mathbf{x}$  ( $\mathbf{x}$  reconstruído). Basicamente, esse tipo de rede profunda é constituída por uma camada interna de codificação descrita pela função  $\mathbf{h} = f(\mathbf{x})$ , que “aprende” as características do vetor de entrada  $\mathbf{x}$  (representação latente), e uma camada de decodificação descrita por  $\mathbf{y} = g(\mathbf{h})$  que reconstrói  $\mathbf{x}$ , conforme sugere a arquitetura apresentada na Figura 6 [45].

Figura 6 – Estrutura básica de um autocodificador: mapeamento/reconstrução da entrada  $\mathbf{x}$  para a saída  $\mathbf{y}$ .



Fonte: Adaptado de Goodfellow *et al.* (2016) [45].

Dessa forma, tomando como referência o AE de três camadas representado na Figura 6, e considerando o vetor de entrada  $\mathbf{x}$  como sendo a  $q$ -ésima coluna da matriz de dados  $\mathbf{X}_{N \times Q}$ , a transformação/codificação de  $\mathbf{x}$  em um “novo” vetor de características  $\mathbf{h}$ , é dada pela função  $f$ , conforme Eq.(3.11):

$$\mathbf{h} = f(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}) \quad (3.11)$$

onde  $\mathbf{W}^{(1)}$  é o vetor de pesos da rede relativo às conexões entre a primeira e a segunda camada (sobrescrito 1) e  $\mathbf{b}^{(1)}$  é o vetor de *bias* associado.

De maneira análoga e subsequente, a decodificação do vetor de características  $\mathbf{h}$ , para o vetor de saída  $\mathbf{y} \approx \mathbf{x}$ , é realizada pela função  $g$ , de acordo com a Eq.(3.12):

$$\mathbf{y} = g(\mathbf{W}^{(2)}\mathbf{h} + \mathbf{b}^{(2)}) \quad (3.12)$$

onde  $\mathbf{W}^{(2)}$  é o vetor de pesos da rede relativo às conexões entre a segunda e a terceira camada (sobrescrito 2) e  $\mathbf{b}^{(2)}$  é o vetor de *bias* associado. No que diz respeito ao processo de ajuste de pesos, o método AE é conceituado como um caso particular de redes “*feedforward*”, e portanto, pode ser treinado empregando o método de “*backpropagation*” com as mesmas técnicas de otimização de uma MLP tradicional [45]. Ressalta-se que o autocodificador pode ter várias camadas de processamento (algoritmo de aprendizado profundo - “*deep learning*”). Contudo, com o intuito de facilitar o entendimento do método, as equações anteriores foram simplificadas, considerando-se apenas uma camada na parte codificadora e decodificadora (AE com três camadas).

No entanto, o interesse principal aqui não é na saída replicada do autocodificador, mas sim nas características  $\mathbf{h}$  que ele pode fornecer. Ou seja, a ideia ao utilizar esse método é explorar a sua capacidade de mapear os padrões existentes nos dados, ao invés de simplesmente repeti-los. Neste contexto, a AE identifica e mantém, de maneira autônoma, apenas as características relevantes para a solução de outra tarefa específica, como por exemplo a classificação. Assim, quando os autocodificadores são empregados somente no mapeamento dos dados, sem reconstrução das características, eles são projetados para produzir  $\mathbf{h}$  com dimensão  $K$  inferior à  $N$  (dimensão de  $\mathbf{x}$ ) e são chamados de Autocodificadores Incompletos.

A grande vantagem de se reduzir a dimensão de  $\mathbf{x}$  para  $\mathbf{h}$  é que o modelo é forçado a priorizar somente alguns atributos do conjunto de entrada, possibilitando a identificação de parâmetros relevantes do conjunto de dados em um alto nível de abstração. Nesta circunstância, o aprendizado da rede AE é realizado através da minimização de uma função  $Z(\mathbf{x}, g(f(\mathbf{x})))$ , que penaliza as diferenças entre  $\mathbf{x}$  e  $g(f(\mathbf{x}))$ . Caso a função de codificação seja linear e  $Z$  seja o erro quadrático médio, o Autocodificador Incompleto se comporta como a técnica de Análise de Componentes Principais (PCA, do inglês “*Principal Component Analysis*”) [45].

Não obstante à eficiência do método AE em sintetizar e extrair elementos importantes dos dados, uma capacidade excessiva de aproximação das partes codificadora e decodificadora ( $\mathbf{y} \approx \mathbf{x}$ ) pode acarretar situações nas quais  $\mathbf{h}$  tenha uma dimensionalidade muito alta, fornecendo poucos parâmetros interessantes para a modelagem do problema abordado e, conseqüentemente, comprometendo a sua capacidade de generalização. Frente a isso, a fim de melhorar o desempenho dos modelos AE, surgiu o Autocodificador Esperso, um autocodificador incompleto onde uma penalidade denominada esparsa  $\Gamma(\mathbf{h})$  é incor-

porada à função  $Z$  no processo de treinamento, resultando em  $Z(\mathbf{x}, g(f(\mathbf{x}))) + \Gamma(f(\mathbf{x}))$ . A penalização esparsa permite a rede autocodificadora representar grandes conjuntos de dados com um pequeno número de componentes  $\mathbf{h}$ , controlando a quantidade de neurônios ativos nas camadas. Dessa forma, o SAE pode produzir modelos mais aptos a identificar informações representativas, concisas e exclusivas do conjunto de dados para o qual foram treinados.

De acordo com Ng (2011) [107], o termo de penalização  $\Gamma$  pode ser obtido pelo cálculo da divergência  $KL$  de Kullback-Leibler [108] através da seguinte equação:

$$\Gamma = \sum_{i=1}^K KL(\rho \parallel \hat{\rho}_i) = \sum_{i=1}^K \rho \log \left( \frac{\rho}{\hat{\rho}_i} \right) + (1 - \rho) \log \left( \frac{1 - \rho}{1 - \hat{\rho}_i} \right) \quad (3.13)$$

onde  $K$  é o número de neurônios na camada intermediária,  $\rho$  é o valor médio de ativação desejado, previamente definido próximo ao limite inferior da função de ativação considerada, chamado também de proporção de esparsidade, e  $\hat{\rho}$  representa o valor médio de ativação do respectivo neurônio  $i$ , dado por:

$$\hat{\rho}_i = \frac{1}{Q} \sum_{j=1}^Q f(\mathbf{W}_i^{(1)T} \mathbf{x}_j + \mathbf{b}_i^{(1)}). \quad (3.14)$$

Se  $\hat{\rho}_i = \rho$ , a função de penalização  $\Gamma$  assume  $KL = 0$ ; caso contrário, conforme  $\rho_i$  diverge de  $\rho$ ,  $KL$  apresenta valores monotonicamente crescentes, evitando, assim, o problema da não propagação dos gradientes para as camadas mais distantes da entrada de rede.

Além do termo de esparsidade  $\Gamma$ , uma outra estratégia utilizada para controlar a dispersão dos gradientes é inserir um termo de regularização dos pesos  $\Gamma_2$ , que atua aumentando os valores de  $\mathbf{W}$  e diminuindo os valores de  $\mathbf{h}$ , conforme Eq.(3.15):

$$\Gamma_2 = \frac{1}{2} \sum_l^L \sum_j^Q \sum_i^N w_{ji}^{(l)} \quad (3.15)$$

na qual  $L$  está relacionada ao número de camadas presentes no codificador,  $Q$  ao número de observações (exemplos) e  $N$  à quantidade de parâmetros de entrada.

Considerando a Eq.(3.13) e Eq.(3.15), e admitindo  $Z$  como sendo erro quadrático médio, a função custo a ser otimizada no processo de treinamento de um modelo SAE pode ser definida por:

$$E = \frac{1}{Q} \sum_q^Q \sum_n^N (x_{nq} - \hat{x}_{nq})^2 + \beta \Gamma + \lambda \Gamma_2 \quad (3.16)$$

onde  $\beta$  e  $\lambda$  são coeficientes que controlam a influência do termo de esparsidade e regularização, respectivamente.

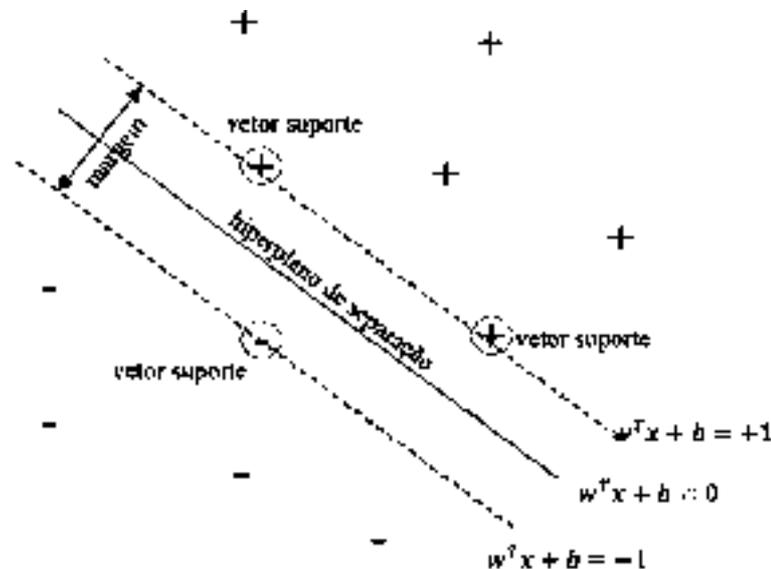
Em problemas de classificação, ao final do treinamento, as características fornecidas pelo SAE são utilizadas como parâmetros de entrada de algoritmos clássicos de reconhecimento de padrões (RNA, SVM, Agrupamento, Árvores de Decisão, entre outras) ou, então,

são repassadas diretamente para o treinamento, agora supervisionado, de uma rede MLP tradicional, conectada à última camada codificadora. Neste caso, a rede é denominada de Autocodificador Esparso Empilhado (“*Stacked Sparse AutoEncoder*”). Ressalta-se, ainda, que o autocodificador empilhado pode ter seu desempenho melhorado retreinando-se todas as suas camadas simultaneamente (ajuste fino da rede ou “*fine tuning*”).

### 3.3 MÁQUINA DE VETOR SUPORTE

Um dos métodos de aprendizado computacional mais populares para a solução de problemas de reconhecimento de padrões é a Máquina de Vetor Suporte. Os modelos SVMs são desenvolvidos a partir de um algoritmo de aprendizado estatístico treinado para determinar o limite entre duas classes de dados em um espaço, onde um hiperplano ótimo de separação é construído com o intuito de maximizar a margem entre as regiões de cada classe e minimizar as classificações erradas [109], como ilustrado na Figura 7. Ao contrário de outras técnicas de aprendizado, o SVM não gera probabilidades, ele atribui os dados à determinada classe baseado nas distâncias dos pontos ao limite de decisão (scores de classificação), definidas por uma função linear  $\mathbf{w}^T \mathbf{x} + b$ .

Figura 7 – Representação de um SVM linear.



Considerando-se o conjunto de dados  $(\mathbf{x}_i, y_i)$  de um problema linear de classificação de dados, sendo  $\mathbf{x}_i$  o vetor de variáveis de entrada do sinal dinâmico  $i$ ,  $y_i$  a saída desejada do sinal  $i$  e  $i$  representando o  $i$ -ésimo sinal do banco de dados, o hiperplano de separação é definido tal que:

$$\begin{aligned} y_i = 1 &\rightarrow \mathbf{w}^T \mathbf{x}_i + b > +1 \quad \forall \mathbf{x}_i \in \Omega_1 \\ y_i = -1 &\rightarrow \mathbf{w}^T \mathbf{x}_i + b < -1 \quad \forall \mathbf{x}_i \in \Omega_2 \end{aligned} \quad (3.17)$$

onde  $\mathbf{w}$  é o vetor de pesos das variáveis de entrada;  $b$  é o *bias*, que indica o desvio do valor real esperado do estimador (erro sistemático); e  $\Omega_1$  e  $\Omega_2$  representam as regiões associadas

às classes presentes na amostra ( $\Omega_1 + \Omega_2 = \Omega$ ). A Eq.(3.17) acima é combinada de forma que:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \forall \mathbf{x}_i \in \Omega \quad (3.18)$$

em que para os dados  $(\mathbf{x}_i, y_i)$  cuja equação acima é satisfeita com igualdade, dá-se o nome de vetores suporte (Figura 7). O problema de aprendizagem do algoritmo SVM é interpretado como a minimização de  $\|\mathbf{w}\|^2 = \mathbf{w}^T \mathbf{w}$ , o que é equivalente a maximizar a distância normal ao hiperplano que separa as duas classes (margem). Assim, o problema de otimização pode ser enunciado como a minimização da função dada pela Eq.(3.19):

$$\Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (3.19)$$

a qual é sujeita à Eq.(3.18), com  $i=1, \dots, n$ . A função de Lagrange para este problema pode ser escrita como:

$$L(\mathbf{w}, b, \Lambda) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \lambda_i [y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1] \quad (3.20)$$

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

$$\mathbf{w}^* = \sum_{i=1}^n \lambda_i^* y_i \mathbf{x}_i \quad (3.21)$$

Salienta-se que os multiplicadores de Lagrange são iguais a zero somente quando a Eq.(3.18) é igual a 1 (vetores suporte). O valor ótimo de *bias* é avaliado como:

$$b^* = y_i - \mathbf{w}^{*T} \mathbf{x}_i, \quad i = 1, \dots, n \quad (3.22)$$

Figura 8 – Representação do hiperplano separador de um SVM não-linear.



Fonte: Adaptado de Cury & Crémona (2012) [84].

No entanto, ao se considerar a classificação binária como sendo não-linear, as entradas são mapeadas em um espaço de características de dimensão maior que o espaço original através de alguma função de kernel, conforme ilustrado na Figura 8. Dessa forma, tem-se que:

$$\begin{aligned} X &\rightarrow H \\ \mathbf{x} &\rightarrow \phi(\mathbf{x}) \end{aligned} \quad (3.23)$$

O mapeamento de um determinado conjunto de testes  $(\mathbf{x}_i, \mathbf{x}_i')$  é realizado através da Eq.(3.24):

$$K(\mathbf{x}_i, \mathbf{x}_i') \equiv \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_i') \quad (3.24)$$

Assim, em um espaço de características diferente do inicial, o problema de otimização do hiperplano, originalmente não-linear, pode ser tratado como se fosse linear, facilitando a convergência da solução. Um dos kernels mais conhecidos e utilizados é o de Função de Base Radial (RBF - *Radial Basis Function*):

$$K(\mathbf{x}_i, \mathbf{x}_i') \equiv e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_i'\|^2}{2\sigma^2}} \quad (3.25)$$

Destaca-se que a teoria do SVM pode ser estendida para problemas multiclases através de estratégias baseadas na combinação de classificadores binários, como as estratégias um contra um e um contra todos, por exemplo [87]. Por englobar todas as combinações de classes possíveis, o método um contra um é o dominante na literatura. Admitindo-se que  $Q$  é a quantidade de classes existente para o problema, nessa estratégia, a acurácia final do modelo é baseada na associação do desempenho de  $Q(Q - 1)/2$  classificadores binários, considerando, por vez, uma classe como sendo positiva, outra sendo negativa e ignorando as demais.

A capacidade de “aprender” e generalizar informações ainda não processadas através de exemplos é uma das principais vantagens ao se utilizar algoritmos de aprendizado de máquinas aplicado ao reconhecimento de padrões. Desse modo, assim como para um modelo RNA, após o treinamento, é preciso avaliar o potencial de generalização do modelo SVM na classificação de “novos” dados. Esta última etapa é denominada fase de teste e consiste basicamente em apresentar ao classificador exemplos diferentes dos utilizados na fase de treino. Cabe ressaltar que a etapa de teste não tem efeito na construção do modelo de classificação, já que fornece apenas uma medida do seu desempenho para dados ainda não vistos.

No presente trabalho, todos os modelos SVM foram implementados adotando-se a estratégia um contra um e o kernel RBF. Consequentemente, os modelos têm dois parâmetros livres que precisam ser especificados:  $\sigma$ , próprio da função de kernel; e  $C$ , um parâmetro de regularização da formulação de maximização da margem. Estes parâmetros foram selecionados pelo procedimento de busca exaustiva em grade (*Grid Search*). Neste método, dois conjuntos finitos de valores (discretos) para  $\sigma$  e  $C$  são previamente determinados e empregados no treinamento de modelos SVM, onde todas as combinações são avaliadas através de uma validação cruzada *10-fold*, cujo conceito será explicado na próxima seção. Por fim, o par de parâmetros  $(\sigma, C)$  que obtiver o modelo com o menor erro de generalização é escolhido. As Equações (3.26) e (3.27) mostram os conjuntos de valores para  $\sigma$  e  $C$ , respectivamente, utilizados no procedimento de busca

em grade associado aos modelos SVM deste estudo.

$$\begin{aligned} \sigma = \{ & 0,0316; 0,0398; 0,0501; 0,0631; 0,0794; 0,3162; 0,3981; \\ & 0,5000; 0,5012; 0,6310; 0,7943; 1,0; 1,5; 2,0; 2,5; 3,0; 3,5; \\ & 4,0; 4,5; 5,0; 5,5; 6,0; 6,5; 7,0; 7,5; 8,0; 8,5; 9,0; 9,5; 10,0 \} \end{aligned} \quad (3.26)$$

$$\begin{aligned} C = \{ & 0,0316; 0,3162; 0,5000; 1,0; 1,5; 2,0; 2,5; 3,0; 3,5; 4,0; 4,5; 5,0; 5,5; \\ & 6,0; 6,5; 7,0; 7,5; 8,0; 8,5; 9,0; 9,5; 10,0; 31,6228; 100,0; 316,2278 \} \end{aligned} \quad (3.27)$$

## 4 ANÁLISE DE SENSIBILIDADE: AUTOCODIFICADOR ESPARSO APLICADO AOS SINAIS TÍPICAMENTE ESTRUTURAIIS

Apesar da ampla aplicação de métodos de aprendizado de máquina nos mais variados tipos de problema, a plena interpretabilidade dos seus mecanismos de processamento é uma das principais lacunas para estudiosos da área. Particularizando a questão para os autocodificadores, a situação não é diferente. O processamento de dados realizados via SAE ainda é considerado por muitos autores uma caixa preta, que requer uma maior base teórica e com muitos tipos de incertezas que, até o momento, não podem ser completamente explicadas [20]. Fato é que, assim como em outros algoritmos de aprendizado de máquina, diferentes parâmetros (tipos de função de ativação, quantidade de camadas/neurônios, combinação de hiperparâmetros, etc) podem afetar significativamente o comportamento dos modelos SAE, levando a diversos níveis de desempenho e precisão. Por este motivo e considerando a escassez de trabalhos na literatura SHM que abordam tal tema, apresenta-se neste capítulo uma breve análise da influência de vários parâmetros nos autocodificadores ao modelar sinais tipicamente estruturais. A ideia é inferir sobre as tendências de desempenho do algoritmo ao variar determinados parâmetros, uma vez que o processo que investiga as relações entre eles é de natureza altamente não-linear (fator que dificulta a análise de sensibilidade, já que a alteração em um parâmetro reflete na configuração dos demais).

A presente avaliação mira nos seguintes parâmetros:

- **Função de ativação.** Consideradas elementos chaves na arquitetura das redes, serão testadas algumas funções de ativação, tanto para a codificação, como para a decodificação dos sinais, checando quais seriam as mais adequadas para representar sinais tipicamente encontrados em monitoramentos estruturais;
- **Hiperparâmetros  $\rho$ ,  $\lambda$  e  $\beta$ .** Relativos à função de otimização do SAE, são parâmetros sensíveis do modelo autocodificador, com influência direta no controle de aprendizado do algoritmo. Embora os valores ideais variem de problema para problema, procura-se aqui algumas indicações sobre o comportamento de tais parâmetros em sinais dinâmicos;
- **Quantidade mínima de sinais de treinamento.** É claro que um maior número de sinais de treinamento contribui para uma melhor modelagem do SAE. No entanto, existem algumas aplicações em que não se dispõe de tantos dados. Ao passo que esta última situação pode dificultar o ajuste do modelo SAE, um elevado número de sinais pode incrementar consideravelmente o tempo de processamento necessário na etapa de treinamento, o que também não é desejável.
- **Número de neurônios na camada interna.** É intuitivo dizer que, quanto maior o número de elementos da camada interna do SAE, maior será sua habilidade de reconstrução de sinais. Em contrapartida, um número excessivo de neurônios

na camada interna ( $\dim(\mathbf{h})$ ) faz com que se limite a sua capacidade de reduzir a dimensionalidade do problema, o que não é almejado;

- **Número de neurônios na camada de entrada.** Também é intuitivo supor que, quanto maior o comprimento do sinal, mais complexa fica a sua reconstrução através do SAE. Porém, sinais de pouco tempo de duração podem não ser suficientes para se caracterizar um comportamento dinâmico de forma adequada pelo SAE. Assim, aqui são investigadas as influências do tempo de duração dos sinais que está diretamente ligado ao número de pontos discretos que os compõem.

Um quadro resumo com os parâmetros aqui avaliados, exceto os valores  $\rho$ ,  $\lambda$  e  $\beta$  (que serão abordados mais adiante), é apresentado na Tabela 1. As funções de ativação logsig, satlin e purelin são descritas pela Eq. 4.1, Eq. 4.2 e Eq. 4.3, respectivamente.

Tabela 1 – Quadro resumo - Análise de sensibilidade do SAE: parâmetros avaliados.

Parâmetros		Argumentos de entrada	
Função de ativação	Codificadora	sigmóide logística (logsig) linear de saturação (satlin)	
	Decodificadora	sigmóide logística (logsig) linear de saturação (satlin) linear (purelin)	
Nº de neurônios na camada interna ( $\dim(\mathbf{h})$ )		5; 8; 10; 12; 15; 18; 20; 25	
Nº de neurônios na camada de entrada (tamanho dos sinais)		Em segundos	0,25; 0,5; 0,75; 1; 2; 5; 8; 10
		Em pontos amostrados	25; 50; 75; 100; 200; 500; 800; 1000
Quantidade de sinais no treinamento		20; 50; 80; 100; 120; 150; 180; 200; 220; 250	

$$f(z) = \frac{1}{1 + e^{-z}} \quad (4.1)$$

$$f(z) = \begin{cases} 0, & \text{se } z \leq 0 \\ z, & \text{se } 0 \leq z \leq 1 \\ 1, & \text{se } z \geq 1 \end{cases} \quad (4.2)$$

$$f(z) = z \quad (4.3)$$

Levando em consideração o comportamento característico das respostas estruturais normalmente adquiridas em sistemas de monitoramento dinâmico, as análises são desenvolvidas com base em sinais harmônicos, gerados computacionalmente. Com o intuito de verificar a habilidade do SAE ao lidar com dados de diferentes complexidades, os sinais são simulados com até três componentes harmônicas. Os mais simples possuem uma única componente com frequência de 1Hz, os intermediários são constituídos por duas

componentes, de 1Hz e 3Hz, e os de nível mais complexo são compostos por harmônicos de 1Hz, 3Hz e 5Hz. A formulação utilizada para a criação dos sinais é descrita pela Eq.(4.4):

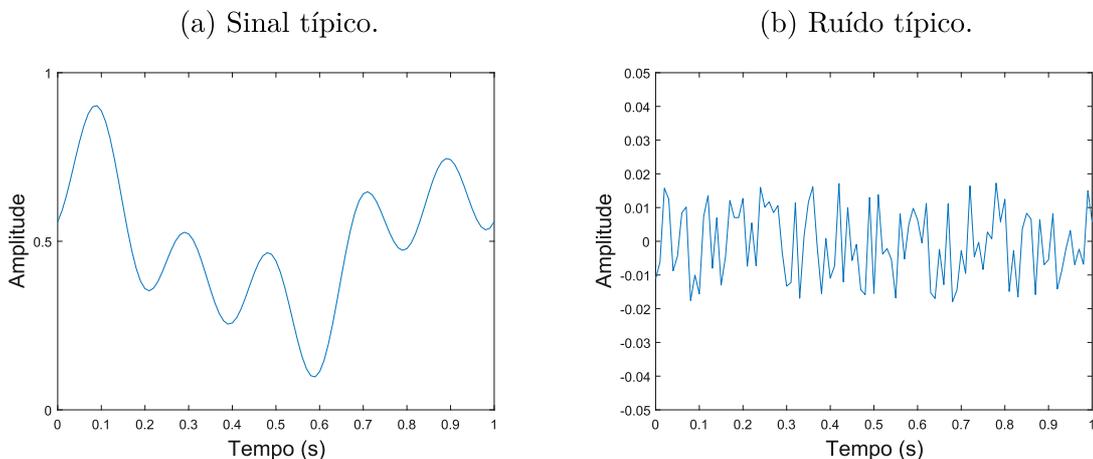
$$x_{ij} = \sum_{k=1}^K A_{kj} \sin(2\pi f_k t_i + \phi_{kj}), \quad \begin{cases} i = 1, \dots, N \\ j = 1, \dots, Q \end{cases} \quad (4.4)$$

sendo  $N$  o número total de pontos amostrados (tamanho dos sinais),  $Q$  a quantidade total de sinais, e  $K$  a quantidade de componentes harmônicas  $f$  consideradas. Posto que, para o caso dessa análise específica,  $f = [1, 3, 5]$  Hz, tem-se:  $K = 1$ , para geração de respostas somente com a primeira frequência;  $K = 2$ , para respostas formadas pelas duas primeiras frequências e;  $K = 3$ , para respostas com as três frequências. Por fim, define-se ainda que  $t_i$  é o tempo correspondente ao  $i$ -ésimo ponto amostrado e,  $\phi_{kj}$  e  $A_{kj}$  são, respectivamente, a  $k$ -ésima fase e amplitude, ambas aleatórias, associadas ao  $j$ -ésimo sinal (com valores de amplitude variando entre  $[0,1]$  e de fase entre  $[0,\pi]$ ). Visando representar as incertezas existentes nas medições dinâmicas, além de simular dados para três composições harmônicas diferentes, admitiu-se também a inserção de ruídos a esses conjuntos de sinais. Quatro níveis de ruído são adotados: sem ruído, 1%, 2,5% e 4% do máximo valor RMS (raiz média quadrática) encontrado para os sinais do grupo de dados em questão. Assumindo que  $\mathbf{x}_j$  é o vetor do  $j$ -ésimo sinal da matriz de dados  $\mathbf{X}_{N \times Q}$  gerada anteriormente, o modo de construção e incorporação dos ruídos a cada uma das respostas vibracionais é dado pela Eq.(4.5):

$$\mathbf{x}_j^{\text{ruído}} = \mathbf{x}_j + \max[\text{RMS}(\mathbf{X})] \eta^{\text{ruído}} \text{rand}(N), \quad (4.5)$$

onde  $\mathbf{x}_j^{\text{ruído}}$  é o vetor do respectivo sinal  $j$  com ruído,  $\eta^{\text{ruído}}$  é o nível de ruído associado e  $\text{rand}(N)$  é um vetor de  $N$  posições, com distribuição uniforme e valores variando entre  $[0,1]$ . A Figura 9 ilustra um exemplo de sinal e ruído gerado.

Figura 9 – Exemplo de sinal e ruído simulados.



Com relação ao desempenho do autocodificador, existem algumas formas de avaliar se determinada configuração de parâmetros é a mais apropriada durante a criação de um

modelo. Conforme mencionado em capítulos anteriores, o treinamento do SAE é realizado através da reconstrução de seus dados de entrada. Portanto, é razoável assumir que a diferença entre os sinais originais e reconstruídos possa indicar se o modelo obtido está bem ajustado ou não. Desta forma, a presente análise utiliza essa diferença, aqui denotada como erro de reconstrução  $\zeta$ , como métrica de avaliação de desempenho do SAE. Para cada sinal modelado pelo SAE,  $\zeta$  é calculado através da Eq.(4.6):

$$\zeta_j = \frac{1}{N} \sum_{i=1}^N |x_{ij} - \hat{x}_{ij}|, \quad (4.6)$$

onde  $x_{ij}$  e  $\hat{x}_{ij}$  são, respectivamente, o  $i$ -ésimo elemento do  $j$ -ésimo vetor de sinal original e do  $j$ -ésimo vetor de sinal reconstruído (com  $j = 1, \dots, Q$ ). Consequentemente, o erro de reconstrução para todo o conjunto de sinais dinâmicos  $\tilde{\zeta}$  é dado pela média de todos os erros  $\zeta_j$ , conforme a Eq.(4.7) a seguir:

$$\tilde{\zeta} = \frac{1}{Q} \sum_{j=1}^Q \zeta_j. \quad (4.7)$$

Uma vez definidas as diretrizes gerais, a primeira etapa deste estudo, que servirá de base para as análises subsequentes, examina quais funções de ativação são mais adequadas para modelar os dados dinâmicos gerados.

#### 4.1 FUNÇÕES DE ATIVAÇÃO

Partindo da premissa de que a escolha dessas funções depende sobretudo das propriedades particulares de cada problema [45], investigou-se nessa fase inicial seis possíveis combinações entre as funções de ativação apresentadas na Tabela 1. Para fins de comparação, as seis combinações foram analisadas em modelos SAE com apenas uma camada codificadora e uma decodificadora, considerando 10 neurônios na camada interna ( $\dim(\mathbf{h}) = 10$ ), e sinais sem ruído, simulados com 1s de duração e total de 100 pontos amostrados (frequência de aquisição  $f_s = 100\text{Hz}$ ). Para cada um dos três tipos de composições senoidais já mencionados, foram geradas 200 respostas ( $Q = 200$ ), sendo 100 delas utilizadas no treinamento do modelo e as outras 100 como conjunto de validação (matriz total de dados  $\mathbf{X}_{100 \times 200}$ ). Os erros de reconstrução  $\tilde{\zeta}$  obtidos para 5 modelos SAE ao avaliar as diferentes combinações de funções de ativação estão na Tabela 2. Os valores do hiperparâmetros  $\lambda$ ,  $\beta$  e  $\rho$  (relativos à função de otimização do SAE) foram definidos pela média do menor erro  $\tilde{\zeta}$  de validação alcançado para os 5 modelos através do procedimento de busca em grade, similar ao que foi apresentado na seção que abordou a teoria SVM, porém sem aplicar a validação cruzada “*k-fold*”. O conjunto de valores de  $\rho$ ,  $\lambda$  e  $\beta$  avaliados pelo procedimento de busca exaustiva do SAE foram extraídos do trabalho de Touati et al. (2020) [110] e estão listados na Eq.(4.8), Eq.(4.9) e Eq.(4.10), respectivamente. Os demais parâmetros empregados foram: método de otimização = SCG,

quantidade máxima de épocas de treinamento = 1000 e, métrica de treinamento = média quadrática.

$$\rho = \{0,0063; 0,0125; 0,0250; 0,0500; 0,1000; 0,2000; 0,4000; 0,8000\} \quad (4.8)$$

$$\lambda = \{0,0001; 0,0010; 0,0100; 0,1000\} \quad (4.9)$$

$$\beta = \{0,5000; 1,0000; 2,0000; 4,0000; 8,0000\} \quad (4.10)$$

Tabela 2 – Erro de reconstrução  $\tilde{\zeta}$  para diferentes combinações de funções de ativação.

	Função de ativação		$\tilde{\zeta}$		Hiperparâmetros		
	Camada Cod.	Camada Decod.	Treino	Validação	$\lambda$	$\beta$	$\rho$
<b>Uma senóide (1Hz)</b>	<b>satlin</b>	<b>purelin</b>	<b>0,00067</b>	<b>0,00074</b>	<b>0,0001</b>	<b>1</b>	<b>0,1</b>
	satlin	logsig	0,01877	0,01995	0,0001	2	0,8
	satlin	satlin	0,03824	0,03831	0,0001	0,5	0,1
	logsig	purelin	0,00173	0,00184	0,0001	0,5	0,2
	logsig	logsig	0,01148	0,01270	0,0001	4	0,2
	logsig	satlin	0,00239	0,00267	0,0001	8	0,8
<b>Duas senóides (1 e 3Hz)</b>	<b>satlin</b>	<b>purelin</b>	<b>0,00044</b>	<b>0,00394</b>	<b>0,0001</b>	<b>4</b>	<b>0,4</b>
	satlin	logsig	0,01397	0,01600	0,0001	1	0,4
	satlin	satlin	0,03565	0,03746	0,001	0,5	0,1
	logsig	purelin	0,00152	0,00253	0,0001	0,5	0,8
	logsig	logsig	0,00764	0,01214	0,0001	0,5	0,8
	logsig	satlin	0,00615	0,00740	0,0001	2	0,4
<b>Três senóides (1, 3 e 5Hz)</b>	<b>satlin</b>	<b>purelin</b>	<b>0,00059</b>	<b>0,00446</b>	<b>0,0001</b>	<b>4</b>	<b>0,4</b>
	satlin	logsig	0,00960	0,01411	0,0001	0,5	0,4
	satlin	satlin	0,03513	0,04312	0,0001	1	0,4
	logsig	purelin	0,00420	0,00755	0,0001	0,5	0,4
	logsig	logsig	0,01286	0,02255	0,0001	0,5	0,4
	logsig	satlin	0,02029	0,02492	0,0001	4	0,4

De um modo geral, a combinação de funções satlin/purelin foi a que alcançou o melhor resultado para os três tipos de sinais, tanto na fase de treinamento quanto na fase de validação, com valores  $\tilde{\zeta}$  da ordem de  $10^{-4}$ . A aplicação de funções de ativação linear por partes (que é o caso da satlin) é de fato, recomendada na maioria das redes neurais “*feedforward*”. Por serem funções “quase” lineares, elas preservam muitas das propriedades dos modelos lineares, como por exemplo, a convergência mais fácil dos métodos de otimização baseados em gradiente e a boa capacidade de generalização, além de serem menos suscetíveis ao problema de não propagação dos gradientes ao longo das camadas (“*vanishing*”) [45]. É possível observar ainda que o uso da função purelin na camada decodificadora conferiu melhor desempenho aos modelos, seja na codificação com

a satlin ou com a logsig (as duas configurações com os menores erros de reconstrução  $\tilde{\zeta}$ , respectivamente). Funções puramente lineares são geralmente utilizadas nas camadas de saída em redes de regressão, por não alterarem a entrada dos neurônios, retornando os valores recebidos diretamente. Em razão do SAE tentar modelar a relação existente entre as variáveis dos dados, a reconstrução dos sinais dinâmicos pode ser interpretada como um tipo de problema de regressão, o que de certa forma, explica o bom desempenho dos modelos com a função purelin na decodificação. Ressalta-se que, apesar da maior probabilidade de sofrer “*vanishing*”, as redes cuja decodificação purelin foi aplicada com a função logsig na camada codificadora também apresentaram baixos valores de  $\tilde{\zeta}$ , podendo ser uma boa opção na modelagem dos sinais senoidais. No que se refere à complexidade dos dados e ao aumento do erro de reconstrução, nenhuma relação foi verificada, com exceção dos erros de validação para três senóides, que foram ligeiramente maiores do que os erros de validação dos outros dois tipos de sinais mas, mesmo assim, não para todas as combinações de funções. Também não foi constatada qualquer relação entre o uso da função de ativação não-linear (logsig) e a melhora de desempenho dos modelos. Destaca-se por fim que, em todos os casos, os erros de reconstrução ao utilizar os dados de validação foram inferiores aos erros obtidos com os dados treinamento, conforme o esperado, uma vez que o primeiro grupo de dados foi usado para treinar o SAE, e o segundo era desconhecido pelos modelos criados.

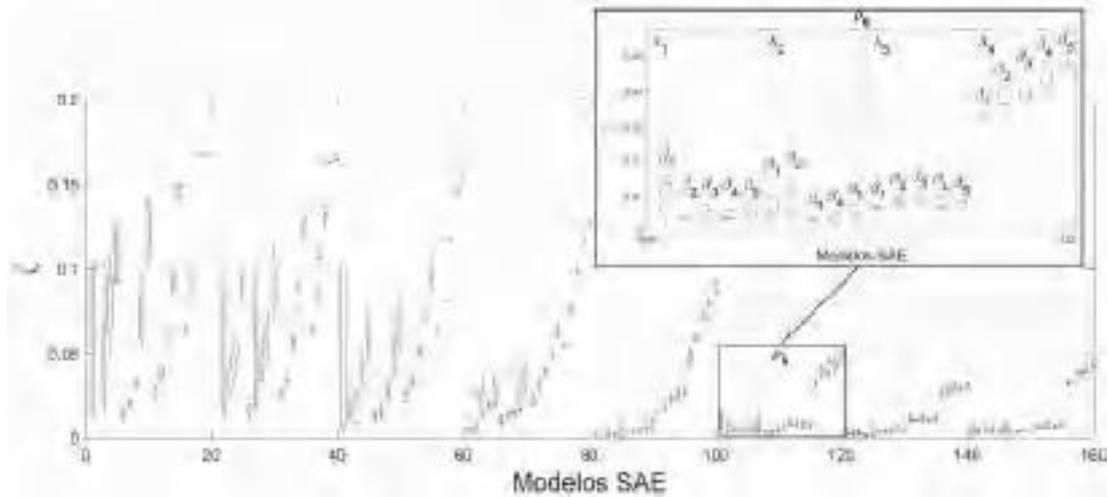
#### 4.2 HIPERPARÂMETROS $\rho$ , $\lambda$ e $\beta$

Em razão de ter obtido os menores  $\tilde{\zeta}$ , o par de funções de ativação satlin/purelin (codificação/decodificação) será o padrão adotado em todas as análises realizadas daqui para frente. Desta forma, as Figuras 10 e 11 exibem a variação de  $\tilde{\zeta}$  (do conjunto de treinamento e validação, respectivamente) para cada uma das combinações  $\lambda$ ,  $\beta$  e  $\rho$  (dentre as 160 possíveis) averiguadas no procedimento de busca exaustiva que definiu os melhores hiperparâmetros relacionados aos dados dos modelos satlin/purelin da Tabela 2. Cada caixa do diagrama das Figuras 10 e 11 compreende os resultados alcançados para 5 modelos SAE diferentes. A cada 20 conjuntos de 5 modelos (20 caixas do diagrama), tem-se um valor de  $\rho$  avaliado (do total de 8) para todos os valores de  $\lambda$  e  $\beta$ , conforme o detalhe da Figura 10(a), respeitando a ordem das Eq.(4.8), (4.9) e (4.10).

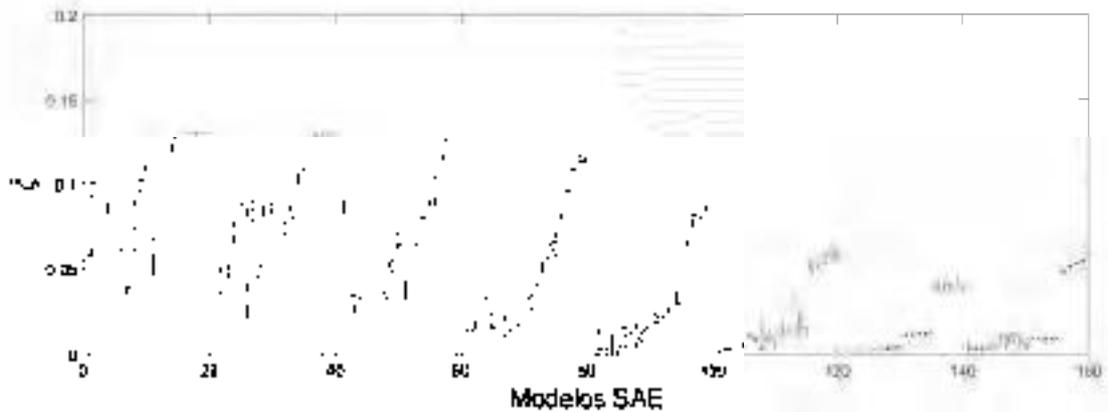
De maneira geral, os gráficos de erro  $\tilde{\zeta}$  em função dos hiperparâmetros empregados no procedimento de busca exaustiva apresentam comportamento similar para os três tipos de sinais, em ambas as fases analisadas (treino e validação). Além da menor dispersão de  $\tilde{\zeta}$  para os valores mais altos de  $\rho$ , identifica-se também uma tendência de redução e estabilização do erro à medida que o valor de  $\rho$  aumenta. Ao contrário do que acontece com  $\lambda$ , onde os erros de reconstrução tendem a piorar com o seu crescimento, sendo possível notar até 4 patamares de erros, associados aos diferentes  $\lambda$ , a depender do valor

Figura 10 – Variação do erro médio de reconstrução  $\tilde{\zeta}$  dos 5 modelos SAE satlin/purelin considerando todas as combinações de hiperparâmetros  $\rho$ ,  $\lambda$  e  $\beta$  do procedimentos de busca exaustiva - conjunto de treinamento.

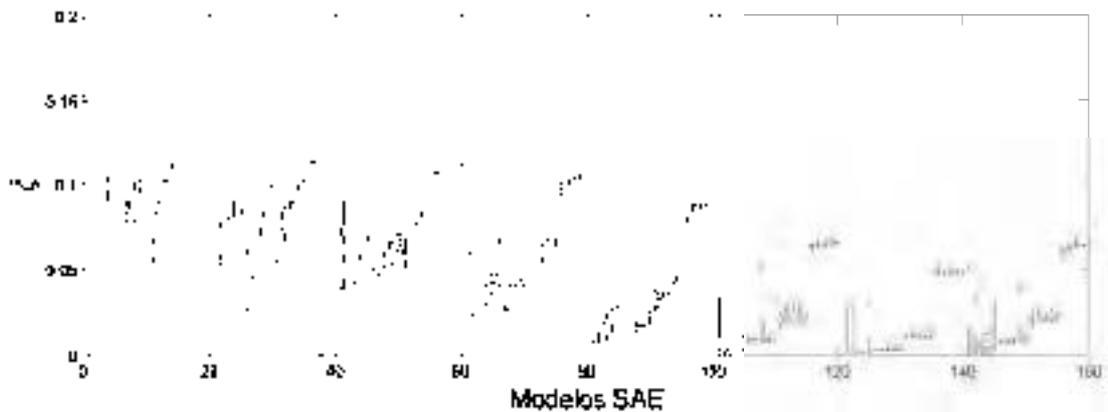
(a) Box plot para sinais compostos por uma senóide.



(b) Box plot para sinais compostos por duas senóides.



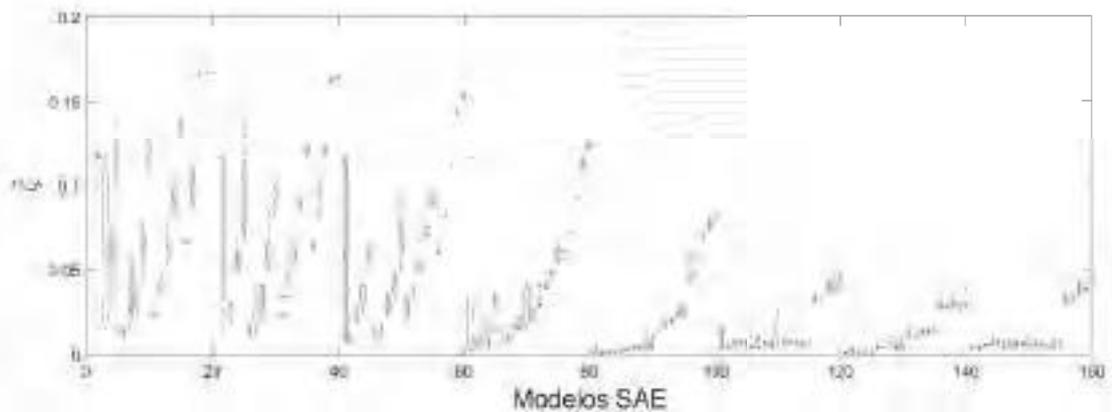
(c) Box plot para sinais compostos por três senóides.



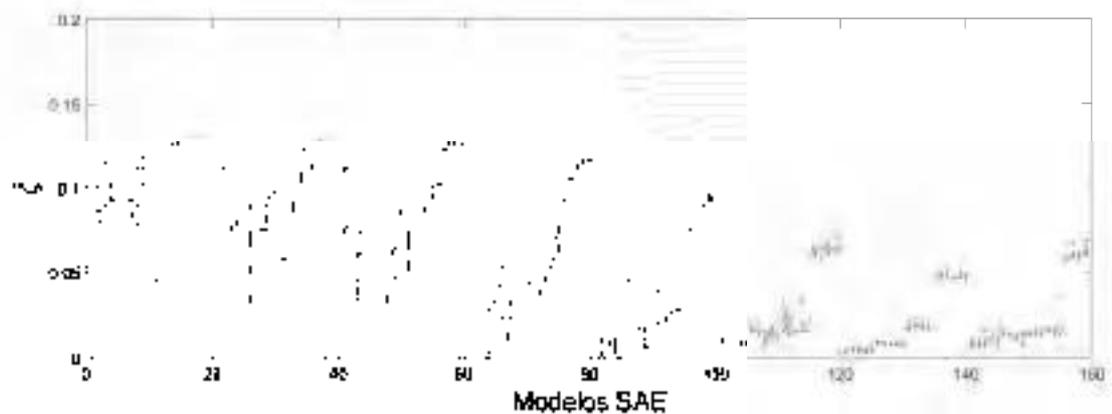
de  $\rho$ . Contudo, com relação a  $\beta$ , não se observa nenhuma relação evidente com o erro  $\tilde{\zeta}$ , podendo ser interpretado como um parâmetro de ajuste fino. Cabe ressaltar ainda que os

Figura 11 – Variação do erro médio de reconstrução  $\tilde{\zeta}$  dos 5 modelos SAE satlin/purelin considerando todas as combinações de hiperparâmetros  $\rho$ ,  $\lambda$  e  $\beta$  do procedimentos de busca exaustiva - conjunto de validação.

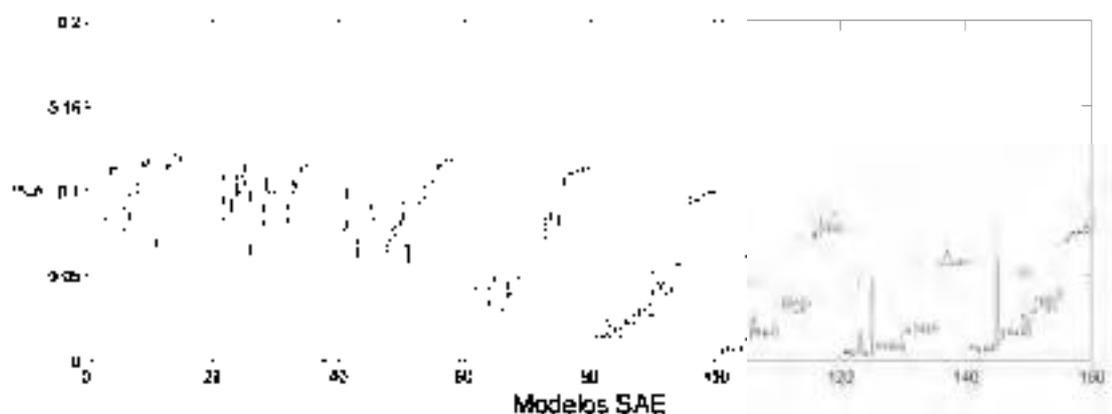
(a) Box plot para sinais compostos por uma senóide.



(b) Box plot para sinais compostos por duas senóides.



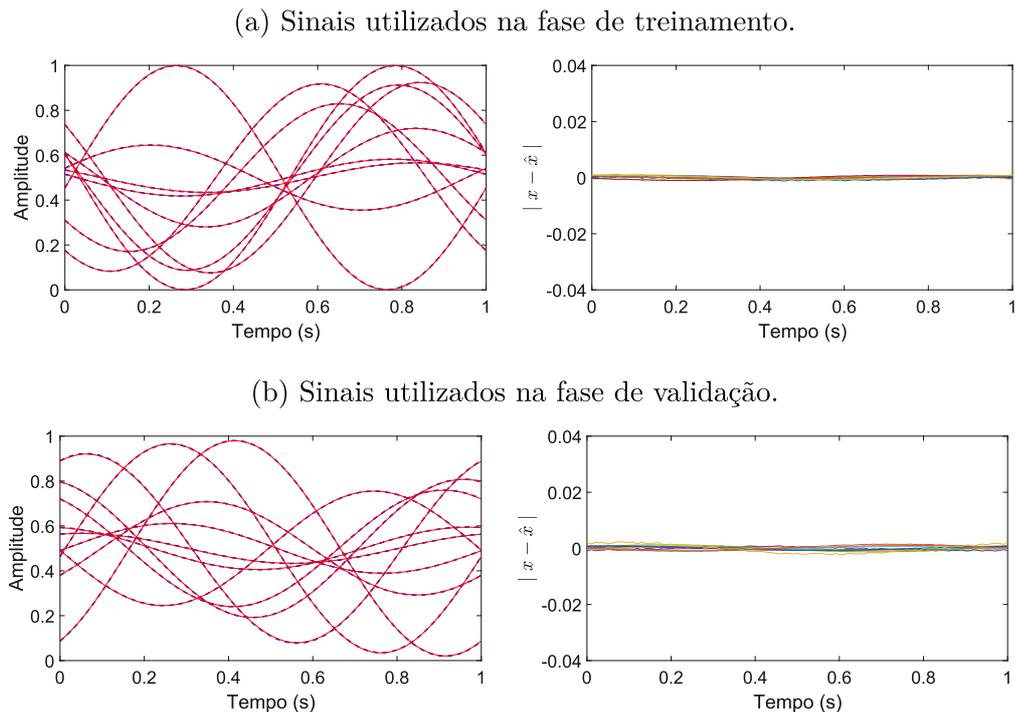
(c) Box plot para sinais compostos por três senóides.



parâmetros dos modelos 82 da Figura 11(a) e 124 das Figuras 11(b) e 11(c), apontados pelos gráficos como os que permitiram os melhores desempenhos, são os mesmos dos modelos de combinação satlin/purelin indicados na Tabela 2 (todos coincidentemente com  $\lambda = 0,0001$ ). Com o intuito de representar visualmente o desempenho de tais modelos,

as Figuras 12, 13 e 14 mostram 10 exemplos de respostas reconstruídas pelo SAE em comparação com os seus respectivos sinais originais, bem como os resíduos da reconstrução  $|x - \hat{x}|$  a eles associados. A eficiência do algoritmo SAE para a modelagem dos dados gerados fica evidente ao confrontar as senóides originais e as por ele reconstruídas. Apesar de nas análises anteriores não ter sido verificada uma relação direta entre o aumento da complexidade dos dados e maiores erros de reconstrução, nota-se pelos valores dos resíduos que o desempenho dos modelos caem ligeiramente com a evolução da complexidade das respostas. Entretanto, como a ideia por trás da modelagem via SAE é generalizar o comportamento dos dados, e não reproduzi-los perfeitamente, esse aumento nos valores dos resíduos era esperado. Já o aspecto senoidal dos resíduos pode ser explicado pela própria formulação desse tipo de erro, que simplesmente calcula a diferença entre os dados originais e reconstruídos, e portanto, tende a apresentar variações similares àquelas presentes no sinal.

Figura 12 – Respostas geradas com uma componente harmônica e seus respectivos sinais reconstruídos pelo SAE e resíduos  $|x - \hat{x}|$ .



#### 4.3 QUANTIDADE DE SINAIS PARA O TREINAMENTO

Nesta análise, além dos três níveis de complexidade (senóides com uma, duas e três componentes harmônicas), serão também incluídos aos sinais os quatro níveis de ruídos definidos no início do capítulo (sem ruído, 1%, 2,5% e 4%). Com exceção da quantidade exemplos de treinamento, foco desta etapa, os demais parâmetros adotados são os mesmos das análises anteriores, a saber: senóides com 1s de duração (100 pontos amostrados), 10 neurônios na camada interna, combinação de funções de ativação satlin/purelin e

Figura 13 – Respostas geradas com até duas componentes harmônicas e seus respectivos sinais reconstruídos pelo SAE e resíduos  $|x - \hat{x}|$ .

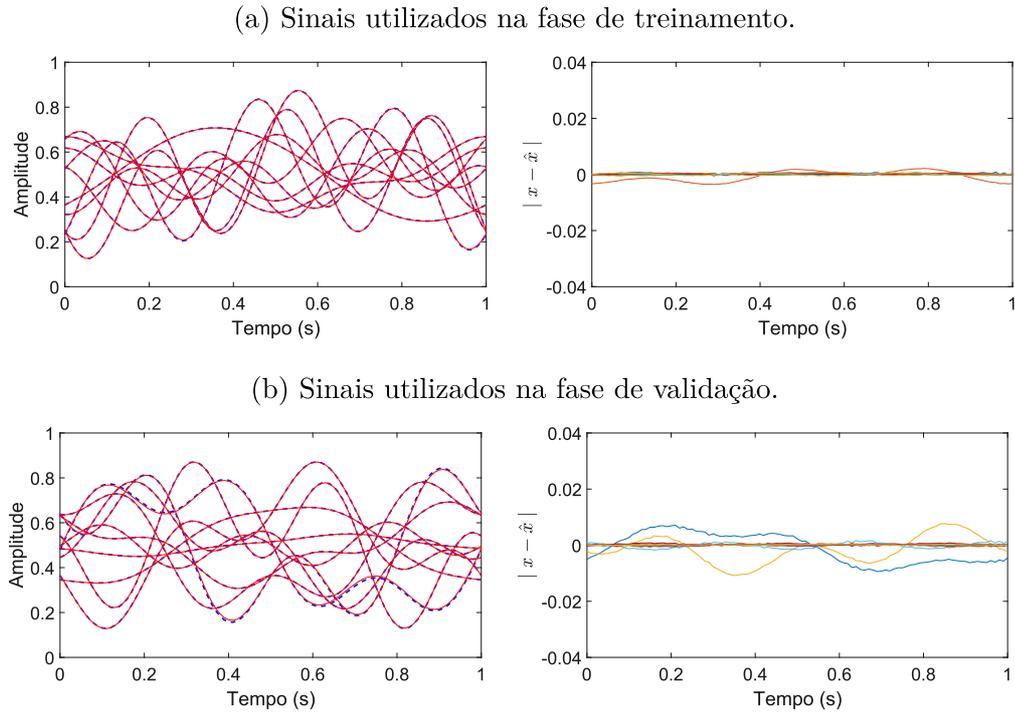
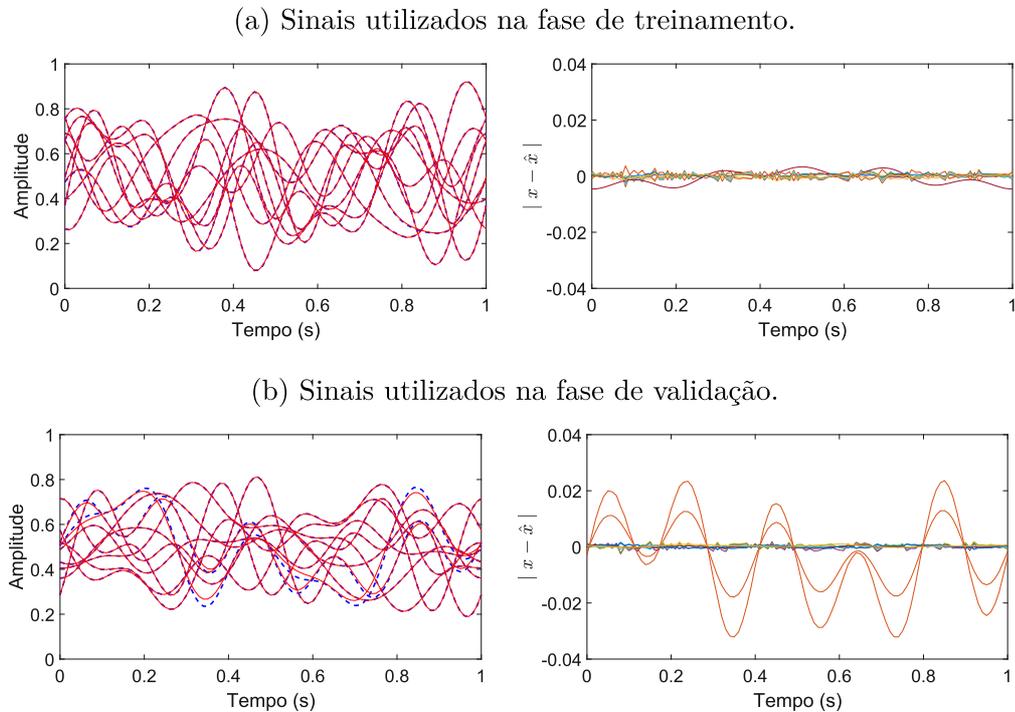


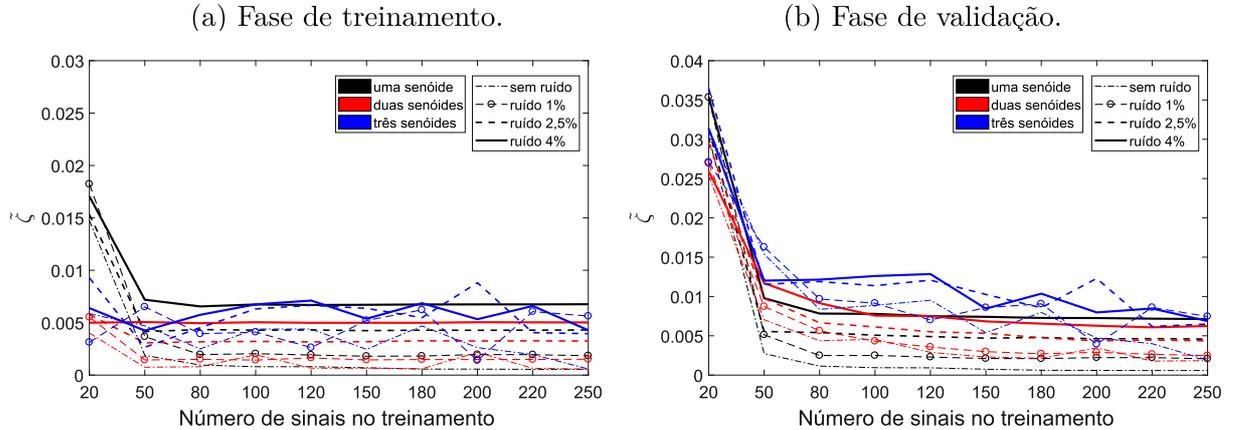
Figura 14 – Respostas geradas com até três componentes harmônicas e seus respectivos sinais reconstruídos pelo SAE e resíduos  $|x - \hat{x}|$ .



seus hiperparâmetros correspondentes (registrados na Tabela 2). Para cada tamanho de conjunto de treinamento especificado na Tabela 1 foram construídos 30 modelos SAE diferentes. A Figura 15 apresenta a média de  $\tilde{\zeta}$  alcançada pelos 30 modelos para os casos considerados. Ressalta-se que, para cada conjunto de treinamento avaliado, tem-se um

conjunto de dados de validação equivalente (com a mesma quantidade de sinais que o primeiro), gerados com as mesmas características.

Figura 15 – Variação do erro  $\tilde{\zeta}$  em função do tamanho do conjunto de dados de treinamento.



Observando ambos os gráficos, de treinamento e validação, pode-se dizer que os conjuntos de treinamento com no mínimo 50/80 exemplos de dados parecem ser suficientes para a reconstrução eficiente das senóides, uma vez que na grande maioria dos casos o erro tende a se estabilizar a partir desses valores. Outras observações que podem ser extraídas da Figura 15:

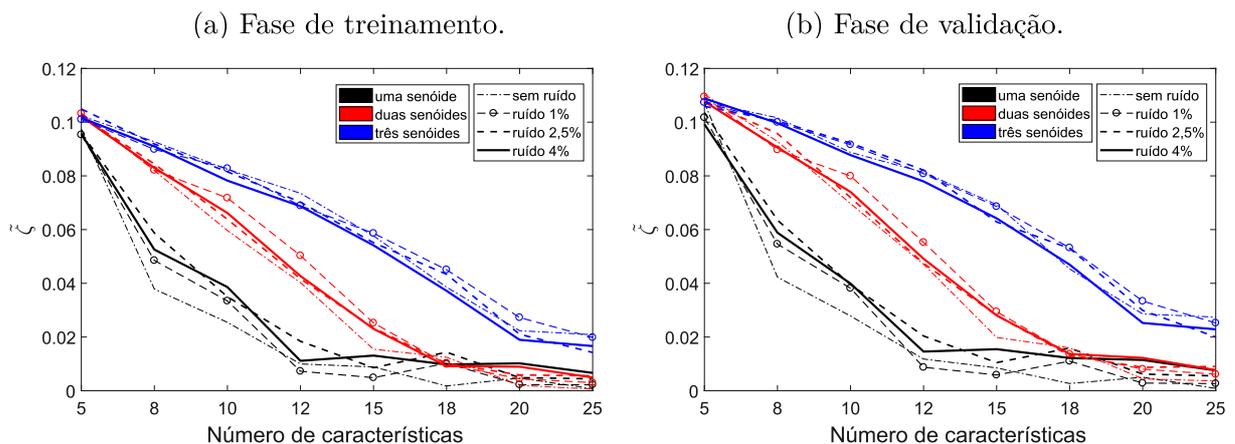
- Os resultados apontam, que para as respostas senóidais aqui estudadas (1s - 100 pontos amostrados), um conjunto de dados com uma quantidade de sinais próxima à metade do seu tamanho original são suficientes para atingir baixos valores de  $\tilde{\zeta}$ ;
- Durante a fase de treinamento, não é possível constatar nenhuma relação direta entre o grau de complexidade dos sinais e a magnitude dos erros  $\tilde{\zeta}$ , uma vez que, neste caso, os erros de reconstrução associados a uma senóide são os mais significativos. Atribui-se esse fenômeno possivelmente ao comportamento tipicamente não linear do SAE que, em algumas situações como a presente, pode ter maiores dificuldades em reconstruir funções mais bem comportadas, onde se observa, por exemplo, um menor número de inversões de sinais de derivada, como é o caso de função definida por apenas uma senóide. Ressalta-se que este fenômeno não foi observado na fase de validação, onde percebe-se claramente que os maiores erros de reconstrução são relativos aos sinais compostos por três senóides, indicando que um melhor ajuste na fase de treinamento, não necessariamente está associado a um melhor desempenho na generalização dos dados;
- Com relação aos ruídos, nota-se que os sinais com menos ruídos tendem a fornecer erros menores e os sinais mais ruidosos erros maiores, comportamento verificado tanto na fase de treinamento, quanto na fase de validação (os erros mais baixos estão

relacionados ao menor nível de ruído, que crescem conforme o nível de ruído cresce, tanto no treinamento quanto na validação), como era de certa forma esperado.

#### 4.4 NÚMERO DE NEURÔNIOS NA CAMADA INTERNA

Em todas as análises feitas até o momento o tamanho dos sinais e o número de neurônios na camada interna do SAE estiveram fixados em 1s (100 pontos) e 10, respectivamente. Por fim as últimas duas análises, a da presente seção e a apresentada a seguir, abordam quantos códigos internos SAE  $\mathbf{h}$  são necessários e tamanho de sinal suficiente para uma boa representação das respostas estruturais dinâmicas. A Figura 16 exibem a variação do erro de reconstrução em função da dimensão do vetor  $\mathbf{h}$  (número de características do SAE). Para cada quantidade de neurônios avaliados foram construídos 30 modelos SAE diferentes, com os mesmos parâmetros da seção anterior (ver satlin/purelin - Tabela 2). Nesta análise foram utilizados sinais de 1s, também com três níveis de complexidade e quatro níveis de ruído.

Figura 16 – Variação do erro  $\zeta$  em função do número de características SAE.



Observando-se os gráficos dispostos Figura 16, cujo o comportamento geral dos erros de treinamento e dos respectivos erros de validação é praticamente o mesmo, pode-se afirmar que:

- O número de características necessárias para atingir uma certa estabilização do erro aumenta conforme a complexidade do sinal aumenta. Para sinais constituídos de uma senóide, em torno de 15 características já é possível perceber a estabilização do erro, enquanto que para duas e três senóides o erro estabiliza com 18 e 20 características, respectivamente;
- Aparentemente sinais com mais ou menos ruídos não refletem na escolha da quantidade de número de características, já que os quatro níveis de ruído convergiram mais ou menos no mesmo ponto para os três tipos de sinais no geral. Este fato indica uma

boa capacidade do SAE em lidar com ruídos, atributo interessante para problemas de SHM, uma vez que esta característica é inerente aos sinais normalmente envolvidos nestes casos.

#### 4.5 TAMANHO DOS SINAIS

Avalia-se aqui a variação do erro de reconstrução  $\tilde{\zeta}$  em função do tamanho dos sinais senóidais. Com exceção do número de neurônios na camada interna do SAE, os parâmetros dos 30 modelos de cada configuração de sinal analisada são os mesmos da seção anterior, bem como os tipos e quantidade de sinais gerados. Observando-se os gráficos com os resultados dispostos na Figura 17, pode-se dizer que:

- Assim como ocorreu na análise precedente, o comportamento geral dos erros de treinamento e dos respectivos erros de validação é praticamente o mesmo;
- Observa-se que sinais mais curtos (até 2 segundos de duração) levam a baixos erros de treinamento e validação o que pode levar a conclusões precipitadas onde se afirma que quanto menores os sinais a serem reconstruídos pelo SAE, melhores os desempenhos do algoritmo. Esta conclusão é válida num escopo de reconstrução de sinais, mas não necessariamente se aplica a um contexto de SHM. Sinais menores poder facilitar o trabalho de reconstrução do SAE, mas não necessariamente carregam informação acerca do comportamento dinâmico da estrutura que permita identificar alterações mecânicas;
- A medida que se aumenta a complexidade dos sinais, nota-se claramente que aqueles mais complexos (com mais senóides) passam a apresentar erros maiores, o que era já esperado. Esta observação só reforça a necessidade de se analisar as particularidades de cada exemplo para se definir o comprimento dos sinais, tais como faixa de frequências envolvidas e taxas de aquisições dos sinais, para que se possa garantir que os sinais adotados necessariamente carreguem estas informações para o modelo SAE.

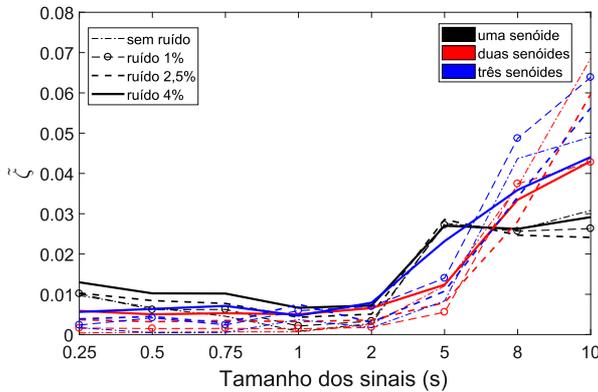
#### 4.6 CONCLUSÕES DO CAPÍTULO

Em resumo, diante dos resultados e argumentos expostos ao longo deste capítulo, pode-se elencar as seguintes conclusões:

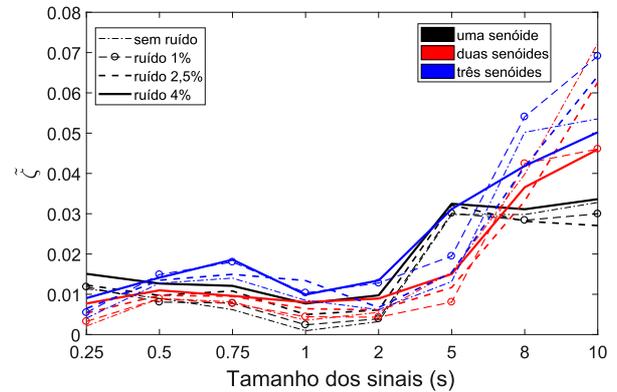
- A combinação das funções satlin na camada codificadora e purelin na camada decodificadora foi a que conferiu os melhores resultados;
- A combinação de funções logsig/purelin também levaram a baixos erros de reconstrução, podendo ser também uma boa opção na modelagem dos sinais senoidais;

Figura 17 – Variação do erro  $\tilde{\zeta}$  em função do tamanho dos sinais.

(a) Fase de treinamento.



(b) Fase de validação.



- Para os sinais aqui analisados, não foi observada relação entre o uso da função de ativação logsig (não-linear) e a melhora de desempenho dos modelos SAE;
- A combinação de hiperparâmetros  $\rho$ ,  $\lambda$  e  $\beta$  exerce grande influência no resultado final do SAE. Mais especificamente, nota-se que valores mais altos de  $\rho$  e mais baixos de  $\lambda$  estão associados à melhora no desempenho geral dos modelos, enquanto que  $\beta$  pode ser interpretado como uma variável de ajuste fino com relação ao erro de reconstrução;
- Apesar de em alguns casos ter sido verificada uma ligeira queda no desempenho dos modelos SAE com os diferentes tipos de respostas (compostas por uma, duas ou três senóides), não foi possível traçar uma relação direta entre o aumento da complexidades dos dados e maiores erros de reconstrução;
- Na análise da quantidade mínima de sinais para treinamento, os resultados alcançados para os sinais de 1s (100 pontos amostrados) indicaram que um número de dados próximo à metade da quantidade de características dos sinais foram suficientes para reconstruir as senóides;
- O número de características SAE necessárias para a modelagem dos sinais aumenta de acordo com a complexidade do sinal;
- Ainda que para os casos estudados na seção “Número de neurônios na camada interna” (sinais de 1s - 100 pontos amostrados), precisou-se de cerca de 20 características (20% do tamanho original das senóides) para uma certa estabilização do erro de reconstrução, em todos as demais análises 10 características foram suficientes para atingir bons resultados;
- Embora tenham sido observados erros de reconstrução mais baixos para as senóides de duração mais curta, entende-se que esta inferência se aplica somente ao escopo

das análises aqui apresentadas, fazendo-se necessárias maiores investigações para extrapolar tal conclusão à sinais advindos de estruturas de fato;

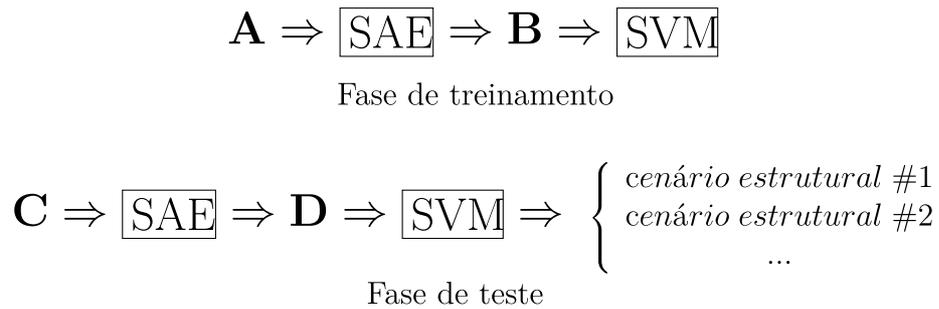
- Quanto aos ruídos, o SAE pareceu ter boa capacidade de implicitamente modelá-los, uma vez que os resultados não foram significativamente afetados pelos mesmos.

Por fim, cabe destacar que foram alcançados níveis de erros de reconstrução relativamente baixos com os modelos SAE ora apresentados, constituídos por apenas uma camada codificadora e uma camada decodificadora, indicando que, para sinais tipicamente encontrados em monitoramentos estruturais, esta arquitetura parece ser suficiente.

## 5 METODOLOGIA SHM SUPERVISIONADA

O presente capítulo tem como propósito verificar a viabilidade do SAE como ferramenta SHM de extração de características. Por se tratar de um problema menos complexo, antes de ser utilizado dentro de uma estratégia de monitoramento não-supervisionada (objetivo principal deste trabalho e foco do próximo capítulo), o SAE é aqui avaliado em uma abordagem de detecção de alterações estruturais totalmente supervisionada. A proposta é aplicar o SAE às respostas dinâmicas (expressas diretamente no domínio do tempo) para “aprender” características relevantes dos dados e usar o algoritmo SVM para classificá-las de acordo com as suas respectivas condições estruturais. Sinais de vibração simulados por um modelo numérico de viga e adquiridos em um viaduto rodoviário brasileiro são considerados nesta abordagem. A metodologia SHM supervisionada adotada, ilustrada na Figura 18, pode ser descrita pelas seguintes etapas:

Figura 18 – Estratégia SHM supervisionada.



### 1. Fase de treinamento

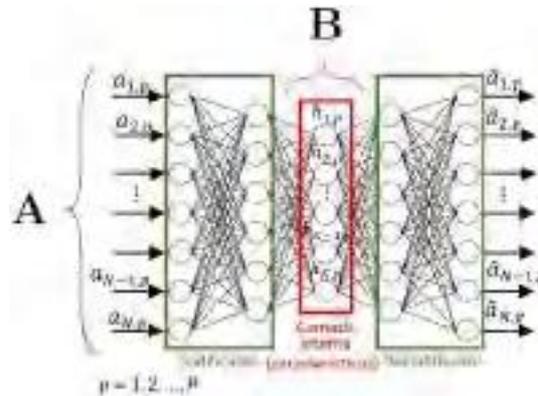
#### a) Organização dos dados

Os dados de treinamento, que nada mais são que um subconjunto aleatório da matriz de respostas dinâmicas  $\mathbf{X}_{N \times Q}$  ( $N$  pontos amostrados  $\times$   $Q$  sinais), são organizados em uma matriz  $\mathbf{A}_{N \times P}$ , sendo  $P$  a quantidade de sinais considerados na fase de treinamento. Ressalta-se que assim como  $\mathbf{X}$ ,  $\mathbf{A}$  contém as respostas dinâmicas da estrutura em questão para os diversos níveis de degradação nela existentes.

#### b) Caracterização dos dados via SAE

Um modelo SAE é criado a partir da matriz  $\mathbf{A}$  para extrair informações representativas dos dados. Vale lembrar que a quantidade  $K$  de características obtida por sinal é dada pelo n<sup>o</sup> de neurônios estipulado para a camada interna do SAE. Dessa forma, para cada vetor de sinal  $\mathbf{x}$  contido em  $\mathbf{A}$ , um vetor de características  $\mathbf{h}$  correspondente é construído pelo SAE ( $\mathbf{h}$  com  $K$  posições, onde  $K \ll N$ ). Tais vetores  $\mathbf{h}$  formam a matriz de características  $\mathbf{B}_{K \times P}$ . A Figura 19 exemplifica o esquema de processamento realizado nesta etapa.

Figura 19 – Esquema de processamento realizado pelo SAE.



### c) Classificação com SVM

Por se tratar de um problema de reconhecimento de padrões supervisionado, a matriz  $\mathbf{B}$  e seu respectivo vetor alvo  $\mathbf{t}_B$  (que apontam a condição estrutural a qual cada sinal pertence) são utilizados para treinar um modelo SVM de classificação.

## 2. Fase de teste

Nesta última parte, o desempenho dos modelos SAE/SVM é avaliado para o conjunto de sinais dinâmicos  $\mathbf{C}_{N \times M}$  ( $N$  pontos amostrados  $\times M$  sinais) que não foram utilizados na fase anterior. A matriz  $\mathbf{C}_{N \times M}$  (subconjunto restante de  $\mathbf{X}_{N \times Q}$  onde  $M = Q - P$ ) é repassada à rede SAE treinada, resultando em uma matriz  $\mathbf{D}_{K \times M}$  constituída pelos respectivos  $M$  vetores  $\mathbf{h}$  de  $K$  características. Por fim, a matriz  $\mathbf{D}$  é apresentada ao SVM treinado, cujas saídas indicam a condição estrutural de cada um dos dados.

Cabe mencionar que outros algoritmos podem ser aplicados para executar a tarefa de classificação, como regressões lineares e não-lineares, Redes Neurais Artificiais e *Clusterização*. Os trabalhos de Cury & Crémona (2012) [84], Finotti *et al.* (2016) [111] e Cardoso *et al.* (2019) [112] são dedicados a esse tipo de análise. No entanto, como a estratégia SHM aqui apresentada tem a finalidade de avaliar a capacidade do SAE em representar corretamente as respostas dinâmicas estruturais, e não foca no desempenho do classificador em si, optou-se somente pela classificação com SVM, que geralmente fornece resultados competitivos.

## 5.1 APLICAÇÃO I - MODELO NUMÉRICO DE VIGA BIAPOIADA

A caracterização dos sinais de vibração usando SAE é inicialmente avaliada em dados sintéticos obtidos por um modelo numérico de viga biapojada de concreto, conforme representado na Figura 20. A viga, modelada com doze elementos de Euller-Bernoulli

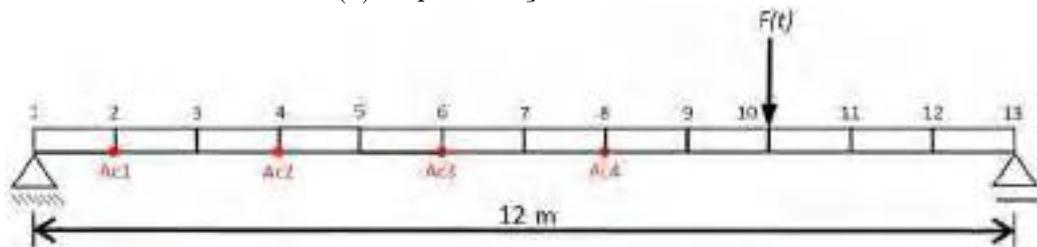
(formados por dois nós, com dois graus de liberdade cada um - rotação e translação vertical), possui as seguintes propriedades: seção transversal retangular de base=0,2m e altura=0,654m, com área= 0,13m<sup>2</sup>; comprimento total = 12m; módulo de elasticidade longitudinal ( $E$ )= 25GPa; massa específica = 2500kg.m<sup>-3</sup> e; momento de inércia = 4,66 × 10<sup>-3</sup>m<sup>4</sup>. A força de excitação externa  $F(t)$  aplicada ao nó 10 (ver Figura 20(a)) é um vetor de ruído com magnitude máxima de 100N, definido aleatoriamente para cada ensaio dinâmico simulado.  $F(t)$  (N) é descrita pela Eq.(5.1):

$$F(t) = 100 \times V \sim D(0, 1) \quad (5.1)$$

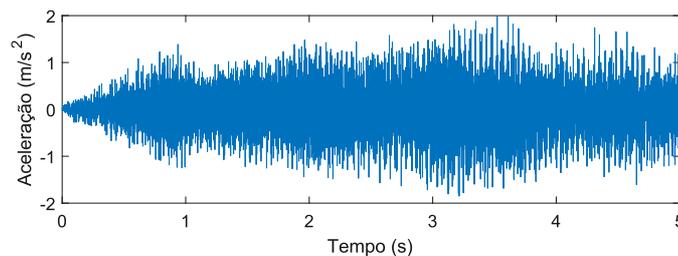
onde  $V \sim D(0, 1)$  é um vetor com valores aleatórios extraídos de uma distribuição uniforme no intervalo de 0 à 1. Na Figura 20(b), tem-se um exemplo da resposta típica da estrutura modelada para a força de excitação aleatória  $F(t)$ .

Figura 20 – Modelo numérico de viga biapoada.

(a) Representação do modelo.



(b) Resposta típica.



Três cenários estruturais foram retratados: viga sem dano, dano nível #1 e dano nível #2. Os níveis de dano #1 e #2 correspondem, respectivamente, à redução de 10% e 20% no módulo de elasticidade longitudinal ao longo da viga (um tipo de degradação estrutural originada pela Reação Álcali-Agregado, por exemplo, que gera fissuração e perda de resistência do concreto [113]). As respostas dinâmicas verticais dos pontos 2 (Ac1), 4 (Ac2), 6 (Ac3) e 8 (Ac4) foram registradas em termos de aceleração, com 5s de duração cada uma e 5001 pontos amostrados (frequência de amostragem de 1000 Hz). As frequências naturais da estrutura em todos os cenários assumidos são fornecidas na Tabela 5.1 para fins de informação.

Trezentos ensaios dinâmicos foram simulados para cada estágio de dano, totalizando 900 históricos de aceleração por ponto de medição. Destaca-se que a abordagem proposta

Tabela 3 – Variação das frequências naturais do modelo numérico de viga biapoiada.

Cenário estrutural	1 <sup>a</sup> frequência natural	2 <sup>a</sup> frequência natural	3 <sup>a</sup> frequência natural	4 <sup>a</sup> frequência natural
Sem dano	6.51Hz	26.05Hz	58.63Hz	104.28Hz
Dano nível #1	6.18Hz	24.71Hz	55.62Hz	98.93Hz
Dano nível #2	5.82Hz	23.30Hz	52.44Hz	93.27Hz

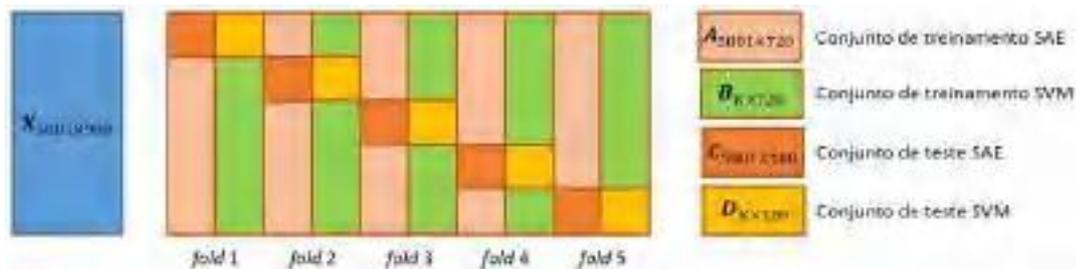
será avaliada investigando-se os sinais de cada ponto de medição separadamente. Assim, todo o conjunto de dados é organizado em quatro matrizes de entrada  $[5001 \times 900]$ , de acordo com a posição onde as respostas estruturais foram medidas (Ac1, Ac2, Ac3 e Ac4). Como a classificação do dano é realizada por um SVM de aprendizado supervisionado, é preciso apontar o cenário ao qual cada ensaio pertence. Por esta razão, são gerados também vetores alvo de 900 elementos, indicando a categoria do sinal através da seguinte codificação: 1 - Sem dano; 2 - Dano nível #1 e, 3 - Dano nível #2. É importante ressaltar que o vetor alvo só é utilizado efetivamente na fase de treinamento do SVM. Durante a fase de teste, esses rótulos não têm participação direta na classificação e são aplicados apenas para comparar os resultados obtidos pelo SVM com o nível real de degradação da estrutura.

Antes de serem processadas pelo SAE, todos os sinais são normalizados para valores de amplitude variando entre  $[0,1]$  (a mesma faixa de valores empregada no capítulo de “*Análise de sensibilidade*”). Posteriormente, a matriz **A**, formada por parte dos dados registrados, é usada na construção do modelo SAE para “aprender” características representativas diretamente das respostas de aceleração expressas no domínio do tempo. Na etapa seguinte, ainda na fase de treinamento, os atributos extraídos da matriz **A** pelo SAE, aqui intitulada como matriz **B**, são repassados como dados de entrada para um algoritmo SVM que cria um modelo com o objetivo de detectar as classes de dano correspondentes. Ao final, na fase de teste, o restante dos dados - matriz **C** e sua decorrente matriz **D**, não utilizadas no treinamento - são apresentados aos modelos SAE/SVM para observar a sua real eficácia ao indicar os estágios de dano presentes na estrutura. A fim de garantir que todos os cenários estruturais sejam igualmente representados nos modelos SAE e SVM, as matrizes **A** e **B** devem ter aproximadamente o mesmo número de dados de cada nível de dano (conjunto de dados balanceado)[114].

Sabendo que a quantidade de características SAE é um fator determinante na etapa de processamento dos dados, em primeiro lugar é investigado o número de códigos internos SAE necessários para a reconstruir satisfatoriamente os sinais da viga, para então avaliar a capacidade do SAE de representar corretamente as respostas dos diferentes cenários estruturais. Na primeira análise, diferentes quantidades  $K$  de neurônios (códigos internos **h**) foram examinadas em função do erro médio de reconstrução  $\tilde{\zeta}$  (Eq.(4.7) apresentada

no capítulo anterior) e da acurácia obtida por um classificador SVM. Para cada número de neurônio considerado, a matriz de entrada - e, conseqüentemente, o vetor alvo - foi subdividida aleatoriamente em outras duas matrizes, alocando 50% dos dados para a fase de treinamento (matriz  $\mathbf{A}[5001 \times 450]$  e matriz  $\mathbf{B}[K \times 450]$ ) e os outros 50% restantes para a fase de teste (matriz  $\mathbf{C}[5001 \times 450]$  e matriz  $\mathbf{D}[K \times 450]$ ), seguindo os passos da metodologia SHM proposta no início do capítulo. Uma vez definido o número de características a serem extraídas por sinal, a segunda análise se preocupa exclusivamente em avaliar o desempenho do SAE/SVM como ferramenta SHM de detecção de dano. Nesse caso, os modelos de detecção de danos estruturais são treinados segundo o método de validação cruzada *5-fold* (ver capítulo 3, final da seção 3.1). Ou seja, a matriz de entrada é dividida aleatoriamente em 5 subgrupos, onde 4/5 dos dados são usados para treinamento (matriz  $\mathbf{A}[5001 \times 720]$  e matriz  $\mathbf{B}[K \times 720]$ ) e 1/5 para teste (matriz  $\mathbf{C}[5001 \times 180]$  e matriz  $\mathbf{D}[K \times 180]$ ), conforme ilustra o esquema da Figura 21.

Figura 21 – Esquema 5-fold de avaliação do desempenho dos modelos SAE/SVM.



A Tabela 4 mostra os parâmetros utilizados na construção dos modelos SAE e SVM para a viga estudada. Ressalta-se que os modelos SAE foram implementados levando em consideração os resultados da análise de sensibilidade realizada no capítulo 4, ou seja, apenas uma camada codificadora e uma decodificadora, cujos parâmetros são os mesmos adotados para os sinais de três senóides e combinação de funções de ativação satlin/purelin. Entende-se que, dentre os casos estudados, os sinais com 3 componentes senoidais são os que mais se assemelham àqueles advindos de estruturas reais. Quanto ao classificador SVM, a função kernel de base radial e a estratégia de classificação um contra um são normalmente as mais utilizadas na literatura. Os parâmetros  $\sigma$  e  $C$  relacionados à função RBF, estimados através do procedimento de busca exaustiva em grade com validação cruzada *5-fold*, serão apresentados mais adiante junto com os resultados alcançados para cada caso analisado.

### 5.1.1 Resultados

Conforme mencionado anteriormente, a primeira fase da presente análise investiga quantos códigos internos SAE ( $\dim(\mathbf{h})$ ) são necessários para uma boa representação das respostas estruturais dinâmicas do exemplo numérico de viga. A Figura 22 exhibe através de gráficos *boxplot* a evolução do erro de reconstrução médio  $\tilde{\zeta}$  em função do aumento do

Tabela 4 – Estratégia SHM supervisionada: Parâmetros SAE e SVM para o exemplo da viga numérica.

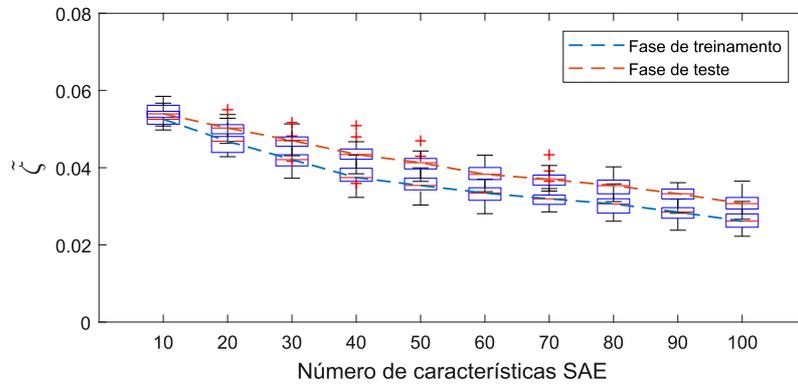
<b>Parâmetros SAE</b>	
Proporção de esparsidade ( $\rho$ )	0,4000
Regularização de esparsidade( $\beta$ )	4,0000
Regularização dos pesos ( $\lambda$ )	0,0001
Função de ativação codificadora/decodificadora	satlin/purelin
Método de otimização	SCG
Valor máximo do gradiente	$1,00 \times 10^{-6}$
Quantidade máxima de épocas de treinamento	1000
Métrica de erro de treinamento	média quadrática
<b>Parâmetros SVM</b>	
Função kernel	RBF
Esquema de codificação multiclasse	um contra um

número de características SAE obtida em cada um dos pontos de medição da viga. Cada *box* é formado pelo erro de 30 modelos SAE, construídos para reduzir a dimensionalidade dos sinais de 5001 pontos amostrados para os números de características indicados nos gráficos. Os 30 modelos SAE são modelos autocodificadores diferentes entre si, isto é, desenvolvidos com os mesmos parâmetros, mas com sementes aleatórias variadas. Os *boxes* associados à linha tracejada azul indicam o valor de  $\tilde{\zeta}$  alcançado pelos 30 modelos para o conjunto de dados de treinamento (matriz **A**). Por outro lado, os *boxes* relacionados com a linha tracejada vermelha correspondem ao valor  $\tilde{\zeta}$  calculado para os mesmos modelos, porém quando submetidos aos dados do conjunto de teste (matriz **C**). As acurácias obtidas pelos classificadores SVM para as respectivas matrizes de características **B** e **D** relativas à Figura 22 estão apresentadas na Tabela 5. Em tais tabelas, separadas por acelerômetros, constam as taxas médias de classificação (acurácia = n° de acertos / n° total de dados classificados) alcançadas durante a fase de teste pelos 30 modelos de cada caso analisado, bem como os parâmetros  $\sigma$  e  $C$  dos classificadores SVM.

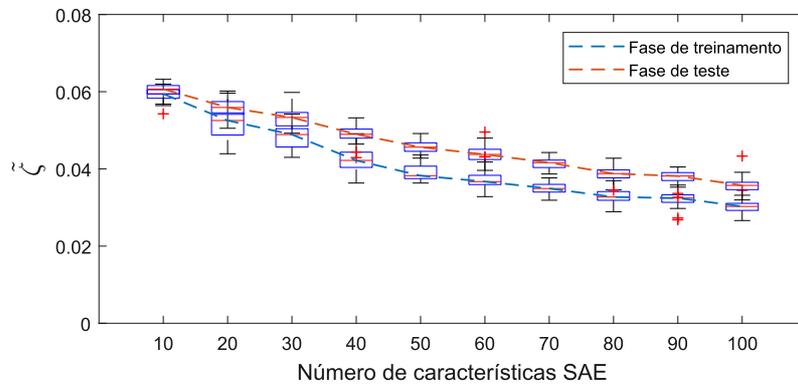
É possível observar que as curvas que relacionam o erro de reconstrução  $\tilde{\zeta}$  com a quantidade de características SAE, traçadas na Figura 22, são bastante semelhantes para todos os canais de acelerômetro simulados. Seja qual for o ponto de medição, a mediana dos erros de treinamento e teste tende a reduzir à medida que o número de características **h** aumenta, com valores  $\tilde{\zeta}$  de aproximadamente 0.06 para modelos SAE com 10 características e  $\tilde{\zeta}$  em torno de 0.03 para modelos SAE com 100 características (a menor e a maior quantidade analisadas, respectivamente). O que parece óbvio na lógica de funcionamento do SAE, uma vez que quanto maior for número de características, melhor será a reconstrução do sinal e, conseqüentemente, menor será o erro. Pode-se notar ainda que os erros  $\tilde{\zeta}$  dos dados de treinamento são menores do que os obtidos para os dados de avaliação, independentemente do número de características SAE, comportamento também verificado para os exemplos tratados no capítulo 4.

Figura 22 – Número de características SAE  $\times$  Erro médio de reconstrução  $\tilde{\zeta}$  para a viga numérica.

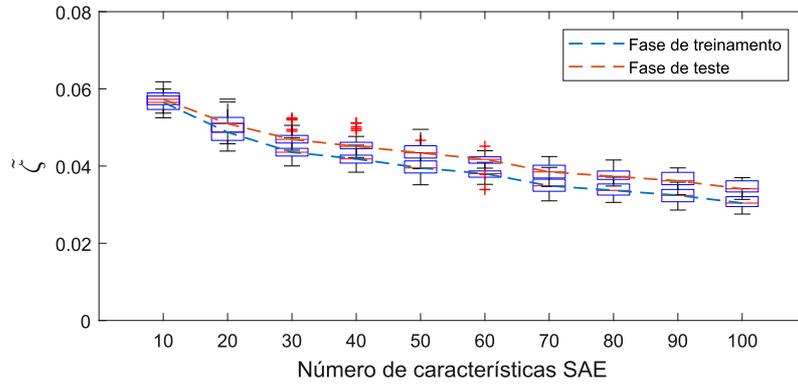
(a) Ponto de medição Ac1.



(b) Ponto de medição Ac2.



(c) Ponto de medição Ac3.



(d) Ponto de medição Ac4.

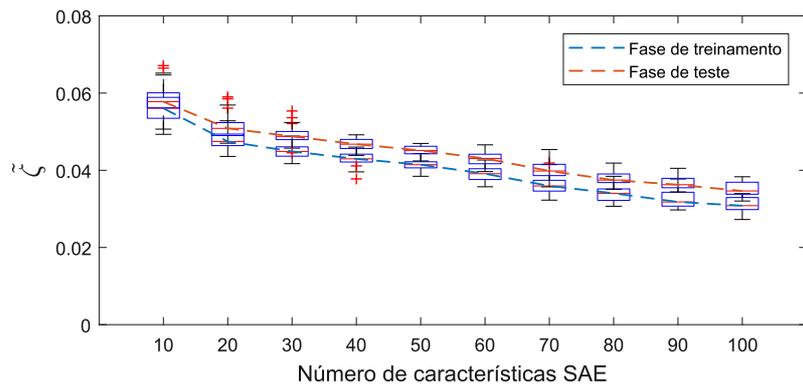
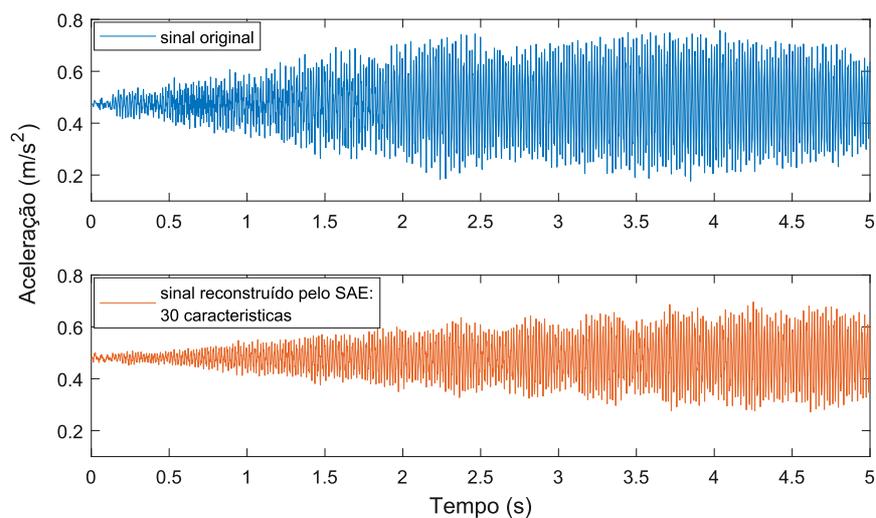


Tabela 5 – Resultados de classificação SVM em função do número de características SAE para a viga numérica.

Dim(h)	Média (%)	Melhor classificação (%)	Pior classificação (%)	Desvio-padrão (%)	$\sigma$	C
<b>Ponto de medição Ac1</b>						
10	87,13	98,67	28,22	18,67	0,6310	31,6228
20	96,78	99,56	90,00	2,61	0,3981	1,0000
30	<b>99,37</b>	<b>100,00</b>	<b>98,44</b>	<b>0,43</b>	<b>1,0000</b>	<b>0,3162</b>
40	99,61	100,00	98,67	0,35	1,0000	0,3162
50	99,56	100,00	97,11	0,56	0,7943	1,0000
60	99,88	100,00	98,89	0,25	1,0000	1,0000
70	99,82	100,00	99,11	0,26	1,0000	1,0000
80	99,79	100,00	98,89	0,31	1,5000	0,3162
90	99,98	100,00	99,78	0,06	1,5000	1,0000
100	99,74	100,00	96,00	0,86	1,5000	0,3162
<b>Ponto de medição Ac2</b>						
10	78,37	98,89	37,78	20,90	0,5000	4,0000
20	98,78	100,00	94,00	1,41	0,7943	0,3162
30	<b>99,77</b>	<b>100,00</b>	<b>99,33</b>	<b>0,23</b>	<b>0,7943</b>	<b>1,0000</b>
40	99,01	100,00	94,22	1,31	0,7943	0,5000
50	99,95	100,00	99,56	0,11	1,0000	0,5000
60	99,98	100,00	99,78	0,06	1,5000	0,3162
70	99,38	100,00	98,22	0,49	1,0000	1,0000
80	99,98	100,00	99,78	0,06	1,5000	0,3162
90	99,99	100,00	99,78	0,04	1,5000	0,5000
100	99,98	100,00	99,78	0,06	1,5000	1,0000
<b>Ponto de medição Ac3</b>						
10	91,17	99,33	45,33	11,36	0,3162	4,0000
20	99,02	100,00	97,56	0,57	0,3981	1,0000
30	<b>99,54</b>	<b>100,00</b>	<b>98,67</b>	<b>0,36</b>	<b>0,6310</b>	<b>0,3162</b>
40	99,51	100,00	98,89	0,30	0,7943	1,0000
50	99,62	100,00	97,56	0,45	0,7943	1,0000
60	99,11	100,00	96,00	0,95	0,7943	0,5000
70	99,30	100,00	96,44	0,79	1,0000	0,3162
80	99,30	100,00	97,78	0,55	1,0000	0,5000
90	99,84	100,00	99,11	0,23	1,5000	0,3162
100	99,87	100,00	99,11	0,20	1,5000	0,3162
<b>Ponto de medição Ac4</b>						
10	88,56	99,33	30,00	20,87	0,5000	2,0000
20	99,38	100,00	98,00	0,45	0,6310	1,5000
30	<b>99,48</b>	<b>100,00</b>	<b>97,56</b>	<b>0,45</b>	<b>0,7943</b>	<b>0,3162</b>
40	96,64	100,00	52,22	9,91	0,6310	0,3162
50	99,63	100,00	98,89	0,30	0,7943	1,5000
60	99,72	100,00	98,67	0,32	1,0000	0,5000
70	99,64	100,00	98,89	0,33	1,5000	0,3162
80	99,81	100,00	98,67	0,30	1,5000	0,3162
90	99,95	100,00	99,56	0,11	1,5000	1,0000
100	99,81	100,00	98,67	0,31	1,5000	0,3162

No entanto, o foco deste trabalho não é exatamente reconstruir o sinal, mas extrair elementos-chave capazes de caracterizar as diferenças entre as respostas estruturais “normais” e “anormais”. Uma das conclusões a que se pode chegar ao analisar os resultados alcançados pelos classificadores SVM, presentes na Tabela 5, é que não é razoável associar o melhor modelo SAE diretamente ao menor erro de reconstrução. Em todos os pontos de medição, a maioria dos modelos SVM construídos utilizando entre 20 e 50 características SAE alcançaram altas taxas de classificação, com média em torno de 99% (desempenho similar aos modelos construídos com maior quantidade de características). Tal resultado pode estar de certa forma ligado à redução mais acentuada de  $\tilde{\zeta}$  percebida nas curvas da Figura 22 no intervalo de 10 a 50 características SAE do que no intervalo de 60 a 100. De fato, uma grande quantidade de características pode atrapalhar a capacidade de generalização tanto do SAE quanto do SVM, particularizando demais o modelo para aqueles dados de treinamento específicos, além de exigir maior custo computacional. Portanto, diante de tudo o que foi discutido, e considerando a boa taxa de classificação e os baixos valores de desvio, os modelos com 30 características SAE parecem ser suficientes para representar corretamente as respostas da viga numérica. Ao examinar em conjunto a Figura 22 e a Tabela 5 fica evidente que os ganhos em termos de erro, acurácia e desvio-padrão não são significativos com um número mais elevado de características. A fim de obter uma representação visual do desempenho dos modelos SAE que reduzem as medições dinâmicas a 30 características, um exemplo da resposta reconstruída da viga e seu respectivo sinal original (normalizado) é exibido na Figura 23.

Figura 23 – Comparação entre um sinal original da viga numérica e sua respectiva reconstrução feita pelo SAE.



Com o intuito de melhor avaliar a habilidade dos modelos SAE de 30 características, o desempenho alcançado por eles dentro da abordagem proposta empregando a validação cruzada *5-fold* é apresentado na Figura 24 em formato de matriz de confusão. O algoritmo SAE/SVM foi executado 30 vezes para os dados de cada um dos pontos de medição, gerando

30 modelos diferentes de detecção de danos estruturais, com os mesmos parâmetros SAE e SVM da Tabela 5, porém treinados segundo o método *5-fold*. As matrizes de confusão apontam as frequências de classificação dos exemplos de teste ao longo dos diferentes níveis de dano. Os elementos diagonais em verde correspondem a quantidade e a porcentagem de classificações corretas, enquanto os elementos em vermelho se referem à quantidade e porcentagem de dados classificados incorretamente. A coluna mais à direita da matriz exibe a métrica de precisão (verdadeiros positivos / (verdadeiros positivos + falsos positivos)) e a linha na parte inferior expõe a métrica de revocação ou “*recall*” (verdadeiros positivos / (verdadeiros positivos + falsos negativos)). O elemento na parte inferior direita do gráfico representa a taxa de classificação (acurácia) geral. A “Classe de saída” corresponde ao nível de dano previsto e a “Classe-alvo” ao nível ao qual o sinal realmente pertence. Tais matrizes foram construídas com todos os subconjuntos de testes de cada modelo *5-fold*, resultando em 27000 diferentes exemplos analisados (180 dados de teste  $\times$  5 “*folds*”  $\times$  30 modelos). As taxas máxima e mínima de classificação e os valores de desvio-padrão associados a esses resultados estão representados em amarelo ao lado das respectivas matrizes de confusão. Cabe ressaltar que a taxa de classificação é o valor médio das identificações corretas obtidas pelos “*folds*” (5 neste caso), considerando apenas os dados de teste.

Figura 24 – Modelo numérico de viga biapoiada: Matrizes de confusão - modelos SAE com 30 características.

(a) Ponto de medição Ac1.

Classe de Saída	Sem dano	9000 33.3%	85 0.3%	59 0.3%	99.8%	Max. 99.8%	
	Dano nível #1	0 0.0%	8915 33.0%	1 0.0%	100.0%		Min. 99.0%
	Dano nível #2	0 0.0%	0 0.0%	8930 33.1%	100.0%		Desvio 0.2%
		100.0% 0.0%	99.1% 0.9%	98.2% 0.8%	99.8%		$\sigma=1,000000$ $\bar{C}=0,316230$
	Sem dano	Dano nível #1	Dano nível #2				
	Classe Alvo						

(b) Ponto de medição Ac2.

Classe de Saída	Sem dano	8996 33.3%	2 0.0%	2 0.0%	100.0%	Max. 100.0%	
	Dano nível #1	3 0.0%	8992 33.3%	11 0.0%	99.8%		Min. 99.7%
	Dano nível #2	1 0.0%	6 0.0%	8987 33.3%	99.9%		Desvio 0.1%
		100.0% 0.0%	99.9% 0.1%	99.9% 0.1%	99.9%		$\sigma=0,794330$ $\bar{C}=1,000000$
	Sem dano	Dano nível #1	Dano nível #2				
	Classe Alvo						

(c) Ponto de medição Ac3.

Classe de Saída	Sem dano	8995 33.3%	29 0.1%	36 0.1%	99.7%	Max. 99.9%	
	Dano nível #1	2 0.0%	8966 33.2%	6 0.0%	99.9%		Min. 99.5%
	Dano nível #2	3 0.0%	5 0.0%	8958 33.2%	99.9%		Desvio 0.1%
		99.9% 0.1%	99.9% 0.0%	99.9% 0.0%	99.7%		$\sigma=0,065096$ $\bar{C}=0,316230$
	Sem dano	Dano nível #1	Dano nível #2				
	Classe Alvo						

(d) Ponto de medição Ac4.

Classe de Saída	Sem dano	9000 33.3%	43 0.2%	54 0.2%	99.9%	Max. 99.9%	
	Dano nível #1	0 0.0%	8957 33.2%	2 0.0%	100.0%		Min. 99.3%
	Dano nível #2	0 0.0%	0 0.0%	8944 33.1%	100.0%		Desvio 0.1%
		100.0% 0.0%	99.9% 0.0%	99.4% 0.6%	99.6%		$\sigma=0,794330$ $\bar{C}=0,316230$
	Sem dano	Dano nível #1	Dano nível #2				
	Classe Alvo						

De uma forma geral, as matrizes de confusão da Figura 24 confirmam os bons resultados já obtidos. Verifica-se que o desempenho dos modelos SAE/SVM construídos com a técnica *5-fold* permaneceu praticamente inalterado ao comparar com o desempenho dos modelos equivalentes onde a validação cruzada não foi considerada (modelos de 30 características da Tabela 5). Na presente análise, as médias das classificações ficaram acima de 99,0% com desvio padrão de até 0,2%. Salienta-se ainda que, apesar de para a maioria dos acelerômetros os modelos serem menos assertivos quando classificam os dados como “sem dano”, estes resultados correspondem, no pior panorama, a apenas 0,06% das respostas totais avaliadas (caso do acelerômetro 1, onde 85 dados que pertenciam à classe “dano nível #1” e 69 dados que eram da classe “dano nível #2” foram erroneamente atribuídos à classe “sem dano”). No que diz respeito ao tempo médio de processamento, cada modelo SAE/SVM da viga numérica levou em média de 5 a 6 minutos para ser criado, um tempo considerado razoável para problemas SHM.

## 5.2 APLICAÇÃO II - VIADUTO VÁRZEA NOVA

A segunda aplicação da metodologia SHM supervisionada é o viaduto Várzea Nova, situado no cruzamento das rodovias BR-101 e BR-230 entre os municípios paraibanos de João Pessoa e Campina Grande. O viaduto, que possui 35,7m de extensão e vão central de 15m, foi atingido por um caminhão com excesso de altura e teve uma das suas quatro vigas principais danificada. Com o intuito de recuperar a estrutura e também adequá-la aos atuais códigos regulamentares do Brasil, uma série de procedimentos de restauração foi implementada, incluindo reforço de pilares, vigas, tabuleiro e fundação. A Figura 25 mostra uma vista em perspectiva do viaduto antes e depois do reforço estrutural. Destaca-se que os dados relativos a esta estrutura foram gentilmente cedidos pelo professor Roberto Leal Pimentel (responsável pelo ensaio) dentro do quadro do projeto CAPES/PROCAD (“*Rede de Cooperação Acadêmica em Durabilidade de Estruturas - Experimentação e Modelagem*”), do qual a autora, como participante, realizou duas missões de estudo (dois meses durante o mestrado e dois meses durante o doutorado) na Universidade Federal da Paraíba (UFPB).

Ensaio dinâmico foram conduzidos antes e depois dos procedimentos de recuperação do viaduto, levando a conjuntos de históricos de acelerações obtidos sob carregamento de tráfego. Um sistema de aquisição de dados *National Instruments NI9215* conectado a um computador portátil foi utilizado para processar os sinais de vibração coletados por dois acelerômetros piezoelétricos *ENDEVCO* modelo *752A13* - ambos fixados na parte superior do tabuleiro da ponte, acima da viga danificada, sendo um posicionado no meio da viga (acelerômetro 1) e o outro a 1/6 do seu comprimento (acelerômetro 2), conforme indicado na Figura 26(a). Para cada condição estrutural, realizaram-se 4 ensaios dinâmicos, resultando em 8 respostas a serem analisadas por canal de acelerômetro. As respostas estruturais tem duração de 512s, amostradas à taxa de 512Hz. A Figura 26(b) exibe um

Figura 25 – Viaduto Várzea Nova.

(a) Antes do reforço estrutural.



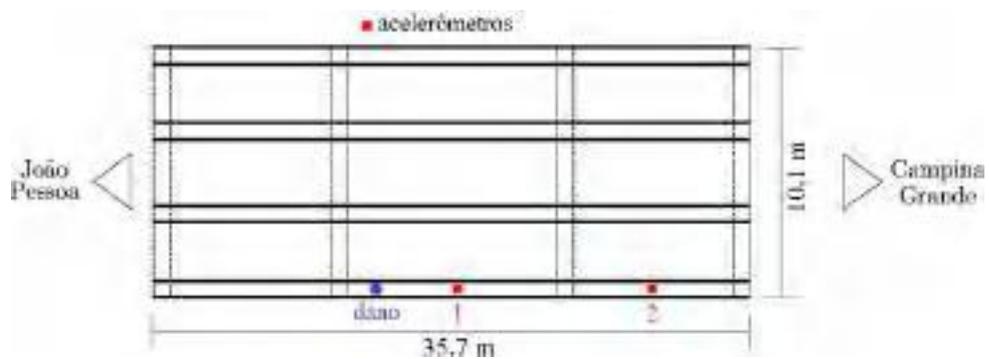
(b) Depois do reforço estrutural.



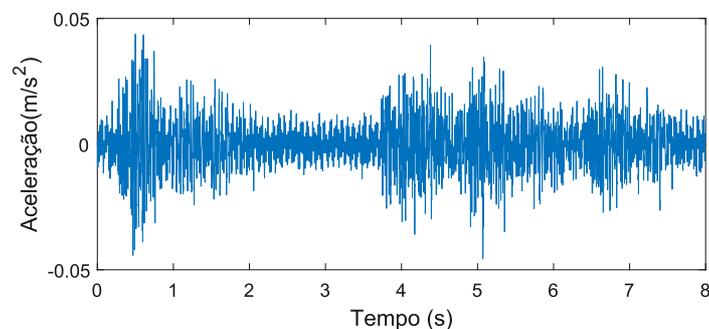
exemplo da resposta típica da estrutura. A variação da primeira frequência natural - antes e depois do reforço - é fornecida na Tabela 6 a título de informação. Assim como esperado, observam-se valores de frequência natural mais elevados após o reforço estrutural, uma vez que tal procedimento aumentou a rigidez da ponte sem alterar significativamente a sua massa.

Figura 26 – Esquema experimental do Viaduto Várzea Nova.

(a) Vista em planta.



(b) Resposta típica.



A fim de traçar um paralelo com os sinais da viga quanto ao número de pontos amostrados e o número de ciclos analisados por segundo, antes de serem processadas pelo SAE, as respostas vibracionais do viaduto foram divididas em sinais de menor duração de

Tabela 6 – Variação da primeira frequência natural do Viaduto Várzea Nova.

Cenário estrutural	1 <sup>a</sup> frequência natural
Antes do procedimento de reforço	13.37Hz
Depois do procedimento de reforço	13.76Hz

tempo. Portanto, cada acelerômetro forneceu 512 sinais de 8s de duração, organizados em matrizes de entrada  $[4096 \times 512]$ , dos quais 256 coletados antes do procedimento de reforço e os restantes 256 coletados após. Dada a aprendizagem supervisionada do SVM, foi gerado também um vetor alvo de 512 posições, onde são especificadas a categoria dos dados através do seguinte código binário: 0 - antes do reforço e 1 - depois do reforço. Assim como na aplicação da viga, os sinais aqui foram normalizadas para valores de amplitude variando entre  $[0, 1]$ .

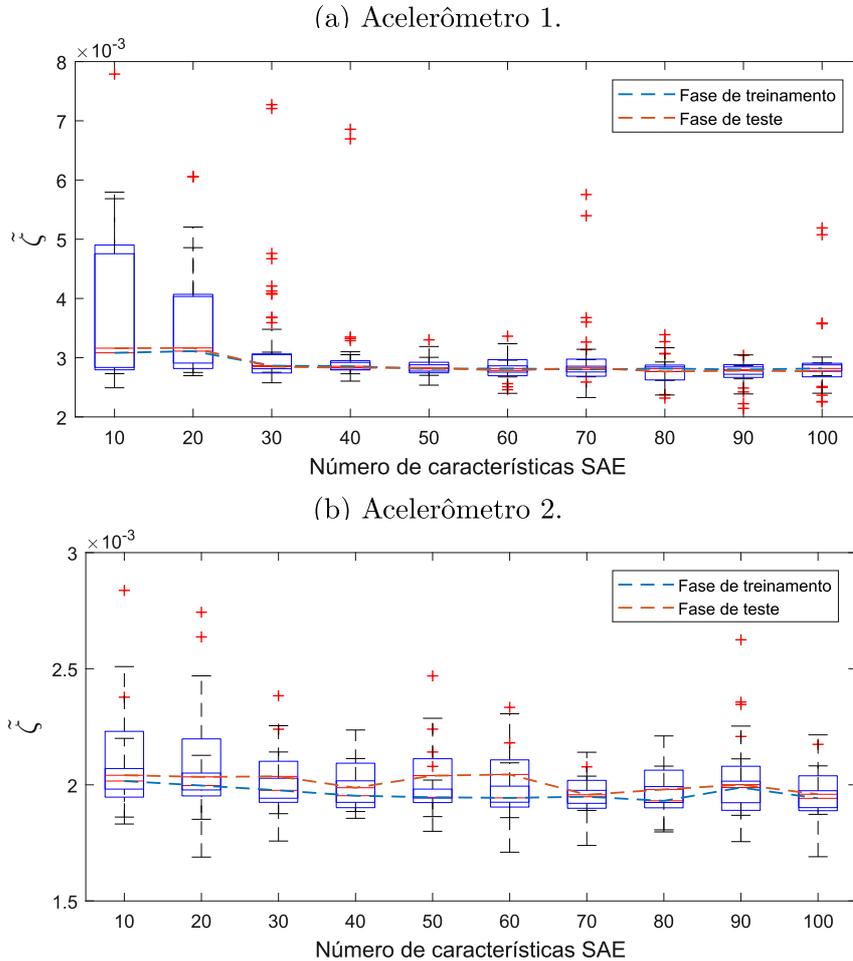
Com relação a quantidade de dados treinamento/teste da primeira etapa de análise - que se preocupa em avaliar as diferentes quantidades  $K$  de características SAE -, optou-se por atribuir aproximadamente 70% dos sinais à fase de treinamento e 30% à fase de teste, em função do menor número de respostas estruturais disponíveis quando comparado à viga numérica (512 para o viaduto e 900 para a viga). Dessa forma, para ambos os canais de acelerômetros, as matrizes de entrada, bem como os seus respectivos vetores alvo, foram subdivididas aleatoriamente nas matrizes de treinamento **A**  $[4096 \times 362]$  e **B**  $[K \times 362]$ , e nas matrizes de teste **C**  $[4096 \times 150]$  e **D**  $[K \times 150]$ . Quanto a segunda parte da análise, que emprega a validação cruzada *5-fold*, a matriz de entrada é dividida aleatoriamente em 5 subgrupos, com aproximadamente 4/5 dos dados destinados para treinamento (matrizes **A** e **B**) e o restante 1/5 para teste (matrizes **C** e **D**), tal como foi realizado para a viga. Além disso, devido aos bons resultados alcançados até aqui e aspectos similares entre os sinais considerados, os parâmetros dos modelos SAE e SVM adotados para o viaduto Várzea Nova são também os mesmos da aplicação estrutural anterior (Tabela 4).

### 5.2.1 Resultados

Os diagramas do tipo “*box plot*” com as curvas de erro  $\tilde{\zeta}$  para o viaduto Várzea Nova são apresentados na Figura 27. Além disso, a Tabela 7 exhibe as taxas de classificações alcançadas pelo algoritmo SVM (com os respectivos parâmetros  $\sigma$  e  $C$ ) relacionadas aos dados da fase de teste dos modelos SAE dos diagramas acima mencionados. Diversas quantidades de códigos internos ( $\dim(\mathbf{h})$ ) foram avaliados considerando 30 diferentes modelos SAE, nos quais a dimensionalidade do problema é reduzida de 4096 pontos amostrados para a quantidade especificada de características  $\mathbf{h}$ .

Os valores de erro  $\tilde{\zeta}$  da Figura 27 revelam que os sinais da presente aplicação foram melhores reconstruídos pelo SAE do que os sinais da viga. Embora os erros de reconstrução sejam considerados baixos em ambas as estruturas, os alcançados para o

Figura 27 – Número de características SAE  $\times$  Erro médio de reconstrução  $\tilde{\zeta}$  para a viaduto Várzea Nova.



viaduto possuem ordem de grandeza de  $10^{-3}$ , enquanto que para viga, tal métrica de erro atingiu valores da ordem de  $10^{-2}$ . Este fato pode estar associado aos respectivos carregamento estruturais. Se por um lado a força de excitação da viga é aleatória de distribuição uniforme entre 0 e 100N, por outro, o viaduto está submetido um carregamento de tráfego. Desta forma, considerando que diferentes excitações levam a comportamentos estruturais significativamente distintos, a viga acaba apresentando históricos de acelerações bem menos comportados do que os medidos no viaduto, fazendo com que o SAE tenha maior facilidade em reconstruir as respostas desse último. Ainda assim, ao observar a Tabela 7, percebe-se que as taxas de classificação obtidas para o viaduto são ligeiramente menores do que as taxas da viga. De certa forma, esta redução nas classificações corretas do viaduto já era esperada, posto que as suas respostas estruturais advém de um ensaio dinâmico experimental real, normalmente mais suscetíveis a incertezas e ruídos, ao contrário do caso da viga, que se trata de um exemplo numérico controlado. Além disso, tais resultados mostram, novamente, que não é possível fazer uma ligação direta entre os menores erros de reconstrução e as maiores taxas de classificação, uma vez que o viaduto obteve menores valores de  $\tilde{\zeta}$  e não necessariamente as melhores acurácias.

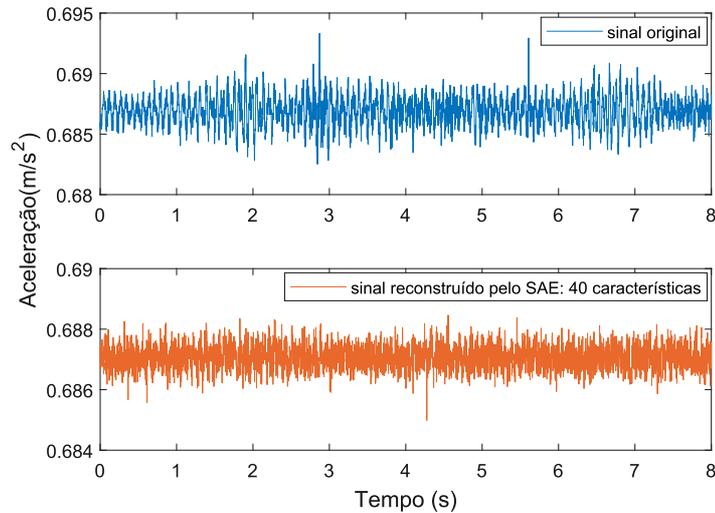
Tabela 7 – Resultados de classificação SVM em função do número de características SAE para o viaduto Várzea Nova.

Dim(h)	Média (%)	Melhor classificação (%)	Pior classificação (%)	Desvio-padrão (%)	$\sigma$	C
<b>Acelerômetro 1</b>						
10	78,27	96,67	41,33	17,51	0,0316	316,2278
20	90,91	98,00	80,67	3,27	0,0316	316,2278
30	93,47	98,67	88,00	2,80	0,0316	100,00
40	<b>95,60</b>	<b>100,00</b>	<b>89,33</b>	<b>2,46</b>	<b>0,0316</b>	<b>100,00</b>
50	95,80	100,00	92,00	1,91	0,0316	316,2278
60	96,60	100,00	92,00	2,07	0,0316	31,6228
70	86,51	100,00	61,33	12,28	0,0398	1,5000
80	71,93	98,67	40,67	16,48	0,0794	3,5000
90	96,13	99,33	90,00	1,94	0,0316	31,6228
100	69,16	100,00	34,00	17,23	0,3162	100,00
<b>Acelerômetro 2</b>						
10	83,44	96,67	45,33	14,50	0,0316	316,2278
20	93,87	98,00	80,67	3,47	0,0316	316,2278
30	95,42	100,00	88,67	2,55	0,0316	100,00
40	<b>97,18</b>	<b>99,33</b>	<b>92,00</b>	<b>1,70</b>	<b>0,0316</b>	<b>316,2278</b>
50	97,42	100,00	95,33	1,33	0,0316	316,2278
60	97,51	100,00	94,67	1,38	0,0316	100,00
70	97,09	99,33	94,00	1,48	0,0316	316,2278
80	97,53	100,00	94,67	1,44	0,0316	100,00
90	97,93	100,00	94,67	1,39	0,0316	316,2278
100	97,16	99,33	94,67	1,26	0,0316	100,00

Com relação ao melhor número de características SAE para esta aplicação, ao analisar os resultados do acelerômetro 1, nota-se um melhor desempenho para os modelos SAE de 50 características (menor número de outliers - Figura 27(a) - e taxa de classificação em torno de 95%). Contudo, para o acelerômetro 2, os modelos SAE que tiveram desempenho superior parecem ser os de 40 características (menor erro  $\tilde{\zeta}$  entre os modelos de 10 à 50 características, e taxa de classificação de aproximadamente 97%). Portanto, por entender que o ganho em termos de acurácia e desvio-padrão ao aumentar as características de 40 para 50 não é significativo, admite-se os modelos de 40 neurônios como sendo os mais adequados para o viaduto - os modelos de 40 e 50 características do acelerômetro 2 possuem resultados similares e a diferença entre os modelos de 40 e 50 neurônios do acelerômetro 1 é o aumento do desvio-padrão em um ponto percentual, um valor aceitável. A Figura 28 exibe um exemplo da resposta dinâmica do viaduto reconstruída pelo SAE ao usar 40 códigos internos em comparação com o seu respectivo sinal original (normalizado).

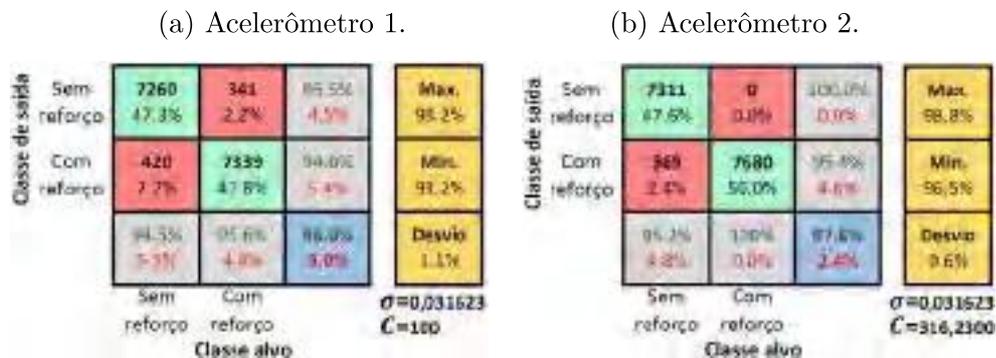
As matrizes de confusão da Figura 29 apresentam as taxas de classificação da metodologia de detecção de danos proposta para 30 diferentes modelos SAE/SVM desenvolvidos com 40 códigos internos e com a técnica de validação cruzada *5-fold*. Assim como para o caso da viga, manteve-se os mesmos parâmetros SAE/SVM empregados na análise

Figura 28 – Comparação entre um sinal original do viaduto Várzea Nova e sua respectiva reconstrução feita pelo SAE



precedente. As matrizes foram montadas considerando todos os subconjuntos da fase de teste dos modelos *5-fold*, assim sendo, 15360 exemplos diferentes foram analisados (entre 102 e 103 dados de teste  $\times$  5 “*folds*”  $\times$  30 modelos).

Figura 29 – Viaduto Várzea Nova: Matrizes de confusão - modelos SAE com 40 características.



Os resultados dos modelos de ambos os acelerômetros ao utilizar a estratégia de validação *5-fold* confirmam o bom desempenho do algoritmo SAE/SVM de 40 características para o viaduto estudado. Apesar de os modelos relacionados ao acelerômetro 1 terem o menor desempenho, as taxas de classificação e desvio-padrão são ainda satisfatórios (acurácia geral de 95% com desvio-padrão de 1,1%). Cada modelo de detecção demorou cerca de 4 minutos para ser desenvolvido.

Em síntese, para ambas as estruturas analisadas, viga numérica e viaduto, a abordagem supervisionada SHM baseada em SAE/SVM foi capaz de apontar corretamente os cenários estruturais de praticamente todas as respostas dinâmicas, com uma relativamente baixa quantidade de características (inferior à 50). Os resultados alcançados até aqui indicam que é possível extrair e interpretar características dos sinais estruturais com o SAE. Um aspecto importante notado neste capítulo é que os melhores modelos SAE não foram obrigatoriamente aqueles que obtiveram o menor erro de reconstrução e, portanto,

outras formas de definir o modelo mais adequado ao problema em questão devem ser consideradas, principalmente ao desenvolver estratégias SHM não-supervisionadas, foco do próximo capítulo.

## 6 METODOLOGIA SHM NÃO-SUPERVISIONADA

Na prática, um dos aspectos mais desafiadores no desenvolvimento de técnicas SHM baseadas exclusivamente em sinais é identificar a ocorrência de danos sem ter dados do sistema danificado disponíveis *a priori*. Entretanto, embora os modelos SAE/SVM tenham alcançado resultados satisfatórios, a classificação/deteção realizada pelo algoritmo SVM é em sua essência supervisionada (através de matrizes “alvo” previamente conhecidas, responsáveis por apontar as respectivas categorias dos sinais), o que pode dificultar a sua utilização dentro da logística de um sistema de monitoramento de estruturas civis. Assim sendo, para que a abordagem estudada utilizando o SAE seja de fato aplicável a este último tipo de sistema SHM, é necessário definir um mecanismo que seja capaz de informar, em tempo real, o atual estado da estrutura. Diante deste contexto, propõe-se no presente capítulo uma metodologia não-supervisionada de deteção de danos baseada no uso do SAE e de cartas de controle  $T^2$  de *Hotelling*. Devido à sua implementação relativamente simples, interpretação intuitiva e resultados eficazes, as cartas de controle são consideradas ferramentas apropriadas e frequentemente utilizadas no desenvolvimento de estratégias de monitoramento estrutural contínuo e deteção de danos, principalmente em abordagens fundamentadas nos resíduos de análises de regressão.

As cartas de controle são ferramentas gráficas estatísticas usadas para monitorar a variabilidade dos parâmetros de um problema ao longo do tempo. Essas cartas geralmente retratam vários pontos de dados, formados por uma característica estatística específica, e seus respectivos limites de controle, retratados por linhas horizontais, responsáveis por indicar os valores extremos de tal característica quando o problema está em estado de controle. Por outro lado, qualquer ponto além desses limites predeterminados revela fontes incomuns de variabilidade, sugerindo uma situação fora de controle [49].

Conforme mencionado anteriormente, a carta de controle aqui utilizada é a de análise multivariada  $T^2$  de *Hotelling*, cuja a estatística nela plotada (os pontos  $T^2$ ) representa a distância entre uma nova observação dos dados e o vetor de média amostral correspondente - quanto maior o valor de  $T^2$ , mais distantes os novos dados estão da média. Essa métrica é baseada na relação entre as variáveis e na dispersão dos dados (matriz de covariância). Portanto, assumindo que a matriz  $\mathbf{H}_{N \times M}$  é constituída por um conjunto de dados coletados durante um determinado período de tempo (no caso deste artigo, representa as características extraídas pelo SAE), a estatística  $T^2$  pode ser calculada pela Eq.(6.1):

$$T^2 = R(\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}})^T \mathbf{S}^{-1} (\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}}) \quad (6.1)$$

onde  $\bar{\mathbf{h}}$  é o vetor de média amostral das  $M$  características disponíveis, obtido a partir de uma submatriz de  $\mathbf{H}$  com  $R$  observações ( $\mathbf{H}_{R \times M}$ ,  $R < N$ ),  $\bar{\bar{\mathbf{h}}}$  e  $\mathbf{S}$  são os vetores de referência da média amostral e da média das matrizes de covariância, respectivamente,

ambas estimadas usando  $s$  submatrizes preliminares, coletadas durante o estado de controle do problema. Neste trabalho, o Limite de Controle Superior (UCL, de “*Upper Control Limit*”) é definido como o 95<sup>ésimo</sup> percentil dos valores de  $T^2$  dos dados de treinamento (valores maiores que o UCL podem ser observados apenas 5% das vezes por acaso). Em contrapartida, o Limite de Controle Inferior (LCL, de “*Lower Control Limit*”) é zero.

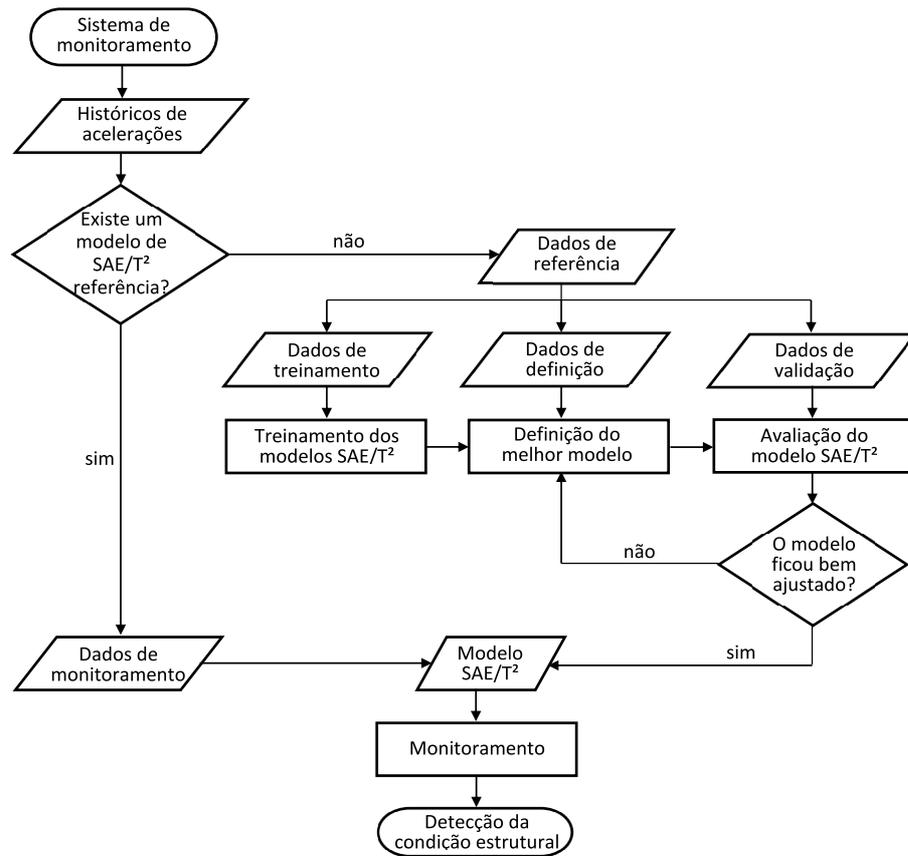
Considerando então um esquema de monitoramento não-supervisionado, a ideia da abordagem aqui desenvolvida, designada como metodologia SAE/ $T^2$ , é processar as respostas dinâmicas por meio de modelos autocodificadores e, posteriormente, detectar o início do comportamento estrutural “anormal” com o auxílio da estatística  $T^2$  de *Hotelling* calculada com as características extraídas pelo SAE. A Figura 30 exibe um esquema geral de tal metodologia, a qual envolve basicamente 4 etapas: treinamento dos modelos SAE/ $T^2$ , definição e validação do melhor modelo, e por fim, monitoramento estrutural. Por ser tratar de uma estratégia que possui muitos parâmetros a serem previamente ajustados, as etapas de treinamento dos modelos e de definição do mais adequado para o problema demandam um esforço maior. Ainda que, para ambas as estruturas estudadas no capítulo anterior, os modelos SAE tenham sido todos construídos com os mesmos parâmetros, com exceção do número de neurônios na camada central (quantidade de características), sabe-se que os hiperparâmetros  $\lambda$ ,  $\beta$  e  $\rho$  influenciam significativamente o seu desempenho, refletindo diretamente nos erros de reconstrução (ver capítulo “*Análise de sensibilidade*”). Além disso, destaca-se também o fato de ter sido observado que somente avaliar o erro de reconstrução não é suficiente para estabelecer o melhor modelo, sendo necessário um melhoramento desse critério de seleção. Portanto, a questão crucial que deve ser discutida é: Como definir os melhores valores de  $\lambda$ ,  $\beta$  e  $\rho$  para um problema específico de detecção de alterações estruturais?

Na presente metodologia propõe-se realizar essa avaliação por meio do método de busca exaustiva em grade, incluindo tanto os modelos SAE quanto a estatística  $T^2$ , simultaneamente, através de um critério de definição baseado no cálculo do erro de reconstrução  $\tilde{\zeta}$  e em um índice de generalização, que será explicado mais adiante neste texto. Partindo dos históricos de acelerações provenientes de um sistema de monitoramento funcionando sob condições normais e, respeitando a ordem cronológica em que esses dados foram coletados, as 4 etapas anteriormente mencionadas podem ser descritas conforme segue:

- **Treinamento dos modelos SAE/ $T^2$**

Pressupondo que ainda não exista um modelo SAE/ $T^2$ , os históricos de acelerações disponíveis, todos do mesmo estado estrutural, passam a ser considerados dados de referência, uma vez que participarão do processo de desenvolvimento e avaliação do modelo que servirá como base de comparação para respostas estruturais futuras. Em razão da seleção de melhores parâmetros ser realizada pelo procedimento de

Figura 30 – Esquema geral da metodologia não-supervisionada de detecção de dano proposta.



busca em grade, nesta etapa são treinados, com parte dos dados de referência (os chamados dados de treinamento), 160 diferentes modelos SAE, respectivamente associados às 160 combinações distintas de  $\lambda$ ,  $\beta$  e  $\rho$ , definidas pelos valores das Equações (4.8), (4.9) e (4.10) apresentadas no capítulo 4 (8 valores de  $\rho \times 4$  valores de  $\lambda \times 5$  valores de  $\beta = 160$  combinações). As  $M$  características extraídas pelo SAE são em seguida utilizadas para calcular a estatística  $T^2$ . Desta forma, para cada um dos 160 modelos SAE tem-se um vetor  $\mathbf{t}^{tr}$  relacionado, cujos os elementos são os valores de  $T^2$  obtidos durante a fase de treinamento, além do erro de reconstrução dos sinais  $\tilde{\zeta}^{tr}$ . Destaca-se aqui que antes de serem processados pelo SAE, os dados de treinamento são aleatorizados, como é de costume em algoritmos baseados na teoria de RNA's e como vem sendo feito em todas as análises realizadas até aqui. Esse “embaralhamento” tem o objetivo de reduzir certas tendências dos dados, conferindo maior poder de generalização para o modelo de inteligência artificial. No entanto, no âmbito da presente abordagem SHM, conforme já enfatizado é importante manter a ordem cronológica do dados. Assim, neste ponto, os sinais são aleatorizados apenas para criar o modelo autocodificador, e logo após essa etapa, os dados, ou melhor, as características extraídas pelo SAE, devem ser colocadas em ordem cronológica novamente.

- **Definição do melhor modelo**

Uma vez gerados os 160 modelos, uma segunda parte do conjunto de dados de referência (os denominados dados de definição), não utilizada durante a fase de treinamento, é aplicada para definir o modelo  $SAE/T^2$  que melhor se ajusta ao problema em questão. Os respectivos valores  $T^2$ , agrupados nos vetores  $\mathbf{t}^{def}$ , são então obtidos em função da apresentação dos dados de definição aos modelos existentes. Atentando-se para o fato de que erros de reconstrução baixos podem estar relacionados a uma baixa capacidade de generalização dos modelos criados, além do erro  $\tilde{\zeta}$ , admite-se nesta fase a métrica intitulada Índice de Generalização ( $IG$ ), calculada individualmente para cada modelo tal como mostra a Eq.(6.2):

$$IG = \|\mathbf{t}_q^{tr} - \mathbf{t}_q^{def}\| \quad (6.2)$$

onde  $\mathbf{t}_q^{tr}$  e  $\mathbf{t}_q^{def}$  representam vetores formados pelos 3 quartis de  $\mathbf{t}^{tr}$  e  $\mathbf{t}^{def}$ , respectivamente. Baseado no cálculo dos quartis, o índice sugerido visa avaliar a diferença de dispersão e tendência entre os vetores  $\mathbf{t}^{tr}$  e  $\mathbf{t}^{def}$ . Espera-se que, por utilizarem a mesma categoria de sinais, os modelos  $SAE/T^2$  que adquirirem boa capacidade de generalização forneçam valores de  $T^2$  estatisticamente semelhantes para os dados de treinamento e de definição. Ou seja, quanto menor o  $IG$ , maior é a probabilidade de ser um modelo  $SAE/T^2$  de bom desempenho. Desta forma, na presente metodologia o melhor modelo  $SAE/T^2$  será definido como aquele que tem, ao mesmo tempo, os menores valores de  $\tilde{\zeta}^{def}$  e de  $IG$ . Para tal, tomando-se os primeiros  $p$  elementos dos vetores  $\tilde{\zeta}^{def}$  e  $\mathbf{IG}$  ( $1 < p < 160$ ), nos quais estão organizados em ordem crescente os erros de reconstrução  $\tilde{\zeta}^{def}$  e os valores de  $IG$  dos 160 modelos gerados na etapa anterior, respectivamente, a estratégia proposta estabelece que para que um  $i$ -ésimo modelo seja definido como o melhor, ele tem que satisfazer simultaneamente às condições da Eq. (6.3) e Eq. (6.4) a seguir:

$$\tilde{\zeta}_i^{def} \in \tilde{\zeta}_p^{def} \quad (6.3)$$

$$IG_i \in \mathbf{IG}_p. \quad (6.4)$$

Se para um dado valor de  $p$  houver mais de um modelo  $SAE/T^2$  que produza  $\tilde{\zeta}^{def}$  e de  $IG$  que preencham as condições descritas nas Eq. (6.3) e Eq. (6.4), adota-se como melhor aquele com o menor  $\tilde{\zeta}^{def}$ . Caso nenhum modelo satisfaça às equações anteriores, a análise é então reiniciada aumentando-se os subconjuntos  $\tilde{\zeta}_p^{def}$  e  $\mathbf{IG}_p$  ao passo  $p = p + 1$  até que o melhor modelo seja encontrado. O valor  $p$  inicial adotado neste trabalho é 1.

- **Validação**

Nesta etapa, a terceira e última parte dos dados de referência (dados de validação), até então não utilizada, é apresentada ao modelo  $SAE/T^2$  selecionado com o objetivo de verificar o seu desempenho. Em razão das características SAE dos dados de referência serem todas derivadas de históricos de acelerações de um mesmo cenário estrutural, a expectativa é de que os valores  $T^2$  de validação tenham comportamento similar àqueles de treinamento e definição e, estejam abaixo do valor UCL. Lembrando que dentro da carta de controle, o UCL é o limite que determina a existência de um comportamento “anormal” e, no presente trabalho, é definido como sendo o valor correspondente a 95% dos valores  $T^2$  de treinamento. Caso a expectativa não seja atendida, retorna-se à etapa anterior onde a busca do melhor modelo continua a partir do último valor de  $p$  analisado. A definição/validação do modelo está completa quando o modelo  $SAE/T^2$  escolhido for capaz de representar corretamente o comportamento estrutural para o qual foi treinado utilizando o conjunto de dados de validação.

- **Monitoramento**

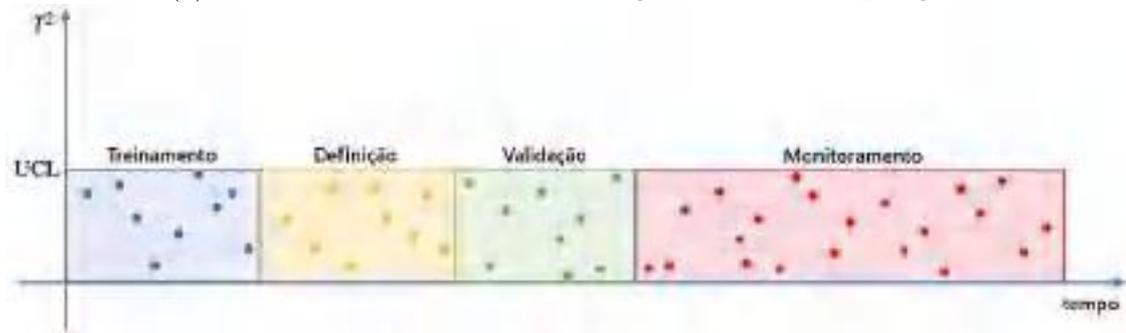
Finalmente, dispondo de um modelo  $SAE/T^2$  devidamente estabelecido, outros dados recém-adquiridos (dados de monitoramento) podem ser classificados como “normais” ou “anormais” a depender da condição estrutural em que se encontram, isto é, se possuem ou não o mesmo comportamento dos dados de referência. As características do SAE e suas respectivas estatísticas  $T^2$  são calculadas a partir dos dados de monitoramento para comparar as respostas estruturais recém-coletadas com as utilizadas na definição do modelo. Se uma alteração estrutural for detectada - situação caracterizada por valores  $T^2$  dos dados de monitoramento persistindo acima do UCL, ao contrário do comportamento observado nas etapas anteriores -, o modelo de referência  $SAE/T^2$  deve ser atualizado para a nova condição estrutural. Para longos períodos de monitoramento, recomenda-se atualizar periodicamente o modelo de referência para incluir possíveis alterações inerentes ao processo natural de envelhecimento estrutural. Nestas situações, os “antigos” dados de monitoramento tornam-se os “novos” dados de referência, e todo o processo da metodologia é reiniciado.

Com o intuito de facilitar o entendimento da metodologia, a Figura 31 exibe uma carta de controle  $T^2$  hipotética relativa a um modelo  $SAE/T^2$  no qual foram analisadas respostas estruturais medidas em dois momentos distintos de monitoramento: estrutura funcionando sob condições normais de operação e sob condições adversas. Por pertencerem à mesma classe de sinais, na Figura 31(a) os pontos  $T^2$  estão abaixo da linha UCL. Por outro lado, na Figura 31(b) é possível identificar a existência de algum tipo alteração

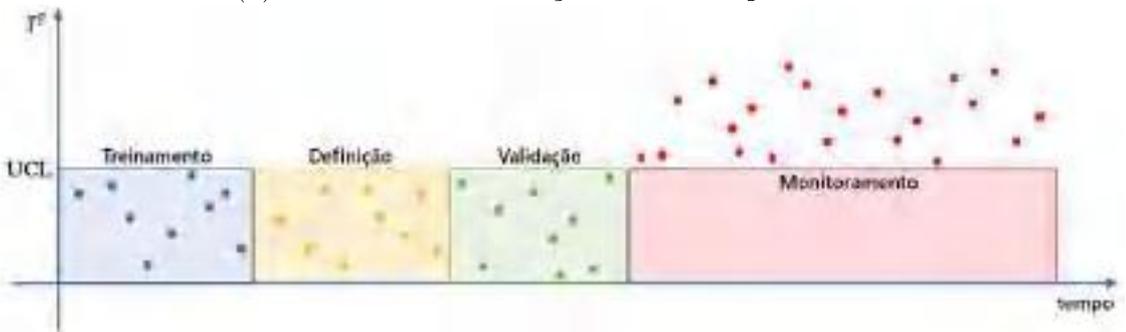
estrutural durante a etapa de monitoramento, uma vez que os valores  $T^2$  se encontram acima do limite de normalidade estipulado.

Figura 31 – Cartas de controle típicas - Metodologia SAE/ $T^2$ .

(a) Estrutura funcionando sob condições normais de operação.



(b) Estrutura com alteração no seu comportamento.



A princípio, a abordagem é exemplificada usando dados experimentais de cinco cenários estruturais distintos de um pórtico de alumínio construído em laboratório. Posteriormente, são analisados os dados da ponte Z24, estrutura frequentemente utilizada para avaliar metodologias SHM. Os dados investigados compreendem as respostas dinâmicas coletadas antes e após a imposição de dano à ponte, sob dois cenários diferentes de temperatura. Por fim, ainda considerando a influência da temperatura, uma última análise é realizada com os dados de um monitoramento contínuo no campanário de *San Vittore*, em *Arcisate*, norte da Itália.

Além do SAE para caracterização dos sinais, a Análise de Componentes Principais (PCA, do inglês “*Principal Component Analysis*”) é também considerada para fins de comparação. Este método foi escolhido devido à sua ampla utilização em pesquisas de detecção de danos. A ideia é calcular os pontos da estatística  $T^2$  substituindo as características do SAE pelos componentes principais. O PCA projeta as medições dinâmicas em um novo subespaço, onde as direções de variação máxima dos dados (componentes principais) determinam as características dos sinais. Desta forma, admitindo  $\mathbf{X}_{I \times J}$  como a matriz que armazena as respostas estruturais ao longo do tempo ( $I$  sinais compostos por  $J$  pontos amostrados), os componentes principais são encontrados resolvendo o problema de autovalor da matriz de covariância de  $\mathbf{X}$  ( $\text{cov } \mathbf{X}$ ). O presente trabalho utiliza a Decomposição em Valores Singulares de  $\mathbf{X}$  para encontrar os autovalores e autovetores do

problema, como segue:

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^* \quad (6.5)$$

onde  $\mathbf{\Sigma}_{I \times J}$  é a matriz cujos elementos da diagonal principal correspondem aos valores singulares de  $\mathbf{X}$  - relacionados aos autovalores de  $(\text{cov } \mathbf{X})$  - enquanto as colunas de  $\mathbf{U}_{I \times I}$  e  $\mathbf{V}_{I \times I}^*$  (transposta conjugada de  $\mathbf{V}$ ) são os vetores singulares à esquerda e à direita de  $\mathbf{X}$ , respectivamente - os autovetores de  $(\text{cov } \mathbf{X})$ .

## 6.1 APLICAÇÃO I - PÓRTICO DE ALUMÍNIO CONSTRUÍDO EM LABORATÓRIO

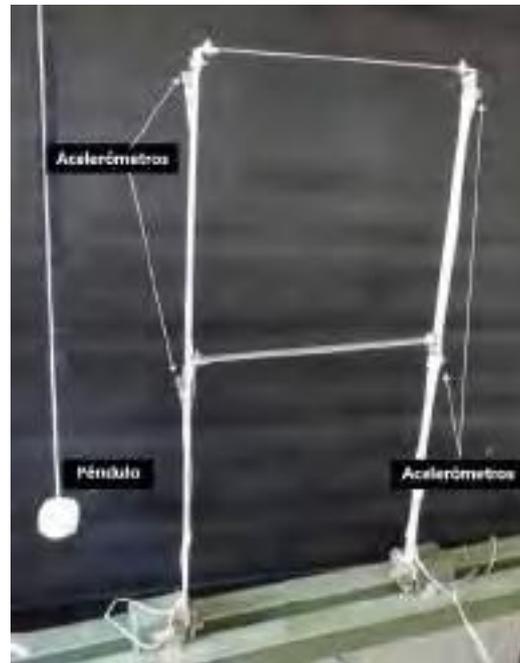
A viabilidade da metodologia proposta é inicialmente avaliada para os dados de uma investigação experimental conduzida em um pórtico de alumínio construído no Laboratório de Imagens e Sinais (LIS) da Universidade Federal de Juiz de Fora. Os ensaios foram conduzidos pelos integrantes do grupo de pesquisa em inteligência artificial aplicado à SHM Clayton Felício da Silva (bolsista de mestrado do PPG de Engenharia Civil da UFJF) e Pedro Henrique Eveling Oliveira (bolsista de iniciação científica da UFJF), a quem, desde já, registram-se os agradecimentos. Trata-se de uma estrutura esbelta de dois andares, formada por 6 barras de alumínio de 300mm de comprimento  $\times$  15,875mm de largura e 1,587mm de espessura, conforme pode ser visto na Figura 32.

Figura 32 – Pórtico de alumínio.

(a) Vista frontal.



(b) Vista em perspectiva.

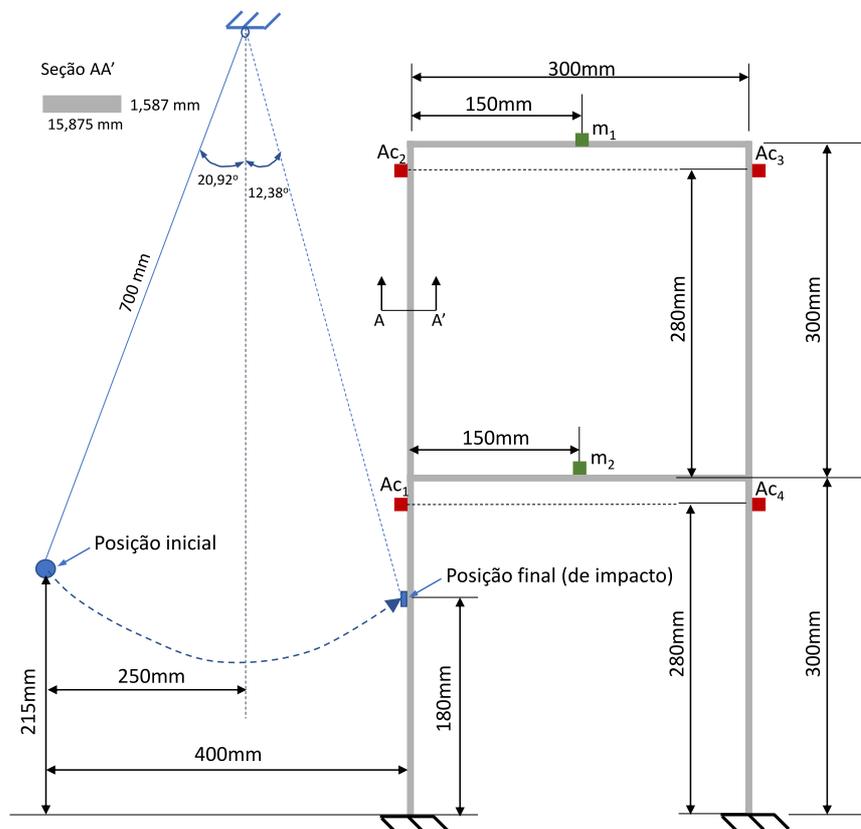


Os ensaios dinâmicos foram realizados utilizando-se quatro acelerômetros piezo-elétricos IEPE Brüel & Kjaer®, de sensibilidade 100mV/g, responsáveis por medir as respostas estruturais causadas pela carga de impacto aplicada por meio de um pêndulo

com massa de 14g, fixado no topo da estrutura de apoio ao pórtico (Figura 32(b)). Partindo do repouso, a massa pendular era abandonada de uma altura fixa, previamente estipulada, submetida à ação da gravidade até colidir com o pórtico. A Figura 33 exhibe com maiores detalhes o esquema experimental acima descrito. Com o objetivo de alterar as características dinâmicas do problema ao longo dos ensaios, massas adicionais  $m_1$  e  $m_2$ , posicionadas tal como na Figura 33, foram gradativamente anexadas às barras verticais do pórtico. Cinco configurações de massas foram consideradas, levando a históricos de acelerações de cinco diferentes cenários estruturais, a saber:

- Cenário #1 - Nenhuma massa adicional anexada à estrutura:  $m_1$  e  $m_2$  iguais a zero.
- Cenário #2 - Uma massa adicional anexada à estrutura:  $m_1 = 7,81\text{g}$  e  $m_2 = 0$ .
- Cenário #3 - Uma massa adicional anexada à estrutura:  $m_1 = 15,62\text{g}$  e  $m_2 = 0$ .
- Cenário #4 - Duas massas adicionais anexadas à estrutura:  $m_1 = 15,62\text{g}$  e  $m_2 = 7,81\text{g}$ .
- Cenário #5 - Duas massas adicionais anexadas à estrutura:  $m_1 = 15,62\text{g}$  e  $m_2 = 15,62\text{g}$ .

Figura 33 – Esquema experimental do pórtico.



Os dados analisados de cada cenário incluem registros de 200 testes dinâmicos (200 diferentes sinais por acelerômetro), todos aquisitados a uma frequência de 500Hz

durante 8.192s (4096 pontos amostrados por sinal). Ressalta-se que as gravações das respostas estruturais iniciaram 7,2ms antes do impacto da massa pendular. Um resultado típico dos testes é apresentado na Figura 34. As frequências naturais da estrutura ao longo dos cenários, identificadas através da transformada de Fourier (FFT - “*Fast Fourier Transform*”), são exibidas na Tabela 8.

Figura 34 – Resposta típica do pórtico.

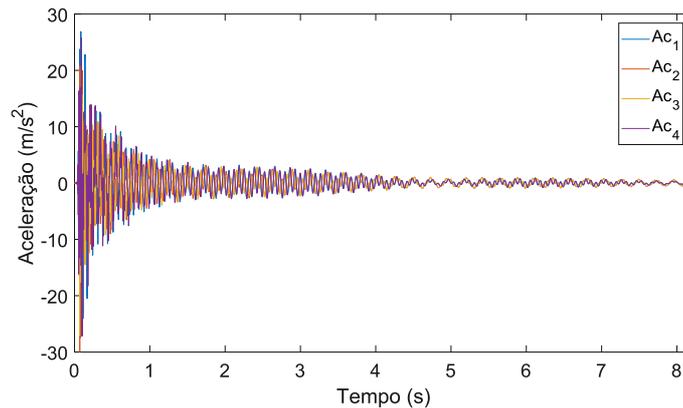


Tabela 8 – Variação das frequências naturais do pórtico.

<b>Cenário estrutural</b>	<b>1ª frequência natural</b>	<b>2ª frequência natural</b>	<b>3ª frequência natural</b>
<b>#1</b>	4,52Hz	15,02Hz	41,64Hz
<b>#2</b>	4,27Hz	14,77Hz	37,48Hz
<b>#3</b>	4,15Hz	14,65Hz	33,33Hz
<b>#4</b>	4,15Hz	14,16Hz	32,97Hz
<b>#5</b>	4,15Hz	13,80Hz	32,11Hz

Nesta aplicação, a metodologia é avaliada com base na análise simultânea dos dados de todos os acelerômetros, totalizando 800 sinais agrupados por cenário estrutural (4 acelerômetros  $\times$  200 ensaios). Devido ao fato das amplitudes relativas às diversas frequências naturais da estrutura estarem menos amortecidas no início das respostas dinâmicas, optou-se por utilizar somente o primeiro segundo de monitoramento de cada sinal (respostas com 500 pontos amostrados no total). Desta forma, o conjunto de dados de cada cenário foi organizado em matrizes  $[500 \times 800]$ , conforme descrito na Eq. 6.6, onde onde o sobrescrito  $c$  indica o cenário estrutural ao qual o conjunto de dados pertence (de #1 a #5) e, cada elemento  $Ac_k(i, j)$  representa o sinal medido pelo acelerômetro  $Ac_k$  (com  $k = 1, \dots, 4$ ) em um tempo discreto  $i$  (com  $i = 1, \dots, 500$ ) para o  $j$ -ésimo teste dinâmico (com  $j = 1, \dots, 200$ ).

Tais matrizes foram examinadas em 5 análises distintas, definidas como Caso A, Caso B, Caso C, Caso D e Caso E, de acordo com o estabelecido na Tabela 9. Em cada caso, utilizou-se os dados de um dos cenários nas etapas de treinamento, definição e validação, enquanto os dados dos quatro cenários restantes foram aplicados durante a

etapa de monitoramento. Vale lembrar que os dados de monitoramento não participam da construção dos modelos. Destaca-se ainda que, antes de serem processados pelo SAE, os sinais de todos os casos tiveram as suas amplitudes normalizadas entre 0 e 1, tomando como referência as amplitudes dos dados do seu respectivo conjunto de treinamento.

$$\mathbf{X}_{(500 \times 800)}^c = \left[ \begin{array}{ccccc} Ac_1(1, 1) & Ac_2(1, 1) & Ac_3(1, 1) & Ac_4(1, 1) & \dots \\ Ac_1(2, 1) & Ac_2(2, 1) & Ac_3(2, 1) & Ac_4(2, 1) & \dots \\ Ac_1(3, 1) & Ac_2(3, 1) & Ac_3(3, 1) & Ac_4(3, 1) & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \\ Ac_1(500, 1) & Ac_2(500, 1) & Ac_3(500, 1) & Ac_4(500, 1) & \dots \\ \\ Ac_1(1, 200) & Ac_2(1, 200) & Ac_3(1, 200) & Ac_4(1, 200) & \\ Ac_1(2, 200) & Ac_2(2, 200) & Ac_3(2, 200) & Ac_4(2, 200) & \\ Ac_1(3, 200) & Ac_2(3, 200) & Ac_3(3, 200) & Ac_4(3, 200) & \\ \vdots & \vdots & \vdots & \vdots & \\ Ac_1(500, 200) & Ac_2(500, 200) & Ac_3(500, 200) & Ac_4(500, 200) & \end{array} \right] \quad (6.6)$$

Tabela 9 – Estrutura de pórtico: casos analisados e organização dos dados.

Caso	Dados de treinamento	Dados de definição	Dados de validação	Dados de monitoramento
A	$\mathbf{X}_{(1...500;1...400)}^1$	$\mathbf{X}_{(1...500;401...600)}^1$	$\mathbf{X}_{(1...500;601...800)}^1$	$\mathbf{X}^2, \mathbf{X}^3, \mathbf{X}^4$ e $\mathbf{X}^5$
B	$\mathbf{X}_{(1...500;1...400)}^2$	$\mathbf{X}_{(1...500;401...600)}^2$	$\mathbf{X}_{(1...500;601...800)}^2$	$\mathbf{X}^1, \mathbf{X}^3, \mathbf{X}^4$ e $\mathbf{X}^5$
C	$\mathbf{X}_{(1...500;1...400)}^3$	$\mathbf{X}_{(1...500;401...600)}^3$	$\mathbf{X}_{(1...500;601...800)}^3$	$\mathbf{X}^1, \mathbf{X}^2, \mathbf{X}^4$ e $\mathbf{X}^5$
D	$\mathbf{X}_{(1...500;1...400)}^4$	$\mathbf{X}_{(1...500;401...600)}^4$	$\mathbf{X}_{(1...500;601...800)}^4$	$\mathbf{X}^1, \mathbf{X}^2, \mathbf{X}^3$ e $\mathbf{X}^5$
E	$\mathbf{X}_{(1...500;1...400)}^5$	$\mathbf{X}_{(1...500;401...600)}^5$	$\mathbf{X}_{(1...500;601...800)}^5$	$\mathbf{X}^1, \mathbf{X}^2, \mathbf{X}^3$ e $\mathbf{X}^4$

Em todas análises, os 160 modelos SAE criados durante a etapa de treinamento (através do procedimento de busca em grade) foram implementados com uma camada codificadora e uma decodificadora. Além de ter obtido resultados satisfatórios em todos os estudos realizados até o presente momento, a estratégia de utilizar apenas uma camada de codificação/decodificação, ao invés de várias, ainda tem a vantagem de demandar um menor tempo de processamento. Quanto ao número de neurônios empregado na camada interna do SAE ( $\dim(\mathbf{h})$ ), sabe-se que se por um lado uma quantidade baixa pode não ser suficiente para representar os sinais dinâmicos de forma justa, por outro, uma quantidade alta de neurônios pode comprometer a capacidade de generalização do modelo. Nos exemplos investigados anteriormente, o intervalo de 10 a 100 neurônios, pareceu ser uma faixa razoável de valores a ser considerada neste tipo de aplicação. Portanto, a partir dessa referência, optou-se aqui por avaliar o desempenho de modelos SAE com 30, 50 e 70 neurônios na camada interna, o que corresponde ao SAE reduzir a dimensionalidade

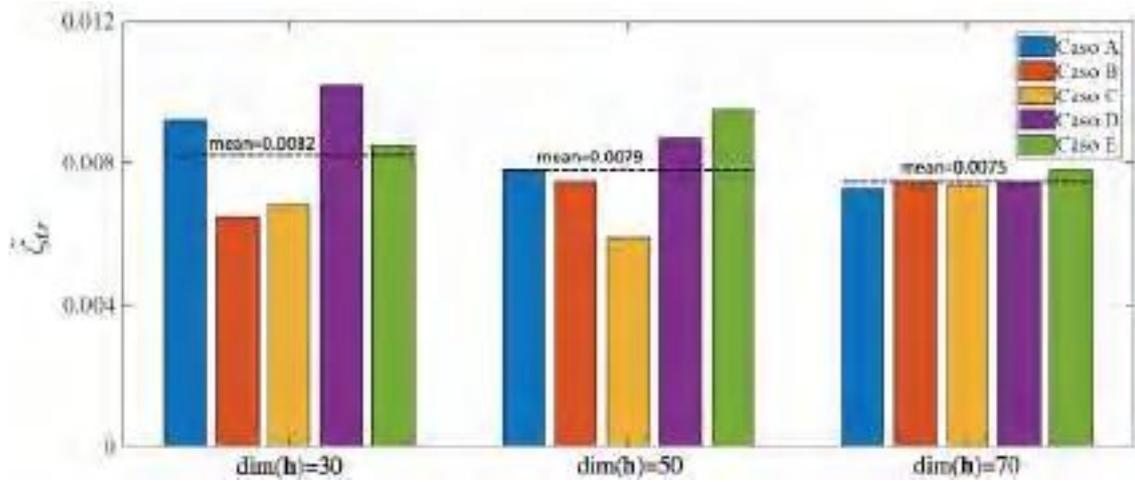
do problema de 500 pontos amostrados para 30, 50 e 70 características, nessa ordem (redes com configuração geral 500-30-500, 500-50-500 e 500-70-500, respectivamente). Já os demais parâmetros foram mantidos tal como no Capítulo 5 (com exceção de  $\rho$ ,  $\beta$  e  $\lambda$ , selecionados com o auxílio do procedimento de busca exaustiva): função de treinamento = método de otimização SCG com valor máximo de gradiente de  $1,00 \times 10^{-6}$ ; função de ativação codificadora = linear de saturação (satlin); função de ativação decodificadora = linear (purelin) e; número máximo de épocas de treinamento = 1000. Com relação às cartas de controle, a estatística  $T^2$  de *Hotelling* foi calculada utilizando subgrupos de dados, já processados pelo SAE, compostos por 5 observações ( $R = 5$ ). Sabendo que o pórtico é uma estrutura de laboratório submetida a condições de ensaio controladas, a influência de fatores ambientais e/ou operacionais é praticamente inexistente. Por esta razão, em uma tentativa de captar uma quantidade maior de possíveis flutuações na estatística  $T^2$ , adotou-se o valor de  $R$  mais baixo ( $R = 5$ ). O limite UCL foi estimado considerando o 95<sup>ésimo</sup> percentil dos 80 valores  $T^2$  da etapa de treinamento (400 exemplos de treinamento/5 observações = 80 subgrupos de dados).

### 6.1.1 Resultados

Com o intuito de estipular a quantidade de características SAE a ser extraída das respostas do pórtico, realizou-se inicialmente, para cada um dos casos da Tabela 9 (dados de treinamento), o treinamento dos modelos SAE via busca exaustiva em grade considerando 30, 50 e 70 neurônios na camada interna. Os resultados de tal análise são mostrados na Figura 35. Neste gráfico, cada barra está associada ao modelo SAE que teve o menor erro de reconstrução médio de treinamento  $\tilde{\zeta}^{tr}$  (entre as combinações de hiperparâmetros  $\lambda$ ,  $\rho$  e  $\beta$ ) dentro do respectivo caso analisado. Apesar de, aparentemente, os modelos apresentarem valores de  $\tilde{\zeta}^{tr}$  menos dispersos com relação a média a medida que a quantidade de características SAE aumenta, a taxa média de decaimento observada é muito baixa (em torno de  $-0,0000175 \tilde{\zeta}_{tr}/\dim(\mathbf{h})$ ). Desta forma, visando manter um baixo índice de erro de reconstrução e, ao mesmo tempo, despender menor esforço computacional, fixou-se para a aplicação do pórtico modelos SAE com 30 neurônios na camada interna ( $\dim(\mathbf{h} = 30)$ ).

A partir dos conjuntos de 160 modelos de 30 códigos internos SAE, previamente desenvolvidos, foram obtidos os valores  $T^2$  associados - produzindo, durante a fase de treinamento, 160 vetores  $\mathbf{t}^{tr}$  de 30 elementos para cada um dos casos A, B, C, D e E analisados. O índice de generalização IG e os erros de reconstrução de treinamento  $\tilde{\zeta}^{tr}$ , de definição  $\tilde{\zeta}^{def}$  e de validação  $\tilde{\zeta}^{val}$  alcançados pelos melhores modelos SAE/ $T^2$  (segundo o critério estabelecido pela Eq. 6.3 e Eq. 6.4), bem como os seus respectivos valores de  $\lambda$ ,  $\rho$  e  $\beta$ , são exibidos na Tabela 10. Destaca-se que o erro de validação é exposto com propósito informativo, já que não entra na definição do melhor modelo. Para fins de comparação, além do critério de seleção do melhor modelo sugerido na metodologia proposta (IG e

Figura 35 – Erro de reconstrução  $\tilde{\zeta}^{tr}$  em função do número de características SAE.



$\tilde{\zeta}^{def}$ ), a Tabela 10 ainda apresenta o desempenho alcançado ao se basear apenas no menor erro  $\tilde{\zeta}^{def}$  como métrica de decisão na etapa de definição e também, ao adotar, no lugar do modelo SAE, um modelo PCA com 30 componentes principais para a caracterização dos dados do pórtico (a mesma quantidade de características  $\mathbf{h}$  estipulada para o SAE). Cabe enfatizar que o índice de generalização é de fato utilizado somente quando aplicado o critério proposto, nos demais, o valor de IG é calculado apenas para conhecimento. As Figuras 36 à 40 mostram as cartas de controle  $T^2$  de *Hotelling* relacionadas aos modelos da Tabela 10. No total, foram avaliados 800 subgrupos de dados por modelo SAE/ $T^2$ : 80 subgrupos de treinamento, 40 de definição, 40 de validação e 640 de monitoramento (160 por cenário monitorado). Complementar aos gráficos de controle, a Tabela 11 apresenta a porcentagem de “*outliers*” detectados pelos modelos dos três critérios para cada caso e tipo de dado.

Ao analisar as cartas de controle (Figura 36 à Figura 40) e as porcentagens de *outliers* (Tabela 11), é possível afirmar que a metodologia SAE/ $T^2$  proposta alcançou bom desempenho em praticamente todos os casos investigados. De maneira geral, em tal abordagem, durante os períodos de treinamento, definição e teste, a maioria dos valores da estatística  $T^2$  ficaram abaixo do limite UCL (pequeno número de falsos alarmes), enquanto que nos períodos de monitoramento, a estatística  $T^2$  ultrapassou abruptamente o valor UCL, com a totalidade ou quase totalidade dos pontos fora da região do gráfico onde o comportamento estrutural era considerado “normal”, indicando corretamente a presença de algum tipo de alteração. Embora em alguns casos a porcentagem de *outliers* da metodologia proposta tenha atingido valores mais altos (caso C, por exemplo, com 37,5% dos valores  $T^2$  de validação erroneamente localizados acima da UCL), nota-se, ainda assim, pontos  $T^2$  de definição e validação com padrão de distribuição próximo aos respectivos pontos  $T^2$  de treinamento, fato não observado nos resultados dos modelos baseados no critério de menor  $\tilde{\zeta}^{def}$  e PCA. Nestas duas últimas abordagens, para a maioria dos casos, os gráficos exibem padrões distintos entre os grupos de dados de referência, o que não

Tabela 10 – Erros de reconstrução dos sinais e hiperparâmetros associados aos modelos selecionados pela metodologia SHM não-supervisionada para o pórtico.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\tilde{\zeta}^{tr}$	$\tilde{\zeta}^{def}$	$\tilde{\zeta}^{val}$	<b>IG</b>
<b>Caso A</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	0,2000	0,0010	8,0	0,0095	0,0115	0,0134	20,48
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	0,4000	0,0010	1,0	0,0051	0,0066	0,0065	112,23
	<b>PCA</b>	-	-	-	0,0009	0,0032	0,0068	175,80
<b>Caso B</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	0,8000	0,0010	1,0	0,0065	0,0101	0,0107	13,41
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	0,4000	0,0010	4,0	0,0060	0,0091	0,0089	57,73
	<b>PCA</b>	-	-	-	0,0009	0,0026	0,0044	151,50
<b>Caso C</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	0,1000	0,0001	4,0	0,0068	0,0114	0,0192	23,38
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	0,4000	0,0001	2,0	0,0048	0,0085	0,0096	497,93
	<b>PCA</b>	-	-	-	0,0008	0,0050	0,0072	1242,70
<b>Caso D</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	0,0500	0,0010	8,0	0,0102	0,0162	0,0117	10,59
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	0,4000	0,0001	0,5	0,0053	0,0086	0,0068	222,94
	<b>PCA</b>	-	-	-	0,0009	0,0025	0,0020	575,60
<b>Caso E</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	0,4000	0,0010	0,5	0,0085	0,0146	0,0147	61,65
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	0,8000	0,0001	1,0	0,0065	0,0124	0,0129	350,16
	<b>PCA</b>	-	-	-	0,0010	0,0046	0,0048	291,40

Tabela 11 – Metodologia SHM não-supervisionada - Pórtico: Porcentagem de “outliers”.

	<b>Critério</b>	<b>Tr. (%)</b>	<b>Def. (%)</b>	<b>Val. (%)</b>	<b>Mon. (%)</b>
<b>Caso A</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	5,0	10,0	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	7,5	90,0	0,0
	<b>PCA</b>	5,0	17,5	100,0	0,0
<b>Caso B</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	12,5	5,0	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	7,5	47,5	0,0
	<b>PCA</b>	5,0	35,0	100,0	0,0
<b>Caso C</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	12,5	37,5	0,2
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	100,0	100,0	0,0
	<b>PCA</b>	5,0	100,0	100,0	0,0
<b>Caso D</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	10,0	0,0	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	30,0	0,0	0,0
	<b>PCA</b>	5,0	100,0	7,5	0,0
<b>Caso E</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	12,5	10,0	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	85,0	100,0	0,0
	<b>PCA</b>	5,0	87,5	92,5	0,0

está correto, uma vez que eles pertencem todos ao mesmo cenário. Portanto, apesar de ser possível diferenciar os dados de monitoramento dos dados de referência em todas as abordagens, apenas a da metodologia proposta foi capaz de retornar pontos  $T^2$  de definição e validação com distribuição similar ao dos pontos  $T^2$  de treinamento. Comportamento este que pode ser também constatado pelos índices de generalização da Tabela 10, cujos

Figura 36 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle - Caso A.

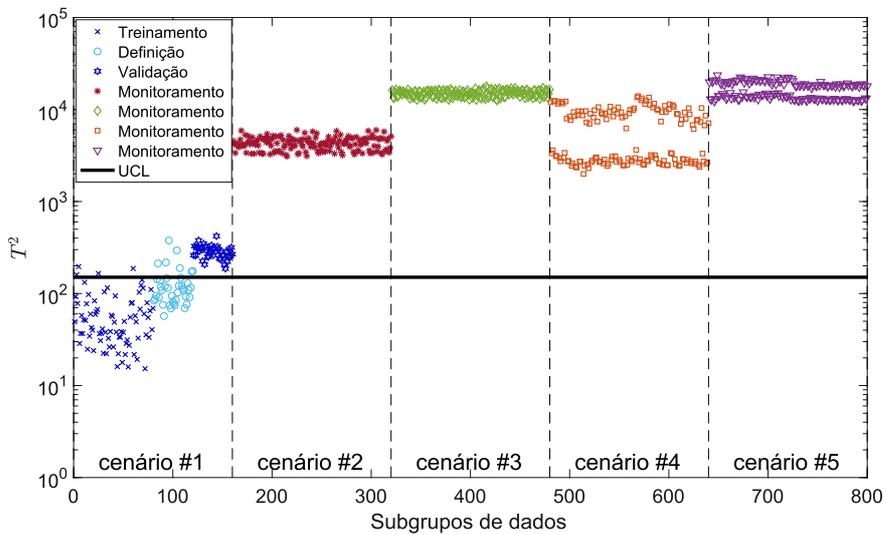
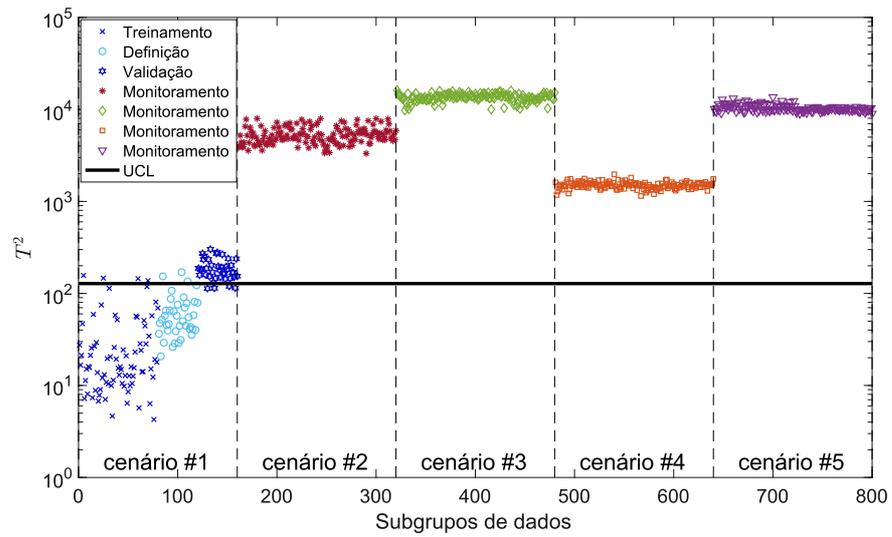
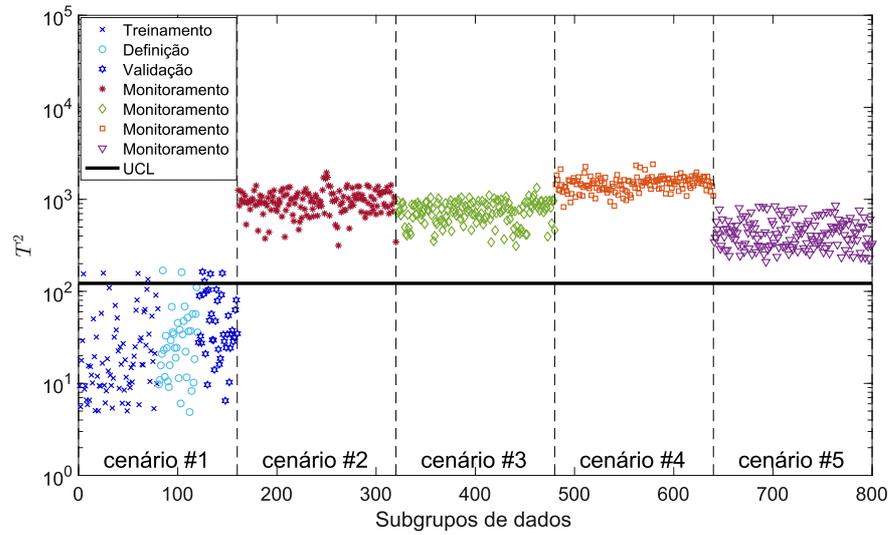


Figura 37 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle - Caso B.

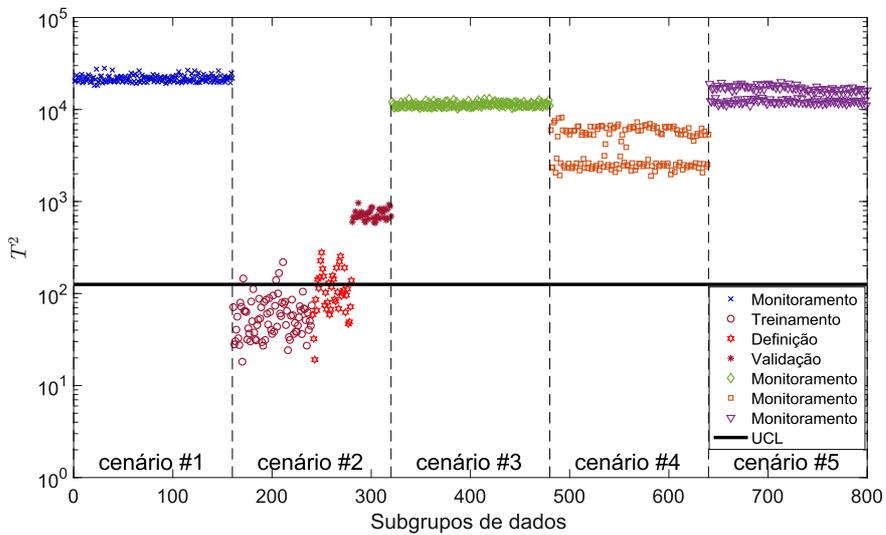
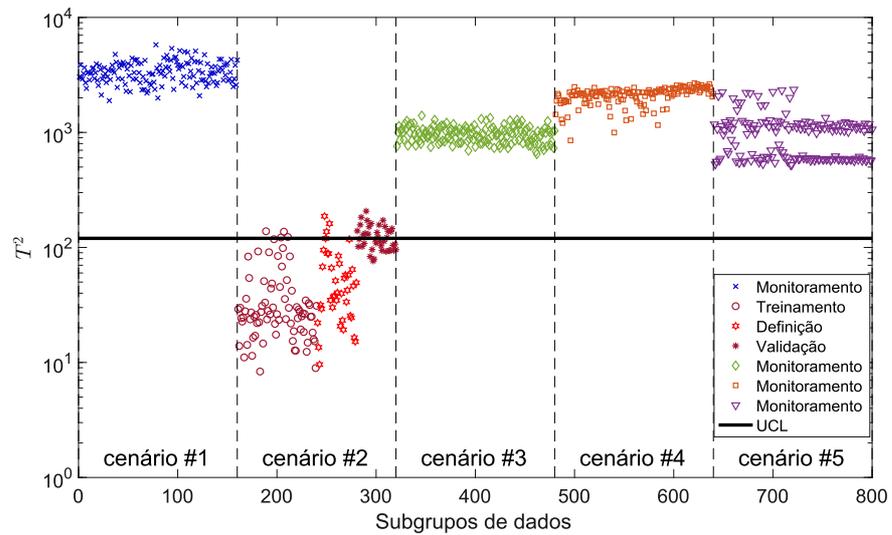
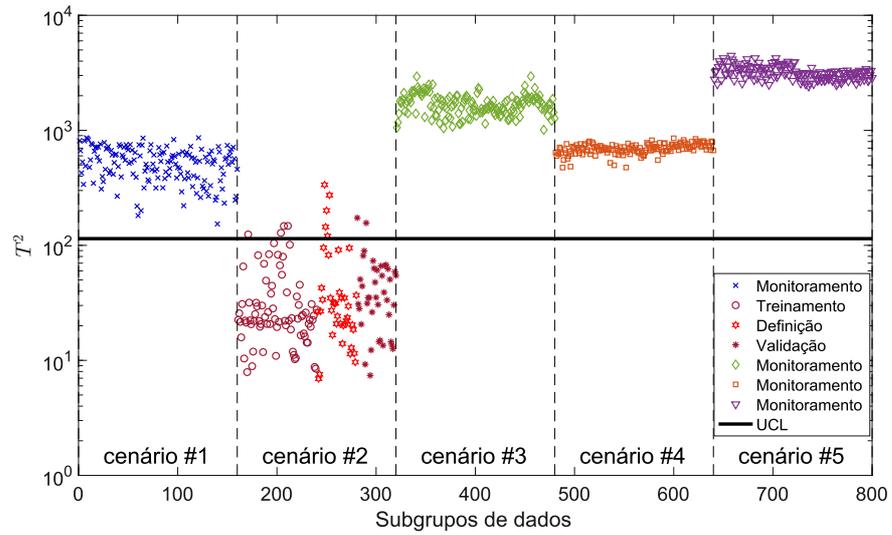


Figura 38 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle - Caso C.

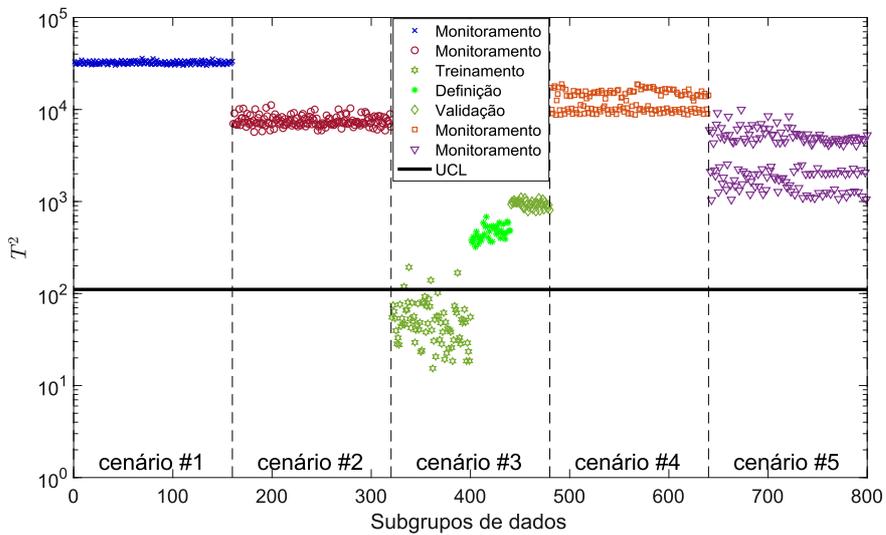
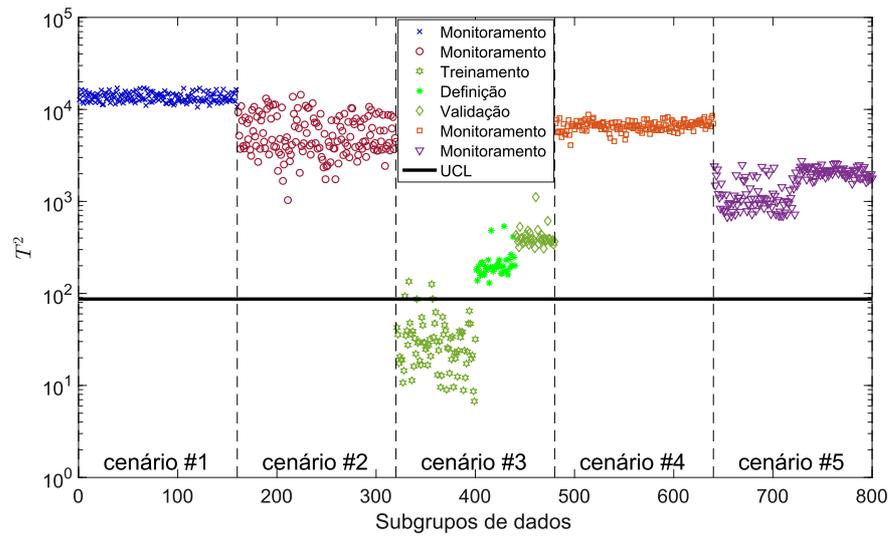
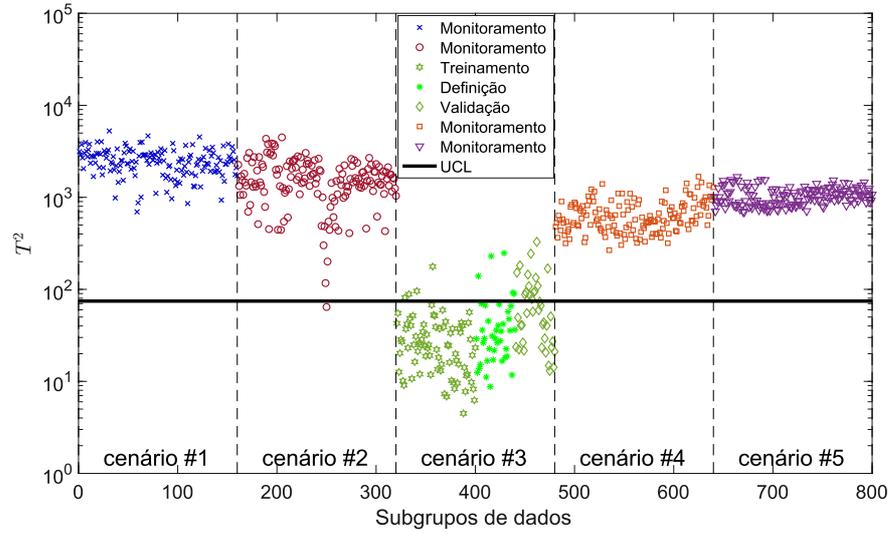


Figura 39 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle - Caso D.

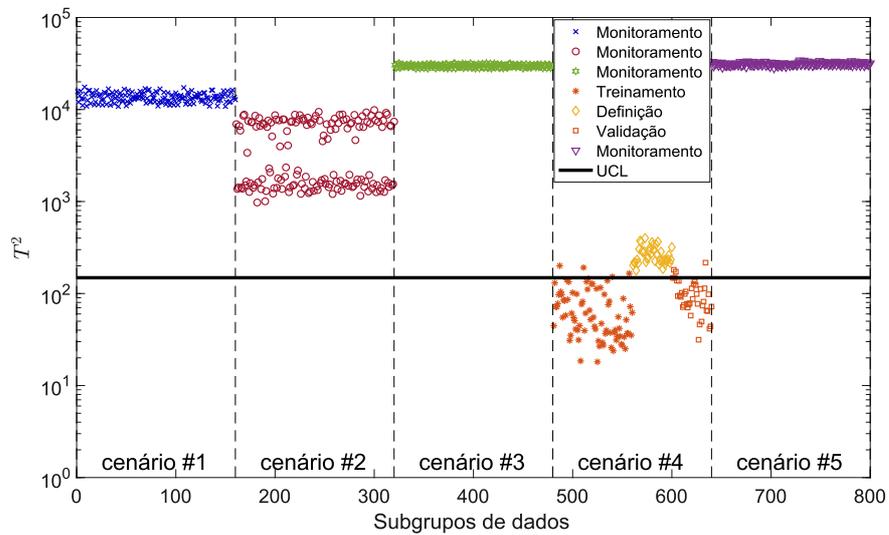
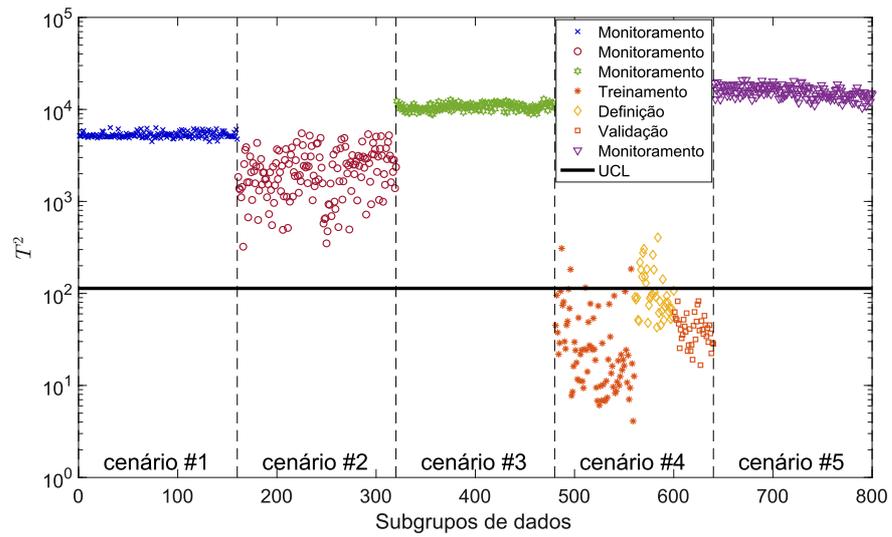
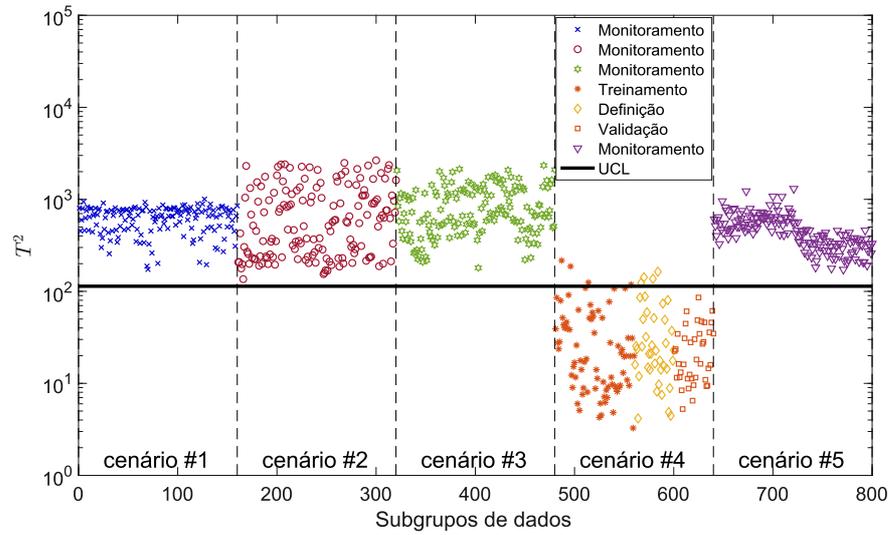
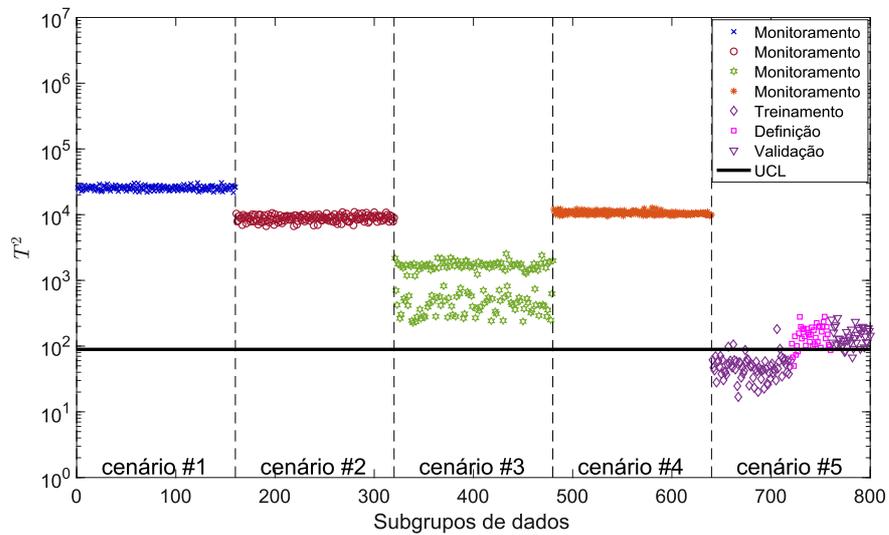
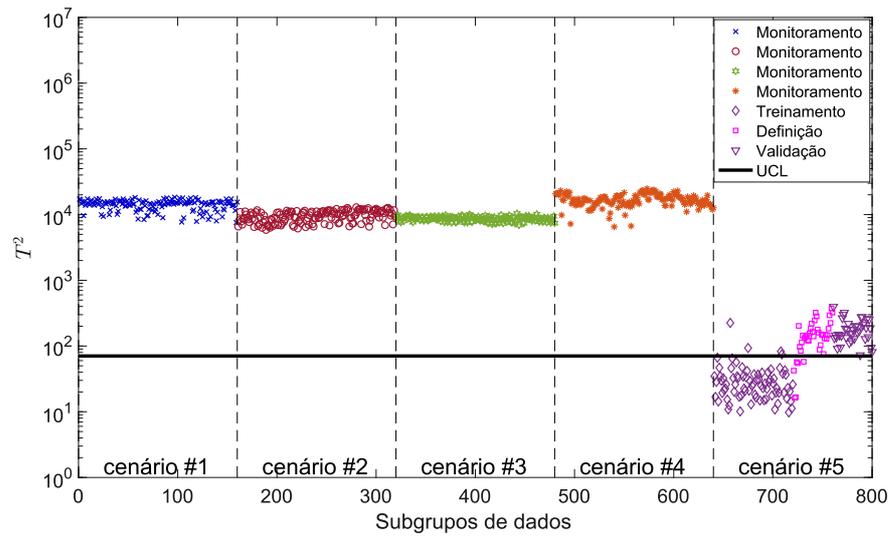
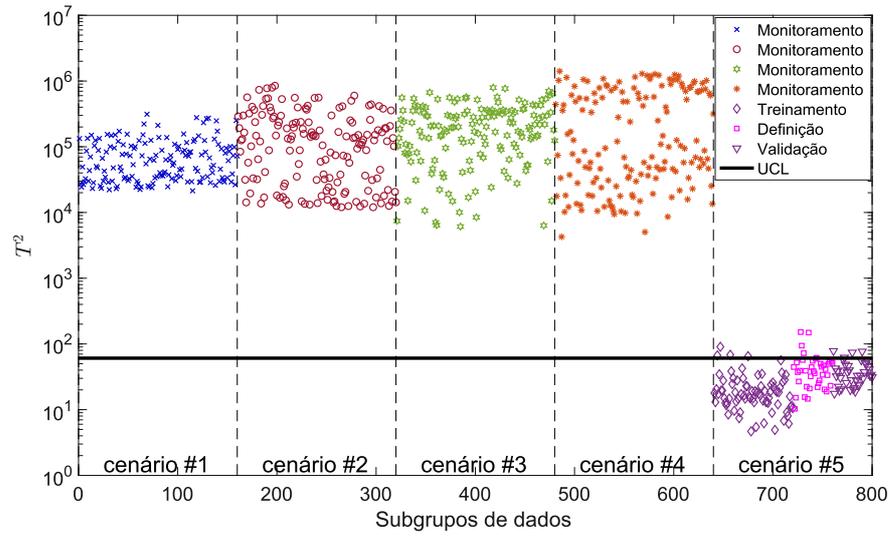


Figura 40 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle - Caso E.



os menores valores estão sempre associados ao primeiro critério.

Com relação à discussão sobre o critério mais adequado para se definir o melhor modelo  $SAE/T^2$ , os resultados comprovam que o melhor desempenho no processo de detecção de alterações estruturais não está necessariamente diretamente relacionado ao menor erro. Para a estrutura analisada, o critério que considerou somente o menor  $\tilde{\zeta}^{def}$  para a escolha do melhor modelo obteve desempenho geral inferior ao critério baseado no uso combinado de  $\tilde{\zeta}^{def}$  e IG, mesmo este havendo os maiores erros de reconstrução. A Tabela 10 mostra que os erros de reconstrução dos sinais aparecem em ordem decrescente da metodologia proposta para a abordagem via PCA. Quanto à estratégia  $PCA/T^2$ , apesar de ter alcançado os menores valores de erro para o número de componentes principais igual à quantidade de características SAE (30), os modelos PCA estão frequentemente ligados a valores superiores de IG e às maiores porcentagens de *outliers*. Ressalta-se que 30 componentes principais explicam 99,99% da variância dos dados do pórtico.

Com o objetivo de verificar se uma ordenação específica dos dados (possíveis exemplos correlacionados) não está influenciando o desempenho da metodologia  $SAE/T^2$ , além das cartas de controle plotadas considerando um único modelo, foram construídas, para cada uma das abordagens, cartas de controle representando a estatística  $T^2$  de 30 diferentes modelos SAE - gerados por sucessivas aleatorizações dos dados de treinamento, com os mesmos hiperparâmetros  $\lambda$ ,  $\rho$  e  $\beta$  da Tabela 10. As Figuras 41 à 45 apresentam as cartas de controle para os casos de A à E, respectivamente. Nesta parte, os limites UCL são calculados tomando a média dos valores UCL dos 30 modelos. A porcentagem de *outliers* identificados é exposta na Tabela 12.

Os gráficos da Figura 41 à Figura 45, bem como os valores da Tabela 12, mostram que a influência da aleatoriedade nos resultados ora apresentados não é suficiente para invalidar as análises realizadas. Observa-se um comportamento semelhante entre os resultados obtidos anteriormente e os alcançados pelos 30 modelos, independente do critério considerado. Por fim, reitera-se aqui que, embora todas as abordagens tenham conseguido diferenciar os dados de referência dos dados de treinamento, apenas a metodologia  $SAE/T^2$  proposta foi capaz de classificar corretamente os dados de treinamento, definição e validação, aspecto importante para que um monitoramento não-supervisionado seja de fato aplicado.

Figura 41 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle para 30 modelos SAE - Caso A.

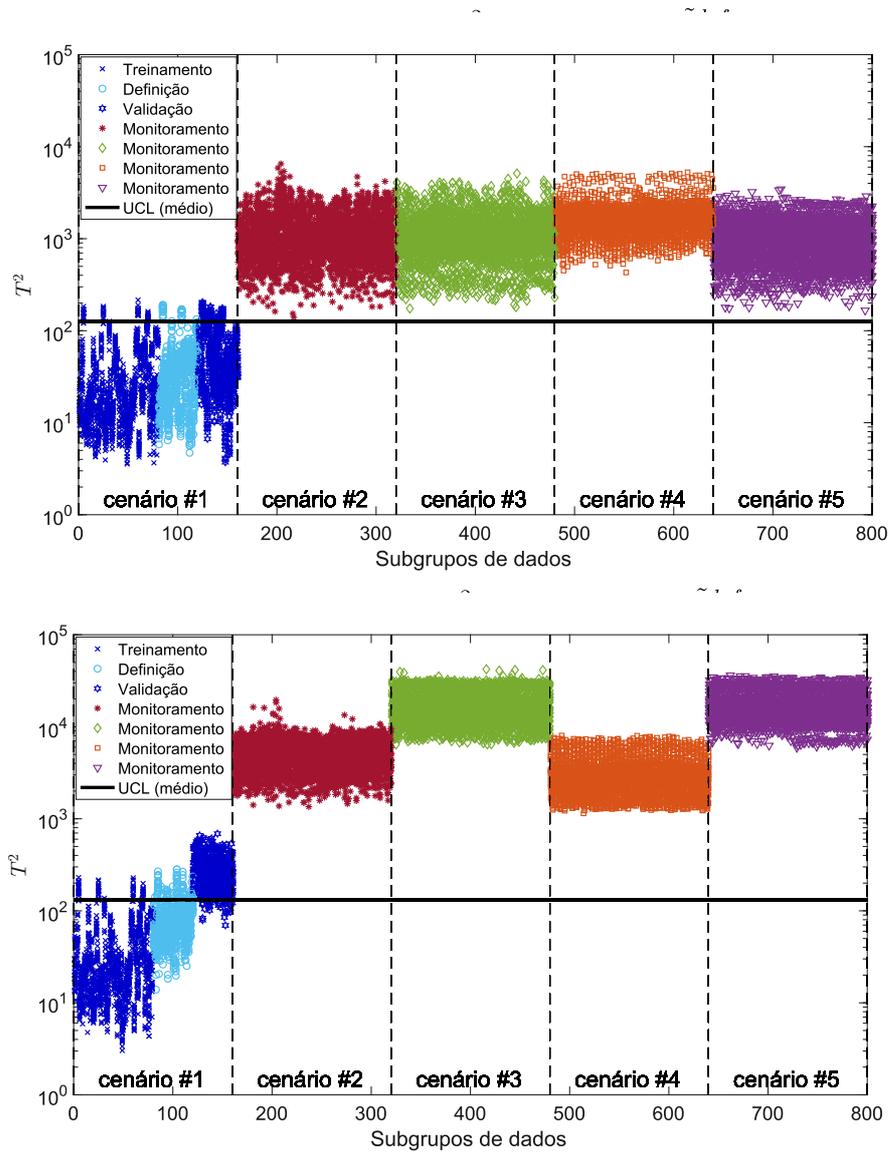


Figura 42 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle de para modelos SAE - Caso B.

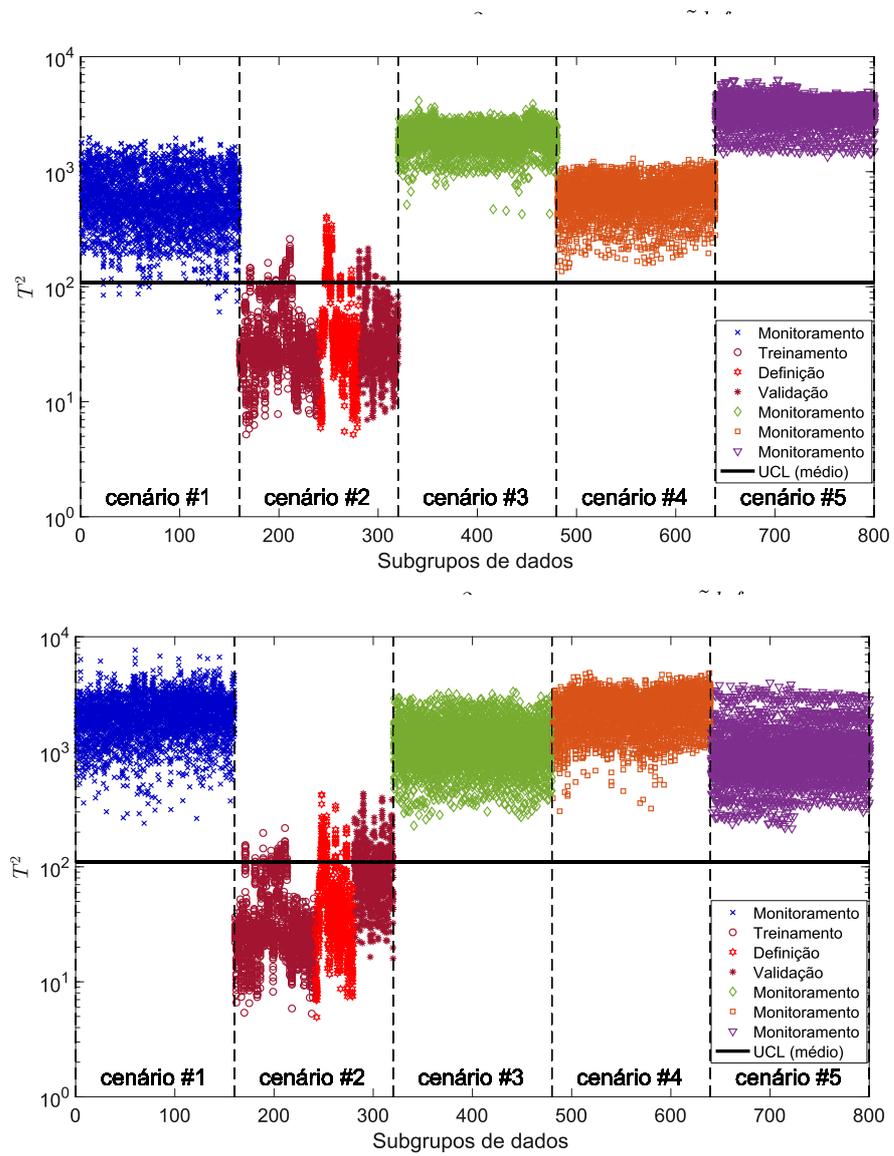


Figura 43 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle de para modelos SAE - Caso C.

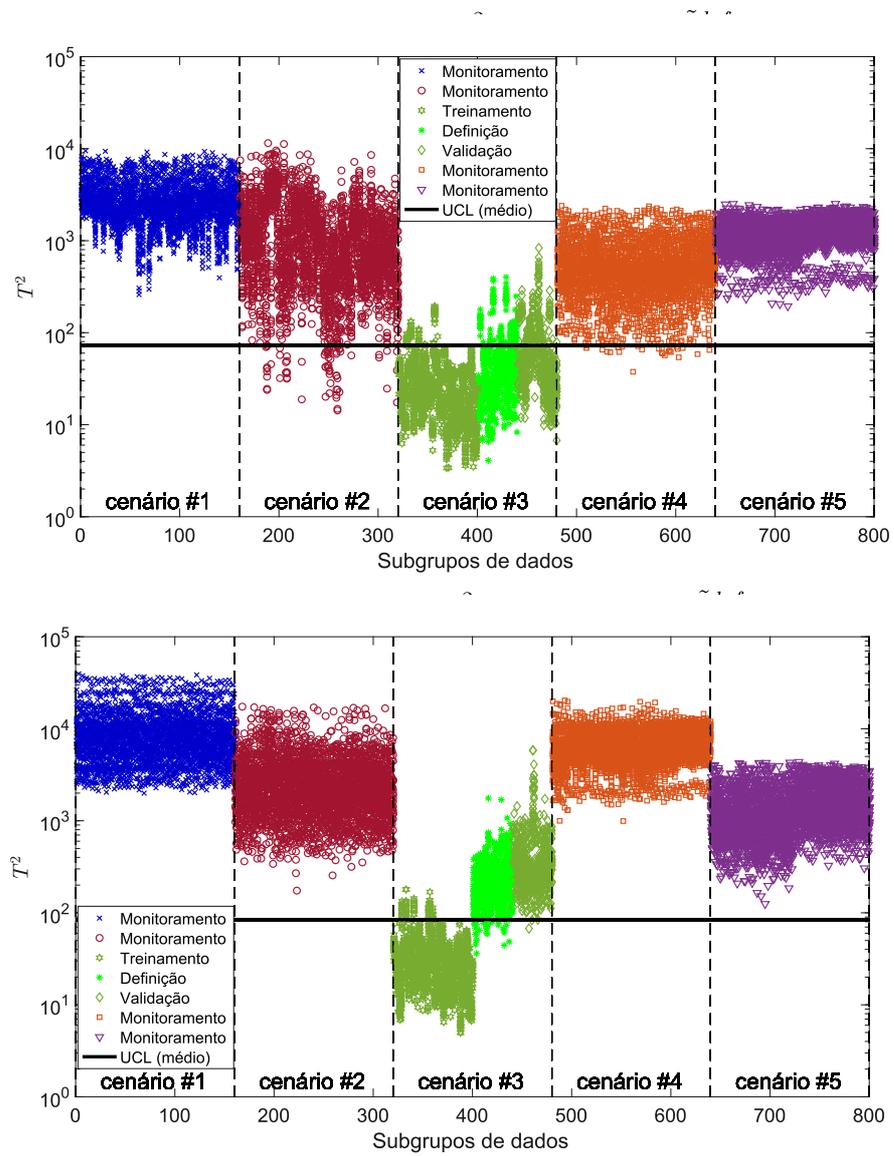


Figura 44 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle para 30 modelos SAE - Caso D.

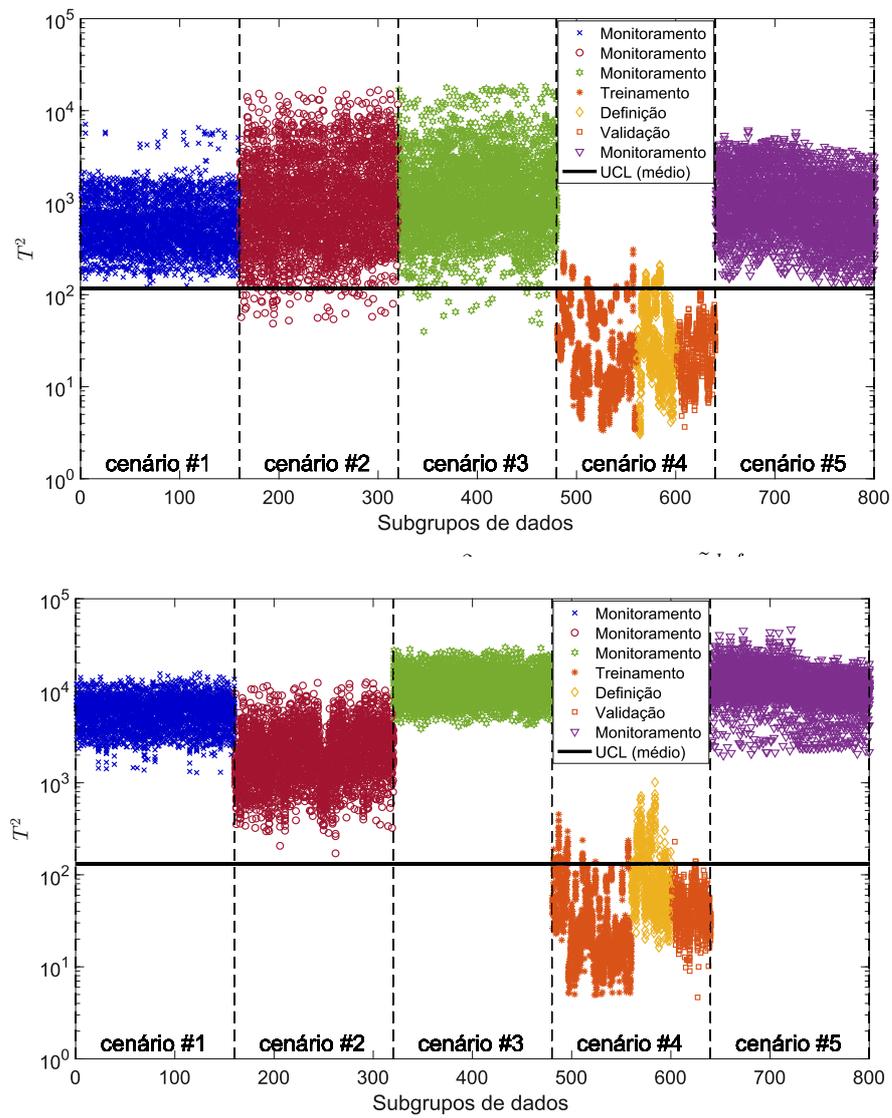


Figura 45 – Metodologia SHM não-supervisionada - Pórtico: Cartas de controle para 30 modelos SAE - Caso E.

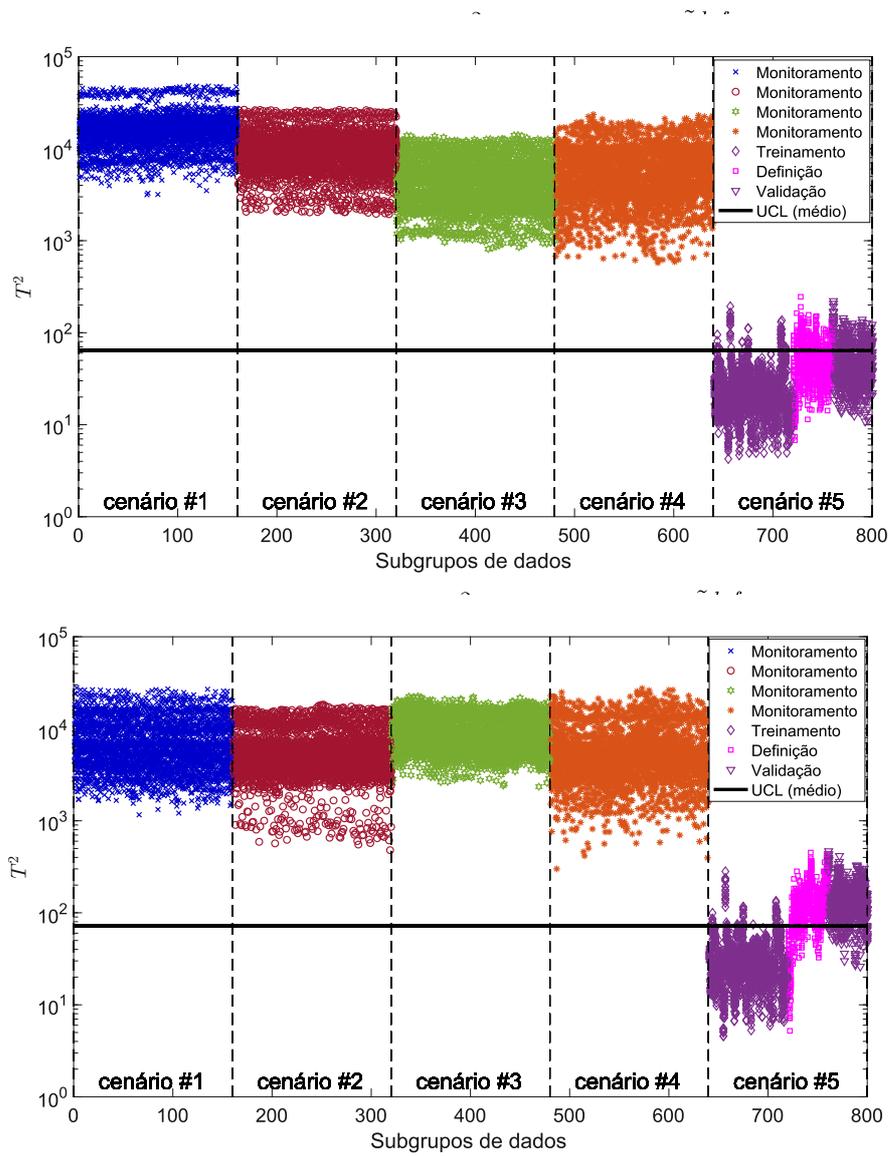


Tabela 12 – Metodologia SHM não-supervisionada - Pórtico: Porcentagem de “outliers” para 30 modelos SAE/ $T^2$ .

	<b>Critério</b>	<b>Tr. (%)</b>	<b>Def. (%)</b>	<b>Val. (%)</b>	<b>Mon. (%)</b>
<b>Caso A</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	5,25	11,00	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	13,88	95,63	0,0
<b>Caso B</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	15,88	5,25	0,07
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	14,12	30,75	0,0
<b>Caso C</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	20,13	35,25	0,55
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	93,75	99,50	0,0
<b>Caso D</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	6,88	0,12	0,49
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	25,75	0,63	0,0
<b>Caso E</b>	<b>IG e <math>\tilde{\zeta}^{def}</math></b>	5,0	32,88	28,88	0,0
	<b>Menor <math>\tilde{\zeta}^{def}</math></b>	5,0	80,13	90,25	0,0

## 6.2 APLICAÇÃO II - PONTE Z24

A ponte Z24, exibida na Figura 46, era um viaduto rodoviário localizado na região de Berna, na Suíça, construído no início da década de 1960 para conectar as comunas de Koppigen e Utzenstorf. Esta estrutura protendida tinha 58m de comprimento, e era composta por três vãos contínuos de 14m, 30m e 14m, respectivamente, apoiados em quatro pilares, conforme ilustra a Figura 47(a). Devido ao projeto de construção de uma nova linha ferroviária, a ponte teve que ser demolida e, antes da sua total destruição, foi instrumentada e gradativamente danificada [115].

Figura 46 – Ponte Z24.

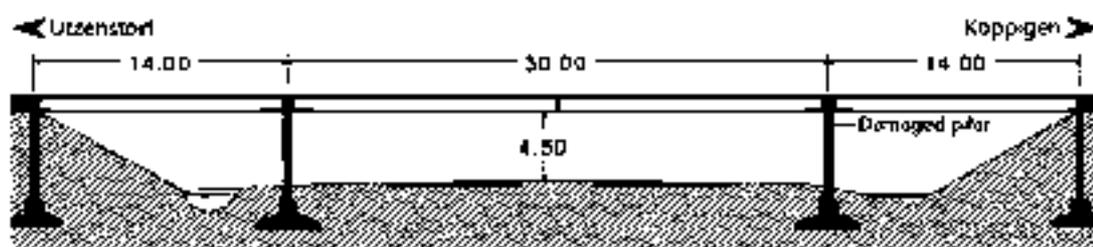


Fonte: De Roeck *et al.* (2000) [115].

O presente estudo avalia a metodologia SAE/ $T^2$  usando sinais dinâmicos de ensaios de vibração forçada realizados em quatro cenários estruturais da ponte Z24, onde apenas danos provenientes de recalque foram considerados. Os recalques foram impostos à estrutura através de um conjunto de macacos hidráulicos instalados no pilar indicado na Figura 47. A descrição dos quatro cenários estruturais, ordenados de acordo com sua progressão ao longo do tempo, é apresentada na Tabela 13. Dois “*shakers*” foram utilizados para gerar excitações verticais com largura de banda variando entre 3-30Hz. Em cada cenário estrutural foram conduzidos nove testes dinâmicos com o auxílio de cinco acelerômetros, instalados em três pontos de medição, R1, R2 e R3, tal como mostra a Figura 47(b). As respostas vibracionais associadas a estes acelerômetros possuem 65835 pontos amostrados, coletados por aproximadamente 11min a uma frequência de amostragem de 100Hz. A Figura 48 exhibe uma resposta típica da ponte Z24 para os testes de vibração forçada. As frequências naturais da estrutura e a variação de temperatura - antes e depois dos danos - são apresentadas na Tabela 14. Salienta-se que a evolução das frequências, bem como os modos estruturais - expostos na Figura 49 a título de informação -, são derivados dos dados de ensaios de vibração ambiente, calculados pelo método de Identificação Estocástica de Subespaço[115].

Figura 47 – Desenho esquemático da Ponte Z24 (unidade: m).

(a) Vista em corte longitudinal.

Fonte: De Roeck *et al.* (2000) [115].

(b) Vista superior e esquema experimental.

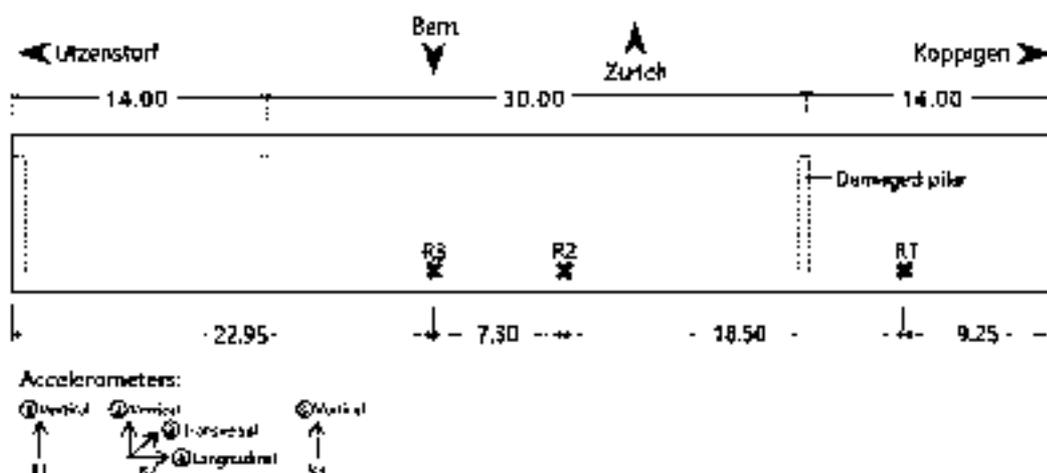


Tabela 13 – Descrição dos cenários estruturais da ponte Z24.

Cenário estrutural	Descrição
Não danificado#1	1ª medição de referência - Estrutura "sã"
Não danificado#2	2ª medição de referência - Estrutura "sã" (com o sistema de macacos hidráulicos instalados)
Danificado#1	Recalque de 40mm (pilar indicado)
Danificado#2	Recalque de 80mm (pilar indicado)

Fonte: De Roeck *et al.* (2000) [115].

Com a intenção de verificar a influência do efeito da variação de temperatura entre os cenários estruturais dentro da abordagem proposta, dois casos distintos são analisados: Caso#1, utilizando os dados do cenário não danificado#1 e danificado#1, em que a diferença absoluta de temperatura entre eles é de 12°C; e Caso#2, empregando os dados não danificado#2 e danificado#2, ambos aquisitados sob a mesma temperatura. Os históricos de acelerações foram reorganizados em sinais de 10 segundos, resultando em respostas estruturais com 1000 pontos amostrados ( $100\text{Hz} \times 10\text{s} = 1000$  pontos). Diferentemente da aplicação anterior (pórtico), as análises da ponte Z24 são realizadas para cada acelerômetro separadamente. Portanto, cada cenário estrutural e acelerômetro fornece uma matriz de dados  $[1000 \times 580]$ , conforme descrito na Eq.6.7:

Figura 48 – Resposta típica da ponte Z24.

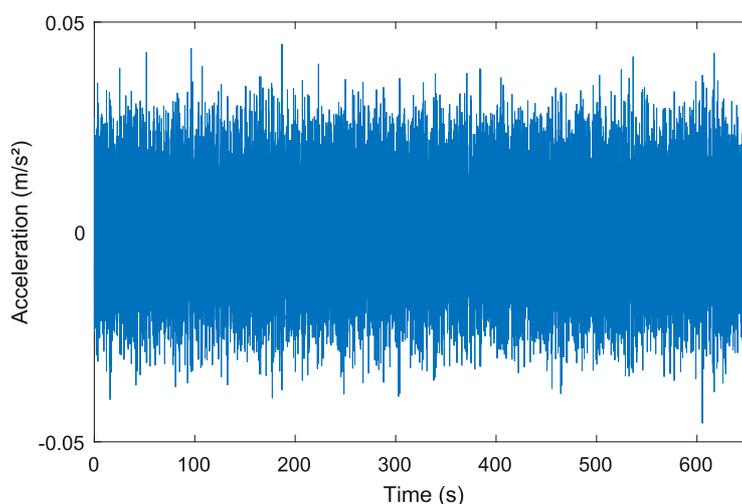


Tabela 14 – Casos analisados da ponte Z24 - Variação das frequências naturais e temperaturas.

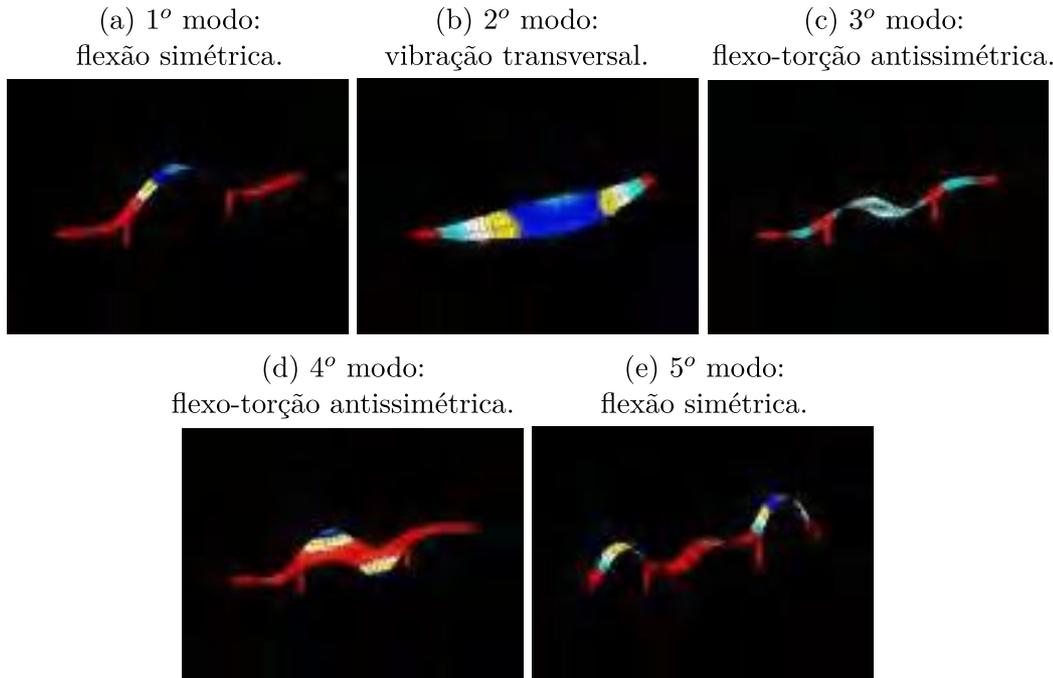
Cenário estrutural	Temperatura	1ª freq. natural	2ª freq. natural	3ª freq. natural	4ª freq. natural	5ª freq. natural
<b>Caso#1</b>						
Não danificado#1	17°C	3,92Hz	5,12Hz	9,93Hz	10,52Hz	12,69Hz
Danificado#1	29°C	3,86Hz	4,93Hz	9,74Hz	10,25Hz	12,48Hz
<b>Diferença absoluta</b>	12°C	0,06Hz	0,19Hz	0,19Hz	0,27Hz	0,21Hz
<b>Caso#2</b>						
Não danificado#2	26°C	3,89Hz	5,02Hz	9,80Hz	10,30Hz	12,67Hz
Danificado#2	26°C	3,76Hz	5,01Hz	9,37Hz	9,90Hz	12,18Hz
<b>Diferença absoluta</b>	0°C	0,13Hz	0,01Hz	0,43Hz	0,40Hz	0,49Hz

Fonte: De Roeck *et al.* (2000) [115].

$$\mathbf{X}_{d(1000 \times 580)}^c = \begin{bmatrix} Ac_k(1, 1) & Ac_k(1, 2) & \dots & Ac_k(1, 580) \\ Ac_k(2, 1) & Ac_k(2, 2) & \dots & Ac_k(2, 580) \\ \vdots & \vdots & \ddots & \vdots \\ Ac_k(1000, 1) & Ac_k(1000, 2) & \dots & Ac_k(1000, 580) \end{bmatrix} \quad (6.7)$$

onde o subscrito  $d$  indica a categoria dos sinais: 1 - sem dano, 2 - com dano; o sobrescrito  $c$  faz referência a qual caso conjunto de dados pertence (#1 ou #2) e, cada elemento  $Ac_k(i, j)$  representa a resposta medida pelo acelerômetro  $k$  (com  $k = 1, \dots, 5$ ) em um tempo discreto  $i$  (com  $i = 1, \dots, 1000$ ) para o  $j$ -ésimo sinal (com  $j = 1, \dots, 580$ ). Em ambos os casos, os dados da estrutura “sã” foram aplicados nas etapas de treinamento, definição e validação, enquanto que os dados relativos à estrutura danificada foram utilizados para monitoramento, conforme definido na Tabela 15. As amplitudes dos sinais de cada matriz de dados são normalizadas entre 0 e 1 considerando os valores observados nos respectivos conjuntos de treinamento.

Figura 49 – Modos de vibração da ponte Z24 - cenário estrutural não danificado#1.



Fonte: De Roeck *et al.* (2000) [115].

Tabela 15 – Ponte Z24: casos analisados e organização dos dados.

Caso	Dados de treinamento	Dados de definição	Dados de validação	Dados de monitoramento
#1	$\mathbf{X}_{1(1\dots 1000;1\dots 300)}^1$	$\mathbf{X}_{1(1\dots 1000;301\dots 440)}^1$	$\mathbf{X}_{1(1\dots 1000;441\dots 580)}^1$	$\mathbf{X}_2^1$
#2	$\mathbf{X}_{1(1\dots 1000;1\dots 300)}^2$	$\mathbf{X}_{1(1\dots 1000;301\dots 440)}^2$	$\mathbf{X}_{1(1\dots 1000;441\dots 580)}^2$	$\mathbf{X}_2^2$

Com exceção do número de neurônios na camada interna do SAE (dim ( $h$ ) - cuja sua determinação será abordada na subseção a seguir) e dos hiperparâmetros  $\rho, \beta$  e  $\lambda$  (obtidos através do procedimento de busca em grade), os demais parâmetros de treinamento dos modelos auto-codificadores da ponte Z24 são os mesmos adotados na aplicação do pórtico. Com relação às cartas de controle  $T^2$ , cada subgrupo de dados é composto por 15 observações (R=15). Portanto, o valor do limite UCL corresponde ao 95<sup>ésimo</sup> percentil dos 20 valores  $T^2$  da etapa de treinamento (300 exemplos de treinamento/15 observações = 20 subgrupos de dados).

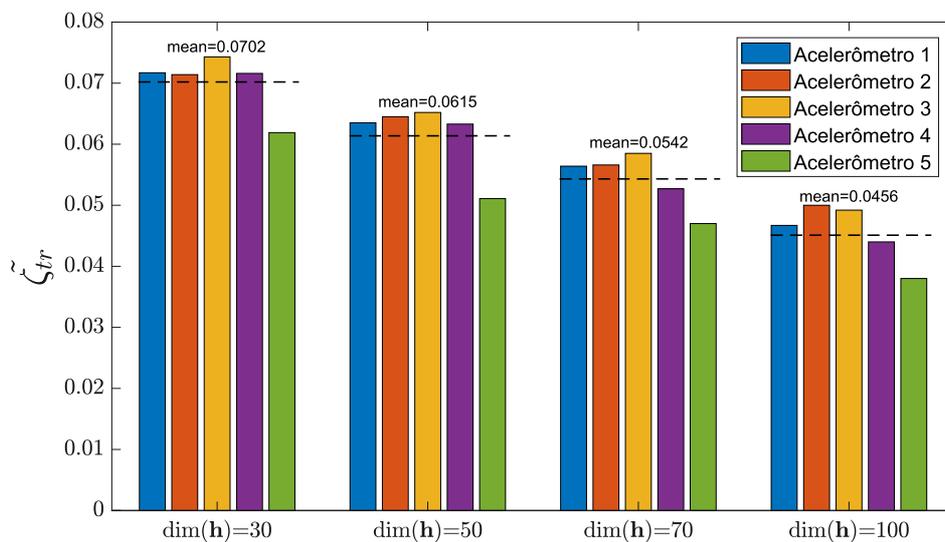
### 6.2.1 Resultados

Com o propósito de avaliar a quantidade de características SAE necessárias para uma boa representação dos sinais da ponte Z24, a Figura 50 apresenta o desempenho dos modelos autocodificadores com 30, 50, 70 e 100 neurônios na camada interna que obtiveram o menor erro de reconstrução médio de treinamento  $\zeta^{tr}$  (entre os 160 modelos construídos via busca em grade para cada dim ( $h$ ) analisada). Tais modelos reduzem a dimensionalidade do problema de 1000 pontos amostrados para 30, 50, 70 e 100 características

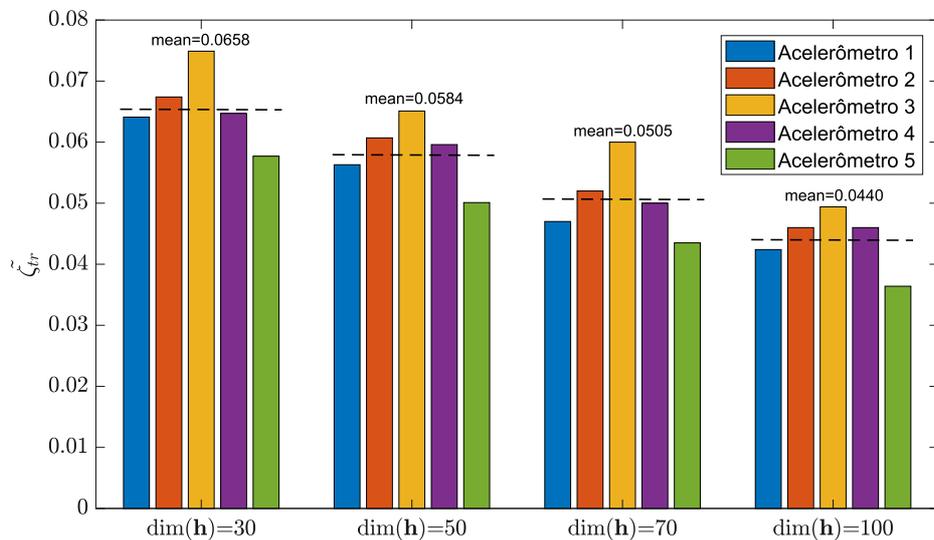
(redes com configuração geral 1000-30-1000, 1000-50-1000, 1000-70-1000 e 1000-100-1000, respectivamente). A ideia de analisar redes autocodificadoras com 100 neurônios na sua camada interna (para além das quantidades de 30, 50 e 70 consideradas para o problema do pórtico) parte do pressuposto de que o monitoramento e detecção de dano em estruturas reais geralmente envolve sinais com muitas incertezas, o que, conseqüentemente, pode levar à necessidade de uma maior quantidade de neurônios (quando comparado com a estrutura estudada anteriormente). Cabe destacar que, embora seja válido utilizar  $\dim(\mathbf{h}) > 100$ , aumentar o número de neurônios pode demandar um tempo de processamento mais expressivo, além de não garantir o bom funcionamento da metodologia de dano SAE/ $T^2$ . Desta forma, admitiu-se aqui limitar a quantidade máxima de características SAE a 10% do tamanho original do sinal (assim como realizado em algumas das análises do capítulo 4).

Figura 50 – Ponte Z24: Erro de reconstrução  $\zeta^{tr}$  em função do número de características SAE.

(a) Caso #1.



(b) Caso #2.



Ao analisar os gráficos da Figura 50, para os dois casos estudados da ponte Z24, optou-se pelos modelos SAE contruídos com 100 neurônios na camada intermediária ( $\dim(\mathbf{h})=100$ ). Ainda que em ambos os casos #1 e #2 possa ser observada uma taxa de decaimento aproximadamente linear (em torno de -0,5% por  $\dim(\mathbf{h})$ ), verifica-se para o Caso #2 uma queda do erro  $\tilde{\zeta}^{tr}$  relativamente menor ao aumentar o número de neurônios de 70 para 100 (-0,4% por  $\dim(\mathbf{h})$  contra os -0,6% por  $\dim(\mathbf{h})$  dos demais intervalos) - o que sinaliza uma possível tendência de estabilização. Ademais, os modelos com 100 neurônios aparentemente apresentaram valores  $\tilde{\zeta}^{tr}$  menos dispersos com relação a média.

Uma vez gerados os 160 modelos SAE de 100 códigos internos, a etapa subsequente consiste em definir o melhor modelo SAE/ $T^2$  para cada um dos acelerômetros e casos de estudo (#1 e #2). Entretanto, para os dados da presente estrutura, a estratégia de definição do melhor modelo baseado na busca de uma única combinação de parâmetros  $\rho$ ,  $\beta$  e  $\alpha$ , conforme estabelecido no início do capítulo, levou a resultados menos satisfatórios em parte significativa das vezes. Acredita-se que isso pode ter ocorrido devido ao fato dos sinais da ponte serem de natureza mais complexa (estrutura real, com carregamento aleatório e influência do ambiente - vento e temperatura), ao contrário dos dados do pórtico por exemplo, onde os sinais estruturais eram mais bem comportados (experimento com carregamento de impacto relativamente controlado e temperatura constante) o que, conseqüentemente, fez com que a estratégia de definição do melhor modelo da forma como foi inicialmente sugerida funcionasse efetivamente. Por este motivo, optou-se então por considerar um conjunto com os cinco melhores modelos que atendessem às condições da Eq. (6.3) e Eq. (6.4), ao invés de diretamente selecionar o primeiro melhor. Desta forma, aumenta-se a chance de ocorrência de um resultado favorável, em virtude de que, por se tratar de um problema não-determinístico, os modelos SAE/ $T^2$  estão sujeitos a variações nos seus resultados. As cartas de controle de tal abordagem SAE/ $T^2$  aplicada à ponte Z24 são exibidas na Figura 51 para o Caso #1 e na Figura 52 para o Caso #2. Além do critério de seleção dos 5 melhores modelos baseado no critério definido na Eq. (6.3) e Eq. (6.4), analisou-se também para comparação o desempenho dos modelos SAE/ $T^2$  que obtiveram os 5 menores erros  $\tilde{\zeta}^{def}$  - Figura 53 para o Caso#1 e Figura 54 para o Caso#2 - e dos modelos PCA/ $T^2$  com 100 componentes principais - Figura 55 para o Caso#1 e Figura 56 para o Caso#2. Para facilitar a apresentação dos resultados, as Figuras 51 à 54 incluem apenas duas cartas de controle por acelerômetro (para um e 30 modelos, respectivamente), relativas ao modelo SAE/ $T^2$  que melhor apontou os diferentes cenários estruturais (dentre os cinco previamente selecionados). Sendo assim, cada figura é composta por 5 pares de gráficos, associados aos acelerômetros 1 à 5 respectivamente. Enquanto os gráficos da esquerda representam as cartas de único modelo SAE/ $T^2$ , os da direita retratam a estatística  $T^2$  para 30 diferentes modelos SAE construídos com os mesmos hiperparâmetros  $\rho$ ,  $\beta$  e  $\lambda$ . Neste último caso em específico, o limite UCL é calculado considerando a média do UCL dos 30 modelos.

Figura 51 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para um e para 30 modelos SAE/ $T^2$ , respectivamente - Caso #1 da ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.

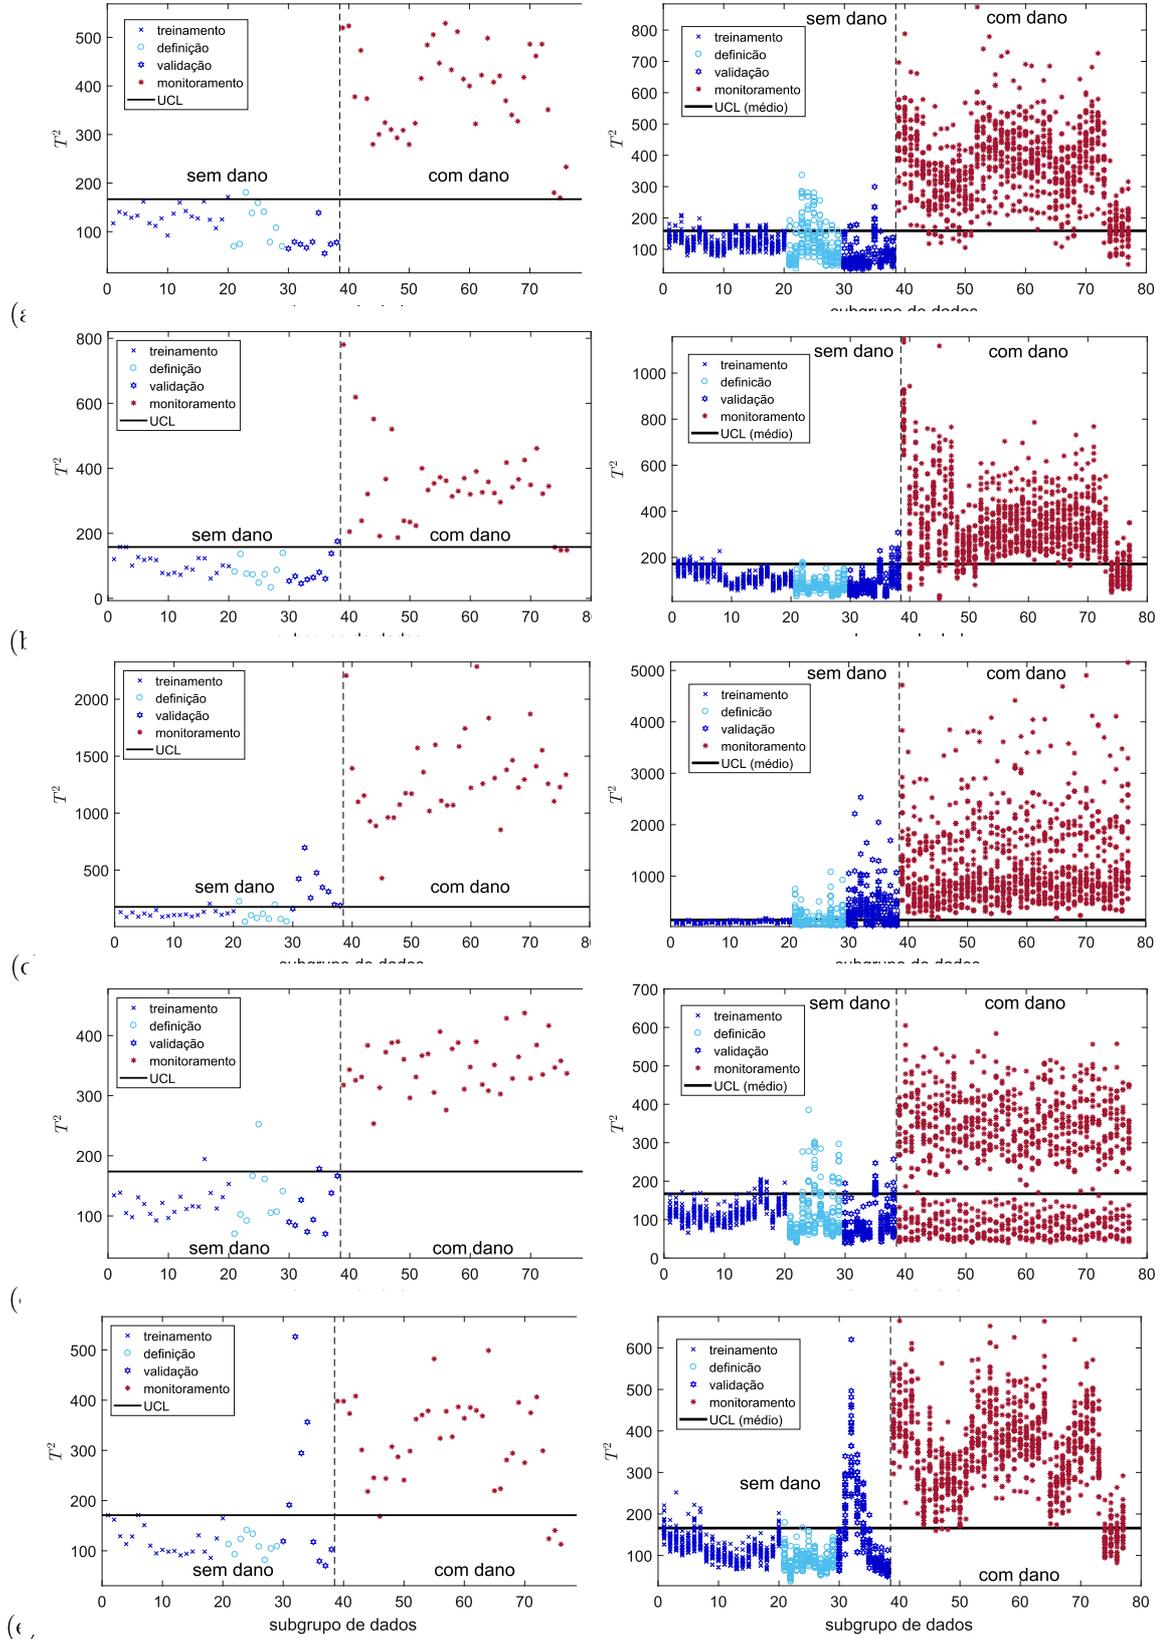


Figura 52 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para um e para 30 modelos SAE/ $T^2$ , respectivamente - Caso #2 da ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.

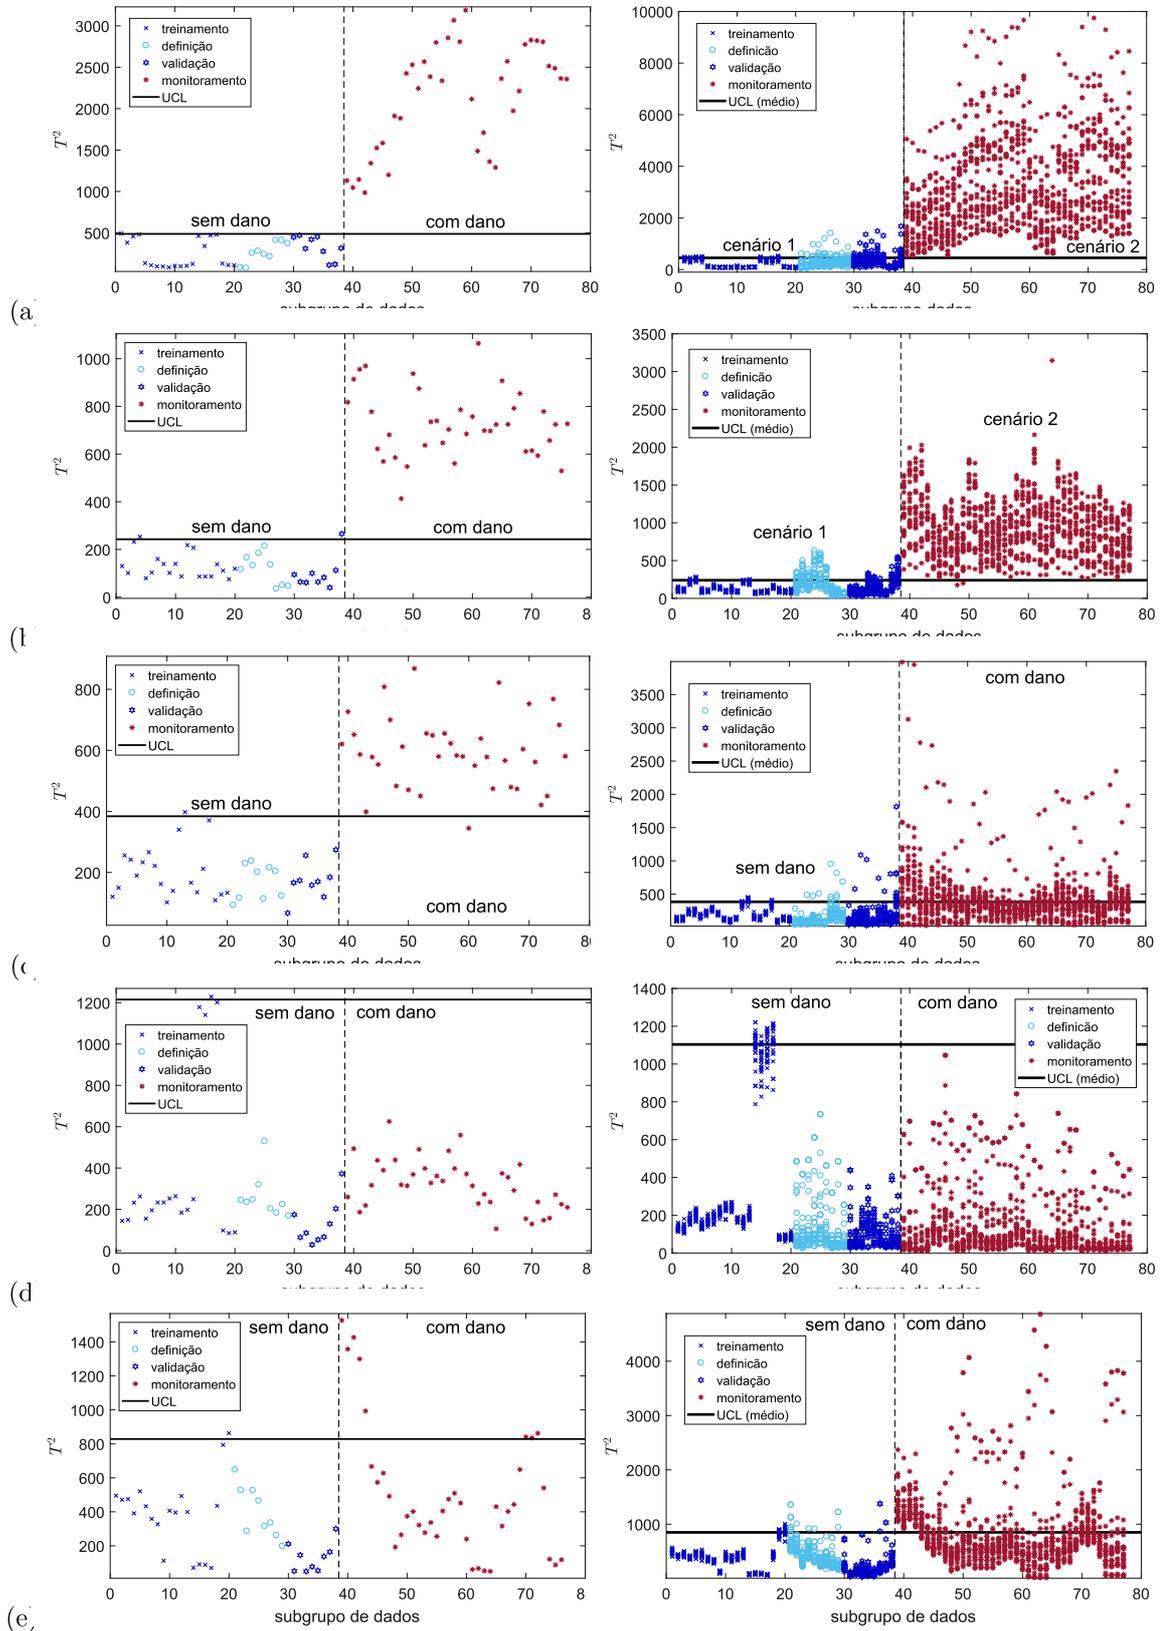


Figura 53 – Metodologia SAE/ $T^2$  - Critério menor  $\tilde{\zeta}^{def}$ : Cartas de controle para um e para 30 modelos SAE/ $T^2$ , respectivamente - Caso #1 da ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.

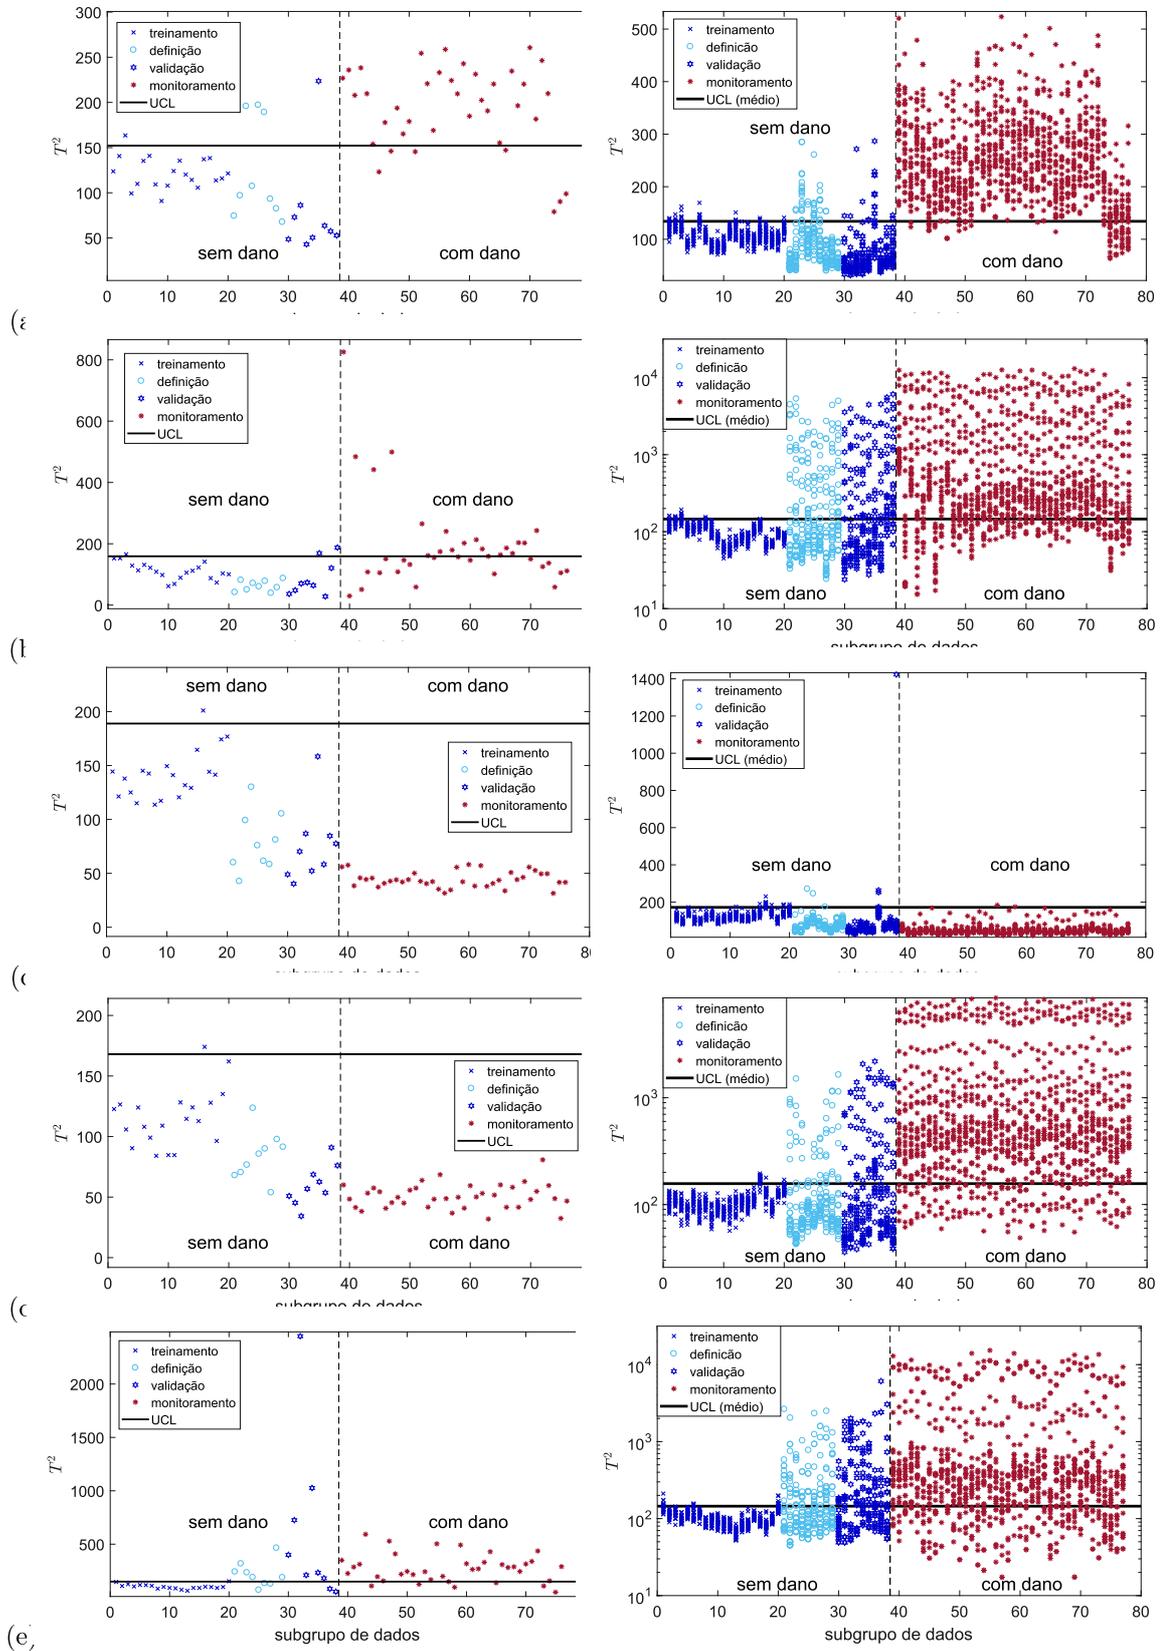


Figura 54 – Metodologia SAE/ $T^2$  - Critério menor  $\tilde{\zeta}^{def}$ : Cartas de controle para um e para 30 modelos SAE/ $T^2$ , respectivamente - Caso #2 da ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.

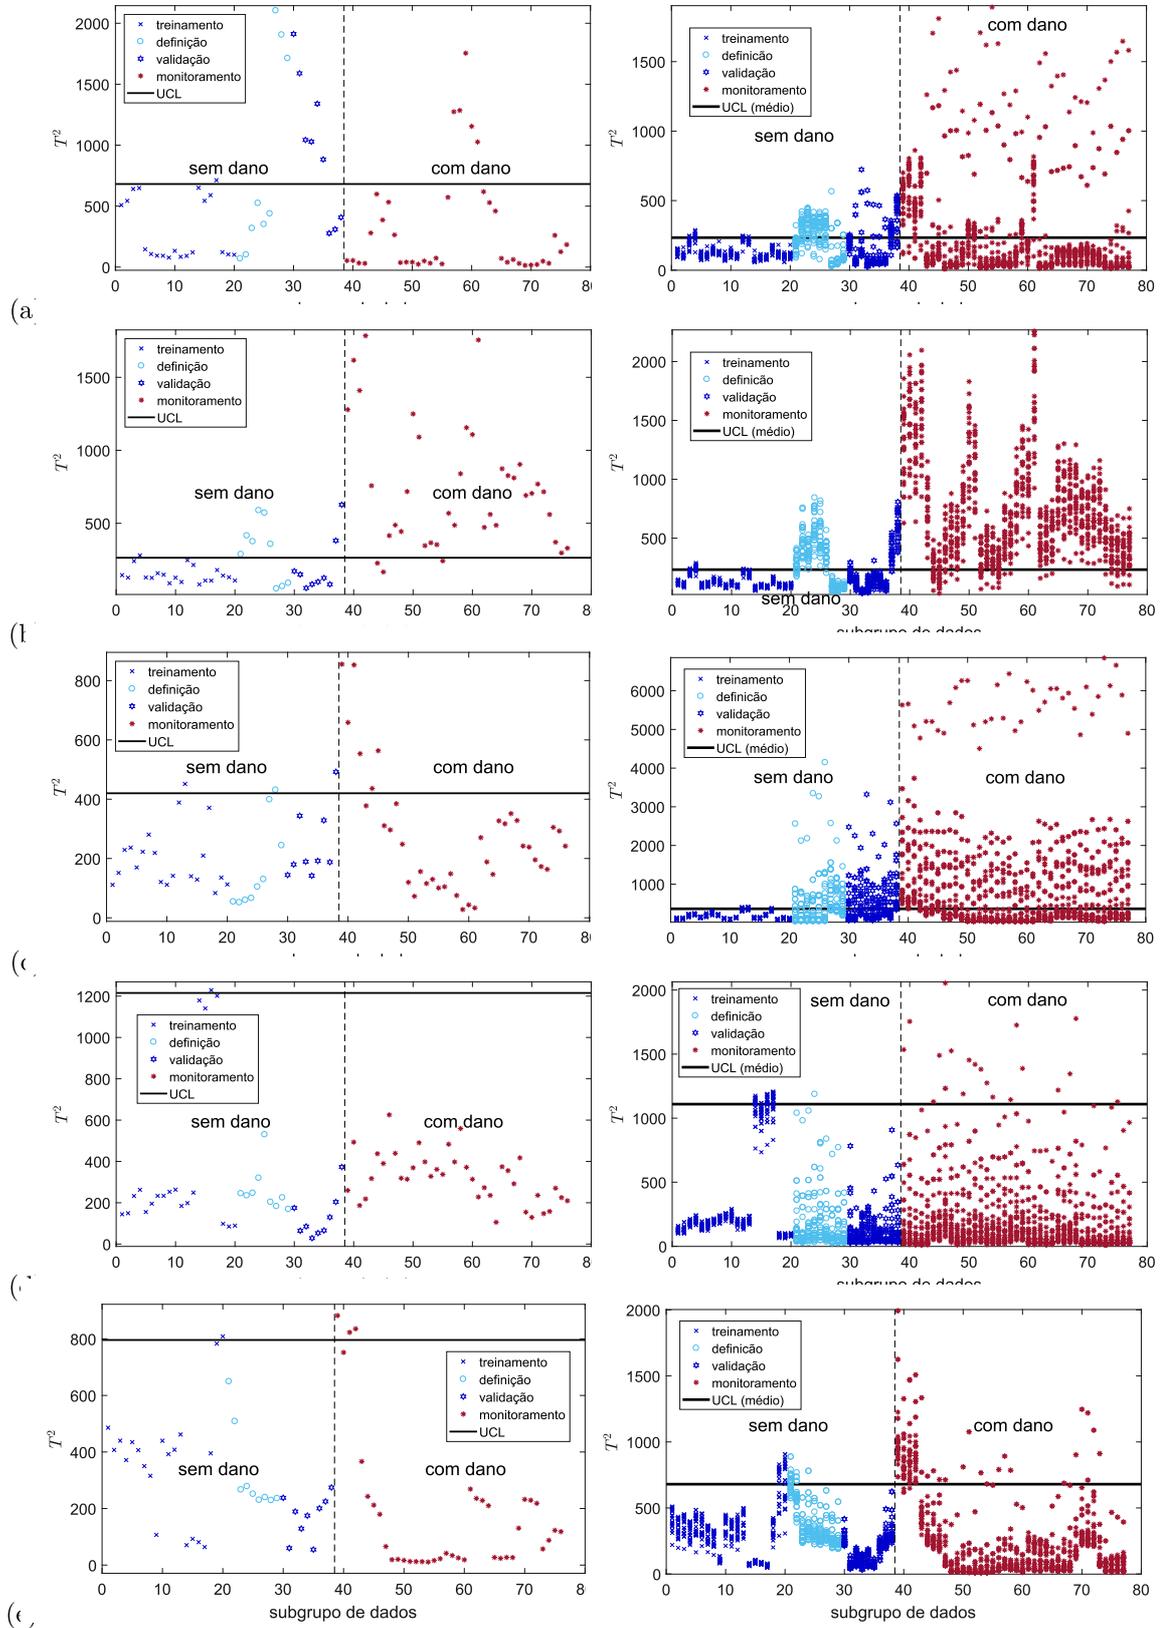
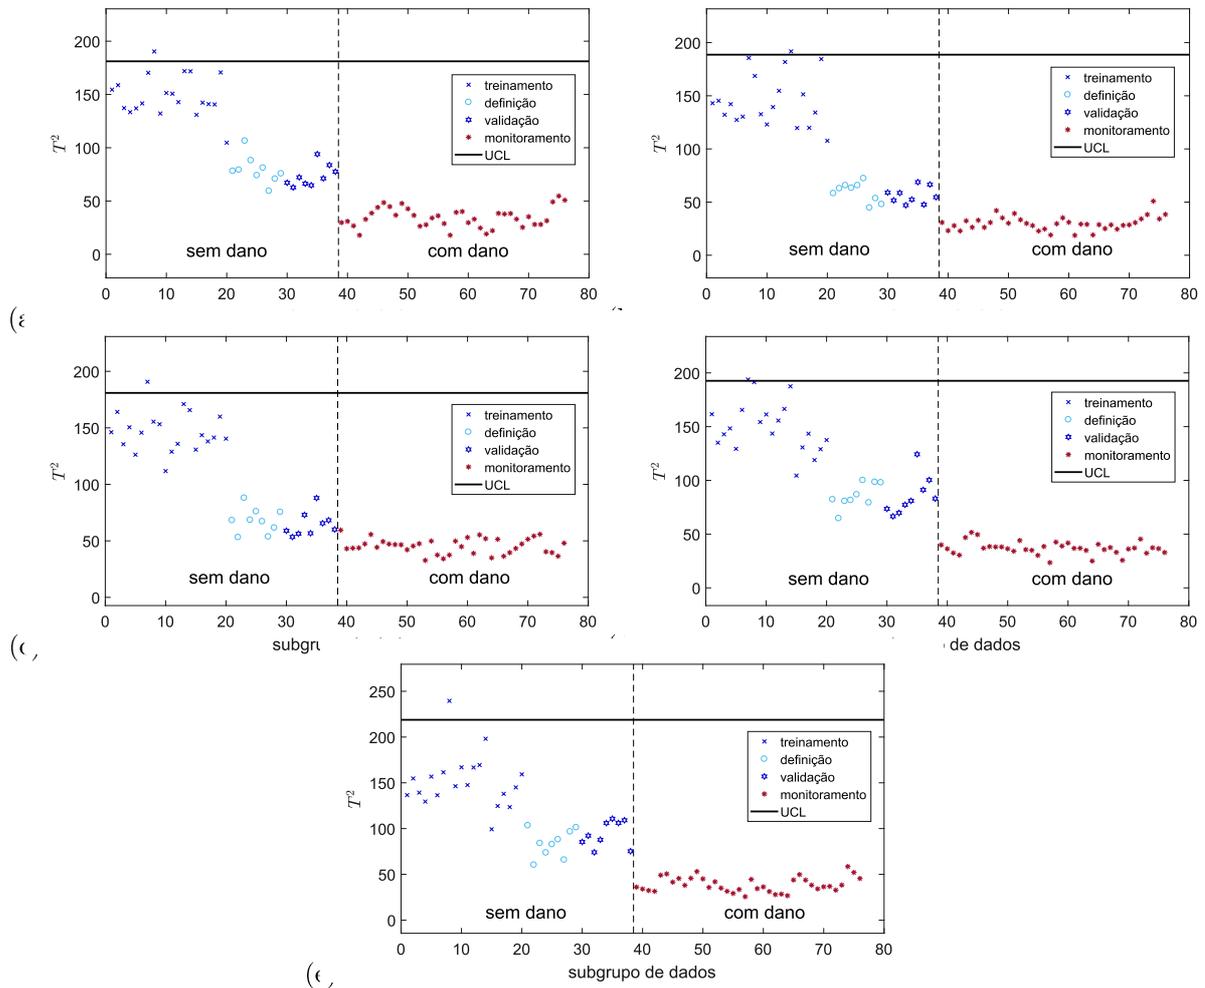


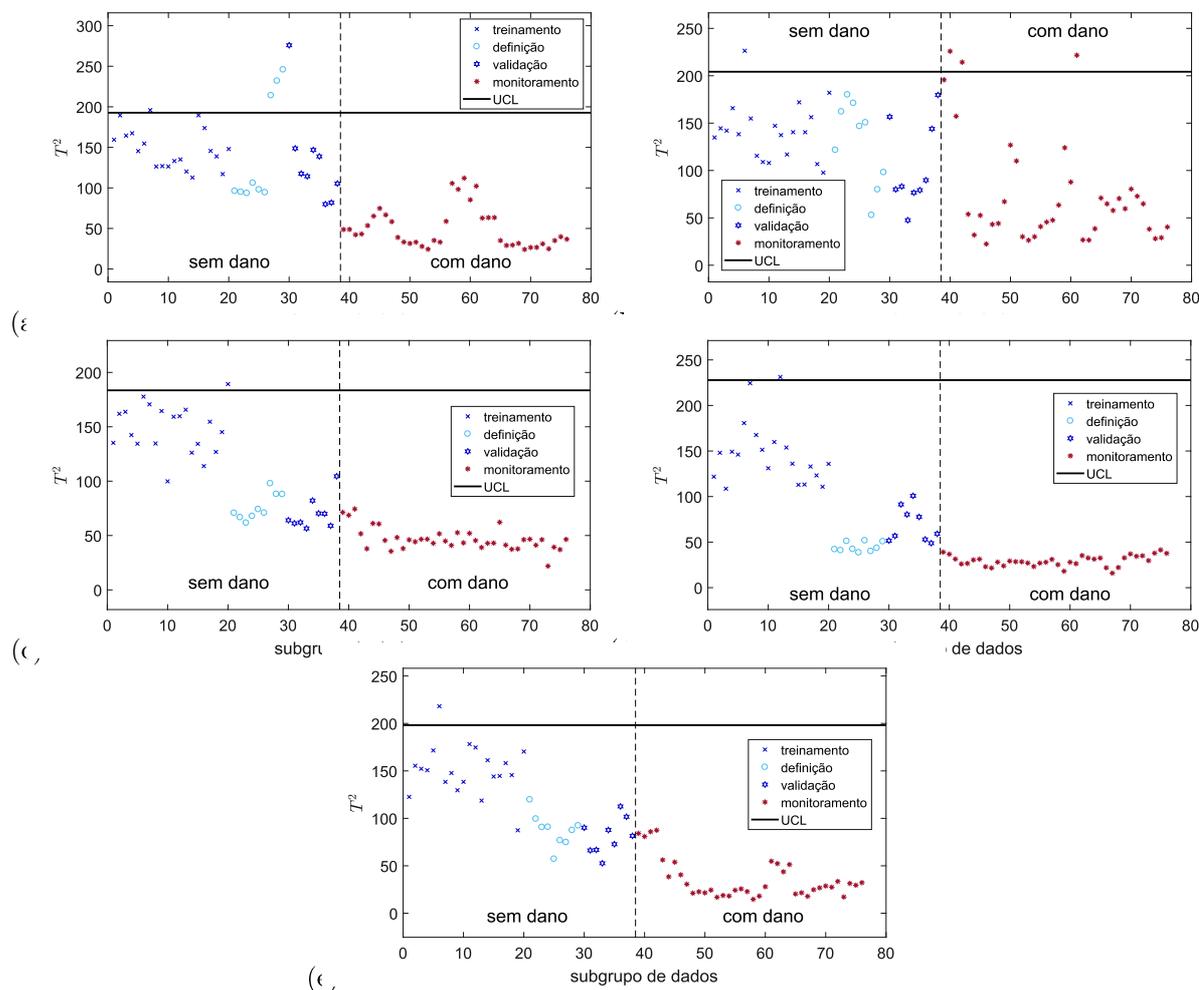
Figura 55 – Metodologia PCA/ $T^2$ : Cartas de controle - Caso #1 da Ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.



No total, foram avaliados 76 subgrupos de dados por modelo, considerando dados de treinamento (20 subgrupos), definição (9 subgrupos), validação (9 subgrupos) e monitoramento (38 subgrupos). Na Tabela 16 encontram-se os valores  $\lambda$ ,  $\rho$  e  $\beta$ , índice IG e os erros de reconstrução de treinamento  $\tilde{\zeta}^{tr}$ , definição  $\tilde{\zeta}^{def}$  e validação  $\tilde{\zeta}^{val}$  relacionados aos resultados das Figuras 51 à 56. Ressalta-se que o resultado completo, cartas de controle e informações da Tabela 16 para os cinco melhores modelos SAE/ $T^2$  elaborados com os dados dos 5 acelerômetros, encontra-se nos anexos A, B e C, ao final deste trabalho.

As cartas de controle construídas com os valores de um único modelo SAE/ $T^2$  revelam que a abordagem proposta é capaz de fornecer bons resultados para o Caso#1 da ponte Z24 (ver Figura 51, gráficos da esquerda). Ainda que seja possível constatar um alto número de outliers nos dados de validação dos acelerômetros 3 e 5, nota-se claramente uma mudança no padrão de comportamento dos pontos  $T^2$  de monitoramento de tais gráficos (maioria dos valores  $T^2$  acima do limite UCL, indicando a presença de dano). Ao analisar os 30 modelos (Figura 51, gráficos da direita), verifica-se que estes estão em conformidade com as respectivas cartas de controle desenvolvidas para somente um modelo, com exceção dos resultados obtidos para o acelerômetro 4. Neste último caso, apesar

Figura 56 – Metodologia PCA/ $T^2$ : Cartas de controle - Caso #2 da Ponte Z24. (a) Acelerômetro 1. (b) Acelerômetro 2. (c) Acelerômetro 3. (d) Acelerômetro 4. (e) Acelerômetro 5.



do modelo unitário indicar uma boa capacidade de detecção, ao gerar os 30 modelos, percebe-se que alguns deles não conseguiram distinguir corretamente os dados do cenário estrutural danificado do não-danificado (presença de dois patamares distintos de valores  $T^2$  na fase de monitoramento). Destaca-se também que, mesmo os resultados referentes ao acelerômetro 3 demonstrando um comportamento similar entre os pares de gráficos, os valores da estatística  $T^2$  de validação estão majoritariamente acima do limite UCL, o que não está correto, uma vez que estes dados pertencem à mesma classe dos dados de treinamento e definição, e por isso, deveriam possuir uma distribuição  $T^2$  semelhante. Desta forma, para o Caso#1, a estratégia SAE/ $T^2$  proposta funcionou de forma efetiva ao modelar os sinais advindos dos acelerômetros 1, 2 e 5. É importante frisar que embora as cartas de controle do acelerômetro 5 apresentem muitos outliers entre os subgrupos de dados 31 e 36, eles não persistem acima do limite UCL, o que pode sinalizar algum tipo de interferência temporária neste ponto de medição durante o período de monitoramento apontado no gráfico. No que se refere às cartas de controle obtidas para os acelerômetros 3 e 4, acredita-se que um motivo provável para os resultados inconclusivos pode estar

Tabela 16 – Erros de reconstrução dos sinais e hiperparâmetros associados aos modelos selecionados pela metodologia SHM não-supervisionada para os casos #1 e #2 da ponte Z24.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
<b>Caso#1</b>								
Ace 1	IG e $\zeta^{def}$	<b>0,8000</b>	<b>0,0100</b>	<b>4,0</b>	<b>0,0505</b>	<b>0,0652</b>	<b>0,0711</b>	<b>73,71</b>
	Menor $\zeta^{def}$	0,8000	0,0010	0,5	0,0471	0,0629	0,0693	107,33
	PCA	-	-	-	0,0037	0,0054	0,0061	209,98
Ace 2	IG e $\zeta^{def}$	<b>0,8000</b>	<b>0,1000</b>	<b>8,0</b>	<b>0,0553</b>	<b>0,0640</b>	<b>0,0733</b>	<b>62,95</b>
	Menor $\zeta^{def}$	0,8000	0,0010	4,0	0,0500	0,0612	0,0714	145,84
	PCA	-	-	-	0,0014	0,0019	0,0022	250,61
Ace 3	IG e $\zeta^{def}$	0,2000	0,0010	1,0	0,0535	0,0694	0,0750	71,74
	Menor $\zeta^{def}$	0,4000	0,0100	1,0	0,0492	0,0659	0,0714	175,59
	PCA	-	-	-	0,0005	0,0008	0,0009	234,64
Ace 4	IG e $\zeta^{def}$	0,8000	0,0100	4,0	0,0507	0,0650	0,0712	46,82
	Menor $\zeta^{def}$	0,2000	0,0010	8,0	0,0476	0,0632	0,0698	90,17
	PCA	-	-	-	0,0001	0,0002	0,0002	181,70
Ace 5	IG e $\zeta^{def}$	<b>0,8000</b>	<b>0,0100</b>	<b>2,0</b>	<b>0,0424</b>	<b>0,0520</b>	<b>0,0605</b>	<b>21,41</b>
	Menor $\zeta^{def}$	0,4000	0,0001	8,0	0,0401	0,0491	0,0575	280,53
	PCA	-	-	-	0,0017	0,0023	0,0028	194,03
<b>Caso#2</b>								
Ace 1	IG e $\zeta^{def}$	<b>0,1000</b>	<b>0,0100</b>	<b>2,0</b>	<b>0,0522</b>	<b>0,0679</b>	<b>0,0679</b>	<b>286,35</b>
	Menor $\zeta^{def}$	0,4000	0,0001	1,0	0,0432	0,0602	0,0606	1672,60
	PCA	-	-	-	0,0038	0,0060	0,0060	132,05
Ace 2	IG e menor erro	<b>0,1000</b>	<b>0,0100</b>	<b>1,0</b>	<b>0,0594</b>	<b>0,0749</b>	<b>0,0737</b>	<b>76,00</b>
	Menor $\zeta^{def}$	0,2000	0,0001	0,5	0,0469	0,0671	0,0661	535,02
	PCA	-	-	-	0,0002	0,0003	0,0003	37,80
Ace 3	IG e $\zeta^{def}$	0,2000	0,0100	8,0	0,0551	0,0718	0,0717	71,61
	Menor $\zeta^{def}$	0,8000	0,0010	8,0	0,0504	0,0700	0,0697	172,42
	PCA	-	-	-	0,0006	0,0009	0,0009	222,05
Ace 4	IG e $\zeta^{def}$	0,2000	0,0010	2,0	0,0464	0,0591	0,0633	50,22
	Menor $\zeta^{def}$	0,2000	0,0010	2,0	0,0464	0,0591	0,0633	50,22
	PCA	-	-	-	0,0018	0,0023	0,0025	286,52
Ace 5	IG e $\zeta^{def}$	0,2000	0,0100	1,0	0,0425	0,0450	0,0496	170,22
	Menor $\zeta^{def}$	0,4000	0,0010	8,0	0,0376	0,0418	0,0454	276,85
	PCA	-	-	-	0,0022	0,0028	0,0031	192,42

relacionado à posição de tais sensores. Enquanto os acelerômetros 3 e 4 foram instalados para captar movimentos transversais e longitudinais (ver Figura 47), os “shakers” geravam componentes predominantemente no sentido vertical. Além disso, a estrutura era bastante rígida no sentido longitudinal. Quanto aos modelos SAE/ $T^2$  alcançados para o Caso#2 (ver Figura 52), conduzindo uma análise similar à realizada para o Caso#1, chega-se a conclusão de que abordagem sugerida foi eficaz em distinguir os dados com e sem dano

dos acelerômetros 1 e 2. Por outro lado, os pares de cartas de controle gerados para os acelerômetros 4 e 5 mostram que os seus respectivos modelos falharam em detectar o dano. Salienta-se que embora o modelo unitário do acelerômetro 3 tenha mostrado bom desempenho, quando simulado os seus 30 modelos também não foi possível diferenciar os dois cenários estruturais. Portanto, diante dos resultados discutidos até aqui, pode-se afirmar que em ambos os casos estudados a estratégia adotada para a escolha dos melhores modelos SAE/ $T^2$  funcionou parcialmente para o exemplo da ponte Z24, visto que em alguns dos acelerômetros não ocorreu a correta classificação dos dados. Contudo, ao observar os hiperparâmetros dos modelos na Tabela 16, nota-se que para o critério de seleção proposto nesta seção, os bons resultados obtidos estão sempre associados aos mesmos valores de  $\rho$  e  $\lambda$  (Caso#1:  $\rho = 0,8$  e  $\lambda = 0,01$  - acelerômetros 1,2 e 5; Caso#2:  $\rho = 0,1$  e  $\lambda = 0,01$  - acelerômetros 1 e 2). Levando isto em consideração, a Figura 57 à Figura 66 apresentam as cartas de controle de 10 modelos SAE/ $T^2$  simulados aleatoriamente para a região dos valores de  $\rho$  e  $\lambda$  que alcançaram o melhor desempenho dentro da abordagem proposta. Para cada par de  $\rho$  e  $\lambda$ , serão avaliados os 5 valores de  $\beta$ , que conforme mencionado no capítulo “*Análise de sensibilidade*”, é visto como um hiperparâmetro de ajuste fino com relação ao erro de reconstrução. Cada figura corresponde aos resultados de um único acelerômetro e é composta por 50 cartas de controle, onde em cada coluna são exibidos os gráficos  $T^2$  de 10 modelos construídos para um determinado  $\beta$ . As Figuras 57 à 61 estão associadas ao Caso#1 e as Figuras 62 à 66 ao Caso#2. Aponta-se que para essas figuras específicas, o cenário 1 se refere aos dados sem dano e o cenário 2 com dano.

No que diz respeito ao Caso#1, as cartas de controle das Figuras 57 à 61 reafirmam os resultados alcançados pela estratégia proposta de definição de modelos (Figuras 51 à 54), tendo em vista que o único modelo fora da região de  $\rho = 0,8$  e  $\lambda = 0,01$ , entre os apontados na Tabela 16, é aquele relacionado ao acelerômetro 3 ( $\rho = 0,2$  e  $\lambda = 0,0001$ ). Ao investigar especificamente os modelos construídos com  $\rho = 0,8$  e  $\lambda = 0,01$  do acelerômetro 3, não são observadas detecções satisfatórias para os conjunto de 10 modelos, embora haja alguns bons resultados pontuais. Em compensação, no Caso#2, ao analisar as Figuras 62 à 66, percebeu-se uma melhora significativa na detecção dos modelos SAE/ $T^2$  treinados com dados dos acelerômetros 3, 4 e 5. Com a nova configuração de hiperparâmetros adotada para o Caso#2 ( $\rho = 0,1$  e  $\lambda = 0,01$ ) foi possível, para todos os acelerômetros, encontrar modelos claramente capazes de identificar a presença de dano, diferente do desempenho atingido pelos modelos automaticamente selecionados (aqueles com  $\rho = 0,2$  e  $\lambda = 0,01/0.001$ ). Tais resultados validam o uso da metodologia SAE/ $T^2$  para problemas SHM, mas também indicam que, apesar de ter funcionado muito bem no exemplo do pórtico, a estratégia de seleção de modelos necessita de aprimoramentos. Contudo, cabe ressaltar que, assim como para a estrutura estudada na seção anterior, os resultados alcançados através do critério baseado no valor de IG e  $\tilde{\zeta}^{def}$  ainda são consideravelmente melhores que aqueles obtidos exclusivamente pelo critério clássico de menor erro de reconstrução,

conforme mostra a Figura 53, Figura 54 e a Tabela 16.

No que se refere aos modelos PCA/ $T^2$ , gerados com o número de componentes principais igual à quantidade de características SAE (100), não foi possível distinguir o estado danificado do não danificado em nenhum dos acelerômetros para ambos os casos (ver Figuras 55 e 56). Além de grande parte dos pontos  $T^2$  estarem abaixo da linha UCL, os gráficos mostram padrões diferentes entre os dados de treinamento e definição/validação, que estão incorretos, pois esses dados pertencem à mesma classe (sem dano). No entanto, como 100 componentes principais representam cerca de 80% da variabilidade dos dados de treinamento da ponte Z24, outras quantidades de componentes principais também foram analisadas. A Tabela 17 mostra o número de componentes principais necessários por acelerômetro para explicar 85%, 90%, 95% e 99% da variância dos dados. Embora a quantidade de componentes principais tenha aumentado, os modelos PCA/ $T^2$  desenvolvidos considerando os números apresentados na Tabela 17 apresentaram comportamentos semelhantes aos exibidos nas Figuras 55 e 56. Por esse motivo e para evitar a repetição de figuras com resultados semelhantes, as cartas de controle destes modelo foram omitidas.

Tabela 17 – Número de componentes principais necessários por acelerômetro para explicar as porcentagens indicadas da variância dos dados da ponte Z24.

Variabilidade dos dados	Acelerômetro									
	Caso #1					Caso #2				
	1	2	3	4	5	1	2	3	4	5
<b>85%</b>	116	133	124	110	95	115	120	120	129	97
<b>90%</b>	139	158	148	133	118	140	143	144	154	122
<b>95%</b>	176	195	184	170	156	178	180	179	192	161
<b>99%</b>	242	255	246	241	228	244	246	241	253	232

Por fim, um aspecto notável dos modelos SAE/ $T^2$ , quando corretamente configurados, é a capacidade de apontar os diferentes cenários estruturais independentemente da influência dos efeitos térmicos, uma vez que o Caso#1 avalia a metodologia com dados coletados sob diferentes temperaturas e o Caso#2 com dados adquiridos sob temperaturas iguais. Mesmo os modelos do Caso#1 alcançando desempenho ligeiramente inferior ao dos Caso#2 (enquanto no primeiro detectou-se o dano em 3 acelerômetros, no segundo, o dano foi verificado em todos os 5 sensores), os resultados das duas análises são relativamente semelhantes, sugerindo que os efeitos de mudança de temperatura têm baixo impacto na estratégia proposta, fator relevante no campo de monitoramento estrutural. Qualquer que seja o tipo de técnica SHM, ela deve ser invariante à influência dos fatores ambientais e, para a presente estrutura, a abordagem SAE/ $T^2$  mostrou-se eficiente para lidar com a variação de temperatura.

Figura 57 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #1 da ponte Z24 para  $\rho = 0,8$  e  $\lambda = 0,01$ , Acelerômetro 1.

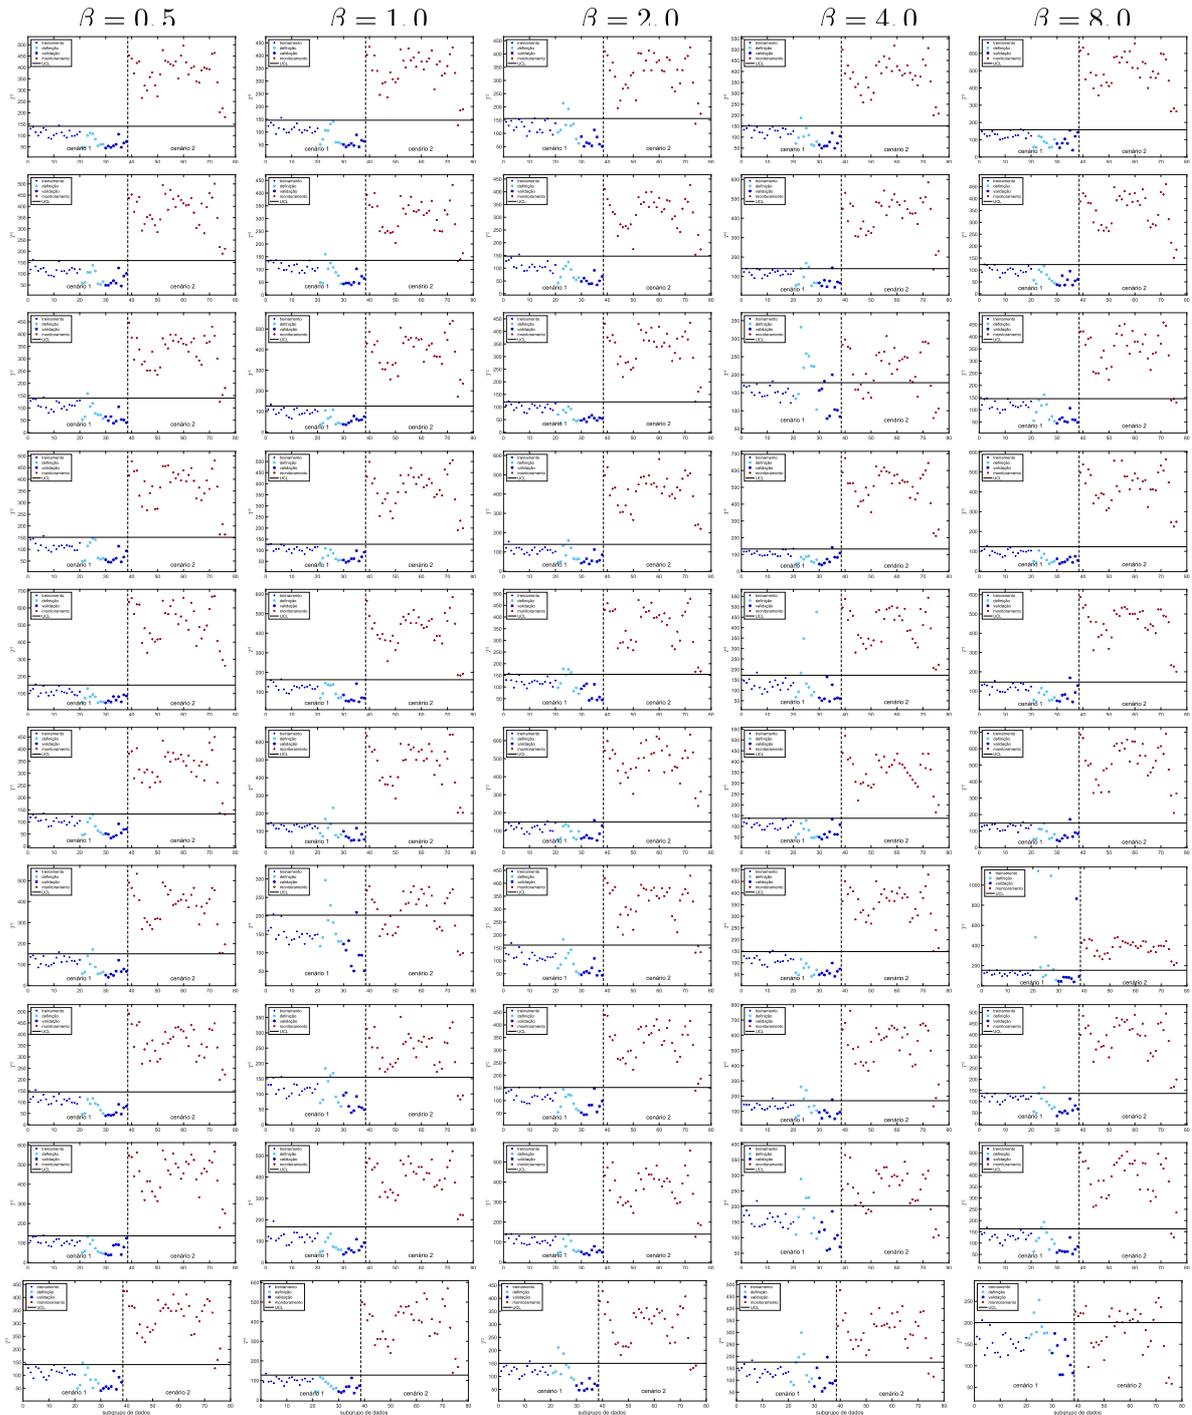


Figura 58 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #1 da ponte Z24 para  $\rho = 0,8$  e  $\lambda = 0,01$ , Acelerômetro 2.

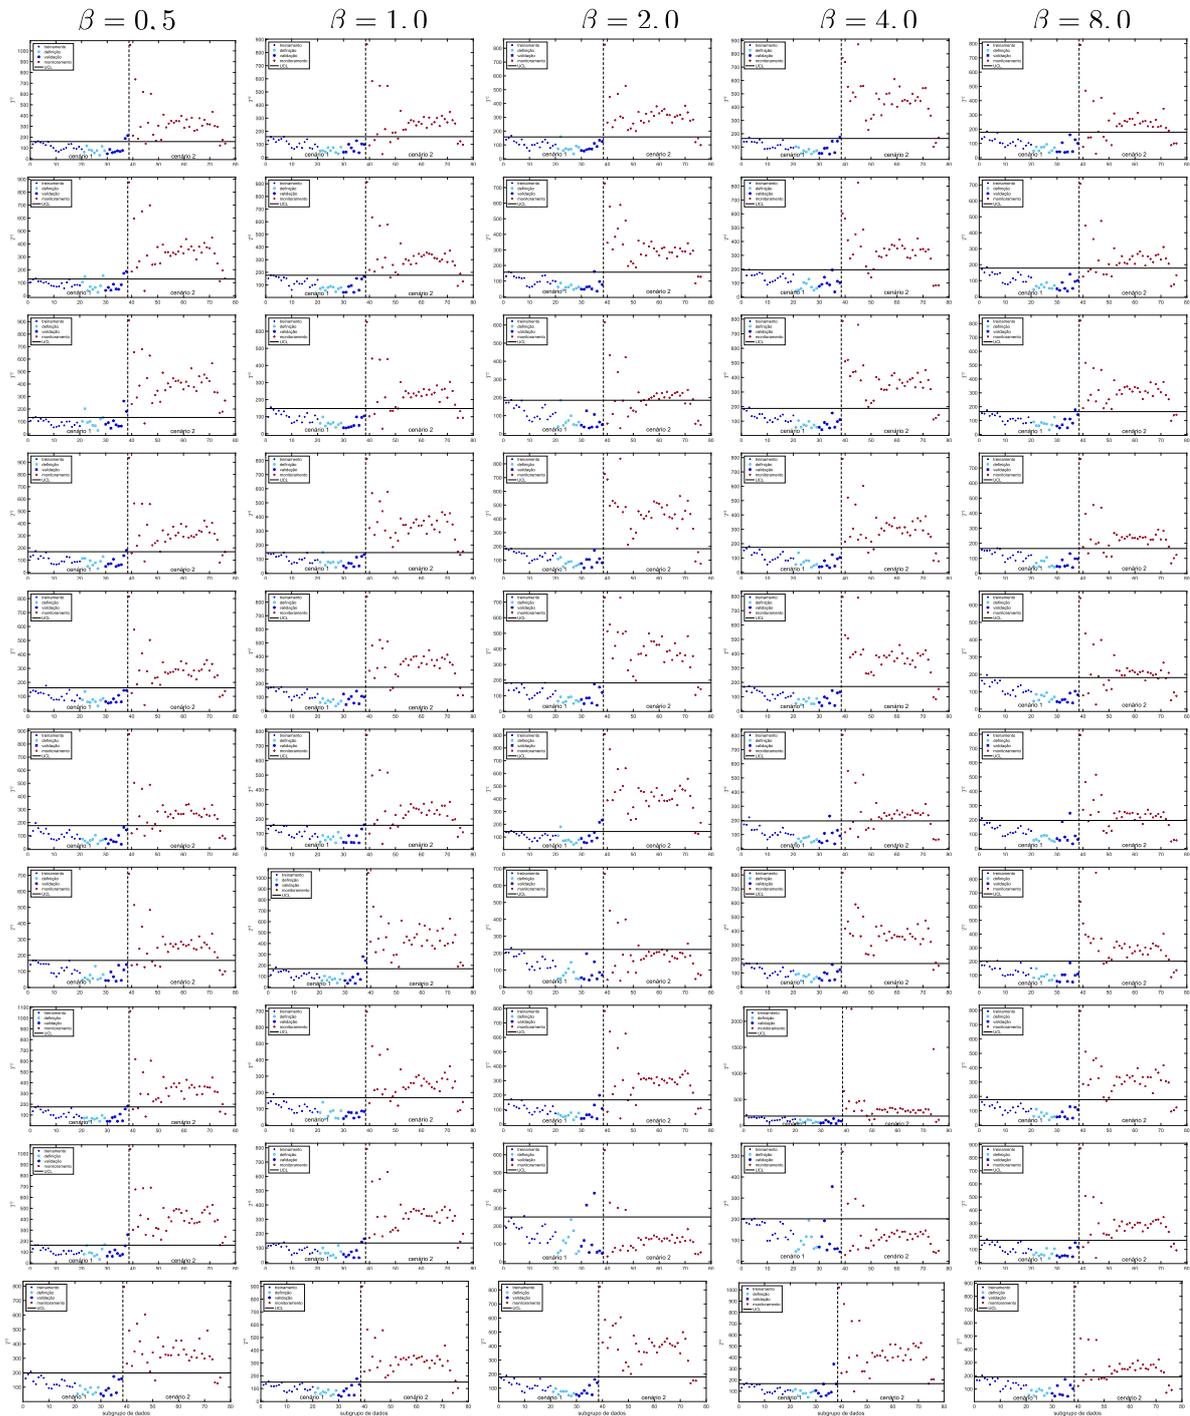


Figura 59 – Metodologia SAE/T<sup>2</sup> - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/T<sup>2</sup> - Caso #1 da ponte Z24 para  $\rho = 0,8$  e  $\lambda = 0,01$ , Acelerômetro 3.

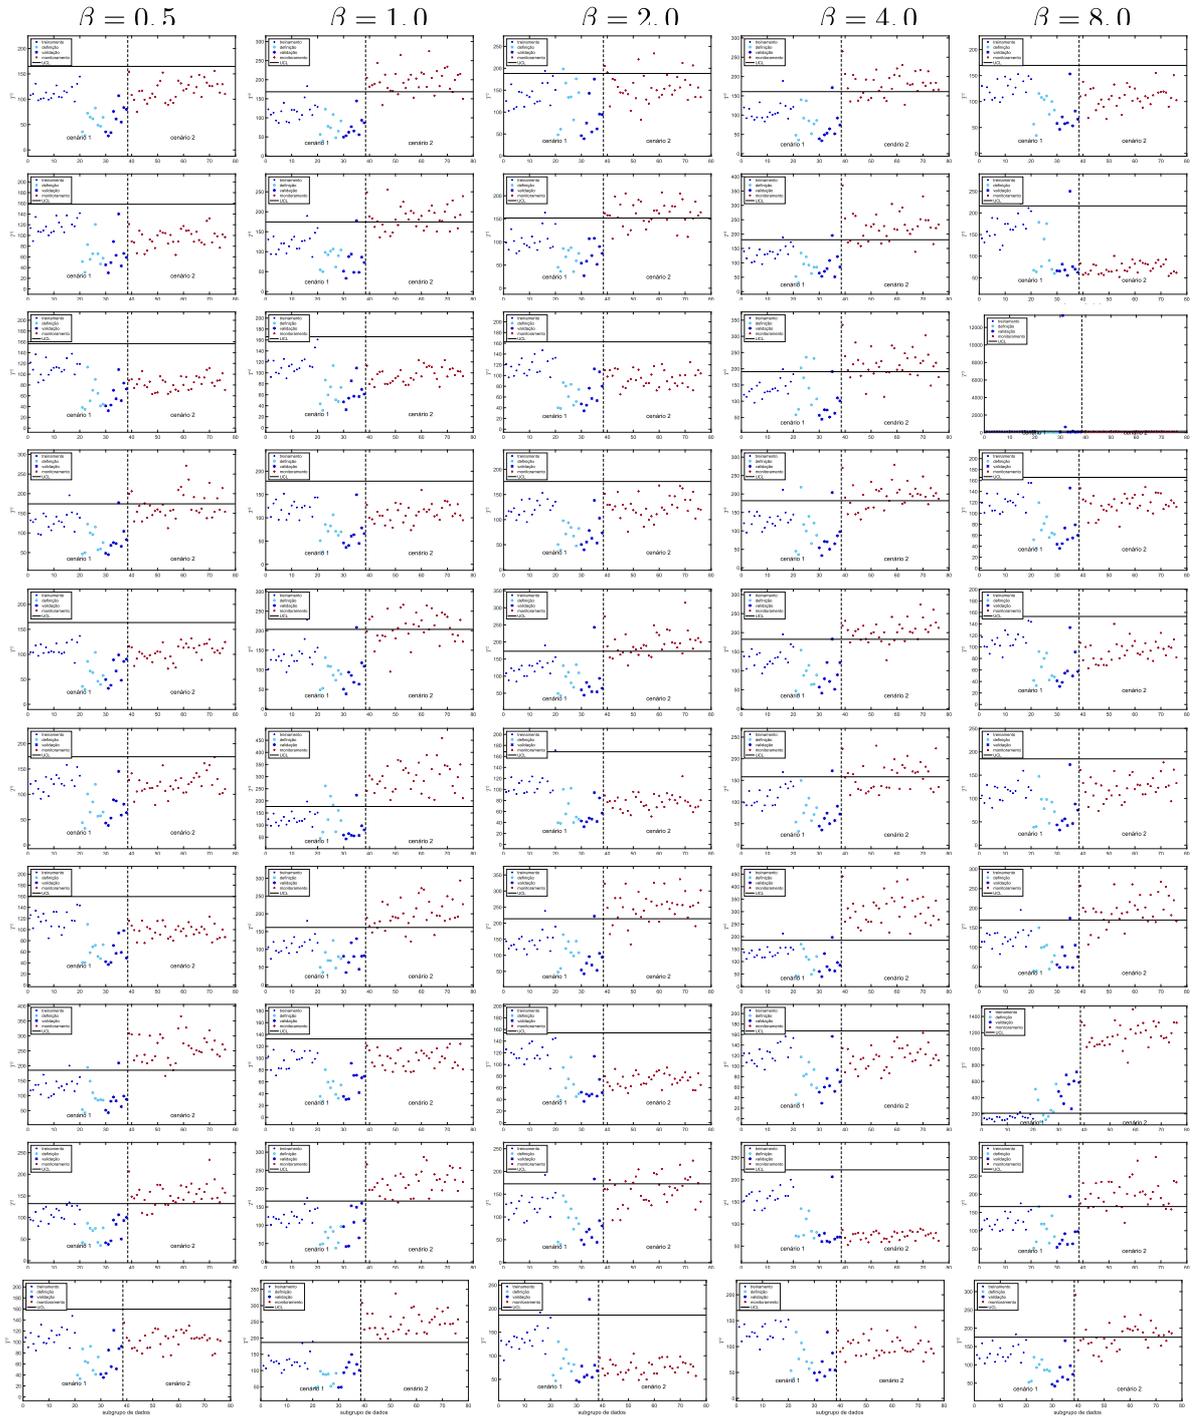


Figura 60 – Metodologia SAE/T<sup>2</sup> - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/T<sup>2</sup> - Caso #1 da ponte Z24 para  $\rho = 0,8$  e  $\lambda = 0,01$ , Acelerômetro 4.

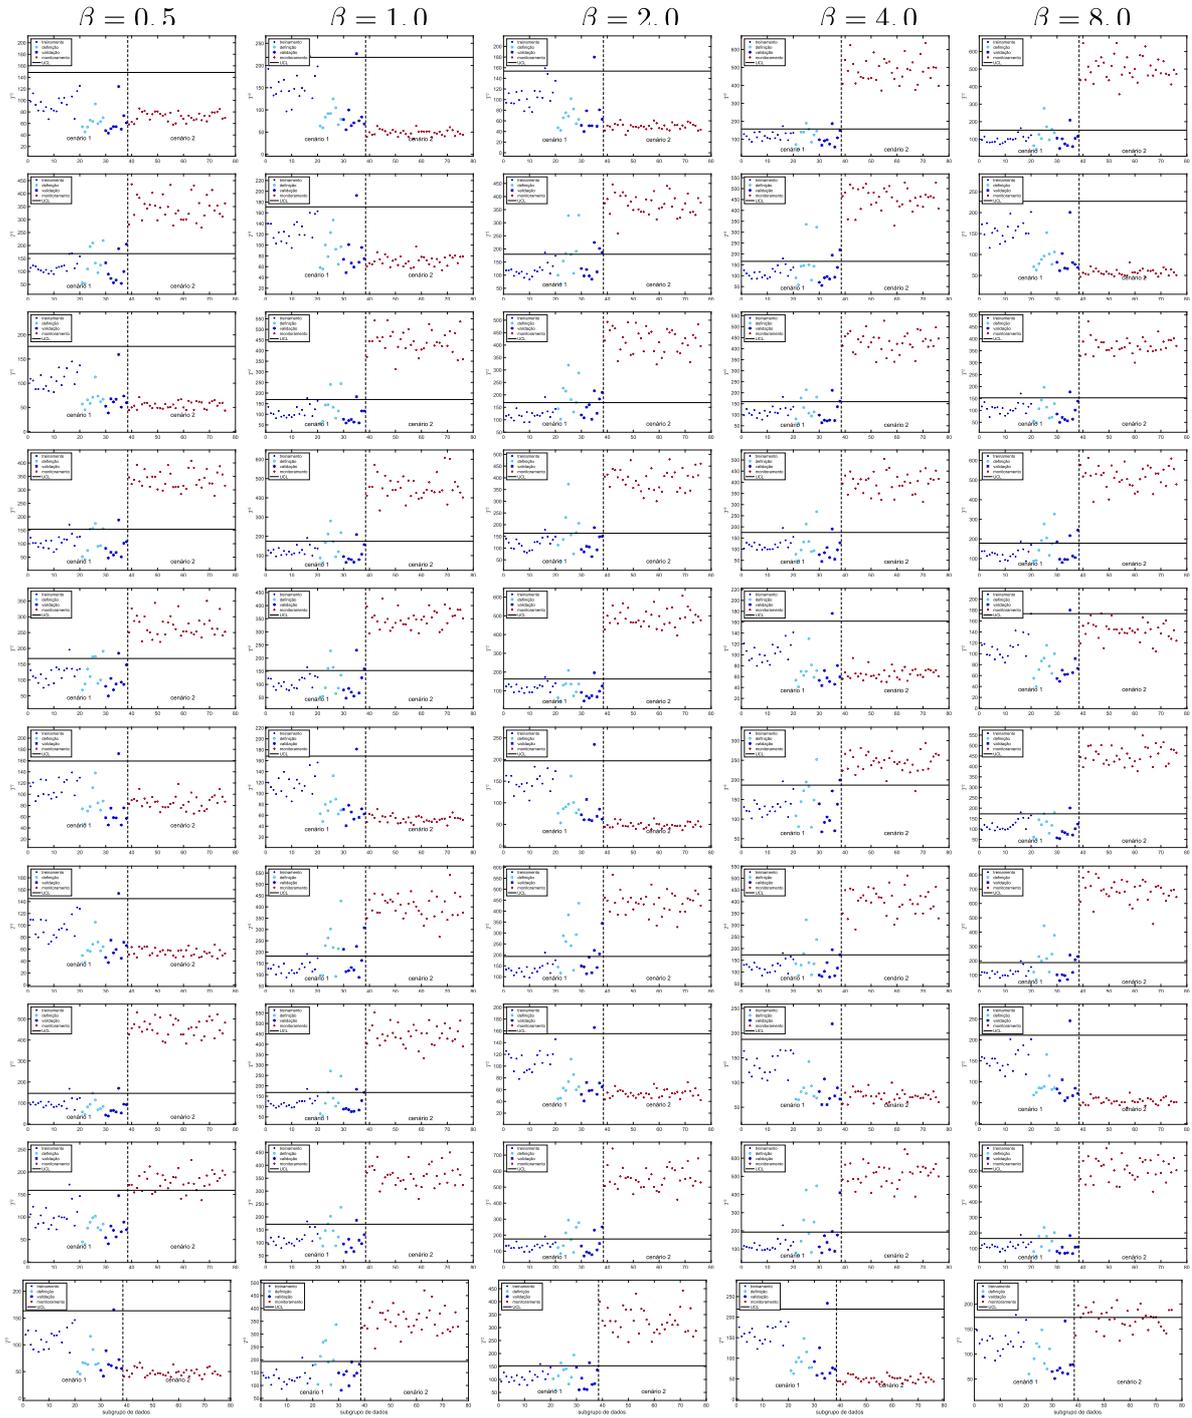


Figura 61 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #1 da ponte Z24 para  $\rho = 0,8$  e  $\lambda = 0,01$ , Acelerômetro 5.

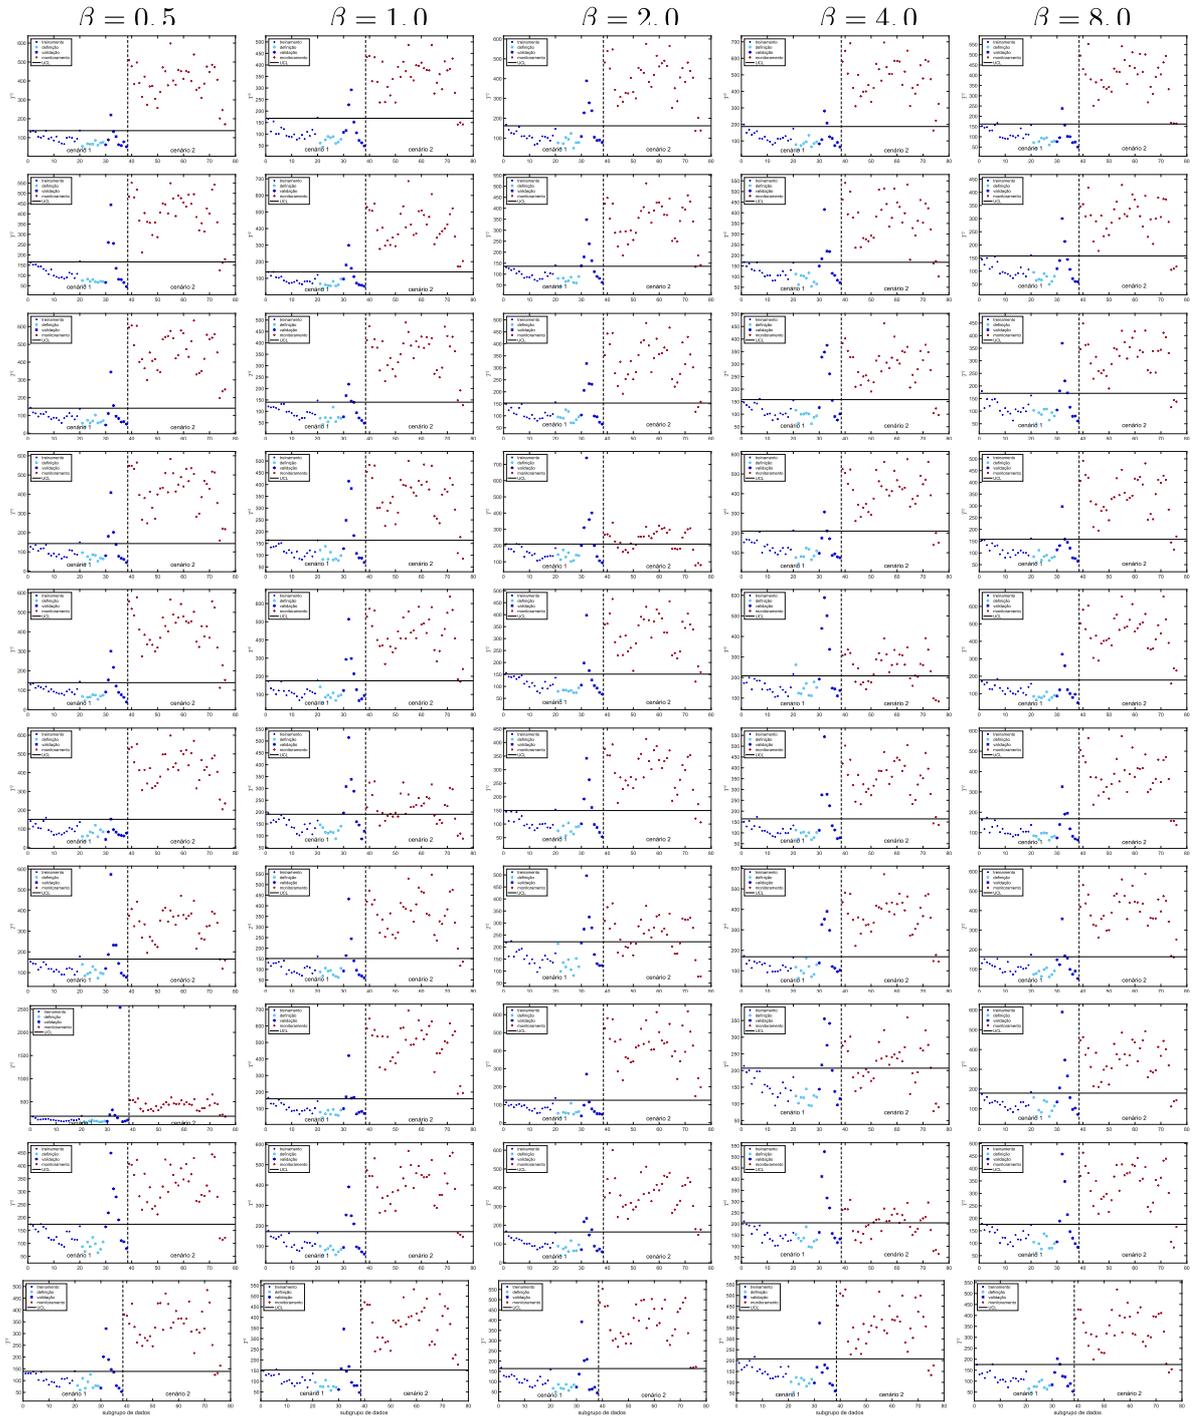


Figura 62 – Metodologia SAE/T<sup>2</sup> - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/T<sup>2</sup> - Caso #2 da ponte Z24 para  $\rho = 0, 1$  e  $\lambda = 0, 01$ , Acelerômetro 1.

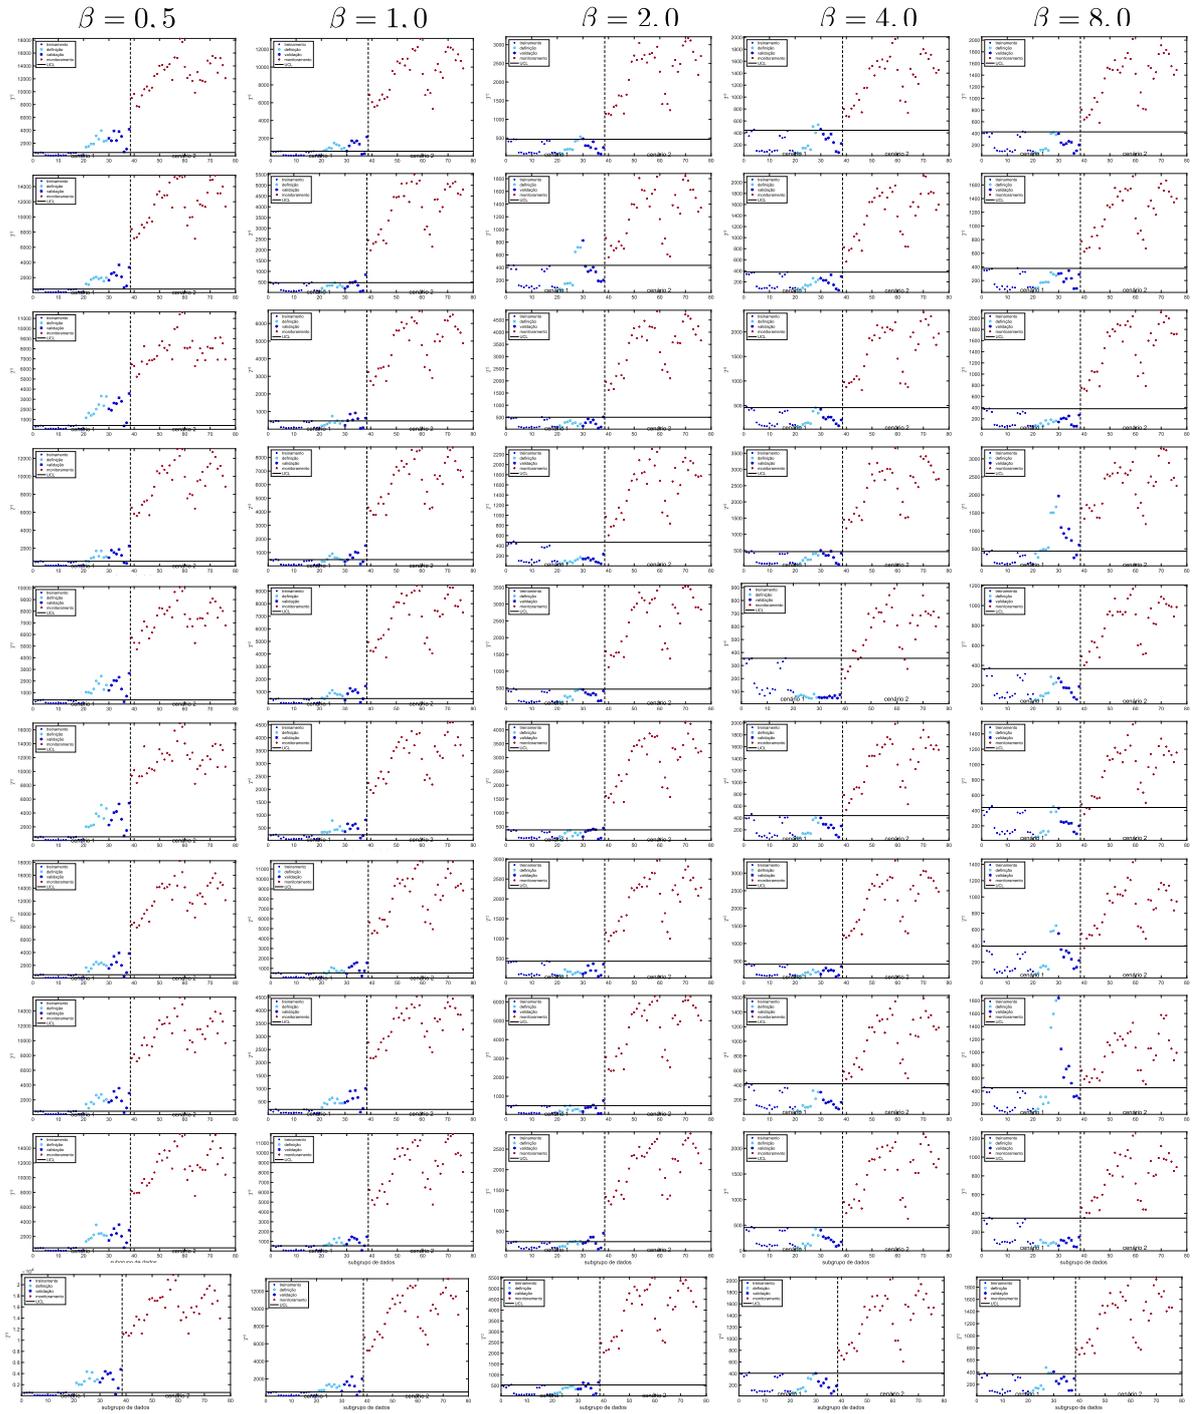


Figura 63 – Metodologia SAE/T<sup>2</sup> - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/T<sup>2</sup> - Caso #2 da ponte Z24 para  $\rho = 0, 1$  e  $\lambda = 0, 01$ , Acelerômetro 2.

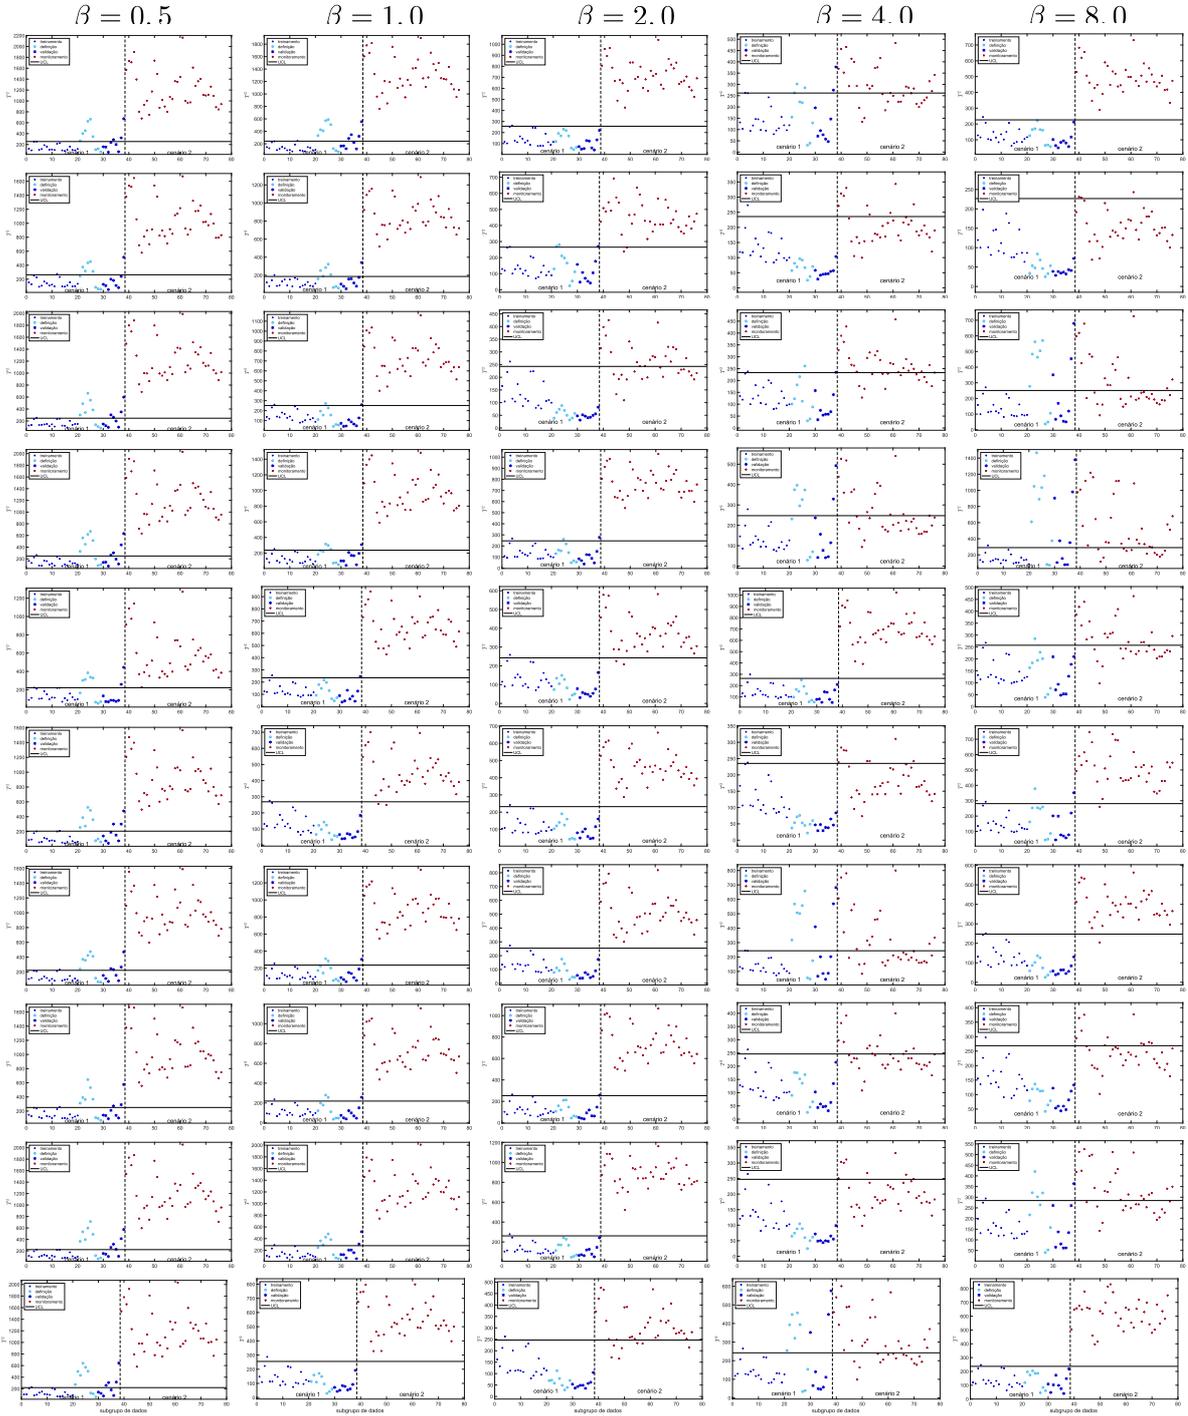


Figura 64 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #2 da ponte Z24 para  $\rho = 0, 1$  e  $\lambda = 0, 01$ , Acelerômetro 3.

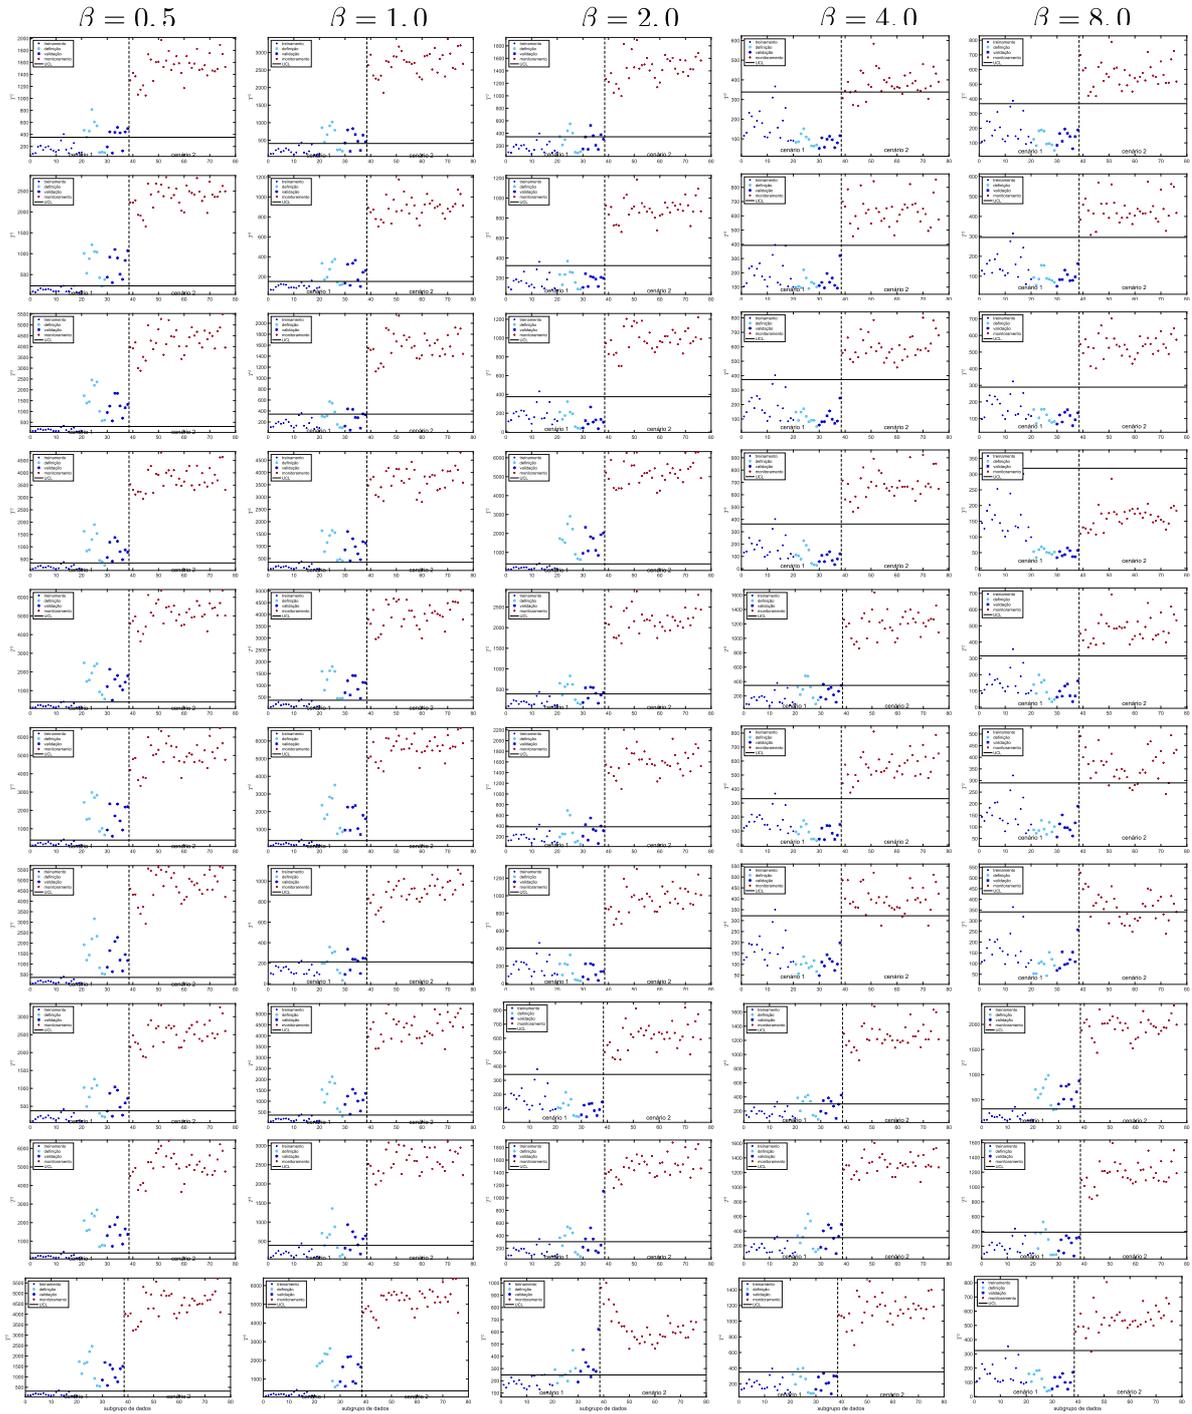


Figura 65 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #2 da ponte Z24 para  $\rho = 0, 1$  e  $\lambda = 0, 01$ , Acelerômetro 4.

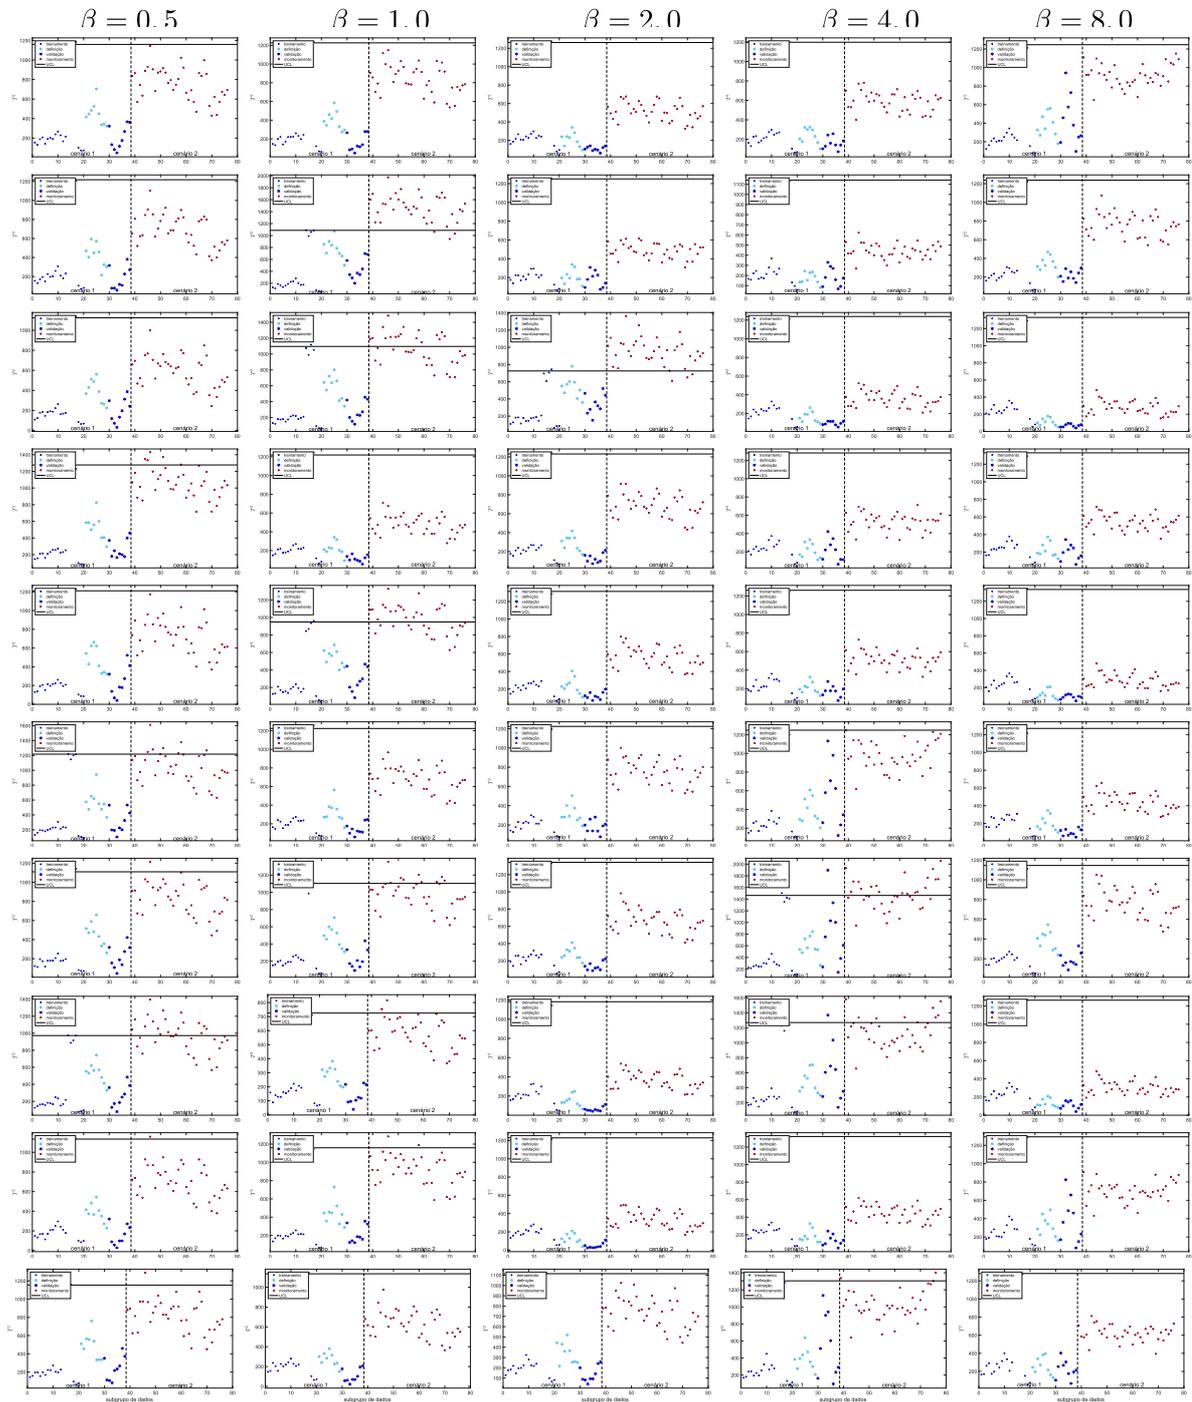
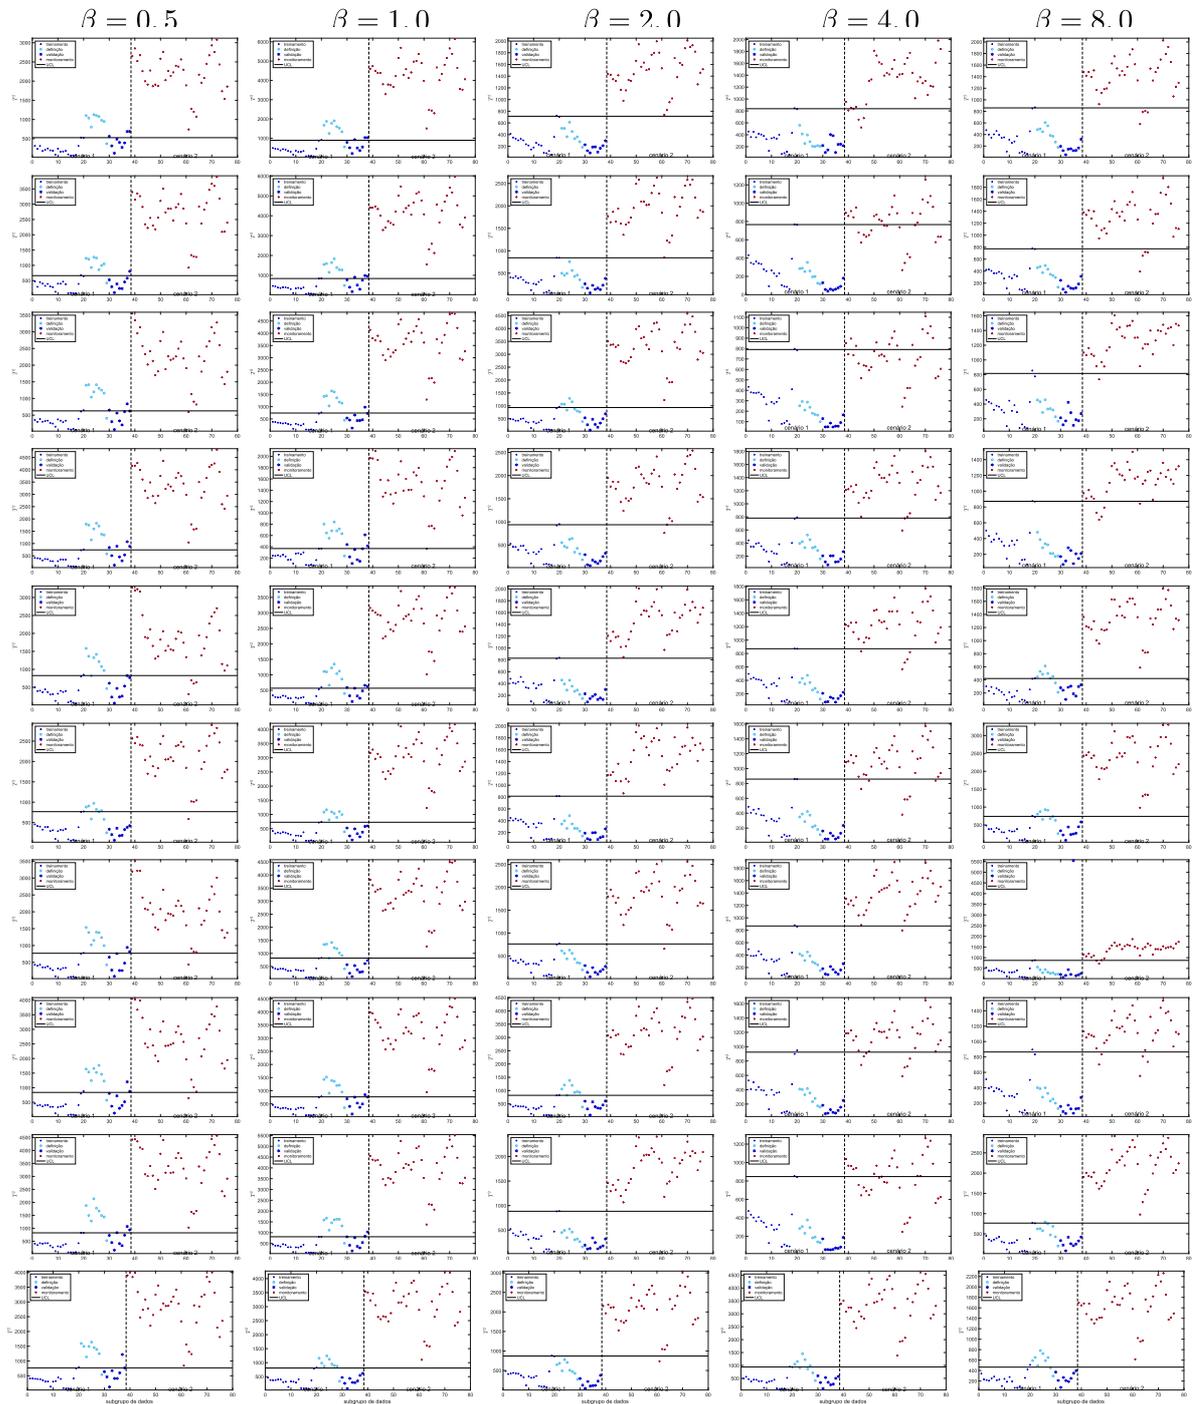


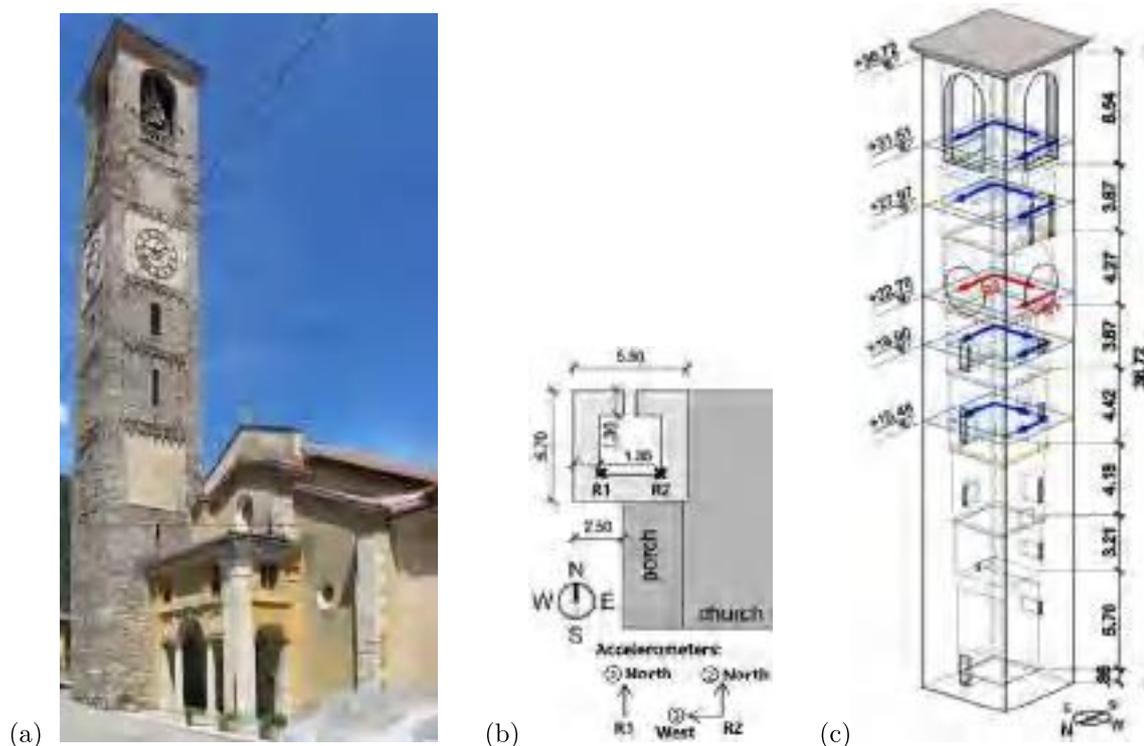
Figura 66 – Metodologia SAE/ $T^2$  - Critério IG e  $\tilde{\zeta}^{def}$ : Cartas de controle para 10 modelos SAE/ $T^2$  - Caso #2 da ponte Z24 para  $\rho = 0, 1$  e  $\lambda = 0, 01$ , Acelerômetro 5.



### 6.3 APLICAÇÃO III - CAMPANÁRIO DA IGREJA *SAN VITTORE*

O campanário investigado é uma estrutura histórica que faz parte da igreja de *San Vittore* em Arcisate, uma pequena cidade no norte da Itália. A estrutura, mostrada na Figura 67, tem aproximadamente 37m de altura, com os dois últimos andares provavelmente construídos no século XVIII. Para avaliar a condição estrutural da torre, um extenso programa de monitoramento foi realizado por pesquisadores da “*Politecnico di Milano*” [116], cujos dados foram gentilmente cedidos pelo professor Carmelo Gentile, que orientou o estágio sanduíche de doutorado da candidata na Itália, nesta mesma instituição de ensino. Após diversas inspeções (avaliação visual, levantamento geométrico, ensaios *in loco* e de laboratórios, entre outros), nenhum problema estrutural grave foi descoberto. Por esta razão, os dados de vibração ambiente do campanário são aqui utilizados para avaliar a sensibilidade da metodologia  $SAE/T^2$  quando uma estrutura não danificada é submetida a diferentes temperaturas. O objetivo desta aplicação é verificar se diferentes níveis de temperatura podem causar falsos alarmes na detecção realizada pela abordagem proposta.

Figura 67 – Campanário da igreja *San Vittore* (unidade: m). (a) Foto da estrutura. (b) Vista superior em corte. (c) Esquema experimental.



Fonte: Cabboi *et al.* [116].

O monitoramento dinâmico contínuo foi realizado de junho de 2009 a fevereiro de 2010 utilizando três acelerômetros piezoelétricos modelo Dytran 3191A1 com sensibilidade de 10 V/g. Os três acelerômetros foram instalados em dois pontos de medição, R1 e R2, conforme representado na Figura 67(b) e na Figura 67(c) (setas vermelhas). As respostas estruturais foram coletadas a uma taxa de amostragem de 200Hz por um sistema de

aquisição de dados de 4 canais NI9234 de resolução de 24 bits, com faixa dinâmica de 102dB e filtros “*anti-aliasing*”. Oito termopares também registraram a temperatura da torre. Um arquivo contendo os três históricos de aceleração (relativos aos três acelerômetros) e a temperatura média observada foi criado para cada hora monitorada. Para cada hora monitorada foi criado um arquivo contendo os históricos de aceleração medidos pelos três acelerômetros e a temperatura média observada durante o período. A Figura 68 mostra uma resposta típica da torre. Os modos de vibração, identificados pela aplicação da técnica SSI-Data disponível no ARTeMIS® aos dados medidos em 5 níveis do edifício (Figura 67(c)), estão ilustrados na Figura 69 [117].

Figura 68 – Resposta típica do campanário de *San Vittore*.

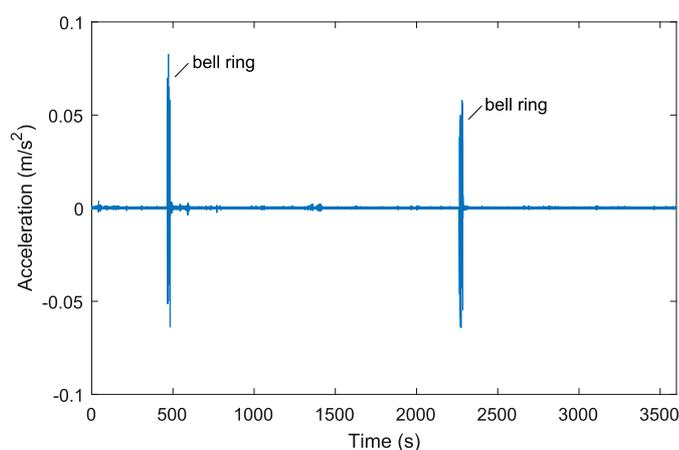
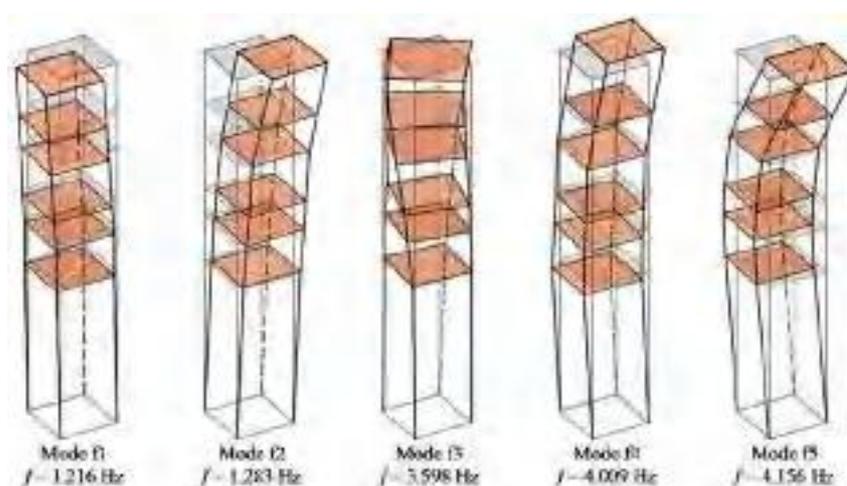


Figura 69 – Modos de vibração do campanário de *San Vittore* (desenhos extraídos da obra de [116]).



Antes de organizar a matriz de entrada SAE, cada histórico de aceleração de 1 hora foi submetido às seguintes operações de pré-processamento: (a) identificação automática e exclusão da vibração transitória induzida pelo toque do sino; (b) remoção de tendências; (c) filtragem passa-baixa; (d) diminuição da taxa de amostragem (de 200Hz para 40Hz). Na tentativa de cobrir diferentes condições termoclimáticas, este estudo utiliza 752h de

dados de vibração adquiridos em junho, julho e novembro. As faixas de temperatura para junho/julho e novembro são de 20°C a 30°C e de 5°C a 13°C, respectivamente [117]. Evidencia-se que em função da simetria da estrutura, tem-se um comportamento dinâmico bastante semelhante para os três pontos instrumentados - conforme pode-se concluir a partir das formas modais apresentadas na Figura 69, e por esta razão, decidiu-se aqui trabalhar somente com os dados do acelerômetro 1.

As respostas estruturais pré-processadas são divididas em sinais de 1 minuto, gerando uma matriz de entrada  $\mathbf{X}_{(2400 \times 45120)}$ : 45120 séries temporais (752h  $\times$  60min = 45120) com 2400 pontos de dados (40Hz  $\times$  60s = 2400). Os dados dos meses de junho e julho foram utilizados nas etapas de treinamento, definição e validação, já os dados de novembro foram aplicados na fase de monitoramento, conforme definido na Tabela 18.

Tabela 18 – Campanário de *San Vittore*: organização dos dados.

Dados de treinamento	Dados de definição	Dados de validação	Dados de monitoramento
$\mathbf{X}_{(1...2400;1...12020)}$	$\mathbf{X}_{(1...2400;12021...16920)}$	$\mathbf{X}_{(1...2400;16921...21820)}$	$\mathbf{X}_{(1...2400;21821...45120)}$

Além da normalização da amplitude dos sinais entre 0 e 1 (com relação aos dados de treinamento), os modelos SAE construídos para a torre sineira também mantiveram a mesma arquitetura e parâmetros utilizados nas outras estruturas estudadas neste capítulo, exceto pelos valores de  $\rho$ ,  $\lambda$  e  $\beta$  (definidos pela busca em grade) e pelo número de neurônios na camada interna, que foi de 240 (vetor de características  $\mathbf{h}$  com 240 componentes, levando à seguinte configuração geral de rede: 2400-240-2400). Em vista dos resultados anteriores e considerando que se trata de um caso que envolve dados de um monitoramento ambiente e, teoricamente, mais difíceis de serem processados, optou-se por se utilizar diretamente 10% do tamanho original dos dados (assim como na aplicação da ponte Z24). A estatística  $T^2$  de *Hotelling* foi calculada usando subgrupos de dados compostos por 20 observações ( $R = 20$ ). Já o limite UCL foi estimado considerando 601 subgrupos de dados (12020 exemplos de treinamento / 20 observações).

### 6.3.1 Resultados

As cartas de controle obtidas para o campanário de *San Vittore* são mostrados na Figura 70. Os resultados apresentam os valores estatísticos  $T^2$  alcançados para os modelos SAE (o modelo mais adequado, entre os 160 criados, segundo o critério baseado no IG e  $\tilde{\zeta}^{def}$  e de menor erro de reconstrução  $\tilde{\zeta}^{def}$ , respectivamente - Figura 70(a) e Figura 70(b)) e PCA (construído com 240 componentes principais para fins de comparação - Figura 70(c)). Ressalta-se que, devido aos 160 modelos apresentarem padrões de comportamento bem similares entre si, optou-se neste exemplo por selecionar um único modelo SAE/ $T^2$  para investigar a estrutura, e não cinco, como foi adotado na ponte Z24. No total, 2256 subgrupos de dados foram avaliados, considerando as etapas de treinamento (601 subgrupos), definição

(245 subgrupos), validação (245 subgrupos) e monitoramento (1165 subgrupos). Cada ponto  $T^2$  corresponde a 20 minutos de monitoramento. Os pontos de 1 à 259 estão relacionados às respostas dinâmicas coletadas em junho ( $\approx 6$  dias), os pontos de 260 à 1091 envolvem os dados de julho ( $\approx 17$  dias) e os pontos de 1092 à 2256 representam os sinais de novembro ( $\approx 24$  dias). O índice de generalização IG e os erros  $\tilde{\zeta}$  associados a tais resultados, bem como os de  $\rho$ ,  $\lambda$  e  $\beta$  dos respectivos modelos, constam na Tabela 19.

Figura 70 – Metodologia SHM não-supervisionada: Cartas de controle obtidas para o campanário de *San Vittore*.

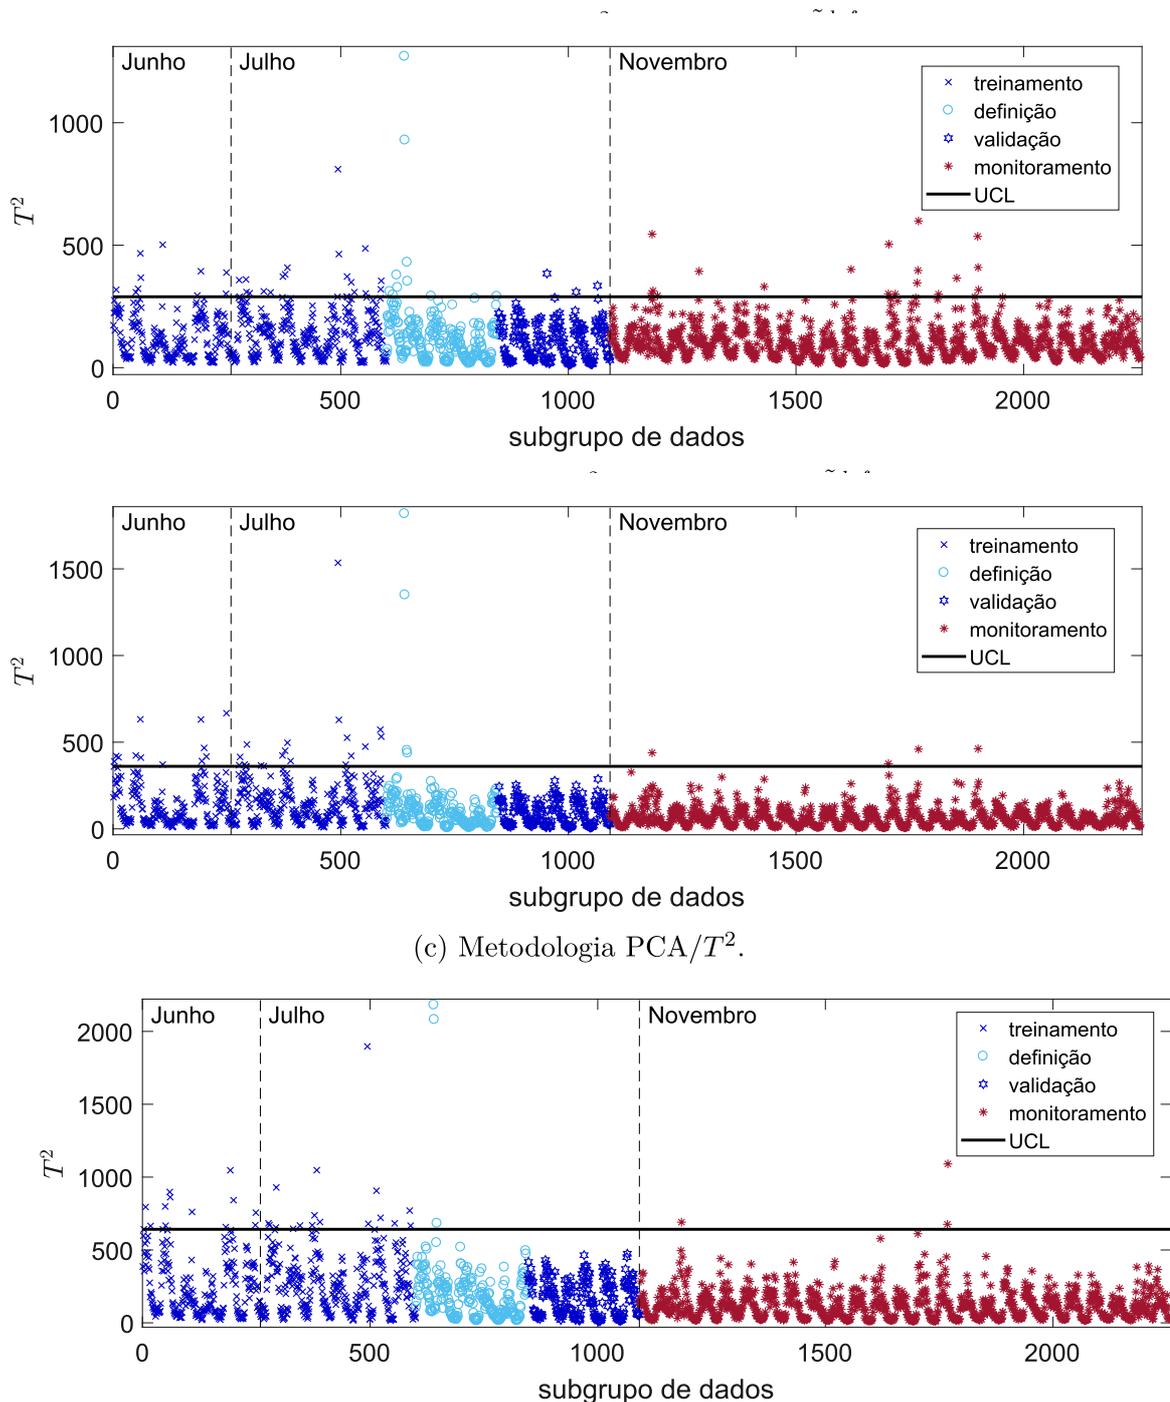
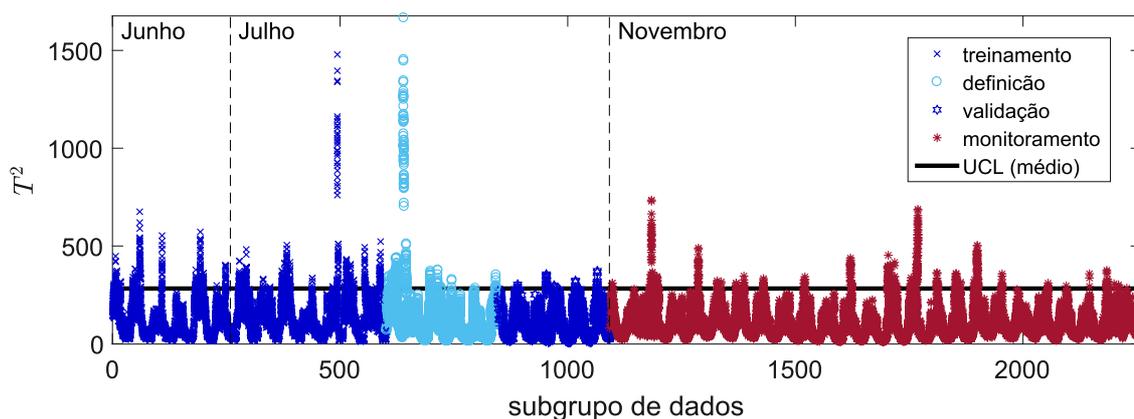


Tabela 19 – Erros de reconstrução dos sinais e hiperparâmetros associados aos modelos selecionados pela metodologia SHM não-supervisionada para o campanário de *San-Vittore*.

Critério	$\rho$	$\lambda$	$\beta$	$\tilde{\zeta}^{tr}$	$\tilde{\zeta}^{def}$	$\tilde{\zeta}^{val}$	IG
IG e $\tilde{\zeta}^{def}$	<b>0,1000</b>	<b>0,0001</b>	<b>0,0500</b>	<b>0,0061</b>	<b>0,0057</b>	<b>0,0053</b>	<b>22,66</b>
Menor $\tilde{\zeta}^{def}$	0,8000	0,0001	2,0000	0,0052	0,0047	0,0051	92,54
PCA	-	-	-	0,000060	0,000061	0,000056	165,21

De acordo com o esperado, a metodologia SAE/ $T^2$  proposta não detectou nenhuma alteração na estrutura. A maioria dos valores da estatística  $T^2$  permanece abaixo do limite UCL durante o treinamento, definição, validação e monitoramento, revelando apenas alguns valores discrepantes. Visando verificar a influência da aleatoriedade em tal resultado, a Figura 71 exibe a carta de controle com os pontos  $T^2$  obtidos para 30 diferentes modelos SAE (gerados com os mesmos  $\rho$ ,  $\lambda$  e  $\beta$  da Tabela 19, aleatorizando os dados de treinamento). O mesmo comportamento pode ser observado no gráfico  $T^2$  da Figura 70(b)), cujo o modelo foi selecionado pelo menor erro, e no gráfico da abordagem PCA/ $T^2$  da Figura 70(c)). No entanto, apesar do bom desempenho dos modelos SAE e PCA, as cartas de controle baseadas em componentes principais apresentaram *outliers* com valores mais significativos (mais distantes do UCL) e, assim como verificado nas outras estruturas analisadas, estão ligadas à valores mais altos de IG (ver Tabela 19) - o que no presente trabalho, até o momento, esteve associado a modelos de detecção de menor qualidade.

Figura 71 – Metodologia SAE/ $T^2$  - critério IG e  $\tilde{\zeta}^{def}$ : Carta de controle obtidas através de 30 modelos SAE para o campanário de *San Vittore*.



Um aspecto interessante que pode ser notado é o comportamento periódico do valor de  $T^2$ . Embora nenhuma variação no comportamento estrutural tenha sido verificada para a análise de longo prazo, os gráficos mostram claramente que os modelos de alguma forma capturaram as diferenças de temperatura ao longo do dia (tendência senoidal). A inspeção dos pontos  $T^2$  confirma este resultado: os picos estão relacionados aos dados diurnos - temperaturas mais altas - e os vales aos dados noturnos - temperaturas mais baixas.

## 7 CONCLUSÕES

O presente trabalho defendeu a tese de que Redes Neurais Codificadoras Esparsas (SAE) podem se apresentar como ferramentas SHM importantes dentro do conjunto de estratégias computacionais de aprendizado de máquina voltadas para detecção de alterações estruturais. A extensa revisão bibliográfica apresentada neste estudo corrobora com tal tese, uma vez que não são escassos os trabalhos recentes abordando esta temática. Entretanto, mesmo em face do grande número de artigos focados no SAE, algumas perguntas ainda estavam por ser respondidas. Pode-se mencionar, sobretudo, que algumas respostas-chaves que artigos recentes buscam oferecer, precisavam ser ratificadas ou, até mesmo, retificadas. Neste sentido, apresentam-se as conclusões acerca do presente documento, inicialmente apontando respostas para duas questões consideradas fundamentais para o uso do SAE em problemas de SHM.

A primeira questão é: **Como o SAE se comporta na tarefa de reproduzir sinais tipicamente oriundos de ensaios dinâmicos?** Pode-se dizer que é possível se obter erros muito baixos de reconstrução, utilizando-se um número relativamente pequeno de neurônios na camada interna do algoritmo, desde que seja adotado um conjunto de parâmetros adequado ao problema para o qual se busca solução. Observou-se que o tipo de função de transferência; o número de neurônios da camada interna; os valores de  $\rho$ ,  $\beta$  e  $\lambda$ ; o nível de ruído, a complexidade (número de componentes harmônicas presentes nas respostas dinâmicas) e o tamanho dos sinais influenciam diretamente o desempenho do SAE. Neste sentido, recomenda-se:

- Uso de funções de transferência: `satlin 4.2` para codificação e `purelin 4.3` para decodificação, apesar de outras combinações também terem fornecido resultados interessantes na análise paramétrica.
- A adoção de procedimento de busca para se determinar o conjunto  $\rho$ ,  $\beta$  e  $\lambda$  mais adequado. No presente trabalho optou-se por uma busca exaustiva, entretanto, espera-se que a adoção de algoritmos de otimização possa melhorar ainda mais o desempenho do SAE.
- Uma análise criteriosa para se definir o número de neurônios na camada interna para cada caso de análise. Não foi possível determinar uma porcentagem fixa entre neurônios na camada interna e o neurônios na camada de entrada (tamanho do sinal). Nos casos avaliados, a proporção adotada, de forma a se atingir resultados satisfatórios, foi até 10% do tamanho original das respostas, a depender da sua complexidade.
- Uma vez que os ruídos inerentes aos sinais analisados (sintéticos ou oriundos de ensaios) parecem não afetar significativamente os resultados do SAE, entende-se que

procedimentos de filtragens aumentariam o tempo de processamento sem melhorias consideráveis para o desempenho.

A outra questão importante que se coloca é: **Os parâmetros extraídos do SAE possibilitam a identificação de padrões de comportamento mecânico-estrutural?** Esta pergunta vem sendo respondida por esta e outras contribuições disponíveis na literatura. No presente trabalho os exemplos de aplicações apresentados apontaram que, tanto na análise supervisionada quanto na análise não-supervisionada, é possível identificar parâmetros do SAE que possibilitam distinguir estados de danificação distintos, o que credencia este algoritmo como uma ferramenta importante para sistemas SHM. Em se tratando especificamente da análise não-supervisionada, as respostas obtidas no decorrer desta tese diferem um pouco daquelas comumente alcançadas quando se aplica as metodologias presentes em trabalhos recentes da literatura, conforme será discutido a seguir, no momento em que se detalha a estratégia não-supervisionada proposta.

No caminho percorrido ao longo dos 5 anos de doutoramento, na busca pelas respostas para as questões supracitadas, é possível destacar algumas contribuições originais apresentadas que, de certa forma, se confundem com as conclusões do presente trabalho:

- **Desenvolvimento de estudo paramétrico, apresentado no capítulo 4.** Esta contribuição demonstrou a importância de uma análise prévia para se direcionar os estudos subsequentes voltados para as aplicações. O vasto território a ser explorado no âmbito das potencialidades e calibrações dos modelos SAE, caso não fossem limitadas a regiões de interesse onde seja possível identificar configurações relevantes de seus parâmetros, levaria a um estudo sem fim e pouco conclusivo. Ressalta-se que, mesmo diante destas análises que direcionaram os estudos desenvolvidos a posteriori, sempre foram necessários ajustes específicos, aplicados a cada exemplo.
- **Apresentação de uma estratégia supervisionada de detecção de dano baseada em SAE/SVM para problemas SHM.** Sobre esta contribuição cabe uma reflexão acerca do lapso temporal desta tese de doutorado: 5 anos. Observa-se que grande parte das publicações que abordam temas afins datam de um período semelhante ao decorrido desde o início do presente trabalho. Assim, nota-se que as publicações da autora (e outros) associadas a este assunto vieram ocorrendo ao longo da tese, reforçando o caráter original do tema quando do início do processo de submissão dos artigos. Desta forma, em função do longo prazo de doutoramento, estendido além dos 4 anos de praxe no Brasil por motivos associados à pandemia, pode-se ter a incorreta impressão de que a estratégia não supervisionada proposta não constitui uma contribuição original, algo que não encontra respaldo quando se observa as publicações da autora em revistas de impacto e congressos que abordam o tema, conforme se relata a seguir:

- **FINOTTI, R. P.**; BONIFÁCIO, A. L.; BARBOSA, F. S.; CURY, A. A.; FONSECA, L. G. Detecção de danos estruturais utilizando análise estatística e Auto-Codificador Esparso. **Mecânica Computacional**, v. 36, n. 19, p. 881-890, 2018.
  - **FINOTTI, R. P.**; BARBOSA, F. S.; CURY, A. A.; PIMENTEL, R. L.; TEODORO, C.; FERREIRA, G. S.; ARAÚJO JR., M. Detection of structural alterations using deep learning to characterize vibration signals. In: **15th International Conference on Vibration Engineering and Technology of Machinery - Proceedings of the 15th International Conference on Vibration Engineering and Technology of Machinery**, Curitiba, 2019. (Resumo expandido)
  - **FINOTTI, R. P.**; BARBOSA, F. S.; CURY, A. A.; PIMENTEL, R. L. Numerical and Experimental Evaluation of Structural Changes Using Sparse Auto-Encoders and SVM Applied to Dynamic Responses. **Applied Sciences**, 11(24), p. 11965, 2021.
  - **FINOTTI, R. P.**; BARBOSA, F. S.; CURY, A. A.; PIMENTEL, R. L. Novelty Detection Using Sparse Auto-Encoders to Characterize Structural Vibration Responses. **Arabian Journal for Science and Engineering**, v. 1, p. 1-14, 2022.
- **Detalhamento de uma proposta não-supervisionada de detecção de dano para uso do SAE em problemas SHM.** A estratégia apresentada usou o SAE como extrator de parâmetros e a métrica  $T^2$  de *Hotelling*. Classicamente, os autores atuais baseiam a definição dos modelos SAE em quantidades diretamente relacionadas aos erros de reconstrução ou, alternativamente e de forma indireta, aos resíduos da reconstrução de sinais. Esta estratégia se mostrou inadequada em diversas situações uma vez que os modelos resultantes apresentaram baixos desempenhos quando da classificação de dados de validação, indicando erroneamente a presença de alterações estruturais. Este problema foi parcialmente resolvido com a alternativa adotada para a definição do modelo SAE a partir de uma mescla entre o critério clássico para avaliação de desempenho do SAE - o erro de reconstrução - e um índice de generalização proposto e definido a partir dos valores do  $T^2$ . A proposta apresentada obteve grande êxito para os exemplos do pórtico e da torre, porém, para o caso da ponte Z24, notou-se que, mesmo apontando corretamente alterações estruturais em várias situações, houve outras onde ocorreram divergências entre as indicações dos modelos selecionados. Este fato indica que a estratégia apresentada, ainda que represente um avanço com relação às métricas atualmente disponíveis na literatura, necessita de aprimoramentos. Alguns resultados parciais que envolvem esta proposta não-supervisionada foram recentemente publicados em revista e congresso

internacional e são listados a seguir:

- **FINOTTI, R. P.**; GENTILE, C.; BARBOSA, F. S.; CURY, A. A. Vibration-based anomaly detection using sparse auto-encoder and control charts. In: **Proceedings of 11th International Conference on Structural Dynamics, EUROODYN 2020**, v. 1, p. 1335-1347, 2020.
- **FINOTTI, R. P.**; GENTILE, C.; BARBOSA, F. S.; CURY, A. A. Structural novelty detection based on sparse autoencoders and control charts. **Structural Engineering and Mechanics**, v. 81, n.5, p. 647-664, 2022.

Ainda sobre a estratégia não-supervisionada, destaca-se que nos dois exemplos onde os efeitos da temperatura foram abordados, notou-se que o SAE modelou estes efeitos de forma implícita, uma vez que as alterações mecânicas atribuídas a esta característica ambiente necessariamente afetam as medições dinâmicas processadas. Para o exemplo da Z24, foi possível identificar através do SAE as alterações estruturais em dois cenários distintos, sendo a primeira e a segunda a situações respectivamente associadas a medições dinâmicas com variação de temperatura e com temperatura constante. Neste exemplo, em ambos os cenários o PCA (algoritmo usado para comparação) não obteve êxito. Já para o exemplo da torre na Itália, observou-se neste caso que tanto o SAE quanto o PCA foram capazes de implicitamente modelar as variações de temperatura, tendo em vista o caráter periódico das respectivas cartas de controle obtidas para este caso de análise.

Ressalta-se a importância dos estágios de doutorado sanduíche realizados pela autora na Universidade Federal da Paraíba e na *Politecnico di Milano*, respectivamente supervisionados pelos professores Roberto Pimentel e Carmelo Gentile, para a formação acadêmica da candidata e para o efetivo desenvolvimento de algumas das publicações mencionadas nestas conclusões.

Por fim, e não menos importante, como é usual em trabalhos de doutoramento no Brasil, segue uma lista de possíveis trabalhos futuros:

- Comparar entre o desempenho do SAE e de CNN na tarefa de extrair parâmetros que viabilizem a identificação de estados de integridade estrutural;
- Aplicar algoritmos de otimização, quer sejam aqueles inspirados na natureza, quer seja os baseados e derivadas de funções, com o intuito de determinar a melhor configuração de parâmetros para o SAE;
- Ajustar a métrica usada para seleção dos modelos SAE com a introdução, por exemplo, de fatores não-determinísticos associados ao caráter aleatório dos métodos de inteligência artificial;

- Aplicar a metodologia não-supervisionada proposta a um estudo extensivo, focado em um número relativamente alto de estruturas, buscando reunir o máximo de informações sobre o desempenho do SAE;
- Fazer um paralelo sobre o a metodologia não supervisionada proposta aplicada a sinais no domínio da frequência, obtidos através de FFT.
- Ampliar a técnica apresentada visando ir além da detecção de danos, quiçá localizando e quantificando as alterações estruturais.

A seguir apresenta-se uma lista com as demais publicações da autora (e outros), realizadas ao longo do doutorado, que abordaram assuntos correlatos à presente tese:

- **FINOTTI, R. P.**; BARBOSA, F.; CURY, A. A.; GENTILE, C. A novel natural frequency-based technique to detect structural changes using computational intelligence. **Procedia engineering**, v. 199, p. 3314-3319, 2017.
- MARRONGELLI, G.; **FINOTTI, R.**; GENTILE, C.; BARBOSA, F. An artificial intelligence strategy to detect damage from response measurements: application on an ancient tower. In: **MATEC Web of Conferences**, v. 211, p. 21002, 2018.
- RODRIGUES, B. L.; **FINOTTI, R. P.**; BARBOSA, F. S. Avaliação de uma estratégia para monitoramento estrutural baseada em redes neurais artificiais e parâmetros estatísticos. In: **Anais do XXII Encontro Nacional de Modelagem Computacional e X Encontro de Ciência e Tecnologia de Materiais**, p. 1425-1434, 2019.
- **FINOTTI, R. P.**; CURY, A. A.; BARBOSA, F. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, p. e165, 2019.
- NUNES, L. A.; **AMARAL, R. P. F.**; BARBOSA, F. S.; CURY, A. A. A hybrid learning strategy for structural damage detection. **Structural Health Monitoring**, v. 20, n. 4, p. 2143-2160, 2021.

## REFERÊNCIAS

- [1] FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 365, n. 1851, p. 303-315, 2006.
- [2] QING, X.; LI, W.; WANG, Y.; SUN, H. Piezoelectric Transducer-Based Structural Health Monitoring for Aircraft Applications. **Sensors**, v. 19, n. 3, p. 545, 2019.
- [3] FATHI, A.; ESFANDIARI, A.; FADAVIE, M.; MOJTAHEDI A. Damage detection in an offshore platform using incomplete noisy FRF data by a novel Bayesian model updating method. **Ocean Engineering**, v. 217, p. 108023, 2020.
- [4] PANG, B.; NAZARI, M.; SUN, Z.; LI, J.; TANG, G. An optimized variational mode extraction method for rolling bearing fault diagnosis. **Structural Health Monitoring**, v. 21, n. 2, p. 558-570, 2022.
- [5] HUI, M.C.H.; WONG, C.K.P. Stonecutters Bridge—durability, maintenance and safety considerations. **Structure and Infrastructure Engineering**, v. 5, n. 3, p. 229-243, 2009.
- [6] CACHOT, E.; VAYSSADE, T.; VIRLOGEUX, M.; LANCON, H.; HAJAR, Z.; SERVANT, C. The Millau viaduct: ten years of structural monitoring. **Structural Engineering International**, v. 25, n. 4, p. 375-380, 2015.
- [7] ANNAMDAS, V.G.M.; BHALLA, S.; SOH, C.K. Applications of structural health monitoring technology in Asia. **Structural Health Monitoring**, v. 16, n. 3, p. 324-346, 2017.
- [8] Disponível em: <http://www.lavocedigenova.it/2018/10/03/mobile/leggi-notizia/argomenti/attualita-4/articolo/secondo-il-prof-gentile-autostrade-conosceva-il-rischio-morandi.html>, acessado em 17 de dezembro de 2018.
- [9] Disponível em: <https://brasil.elpais.com/internacional/2021-05-04/queda-de-viaduto-do-metro-deixa-23-mortos-na-cidade-do-mexico.html>, acessado em 13 de novembro de 2021.
- [10] Disponível em: <https://g1.globo.com/mundo/noticia/2018/08/16/desabou-a-ponte-morandi-ouca-ligacao-para-servico-de-emergencia-avisando-sobre-tragedia-na-italia.ghtml>, acessado em 17 de dezembro de 2018.
- [11] Disponível em: <https://g1.globo.com/mundo/noticia/2021/05/04/viaduto-desaba-e-trem-do-metro-cai-em-avenida-no-mexico.ghtml>, acessado em 13 de novembro de 2021.
- [12] BATTISTA, R. C.; PFEIL, M. S. Monitoring and control of wind-induced oscillations of a steel bridge. In: **Proceedings of the Fourth European Conference on Structural Dynamics-EURODYN'2002**, p. 925-930, 2002.
- [13] BAILEY, C. A critical analysis of the design and construction of The Juscelino Kubitschek Bridge. In: **Proceedings of Bridge Engineering Conference 2007**. 2007.

- [14] DE OLIVEIRA, J.V.M.; LAROCCA, A.P.C.; DE ARAÚJO NETO, J.O.; CUNHA, A. L.; DOS SANTOS, M. C.; SCHAAL, R. E. Vibration monitoring of a small concrete bridge using wavelet transforms on GPS data. **Journal of Civil Structural Health Monitoring**, v. 9, p. 397–409, 2019.
- [15] Disponível em: <https://www.marinha.mil.br/dphdm/ponte-rio-niteroi>, acessado em 16 de janeiro de 2019.
- [16] Disponível em: [https://pt.wikipedia.org/wiki/Ponte\\_Juscelino\\_Kubitschek](https://pt.wikipedia.org/wiki/Ponte_Juscelino_Kubitschek), acessado em 15 de janeiro de 2019.
- [17] Disponível em: [http://www.antt.gov.br/backend/galeria/arquivos/proj04fernao\\_dias\\_oae\\_fase4\\_jul15final.pdf](http://www.antt.gov.br/backend/galeria/arquivos/proj04fernao_dias_oae_fase4_jul15final.pdf), acessado em 2 de julho de 2019.
- [18] Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2018/11/30/viaduto-que-cedeu-na-marginal-pinheiros-comeca-a-ser-levantado-com-macacos-hidraulicos-neste-sabado.ghtml>, acessado em 15 de janeiro de 2019.
- [19] Disponível em: <https://www.emaisgoias.com.br/viaduto-da-galeria-dos-estados-desaba-em-brasilia/>, acessado em 15 de janeiro de 2019.
- [20] AVCI, O.; ABDELJABER, O.; KIRANYAZ, S.; HUSSEIN, M.; GABBOUJ, M.; INMAN, D. J. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. **Mechanical systems and signal processing**, v. 147, p. 107077, 2021.
- [21] NUNES, L. A.; AMARAL, R. P. F.; BARBOSA, F. S.; CURY, A. C. A hybrid learning strategy for structural damage detection. **Structural Health Monitoring**, v. 20, n. 4, 2143-2160, 2021.
- [22] DAN, J.; FENG, W.; HUANG, X.; WANG, Y. Global bridge damage detection using multi-sensor data based on optimized functional echo state networks. **Structural Health Monitoring**, v. 20, n. 4, 1924-1937, 2021.
- [23] DA SILVA, S.; HANSEN, C. Damage detection through nonparametric models using Kautz filters. **Meccanica**, v. 56, 1177–1189, 2021.
- [24] WAH, W. S. L.; CHEN, Y. T.; OWEN, J. S. A regression-based damage detection method for structures subjected to changing environmental and operational conditions. **Engineering Structures**, v. 228, p. 111462, 2021.
- [25] DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B. A summary review of vibration-based damage identification methods. **Shock and Vibration Digest**, v. 30, n. 2, p. 91-105, 1998.
- [26] CARDEN, E. P.; FANNING, P. Vibration based condition monitoring: a review. **Structural Health Monitoring**, v. 3, n. 4, p. 355-377, 2004.
- [27] FAN, W.; QIAO, P. Vibration-based damage identification methods: a review and comparative study. **Structural Health Monitoring**, v. 10, n. 1, p. 83-129, 2011.
- [28] DAS, S.; SAHA, P.; PATRO, S. K. Vibration-based damage detection techniques used for health monitoring of structures: a review. **Journal of Civil Structural Health Monitoring**, v. 6, n. 3, p. 477-507, 2016.

- [29] XIA, Y.; CHEN, B.; WENG, S.; NI, Y. Q.; XU, Y. L. Temperature effect on vibration properties of civil structures: a literature review and case studies. **Journal of civil structural health monitoring**, v. 2, n. 1, p. 29-46, 2012.
- [30] ZHOU, G. D.; YI, T. H. A summary review of correlations between temperatures and vibration properties of long-span bridges. **Mathematical Problems in Engineering**, p. 638209, 2014.
- [31] REGNI, M.; AREZZO, D.; CARBONARI, S.; GARA, F.; ZONTA, D. Effect of environmental conditions on the modal response of a 10-story reinforced concrete tower. **Shock and Vibration**, p. 9476146, 2018.
- [32] GILLICH, G. R.; FURDUI, H.; WAHAB, M. A.; KORKA, Z. I. A robust damage detection method based on multi-modal analysis in variable temperature conditions. **Mechanical Systems and Signal Processing**, v. 115, p. 361-379, 2019.
- [33] MORALES, F. A. O.; CURY, A.; PEIXOTO, R.A.F. Analysis of thermal and damage effects over structural modal parameters. **Structural Engineering and Mechanics**, v. 65, n. 1, p. 43-51, 2019.
- [34] AMEZQUITA-SANCHEZ, J. P.; ADELI, H. Signal processing techniques for vibration-based health monitoring of smart structures. **Archives of Computational Methods in Engineering**, v. 23, n. 1, p. 1-15, 2016.
- [35] CRÉMONA, C.; SANTOS, J. Structural Health Monitoring as a Big-Data Problem. **Structural Engineering International**, v. 28, n. 3, p. 243-254, 2018.
- [36] SALEHI, H.; BURGUENO, R. Emerging artificial intelligence methods in structural engineering. **Engineering Structures**, v. 171, p. 170-189, 2018.
- [37] FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, n. 2, p. e165, 2019.
- [38] CARDOSO, R.A.; CURY, A.; BARBOSA, F.; GENTILE, C. Unsupervised real-time SHM technique based on novelty indexes. **Structural Control and Health Monitoring**, v. 26, p. e2364, 2019.
- [39] NGUYEN, D. H.; BUI, T. T.; DE ROECK, G.; WAHAB, M. A. Damage detection in Ca-Non Bridge using transmissibility and artificial neural networks. **Structural Engineering and Mechanics**, v. 71, n. 2, p. 175-183, 2019.
- [40] UMAR, S.; VAFAEI, M.; ALIH, S. C. Sensor clustering-based approach for structural damage identification under ambient vibration. **Automation in Construction**, v. 121, p. 103433, 2021.
- [41] ANOWAR, F.; SADAOUI, S.; SELIM, B. Conceptual and empirical comparison of dimensionality reduction algorithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA, t-SNE). **Computer Science Review**, v. 40, p. 100378, 2021.
- [42] ESFANDIARI, A.; NABIYAN, M. S.; ROFOOEI, F. R. Structural damage detection using principal component analysis of frequency response function data. **Structural Control and Health Monitoring**, v. 27, n. 7, p. e2550, 2020.

- [43] AGIS, D.; POZO, F. A frequency-based approach for the detection and classification of structural changes using t-SNE. **Sensors**, v. 19, n. 23, p. 5097, 2019.
- [44] KHAN, S.; YAIRI, T. A review on the application of deep learning in system health management. **Mechanical Systems and Signal Processing**, v. 107, p. 241-265, 2018.
- [45] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.
- [46] GU, J.; GUL, M.; WU, X. Damage detection under varying temperature using artificial neural networks. **Structural Control and Health Monitoring**, v. 24, n. 11, p. e1998, 2017.
- [47] PATHIRAGE, C.S.N.; LI, J.; LI, L.; HAO, H.; LIU, W.; Wang, R. Development and application of a deep learning-based sparse autoencoder framework for structural damage identification. **Structural Health Monitoring**, v. 18, n. 1, p. 103-122, 2019.
- [48] WANG, Z.; CHA, Y.J. Unsupervised deep learning approach using a deep auto-encoder with a one-class support vector machine to detect damage. **Structural Health Monitoring**, v. 20, n. 1, p. 406-425, 2021.
- [49] MONTGOMERY, D. **Introduction to Statistical Quality Control**. John Wiley & Sons, 2009.
- [50] WANG, Z.; ONG, K. C. G. Autoregressive coefficients based Hotellings T2 control chart for structural health monitoring. **Computers & Structures**, v. 86, n. 19-20, p. 1918-1935, 2008.
- [51] PRAKASH, G.; SADHU, A.; NARASIMHAN, S.; BREHE, J. M. Initial service life data towards structural health monitoring of a concrete arch dam. **Structural Control and Health Monitoring**, v. 25, n. 1, p. e2036, 2018.
- [52] GARCIA-MACIAS, E.; UBERTINI, F. MOVA/MOSS: Two integrated software solutions for comprehensive structural health monitoring of structures. **Mechanical Systems and Signal Processing**, v. 143, p. 106830, 2020.
- [53] RENS, K.L.; WIPF, T.J.; KLAIBER, F.W. Review of nondestructive evaluation techniques of civil infrastructure. **Journal of Performance of Constructed Facilities**, v. 11, n. 4, p. 152-160, 1997.
- [54] CAWLEY, P.; ADAMS, R.D. The location of defects in structures from measurements of natural frequencies. **The Journal of Strain Analysis for Engineering Design**, v. 14, n. 2, p. 49-57, 1979.
- [55] KATO, M.; SHIMADA, S. Vibration of PC bridge during failure process. **Journal of Structural Engineering**, v. 112, n. 7, p. 1692-1703, 1986.
- [56] MAZUREK, D.F.; DEWOLF, J.T. Experimental study of bridge monitoring technique. **Journal of Structural Engineering**, v. 116, n. 9, p. 2532-2549, 1990.

- [57] MESSINA, A.; WILLIAMS, E.J.; CONTURSI, T. Structural damage detection by a sensitivity and statistical-based method. **Journal of Sound and Vibration**, v. 216, n. 5, p. 791-808, 1998.
- [58] PEETERS, B.; DE ROECK, G. One-year monitoring of the Z24-Bridge: environmental effects versus damage events. **Earthquake Engineering & Structural Dynamics**, v. 30, n. 2, p. 149-171, 2001.
- [59] ALLEMANG, R.J.; BROWN, D.L. A correlation coefficient for modal vector analysis. In: **Proceedings of the 1st international modal analysis conference**, v.1 , p. 110-116, 1982.
- [60] LIEVEN, N.A.J.; EWINS, D.J. Spatial correlation of mode shapes, the coordinate modal assurance criterion (COMAC). In: **Proceedings of the sixth international modal analysis conference**, v.1, p. 690-695, 1988.
- [61] WOLFF, T.; RICHARDSON, M. Fault detection in structures from changes in their modal parameters. In: **Proceedings of the 7th international modal analysis conference**, v.1, p. 87-94, 1989.
- [62] ALAMPALLI, S. Effects of testing, analysis, damage, and environment on modal parameters. **Mechanical Systems and Signal Processing**, v. 14, n. 1, p. 63-74, 2000.
- [63] PANDEY, A.K.; BISWAS, M.; SAMMAN, M.M. Damage detection from changes in curvature mode shapes. **Journal of Sound and Vibration**, v. 145, n. 2, p. 321-332, 1991.
- [64] STUBBS, N.; KIM, J.T.; FARRAR, C.R. Field verification of a nondestructive damage localization and severity estimation algorithm. In: **Proceedings-SPIE the international society for optical engineering**. SPIE International Society for Optical, p. 210-210, 1995.
- [65] PANDEY, A.K.; BISWAS, M. Damage detection in structures using changes in flexibility. **Journal of Sound and Vibration**, v. 169, n. 1, p. 3-17, 1994.
- [66] NDAMBI, J.M.; VANTOMME, J.; HARRI, K. Damage assessment in reinforced concrete beams using eigenfrequencies and mode shape derivatives. **Engineering Structures**, v. 24, n. 4, p. 501-515, 2002.
- [67] ALVANDI, A.; CRÉMONA, C. Assessment of vibration-based damage identification techniques. **Journal of Sound and Vibration**, v. 292, n. 1-2, p. 179-202, 2006.
- [68] SHIH, H.W.; THAMBIRATNAM, D.P.; CHAN, T.H.T. Vibration based structural damage detection in flexural members using multi-criteria approach. **Journal of Sound and Vibration**, v. 323, n. 3-5, p. 645-661, 2009.
- [69] CURY, A.A.; BORGES, C.C.H.; BARBOSA, F.S. A two-step technique for damage assessment using numerical and experimental vibration data. **Structural Health Monitoring**, v. 10, n. 4, p. 417-428, 2011.
- [70] MODENA, C.; SONDA, D.; ZONTA, D. Damage localization in reinforced concrete structures by using damping measurements. **Key Engineering Materials**, v. 167-168, p. 132-141, 1999.

- [71] KAWIECKI, G. Modal damping measurement for damage detection. **Smart Materials and Structures**, v. 10, n. 3, p. 466-471, 2001.
- [72] CURADELLI, R.O.; RIERA, J.D.; AMBROSINI, D.; AMANI, M.G. Damage detection by means of structural damping identification. **Engineering Structures**, v. 30, n. 12, p. 3497-3504, 2008.
- [73] SOHN, H. Effects of environmental and operational variability on structural health monitoring. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 365, n. 1851, p. 539-560, 2006.
- [74] WORDEN, K.; FARRAR, C.R.; MANSON, G.; PARK, G. The fundamental axioms of structural health monitoring. **Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 463, n. 2082, p. 1639-1664, 2007.
- [75] HOU, Z.; NOORI, M.; AMAND, R.S. Wavelet-based approach for structural damage detection. **Journal of Engineering Mechanics**, v. 126, n. 7, p. 677-683, 2000.
- [76] VANIK, M.W.; BECK, J.L.; AU, S.K. Bayesian probabilistic approach to structural health monitoring. **Journal of Engineering Mechanics**, v. 126, n. 7, p. 738-745, 2000.
- [77] NAIR, K.K.; KIREMIDJIAN, A.S.; LAW, K.H. Time series-based damage detection and localization algorithm with application to the ASCE benchmark structure. **Journal of Sound and Vibration**, v. 291, n. 1-2, p. 349-368, 2006.
- [78] ESFANDIARI, A.; BAKHTIARI-NEJAD, F.; SANAYEI, M.; RAHAI, A. Structural finite element model updating using transfer function data. **Computers & Structures**, v. 88, n. 1-2, p. 54-64, 2010.
- [79] MARWALA, T. Damage identification using committee of neural networks. **Journal of Engineering Mechanics**, v. 126, n. 1, p. 43-50, 2000.
- [80] WORDEN, K.; LANE, A.J. Damage identification using support vector machines. **Smart Materials and Structures**, v. 10, n. 3, p. 540-547, 2001.
- [81] NI, Y.Q.; HUA, X.G.; FAN, K.Q.; KO, J.M. Correlating modal properties with temperature using long-term monitoring data and support vector machine technique. **Engineering Structures**, v. 27, n. 12, p. 1762-1773, 2005.
- [82] WEN, C.M.; HUNG, S.L.; HUANG, C.S.; JAN, J.C. Unsupervised fuzzy neural networks for damage detection of structures. **Structural Control and Health Monitoring**, v. 14, n. 1, p. 144-161, 2007.
- [83] CURY, A.; CRÉMONA, C.; DIDAY, E. Application of symbolic data analysis for structural modification assessment. **Engineering Structures**, v. 32, n. 3, p. 762-775, 2010.
- [84] CURY, A.; CRÉMONA, C. Pattern recognition of structural behaviors based on learning algorithms and symbolic data concepts. **Structural Control and Health Monitoring**, v. 19, n. 2, p. 161-186, 2012.

- [85] MERUANE, V.; HEYLEN, W. An hybrid real genetic algorithm to detect structural damage using modal properties. **Mechanical Systems and Signal Processing**, v. 25, n. 5, p. 1559-1573, 2011.
- [86] SHIRAZI, M.R.N.; MOLLAMAHOUDI, H.; SEYEDPOOR, S. M. Structural damage identification using an adaptive multi-stage optimization method based on a modified particle swarm algorithm. **Journal of Optimization Theory and Applications**, v. 160, n. 3, p. 1009-1019, 2014.
- [87] BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer-Verlag, 2006.
- [88] NI, Y.Q.; ZHOU, X.T.; KO, J.M. Experimental investigation of seismic damage identification using PCA-compressed frequency response functions and neural networks. **Journal of Sound and Vibration**, v. 290, n. 1-2, p. 242-263, 2006.
- [89] SANTOS, J.P.; CRÉMONA, C.; ORCESI, A.D.; SILVEIRA, P.; CALADO, L. Static-based early-damage detection using symbolic data analysis and unsupervised learning methods. **Frontiers of Structural and Civil Engineering**, v. 9, n. 1, p. 1-16, 2015.
- [90] ZANG, C.; FRISWELL, M.I.; IMREGUN, M. Structural damage detection using independent component analysis. **Structural Health Monitoring**, v. 3, n. 1, p. 69-83, 2004.
- [91] SONG, H.; ZHONG, L.; HAN, B. Structural damage detection by integrating independent component analysis and support vector machine. **International Journal of Systems Science**, v. 37, n. 13, p. 961-967, 2006.
- [92] SANTOS, A.; FIGUEIREDO, E.; SILVA, M. F. M.; SALES, C. S.; COSTA, J. C. W. A. Machine learning algorithms for damage detection: Kernel-based approaches. **Journal of Sound and Vibration**, v. 363, p. 584-599, 2016.
- [93] JEONG, M.; CHOI, J.H.; KOH, B.H. Isomap-based damage classification of cantilevered beam using modal frequency changes. **Structural Control and Health Monitoring**, v. 21, n. 4, p. 590-602, 2014.
- [94] ABDELJABER, O.; AVCI, O.; KIRANYAZ, S.; GABBOUJ, M.; INMAN, D. J. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. **Journal of Sound and Vibration**, v. 388, p. 154-170, 2017.
- [95] TENG, Z.; TENG, S.; ZHANG, J.; CHEN, G.; CUI, F. Structural Damage Detection Based on Real-Time Vibration Signal and Convolutional Neural Network. **Applied Sciences**, v. 10, n. 14, p. 4720, 2020.
- [96] CHEN, Z.; WANG, Y.; WU, J.; DENG, C.; HU, K. Sensor data-driven structural damage detection based on deep convolutional neural networks and continuous wavelet transform. **Applied Intelligence**, v. 51, p. 5598-5609, 2021.
- [97] BAO, Y.; TANG, Z.; LI, H.; ZHANG, Y. Computer vision and deep learning-based data anomaly detection method for structural health monitoring. **Structural Health Monitoring**, v. 18, n. 2, p. 401-421, 2019.

- [98] SILVA, M.F.; SANTOS, A.; SANTOS, R.; FIGUEIREDO, E.; COSTA, J.C.W.A. Damage-sensitive feature extraction with stacked autoencoders for unsupervised damage detection. **Structural Control and Health Monitoring**, v. 28, n. 5, p. e2714, 2021.
- [99] MA, X.; LIN, Y.; NIE, Z.; MA, H. Structural damage identification based on unsupervised feature-extraction via Variational Auto-encoder. **Measurement**, v. 160, p. 107811, 2020.
- [100] SHANG, Z.; SUN, L.; XIA, Y.; ZHANG, W. Vibration-based damage detection for bridges by deep convolutional denoising autoencoder. **Structural Health Monitoring**, v. 20, n. 4, p. 1880-1903, 2021.
- [101] FINOTTI, R.P.; BONIFÁCIO, A.L.; BARBOSA, F.S.; CURY, A.A; FONSECA, L.G. Detecção de danos estruturais utilizando análise estatística e Auto-Codificador Esparsos. **Mecânica Computacional**, v. 36, n. 19, p. 881-890, 2018.
- [102] PRINCIPE, J.C.; EULIANO, N.R.; LEFEBVRE, W.C. **Neural and Adaptive Systems: Fundamentals Through Simulations**. John Wiley & Sons, 2000.
- [103] HAGAN, M.T.; MENHAJ, M.B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989-993, 1994.
- [104] MØLLER, M.F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, v. 6, n. 4, p. 525-533, 1993.
- [105] KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Proceedings of the 14th International Joint Conference on Artificial Intelligence - IJCAI**, v. 14, n. 2, p. 1137-1145, 1995.
- [106] RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533-336, 1986.
- [107] NG, A. Sparse autoencoder. **CS294A Lecture Notes**, v. 72, p. 1-19, 2011.
- [108] KULLBACK, S.; LEIBLER, R.A. On information and sufficiency. **The Annals of Mathematical Statistics**, v. 22, n. 1, p. 79-86, 1951.
- [109] VAPNIK, V. **The Nature of Statistical Learning Theory**. Springer-Verlag, 1995.
- [110] TOUATI, R.; MIGNOTTE, M.; DAHMANE, M. Anomaly feature learning for unsupervised change detection in heterogeneous images: A deep sparse residual model. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 588-600, 2020.
- [111] FINOTTI, R.; BONIFÁCIO, A.; BARBOSA, F.; CURY, A. Evaluation of computational intelligence methods using statistical analysis to detect structural damage. **Mecânica Computacional**, v. 34, n. 22, p. 1389-1397, 2016.
- [112] CARDOSO, R.D.A.; CURY, A.; BARBOSA, F. Automated real-time damage detection strategy using raw dynamic measurements. **Engineering Structures**, v. 196, p. 109364, 2019.

- [113] DE MORAES, M.C.; BUTH, I.S.; DA LUZ, C.A.; LANGARO, E.A.; MEDEIROS, M.H.F. Alkali-activated cement subject to alkali-aggregate reaction. **ACI Materials Journal**, v. 118, n.5, p. 137+, 2021.
- [114] JAPKOWICZ, N.; STEPHEN, S. The class imbalance problem: A systematic study. **Intelligence Data Analysis**, v. 6, n. 5, p. 429–449, 2002.
- [115] DE ROECK, G.; PEETERS, B.; MAECK, J. Dynamic monitoring of civil engineering structures. In: **Proceedings of 4th International Colloquium on Computational Methods for Shell and Spatial Structures - IASS-IACM 2000**, Athens, Greece, 2000.
- [116] CABBOI, A.; GENTILE, C.; SAISI, A. From continuous vibration monitoring to FEM-based damage assessment: application on a stone-masonry tower. **Construction and Building Materials**, v. 156, p. 252-265, 2017.
- [117] GENTILE, C.; SAISI, A.; CABBOI, A. Structural identification of a masonry tower based on operational modal analysis. **International Journal of Architectural Heritage**, v. 9, n. 2, p. 98-110, 2015.

ANEXO A – Metodologia não-supervisionada de detecção de dano  
 SAE/ $T^2$ : Resultados complementares da ponte Z24 - 5 melhores modelos  
 segundo o critério IG e  $\tilde{\zeta}^{def}$ .

Figura 72 – Caso #1 - Acelerômetro 1. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

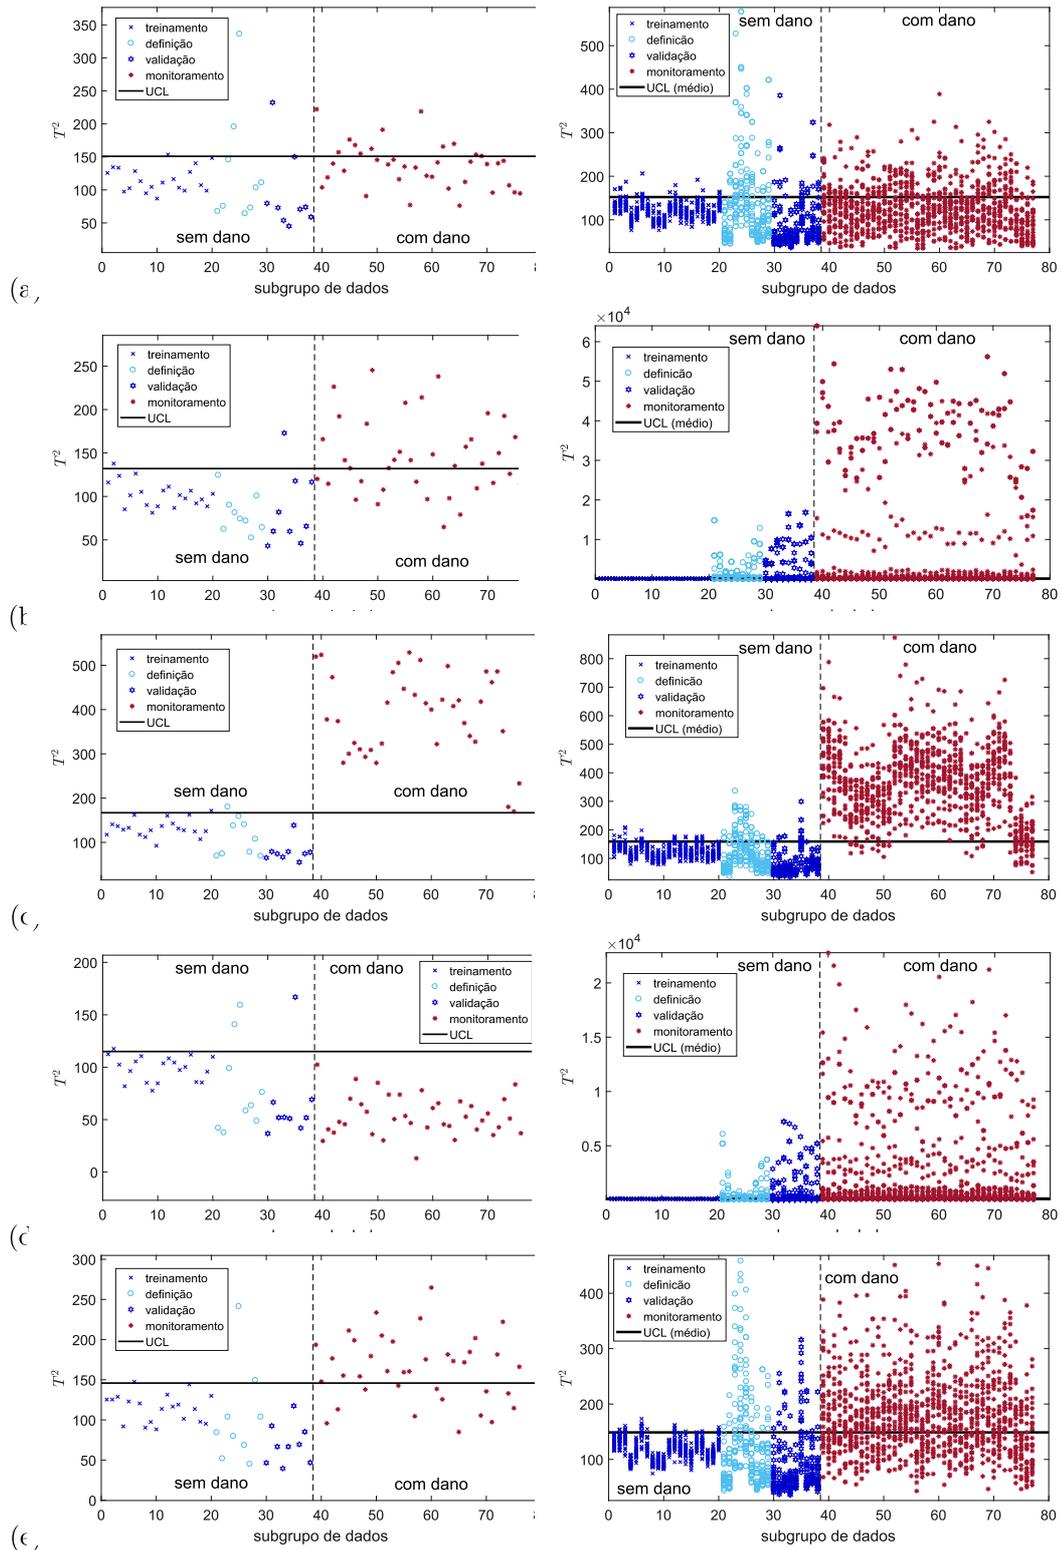


Figura 73 – Caso #1 - Acelerômetro 2. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

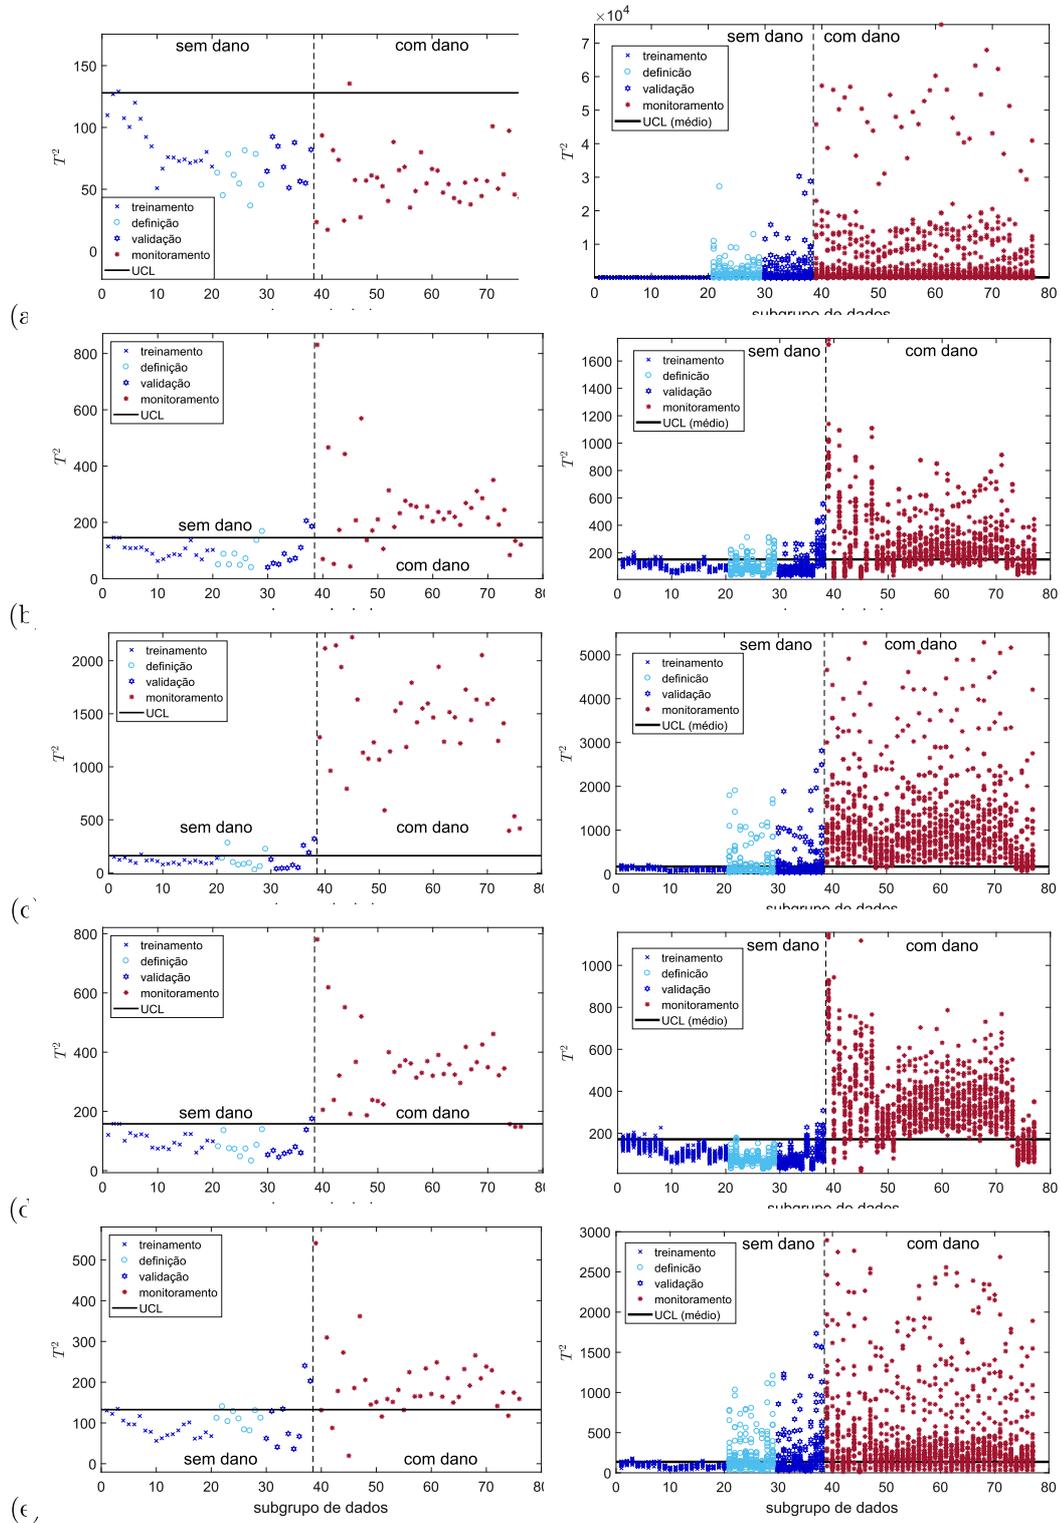


Figura 74 – Caso #1 - Acelerômetro 3. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

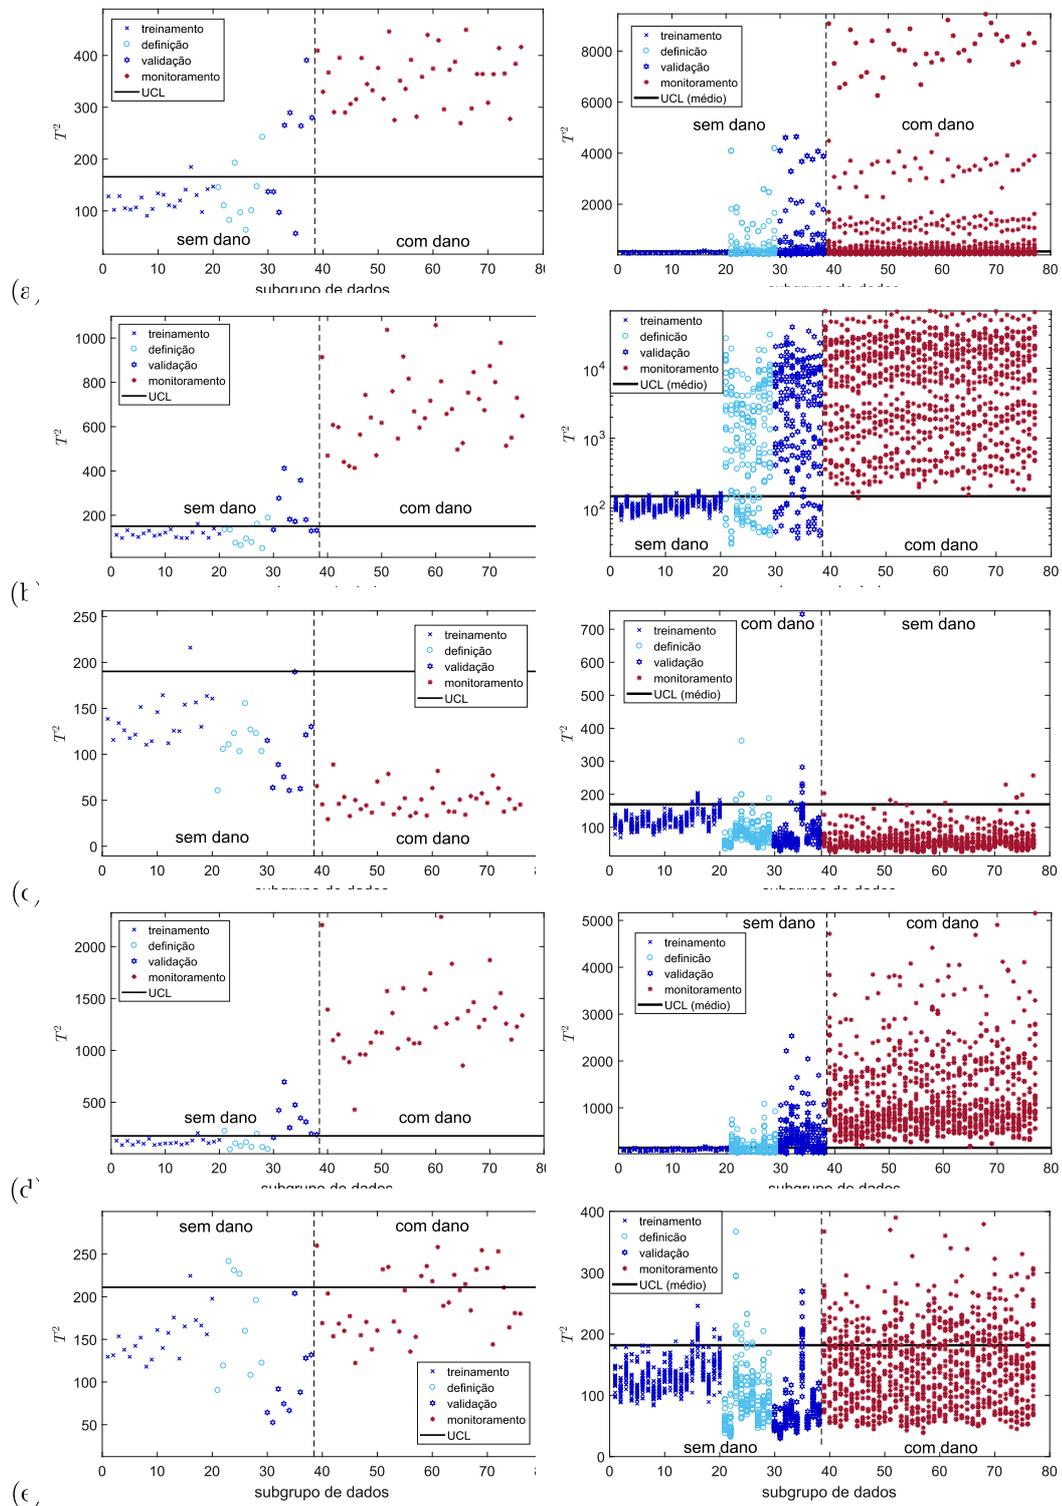


Figura 75 – Caso #1 - Acelerômetro 4. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

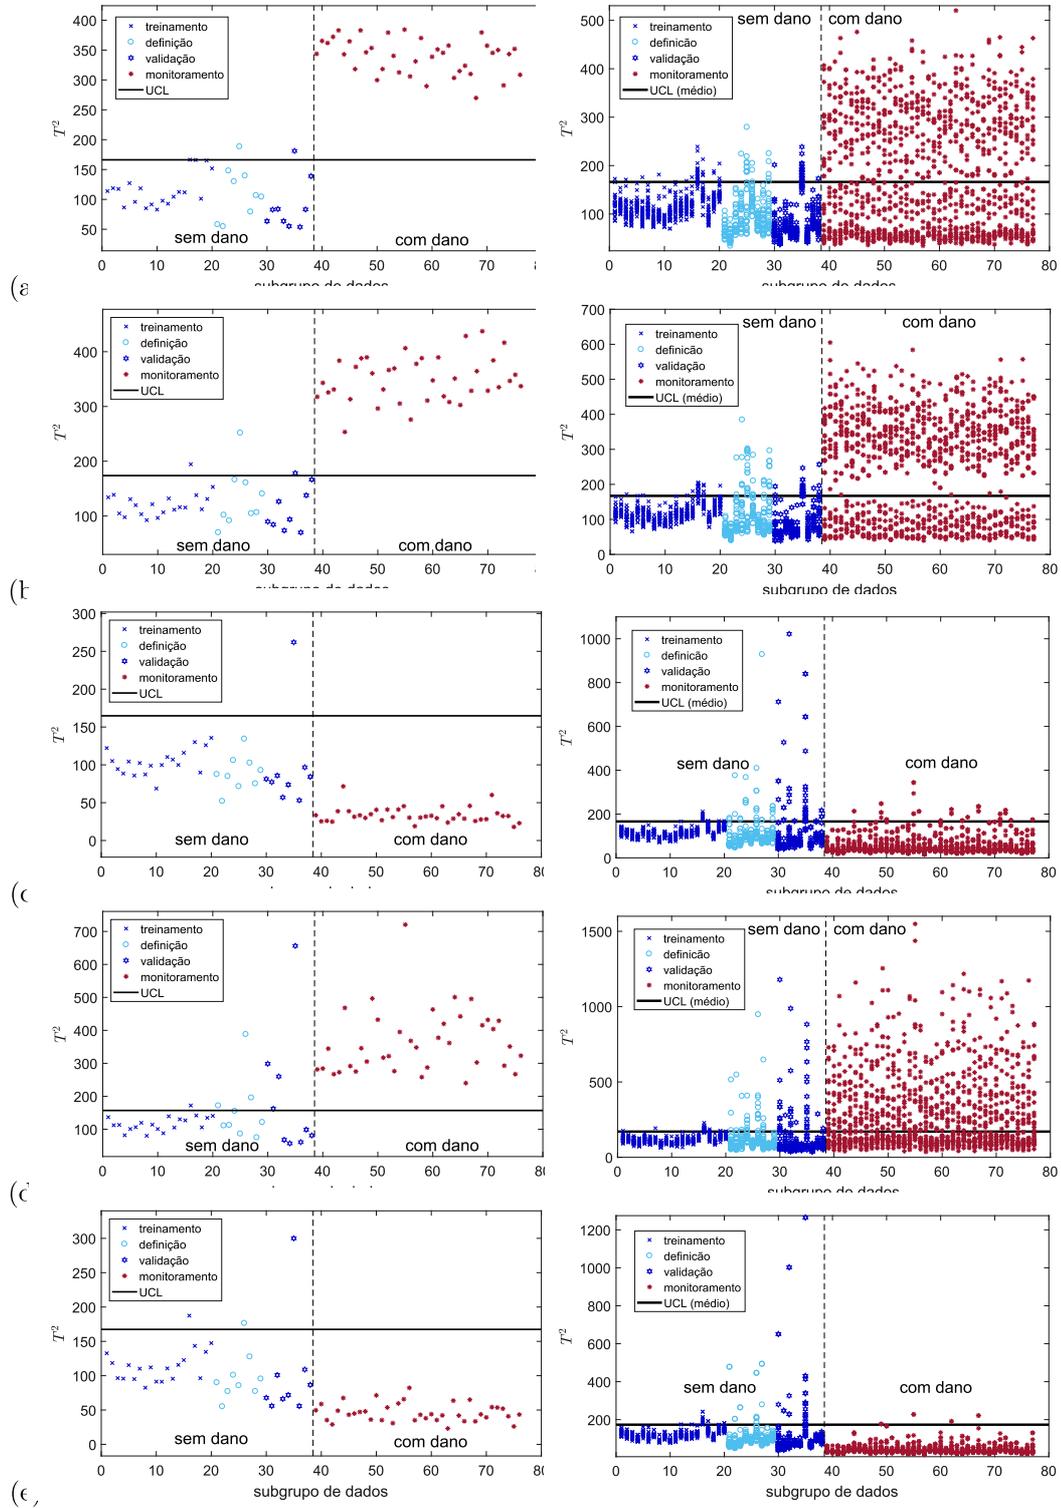


Figura 76 – Caso #1 - Acelerômetro 5. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

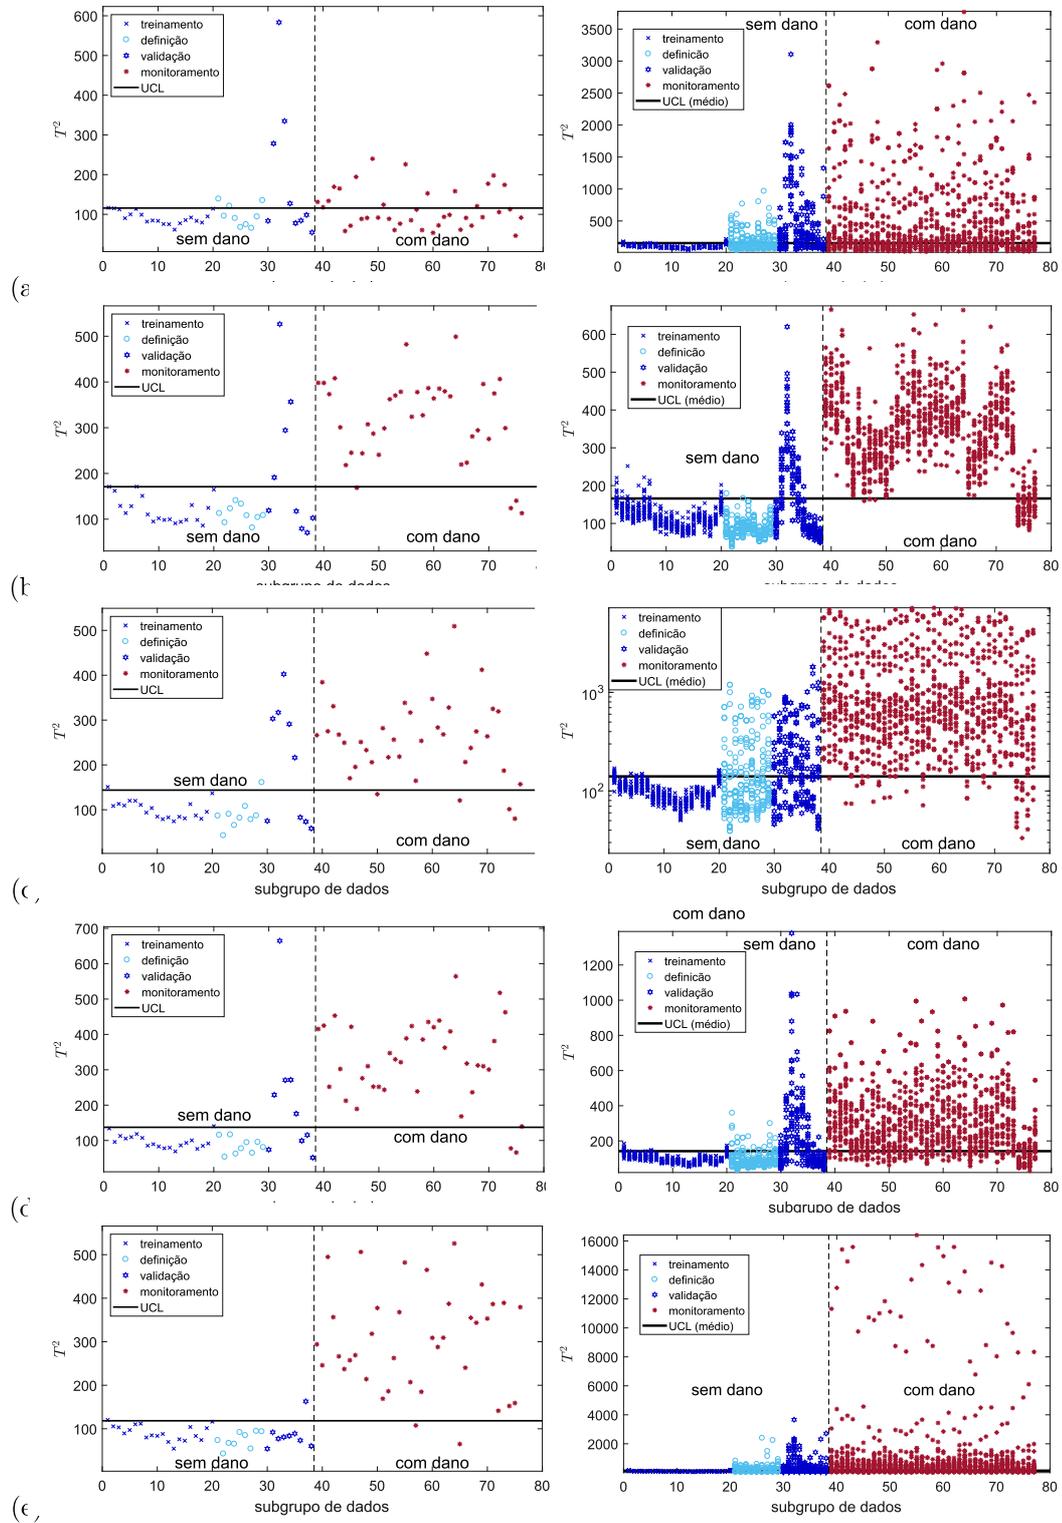


Figura 77 – Caso #2 - Acelerômetro 1. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

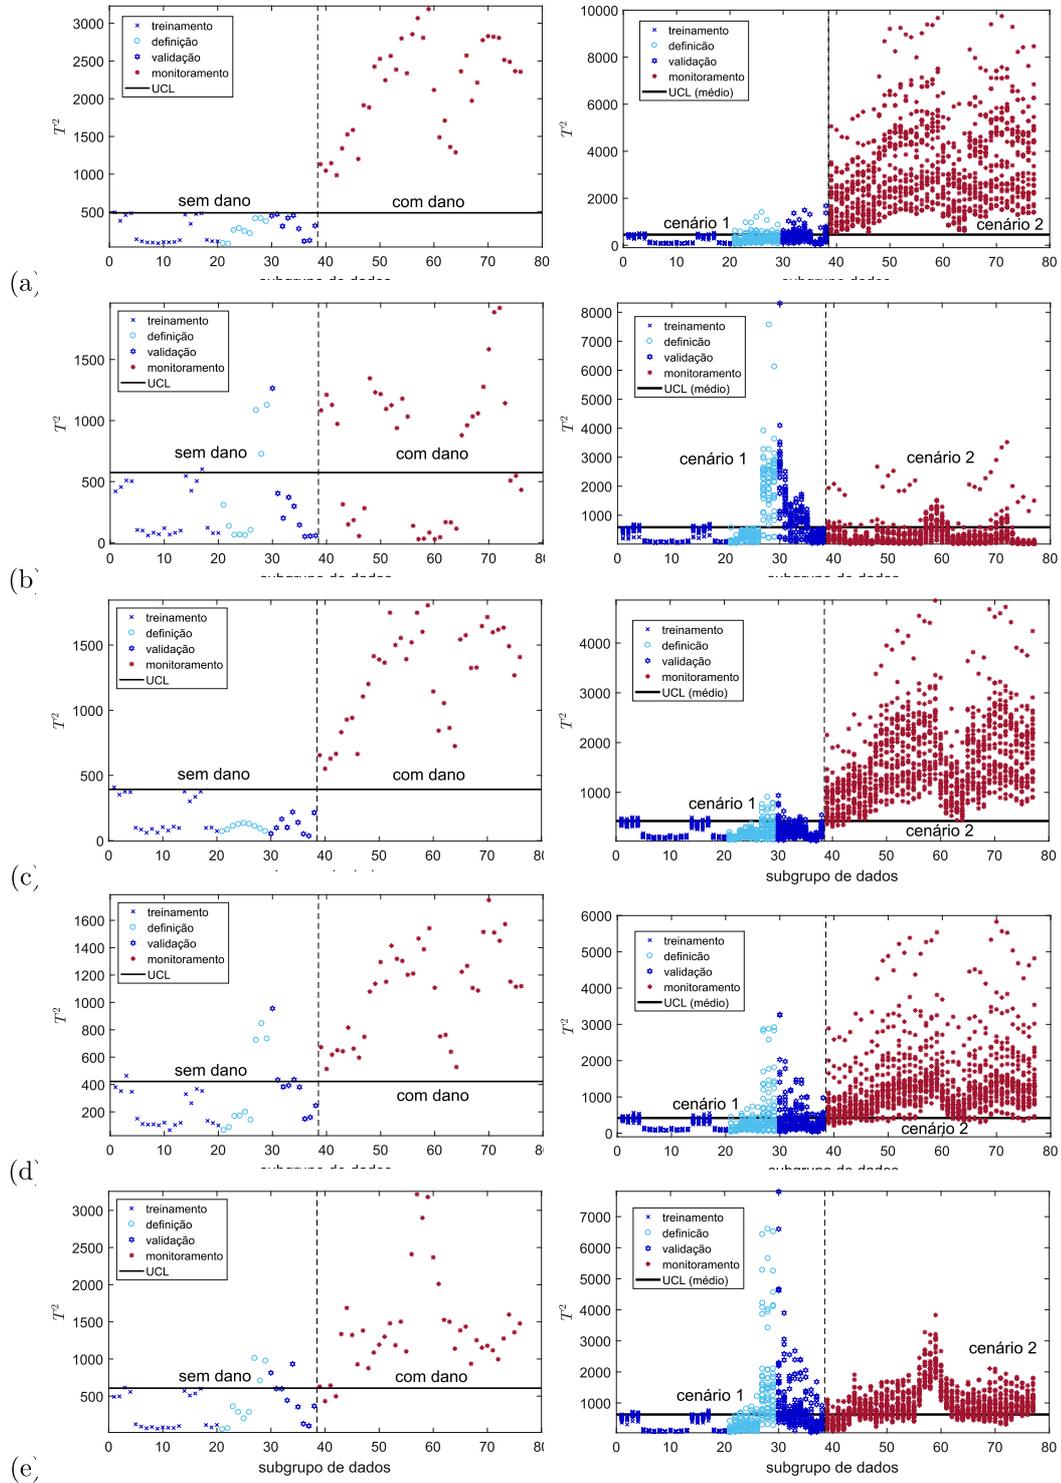


Figura 78 – Caso #2 - Acelerômetro 2. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

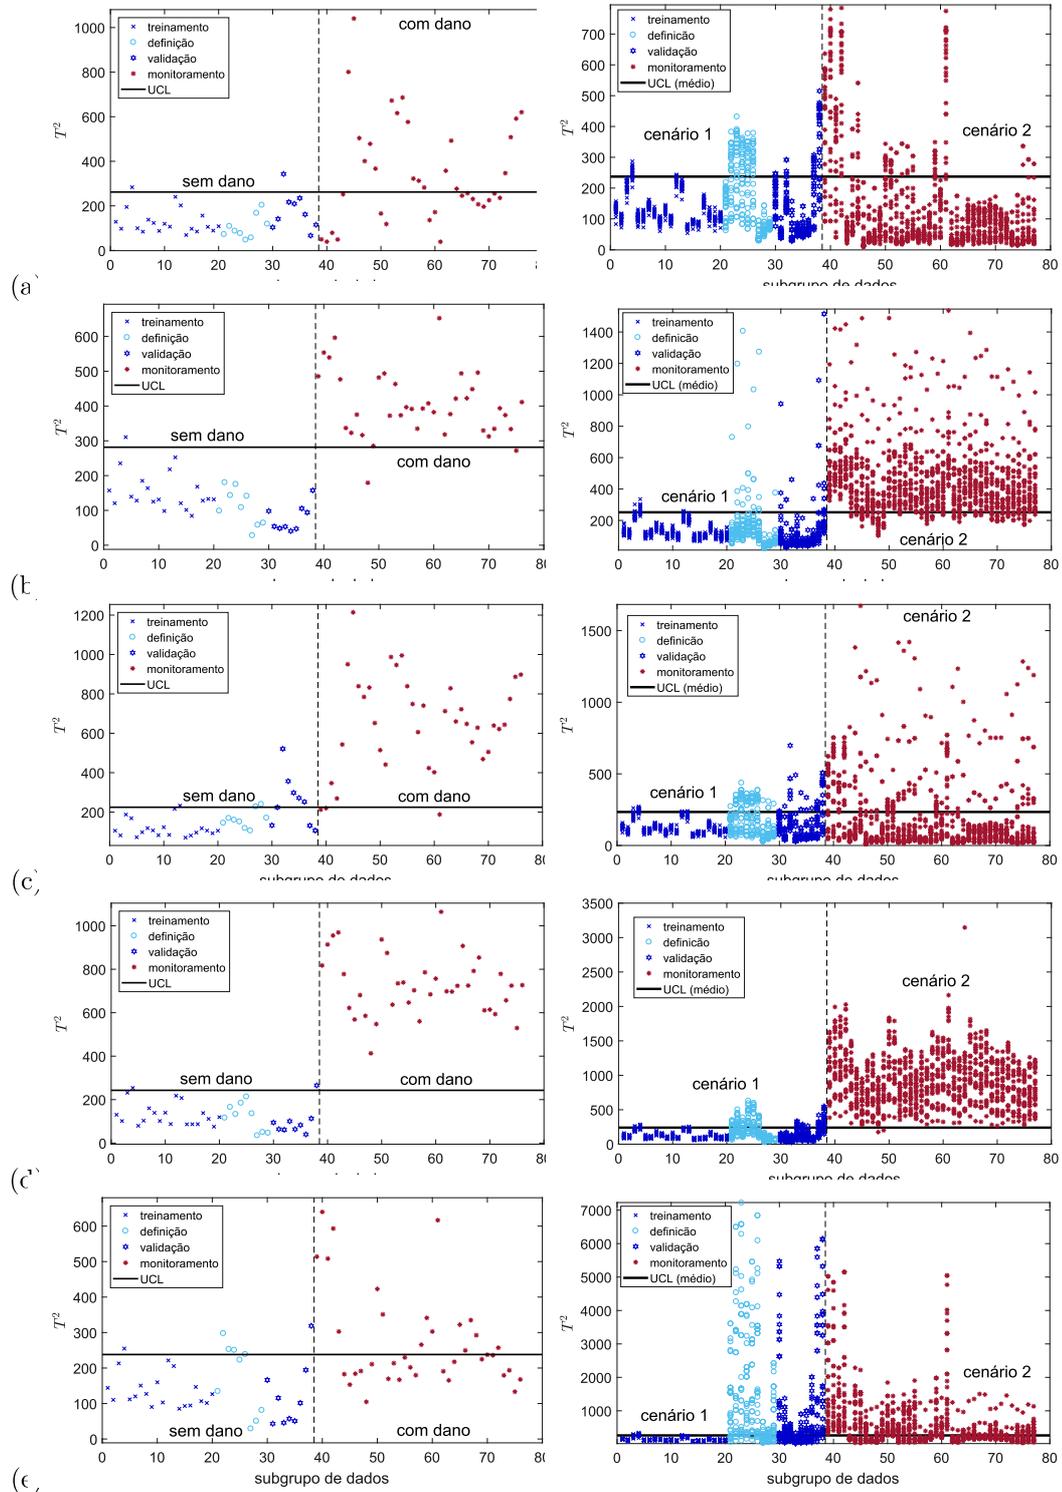


Figura 79 – Caso #2 - Acelerômetro 3. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

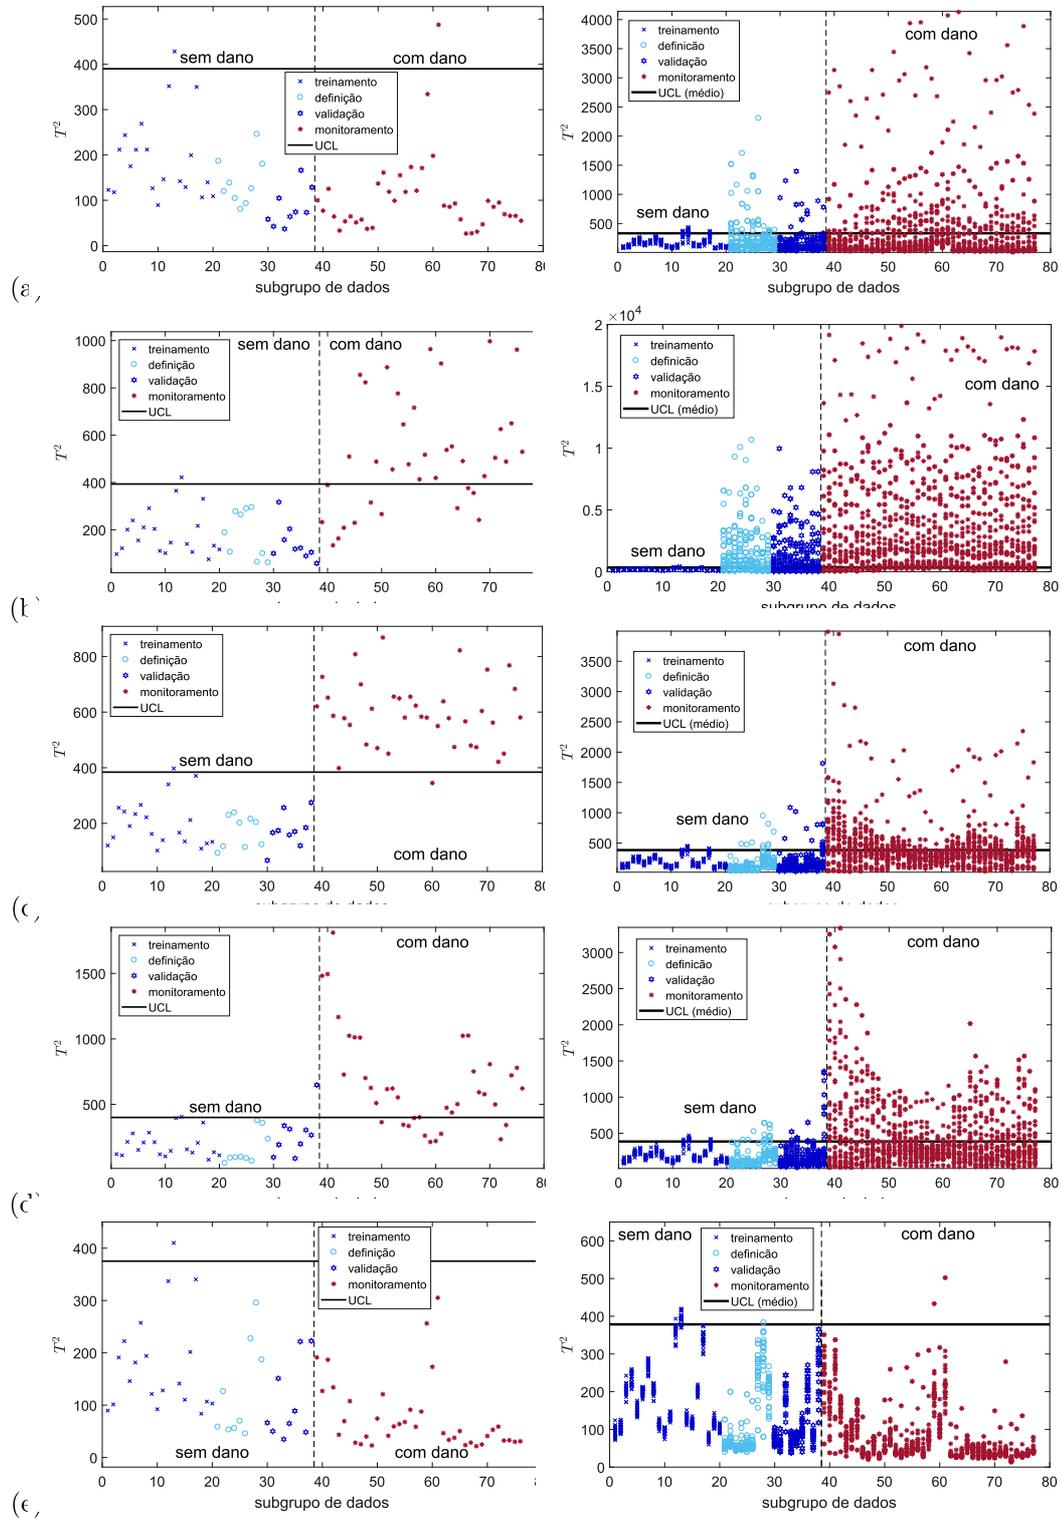


Figura 80 – Caso #2 - Acelerômetro 4. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

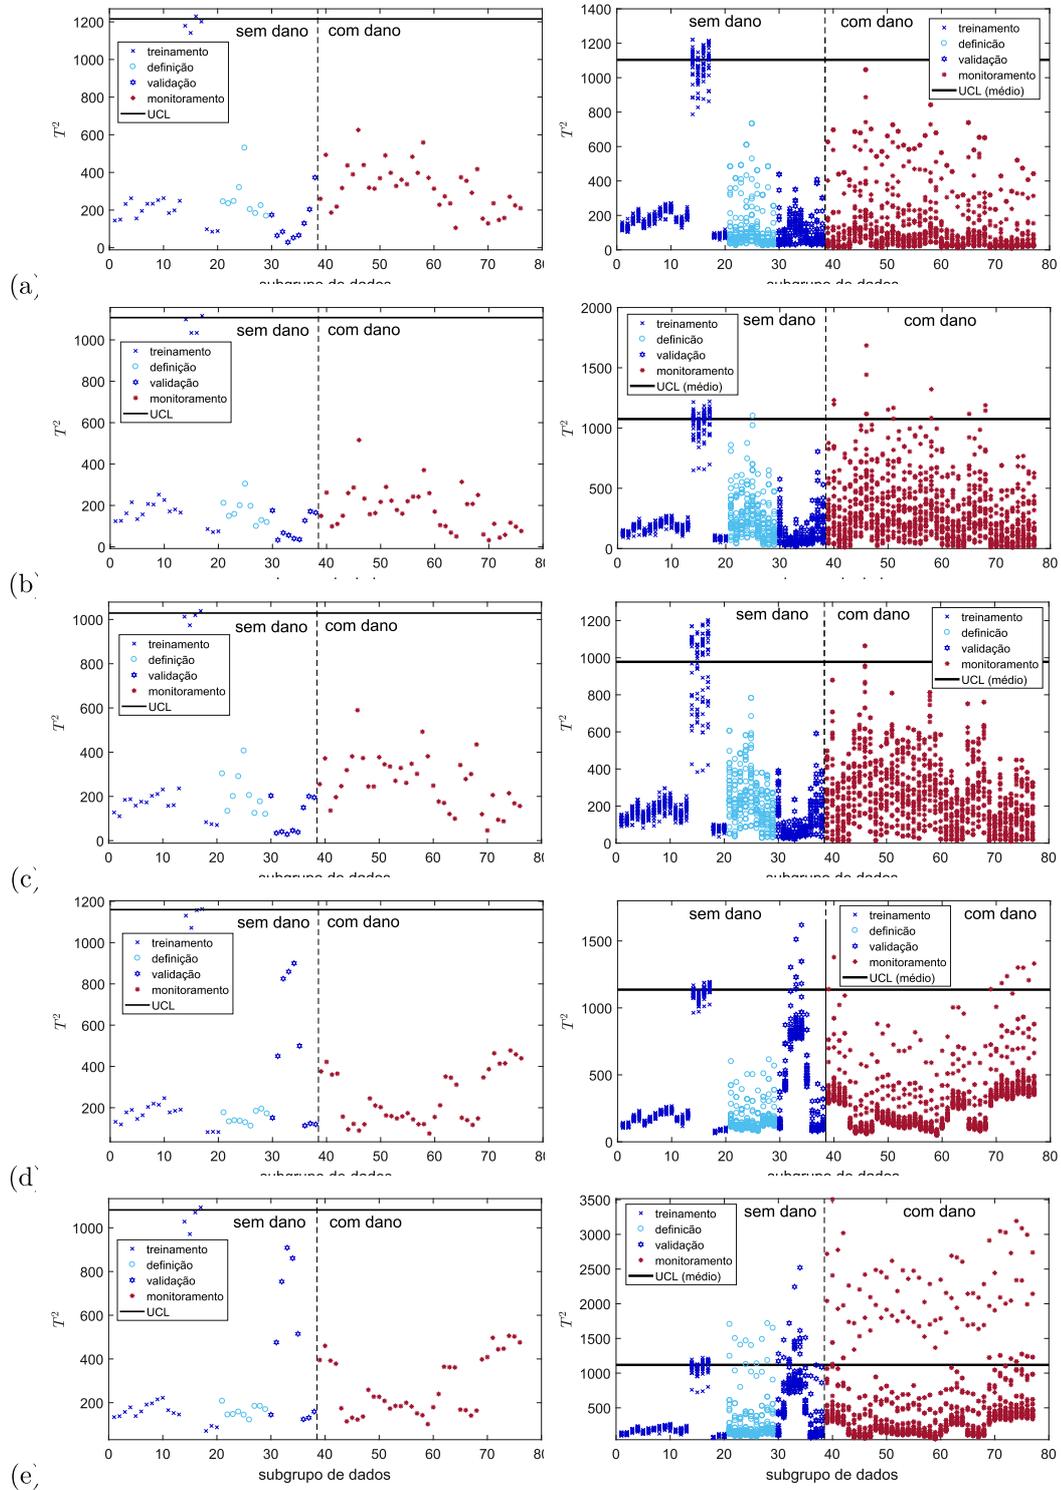
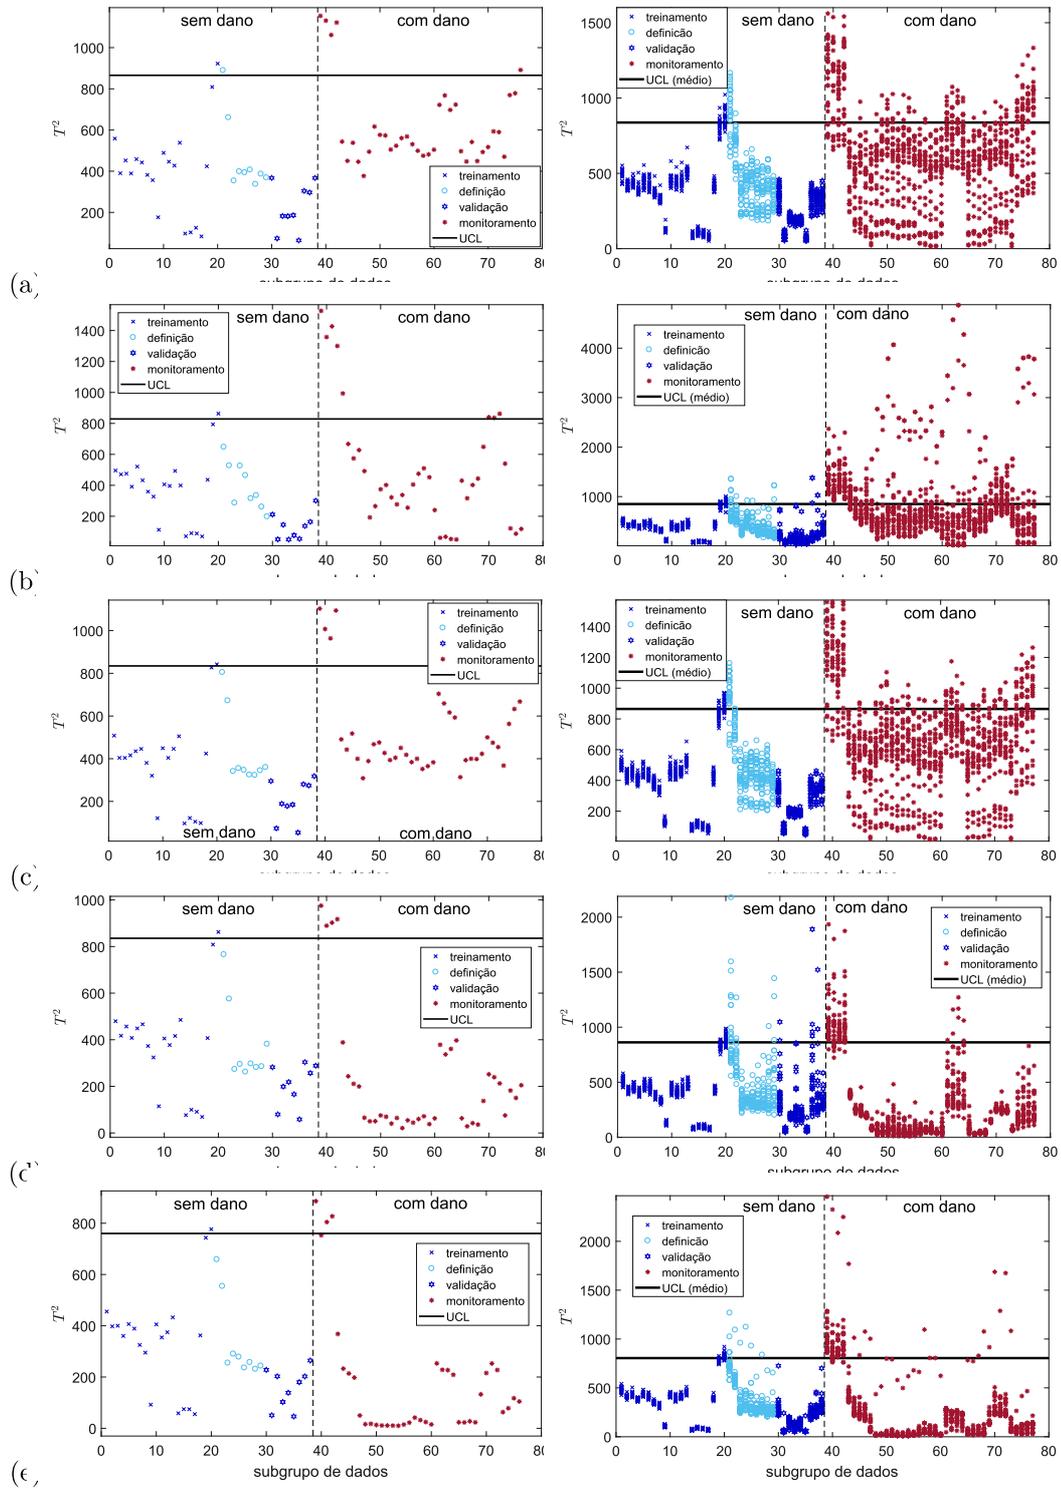


Figura 81 – Caso #2 - Acelerômetro 5. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.



ANEXO B – Metodologia não-supervisionada de detecção de dano  
 SAE/ $T^2$ : Resultados complementares da ponte Z24 - 5 melhores modelos  
 segundo o critério menor  $\tilde{\zeta}^{def}$ .

Figura 82 – Caso #1 - Acelerômetro 1. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

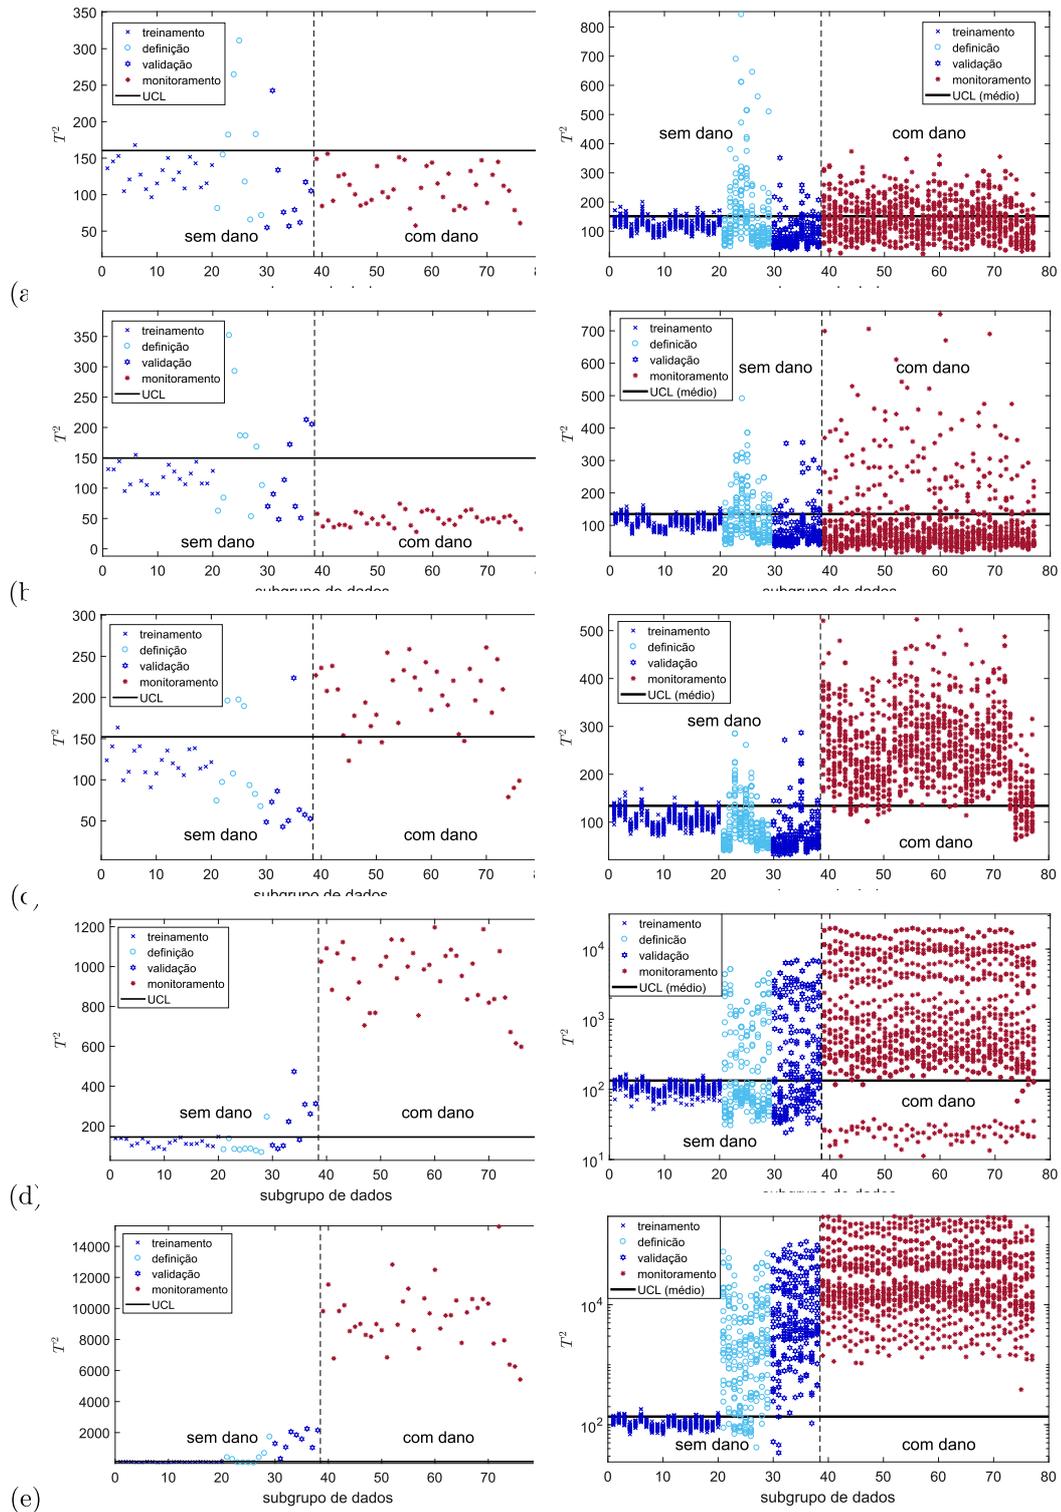


Figura 83 – Caso #1 - Acelerômetro 2. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

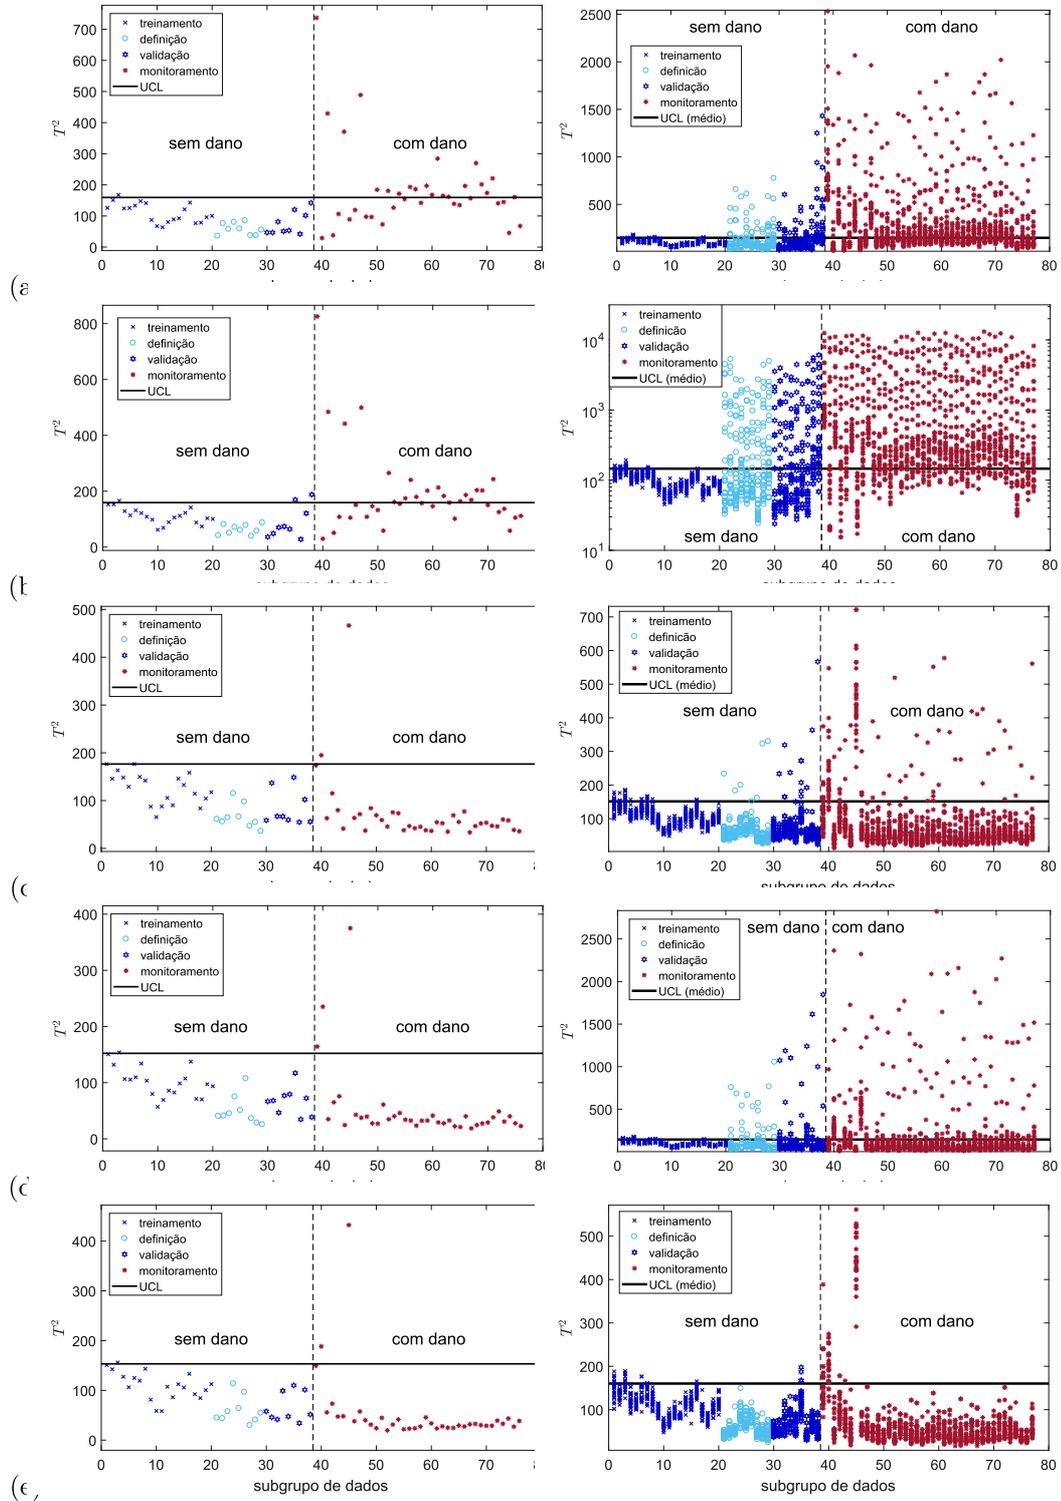


Figura 84 – Caso #1 - Acelerômetro 3. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

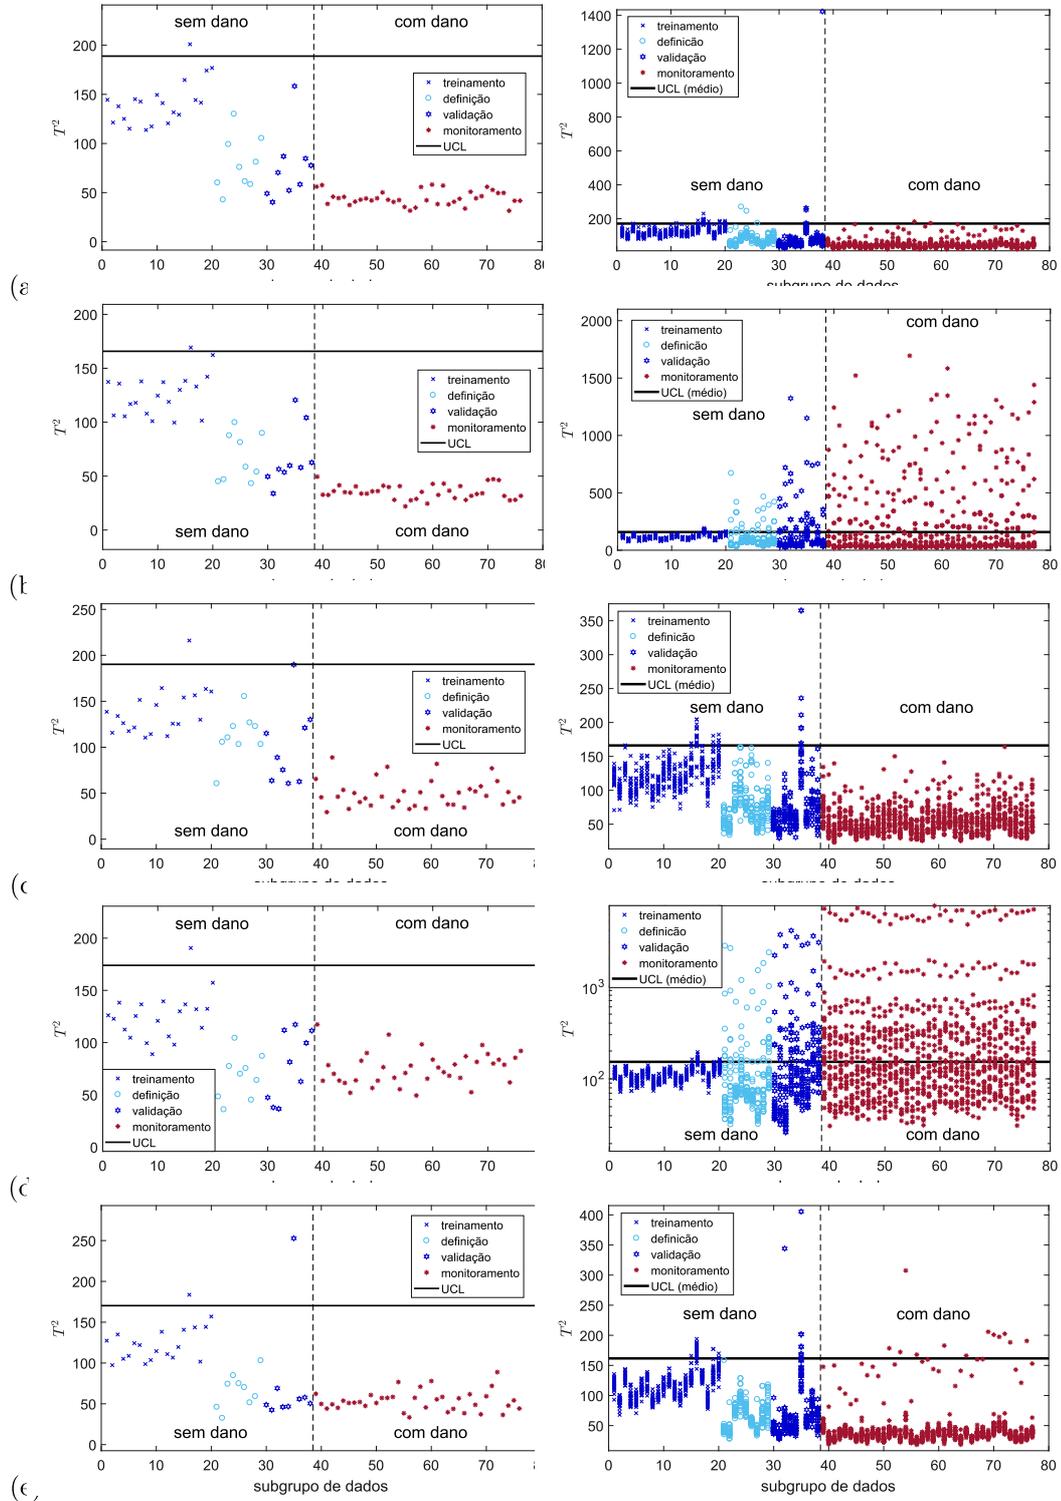


Figura 85 – Caso #1 - Acelerômetro 4. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

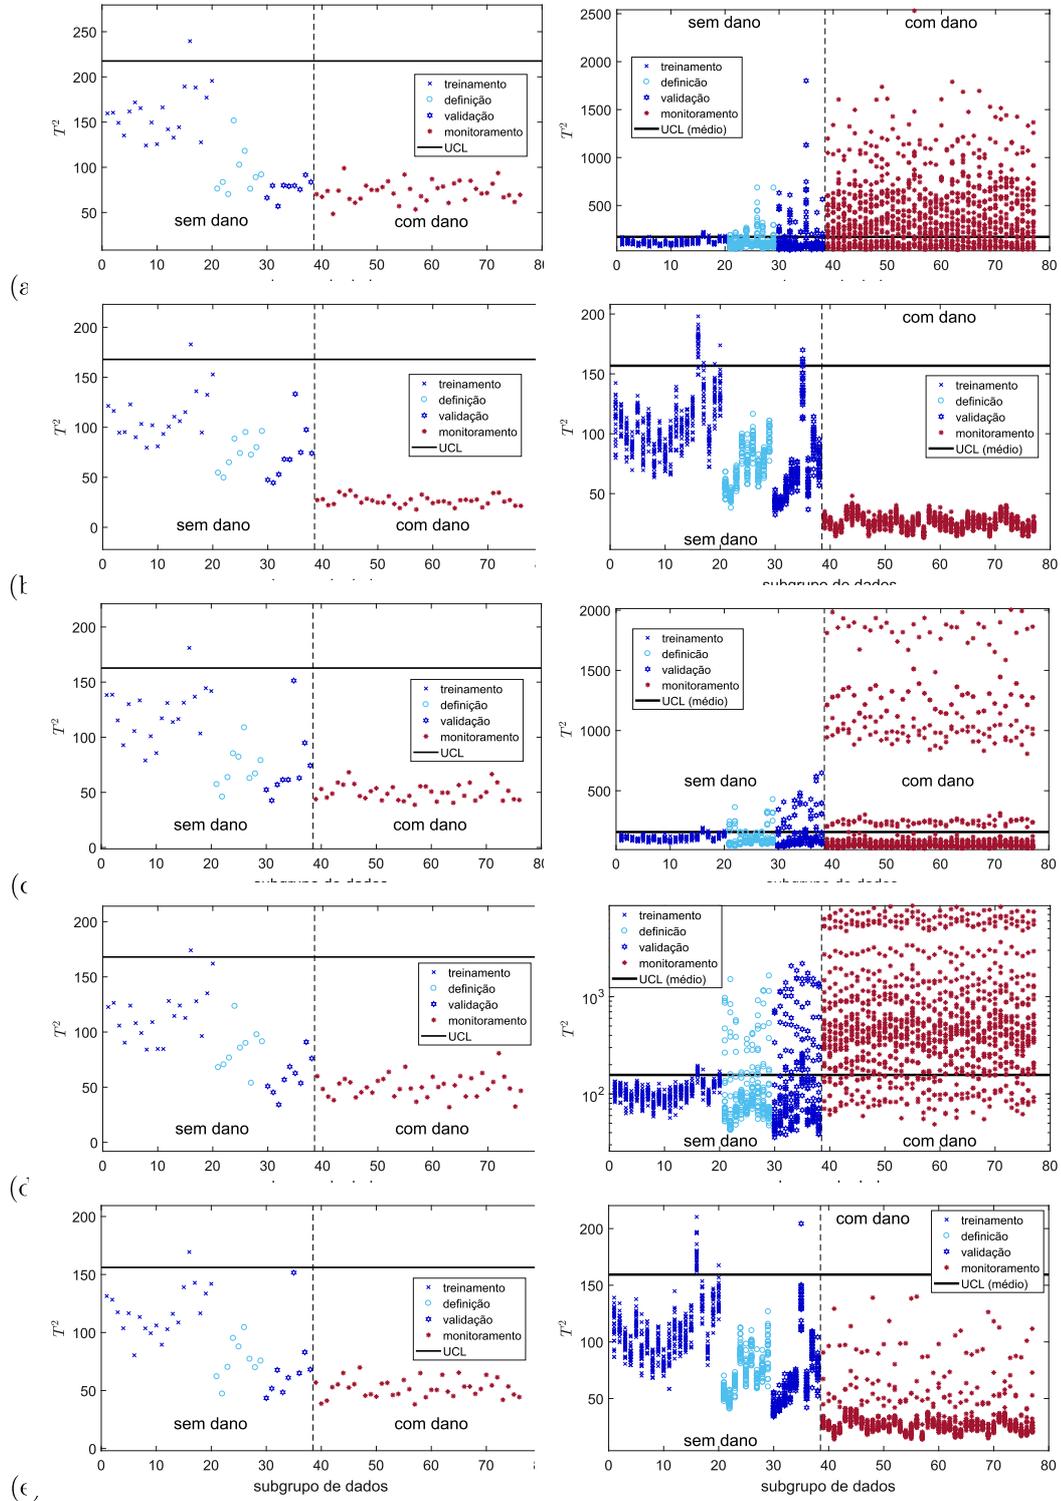


Figura 86 – Caso #1 - Acelerômetro 5. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

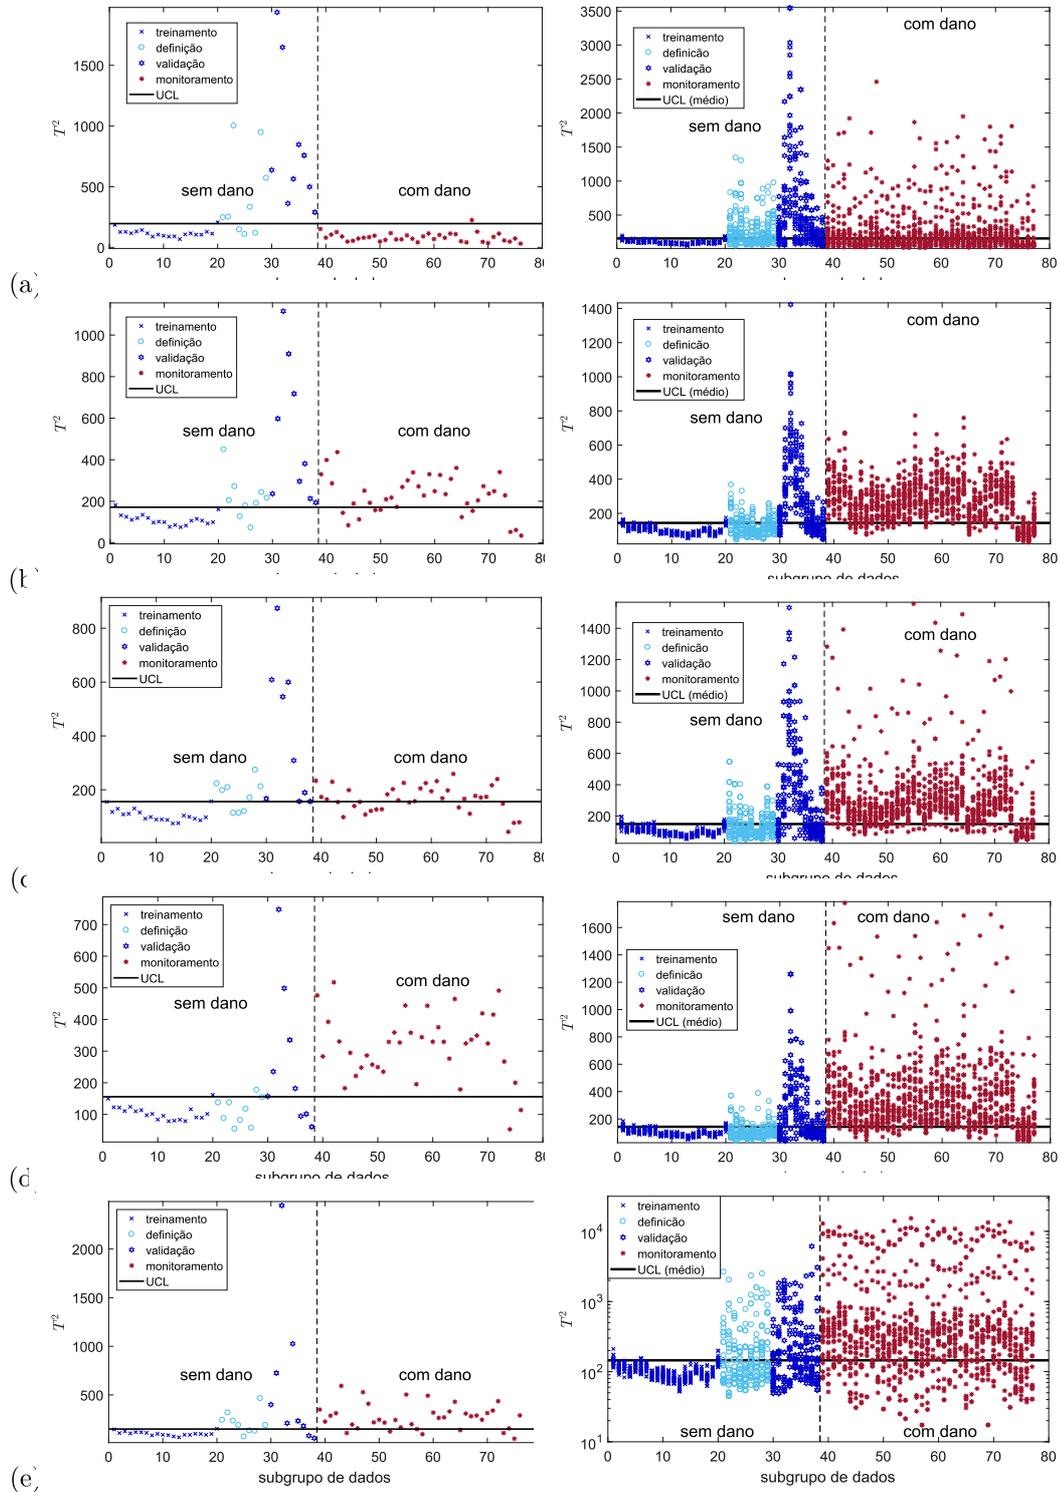


Figura 87 – Caso #2 - Acelerômetro 1. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

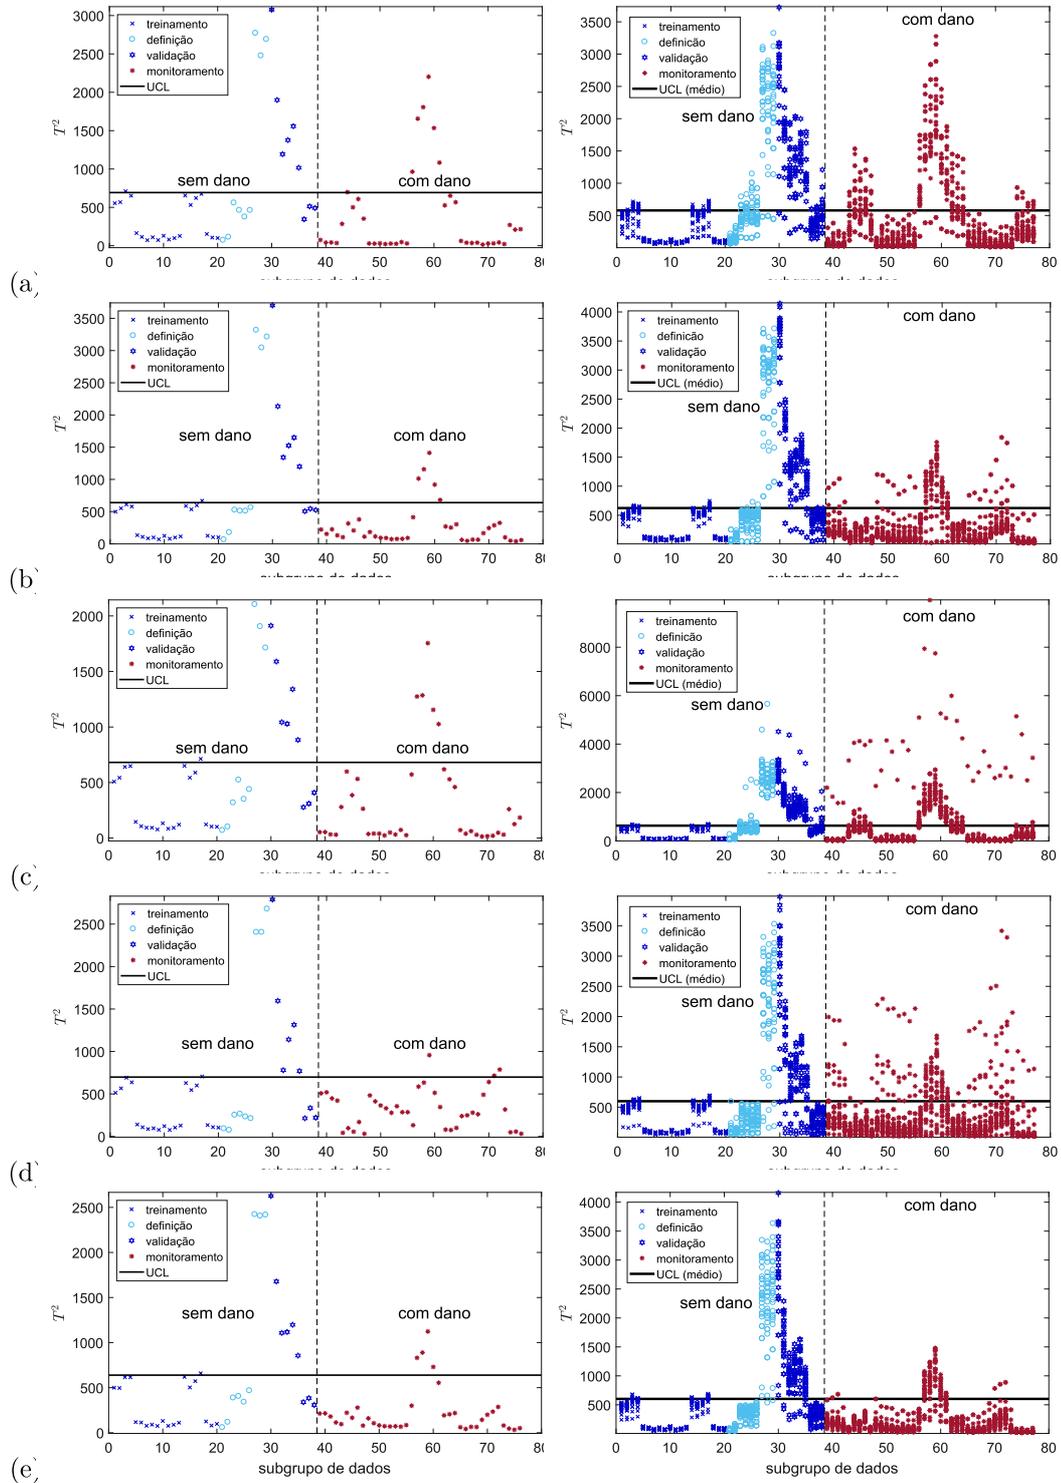


Figura 88 – Caso #2 - Acelerômetro 2. Cartas de controle para 1 e 30 modelos  $SAE/T^2$ , respectivamente.

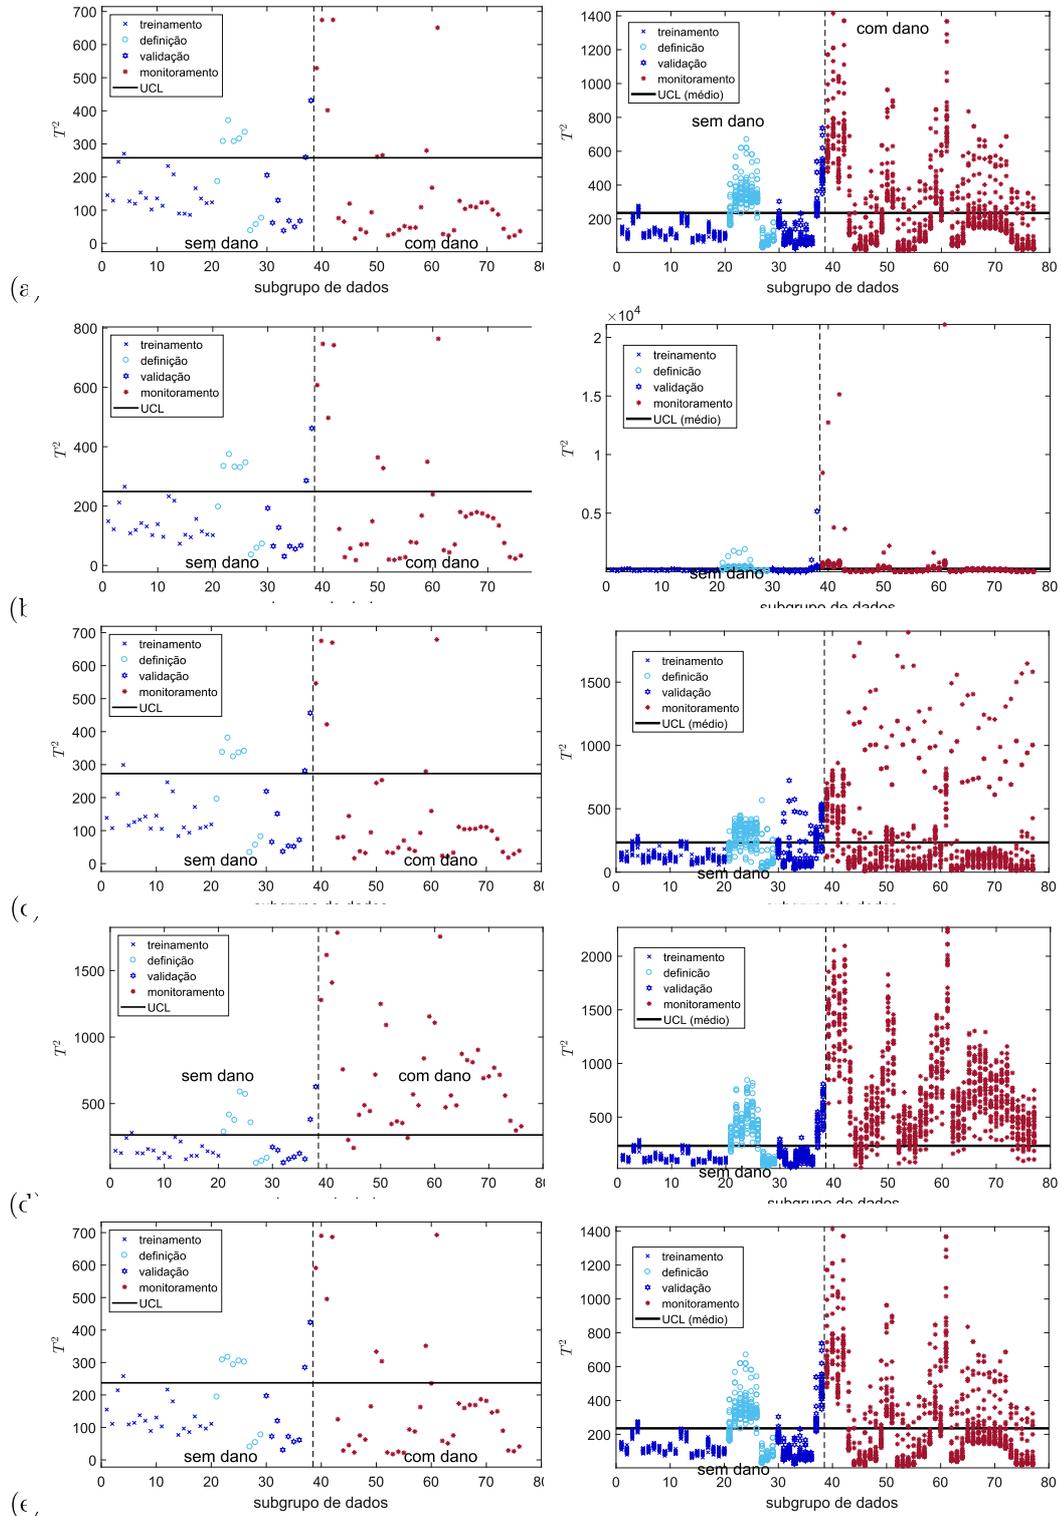


Figura 89 – Caso #2 - Acelerômetro 3. Cartas de controle para um e 30 modelos  $SAE/T^2$ , respectivamente.

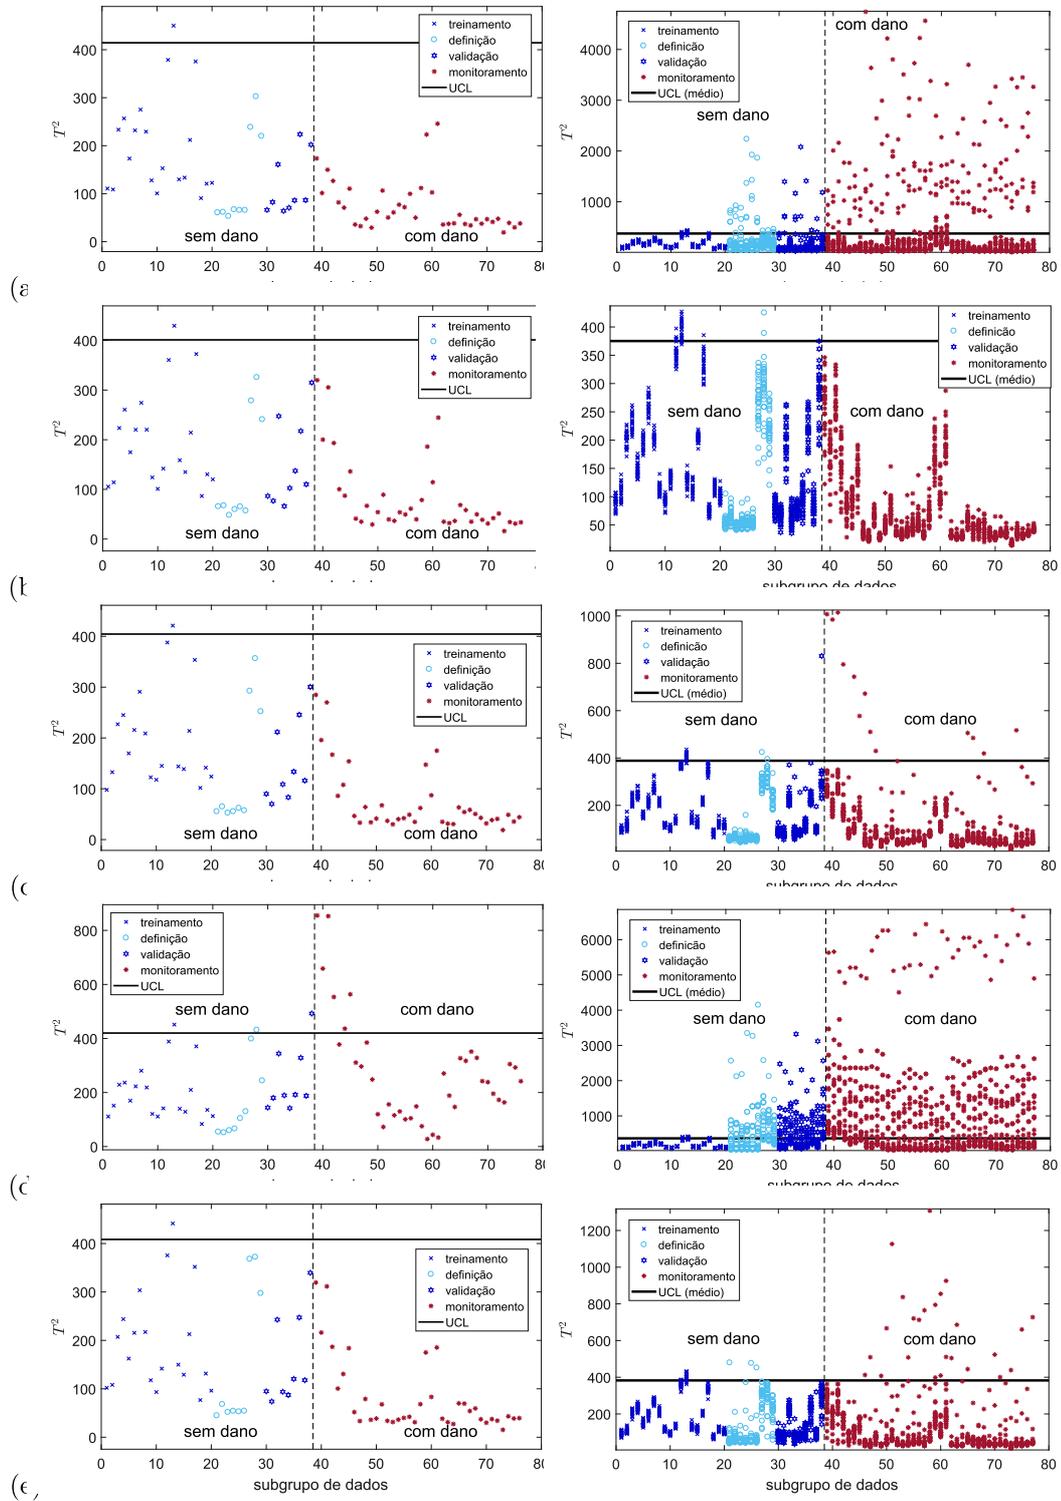


Figura 90 – Caso #2 - Acelerômetro 4. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.

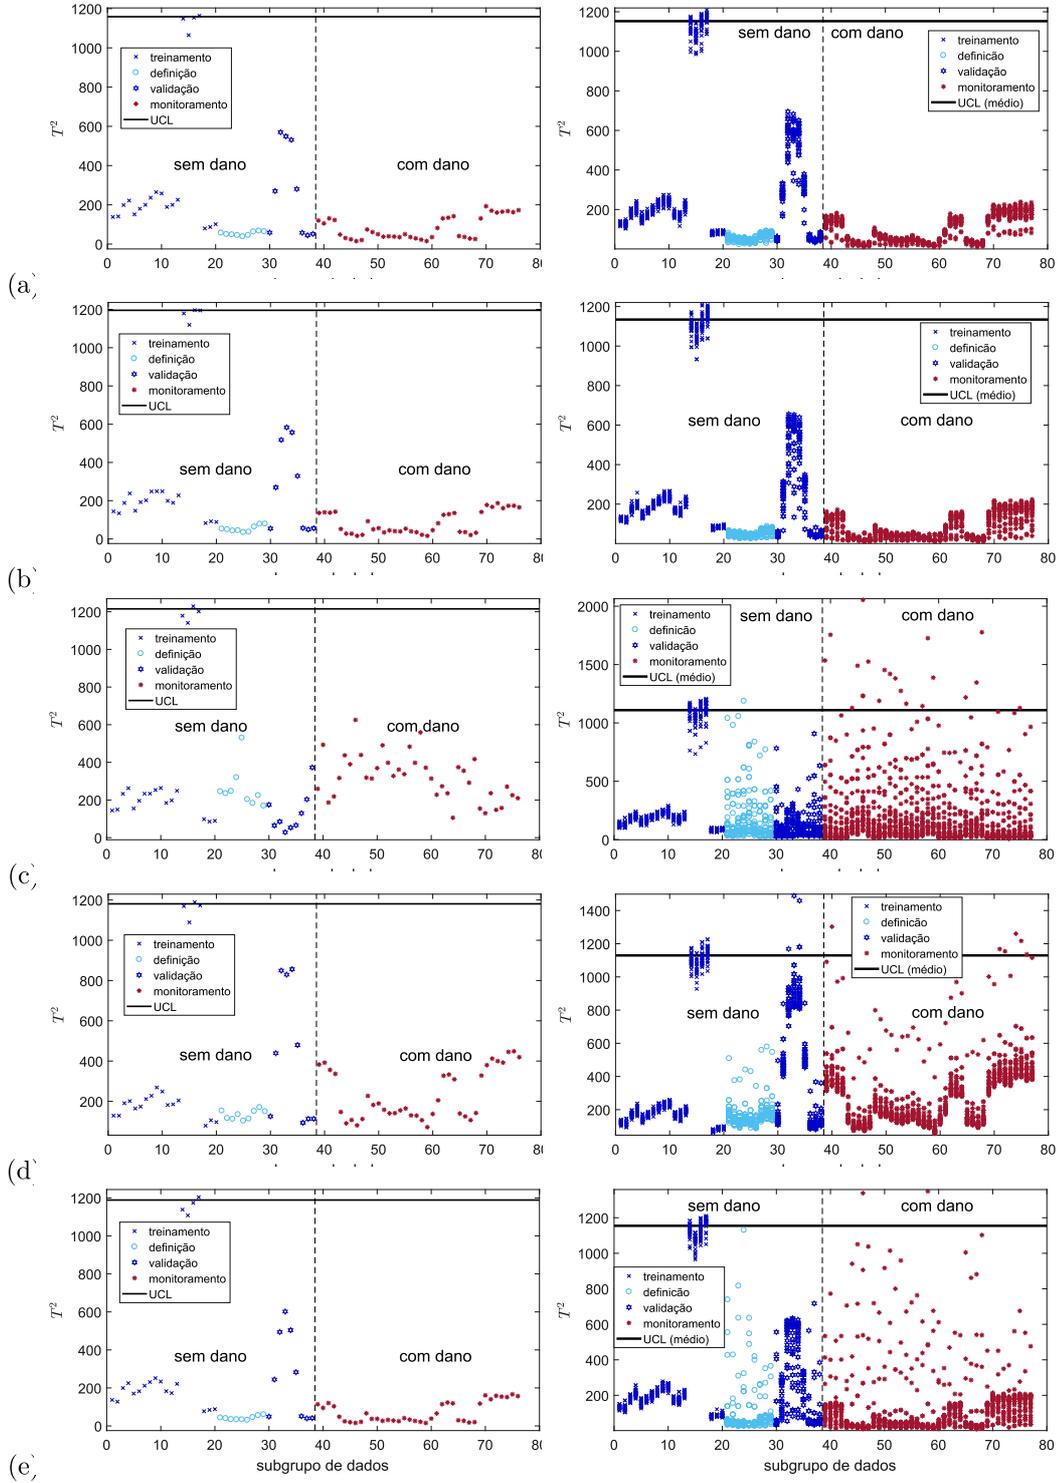
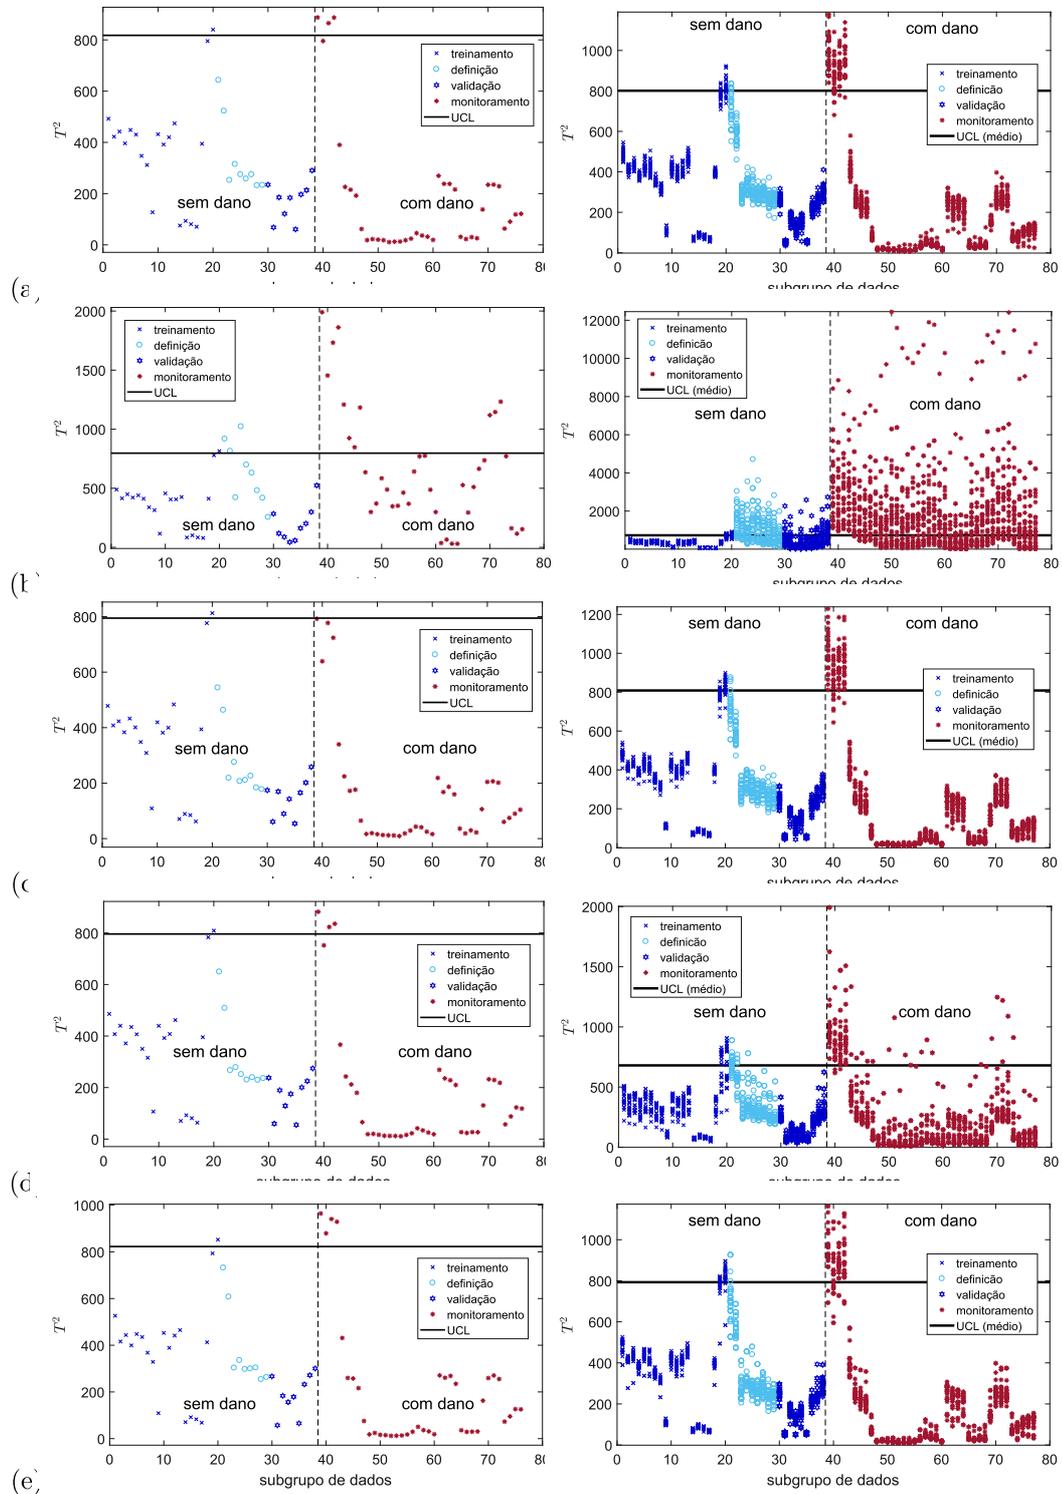


Figura 91 – Caso #2 - Acelerômetro 5. Cartas de controle para um e 30 modelos SAE/ $T^2$ , respectivamente.



ANEXO C – Metodologia não-supervisionada de detecção de dano SAE/ $T^2$ :  
 Resultados complementares da ponte Z24 - Erros de reconstrução dos sinais  
 e hiperparâmetros associados às cartas de controle dos anexos A e B.

Tabela 20 – Caso #1 - Acelerômetro 1.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
Mod 1	IG e $\zeta^{def}$	0,4	0,01	4,0	0,0502	0,0645	0,0705	64,95
	Menor $\zeta^{def}$	0,4	0,01	1,0	0,0467	0,0621	0,0686	118,31
Mod 2	IG e $\zeta^{def}$	0,4	0,0001	4,0	0,0497	0,0650	0,0713	68,87
	Menor $\zeta^{def}$	0,4	0,001	0,5	0,0470	0,0623	0,0690	161,11
Mod 3	IG e $\zeta^{def}$	0,8	0,01	4,0	0,0505	0,0652	0,0711	73,71
	Menor $\zeta^{def}$	0,8	0,001	0,5	0,0471	0,0629	0,0693	107,33
Mod 4	IG e $\zeta^{def}$	0,4	0,0001	2,0	0,0510	0,0653	0,0712	76,59
	Menor $\zeta^{def}$	0,8	0,0001	4,0	0,0473	0,0638	0,0704	91,04
Mod 5	IG e $\zeta^{def}$	0,4	0,01	0,5	0,0498	0,0641	0,0702	78,77
	Menor $\zeta^{def}$	0,2	0,0001	4,0	0,0476	0,0646	0,0715	546,64

Tabela 21 – Caso #1 - Acelerômetro 2.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
Mod 1	IG e $\zeta^{def}$	0,4	0,0001	8	0,0537	0,0630	0,0727	67,02
	Menor $\zeta^{def}$	0,8	0,001	1	0,0500	0,0611	0,0713	159,11
Mod 2	IG e $\zeta^{def}$	0,8	0,001	0,5	0,0518	0,0622	0,0721	76,25
	Menor $\zeta^{def}$	0,8	0,001	4	0,0500	0,0612	0,0714	145,84
Mod 3	IG e $\zeta^{def}$	0,2	0,01	8	0,0539	0,0633	0,0729	79,28
	Menor $\zeta^{def}$	0,4	0,01	4	0,0502	0,0610	0,0708	188,78
Mod 4	IG e $\zeta^{def}$	0,8	0,01	8	0,0553	0,0640	0,0733	62,95
	Menor $\zeta^{def}$	0,4	0,001	0,5	0,0511	0,0615	0,0714	170,60
Mod 5	IG e $\zeta^{def}$	0,8	0,0001	0,5	0,0544	0,0640	0,0736	85,61
	Menor $\zeta^{def}$	0,4	0,01	2	0,0512	0,0614	0,0713	159,66

Tabela 22 – Caso #1 - Acelerômetro 3.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
Mod 1	IG e $\zeta^{def}$	0,8	0,0001	2	0,0507	0,0689	0,0745	50,09
	Menor $\zeta^{def}$	0,4	0,01	1	0,0492	0,0659	0,0714	175,59
Mod 2	IG e $\zeta^{def}$	0,2	0,001	8	0,0521	0,0691	0,0746	64,86
	Menor $\zeta^{def}$	0,4	0,001	2	0,0499	0,0662	0,0718	178,95
Mod 3	IG e $\zeta^{def}$	0,4	0,01	8	0,0503	0,0666	0,0722	69,31
	Menor $\zeta^{def}$	0,4	0,01	8	0,0503	0,0666	0,0722	69,31
Mod 4	IG e $\zeta^{def}$	0,2	0,001	1	0,0535	0,0694	0,0750	71,74
	Menor $\zeta^{def}$	0,8	0,0001	4	0,0503	0,0676	0,0731	174,35
Mod 5	IG e $\zeta^{def}$	0,8	0,01	4	0,0509	0,0677	0,0730	83,23
	Menor $\zeta^{def}$	0,4	0,001	0,5	0,0504	0,0668	0,0724	168,59

Tabela 23 – Caso #1 - Acelerômetro 4.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
Mod 1	IG e $\zeta^{def}$	0,8	0,01	0,5	0,0509	0,0649	0,0710	44,45
	Menor $\zeta^{def}$	0,2	0,01	8	0,0440	0,0610	0,0681	201,68
Mod 2	IG e $\zeta^{def}$	0,8	0,01	4	0,0507	0,0650	0,0712	46,82
	Menor $\zeta^{def}$	0,4	0,0001	0,5	0,0470	0,0614	0,0683	95,47
Mod 3	IG e $\zeta^{def}$	0,4	0,01	8	0,0501	0,0635	0,0699	49,14
	Menor $\zeta^{def}$	0,8	0,001	8	0,0474	0,0628	0,0697	154,51
Mod 4	IG e $\zeta^{def}$	0,2	0,01	4	0,0512	0,0654	0,0719	51,70
	Menor $\zeta^{def}$	0,2	0,001	8	0,0476	0,0632	0,0698	90,17
Mod 5	IG e $\zeta^{def}$	0,4	0,01	2	0,0498	0,0631	0,0697	59,55
	Menor $\zeta^{def}$	0,4	0,001	2	0,0479	0,0627	0,0694	119,41

Tabela 24 – Caso #1 - Acelerômetro 5.

	Critério	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	IG
Mod 1	IG e $\zeta^{def}$	0,4	0,0001	1	0,0414	0,0503	0,0585	32,46
	Menor $\zeta^{def}$	0,4	0,001	1	0,0380	0,0475	0,0563	710,73
Mod 2	IG e $\zeta^{def}$	0,8	0,01	2	0,0424	0,0520	0,0605	21,41
	Menor $\zeta^{def}$	0,8	0,001	2	0,0392	0,0493	0,0582	296,15
Mod 3	IG e $\zeta^{def}$	0,8	0,0001	4	0,0403	0,0502	0,0590	39,68
	Menor $\zeta^{def}$	0,8	0,001	1	0,0395	0,0495	0,0583	224,99
Mod 4	IG e $\zeta^{def}$	0,8	0,0001	0,5	0,0414	0,0508	0,0595	39,78
	Menor $\zeta^{def}$	0,8	0,0001	1	0,0397	0,0497	0,0585	48,90
Mod 5	IG e $\zeta^{def}$	0,4	0,001	8	0,0427	0,0510	0,0594	43,17
	Menor $\zeta^{def}$	0,4	0,0001	8	0,0401	0,0491	0,0575	280,53

Tabela 25 – Caso #2 - Acelerômetro 1.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	<b>IG</b>
<b>Mod 1</b>	<b>IG e <math>\zeta^{def}</math></b>	0,1	0,01	2	0,0522	0,0679	0,0679	286,35
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	4	0,0424	0,0593	0,0597	2467,10
<b>Mod 2</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,0001	1	0,0470	0,0660	0,0662	374,23
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,001	4	0,0428	0,0598	0,0601	3252,00
<b>Mod 3</b>	<b>IG e <math>\zeta^{def}</math></b>	0,1	0,01	4	0,0544	0,0692	0,0690	251,60
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	1	0,0432	0,0602	0,0606	1672,60
<b>Mod 4</b>	<b>IG e <math>\zeta^{def}</math></b>	0,1	0,01	8	0,0519	0,0680	0,0681	440,19
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,0001	2	0,0435	0,0614	0,0616	2022,80
<b>Mod 5</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,01	2	0,0515	0,0655	0,0659	509,49
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,0001	0,5	0,0437	0,0607	0,0608	2352,90

Tabela 26 – Caso #2 - Acelerômetro 2.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	<b>IG</b>
<b>Mod 1</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,0001	4	0,0510	0,0830	0,0801	60,54
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,0001	0,5	0,0460	0,0661	0,0646	381,56
<b>Mod 2</b>	<b>IG e <math>\zeta^{def}</math></b>	0,1	0,01	2	0,0544	0,0740	0,0718	109,17
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	1	0,0460	0,0651	0,0637	426,91
<b>Mod 3</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,0001	8	0,0554	0,0919	0,0882	173,43
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,001	8	0,0461	0,0660	0,0645	413,70
<b>Mod 4</b>	<b>IG e <math>\zeta^{def}</math></b>	0,1	0,01	1	0,0594	0,0749	0,0737	76,00
	<b>Menor <math>\zeta^{def}</math></b>	0,2	0,0001	0,5	0,0469	0,0671	0,0661	535,02
<b>Mod 5</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,01	8	0,0518	0,0701	0,0684	224,35
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	8	0,0472	0,0658	0,0643	368,66

Tabela 27 – Caso #2 - Acelerômetro 3.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	<b>IG</b>
<b>Mod 1</b>	<b>IG e <math>\zeta^{def}</math></b>	0,4	0,0001	8	0,0509	0,0692	0,0686	104,33
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	4	0,0494	0,0682	0,0677	178,02
<b>Mod 2</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,001	8	0,0521	0,0728	0,0730	112,07
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	0,5	0,0498	0,0680	0,0674	172,58
<b>Mod 3</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,01	8	0,0551	0,0718	0,0717	71,61
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,01	0,5	0,0504	0,0681	0,0679	194,52
<b>Mod 4</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,01	4	0,0553	0,0715	0,0715	115,79
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,001	8	0,0504	0,0700	0,0697	172,42
<b>Mod 5</b>	<b>IG e <math>\zeta^{def}</math></b>	0,4	0,0001	1	0,0532	0,0701	0,0695	138,64
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	1	0,0509	0,0686	0,0681	246,48

Tabela 28 – Caso #2 - Acelerômetro 4.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	<b>IG</b>
<b>Mod 1</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,001	2	0,0464	0,0591	0,0633	50,22
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	0,5	0,0460	0,0523	0,0568	448,37
<b>Mod 2</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,0001	1	0,0499	0,0589	0,0633	58,57
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	1	0,0462	0,0524	0,0571	437,67
<b>Mod 3</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,0001	0,5	0,0501	0,0595	0,0640	90,58
	<b>Menor <math>\zeta^{def}</math></b>	0,2	0,001	2	0,0464	0,0591	0,0633	50,22
<b>Mod 4</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,0001	1	0,0489	0,0541	0,0591	110,83
	<b>Menor <math>\zeta^{def}</math></b>	0,8	0,0001	0,5	0,0469	0,0529	0,0579	201,53
<b>Mod 5</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,0001	8	0,0504	0,0545	0,0594	45,47
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	4	0,0472	0,0531	0,0577	479,86

Tabela 29 – Caso #2 - Acelerômetro 5.

	<b>Critério</b>	$\rho$	$\lambda$	$\beta$	$\zeta^{tr}$	$\zeta^{def}$	$\zeta^{val}$	<b>IG</b>
<b>Mod 1</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,01	1	0,0396	0,0429	0,0472	133,74
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	0,5	0,0364	0,0412	0,0447	240,58
<b>Mod 2</b>	<b>IG e <math>\zeta^{def}</math></b>	0,2	0,01	1	0,0425	0,0450	0,0496	170,22
	<b>Menor <math>\zeta^{def}</math></b>	0,2	0,001	8	0,0372	0,0441	0,0483	819,90
<b>Mod 3</b>	<b>IG e <math>\zeta^{def}</math></b>	0,8	0,01	4	0,0426	0,0445	0,0489	188,57
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,0001	1	0,0375	0,0421	0,0457	291,97
<b>Mod 4</b>	<b>IG e <math>\zeta^{def}</math></b>	0,4	0,01	1	0,0405	0,0431	0,0470	203,88
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	8	0,0376	0,0418	0,0454	276,85
<b>Mod 5</b>	<b>IG e <math>\zeta^{def}</math></b>	0,4	0,0001	2	0,0413	0,0438	0,0477	208,26
	<b>Menor <math>\zeta^{def}</math></b>	0,4	0,001	1	0,0378	0,0418	0,0455	227,61