

Universidade Federal de Juiz de Fora
Faculdade de Engenharia
Programa de Pós-Graduação em Engenharia Civil

KARIN KAUSS

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL UTILIZANDO MODELOS
AUTORREGRESSIVOS**

Juiz de Fora

2022

KARIN KAUSS

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL UTILIZANDO MODELOS
AUTORREGRESSIVOS**

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

Orientador: Prof. Dr. Alexandre Abrahão Cury

Coorientador: Prof. Dr. Flávio de Souza Barbosa

Juiz de Fora

2022

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

Kauss, Karin.

MONITORAMENTO DA INTEGRIDADE ESTRUTURAL
UTILIZANDO MODELOS AUTORREGRESSIVOS / Karin Kauss. --
2022.

113 p. : il.

Orientador: Alexandre Abrahão Cury

Coorientador: Flávio de Souza Barbosa

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Civil, 2022.

1. Monitoramento da Integridade Estrutural. 2. Modelos autorregressivos. 3. Distância de Mahalanobis. 4. AR e ARMA. 5. ARX e ARMAX. I. Cury, Alexandre Abrahão, orient. II. Barbosa, Flávio de Souza, coorient. III. Título.

Karin Kauss**Título: Monitoramento da integridade estrutural utilizando modelos autorregressivos**

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

Aprovada em 1 de agosto de 2022.

BANCA EXAMINADORA

Prof. Dr. Alexandre Abrahão Cury - Orientador e Presidente da banca
Universidade Federal de Juiz de Fora

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

Prof.^a Dr.^a Patrícia Habib Hallak
Universidade Federal de Juiz de Fora

Prof. Dr. Marcelo Miranda Barros
Universidade Federal de Juiz de Fora

Prof. Dr. Claudio José Martins
Centro Federal de Educação Tecnológica de Minas Gerais

Juiz de Fora, 19/07/2022.



Documento assinado eletronicamente por **Alexandre Abrahao Cury, Professor(a)**, em 01/08/2022, às 16:41, 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 **Patricia Habib Hallak, Professor(a)**, em 01/08/2022, às 16:43, 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 01/08/2022, às 16:45, 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 **Marcelo Miranda Barros, Professor(a)**, em 01/08/2022, às 16:45, 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 **Cláudio José Martins, Usuário Externo**, em 08/08/2022, às 09:25, 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) através do ícone Conferência de Documentos, informando o código verificador **0875774** e o código CRC **E06061CE**.

RESUMO

A população mundial está em constante crescimento e a evolução da sociedade e do estilo de vida cotidiano demandam construções de infraestruturas de grande porte que atendam às suas necessidades, tais como: pontes, viadutos, edifícios altos, entre outros. Estratégias baseadas no Monitoramento da Integridade Estrutural (do inglês, *Structural Health Monitoring - SHM*) possibilitam identificar danos presentes nas estruturas, além dos seus respectivos locais e intensidades, a partir de suas respostas dinâmicas. Assim, o SHM pode ser considerado uma ferramenta essencial para evitar possíveis falhas estruturais e aumentar a vida útil das estruturas. Neste trabalho, quatro modelos autorregressivos baseados em séries temporais - AR, ARMA, ARX e ARMAX - são utilizados para o processamento de sinais dinâmicos, extraíndo deles parâmetros sensíveis ao dano estrutural em cenários danificados e não danificados das estruturas analisadas. Os níveis de dano são calculados a partir de um indicador, cujo valor é obtido através da Distância de Mahalanobis. Esses modelos foram aplicados a dados de quatro estruturas, sendo duas estruturas ensaiadas em laboratório: um pórtico de três andares, de pequeno porte, e um pórtico de quatro andares, de médio porte, além de duas estruturas reais de grande porte, atualmente em uso: um viaduto de 17,5 m de extensão e uma ponte com vão principal de 260 m. A partir da análise dos resultados, nota-se a relativa eficiência dos quatro modelos autorregressivos para detectar danos estruturais. Destaca-se a capacidade do modelo AR em alcançar bons resultados, registrando um tempo relativamente curto de execução dos códigos. Recomenda-se o uso do modelo AR de ordens menores, caso não tenha excitações dinâmicas registradas e disponíveis; e/ou o uso do modelo ARX, quando houver excitações dinâmicas registradas.

Palavras-chave: Monitoramento da Integridade Estrutural, Modelos autorregressivos, Distância de Mahalanobis.

ABSTRACT

The World population is constantly increasing, the evolution of society as well as the daily lifestyle require the construction of large infrastructures that meet their needs, such as: bridges, viaducts, skyscrapers, among others. Strategies based on Structural Health Monitoring (SHM) make it possible to identify damage present in structures, in addition to their respective locations and intensities, through their dynamic responses. Thus, the SHM becomes an essential tool to avoid possible structural failures and increase the useful life of structures. In this work, four autoregressive models based on time series - AR, ARMA, ARX and ARMAX - are used for the processing of dynamic signals, extracting from them parameters sensitive to structural damage in damaged and undamaged scenarios of the analysed structures. Damage levels are calculated from an indicator, whose value is obtained through the Mahalanobis Distance. These models were applied to two structures tested in laboratory: a small-sized three-floor frame and a medium-sized four-floor frame; As well as two large real-world structures, which are completed and currently in use: a 17.5 m long viaduct and a bridge with a main span of 260 m. From the analysis of results, there is a relative efficiency of the four autorregressive models in detecting structural damage. It is important to highlight the AR model ability to achieve good results, registering a relatively short code execution time. The AR model is recommended in smaller orders, if there are no dinamic excitations registered and available; and/or the usage of the ARX model, whenever dinamic excitations are registered.

Keywords: Structural Health Monitoring, Autoregressive Models, Mahalanobis Distance

LISTA DE ILUSTRAÇÕES

Figura 1	– O colapso da Ponte Morandi na Itália	14
Figura 2	– Esquema do sistema SHM	15
Figura 3	– O modelo geral para a identificação paramétrica	22
Figura 4	– Esquema do modelo ARX	24
Figura 5	– Esquema do modelo ARMAX	25
Figura 6	– Fluxograma de implementação dos códigos.....	26
Figura 7	– Saída gráfica de um exemplo modelo	30
Figura 8	– Exemplo geral das imagens resultantes das simulações do experimento 3SS.....	31
Figura 9	– Foto da estrutura ensaiada. (a) Estrutura de três andares com a Base; (b) Detalhe mostra a fixação da cluna central e o para-choque.....	34
Figura 10	– Exemplo amostral de um sinal capturado pelo sensor.....	35
Figura 11	– Esquema da estrutura ensaiada mostrando os Channels, Shaker, Load cell, Baseplate e Bumper	38
Figura 12	– Esquema e detalhes da montagem da estrutura ensaiada. (a) detalhe da massa adicionada; (b) detalhe sobre a coluna central e o Para-choque	38
Figura 13	– Exemplo geral das imagens resultantes das simulações do experimento 3SS.....	40
Figura 14	– Foto da estrutura ensaiada. (a) Estrutura de três andares com a Base; (b) Detalhe mostra a fixação da coluna central e o Para-choque	45
Figura 15	– Esquema da estrutura ensaiada. (a) vista plana; (b) vista leste	46
Figura 16	– Detalhes de montagem. (a) a distribuição das lajes nos vãos; (b) a fixação da laje de concreto; (c) detalhe de conexão entre duas vigas e uma coluna..	46
Figura 17	– Detalhe de fixação a estrutura na grelha estrutural embutida na laje-base de concreto	47
Figura 18	– Exemplo amostral de um sinal capturado pelo sensor – <i>YF</i>	48
Figura 19	– ilustração dos cenários de dano do experimento <i>YF</i> ; os elementos de cor vermelhas.....	50
Figura 20	– Exemplo geral das imagens resultantes das simulações do experimento <i>YF</i>	52
Figura 21	– Vista geral do Viaduto <i>PK 075+317</i>	60
Figura 22	– Detalhe do procedimento de reforço e dos mancais.....	61
Figura 23	– Posição dos sensores sob o pavimento.....	61
Figura 24	– Exemplo amostral de um sinal capturado pelo sensor.....	62
Figura 25	– Exemplo geral das imagens resultantes das simulações do experimento do Viaduto <i>PK 075+317</i>	63
Figura 26	– Vista geral do <i>TYB</i>	67
Figura 27	– Vista geral do <i>TYB</i>	68
Figura 28	– Esquema da Ponte <i>TYB</i>	68
Figura 29	– Seção transversal do tabuleiro da Ponte <i>TYB</i>	69
Figura 30	– O dano estrutural encontrado no vão principal. (a) aberturas severas no face inferior da viga. (b) Fratura da barra de aço embutida no concreto.....	69

Figura 31	– Danos apresentados em cabos estiadados, mostrando corrosão nos fios de aço após abrir uma janela de inspeção.....	70
Figura 32	– Dano estrutural detectado depois de instalar o SHM. (a) localização da ocorrência do dano. (b) detalhe do dano, rachaduras avançadas.....	70
Figura 33	– Dano estrutural detectado depois de instalar o SHM. (a) localização da ocorrência do dano, marcado com ponto azul. (b) detalhe do dano, deslocamento do pilar.....	71
Figura 34	– Esquema de distribuição dos sensores. (a) ao longo do tabuleiro. (b) ao longo da seção transversal.....	72
Figura 35	– Exemplo amostral de um sinal capturado por dois sensores. O 1° na extremidade e o 8° no meio do vão.....	72
Figura 36	– Exemplo geral das imagens resultantes das simulações do experimento do TYB.....	75

LISTA DE TABELAS

Tabela 1	– Exemplos de acidentes trágicos e suas causas.....	14
Tabela 2	– Simulações realizadas dos modelos ARX e ARMA.....	27
Tabela 3	– Simulações realizadas do modelo ARMAX.....	28
Tabela 4	– Resultado da classificação de todos os sensores de exemplo modelo.....	31
Tabela 5	– Resultado da classificação de exemplo modelo.....	3
Tabela 6	– Resultado da classificação de todos os sensores de exemplo modelo.....	32
Tabela 7	– Resultado da classificação de todos os sensores de exemplo modelo.....	32
Tabela 8	– Resultado da classificação de exemplo modelo e do tempo gasto.....	33
Tabela 9	– Cenários de dano do experimento 3SS com as descrições devidas.....	37
Tabela 10	– Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada – Pórtico 3SS.....	40
Tabela 11	– Resultado da classificação de todos os sensores do modelo AR – Pórtico 3SS.....	40
Tabela 12	– Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada – Pórtico 3SS.....	41
Tabela 13	– Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada – Pórtico 3SS.....	41
Tabela 14	– Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada – Pórtico 3SS.....	42
Tabela 15	– Resultado da classificação de todos os sensores do modelo ARX – Pórtico 3SS.....	43
Tabela 16	– Resultado da classificação de todos os sensores do modelo ARX – Pórtico 3SS.....	43
Tabela 17	– Resultado da classificação de todos os sensores do modelo ARMAX – Pórtico 3SS.....	44
Tabela 18	– Cenários de dano do experimento YF com as descrições devidas.....	49
Tabela 19	– Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada – Pórtico YF.....	52
Tabela 20	– Resultado da classificação de todos os sensores do modelo AR – Pórtico YF.....	53
Tabela 21	– Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada – Pórtico YF.....	54
Tabela 22	– Resultado da classificação de todos os sensores do modelo ARMA – Pórtico YF.....	55
Tabela 23	– Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada – Pórtico YF.....	56
Tabela 24	– Resultado da classificação de todos os sensores do modelo ARX – Pórtico YF.....	57
Tabela 25	– Resultado da classificação do modelo ARMAX e do tempo gasto de cada ordem simulada – Pórtico YF.....	58

Tabela 26	– Resultado da classificação de todos os sensores do modelo ARMAX – Pórtico <i>YF</i>	59
Tabela 27	– Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada – Viaduto <i>PK 075+317</i>	64
Tabela 28	– Resultado da classificação de todos os sensores do modelo AR – Viaduto <i>PK 075+317</i>	64
Tabela 29	– Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada – Viaduto <i>PK 075+317</i>	65
Tabela 30	– Resultado da classificação de todos os sensores do modelo AR – Viaduto <i>PK 075+317</i>	66
Tabela 31	– Resultado da classificação do modelo AR, com 20 Samples, e do tempo gasto de cada ordem simulada – <i>TYB</i>	76
Tabela 32	– Resultado da classificação do modelo AR, com 30 Samples, e do tempo gasto de cada ordem simulada – <i>TYB</i>	76
Tabela 33	– Resultado da classificação de todos os sensores do modelo AR com 20 Samples – <i>TYB</i>	76
Tabela 34	– Resultado da classificação do modelo ARMA, com 20 Samples, e do tempo gasto de cada ordem simulada – <i>TYB</i>	77
Tabela 35	– Resultado da classificação do modelo ARMA, com 30 Samples, e do tempo gasto de cada ordem simulada – <i>TYB</i>	78
Tabela 36	– Resultado da classificação de todos os sensores do modelo ARMA com 20 Samples – <i>TYB</i>	78

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVO GERAL	16
1.1.1	Objetivos específicos	16
1.2	JUSTIFICATIVA	16
2	REVISÃO TEÓRICA	17
2.1	MODELOS AUTORREGRESSIVOS	21
2.1.1	Modelo AR	22
2.1.2	Modelo ARMA	23
2.1.3	Modelo ARX	23
2.1.4	Modelo ARMAX	24
3	METODOLOGIA	26
4	APLICAÇÕES	34
4.1	PÓRTICO 3SS	34
4.1.1	O sistema estrutural	34
4.1.2	Sistema de aquisição dos dados	35
4.1.3	Cenários de dano	36
4.1.4	Implementação no MATLAB	39
4.1.5	Resultados	39
4.1.5.1	<i>Modelo AR - 3SS</i>	40
4.1.5.2	<i>Modelo ARMA - 3SS</i>	41
4.1.5.3	<i>Modelo ARX - 3SS</i>	42
4.1.5.4	<i>Modelo ARMAX - 3SS</i>	43
4.2	PÓRTICO <i>YELLOW FRAME</i>	45
4.2.1	O sistema estrutural	45
4.2.2	Sistema de aquisição dos dados	48
4.2.3	Cenários de dano	49
4.2.4	Implementação da metodologia	51
4.2.5	Resultados	51
4.2.5.1	<i>Modelo AR – excitação ambiental</i>	52
4.2.5.2	<i>Modelo ARMA – excitação ambiental</i>	54
4.2.5.3	<i>Modelo ARX – excitação ambiental</i>	56
4.2.5.4	<i>Modelo ARMAX – excitação ambiental</i>	58

4.3	VIADUTO FERROVIÁRIO PK 075+317 – TGV.....	60
4.3.1	O sistema estrutural.....	60
4.3.2	Sistema de aquisição dos dados.....	61
4.3.3	Cenários de dano.....	62
4.3.4	Implementação da metodologia.....	62
4.3.5	Resultados.....	63
4.3.5.1	<i>Modelo AR – TGV.....</i>	64
4.3.5.2	<i>Modelo ARMA – TGV.....</i>	65
4.4	TIANJIN YONGHE BRIDGE- TYB.....	67
4.4.1	O sistema estrutural.....	68
4.4.2	Sistema de aquisição dos dados.....	71
4.4.3	Cenários de dano.....	73
4.4.4	Implementação da metodologia.....	73
4.4.5	Resultados.....	74
4.4.5.1	<i>Modelo AR – TYB.....</i>	75
4.4.5.2	<i>Modelo ARMA – TYB.....</i>	77
5	CONSIDERAÇÕES FINAIS	80
5.1	TRABALHOS FUTUROS.....	82
	REFERÊNCIAS.....	83
	Apêndice A – Resultados da classificação - Pórtico 3SS.....	89
	Apêndice B – Resultados da classificação- Pórtico YF.....	94
	Apêndice C – Resultados da classificação - Viaduto Ferroviário PK	
	075+317 – TGV.....	103
	Apêndices D – Resultados da classificação – TYB.....	106

1 INTRODUÇÃO

A população mundial está em constante crescimento e a evolução da sociedade e do estilo de vida cotidiano demandam construções de infraestruturas de grande porte que atendam às suas necessidades, tais como: pontes, viadutos, edifícios altos, entre outros. As estruturas de grande porte, de modo geral, sofrem constantes alterações física e química nas suas propriedades causadas por distintos agentes que se dividem em duas categorias, de acordo com a duração da ocorrência deles na estrutura (Cury e Cremona, 2010): (a) as alterações de longa duração, ou progressivas, atingem as estruturas ao longo do tempo de uso. Como exemplo, destacam-se: fadiga, corrosão, deformações excessivas, entre outras, ou até mesmo a falta de manutenção adequada e carregamentos não previstos no dimensionamento; (b) as alterações súbitas, que têm menos probabilidade de acontecer, porém, provocam danos maiores e inesperados, tais como: sismos, tempestades, acidentes envolvendo veículos, etc.

Muitas estruturas ao redor do mundo estão chegando ao final de suas vidas úteis e continuam sendo usadas, pois a simples substituição delas é economicamente inviável. Por isso, possuir uma técnica de monitoramento estrutural avançada pode-se tornar uma solução para acompanhar as condições das estruturas sob as alterações de suas propriedades, aliadas ao objetivo de se aumentar a sua vida útil.

O Monitoramento da Integridade Estrutural (do inglês- *Structural Health Monitoring*- SHM) é uma estratégia que visa identificar danos presentes na estrutura investigada, podendo, inclusive, avaliar o local e a intensidade do dano. Com essas informações, é possível determinar as ações adequadas a serem tomadas em relação ao dano detectado. Nos casos em que o dano é descoberto cedo, a recuperação estrutural pode ser aplicada de forma eficaz para manter a condição da estrutura e aumentar a sua vida útil, além de oferecer uma vantagem econômica de curto e longo prazos, estabelecendo-se calendários de manutenção periódicos e evitando reparos de alto custo. Em circunstâncias extremas, as estruturas precisam ser interditadas a fim de se evitar uma possível catástrofe envolvendo perdas humanas. Deste modo, verifica-se a importância de se ter um sistema de monitoramento com tecnologia avançada que indique com precisão e agilidade a ocorrência dos danos.

O SHM é um sistema que consiste na união de equipamentos (sensores) que capturam sinais e de técnicas que estudam e processam os dados coletados para obter repostas sobre o estado de dano. No início, os primeiros sistemas de SHM recebiam periodicamente as atualizações dos dados, os quais eram posteriormente analisados. Apesar de servir ao propósito destinado, muitas melhorias precisavam ser realizadas a fim de atingir um sistema de

monitoramento que funcionasse em tempo real e contínuo, relatando o estado de dano da estrutura, haja vista a imensa importância de se acompanhar a integridade das estruturas continuamente e, em especial, depois de sofrerem eventos inesperados. Avanços recentes nas técnicas SHM permitiram que o intervalo de tempo entre a obtenção dos dados e a geração de respostas fosse gradativamente diminuído ou até eliminado. Assim, os danos, na maioria das vezes, podem ser detectados a tempo de serem revertidos, além de prevenir futuras falhas, o que representa, também, uma vantagem econômica.

É válido ressaltar que os sistemas de monitoramento SHM não vieram para substituir os procedimentos de inspeções tradicionais, mas sim para complementá-los. Porém, em muitas situações o acesso do profissional avaliador ao local examinado é inviável e/ou perigoso, o que torna o serviço custoso e demorado e pode apresentar risco aos profissionais. Além disso, os resultados podem apresentar incertezas, já que dependem da referência visual, interpretação, experiência e julgamento do profissional qualificado. Em outras palavras, os resultados estão sujeitos ao erro humano. Esse processo não garante um monitoramento contínuo ou pelo menos periódico, haja vista os extensos intervalos entre as inspeções realizadas.

Neste trabalho, serão estudados os sistemas de SHM que buscam detectar danos na estrutura a partir de suas respostas dinâmicas. A lógica por trás disso é que as alterações nas propriedades dinâmicas detectadas das estruturas podem estar diretamente ligadas ao surgimento de danos na mesma. Com o avanço da tecnologia, o *SHM* busca aprimorar as estratégias que, além de detectar os danos, possam indicar a sua extensão e a sua magnitude. Uma das vantagens dos métodos baseados em vibrações é a possibilidade de se usar as vibrações ambientais como fonte de excitação.

Compreende-se como dano estrutural qualquer alteração no sistema estrutural que afete ou possa afetar futuramente o desempenho da estrutura como, por exemplo, fissuras nas estruturas de concreto armado e peças corroídas nas estruturas metálicas. Essas patologias visíveis podem causar desconforto e insegurança ao público, além de promover riscos à segurança da estrutura em situações de danos mais intensos. Por isso, o contínuo monitoramento da estrutura e a identificação de danos em um estágio inicial contribuem para a redução dos custos de manutenção e de reparo, além de aumentar a sua confiabilidade e a sua vida útil.

Do ponto de vista histórico, lamentavelmente, muitos acidentes ao redor do mundo foram causados por falhas que poderiam ter sido evitadas ou, pelo menos, minimizadas caso houvesse um sistema de monitoramento eficaz das estruturas.

Na Tabela 1 mostram-se alguns casos de acidentes e as causas que levaram a estrutura a falhar. Mais recentemente, pode-se citar o caso da Ponte Morandi, localizada em Gênova – Itália. Uma seção de 200 m de extensão colapsou junto com uma das três torres que a sustentavam, conforme mostrado na Figura 1. A tragédia ocorreu no dia 14 de agosto de 2018, causando 43 mortes e 600 pessoas sem-teto.

Tabela 1 – Exemplos de acidentes tragicos e suas causas

Estrutura	Localização	Ano	Causa
Ponte do rio Mianus	EUA	1983	Corrosão do metal + fadiga
Viaduto da rua Cypress	EUA	1989	Terremoto
Ponte Seongu	Coréia do Norte	1994	Falha estrutural: defeito na solda
Ponte Tarcoles	Costa Rica	2009	Sobrecarga devido a caminhões pesados
Myllysilta	Finlândia	2010	Inclinação devido à falha nos pilares
Ponte Gongguan	China	2011	Sobrecarga
Ponte Skjeggstad	Noruega	2015	Deslocamento de pilar
Viaduto Vivekananada	Índia	2016	Ligação seção e pilar
Viaduto no Eixão Sul	Brasil	2018	Deterioração da estrutura e falta de manutenção
Ponte Morandi	Itália	2018	Falta de manutenção, sobrecarga não prevista no projeto, erosão do solo e tempestade

Fonte: Adaptado de Alves *et al.* (2016).

Figura 1 – O colapso da Ponte Morandi Itália



Fonte: Zennaro (2019).

Geralmente, a correção e o aperfeiçoamento das técnicas adotadas sempre vêm depois da ocorrência do erro ou imperfeição. No caso da engenharia, os erros podem ser bastante trágicos e custosos. Essas imensas perdas motivam estudos em prol do monitoramento estrutural.

Atualmente, com o aprendizado dos erros do passado, muitas estruturas de grande porte estão usando sistemas de monitoramento contínuo para garantir a sanidade do sistema estrutural e prevenir desastres. Como exemplo disso, pode-se citar o Viaduto de Millau (CACHOT *et al.*, 2015) na França, a Ponte Tsing Ma na China (NI *et al.*, 2011), o arranha-céu Burj Khalifa em Dubai (KIJEWSKI-CORREA *et al.*, 2013), a Ponte Golden Gate nos Estados Unidos (XIA; XU, 2012), além de outras.

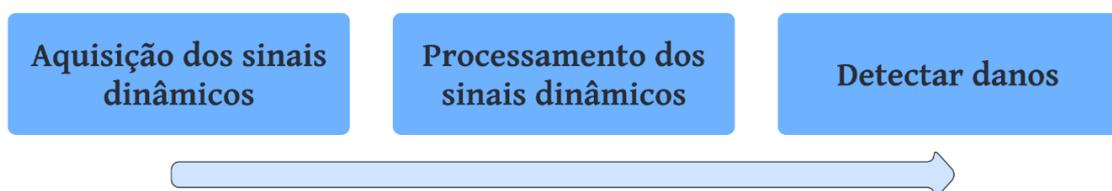
Por muito tempo, as estratégias de identificação dos danos foram classificadas de acordo com a escala de quatro níveis de Rytter (RYTTER, 1993). Recentemente, houve a adição de mais um nível na hierarquia proposta por Worden e Dulieu-Barton (2004). As técnicas de SHM podem ser classificadas de acordo com a habilidade delas em responder às questões dadas em cada nível:

- Nível 1: O dano está presente no sistema estrutural (detecção)?
- Nível 2: Onde o dano está localizado (localização)?
- Nível 3: Qual é o tipo de dano detectado (tipo)?
- Nível 4: Qual é a extensão do dano (severidade)?
- Nível 5: Qual é o tempo de vida útil restante da estrutura (predição)?

O presente trabalho foca no “nível 1” da escala Rytter; ou seja, na identificação de alterações estruturais em si e da intensidade do dano através do “índice de dano”. Entretanto, pretende-se, também, fornecer alguns indícios acerca da possível localização do dano (nível 2).

Na Figura 2, verifica-se o esquema que descreve os três estágios principais da implementação de um sistema SHM. Neste trabalho, modelos autorregressivos são utilizados na fase do processamento dos sinais coletados a fim de se obter os seus parâmetros; o processo de extração desses parâmetros é baseado no ajuste dos modelos autorregressivos às respostas dinâmicas no domínio do tempo, adquiridas pelos sensores, nos estados danificados e não danificados da estrutura; por fim, os indicadores de dano são construídos.

Figura 2 – Esquema do sistema SHM



Fonte: Elaborado pela autora (2022).

1.1 OBJETIVO GERAL

O objetivo geral do presente trabalho é abordar o Monitoramento da Integridade Estrutural (SHM) e, em especial, o uso de modelos autorregressivos para detectar danos e alterações nas características dinâmicas das estruturas, buscando assegurar um monitoramento contínuo eficaz das estruturas.

1.1.1 Objetivos específicos

- Avaliar a aplicação dos modelos autorregressivos do tipo AR (do inglês - *AutoRegressive*), ARMA (do inglês - *AutoRegressive Moving Average*), ARX (do inglês - *AutoRegressive with eXogenous inputs*) e ARMAX (do inglês - *AutoRegressive Moving Average with eXogenous inputs*) para detecção de dano em estruturas de pequeno, médio e grande portes;
- Avaliar a eficácia dos modelos e indicar qual deles apresenta melhor relação resultado/tempo de processamento.

1.2 JUSTIFICATIVA

O tema de “monitoramento estrutural” vem ganhando muita importância nas pesquisas científicas ao longo dos anos. Os pesquisadores ao redor do mundo estão em busca contínua de modos eficazes e ágeis para a detecção dos danos em estruturas, visando mitigar a ocorrência de acidentes catastróficos, causando perdas imensuráveis e que poderiam ser evitadas com um sistema funcional de monitoramento.

2 REVISÃO TEÓRICA

Os métodos que empregam as respostas das vibrações dinâmicas no processo de detecção de dano fundamentam-se no fato que o dano, ocorrido na estrutura, altera essencialmente a sua rigidez, o que acaba ocasionando alteração nas respostas dinâmicas da estrutura.

O prognóstico de danos é a estimativa da vida útil restante de um sistema danificado conforme citado no trabalho de FARRAR e SOHN (2000). Os danos afetam o desempenho atual e futuro da estrutura analisada (FARRAR e WORDEN, 2007). A capacidade de prognóstico de danos está diretamente relacionada à evolução das técnicas SHM mais simples, que apenas detectam ou localizam danos (FARRAR e LIEVEN, 2007; WORDEN et al., 2007). Essa estimativa depende da criação de modelos de previsão; a saída dos modelos juntamente com informações de monitoramento de uso tem o objetivo de prever o desempenho do sistema (FARRAR e LIEVEN, 2007). Chattopadhyay et al. (2013) evidenciam o esforço mútuo das diferentes áreas da engenharia, tais como: mecânica dos materiais, sensores e processamento, a fim de elaborar estratégias de prognóstico confiáveis.

Doebeling et al. (1998) realizaram uma extensa revisão dos métodos de detecção de danos baseados na análise de vibrações; isto é, métodos que não dependem de modelagem detalhada de elementos finitos. Em alguns casos, são necessários dados da estrutura analisada no seu estado não danificado (estrutura intacta), o que nem sempre é possível. Ainda que esses métodos sejam capazes de quantificar a severidade dos danos estruturais, alcançando o nível 4 da escala Rytter mencionada no item 1, tais métodos não são eficientes para detectar danos nas fases iniciais de seus surgimentos.

No entanto, para superar as desvantagens apresentadas, uma análise estatística de séries temporais pode ser aplicada aos métodos de detecção de danos; assim, alcança-se a possibilidade de desenvolver técnicas de SHM automatizadas (FARRAR e SOHN, 2000; SOHN et al., 2001; FUGATE et al., 2000; FASSOIS e SAKELLARIOU, 2007). Farrar e Sohn (2000) explicitaram um guia que visa explicar o esquema de detecção de danos com base no processamento de séries temporais, a saber:

1. Avaliação operacional.
2. Aquisição e tratamento de dados.
3. Seleção de recursos e compactação de dados.
4. Desenvolvimento de modelo estatístico.

O primeiro item trata da avaliação das características e limitações do sistema SHM, incluindo as condições operacionais e ambientais a que a estrutura estiver sujeita. O segundo

item está relacionado ao sistema de aquisição de dados, já que a seleção dos sensores e as suas localizações na estrutura interferem na qualidade da coleta dos sinais. O terceiro item refere-se à seleção de características do sinal que deve ser realizada com cuidado, uma vez que são sensíveis à variabilidade operacional e ambiental (SOHN, 2007). Por último, os modelos estatísticos podem ser aplicados às características do sinal extraído para avaliar a integridade da estrutura.

As séries temporais em questão podem ser usadas para estruturar os modelos autorregressivos (SOHN et al., 2000; LU; GAO, 2005; SILVA et al., 2011). Assim, ter-se-á várias vantagens em relação aos métodos tradicionais de detecção dos danos, já que os modelos autorregressivos não requerem transformação de domínio que, por sua vez, depende de importantes parâmetros de estimação e da faixa de frequência adotada (SOHN et al., 2001; FASSOIS; 20 SAKELLARIOU, 2007; SILVA et al., 2008; FIGUEIREDO et al., 2011).

Os modelos autorregressivos escolhidos para serem analisados nesse trabalho – modelos AR (*AutoRegressive*), ARMA (*AutoRegressive Moving Average*), ARX (*AutoRegressive with eXogenous inputs*) e ARMAX (*AutoRegressive Moving Average with eXogenous inputs*) – partem da análise de séries temporais. Existem vários trabalhos na literatura que utilizam um ou mais modelos autorregressivos estudados e utilizados na detecção e/ou localização de danos estruturais. Os trabalhos mencionados serão ordenados de acordo com os modelos autorregressivos empregados neles, AR, ARX, AR e ARX, ARMA e, por fim, ARMAX. Os trabalhos de cada grupo estão em ordem cronológica.

Verifica-se o uso do modelo AR nas aplicações de vários trabalhos acadêmicos que tratam das repostas dinâmicas das estruturas capturadas por acelerômetros (FIGUEIREDO et al., 2010; LAUTOUR & OMENZETTER, 2010; DATTEO et al., 2018; AZIM & GÜL, 2019) pelos seguintes motivos: (a) habilidade de extrair características sensíveis ao dano; (b) dependência somente das repostas dinâmicas coletadas das estruturas; (c) os parâmetros refletem as propriedades estruturais independente da fonte de excitação (ENTEZAMI & SHARIATMADAR, 2017); (d) implementação computacional relativamente simples.

Adamas e Farrar (2002) propuseram o uso dos coeficientes do modelo AR para caracterizar o estado de danos lineares. Silva S. et al. (2005) utilizaram o modelo AR a fim de ajustar históricos temporais de sinais de vibração em uma condição sem falha da estrutura para, em seguida, estimar o erro residual, que é a diferença entre a predição do modelo AR e a medida real da estrutura em várias condições de danos. O modelo AR alcançou as expectativas em detectar e localizar os danos.

Figueiredo e al. (2010) aplicaram uma análise de séries temporais não lineares com base em um modelo autorregressivo AR para monitorar uma estrutura semelhante à encontrada em (FIGUEIREDO et al., 2011) sob condições operacionais e ambientais variadas. Tal estrutura apresenta comportamento não linear para alguns tipos de danos que ocorrem frequentemente em estruturas do mundo real. A estrutura analisada pelos autores é o *Pórtico Yellow Frame* que também será analisada no presente trabalho. Figueiredo e al. (2011) testaram quatro algoritmos de aprendizado de máquina não supervisionados (rede neural associativa automática, análise fatorial, distância de Mahalanobis e decomposição de valor singular) para detecção de danos em uma estrutura de três andares simulando variações operacionais e ambientais alterando as condições de rigidez e massa. Os danos foram simulados com a introdução de um para-choque reproduzindo os efeitos de uma rachadura. Novamente, nenhuma medição das fontes de variabilidade ou modelos físicos foram necessários para a separação dos efeitos. Este trabalho também avaliou a aptidão de tais algoritmos para *hardware* embarcado que é uma questão crucial para aplicações práticas.

Ribeiro et al. (2019) descrevem a avaliação experimental dos efeitos dinâmicos induzidos pelo vento numa torre de telecomunicações de elevada altura com base em um sistema de monitorização permanente. O sistema de monitoramento inclui acelerômetros, anemômetros e uma estação meteorológica, permitindo a caracterização das acelerações máximas da estrutura e dos regimes de vento durante um período de 3 meses. A análise dos resultados possibilitou a identificação de eventos específicos, denominados de eventos críticos, para os quais a resposta dinâmica da torre sob ações do vento surge amplificada. A identificação automática dos eventos críticos baseou-se na aplicação aos registros de aceleração de um modelo autorregressivo (AR) e na estimativa da sua ordem de modelo ótima com base numa decomposição de valores singulares (SVD). Os resultados comprovaram a robustez e eficiência da técnica proposta na identificação do número, duração e amplitude máxima das acelerações associadas aos eventos críticos, visando a sua potencial integração em sistemas SHM.

Lynch *et al.* (2002) fizeram uso das mudanças dos erros residuais do modelo ARX, provocados pelo dano estrutural para comparar com uma base de dados constituída para estrutura considerada íntegra.

O uso do modelo AR em conjunto com o modelo ARX é observado em muitos trabalhos acadêmicos (ADAMS; FARRAR, 2002; SOHN *et al.*, 2005). Sohn, Farrah (2001) criaram um modelo de predição de dois estágios para detectar e localizar o dano; assumiu-se que o erro predito pelo modelo AR seja causado pelas excitações ambientais. Esses parâmetros são usados,

em seguida, como dados de entrada para o modelo ARX onde seu erro predito indica a sensibilidade do dano.

Silva et al. (2007) usaram um modelo AR-ARX de duas etapas criado a partir de medições de resposta de vibração para predição linear. Os testes foram realizados em uma estrutura simulada, de referência, levando a muitas medições que foram comprimidas pela análise de componentes principais para serem aplicadas no modelo. Erros de predição foram aplicados a um método de agrupamento *fuzzy* separando condições não danificadas de danificadas.

Cano W. (2015) apresenta uma abordagem baseada no processamento de séries temporais para tratar o problema de detecção e o prognóstico de danos em estruturas com sensores e atuadores piezelétricos acoplados considerando as possíveis variabilidades ambientais e operacionais. Primeiramente, um modelo autorregressivo é criado para o monitoramento estrutural como no procedimento anterior, porém, utilizando o controle estatístico de processos para detectar um dano progressivo empregando o modelo AR. Em seguida, os modelos autorregressivos com entradas exógenas, modelos ARX, são estimados para as condições de referência e de dano para acompanhar as variações de parâmetros e permitir a realização de um prognóstico sobre a condição estrutural futura da estrutura.

Meixedo A. G. (2021) empregou os modelos AR e ARX na identificação de danos em pontes ferroviárias; esses modelos lineares apresentaram eficiência na extração de características das respostas dinâmicas de sistemas não lineares (ponte x trem). Na comparação entre os dois modelos, o modelo ARX oferece maior sensibilidade na detecção de danos, haja vista a sua capacidade de capturar informações cruzadas entre os sensores (dados de entrada x dados de saída).

Silva et al. (2008b) criaram um método semelhante, primeiramente aplicando análise de componentes principais para redução de dados de sinais de vibração medidos em uma estrutura de estante de três andares para analisar o modelo ARMA. Em seguida, os erros de previsão foram usados como índices sensíveis à estrutura para testar dois métodos de agrupamento *fuzzy* – *fuzzy* c-means e Gustafson Kessel evidenciando o sucesso do último modelo. A estrutura analisada pelos autores é o *Pórtico 3SS* que será analisada também no presente trabalho.

Saito e Yokota (1996) analisaram edifícios gêmeos localizados em Tóquio que foram submetidos a terremotos ocorridos entre 1992 e 1993. Os autores estimaram as frequências naturais de vibração e as taxas de amortecimento dos edifícios estudados através da aplicação dos modelos ARMAX nos dados, obtidos a partir da resposta dos últimos aos terremotos, e identificação dos parâmetros do modelo.

De modo geral, na literatura bibliográfica dos trabalhos que buscam realizar o monitoramento estrutural empregando os modelos autorregressivos nos sinais dinâmicos, observou-se a ausência de trabalhos que incluam todos os quatro modelos autorregressivos adotados – AR, ARMA, ARX e ARMAX – em um único trabalho. Esse foi um dos motivos para a escolha desses quatro modelos que demonstraram ser eficientes, mas que não foram comparados entre si.

2.1 MODELOS AUTORREGRESSIVOS

De forma geral, os modelos discretos empregados nesse trabalho podem ser obtidos a partir do modelo geral (Aguirre, 2004):

$$A(q)y(t) = \frac{B(q)}{F(q)}x(t) + \frac{C(q)}{D(q)}\varepsilon(t) \quad (2.1)$$

Em que: $y(t)$, $x(t)$, $\varepsilon(t)$ representam uma série temporal de resposta, uma entrada pré-estabelecida e o ruído branco e representa, respectivamente.

O polinômio $A(q)$ refere-se aos polos comuns entre a modelagem da dinâmica do sistema e a modelagem do ruído (útil em casos em que se assume que o ruído entra no sistema junto com a entrada). Os polinômios $F(q)$ e $B(q)$ representam polos e zeros que afetam somente a entrada. Por último, os polinômios $D(q)$ e $C(q)$ representam os polos e zeros que afetam somente o ruído, conforme ilustrado na Figura 3. Esses polinômios são definidos como:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a};$$

$$B(q) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b};$$

$$C(q) = 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c}; \quad (2.2)$$

$$D(q) = 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d};$$

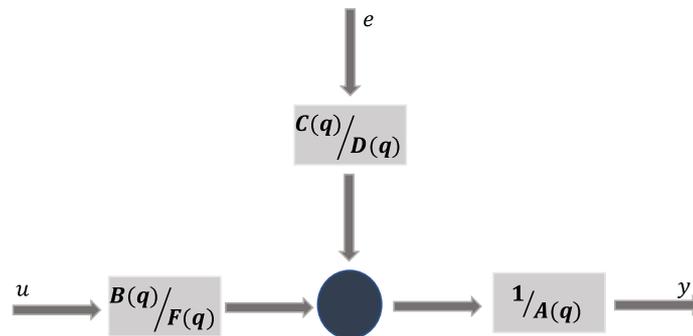
$$F(q) = 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f}.$$

onde na , nb , nc , nd e nf são as ordens dos respectivos polinômios. O operador de atraso q^{-1} atua nas variáveis, da forma a seguir, com T sendo um período constante de tempo:

$$q^{-1}u(t) = u(t - T) \quad (2.3)$$

$$q^{-2}u(t) = u(t - 2T) \quad (2.4)$$

Figura 3 – O modelo geral para a identificação paramétrica



Fonte: Adaptado pelo Bittencourt (2007).

De acordo com a forma de cada um dos polinômios (2.2), pode-se obter modelos autônomos AR e ARMA, além dos modelos não-autônomos, ARX e ARMAX e outras (AGUIRRE, 2004). Os modelos AR, ARMA, ARX e ARMAX serão abordados nas próximas seções.

2.1.1 Modelo AR

O AR (do inglês - *AutoRegressive*) é um modelo de autorregressão linear autônomo utilizado nas modelagens de séries temporais; o modelo AR (n_a) é uma regressão linear do valor atual da série contra n_a valores passados ponderados; ou seja, o modelo AR usa as informações passadas da série temporal para estimar a saída. A saída y_t pode ser expressa por (WOLD, 1954):

$$y_t = \sum_{i=1}^{n_a} a_i y_{t-i} + \varepsilon_t \quad (2.5)$$

onde y_t a série temporal; a_i são os parâmetros da parte autoregressiva do modelo, com $a_{n_a} \neq 0$ e com $a_0 = 1$; n_a é um valor inteiro que define o máximo atraso do y e que define a ordem dinâmica do modelo AR; ε_t é o resíduo de modelagem (o erro um passo à frente entre a série observada e a série obtida via modelo AR).

2.1.2 Modelo ARMA

O modelo ARMA (do inglês - *AutoRegressive Moving Average*) é visto como uma classe mais geral de representações lineares autônomas. São formados por uma parte autorregressiva AR (n_a) definida como uma regressão linear do valor atual da série contra n_a valores passados ponderados; e uma parte contendo médias móveis MA (n_c), uma soma ponderada da observação atual e de n_c observações do passado de um processo ruído branco.

O modelo ARMA (n_a, n_c) utiliza o resíduo de estimação no processo de estimação, sendo dado por:

$$y_t = \sum_{i=1}^{n_a} a_i y_{t-i} + \sum_{m=1}^{n_c} c_m \varepsilon_{t-m} + \varepsilon_t \quad (2.6)$$

onde: y_t a série temporal; a_i são os parâmetros da parte autorregressiva do modelo, com $a_{n_a} \neq 0$ e com $a_0 = 1$; ε_{t-m} são os componentes aleatórios defasados; c_m são os coeficientes da componente aleatória; n_a e n_c são as ordens dos dados de entrada e de defasagem do erro, respectivamente; ε_t são os termos de erro do modelo do t-ésimo sinal. O modelo ARMA (n_a, n_c) usa n_a defasagens do retorno bem como n_c defasagens do termo de erro para especificar a forma funcional linear a ser estimada.

2.1.3 Modelo ARX

Modelo ARX (do inglês - *AutoRegressive with exogenous inputs*) é uma derivação não-autônoma do modelo AR. Os modelos ARX são uma extensão dos modelos AR, pois considerem a possibilidade de inclusão de variáveis exógenas como regressores.

O modelo ARX é obtido a partir do modelo geral (2.1). tomando-se $C(q) = D(q) = F(q) = 1$; sendo $A(q), B(q)$ são polinômios arbitrários; ARX (n_a, n_b) pode ser expresso por:

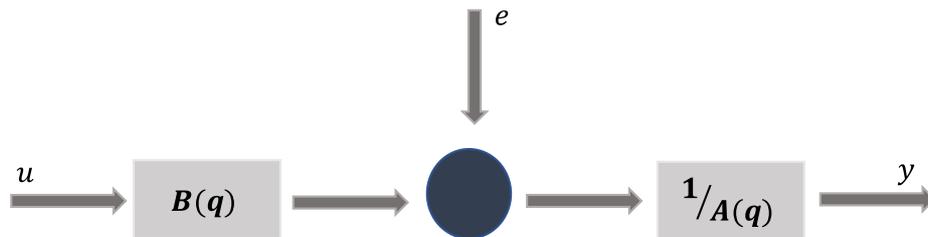
$$y_t = \sum_{i=1}^{n_a} a_i y_{t-i} + \sum_{k=1}^{n_b} b_k x_{t-k} + \varepsilon_t \quad (2.7)$$

onde: y_t são os termos da saída, x_t são os termos da entrada e ε_t são os termos de erro do modelo do t-ésimo sinal; y_t a série temporal; a_i são os parâmetros da parte autorregressiva do modelo, com $a_{n_a} \neq 0$ e com $a_0 = 1$; x_t expressa as variáveis exógenas organizadas em série temporal; b_k são os parâmetros dos termos de variáveis exógenas. n_a e n_b são as ordens dos dados de entrada e saída, respectivamente.

Verifica-se que os modelos AR (n_a) são um caso particular dos modelos ARX (n_a, n_b), quando não há sinais exógenos, ou seja, quando o valor do n_b é zero ($n_b = 0$).

Toma-se ε_t como o resíduo de modelagem, referindo à razão entre o polinômio $\varepsilon(t)$ e $A(q)$; que representa o ruído modelado como um processo branco filtrado por um filtro autorregressivo. Com os valores inicialmente adotados do polígono, o esquema do modelo ARX se encontra na Figura 4 a partir do esquema geral.

Figura 4 – Esquema do modelo ARX



Fonte: Adaptado pelo Bittencourt (2007).

2.1.4 Modelo ARMAX

Do mesmo modo, o modelo ARMAX (do inglês - *AutoRegressive Moving Average with exogenous inputs*) é uma derivação não-autônoma do modelo ARMA. Os modelos ARMAX são uma extensão dos modelos ARMA, pois consideram a possibilidade de inclusão de variáveis exógenas como repressores.

O modelo ARMAX é obtido a partir do modelo geral (2.1), tomando-se $D(q) = F(q) = 1$; sendo $A(q)$, $B(q)$ e $C(q)$ são polinômios arbitrários, ARMAX (n_a, n_b, n_c) pode ser expresso por, Louzada D. R. (2013):

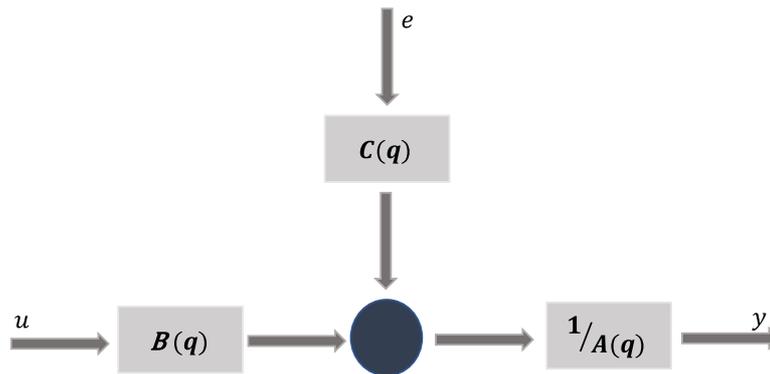
$$y_t = \sum_{i=1}^{n_a} a_i y_{t-i} + \sum_{m=1}^{n_c} c_m \varepsilon_{t-m} + \sum_{k=1}^{n_b} b_k x_{t-i} + \varepsilon_t \quad (2.8)$$

onde: y_t a série temporal; a_i são os parâmetros da parte autorregressiva do modelo, com $a_{n_a} \neq 0$ e com $a_0 = 1$; ε_{t-m} são os componentes aleatórios defasados; c_m são os coeficientes da componente aleatória; x_t expressa as variáveis exógenas organizadas em série temporal; b_k são os parâmetros dos termos de variáveis exógenas. n_a, n_c e n_b são as ordens dos dados de entrada, defasagem do erro e saída, respectivamente. ε_t são os termos de erro do modelo do t-ésimo sinal.

Verifica-se que os modelos ARMA (n_a, n_c) são um caso particular dos modelos ARMAX (n_a, n_b, n_c) , quando não há sinais exógenos, ou seja, quando o valor do n_b é zero ($n_b = 0$).

Toma-se ε_t como o resíduo de modelagem, referindo à razão entre o polinômio $\varepsilon(t) \times C(q)$ e $A(q)$; que representa o ruído modelado como um processo branco filtrado por um filtro ARMA. Com os valores inicialmente adotados do polígono, o esquema do modelo ARMAX se encontra na Figura 5 a partir do esquema geral.

Figura 5 – Esquema do modelo ARMAX

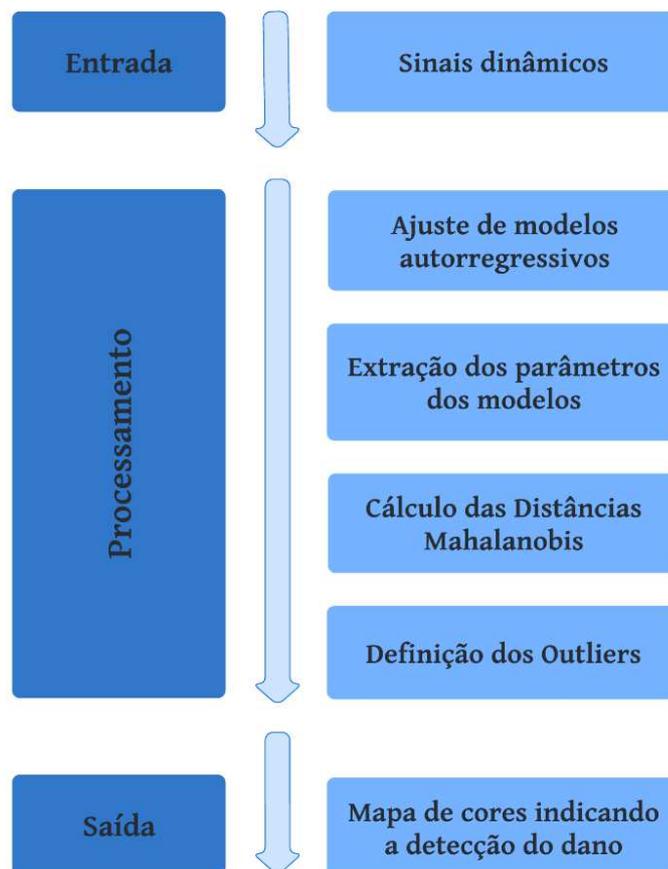


Fonte: Adaptado pelo Bittencourt (2007).

3 METODOLOGIA

A metodologia deste trabalho consiste na implementação dos modelos de autorregressão em códigos executáveis e na simulação dos modelos discretos AR, ARMA, ARX e ARMAX em estudo de caso de quatro estruturas distintas. Sendo duas estruturas ensaiadas em laboratório: um pórtico de três andares, de pequeno porte, e um pórtico de quatro andares, de médio porte. Ademais, duas estruturas reais de grande porte, atualmente em uso: um viaduto de 17,5 m de extensão e uma ponte com vão principal de 260 m. Ressalta-se que os ensaios laboratoriais, citados e analisados no presente trabalho, não foram realizados pela autora do mesmo. A Figura 6 mostra um fluxograma que indica os passos realizados na implementação e execução dos códigos no MATLAB.

Figura 6 – Fluxograma de implementação dos códigos



Fonte: Elaborado pela autora (2022).

O presente trabalho tem o objetivo de estudar a aplicação do monitoramento das estruturas praticamente em tempo real; por isso, foi estabelecido o tempo máximo de execução dos códigos dos modelos como 5 horas.

A escolha das ordens, que são os dados de entrada, foi estabelecida através da fixação de valores mínimos e máximos. Assim, analisa-se as ordens entre os valores em um intervalo de cinco em cinco, incluindo a ordem mínima e máxima. Inicialmente, foi escolhida a ordem mínima como 5 e a ordem máxima como 50. Porém, após estudos preliminares, notou-se nas ordens mais altas que o tempo gasto na execução do código ultrapassou o tempo estabelecido de 5 horas. Por isso, adotou-se a ordem mínima como 5 e a ordem máxima como 30.

O modelo AR demanda apenas uma ordem a ser informada como dado de entrada. Assim, as simulações realizadas dos modelos AR são: AR (5), AR (10), AR (15), AR (20), AR (25), e AR (30), resultando em 6 simulações do modelo AR.

Para os modelos que possuem duas ordens a serem informadas como dados de entrada, tais como ARMA e ARX, fixou-se o valor da ordem, tanto no valor mínimo (5) quanto no máximo (30), variando-se o valor da outra; conforme mostrado a seguir:

- A: [1° variando, 2° fixo no Min];
- B: [1° variando, 2° fixo no Max];
- C: [1° fixo no Min, 2° variando];
- D: [1° fixo no Max, 2° variando].

Resultando, portanto, em 20 combinações de cada modelos, conforme listadas na Tabela 2:

Tabela 2 – Simulações realizadas dos modelos ARX e ARMA

Modelo ARX	A:	ARX (5,5)	ARX(10,5)	ARX (15,5)	ARX (20,5)	ARX (25,5)	ARX (30,5)
	B:	ARX (5,30)	ARX (10,30)	ARX (15,30)	ARX (20,30)	ARX (25,30)	ARX (30,30)
	C:		ARX (5,10)	ARX (5,15)	ARX (5,20)	ARX (5,25)	
	D:		ARX (30,10)	ARX (30,15)	ARX (30,20)	ARX (30,25)	
Modelo ARMA	A:	ARMA (5,5)	ARMA (10,5)	ARMA (15,5)	ARMA (20,5)	ARMA (25,5)	ARMA (30,5)
	B:	ARMA (5,30)	ARMA (10,30)	ARMA (15,30)	ARMA (20,30)	ARMA (25,30)	ARMA (30,30)
	C:		ARMA (5,10)	ARMA (5,15)	ARMA (5,20)	ARMA (5,25)	
	D:		ARMA (30,10)	ARMA (30,15)	ARMA (30,20)	ARMA (30,25)	

Fonte: Elaborado pela autora (2022).

Para os modelos que têm três ordens a serem informadas como dados de entrada (caso do ARMAX), fixou-se os valores de duas ordens, tanto no valor mínimo como no máximo, variando o valor da terceira; conforme descrito a seguir:

- A: [1° fixo no Min, 2° fixo no Min, 3° variando]
- B: [1° fixo no Max, 2° fixo no Max, 3° variando]
- C: [1° fixo no Min, 2° variando, 3° fixo no Min]
- D: [1° fixo no Max, 2° variando, 3° fixo no Max]
- E: [1° variando, 2° fixo no Min, 3° fixo no Min]
- F: [1° variando, 2° fixo no Max, 3° fixo no Max]

Resultando, portanto, em 32 combinações, conforme listadas na Tabela 3:

Tabela 3 – Simulações realizadas dos modelos ARMAX

Modelo ARMAX	A:	ARMAX (5,5,5)	ARMAX (5,5,10)	ARMAX (5,5,15)	ARMAX (5,5,20)	ARMAX (5,5,25)	ARMAX (5,5,30)
	B:	ARMAX (30,30,5)	ARMAX (30,30,10)	ARMAX (30,30,15)	ARMAX (30,30,20)	ARMAX (30,30,25)	ARMAX (30,30,30)
	C:		ARMAX (5,10,5)	ARMAX (5,15,5)	ARMAX (5,20,5)	ARMAX (5,25,5)	ARMAX (5,30,5)
	D:	ARMAX (30,5,30)	ARMAX (30,10,30)	ARMAX (30,15,30)	ARMAX (30,20,30)	ARMAX (30,25,30)	
	E:		ARMAX (10,5,5)	ARMAX (15,5,5)	ARMAX (20,5,5)	ARMAX (25,5,5)	ARMAX (30,5,5)
	F:	ARMAX (5,30,30)	ARMAX (10,30,30)	ARMAX (15,30,30)	ARMAX (20,30,30)	ARMAX (25,30,30)	

Fonte: Elaborado pela autora (2022).

Assim, levando-se em conta as ordens escolhidas, totalizam-se 78 simulações para cada caso de estudo do presente trabalho, já que são 6 simulações do modelo AR, 20 simulações do modelo ARMA, 20 simulações do modelo ARX e 32 simulações do modelo ARMAX.

Os níveis de dano são calculados a partir do índice de dano (do inglês – *Damage Index* - *DI*) cujo valor é calculado através da Distância de Mahalanobis. Os índices de dano (*DI*) são graficamente representados por barras, onde cada barra indica o nível de dano para os ensaios de cada cenário.

A Distância de Mahalanobis (do inglês- *Mahalanobis Distance- MD*) mede a distância entre os parâmetros extraídos da estrutura *de referência (sem dano)* e das estruturas ensaiadas de cada cenário. A *MD* para cada simulação *i* pode ser expressa a seguir:

$$MD_i = \sqrt{(x_i - \bar{x}_B) \cdot S_B^{-1} \cdot (x_i - \bar{x}_B)^T} \quad (3.1)$$

onde: x_i são os vetores de m parâmetros da estrutura ensaiada, \bar{x}_B são as matrizes das médias dos parâmetros da estrutura *de referência*, S_B são as matrizes de covariância dos parâmetros da estrutura *de referência* e T é a transposta.

Ter-se-á o índice de dano, *DI*, como o valor da *MD* aplicada entre os parâmetros extraídos da estrutura *de referência* e das estruturas ensaiadas de cada cenário, expresso na equação (3.2). Quanto menor for o valor do *MD*, maior a similaridade dos parâmetros das estruturas ensaiadas com aqueles da *referência*. Por outro lado, quanto maior for o valor de *MD*, menor será essa similaridade.

$$DI = MD(x, x_B) \quad (3.2)$$

Os cenários de dano analisados são ordenados crescentemente em gráficos de barras pela intensidade do nível de dano esperado; onde, cada barra indica o índice de dano para cada cenário de dano analisado. Por isso, espera-se que as barras estejam dispostas como uma “escada subindo”, já que o índice de dano é diretamente proporcional à intensidade do nível de dano presente na estrutura. Quando ocorre a estruturação conforme uma escada, isso demonstra o sucesso do método adotado.

Em muitos casos, os cenários fogem do esperado e não atribuem para a estruturação um modo “escada perfeita”. Diante disso, para o presente trabalho, adotou-se uma cor para cada uma das três classes; logo, três cores. A escala tem o intuito de avaliar as classes da coerência dos resultados com o estilo “escada”; os resultados em questão são os resultados de cada sensor apresentados através das saídas gráficas, onde cada barra representa cenário de dano analisado. As classes da escala são citadas conforme a seguir:

- Classe 1 – Cor verde (GRE): indica que mais de 80% das barras formam uma escada perfeita;
- Classe 2 – Cor amarela (YEL): indica que de 50% até 80% das barras formam uma escada perfeita;
- Classe 3 – Cor vermelha (RED): indica que menos de 50% das barras formam uma escada perfeita.

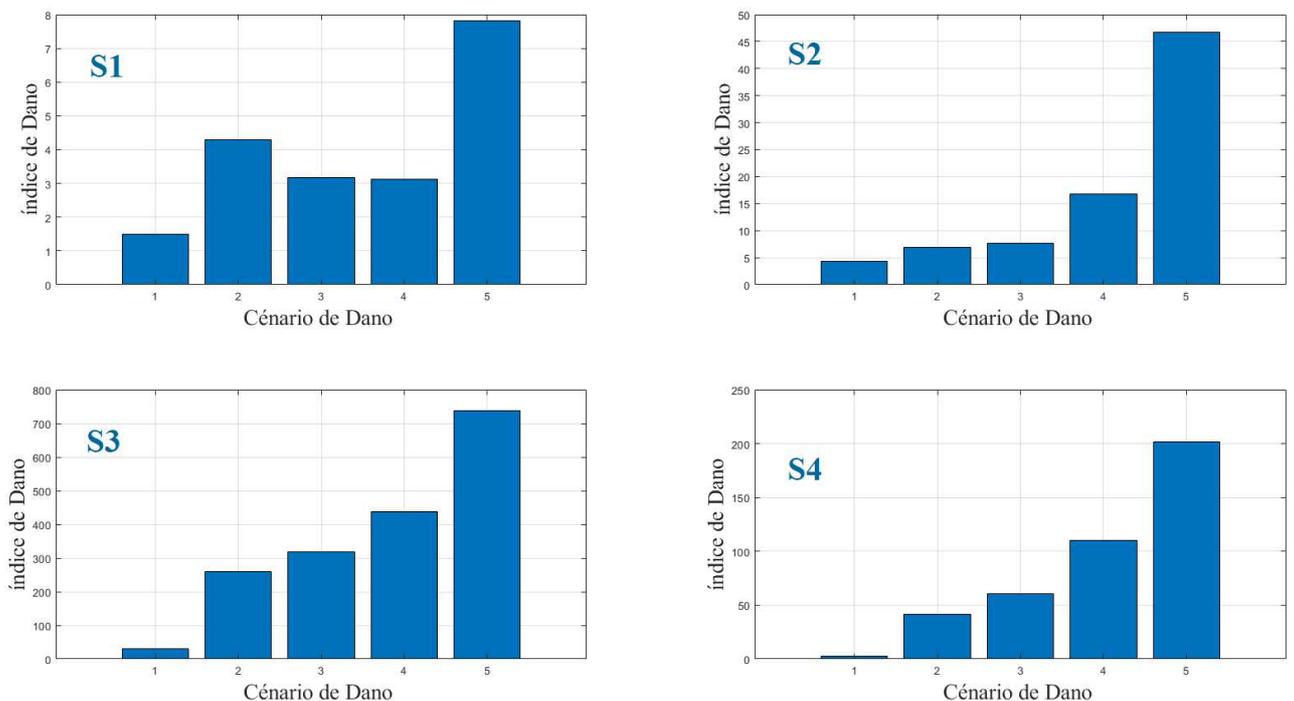
Pela observação da escala adotada, é fácil perceber que as classes são ordenadas da mais favorável, Classe 1, até a menos favorável, Classe 3. No presente trabalho, os exemplos analisados contêm diferentes números de cenários; diante disso, as saídas gráficas conterão diferentes números de barras. Assim, espera-se que os números das barras incluídas em cada classe sejam diferentes de um caso para outro. O número das barras de cada classe será informado para cada caso estudado, conforme abordado nos itens a seguir.

Depois de analisar as saídas gráficas, classificam-se os modelos autorregressivos, com as suas devidas ordens, pela classe mais ocorrente registrada das saídas gráficas. A Figura 7 mostra o resultado de um Modelo Exemplo, sendo AR (5) com 4 saídas gráficas já que são 4 sensores. Na Figura 7, os sensores S1, S2 e S3 apresentam o modo “escada perfeita”

A Tabela 4 classifica as 4 saídas gráficas usando a escala de cores estabelecida, em que S1 refere-se ao sensor número 1 classificado na Classe 2 (YEL) e S2 refere-se ao sensor número 2 classificado na Classe 1 (GRE), e assim por diante; a escala de cor é descrita pela cor do fundo da célula.

A Tabela 5 contém uma demonstração da análise do modelo em si. Assim, pode-se verificar que a análise dos cenários, mostrados na Tabela 4, levou à classificação dos modelos com as devidas ordens Tabela 5.

Figura 7 – Saída gráfica de um exemplo modelo



Fonte: Elaborado pela autora (2022).

Tabela 4 – Resultado da classificação de todos os sensores de exemplo modelo

AR (5)	S1	S2	S3	S4
--------	----	----	----	----

Fonte: Elaborado pela autora (2022).

Tabela 5 – Resultado da classificação de exemplo modelo

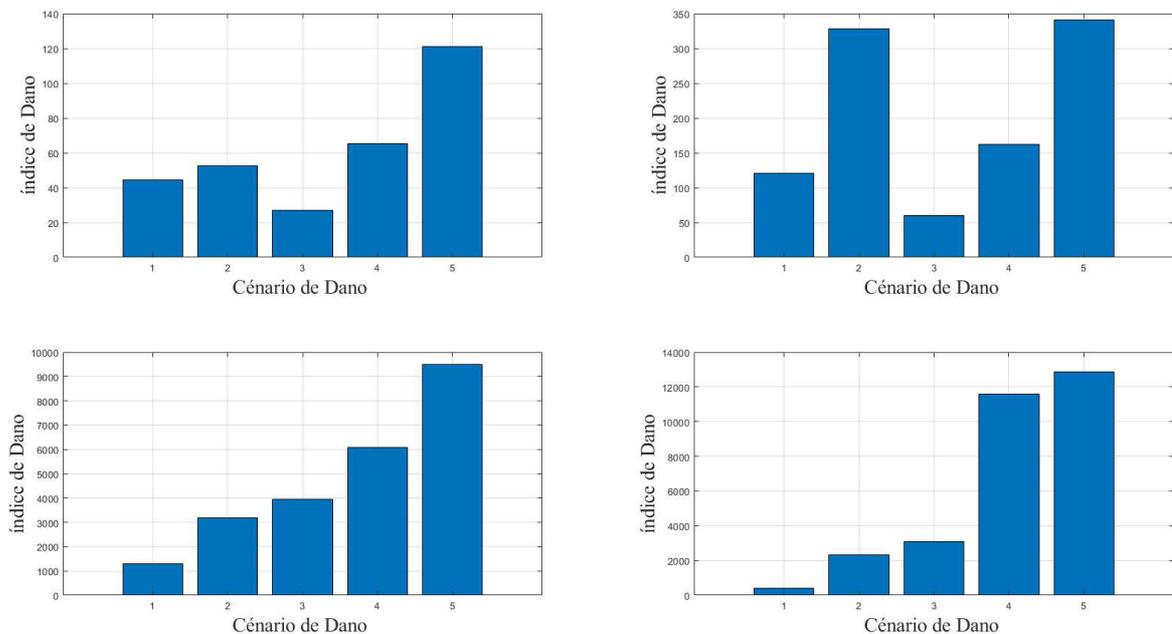
Class.	AR (5)
--------	--------

Fonte: Elaborado pela autora (2022).

Nos casos em que ocorre empate entre os resultados de análise dos sensores, optou-se sempre por classificar o modelo como uma classe inferior. Por exemplo: as saídas gráficas de modelo ARMA (5,20) hipotético se encontram na Figura 8; neste caso, houve duas saídas gráficas classificadas na Classe 1 (GRE) e duas na Classe 2 (YEL), conforme mostrado na Tabela 6. Assim, ter-se-á que o modelo é classificado como a Classe 2, conforme mostrado na Tabela 7.

Quando o empate ocorre entre a Classe 2 e a Classe 3, considera-se o modelo na Classe 3. Quando o empate ocorre entre a Classe 1 e a Classe 3, o modelo é considerado como Classe 2.

Figura 8 – Exemplo geral das imagens resultantes das simulações do experimento 3SS



Fonte: Elaborado pela autora (2022).

Tabela 6 – Resultado da classificação de todos os sensores de exemplo modelo

ARMA (5,20)	Sensor 1	Sensor 2	Sensor 3	Sensor 4
-------------	----------	----------	----------	----------

Fonte: Elaborado pela autora (2022).

Tabela 7 – Resultado da classificação de todos os sensores de exemplo modelo

Class.	ARMA (5,20)
--------	-------------

Fonte: Elaborado pela autora (2022).

Além disso, para se ter uma melhor percepção do tempo gasto pela execução dos códigos de cada modelo simulado, registrou-se e classificou-se os tempos gastos com uma cor para cada uma das três classes, logo, três cores. As cores de cada classe são citadas conforme a seguir:

- Classe 1t – Cor verde (GREt): indica que o tempo registrado é inferior de uma hora;
- Classe 2t – Cor amarela (YELt): indica que o tempo registrado é entre uma e três horas;
- Classe 3t – Cor vermelha (REDt): indica que o tempo gasto é entre três e cinco horas.

O tempo máximo de execução de código adotado nesse trabalho é de 5 horas. A escolha das ordens dos modelos e, também, dos números dos sinais analisados foi feita tendo em mente que o tempo gasto de execução de códigos não ultrapasse as 5 horas. Porém, excepcionalmente, em algumas ordens, o tempo registrado ultrapassou as 5 horas estimadas e a classificação desse tempo foi registrada na cor preta.

Escolheu-se as duas escalas a fim de facilitar a organização dos resultados e, por sua vez, a sua leitura, para que com apenas uma rápida análise se possa identificar as melhores classificações com o menor tempo gasto. Na Tabela 8, mostra-se uma demonstração da análise de classificação do modelo AR (5) na classe 1 (GRE) e do tempo gasto de execução de código na classe 1t (GREt).

Tabela 8 – Resultado da classificação de exemplo modelo e do tempo gasto

Class.	AR (5)
Tempo (h)	0,009

Fonte: Elaborado pela autora (2022).

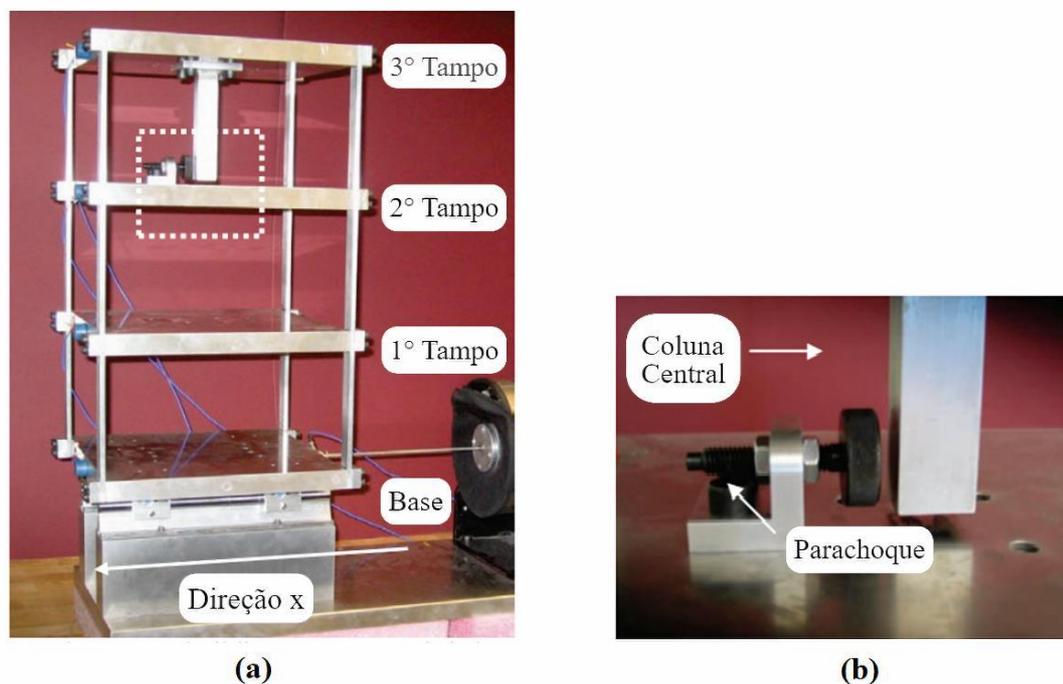
Compreende-se que a análise do tempo depende diretamente da configuração do computador usado para processar e executar os códigos. Mesmo assim, resolveu-se levar em consideração o tempo gasto a fim de se ter uma mínima noção e comparação entre os modelos. No presente trabalho, utilizou-se uma máquina com processador Intel Core i5 9600k, placa de vídeo NVIDIA GeForce GTX 1050 2GB, memória RAM de 32GB e SSD de 500GB.

4 APLICAÇÕES

4.1 PÓRTICO 3SS

Nesta seção apresenta-se o caso analisado de uma estrutura ensaiada no *Los Alamos National Laboratory* (LANL) com a colaboração do *Laboratory for Concrete Technology and Structural Behavior* (LABEST) em que ambos têm foco no prognóstico de danos. O presente item e seus respectivos subitens são baseados nas referências: Figueiredo E. *et al.* (2009) e Example Usages (2014). A Figura 9 mostra a estrutura ensaiada de três andares.

Figura 9 – Foto da estrutura ensaiada. (a) Estrutura de três andares com a base; (b) Detalhe que mostra a fixação da coluna central e o para-choque



Fonte: Figueiredo *et al.* (2009).

4.1.1 O sistema estrutural

A estrutura analisada é formada por três andares, no inglês *3-Story Structure*; por isso, veio o nome de *3SS*, os pilares e os tampos são de alumínio, juntados através de parafusos *Bolts*; cada andar consiste em 4 pilares conectados com o tampo inferior e superior. No total, tem-se quatro (4) tampos: Base, 1º Tampo, 2º Tampo e 3º Tampo; também, doze colunas conforme a Figura 9 (a). A estrutura é posicionada em cima de trilhos que permite o seu deslizamento em apenas uma direção horizontal, adotada com a direção em x .

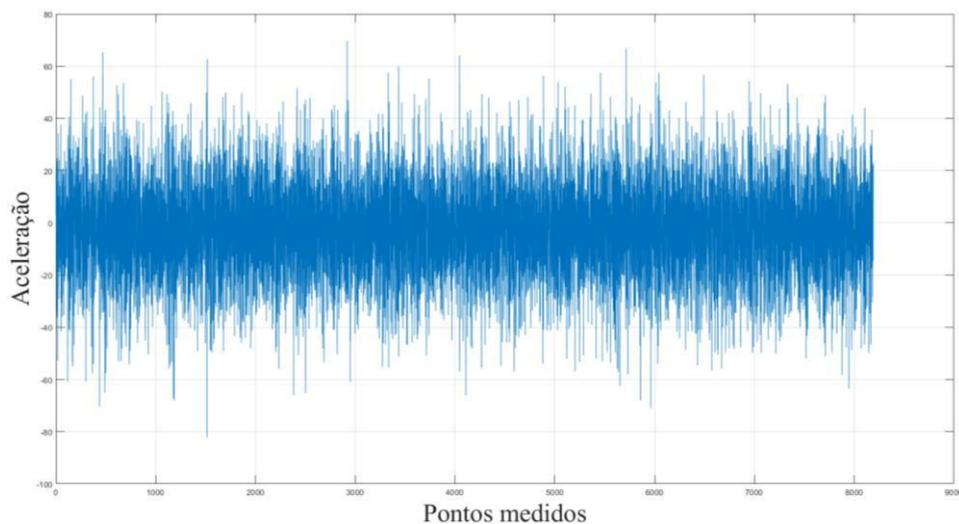
Para simular o dano, foi fixada uma coluna central pendurada do 3º piso e um para-choque na face superior do 2º Tampo; esse conjunto tende a criar um comportamento não-linear quando a coluna central encosta no para-choque. Essa não-linearidade pode ser vista como dano. A intensidade desse dano pode ser variada e controlada através do ajuste da distância entre a coluna e o para-choque.

A estrutura ensaiada é submetida a um tipo de dano que simula o dano causado pelas fissuras que abrem e fecham nas estruturas de escala natural (1:1); ou até simular a perda de conexão provocada pelas cargas dinâmicas.

4.1.2 Sistema de aquisição dos dados

O *shaker* (agitador) é um aparelho eletrodinâmico que provoca, através de cargas dinâmicas, excitações laterais no centro da espessura do tampo da base; e por sua vez, excitação na estrutura inteira já que todos os seus elementos são interligados (elementos parafusados). A estrutura analisada junto com o shaker ficam em cima do assento suporte (do inglês- *Baseplate*); a *Baseplate*, a estrutura analisada e o *Shaker* situam-se em cima de uma espuma rígida. A função da espuma rígida é minimizar as fontes anormais das excitações não mensuradas introduzidas pelo tampo da base. Na Figura 10 encontra-se um exemplo amostral de um sinal capturado por um sensor e empregado na análise.

Figura 10 – Exemplo amostral de um sinal capturado pelo sensor



Fonte: Elaborado pela autora (2022), a partir dos sinais oferecidos.

Uma célula de carga (do inglês- *load cell*) foi instalada na extremidade do tampo da base, no ponto da ligação do *shaker* com a estrutura, a fim de medir a sollicitação que o *shaker* está exercendo na mesma. A célula de carga é um sensor que mede a força aplicada e a converte em sinais eletrônicos. No presente caso, a célula de carga tem sensibilidade nominal de $2,2 \text{ mV/N}$. Na Figura 11 nota-se a célula de carga representada pelo *Channel 1*.

Quatro acelerômetros foram instalados no centro da espessura de cada tampo (Base, 1º Tampo, 2º Tampo e 3º Tampo) no lado oposto do lado da instalação da célula de carga e o *shaker*; apresentados na Figura 12 (a) por: *Channel 2*, *Channel 3*, *Channel 4* e *Channel 5*. Esses acelerômetros funcionam como sensores e têm sensibilidade nominal de 1000 mV/g .

Utilizou-se o sistema de aquisição dos dados *PXI* com os seus devidos instrumentos para coletar e processar os dados. Os sinais de resposta dos cinco sensores foram adquiridos usando um módulo *PXI-4472B DAQ.aC*.

4.1.3 Cenários de dano

Os 17 distintos cenários de danos são apresentados na Tabela 9. Para cada cenário de dano realizou-se 50 ensaios; gerando 50 sinais por sensor para cada cenário adotado. Basicamente, os cenários foram divididos em quatro grupos de acordo com o tipo de dano analisado.

O primeiro grupo (cenário 1) consiste em um cenário não danificado da estrutura (do inglês – *Baseline*) que funciona como um estado de referência. Nesse estado, a coluna central e o Para-choque são incluídos na estrutura analisada; porém, com uma distância que não permite a colisão entre eles.

O segundo grupo (cenários 2 - 9) busca examinar as variedades operacionais e ambientais atuando nas estruturas que se manifestam como alterações no módulo de elasticidade e na distribuição da massa. Levando isso em consideração, os cenários baseiam-se em variar o carregamento, adicionando massa de $1,2 \text{ kg}$ na Base ou no 1º Tampo, mostrado na Figura 12 (b); ou reduzir a rigidez por meio da redução da área de elasticidade de uma coluna ou mais por meio de redução da área transversal delas.

O terceiro grupo (cenários 10 - 14) analisa os danos causados pela não-linearidade do sistema estrutural. Os cenários baseiam-se em variar as distâncias entre a coluna central e o para-choque a fim de se obter diferentes níveis de não-linearidade.

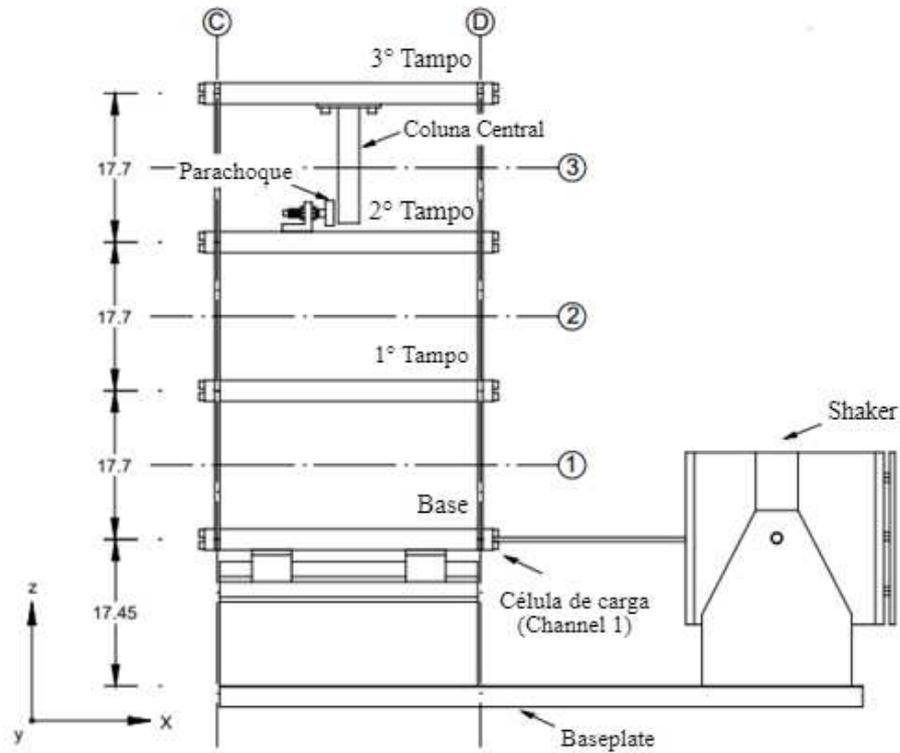
O quarto grupo (cenários 15 - 17) busca criar condições mais realísticas à estrutura analisada. É a junção do segundo grupo com o terceiro. Esse grupo não será analisado, e assim, não se considera os cenários 15, 16 e 17.

Tabela 9 – Cenários de dano do experimento 3SS com as devidas descrições

Nº - Cenários de dano	Descrição de estado de dano
Cenário 1	<i>Baseline</i> - cenário não danificado
Cenário 2	Massa= 1,2 kg na Base
Cenário 3	Massa= 1,2 kg no 1º andar
Cenário 4	87,5% redução de <i>E</i> na coluna 1BD
Cenário 5	87,5% redução de <i>E</i> na coluna 1AD e 1BD
Cenário 6	87,5% redução de <i>E</i> na coluna 2BD
Cenário 7	87,5% redução de <i>E</i> na coluna 2AD e 2BD
Cenário 8	87,5% redução de <i>E</i> na coluna 3BD
Cenário 9	87,5% redução de <i>E</i> na coluna 3AD e 3BD
Cenário 10	Espaçamento= 0,20 mm
Cenário 11	Espaçamento= 0,15 mm
Cenário 12	Espaçamento= 0,13 mm
Cenário 13	Espaçamento= 0,10 mm
Cenário 14	Espaçamento= 0,05 mm
Cenário 15	Espaçamento= 0,20 mm e Massa=1,2 kg na Base
Cenário 16	Espaçamento= 0,20 mm e Massa=1,2 kg no 1º andar
Cenário 17	Espaçamento= 0,10 mm e Massa=1,2 kg no 1º andar

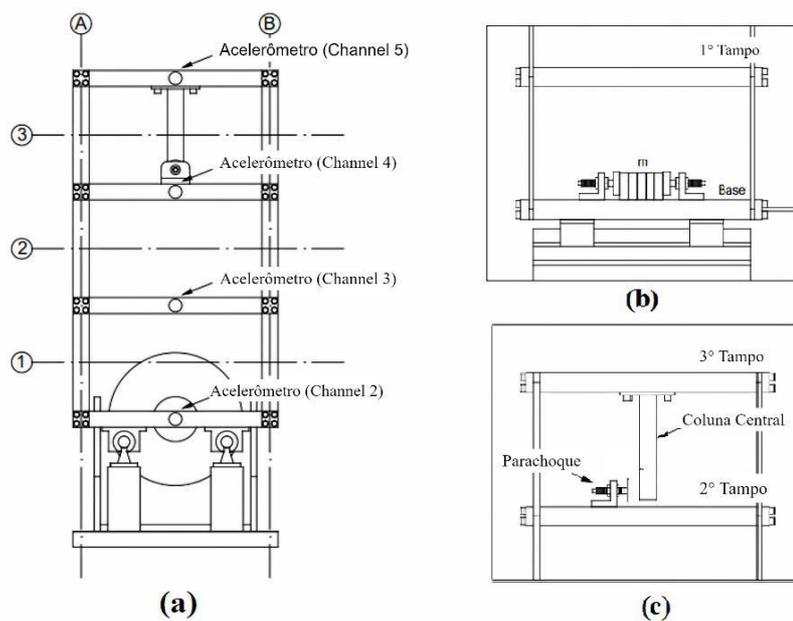
Fonte: Adotado de Example Usages (2014).

Figura 11 – Esquema da estrutura ensaiada mostrando os canais, *shaker*, célula de carga, *Baseplate* e *Bumper*



Fonte: Example Usages (2014).

Figura 12 – Esquema e detalhes da montagem da estrutura ensaiada. (a) detalhe da massa adicionada; (b) detalhe sobre a coluna central e o Para-choque



Fonte: Example Usages (2014).

4.1.4 Implementação da metodologia

Neste item, citam-se as informações principais e resumidas sobre a implementação da metodologia. Os arquivos de dados coletados do 3SS contêm 10 ensaios por nível de dano, sendo 14 cenários de dano no total.

Cada ensaio possui 8192 pontos medidos por 4 acelerômetros armazenados nas colunas de 2 até 5; os sinais de excitação do *shaker* são armazenados na coluna 1. Assim, a matriz *dataset* possuirá dimensões: $8192 \times 5 \times 140$, a saber: o valor 8192 indica o número de pontos medidos; o valor 5 refere-se ao número de canais; o valor 140 é obtido a partir da multiplicação entre a quantidade dos cenários, que são 14, e a quantidade de ensaios por cenário, que são 10.

Dados de entrada:

- Nome do arquivo dos dados (*data3SS.mat*)
- Ordem do modelo: [*na*] (Para o modelo AR)
- Ordem do modelo: [*na*] (Para o modelo ARMA)
- Ordem do modelo: [*na nb*] (Para o modelo ARX)
- Ordem do modelo: [*na nb nc*] (Para o modelo ARMAX)

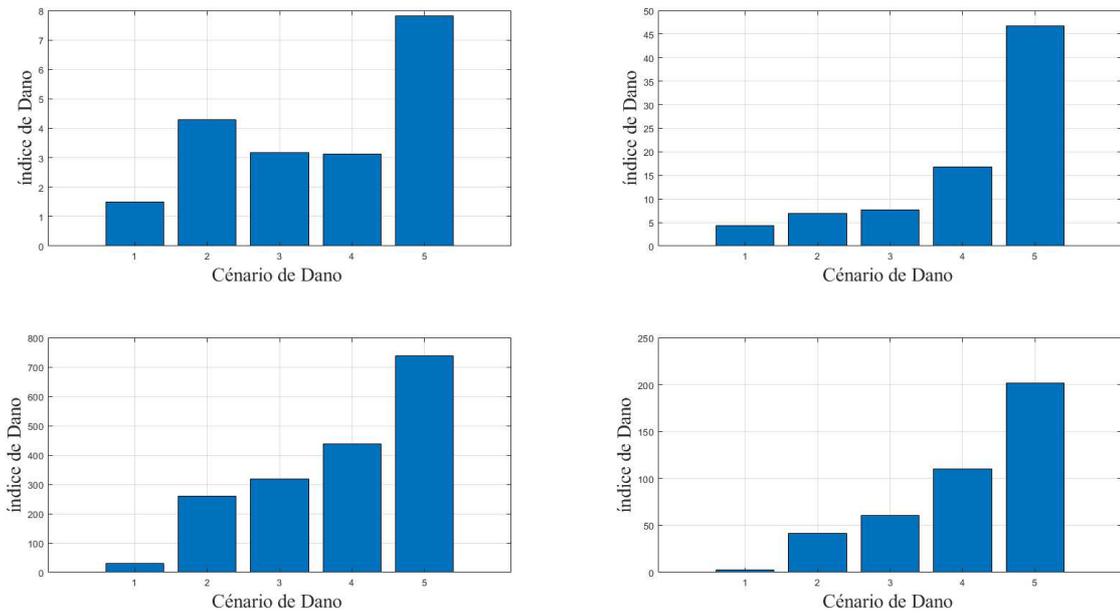
4.1.5 Resultados

Nesta seção mostram-se os resultados obtidos a partir das simulações realizadas, dispostos em tabelas de acordo com as ordens escolhidas para cada modelo. No total, foram realizadas 78 simulações, resultantes de 6 simulações do modelo AR, 20 simulações do modelo ARMA, 20 simulações do modelo ARX e 32 simulações de ARMAX. Assim, serão escolhidas algumas simulações que apresentam os melhores resultados em relação a todos os sensores.

Como mencionado anteriormente, o total dos cenários de danos é 14; porém, os primeiros 9 ensaios foram considerados e utilizados como referência e, assim, analisou-se apenas 5 cenários: 10, 11, 12, 13 e 14. Os resultados do experimento do 3SS, para todos os modelos, possuem quatro saídas gráficas, já que o experimento conta com 4 sensores; cada saída gráfica possui 5 barras, pois são 5 cenários de dano analisados. A Figura 13 mostra um exemplo do resultado da simulação utilizando um modelo AR (5), confirmando o citado anteriormente a respeito do número de saídas gráficas e barras.

A classificação das classes seguiu-se a seguinte padrão: (i) Classe 1 (GRE), quando tem 5 ou 4 barras formando uma escada subindo; (ii) Classe 2 (YEL), quando tem 3 ou 2 barras formando uma escada subindo e (iii) Classe 3 (RED), quando tem menos de 2 barras formando escada.

Figura 13 – Exemplo geral das imagens resultantes das simulações do experimento 3SS



Fonte: Elaborado pela autora (2022).

4.1.5.1 Modelo AR – 3SS

O modelo AR requer apenas uma ordem como dado de entrada. Na Tabela 10 é exibida a classificação do modelo AR para as seis ordens simuladas e o tempo de execução dos códigos. A Tabela 11 apresenta os resultados da classificação, de todas as ordens adotadas, para todos os sensores.

Tabela 10 – Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - Pórtico 3SS

AR	Class.	AR 5	AR 10	AR 15	AR 20	AR 25	AR 30
	Tempo (h)	0,009	0,020	0,035	0,0613	0,097	0,273

Fonte: Elaborado pela autora (2022).

Tabela 11 – Resultado da classificação de todos os sensores do modelo AR - Pórtico 3SS

AR 5	S1	S2	S3	S4
AR 10	S1	S2	S3	S4
AR 15	S1	S2	S3	S4
AR 20	S1	S2	S3	S4
AR 25	S1	S2	S3	S4
AR 30	S1	S2	S3	S4

Fonte: Elaborado pela autora (2022).

Da Tabela 10, evidencia-se que os resultados de todas as ordens são classificados na Classe 1 (GRE) com tempo de execução consideravelmente curto; a simulação do modelo AR (5) foi realizada em menos de 1 minuto e o maior tempo gasto foi de aproximadamente 16 minutos para o modelo AR (30); assim, todas as simulações se classificaram na Classe t1 (GREt).

4.1.5.2 Modelo ARMA - 3SS

O modelo ARMA requer duas ordens como dados de entrada. Na Tabela 12 é exibida a classificação do modelo ARMA para as vinte simulações e o tempo de execução dos códigos. A Tabela 13 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARMA (5,5), ARMA (5,10), ARMA (5,15), ARMA (5,20), ARMA (5,25) e ARMA (5,30). A análise de todas as ordens se encontram no Apêndice A.

Tabela 12 – Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada – Pórtico 3SS

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,031	0,037	0,050	0,058	0,078	0,119
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,033	0,047	0,064	0,093	0,168	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,187	0,199	0,266	0,301	0,327	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,150	0,191	0,220	0,281		

Fonte: Elaborado pela autora (2022).

Tabela 13 – Resultado da classificação de todos os sensores do modelo ARMA – Pórtico 3SS

ARMA 5 5	S1	S2	S3	S4
ARMA 5 10	S1	S2	S3	S4
ARMA 5 15	S1	S2	S3	S4
ARMA 5 20	S1	S2	S3	S4
ARMA 5 25	S1	S2	S3	S4
ARMA 5 30	S1	S2	S3	S4

Fonte: Elaborado pela autora (2022).

Da Tabela 12, evidencia-se que das vinte ordens simuladas, 8 ordens se classificaram na Classe 1 (GRE) e 12 ordens na Classe 2 (YEL). O tempo de execução registrado é consideravelmente curto; a simulação do modelo ARMA (5,5) foi realizada em menos de 2 minutos e o maior tempo gasto foi de aproximadamente 20 minutos para o modelo ARMA (30,30); assim, todas as simulações se classificaram na classe t1 (GREt).

Ambos os modelos ARMA (5,20) e ARMA (5,30) mostraram dois sensores classificados na classe 1 (GRE) e dois sensores classificados na classe 2 (YEL); com isso, a classificação dos modelos se enquadra na classe 2 (YEL), visto na Tabela 12.

4.1.5.3 Modelo ARX - 3SS

O modelo ARX requer duas ordens como dados de entrada. Na Tabela 14 é exibida a classificação do modelo ARX para as vinte simulações e o tempo de execução dos seus códigos. A Tabela 15 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARX (5,5), ARX (5,10), ARX (5,15), ARX (5,20), ARX (5,25) e ARX (5,30). A análise de todas as ordens se encontram no Apêndices A.

Tabela 14 – Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada – Pórtico 3SS

ARX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,014	0,021	0,034	0,058	0,090	0,265
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,024	0,040	0,067	0,107	0,279	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,283	0,291	0,291	0,389	0,297	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,2720	0,2715	0,275	0,286		

Fonte: Elaborado pela autora (2022).

Tabela 15 – Resultado da classificação de todos os sensores do modelo ARX – Pórtico 3SS

ARX 5 5	S1	S2	S3	S4
ARX 5 10	S1	S2	S3	S4
ARX 5 15	S1	S2	S3	S4
ARX 5 20	S1	S2	S3	S4
ARX 5 25	S1	S2	S3	S4
ARX 5 30	S1	S2	S3	S4

Fonte: Elaborado pela autora (2022).

Da Tabela 14, evidencia-se que as vinte ordens simuladas se classificaram na classe na classe 1 (GRE) com tempo de execução consideravelmente curto; a simulação do modelo ARX (5,5) foi realizada em menos de 1 minuto e o maior tempo gasto foi de aproximadamente 18 minutos para o modelo ARX (30,30) sendo das ordens superiores; assim, todas as simulações se classificaram na classe t1 (GREt). Destaca-se que para o modelo ARX, todos os sensores em todas as ordens se classificaram na classe 1 (GRE), conforme mostrado no Apêndice A.

4.1.5.4 Modelo ARMAX- 3SS

O modelo ARMAX requer três ordens como dados de entrada. Na Tabela 16 é exibida a classificação do modelo ARMAX para as trinta e duas (32) simulações e o tempo de execução dos códigos. A Tabela 17 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARMAX (5,5), ARMAX (5,10), ARMAX (5,15), ARMAX (5,20), ARMAX (5,25) e ARMAX (5,30). A análise de todas as ordens se encontra no Apêndice A.

Tabela 16 – Resultado da classificação do modelo ARMAX e do tempo gasto de cada ordem simulada - Pórtico 3SS

ARMAX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,042	0,060	0,073	0,099	0,130	0,192
	class.	5.10.5	5.15.5	5.20.5	5.25.5	5.30.5	
	Tempo	0,060	0,073	0,113	0,127	0,248	
	class.	10.5.5	15.5.5	20.5.5	25.5.5	30.5.5	
	Tempo	0,062	0,076	0,102	0,140	0,278	

class.	30.30.5	30.30.10	30.30.15	30.30.20	30.30.25	30.30.30
Tempo	0,429	0,479	0,510	0,584	0,619	0,679
class.	30.5.30	30.10.30	30.15.30	30.20.30	30.25.30	
Tempo	0,565	0,672	0,600	0,628	0,688	
class.	5.30.30	10.30.30	15.30.30	20.30.30	25.30.30	
Tempo	0,543	0,492	0,506	0,587	0,654	

Fonte: Elaborado pela autora (2022).

Tabela 17 – Resultado da classificação de todos os sensores do modelo ARMAX - Pórtico 3SS

ARMAX 5 5 10	S1	S2	S3	S4
ARMAX 5 5 10	S1	S2	S3	S4
ARMAX 5 5 15	S1	S2	S3	S4
ARMAX 5 5 20	S1	S2	S3	S4
ARMAX 5 5 25	S1	S2	S3	S4
ARMAX 5 5 30	S1	S2	S3	S4

Fonte: Elaborado pela autora (2022).

Da Tabela 16, evidencia-se que das 32 ordens simuladas, 19 ordens se classificaram na classe 1 (GRE) e 13 ordens na classe 2 (YEL). O tempo de execução registrado é consideravelmente curto; a simulação do modelo ARMAX (5,5,5) foi realizada em menos de 3 minutos e o maior tempo gasto foi de aproximadamente 40 minutos para o modelo ARMAX (30,30,30) sendo das ordens superiores. A duração média dos modelos ARMAX com duas ordens sendo de valor 5 foi de 10 minutos e daqueles com duas ordens do valor 30 foi de 35 minutos. Mesmo assim, todas as simulações se classificaram na classe t1 (GREt).

4.2 PÓRTICO *YELLOW FRAME*

Nesta seção, apresenta-se o experimento realizado no Laboratório de Engenharia Sísmica (do inglês - *Earthquake Engineering Laboratory*) localizado na *University of British Columbia* (UBC) no Canadá que busca estudar o *SHM* de uma estrutura ensaiada no laboratório de 4 andares, conforme mostra a Figura 14. O experimento foi realizado entre os dias 4 e 7 de agosto de 2002, simulando vários cenários de dano. A estrutura estudada situou-se na parte externa do laboratório com o intuito de capturar as alterações ambientais. O presente item e seus respectivos subitens são baseados nas referências: *UBC Test Structure* (2002) e Cardoso R. *et al.* (2019).

Figura 14 – Foto global do YF e o local da instalação, mostra vigas, colunas e contraventamento

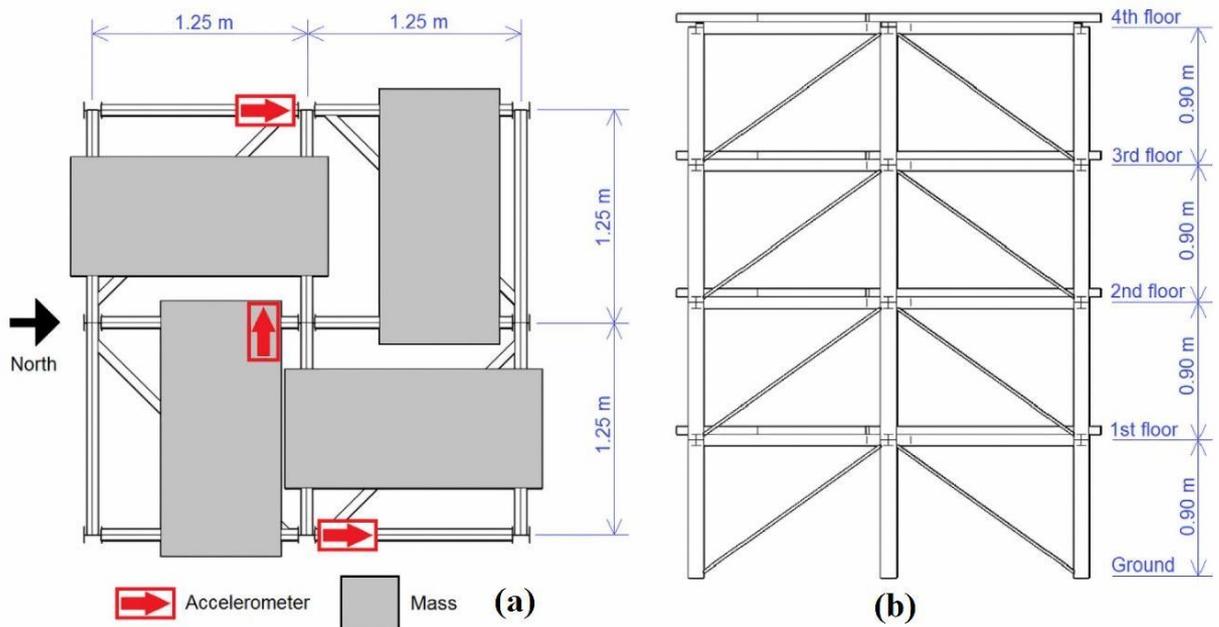


Fonte: Disponibilizado com os dados *UBC Test Structure* (2002).

4.2.1 O sistema estrutural

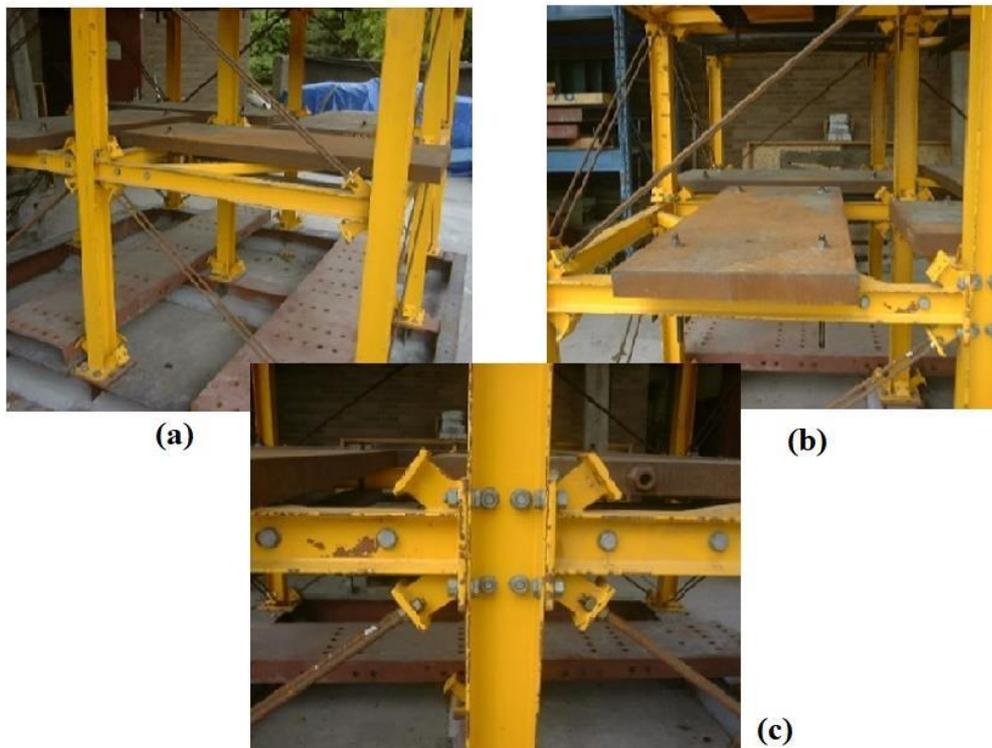
A estrutura analisada é um pórtico metálico amarelo; por isso, veio o nome *Yellow Frame* (YF), constituído por quatro andares com 0,9 m de distância entre eles. Cada andar é formado por três fileiras de vigas metálicas horizontais tanto na direção *x* enquanto na direção *y*; cada fileira é composta por duas vigas de 1,25 m de comprimento separadas por um pilar metálico, conforme a Figura 15 (a). Totalizando em 12 vigas e 9 pilares por andar e com as dimensões globais do pórtico 2,5m x 2,5m x 3,6m (largura x comprimento altura), conforme mostra a Figura 15 (b).

Figura 15 – Esquema da estrutura ensaiada. (a) vista plana; (b) vista leste



Fonte: Cardoso R. *et al.* (2019).

Figura 16 – Detalhes de montagem. (a) a distribuição das lajes nos vãos; (b) a fixação da laje de concreto; (c) detalhe de conexão entre duas vigas e uma coluna



Fonte: Disponibilizado com os dados *UBC Test Structure* (2002).

Os componentes do pórtico são perfis laminados com tensão de escoamento nominal de 300 MPa . As seções foram especialmente produzidas para a estrutura ensaiada; as colunas são perfis de seções $B\ 100 \times 9$ e as vigas são perfis de seções $S\ 75 \times 11$. Na Figura 16 (c) pode-se ver o detalhe de conexão entre duas vigas, uma coluna e barras de contraventamento que também aparecem na Figura 16 (b). O sistema de contraventamento é composto por dois cabos de aço de $1,27\text{ cm}$ de diâmetro dispostos diagonalmente e paralelamente em todos os vãos externos dos andares, conforme mostra a Figura 16 (a).

Para garantir a distribuição do carregamento, a massa foi disposta como lajes de concreto nos quatro vãos de aberturas por andar, conforme ilustra a Figura 16 (b), resultando em: 4 lajes de 1000 kg nos primeiros três andares e 4 lajes de 750 kg no quarto andar. Essa distribuição pode ser conferida na Figura 16 (a) e no esquema apresentado na Figura 15 (a).

O pórtico estudado, *YF*, é instalado em cima de uma laje-base de concreto, denominada de *Ground*, mostrada na Figura 17, num ambiente externo; os nove pilares são aparafusados numa grelha metálica estrutural que, por sua vez, é embutida na laje-base de concreto.

Figura 17 – Detalhe de fixação a estrutura na grelha estrutural embutida na laje-base de concreto



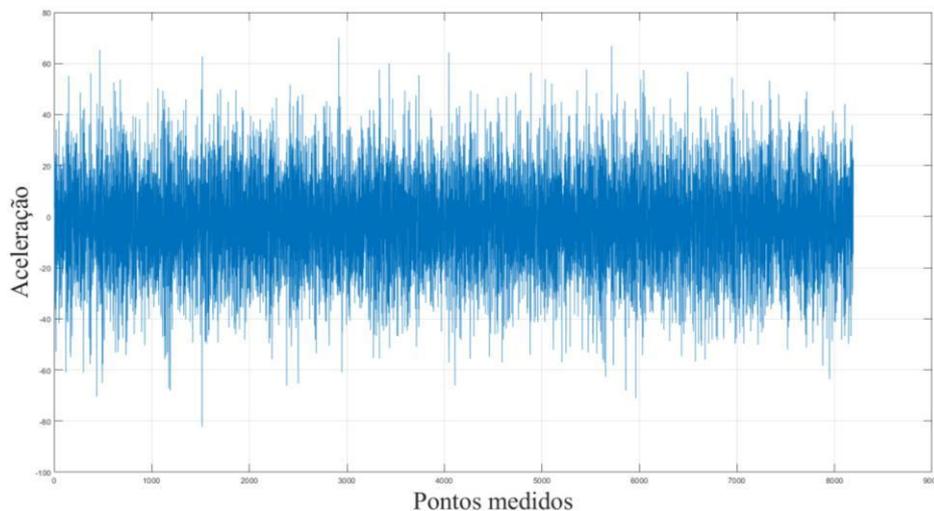
Fonte: Disponibilizado com os dados *UBC Test Structure* (2002).

4.2.2 Sistema de aquisição dos dados

O experimento adotou o sistema *DasyLab* de aquisição dos dados. É um *software* que oferece aquisição de dados em tempo real, análise, controle e a possibilidade de gerar interfaces gráficas (do inglês - *Graphical User Interfaces* - *GUIs*).

Após a montagem da estrutura, realizou-se vários testes com diferentes origens de excitação, a saber: teste da vibração ambiental, teste de *shaker* e teste de impacto. O presente trabalho aborda o teste da vibração ambiental, onde as excitações são geradas pelo vento, passageiros e tráfego ao redor da estrutura. Na Figura 18 encontra-se um exemplo amostral de um sinal capturado por um sensor e empregado na análise.

Figura 18 – Exemplo amostral de um sinal capturado pelo sensor



Fonte: Elaborado pela autora, a partir dos dados coletados (2022).

Quinze (15) sensores foram distribuídos no pórtico ao total; foram instalados três sensores por andar em todos os andares da estrutura, inclusive na laje base (*ground*). O sistema *DasyLab* de aquisição de dados adquire 16 canais de dados em cada ensaio; sendo os primeiros 15 primeiros referentes aos sinais da estrutura e último canal relativo às vibrações ambientais.

Os acelerômetros empregados são do tipo *FBA* e *EPI*; o acelerômetro *FBA* (do inglês – *Force Balance Accelerometer*) é de alta sensibilidade às frequências baixas com faixa de frequência de 20 *Hz*, sendo capaz de medir os movimentos em todas as direções. *EPI* é um tipo melhorado do *FBA* com uma faixa de frequência mais ampla de até 200 *Hz* que permite detectar e estudar altas frequências, também podendo medir os movimentos em todas as direções. Ambos os acelerômetros têm sensibilidade de 5 *V/g*.

4.2.3 Cenários de dano

Os distintos cenários de danos foram simulados pela remoção de elementos de contraventamento e/ou afrouxamento dos parafusos; a descrição detalhada de cada cenário de dano encontra-se na Tabela 18 em ordem crescente da numeração dos casos. A Figura 19 ilustra a estrutura ensaiada em todos os cenários adotados; as barras vermelhas representam os elementos removidos em cada cenário.

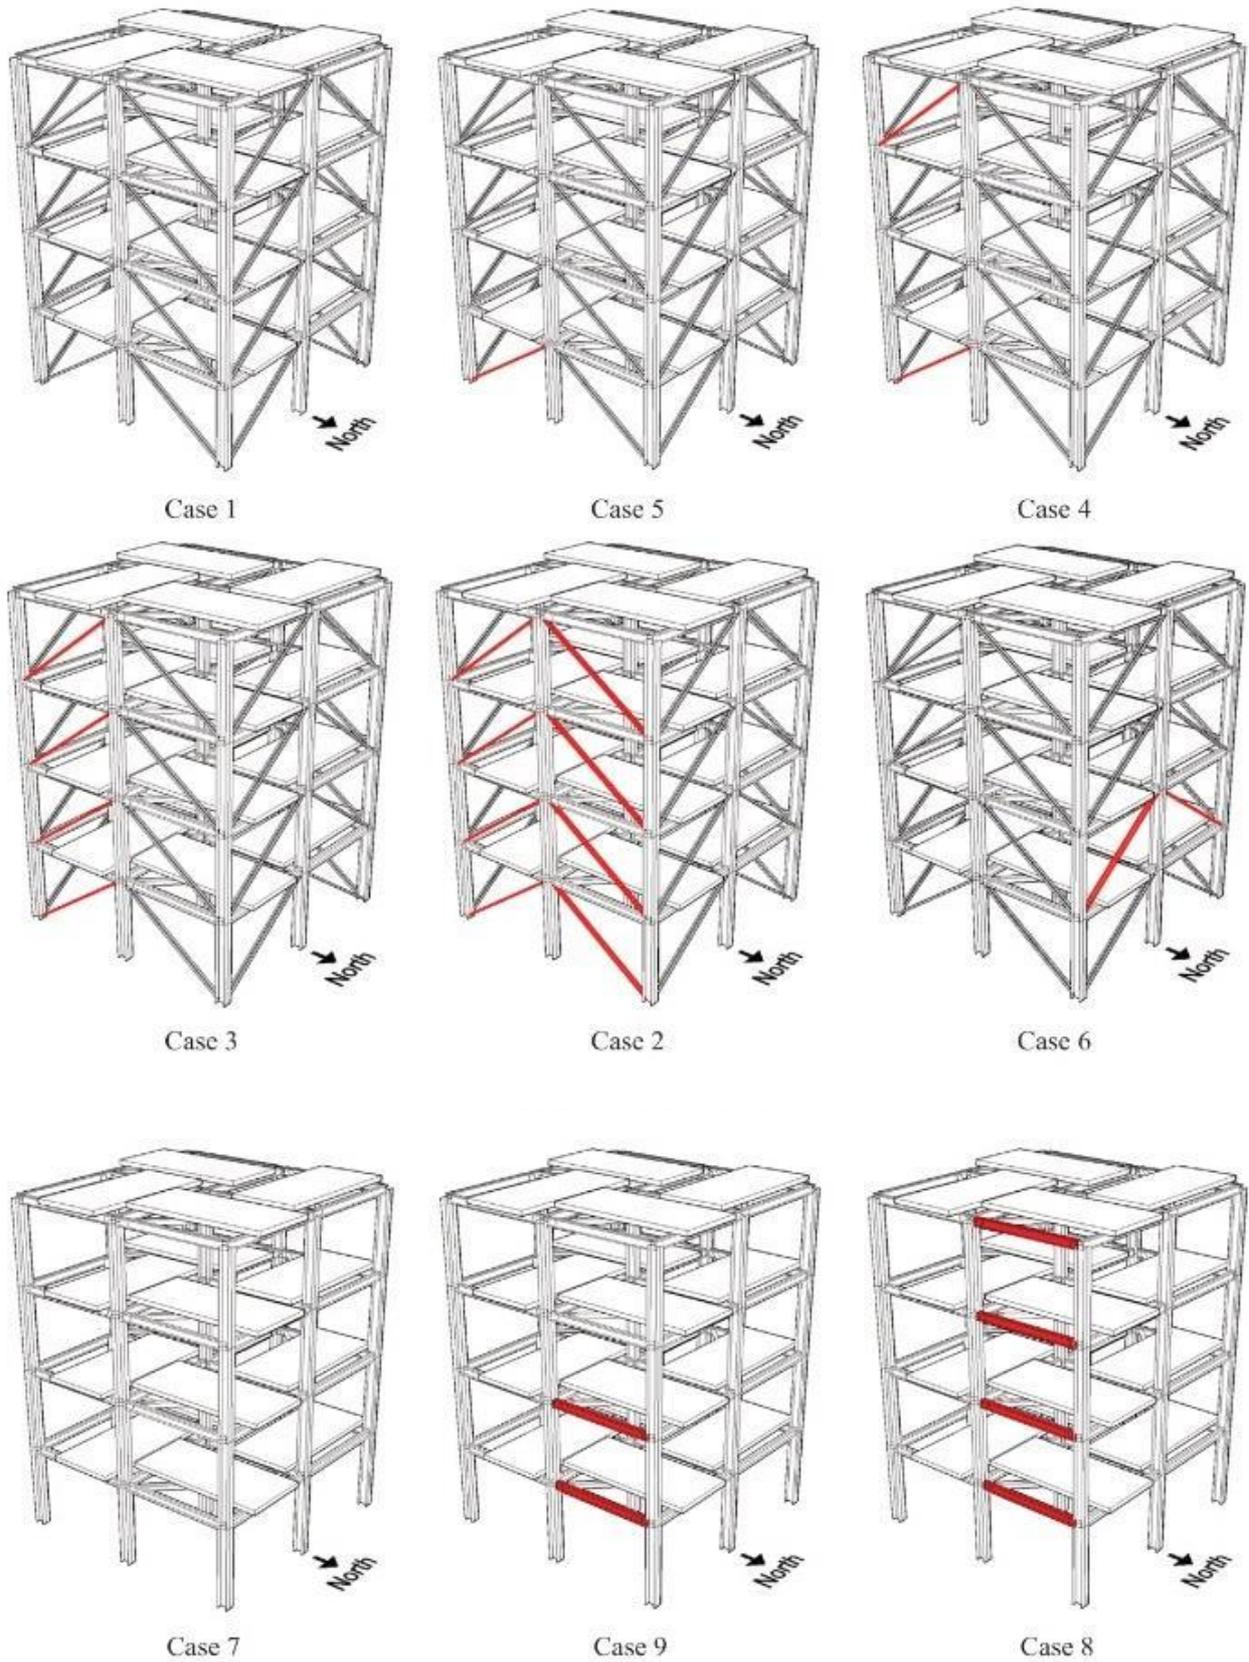
De ponto de vista da intensidade do dano, os cenários são reorganizados na seguinte ordem: 1, 5, 4, 3 e 2 simulam um dano gradual no sistema de contraventamento da estrutura originado pela remoção de elementos de contraventamento. O cenário 1 representa um estado não danificado da estrutura (do inglês – *Baseline*) que funciona como um estado de referência. Os cenários na seguinte ordem: 7, 9 e 8 simulam a progressão de dano na estrutura não contraventadas, provocada pelo afrouxamento dos parafusos. O cenário 6 foi excluído da análise já que tem um número de pontos menor do que nos outros ensaios. Para o presente trabalho foram analisados os cenários 1, 5, 4, 3, 2 e 7 que são organizados gradualmente.

Tabela 18 – Cenários de dano do experimento *YF* com as descrições devidas

Nº - cenários de dano	Descrição de estado de dano
Cenário 1	Estrutura totalmente contraventada.
Cenário 2	Todos os contraventamentos removidos no lado leste.
Cenário 3	Contraventamentos removidos em todos os andares em único lado do canto sudeste.
Cenário 4	Contraventamentos removidos nos 1º e 4º andares no lado sudeste.
Cenário 5	Contraventamentos removidos nos 1º andar no lado sudeste.
Cenário 6	Contraventamentos removidos nos 2º andar na face norte.
Cenário 7	Todos os contraventamentos das faces removidos.
Cenário 8	Cenário 7 + afrouxamento dos parafusos em todos os andares na extremidade da viga na face leste e no lado norte.
Cenário 9	Cenário 7 + afrouxamento dos parafusos <i>bolts</i> nos 1º e 2º andares na extremidade da viga na face leste e no lado norte.

Fonte: Adaptada de Cardoso R. *et al.* (2019).

Figura 19 – Ilustração dos cenários de dano do experimento *YF*; os elementos de cor vermelhas



Fonte: Cardoso R. *et al.* (2019).

4.2.4 Implementação da metodologia

Nesta seção, apresentam-se as informações principais e resumidas sobre a implementação da metodologia.

Cada ensaio do experimento que usa as vibrações ambientais como fonte de excitação foi subdividido em 6000 pontos medidos em 15 acelerômetros ordenados nas colunas de 1 até 15; a vibração ambiental é armazenada na coluna 16. São considerados apenas 6 cenários de dano no total, na seguinte ordem: 1, 5, 4, 3, 2 e 7. Como já mencionado, o ensaio 6 foi removido, por possuir menor número de pontos medidos. Do ensaio 7, apenas os primeiros 6000 pontos são considerados. Assim, a matriz *dataset* possuirá dimensões: $6000 \times 16 \times 60$, a saber: o valor 6000 indica o número de pontos medidos; o valor 16 refere-se ao número de canais; o valor 60 é obtido a partir da multiplicação entre a quantidade dos cenários, que são 6, e a quantidade dos ensaios por cenários, que são 10.

Dados de entrada:

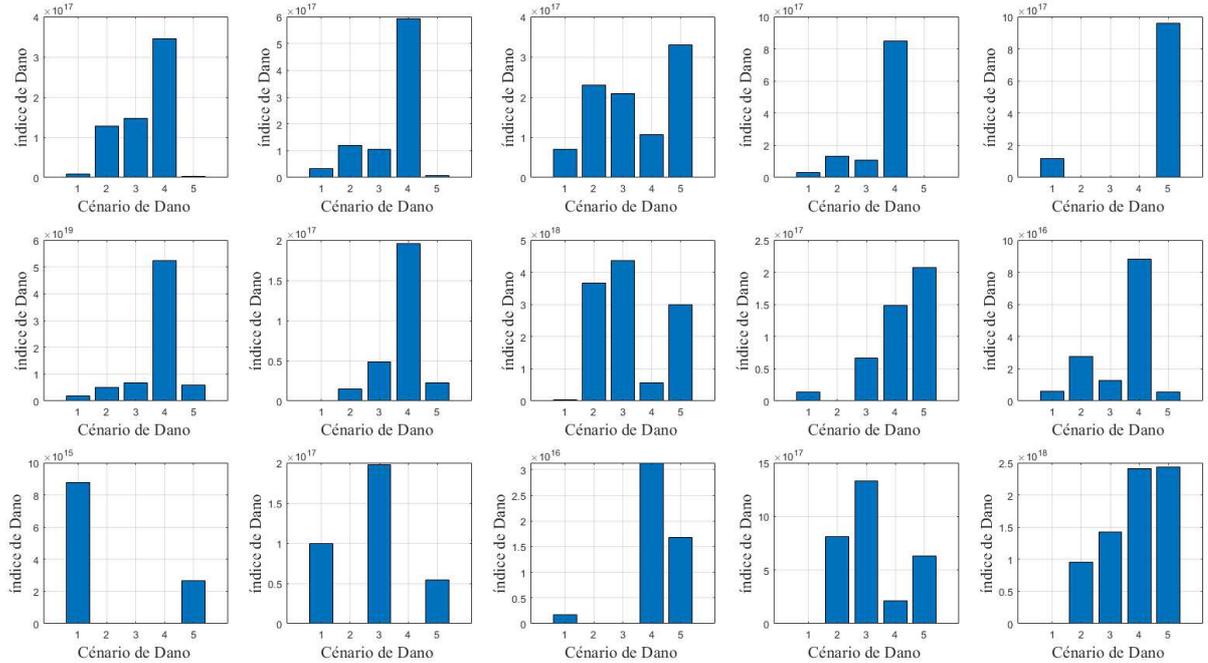
- Nome do arquivo (*ambient.mat* ou *shaker.mat*)
- Ordem do modelo: [*na*] (Para o modelo *AR*)
- Ordem do modelo: [*na*] (Para o modelo *ARMA*)
- Ordem do modelo: [*na nb*] (Para o modelo *ARX*)
- Ordem do modelo: [*na nb nc*] (Para o modelo *ARMAX*)

4.2.5 Resultados

Nesta seção mostram-se os resultados obtidos a partir das simulações realizadas, dispostos em figuras de acordo com as ordens escolhidas para cada modelo. No total, são 78 simulações, resultantes de 6 simulações do modelo *AR*, 20 simulações do modelo *ARMA*, 20 simulações do modelo *ARX* e 32 simulações de *ARMAX*. Assim, foram escolhidas algumas simulações que apresentaram resultados mais favoráveis em relação a todos os sensores. Os resultados do experimento do *YF*, para todos os modelos, mostraram 15 saídas gráficas, já que há 15 sensores, e 5 barras em cada saída gráfica, pois são 5 cenários de dano analisados. A Figura 20 é um exemplo da imagem resultante da simulação do modelo *AR* (5), confirmando o citado anteriormente a respeito do número de saídas gráficas e barras.

A classificação das classes seguiu-se no seguinte padrão: (i) Classe 1 (GRE), quando tem 5 ou 4 barras formando uma escada subindo; (ii) Classe 2 (YEL), quando tem 3 ou 2 barras formando uma escada subindo e (iii) Classe 3 (RED), quando tem menos de 2 barras formando escada.

Figura 20 – Exemplo geral das imagens resultantes das simulações do experimento *YF*



Fonte: Elaborado pela autora (2022).

4.2.5.1 Modelo AR – excitação ambiental

O modelo AR requer apenas uma ordem como dado de entrada. Na Tabela 19 é exibida a classificação do modelo AR, para as seis ordens simuladas, e o tempo de execução dos códigos. A Tabela 20 apresenta os resultados da classificação, de todas as ordens adotadas, para todos os sensores.

Tabela 19 – Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - Pórtico *YF*

AR	Class.	AR 5	AR 10	AR 15	AR 20	AR 25	AR 30
	Tempo (h)		0,042	0,181	0,375	0,721	1,862

Fonte: Elaborado pela autora (2022).

Tabela 20 – Resultado da classificação de todos os sensores do modelo AR - Pórtico *YF*

AR 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Fonte: Elaborado pela autora (2022).

Da Tabela 19, evidencia-se que das 6 ordens simuladas, 4 ordens se classificaram na classe 2 (YEL) e 2 ordens na classe 3 (RED). Os muitos sensores classificados na classe 3 (RED) fizeram com que os modelos AR (10) e AR (20) se classificassem na classe 3 (RED). O tempo de execução registrado é razoavelmente reduzido para as primeiras 4 simulações; a simulação do modelo AR (5) foi realizada em menos de 3 minutos. Os modelos AR (5), AR (10), AR (15) e AR (20) se classificam na classe 1t (GREt); o modelo AR (20) registrou o tempo de 45 minutos de execução de código, sendo a maior duração registrada e classificada na classe 1t (GREt).

Para a simulação AR (25), o tempo registrado de execução de código se-enquadrou na classe 2t (YELt). O tempo de execução de código para o modelo AR (30) ultrapassou o tempo limite de 5 horas estabelecido nesse trabalho, recebendo a cor preta como classificação. Note-se a diferença considerável entre os tempos registrados de modelos sucessivos AR (25) e AR (30).

4.2.5.2 Modelo ARMA – excitação ambiental

O modelo ARMA requer duas ordens como dados de entrada. Na Tabela 21 é exibida a classificação do modelo ARMA, para as vinte simulações, e o tempo de execução dos códigos. A Tabela 22 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARMA (5,5), ARMA (5,10), ARMA (5,15), ARMA (5,20), ARMA (5,25) e ARMA (5,30). A análise de todas as ordens se encontra no Apêndice B.

Tabela 21 – Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada - Pórtico YF

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo	0,053	0,066	0,091	0,116	0,236	0,926
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,065	0,079	0,111	0,196	0,316	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,385	0,450	0,472	0,464	1,697	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,825	1,064	1,295	1,453		

Fonte: Elaborado pela autora (2022).

Tabela 22 – Resultado da classificação de todos os sensores do modelo ARMA - Pórtico *YF*

ARMA 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Fonte: Elaborado pela autora (2022).

Da Tabela 21, evidencia-se que os resultados de todas as ordens são classificados na classe 2 (YEL), exceto para o modelo ARMA (10,5) que se classifica na classe 3 (RED). O tempo de execução não ultrapassou a uma hora para a maioria das simulações e, assim, se classificaram na classe 1t (GREt); com exceção de quatro simulações que contêm ordens superiores, são eles: ARMA (15,30), ARMA (20,30), ARMA (25,30) e ARMA (30,30); fazendo parte da classe 2t (YELt).

4.2.5.3 Modelo ARX – excitação ambiental

O modelo ARX requer duas ordens como dados de entrada. Na Tabela 23 é exibida a classificação do modelo ARX, para as vinte simulações, e o tempo de execução dos códigos. A Tabela 24 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARX (5,5), ARX (5,10), ARX (5,15), ARX (5,20), ARX (5,25) e ARX (5,30). A análise de todas as ordens se encontra no Apêndice B.

Tabela 23 – Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada - Pórtico YF

ARX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo	0,063	0,190	0,318	0,670	1,137	2,179
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,261	0,422	0,082	1,429	2,403	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	2,413	2,480	2,587	2,698	2,880	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	2,201	2,372	2,516	2,619		

Fonte: Elaborado pela autora (2022).

Tabela 24 – Resultado da classificação de todos os sensores do modelo ARX - Pórtico *YF*

ARX 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Fonte: Elaborado pela autora (2022).

Da Tabela 23, evidencia-se que os resultados de todas as ordens são classificados na classe 2 (YEL), exceto para o modelo ARX (10,5) que se classifica na classe 3 (RED). O tempo de execução ultrapassou a uma hora para a maioria das simulações e, assim, se classificaram na classe 2t (YELt); com exceção de sete simulações que contêm ordens superiores, são eles: ARX (5,5), ARX (5,10), ARX (5,15), ARX (5,20), ARX (10,5), ARX (15,5) e ARX (20,5); fazendo parte da classe 1t (GREt).

4.2.5.4 Modelo ARMAX –excitação ambiental

O modelo ARMAX requer três ordens como dados de entrada. Na Tabela 25, é exibida a classificação do modelo ARMAX, para as trinta e duas simulações (32), e o tempo de execução dos códigos. A Tabela 26 apresenta os resultados das classificações das primeiras 6 ordens adotadas para todos os sensores. As seis simulações apresentadas aqui são: ARMAX (5,5), ARMAX (5,10), ARMAX (5,15), ARMAX (5,20), ARMAX (5,25) e ARMAX (5,30). A análise de todas as ordens se encontra no Apêndice B.

Tabela 25 – Resultado da classificação do modelo ARMAX e do tempo gasto de cada ordem simulada - Pórtico *YF*

ARMAX	class.	5.5.5	5.5.10	5.5.15	5.5.20	5.5.25	5.5.30
	Tempo	0,006	0,081	0,111	0,156	0,265	0,428
	class.	5.10.5	5.15.5	5.20.5	5.25.5	5.30.5	
	Tempo	0,073	0,085	0,116	0,169	0,179	
	class.	10.5.5	15.5.5	20.5.5	25.5.5	30.5.5	
	Tempo	0,072	0,105	0,143	0,236	0,406	
	class.	30.30.5	30.30.10	30.30.15	30.30.20	30.30.25	30.30.30
	Tempo	0,412	0,623	0,550	0,664	0,678	0,766
	class.	30.5.30	30.10.30	30.15.30	30.20.30	30.25.30	
	Tempo	0,777	0,922	0,839	0,847	0,773	
	class.	5.30.30	10.30.30	15.30.30	20.30.30	25.30.30	
	Tempo	0,486	0,580	0,751	0,689	0,827	

Fonte: Elaborado pela autora (2022).

Tabela 26 – Resultado da classificação de todos os sensores do modelo ARMAX - Pórtico *YF*

ARMAX 5 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Fonte: Elaborado pela autora (2022).

Da Tabela 25, evidencia-se que os resultados de todas as ordens são classificados na classe 2 (YEL) com tempo de execução consideravelmente curto; em que todas as simulações se enquadram na classe 1 (GREt). o maior tempo gasto foi de aproximadamente 45 minutos para os modelos com ordens maiores. A simulação do modelo ARMAX (5,5,5) foi realizada em menos de 4 minutos e o maior tempo gasto foi de aproximadamente 50 minutos para o modelo ARMAX (25,30,30) sendo das ordens superiores. A duração média dos modelos ARMAX com duas ordens sendo de valor 5 é de 10 minutos e daqueles com duas ordens do valor 30 é de 42 minutos. Mesmo assim, todas as simulações se classificaram na classe t1 (GREt).

4.3 VIADUTO FERROVIÁRIO PK 075+317 – TGV

O viaduto ferroviário analisado, PK 075+317, construído no início dos anos 80, é situado na parte sudeste da França entre as cidades Sens e Soucy no condado de Yonne. Essa ponte, mostrada na Figura 21, tem uma função estratégica em ligar Paris a Lyon através do Trem de Grande Velocidade (do francês- *Train à Grande Vitesse- TGV*).

O presente item e subitens a seguir foram elaborados baseando-se nas referências bibliográficas: Cury et. al (2010); Nunes L. et al. (2020); Cardoso R. et al. (2019); Nunes et al. (2020).

Figura 21- Vista geral do Viaduto PK 075+317



Fonte: Cury e Cremona (2010).

4.3.1 O sistema estrutural

O viaduto estudado é uma estrutura formada por duas vigas mistas composta por um único vão de 17,5 m de comprimento. A passagem repetitiva, diariamente, do trem TGV no viaduto causa uma frequência de excitação entre 4 e 5 Hz que coincide com a primeira frequência natural da estrutura de 5 Hz. A fim de evitar a ocorrência do fenômeno de ressonância na estrutura, precisou-se realizar uma intervenção estrutural para modificar a frequência natural da estrutura e afastá-la da frequência do trem. O reforço estrutural pelo aperto de mancais específicos garante o aumento da sua rigidez e, por sua vez, o incremento de sua primeira frequência natural, conforme ilustrado na Figura 22.

Figura 22 - Detalhes do procedimento de reforço e aperto dos mancais

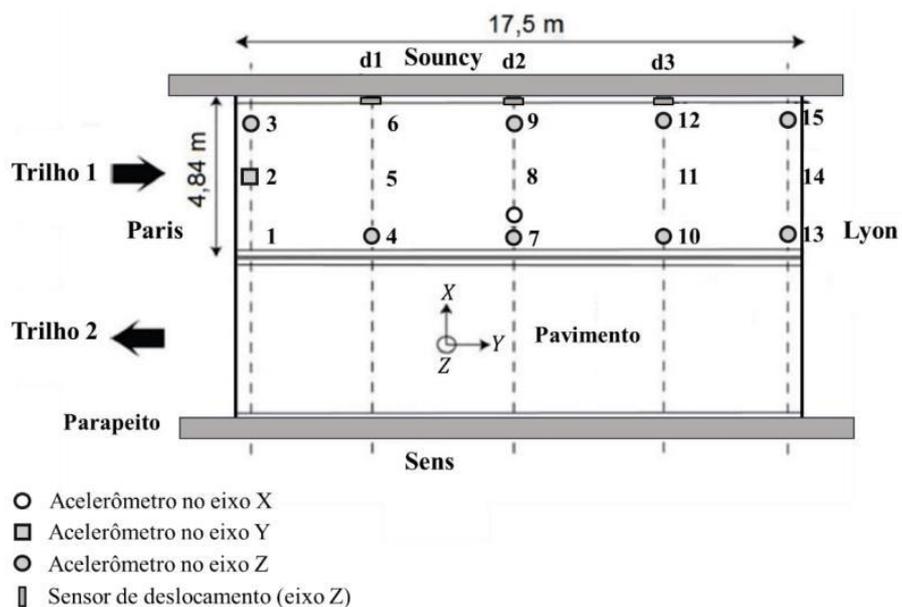


Fonte: Cury e Cremona (2010).

4.3.2 Sistema de aquisição dos dados

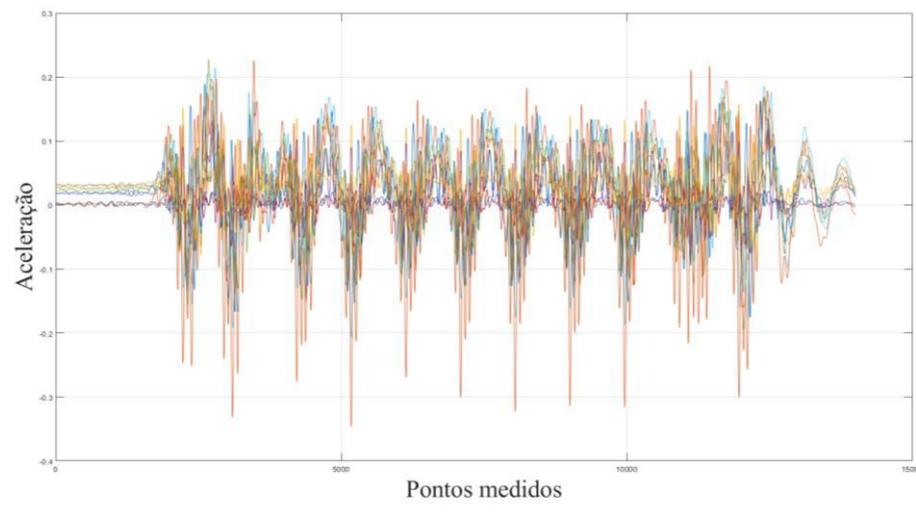
O sistema de aquisição dos dados é formado pelos acelerômetros, instalados embaixo do tabuleiro do viaduto, com taxa de amostragem de 4096 Hz. No total, são 10 acelerômetros que trabalham como sensores para o sistema de monitoramento; oito acelerômetros verticais (eixo z) e dois acelerômetros horizontais (eixo x e eixo y), conforme exposto na Figura 23. Os ensaios foram realizados durante a passagem do trem TGV registrando apenas os sinais dinâmicos da aceleração sem considerar a vibração ambiental. Na Figura 24 encontra-se um exemplo amostral de um sinal capturado por um sensor e empregado na análise.

Figura 23 – Posição dos sensores sob o pavimento.



Fonte: Adaptado de Cury e Cremona (2010).

Figura 24 – Exemplo amostral de um sinal capturado pelo sensor.



Fonte: Elaborado pela autora, a partir dos dados fornecidos (2022).

4.3.3 Cenários de dano

O sistema de monitoramento tem o propósito de avaliar a influência do reforço estrutural em evitar a ressonância da estrutura. A coleta de dados foi realizada em três fases: (i) Antes de efetuar o reforço estrutural, ou seja, o estado de referência, com 15 ensaios dinâmicos, no dia 24 de junho de 2003; (ii) Durante o processo de reforço estrutural, com 13 ensaios dinâmicos, no dia 25 de junho de 2003; e (iii) Depois de efetuar o reforço estrutural, com 13 ensaios dinâmicos, no dia 26 de junho de 2003.

Vale ressaltar que no caso do Viaduto TGV os cenários estudados não são cenários de dano estrutural; pelo contrário, são cenários de melhoria e restauração do viaduto. O emprego do exemplo do TGV nos permite testar a capacidade dos modelos autorregressivos em detectar alterações nas estruturas, sendo de melhoria ou de dano.

4.3.4 Implementação da metodologia

Nesta seção, apresentam-se as informações principais e resumidas sobre a implementação da metodologia. Os três arquivos do TGV, *Sinais_antes.mat*, *Sinais_durante.mat* e *Sinais_depois.mat*, expressam os três cenários analisados antes, durante e depois. O número dos ensaios foi padronizado para 13 ensaios para cada cenário. As 13 matrizes em cada arquivo são da dimensão $[n \times m]$, a dimensão m indica o número dos sensores, que é fixo e do valor 10, e a dimensão n indica o número dos sinais capturados de cada sensor, que não é fixo e de valor que varia em torno de 10000 sinais por sensor.

A fim de padronizar o número dos sinais analisados, evitar os seus resíduos, vistos na Figura 24, e controlar o tempo de execução, fixou-se o número dos sinais como 5000 e dividiu-se o sinal manualmente em 2 matrizes de dimensão [5000 x 10]. Assim, o número de ensaios passa a ser 26 por cenário. Não foi possível simular os modelos autorregressivos ARX e ARMAX pela ausência de um canal que contenha as excitações dinâmicas impostas à estrutura.

Dados de entrada:

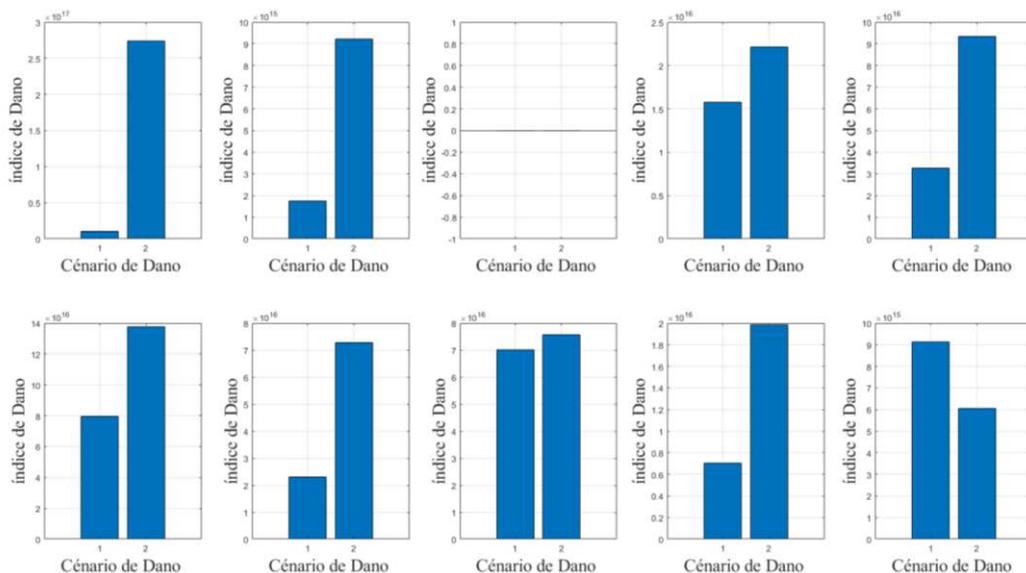
- Arquivos (*Sinais_antes.mat*, *Sinais_durante.mat* e *Sinais_depois.mat*)
- Ordem do modelo: [na nk] (Para o modelo AR)
- Ordem do modelo: [na nc] (Para o modelo ARMA)

4.3.5 Resultados

Nesta seção, mostram-se os resultados alcançados, dispostos em figuras de acordo com as ordens escolhidas para cada modelo. No total, são 26 simulações, resultantes de 6 simulações do modelo AR e 20 simulações do modelo ARMA.

Os resultados do exemplo TGV, para ambos os modelos, mostraram 10 saídas gráficas, já que há 10 sensores, e 2 barras em cada saída gráfica, pois são 2 cenários analisadas de alterações da rigidez devido ao reforço estrutural. A Figura 25 é um exemplo da imagem resultante da simulação do modelo AR (25), confirmando o citado anteriormente a respeito do número de saídas gráficas e de barras.

Figura 25 – Exemplo geral das imagens resultantes das simulações do experimento do Viaduto PK 075+317



Fonte: Elaborado pela autora (2022).

A classificação das classes seguiu o seguinte padrão: (i) Classe 1 (GRE), quando tem duas barras, formando uma escada subindo; (ii) Classe 2 (YEL), quando a primeira barra é ausente e a segunda barra é exibida e (iii) Classe 3 (RED), quando aparece uma escada descendo.

4.3.5.1 Modelo AR - TGV

O modelo AR requer apenas uma ordem como dado de entrada. Na Tabela 27 é exibida a classificação do modelo AR, para as seis ordens simuladas, e o tempo de execução dos códigos. A Tabela 28 apresenta os resultados da classificação, de todas as ordens adotadas, para todos os sensores.

Tabela 27 – Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - Viaduto PK 075+317

AR	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,0188	0,0483	0,1507	0,2511	0,4771	0,6535

Fonte: Elaborado pela autora (2022).

Tabela 28 – Resultado da classificação de todos os sensores do modelo AR - Viaduto PK 075+317

AR 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10

Fonte: Elaborado pela autora (2022).

Da Tabela 27, evidencia-se que os resultados de todas as ordens são classificados na classe 1 (GRE) com tempo de execução consideravelmente curto; a simulação do modelo AR (5) foi realizada em menos de 2 minutos e o maior tempo gasto foi de aproximadamente 40 minutos para o modelo AR (30) sendo das ordens superiores; assim, todas as simulações se classificaram na classe t1 (GREt).

4.3.5.2 Modelo ARMA - TGV

O modelo ARMA requer duas ordens como dados de entrada. Na Tabela 29 é exibido o resultado da análise das classes e do tempo de gasto de execução do código. Na Tabela 30 são mostrados as análises dos sensores de cada simulação realizada com as ordens escolhidas. A análise de todas as ordens se encontram no Apêndice C.

Tabela 29 – Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada - Viaduto PK 075+317

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,0392	0,0553	0,1584	0,1884	0,2944	0,2944
	Class.	10.5	15.5	20.5	25.5	30.5	
	tempo	0,0562	0,1067	0,1561	0,2869	0,4169	
	Class.	30.10	30.15	30.20	30.25	30.30	
	tempo	0,4307	0,4976	0,5516	0,6158	0,6509	
	Class.	10.30	15.30	20.30	25.30		
	tempo	0,4706	0,5623	0,5572	0,5683		

Fonte: Elaborado pela autora (2022).

Tabela 30 – Resultado da classificação de todos os sensores do modelo ARMA - Viaduto PK 075+317

ARMA 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10

Fonte: Elaborado pela autora (2022).

Da Tabela 29, evidencia-se que das vinte ordens simuladas, 8 ordens se classificaram na classe 1 (GRE), 7 ordens na classe 2 (YEL) e 5 ordens na classe 3 (RED). O tempo de execução registrado é consideravelmente curto; a simulação do modelo ARMA (5,5) foi realizada em menos de 3 minutos e o maior tempo gasto foi de aproximadamente 40 minutos para o modelo ARMA (30,30) sendo das ordens superiores; assim, todas as simulações se classificaram na classe t1 (GREt).

Ambos os modelos ARMA (5,15) e ARMA (5,30) mostraram cinco sensores classificados na classe 1 (GRE) e cinco sensores classificados na classe 3 (GRE); com isso, a classificação dos modelos se enquadra na classe 2 (YEL), visto na Tabela 29.

4.4 TIANJIN YONGHE BRIDGE- *TYB*

A estrutura analisada é uma ponte estaiada, de grande porte, com 510 m de extensão e situada na China continental, mostrada nas Figuras 26 e 27 por duas perspectivas; a ponte conecta as duas cidades Tianjin e Hangu, avançando sobre o rio *Yongding New River*. A construção dessa ponte começou no ano 1983 e foi inaugurada no dezembro do ano 1987.

O presente item e subitem a seguir foram elaborados baseando-se nas referências bibliográficas: Alves V e Cury A (2021); Hongjiang Li (2020); Arangio S e Bontempi F (2015); Kaloop M e Hu J. (2015); Li S *et al.* (2014); Shunlong Li *et al.* (2014); Li H. *et al.* (2012); Hui Li *et al.* (2010).

Figura 26 – Vista geral do *TYB*



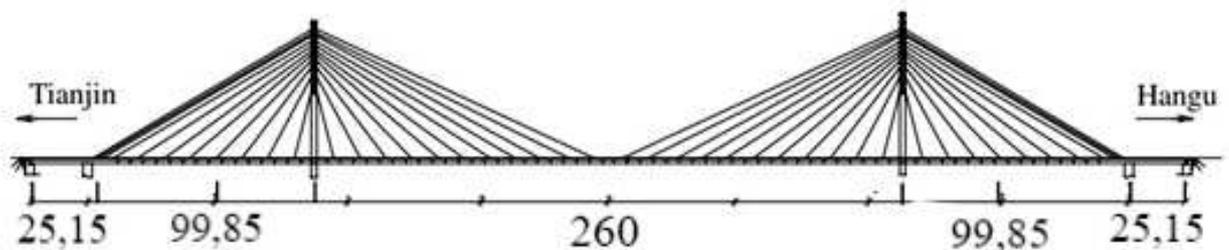
Fonte: Shunlong Li *et al.* (2014).

Figura 27– Vista geral do *TYB*

Fonte: Shunlong Li *et al.* (2014).

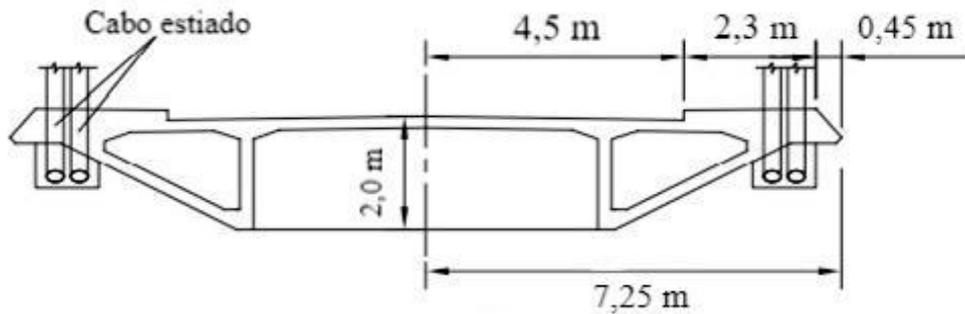
4.4.1 O sistema estrutural

A ponte é constituída por um vão principal de 260 m e dois vãos laterais de 25,15 m e 99,85 m em cada lado, conforme ilustrado na Figura 28, com largura constante ao longo do tabuleiro de 13,6 m, incluindo a estrada para veículos e passagens para pedestres, conforme a seção transversal ilustrada na Figura 29. As torres de concreto, em formato de H, têm 60,5 m de altura e são conectadas através de duas vigas. O tabuleiro, as torres e as vigas são de concreto protendido. Existem 88 pares de cabos, contendo fios de aço de 5mm de diâmetro. O número de fios de aço varia entre 69 e 199 fios por cabo.

Figura 28 – Esquema da Ponte *TYB*

Fonte: Arangio S e Bontempi F (2015).

Figura 29 – Seção transversal do tabuleiro da Ponte TYB



Fonte: Hongjiang Li (2020)

Depois de 19 anos de uso, uma viga no vão principal apresentou dano através da formação de rachadura, de 2 cm, na sua superfície inferior. A ponte passou por um processo de reforço estrutural durante os anos de 2005 até 2007, haja vista a inspeção realizada *in loco*, no ano 2005, que detectou a presença de danos estruturais que ameaçavam a sanidade da ponte. Assim, a ponte foi reabilitada e pôde ser usada novamente no final do ano 2007.

O processo de reforço estrutural incluiu o reforço da viga do vão principal, na qual encontraram-se aberturas preocupantes, conforme mostrado na Figura 30 a e b; além da troca de todos os cabos que apresentaram um grau avançado de corrosão, conforme exibido na Figura 31. Durante a reabilitação estrutural, um sistema de monitoramento estrutural mais elaborado, de longo prazo, foi estabelecido e instalado pela *Harbin Institute of Technology Research Center* a fim de garantir a sanidade futura da ponte. O processo de monitoramento teve o seu início no primeiro mês do ano 2008.

Figura 30 – O dano estrutural encontrado no vão principal. (a) aberturas severas na face inferior da viga. (b) Fratura da barra de aço embutida no concreto.



(a)

(b)

Fonte: Arangio S e Bontempi F (2015).

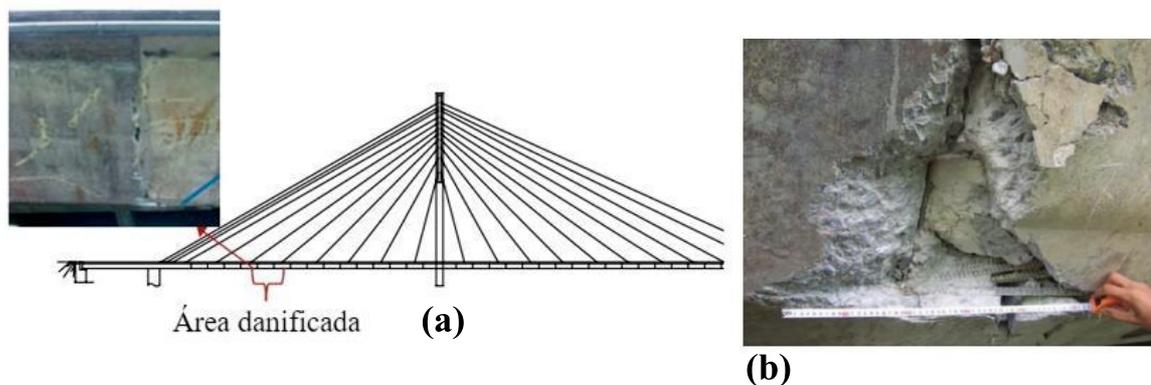
Figura 31 – Danos apresentados em cabos estiadados, mostrando corrosão nos fios de aço após abrir uma janela de inspeção.



Fonte: Arangio S e Bontempi F (2015).

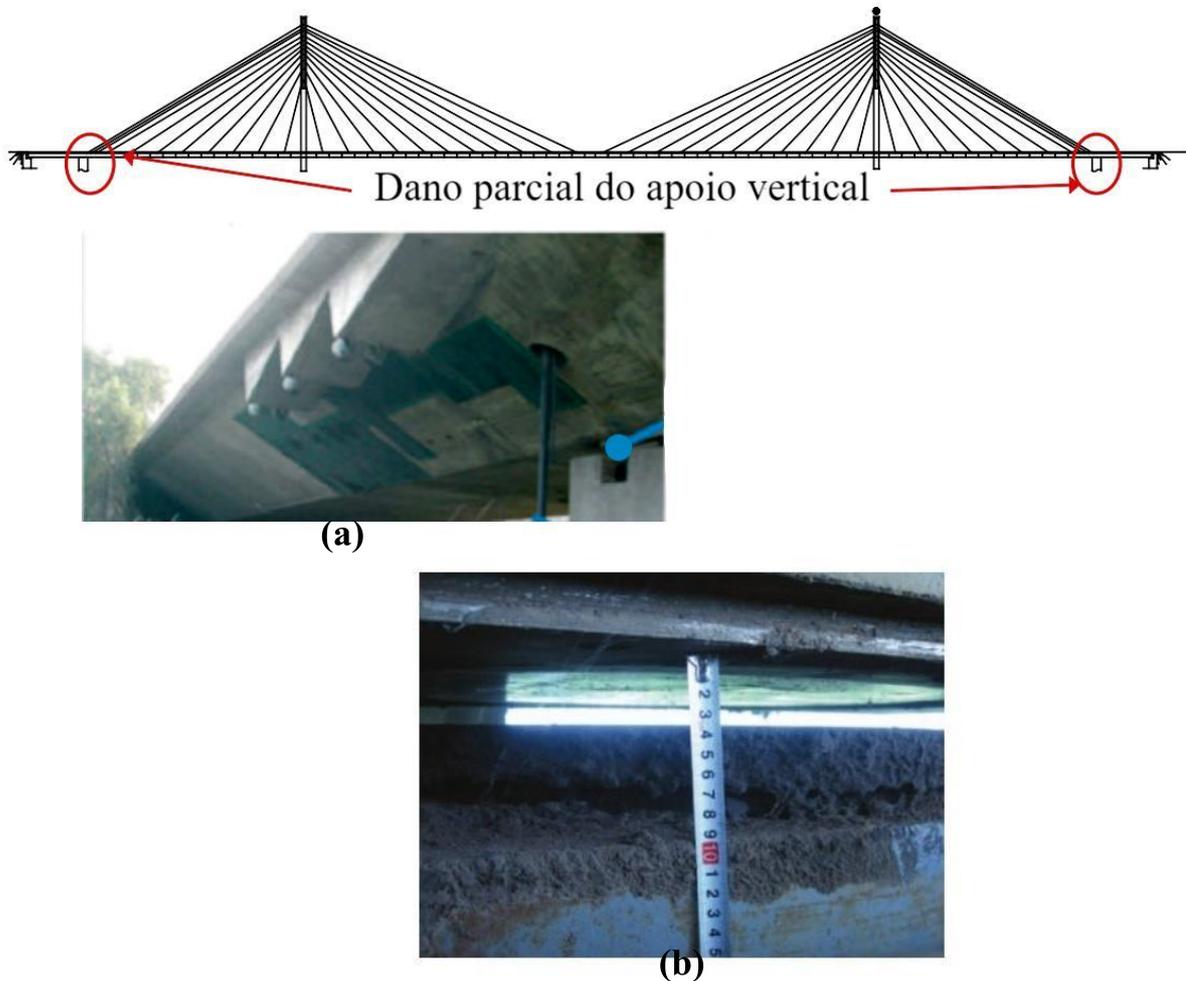
Em agosto de 2008, durante uma inspeção, detectou-se dois tipos diferentes de danos na ponte: (i) rachaduras avançadas, expostas na Figura 32 a, nos trechos de extremidade dos vãos laterais, perto dos apoios, conforme indicado na Figura 32 b; (ii) danos nos pilares devido a uma sobrecarga não prevista em projeto, causando o destacamento do pilar e, por sua vez, uma perda de apoios verticais da estrutura, conforme mostrado na Figura 33 a e b.

Figura 32 – Dano estrutural detectado depois de instalar o SHM. (a) localização da ocorrência do dano. (b) detalhe do dano, rachaduras avançadas.



Fonte: Arangio S e Bontempi F (2015).

Figura 33 – Dano estrutural detectado depois de instalar o SHM. (a) localização da ocorrência do dano, marcado com ponto azul. (b) detalhe do dano, deslocamento do pilar.



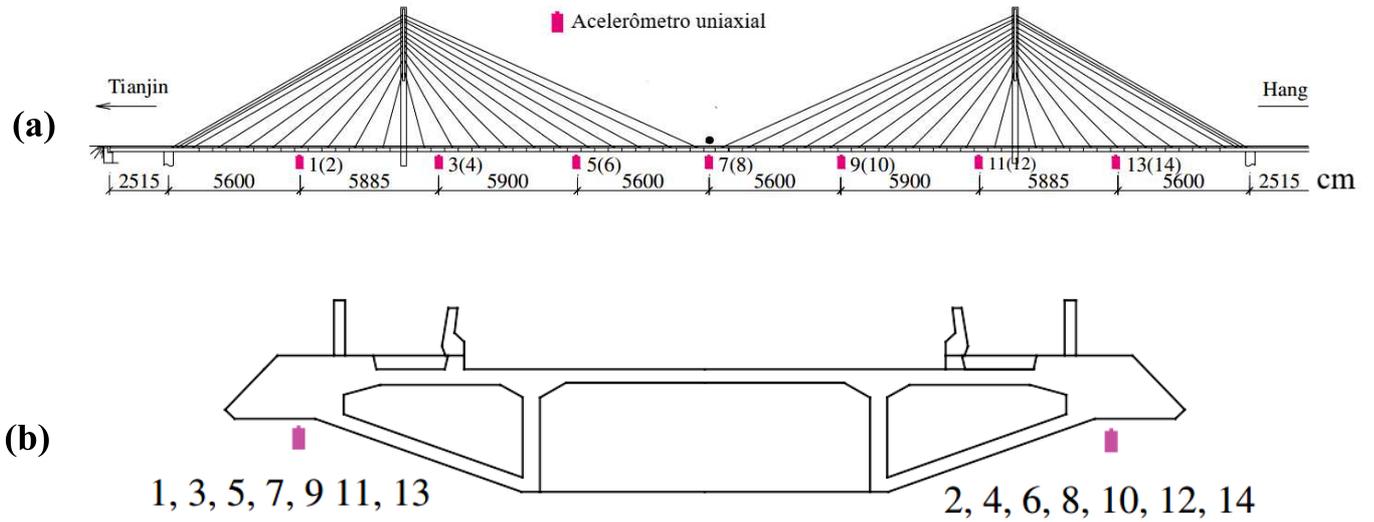
Fonte: Arangio S e Bontempi F (2015).

4.4.2 Sistema de aquisição dos dados

Cerca de 150 sensores diferentes foram distribuídos nos distintos elementos estruturais da ponte, tais como: tabuleiro, torres, vigas, pilares e cabos. Os diferentes sensores têm o objetivo de detectar e registrar as vibrações e as excitações ambientais, formando um sistema de monitoramento estrutural completo e sofisticado.

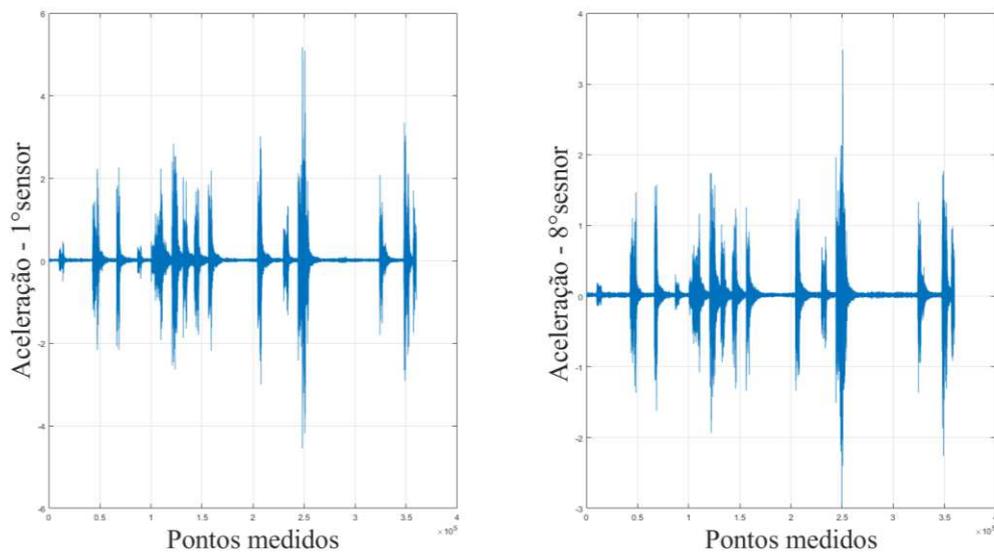
No presente trabalho, analisam-se os sinais registrados dos 14 acelerômetros uniaxiais instalados no tabuleiro do vão principal e dos dois vãos laterais. Na Figura 34a mostra-se a posição dos sensores e o distanciamento entre eles. A taxa de amostragem dos acelerômetros é de 100 Hz. Na Figura 35 encontra-se um exemplo amostral de um sinal capturado por um sensor e empregado na análise.

Figura 34 – Esquema de distribuição dos sensores. (a) ao longo do tabuleiro. (b) ao longo da seção transversal.



Fonte: Hui Li *et al.* (2010).

Figura 35 – Exemplo amostral de um sinal capturado por dois sensores. O 1° na extremidade e o 8° no meio do vão.



Fonte: Elaborado pela autora, a partir dos dados fornecidos (2022).

4.4.3 Cenários de dano

Os dados coletados foram organizados em pastas contendo os arquivos compactados “200801”, “200802”, “200803”, “2008April”, “2008June”, “2008July” e “2008August” que neles são armazenados os sinais de aceleração registrados nos meses de janeiro, fevereiro, março, abril, junho, julho e agosto, respectivamente, em arquivos com extensão “.mat”.

O *dataset* fornecido é formado pelo registro de 1 hora de aceleração para as 24 horas diários, com taxa de amostragem de 100 Hz. Menciona-se que os dados fornecidos apresentaram uma ausência de alguns dias de medição e/ou certas horas do dia; por exemplo, no mês de fevereiro, realizou-se a medição durante apenas três dias.

O monitoramento iniciou-se, de fato, depois de ter a estrutura reabilitada em dezembro do ano de 2007; os primeiros sinais capturados foram em janeiro de 2008. Considera-se que a estrutura no início do monitoramento se encontra sem danos, formando um cenário não danificado da estrutura que funciona como um cenário de referência. A segunda inspeção que ocorreu no agosto do ano de 2008 indicou a ocorrência de dano considerável da estrutura, por isso, espera-se que os sinais coletados próximos a essa data indiquem uma grande alteração em relação aos sinais capturados nos primeiros meses, indicando dano estrutural.

Com o intuito de monitorar a estrutura e ter uma noção melhor do desenvolvimento do dano entre as duas inspeções, escolheu-se quatro terças-feiras, de quatro meses distintos, para analisar a graduação do dano. Os cenários 1 e 2 são próximos entre si, e tem intervalo de apenas duas semanas, sendo assim, as alterações detectadas seriam menores que aquelas detectadas no 3º cenário. Nos dias escolhidos, listados abaixo, a medição foi realizada durante as 24 horas.

- Terça feira: 22/01/2008 (Cenário de Referência- *Baseline*)
- Terça feira: 25/03/2008 (1º Cenário de dano)
- Terça feira: 08/04/2008 (2º Cenário de dano)
- Terça feira: 29/07/2008 (3º Cenário de dano)

4.4.4 Implementação da metodologia

O código elaborado levou em consideração os quatro cenários adotados, simulando apenas os modelos regressivos AR e ARMA. O grande volume de sinais registrados diariamente tornou inviável o uso integral dos mesmos, ultrapassando o limite pré-estabelecido de 5 horas de execução dos códigos. Por isso, optou-se em analisar um intervalo fixo de horas diárias para os quatro dias escolhidos. O intervalo de análise foi de 40 minutos; os dados analisados compreendem os sinais capturados entre 18:00 horas e 18:40 horas.

Com a taxa de amostragem de 100 Hz, 360000 sinais são registrados por hora (60 minutos). Adotou-se um *Sample* de 2 minutos, assim, ter-se-á o *Sample* de 12000 sinais. O *Sample* é um parâmetro que foi definido arbitrariamente; serviu como valor da quantia razoável de sinais para o treinamento do modelo, sem torná-lo demorado. Chegou-se a esse valor depois de avaliar-se outros valores e verificar-se os bons resultados que o modelo foi capaz de apresentar em tempo admissível. Observe-se que uma pequena variação no valor do *Sample* não alteraria bruscamente o resultado.

Simulou-se os modelos autorregressivos AR e ARMA com dois números distintos de *Sample* (*ns*), *ns* de 20 e *ns* de 30 (o máximo possível com o tamanho de *Sample* escolhido); deste modo, é possível analisar o desempenho do modelo e o tempo gasto em ambas as situações.

Encontram-se 17 colunas em cada arquivo de dados fornecidos; a primeira coluna, armazena o tempo de medição; e as próximas colunas, de 2 a 17, armazenam as acelerações coletadas dos 14 sensores.

Dados de entrada:

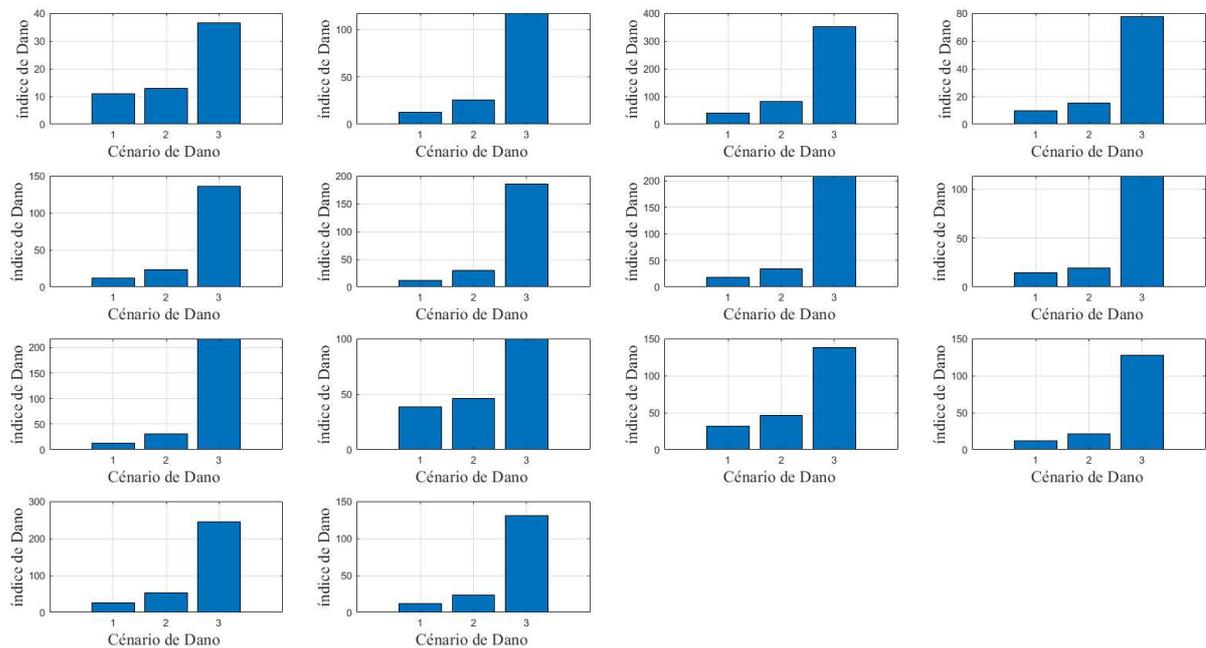
- Arquivos (*d_08_1_22_1.mat* até *d_08_1_22_24.mat*)
- Arquivos (*d_08_3_25_1.mat* até *d_08_3_25_24.mat*)
- Arquivos (*d_08_4_8_1.mat* até *d_08_4_8_24.mat*)
- Arquivos (*d_08_7_29_1.mat* até *d_08_7_29_24.mat*)
- Ordem do modelo: [*na*] (Para o modelo *AR*)
- Ordem do modelo: [*na nc*] (Para o modelo *ARMA*)

4.4.5 Resultados

Nesta seção, mostram-se os resultados das simulações alcançadas ao longo da pesquisa, dispostos em figuras de acordo com as ordens escolhidas para cada modelo. No total, são 26 simulações, resultantes de 6 simulações do modelo AR e 20 simulações do modelo ARMA.

Os resultados da estrutura Tianjin, para ambos os modelos, mostraram 14 saídas gráficas, já que têm 14 sensores e 3 barras em cada saída gráfica, pois são 3 cenários de danos. A Figura 36 é um exemplo da imagem resultante da simulação do modelo AR (5), confirmando o citado anteriormente a respeito do número de saídas gráficas e barras.

Figura 36 – Exemplo geral das imagens resultantes das simulações, com 20 e 30 *Samples*, do experimento do *TYB*



Fonte: Elaborado pela autora (2022).

Para todos os exemplos, o ajuste de número das amostras a serem consideradas foi realizado levando em conta o tempo gasto e a qualidade dos resultados obtidos. A fim de ilustrar o processo de avaliação da escolha do *ns*, mostrou-se a comparação entre duas situações, na qual a primeira considera o *ns* como 20 e a segunda considera o *ns* como 30.

Teoricamente, quanto maior for o número de *Samples* adotado, mais resultados assertivos serão alcançados, mesmo levando mais tempo de execução. Porém, depois de testar ambas as situações, verificou-se que os resultados das simulações com *ns* de 30 não apresentam melhorias em relação às simulações com *ns* de 20; mais ainda, o modelo com 30 *Samples* demorou mais tempo do que o modelo com 20 *Samples*.

A classificação das classes seguiu o seguinte padrão: (i) Classe 1 (GRE), quando tem três barras formando uma escada subindo; (ii) Classe 2 (YEL), quando tem duas barras formando uma escada subindo e (iii) Classe 3 (RED), quando aparece uma escada descendo ou mostra algum erro na plotagem para o sensor.

4.4.5.1 Modelo AR - TYB

O modelo AR requer apenas uma ordem como dado de entrada. Nas Tabelas 31 e 32 são exibidos os resultados da análise das classes e do tempo de gasto de execução do código para as simulações de 20 *Samples* e 30 *Samples*, sucessivamente. Na Tabela 33 mostra-se as

análises dos sensores de cada simulação, com 20 Samples, realizadas com as ordens escolhidas. A análise de todas as ordens se encontram no Apêndice D.

Tabela 31 – Resultado da classificação do modelo AR, com 20 Samples e do tempo gasto de cada ordem simulada - *TYB*

AR-20S	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,0983	0,4878	1,0424	1,7775	3,6241	6,346

Fonte: Elaborado pela autora (2022).

Tabela 32 – Resultado da classificação do modelo AR, com 30 Samples e do tempo gasto de cada ordem simulada - *TYB*

AR-30S	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,143	0,748	1,498	2,761	5,213	7,826

Fonte: Elaborado pela autora (2022).

Tabela 33 – Resultado da classificação de todos os sensores do modelo AR com 20 Samples - *TYB*

AR 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

AR 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

Fonte: Elaborado pela autora (2022).

Com os 20 Samples, o modelo AR apresentou-se das seis ordens simuladas, 5 ordens sendo na classe 1 (GRE) e uma ordem na classe 2 (YEL). Todas as simulações desenvolvidas com 30 Samples se classificaram na classe 1 (GRE). Entretanto, notou-se que as simulações com 30 Samples registraram tempo de execução maior para os mesmos modelos, e suas devidas ordens, realizados com 20 Samples.

Em ambos os casos, o tempo de execução de duas ordens simuladas foram classificadas na classe 1t (GREt), duas ordens na classe 2t (YELt), uma ordem na classe 3t (RED) e o modelo com a ordem AR (30) se classificou-se na cor preta por ultrapassar o limite estabelecido. Observou-se uma diferença considerável entre os tempos registrados de modelos sucessivos AR (25) e AR (30).

4.4.5.2 Modelo ARMA - TYB

O modelo ARMA requer apenas uma ordem como dado de entrada. Nas Tabelas 34 e 35 são exibidos o resultado da análise das classes e do tempo de gasto de execução do código para as simulações de 20 Samples e 30 Samples, sucessivamente. A Tabela 36 apresenta os resultados de análise e classificação das primeiras 6 ordens adotadas para todos os sensores, empregando os 20 Samples. As seis simulações apresentadas aqui são: ARMA (5,5), ARMA (5,10), ARMA (5,15), ARMA (5,20), ARMA (5,25) e ARMA (5,30). A análise de todas as ordens encontram-se no Apêndice D.

Tabela 34 – Resultado da classificação do modelo ARMA, com 20 Samples e do tempo gasto de cada ordem simulada – TYB

ARMA-20S	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,0626	0,1041	0,1631	0,2562	0,4361	0,7288

Class.	10.5	15.5	20.5	25.5	30.5
Tempo	0,1131	0,1593	0,2672	0,4203	0,6287
Class.	30.10	30.15	30.20	30.25	30.30
Tempo	2,3682	0,8464	0,7709	0,7678	0,8489
Class.	10.30	15.30	20.30	25.30	
Tempo	0,8958	0,8838	0,8777	0,7564	

Fonte: Elaborado pela autora (2022).

Tabela 35 – Resultado da classificação do modelo ARMA, com 30 Samples e do tempo gasto de cada ordem simulada – *TYB*

ARMA-30S	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,1006	0,181	0,288	0,4496	0,7548	1,1257
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,1608	0,2558	0,4456	0,6806	1,0462	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	1,0093	1,1987	1,207	1,2691	1,3753	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	1,4081	1,3583	1,4236	1,3609		

Fonte: Elaborado pela autora (2022).

Tabela 36 – Resultado da classificação de todos os sensores do modelo ARMA com 20 Samples – *TYB*

ARMA 5 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

ARMA 5 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

Fonte: Elaborado pela autora (2022).

Com os 20 Samples, o modelo ARMA apresentou 9 simulações com a classe 1 (GRE), 8 simulações com a classe 2 (YEL) e 3 simulações com a classe 3 (RED). Com os 30 Samples, o modelo ARMA apresentou 7 simulações com a classe 1 (GRE), 10 simulações com a classe 2 (YEL) e 3 simulações com a classe 3 (RED). Verificou-se que as simulações com 30 Samples registraram tempo de execução maior para os mesmos modelos, e suas devidas ordens, realizados com 20 Samples.

No modelo ARMA com 20 Samples, o tempo registrado de execução dos códigos foi razoavelmente curto; com a simulação do modelo ARMA (5,5) realizada em menos de 4 minutos. As simulações de todas as ordens se enquadram na classe 1t (GREt) exceto para o modelo ARMA (30,10) que se enquadra na classe 2 (YELt) por registrar mais de duas horas. A duração média dos modelos ARMA com ordem baixas é de 18 minutos e daqueles com duas ordens superiores, com valor de 30, é de 50 minutos.

No modelo ARMA com 30 Samples, 9 ordens simulados enquadraram-se na classe 1t (GREt) e 11 ordens, na classe 2t (YELt) sendo das ordens superiores. A duração média dos modelos ARMA como ordem baixas é de 30 minutos e daqueles com duas ordens superiores, com valor de 30, é de uma hora; o que proporcionou a diferença de classes.

Observa-se que o modelo com 30 samples não apresentou melhoria de classes em relação ao modelo com 20 samples, além de apresentar um aumento no tempo registrado de execução de códigos.

5 CONSIDERAÇÕES FINAIS

O presente abordou o uso de modelos autorregressivos para a construção de um indicador baseado na distância de Mahalanobis a fim de detectar os danos em estruturas como parte de um sistema de Monitoramento da Integridade Estrutural (SHM). Quatro modelos foram analisados (AR, ARMA, ARX, ARMAX) e aplicados a estruturas de pequeno, médio e grande portes, sob diferentes excitações. Ademais, registrou-se e analisou-se o tempo gasto na execução dos códigos de cada modelo.

Em geral, os modelos foram capazes em alcançar o objetivo em detectar os danos estruturais em menos de uma hora para a maioria dos modelos. No total, foram realizadas 234 simulações, conforme resumido a seguir:

- Trinta (30) simulações do modelo AR: 6 simulações para cada ensaio. Sendo eles: Pórtico 3SS, Pórtico *YF*, Viaduto *PK 075+317*, Ponte *TYB 20 Samples* e Ponte *TYB 30 Samples*;
- Cem (100) simulações do modelo ARMA: 20 simulações para cada ensaio. Sendo eles: Pórtico 3SS, Pórtico *YF*, Viaduto *PK 075+317*, Ponte *TYB 20 Samples* e Ponte *TYB 30 Samples*;
- Quarenta (40) simulações do modelo ARX: 20 simulações para cada ensaio. Sendo eles: Pórtico 3SS e Pórtico *YF*;
- Sessenta e quatro (64) simulações do modelo ARMAX: 32 simulações para cada ensaio. Sendo eles: Pórtico 3SS e Pórtico *YF*.

Em termos de qualidade de resultados e tempo de execução, pode-se sumarizar da seguinte forma:

- O modelo AR apresentou os melhores resultados para duas estruturas ensaiadas, o Pórtico 3SS e o Viaduto *PK 075+317*, sendo que todas as simulações realizadas se enquadraram na combinação entre a Classe 1 (GRE) e a Classe 1t (GREt). Na análise da Ponte *TYB* com 20 ou 30 Samples, apenas 30% dos modelos ensaiados enquadraram-se na combinação entre a Classe 1 (GRE) e a Classe 1t (GREt). Porém, 90% das simulações foram classificadas na Classe 1 (GRE) com tempo de execução de código variando entre a Classes 1t, 2t e 3t. Assim, para a Ponte *TYB*, os modelos AR (5) e AR (10) conseguiram a combinação entre a Classe 1 (GRE) e a Classe 1t (GREt).

- O modelo ARMA, de modo geral, apresentou resultados satisfatórios na classificação das simulações para três estruturas ensaiadas; o Pórtico 3SS, o Viaduto *PK 075+317* e a Ponte *TYB*, em que a maioria das simulações se enquadrou nas Classes: Classe 1 (GRE), Classe 2 (YEL), Classe 1t (GREt) e Classe 2t (YELt). Porém, menos de 50% das simulações realizadas se enquadrando na combinação entre a Classe 1 (GRE) e a Classe 1t (GREt); apresentando desvantagem em relação ao modelo AR. Notou-se que os modelos ARMA aplicados nas estruturas Pórtico 3SS e Ponte *TYB*, com 20 e 30 Samples, alcançaram a combinação entre a Classe 1 (GRE) e a Classe 1t (GREt) com simulações de ordens menores. Todavia, para a estrutura Viaduto *PK 075+317*, a combinação foi atingida com simulações de ordens maiores.
- O Modelo ARX apresentou bons resultados para a estrutura ensaiada o Pórtico 3SS, tendo todas as simulações realizadas enquadrando-se na combinação entre a Classe 1 (GRE) e a Classe 1t (GREt). O Modelo ARMAX apresentou resultados razoáveis para a estrutura ensaiada Pórtico 3SS, tendo mais de 50% das simulações realizadas enquadrando-se na combinação entre a Classe 1 (GRE) e a Classe 1t (GREt).

Como recomendações gerais, destacam-se:

- Os modelos ARX e ARMAX são uma extensão dos modelos AR e ARMA, respectivamente, pois consideram a possibilidade de inclusão de variáveis exógenas como regressores. Em outras palavras, os modelos ARX e ARMAX precisam de um canal que contenha as excitações dinâmicas capturadas, o que pode ser difícil em algumas estruturas, conforme o ocorrido na estrutura Viaduto *PK 075+317* abordada no presente trabalho. Caso seja possível a obtenção de arquivo das excitações dinâmicas capturadas, sugere-se o emprego do modelo ARX ao modelo ARMAX, por apresentar melhores resultados com menos tempo gasto.
- Verificou-se que o tempo de execução de códigos dos modelos adotados depende diretamente do valor das ordens escolhidas das simulações. Quanto maior for o valor da ordem, maior será o tempo de execução de seus códigos. Além disso, o tempo depende do número dos sinais adotados para cada cenário de dano estudado e do número de Samples adotado para o treinamento dos

modelos autorregressivos para cada estrutura examinada. Verificou-se que maior número de Samples não, necessariamente, representa sempre uma melhoria nos resultados, mas, certamente, demandará maior tempo de execução.

- Destaca-se a capacidade do modelo AR em alcançar bons resultados, registrando um tempo relativamente curto de execução dos códigos. Os resultados confirmam a bibliografia existente, exaltando as vantagens do modelo AR por ser o mais simples, o menos custoso computacionalmente e, também, por não depender das excitações dinâmicas.
- Assim, recomenda-se o uso do modelo AR de ordens menores, caso não tenha excitações dinâmicas registradas e disponíveis; e/ou o uso do modelo ARX, quando houver excitações dinâmicas registradas.

5.1 TRABALHOS FUTUROS

Como trabalhos futuros, sugere-se:

- a) Utilizar técnicas de otimização a fim de se encontrar as ordens ótimas dos modelos, sem a necessidade de se testar várias combinações distintas;
- b) Desenvolver critérios que permitam determinar a duração mínima necessária do sinal para se calibrar os modelos.
- c) Avaliar outras métricas, além da distância de Mahalanobis, para a definição do indicador de dano;
- d) Acoplar a presente metodologia a outras que permitam localizar e quantificar danos estruturais.

REFERÊNCIAS

- ADAMS, D. E.; FARRAR, C. R. **Classifying linear and nonlinear structural damage using frequency domain ARX models. Structural Health Monitoring.** London, v. 1, n. 2, p. 185-201, 2002.
- AGUIRRE, L. A. (2004). **Introdução à identificação de Sistemas: Técnicas Lineares e Não Lineares aplicadas a Sistemas Reais.** Editora UFMG. 2ª edição.
- AKAIKE, H. (1974). **A new look at the statistical model identification.** IEEE Trans. Automatic Control, 19 (6), 716–723.
- ALVES, V.; CURY, A.; CREMONA, C. **On the use of symbolic vibration data for robust structural health monitoring. Structures and Buildings.** V. 169, p. 715-723, 2016.
- ALVES V, CURY A. **A fast and efficient feature extraction methodology for structural damage localization based on raw acceleration measurements.** Struct Control Health Monit. 2021;28:e2748. Disponível em: <<https://doi.org/10.1002/stc.2748>>. Acesso em: 10 de mai. 2022
- ARANGIO S, BONTEMPI F. (2015) **Structural health monitoring of a cable-stayed bridge with Bayesian neural networks, Structure and Infrastructure Engineering.** 11:4, 575-587. Disponível em: <<http://dx.doi.org/10.1080/15732479.2014.951867>>. Acesso em: 13 de mai. 2022
- AZIM, R., & GÜL, M. (2019). **Damage detection of steel girder railway bridges utilizing operational vibration response. Structural Control and Health Monitoring.** (August), 1–15. Disponível em: <<https://doi.org/10.1002/stc.2447>>. Acesso em: 7 de mai. 2022
- BISHOP, C. (1995). **Neural Networks for Pattern Recognition.** Oxford, UK: Oxford University Press.
- BITTENCOURT, M. CASTRO; Trabalho de conclusão de curso: **Identificação de sistemas dinâmicos lineares; métodos paramétricos e não paramétricos.** Aprovado pela universidade de Brasília, julho de 2007.
- CACHOT, E.; VAYSSADE, T.; VIRLOGEUX, M.; LANCON, H.; HAJAR, Z.; SERVANT, C. **The Millau Viaduct: Ten Years of Structural Monitoring.** Structural Engineering International, v. 25, n. 4, p. 375-380, 2015.
- CARDOSO R. DE A.; CURY A.; BARBOSA F.; **Automated real-time damage detection strategy using raw dynamic measurements.** Publicado no Engineering Structures 196 (2019) 109364; Elsevier, jul. 2019.
- CANO, WAGNER FRANCISCO REZENDE. **Aplicação da análise de séries temporais para detecção e prognóstico de danos em estruturas inteligentes.** Dissertação (mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2015 – Ilha Solteira.

CHATTOPADHYAY, A. et al. **A Multidisciplinary Approach to Health Monitoring and Materials Damage Prognosis for Metallic Aerospace Systems**. [S.l.], 2013. Disponível em: <<http://www.dtic.mil/cgibin/GetTRDoc?Location=U2doc=GetTRDoc.pdfAD=ADA587226>>. Acesso em: 10 de mai. 2022.

Structural health monitoring in smart structures through time series analysis. **Structural Health Monitoring, SAGE Publications**. V. 7, n. 3, p. 231–244, 2008. Available at:< [Structural Health Monitoring in Smart Structures Through Time Series Analysis - Samuel da Silva, Milton Dias Júnior, Vicente Lopes Junior, 2008 \(sagepub.com\)](#)> . Access o n: 22 June 2015.

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

Cury, A., & Cremona, C. (2010). **Novelty detection based on symbolic data analysis applied to structural health monitoring**. Bridge Maintenance, Safety and Management - IABMAS’10, 172– 182.

DATTEO, A., BUSCA, G., QUATTROMANI, G., & CIGADA, A. (2018). **On the use of AR models for SHM: A global sensitivity and uncertainty analysis framework**. Reliability Engineering and System Safety, 170, 99–115. Disponível em: < <https://doi.org/10.1016/j.ress.2017.10.017>> Acesso em: 14 de mar. 2022.

DOEBLING, S. W. et al. **A summary review of vibration-based damage identification methods**. Shock and vibration digest. Citeseer, v. 30, n. 2, p. 91–105, 1998. Disponível em:< [Microsoft Word - LitReview_Journal.doc \(psu.edu\)](#)>. Acesso em: 9 de mar. 2022.

ENTEZAMI, A., & SHARIATMADAR, H. (2017). **An unsupervised learning approach by novel damage indices in structural health monitoring for damage localization and quantification**. Structural Health Monitoring. 1–21. Disponível em :<<https://doi.org/10.1177/1475921717693572>>. Acesso em: 9 de mar. 2022.

Example Usages, Structural Health Monitoring Tools (SHMTools). LA-CC-14-046. LA-UR-14-21093. Los Alamos National Security, LLC. Publicado com MATLAB® R2013a. 30 de maio 2014.

FARRAR, C. R.; SOHN, H. **Pattern recognition for structural health monitoring**. In: **Workshop on Mitigation of Earthquake Disaster by Advanced Technologies**. [s.n.], 2000. Disponível em: <<https://institute.lanl.gov/ei/shm/pubs/mceer00.pdf>>. Acesso em: 4 de mar. 2022

FARRAR, C. R.; WORDEN, K. **An introduction to structural health monitoring**. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, The Royal Society**. V. 365, n. 1851, p. 303–315, 2007. Disponível em: <[An introduction to structural health monitoring | Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences \(royalsocietypublishing.org\)](#)> Acesso em: 4 de mar. 2022

FARRAR, C. R.; LIEVEN, N. A. **Damage prognosis: the future of structural health monitoring. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences.** The Royal Society, v. 365, n. 1851, p. 623–632, 2007. Disponível em: <[Damage prognosis: the future of structural health monitoring | Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences \(royalsocietypublishing.org\)](https://royalsocietypublishing.org/)> . Acesso em: 7 de mar. 2022

FASSOIS, S. D.; SAKELLARIOU, J. S. **Time-series methods for fault detection and identification in vibrating structures. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences.** The Royal Society, v. 365, n. 1851, p. 411–448, 2007. Disponível em: <[Time-series methods for fault detection and identification in vibrating structures | Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences \(royalsocietypublishing.org\)](https://royalsocietypublishing.org/)> . Acesso em: 16 de mar. 2022

FIGUEIREDO E.; PARK G.; FIGUEIRAS J.; FARRAR C. **Worden K. Structural Health Monitoring Algorithm Comparisons Using Standard Data Sets.** Editado pelo Mable Amador, grupo IRM- CAS. Los Alamos National Laboratory; LA – 14393, mar. 2009.

FIGUEIREDO, E., PARK, G., FARRAR, C. R., WORDEN, K., & FIGUEIRAS, J. (2010). **Machine learning algorithms for damage detection under operational and environmental variability. Structural Health Monitoring.** 10(6), 559–572. Disponível em: <<https://doi.org/10.1177/1475921710388971>>. Acesso em: 16 de mar. 2022

FIGUEIREDO, E. et al. **Machine learning algorithms for damage detection under operational and environmental variability.** Structural Health Monitoring. SAGE Publications, v. 10, n. 6, p. 559–572, 2011. Disponível em: <[Machine learning algorithms for damage detection under operational and environmental variability - Eloi Figueiredo, Gyuhae Park, Charles R Farrar, Keith Worden, Joaquim Figueiras, 2011 \(sagepub.com\)](https://sagepub.com/)> . Acesso em: 1 de mar. 2022

_____. **Autoregressive modeling with state-space embedding vectors for damage detection under operational variability.** International Journal of Engineering Science, Elsevier, v. 48, n. 10, p. 822–834, 2010. Disponível em: <[Autoregressive modeling with state-space embedding vectors for damage detection under operational variability - ScienceDirect](https://www.sciencedirect.com/)> . Acesso em: 1 de mar. 2022

FUGATE, M. L.; SOHN, H.; FARRAR, C. R. **Unsupervised learning methods for vibration-based damage detection. In: Proceedings of 18th International Modal Analysis Conference.** IMAC. [s.n.], 2000. p. 18. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.4.3039rep=rep1type=pdf>>. Acesso em: 1 de mar. 2022

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

LAUTOUR, O. R. DE, & OMENZETTER, P. (2010). **Damage classification and estimation in experimental structures using time series analysis and pattern recognition.** Mechanical

Systems and Signal Processing, 24, 1556–1569. Disponível em:< <https://doi.org/10.1016/j.ymssp.2009.12.008>>. Acesso em: 25 de mar. 2022

LOUZADA D.R.; Tese (doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Mecânica, 2013, PUC-Rio. Certificação Digital N° 0821302/CA. **Deteção e caracterização de danos estruturais através de sensores a rede de Bragg e Redes Neurais Artificiais.** Disponível em: <[Microsoft Word - Daniel Ramos Louzada \(puc-rio.br\)](#)>. Acesso em: 17 de mar. 2022

LI H, LI S, JINPING O, LI H. **Reliability assessment of cable-stayed bridges based on structural health monitoring techniques, Structure and Infrastructure Engineering.** 2012; 8:9, 829-845. Disponível em: <<https://doi.org/10.1080/15732479.2010.496856>>. Acesso em: 8 de fev. 2022.

LU, Y.; GAO, F. **A novel time-domain auto-regressive model for structural damage diagnosis. Journal of Sound and Vibration.** Elsevier, v. 283, n. 3, p. 1031–1049, 2005. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0022460X0400584X>>. Acesso em: 13 de fev. 2022

LYNCH, J. P.; SUNDARARAJAN, A.; LAW, K. H.; KIREMIDJIAN, A. S. **Embedding algorithms wireless structural system. In: international conference on advances and new challenges in earthquake engineering research.** 2., 2002, Hong Kong. Proceedings... Hong Kong: Icanecer, 2002. p. 1- 8. . Acesso em: 5 de fev. 2022

Meixedo A. G. **Damage identification in railway bridges based on train induced dynamic responses.** Dissertação apresentada a FACULDADE DE ENGENHARIA UNIVERSIDADE DO PORTO, FEUP. 2021.

NAIR, K. K., KIREMIDJIAN, A. S., & LAW, K. H. (2006). **Time series-based damage detection and localization algorithm with application to the ASCE benchmark structure.** Journal of Sound and Vibration, 291(1-2), 349–368. Disponível em:< [doi:10.1016/j.jsv.2005.06.016](https://doi.org/10.1016/j.jsv.2005.06.016)>. Acesso em: 12 de fev. 2022

NI, Y.; XIA, H.; WONG, K.; KO, J. **In-Service Condition Assessment of Bridge Deck Using Long-Term Monitoring Data of Strain Response.** Journal of Bridge Engineering, v. 17, n. 6, p. 876-885, 2011.

PAIXÃO DA J. L.; SAUSEN A.T.Z.R.; CEZIMBRA A.B.; SAUSEN P.S.; **aplicação de modelos ARX e ARMAX da teoria de identificação de sistemas para predição do tempo de vida de baterias que alimentam dispositivos móveis.** SALÃO DO CONHECIMENTO. XXII Seminário de Iniciação Científica. UNIJUI- 2014.

RYTTER, A. (1993). **Vibrational Based Inspection of Civil Engineering Structures.** Aalborg: Dept. of Building Technology and Structural Engineering, Aalborg University.

UBC Test Structure. Description of Experimental Data Obtained Structural Health Monitoring of UBC Test Structure. Autores: James Beck, Dennis Bernal, Juan Caicedo, Shirley Dyke, Mark Forsyth, Jean-Francois Lord, Anthony Mizumori, Martin Turek and Carlos Ventura. Na University of British Columbia; 4-7 de agt. 2002.

SAITO, T. E YOKOTA, H., 1996. **Evaluation of Dynamic Characteristics of High-Rise Buildings Using System Identification Techniques.** *Journal of Wind Engineering and Industrial Aerodynamics*. 59, 299-307.

SILVA DA S.; JÚNIOR M.D.; JÚNIOR V.L. **Detecção de falhas estruturais utilizando controle estatístico de processos.** DINCON 2005. 4o Congresso Temático de Dinâmica, Controle e Aplicações. UNESP – Campus de Bauru. junho de 2005.

SILVA, S. et al. **Structural damage detection by fuzzy clustering.** *Mechanical Systems and Signal Processing*. Elsevier, v. 22, n. 7, p. 1636–1649, 2008.

SILVA, S.; GONSALEZ, C. G.; LOPES Jr, V. **Structural health monitoring in smart structures through time series analysis.** *Structural Health Monitoring*, SAGE Publications, v. 7, n. 3, p. 231–244, 2008. Disponível em: <[Structural Health Monitoring in Smart Structures Through Time Series Analysis - Samuel da Silva, Milton Dias Júnior, Vicente Lopes Junior, 2008b \(sagepub.com\)](#)> Acesso em: 30 de abr. 2022.

_____. **Adaptive filter feature identification for structural health monitoring in an aeronautical panel.** *Structural Health Monitoring*, SAGE Publications, v. 10, n. 5, p. 481–489, 2011. Disponível em:< [Adaptive filter feature identification for structural health monitoring in an aeronautical panel - Samuel da Silva, Camila Gianini Gonzalez, Vicente Lopes, 2011 \(sagepub.com\)](#)> . Acesso em: 7 de jan. 2022.

SOHN, H.; CZARNECKI, J. A.; FARRAR, C. R. **Structural health monitoring using statistical process control.** *Journal of Structural Engineering, American 57 Society of Civil Engineers*. v. 126, n. 11, p. 1356–1363, 2000. Disponível em: <[Structural Health Monitoring Using Statistical Process Control | Journal of Structural Engineering | Vol 126, No 11 \(ascelibrary.org\)](#)> . Acesso em: 25 de abr. 2022.

SOHN, H.; FARRAR, C. R. **Damage diagnosis using time series analysis of vibration signals.** *Smart materials and structures*, IOP Publishing, v. 10, n. 3, p. 446, 2001. Disponível em: <[Damage diagnosis using time series analysis of vibration signals - IOPscience](#)> . Acesso em: 30 de mai. 2022.

SOHN, H. et al. **Structural health monitoring using statistical pattern recognition techniques.** *Transactions-American Society of Mechanical Engineers Journal of Dynamic Systems Measurement And Control*, Citeseer, v. 123, n. 4, p. 706–711, 2001. Disponível em: <https://institute.lanl.gov/ei/shm/pubs/jdsmc_01.pdf> . Acesso em: 21 de mai. 2022.

SOHN, H.; ALLEN, D. W.; WORDEN, K.; FARRAR, C. R. **Structural damage classification using extreme value statistics.** *Journal of Dynamic Systems, Measurement and Control*, Los Alamos, v. 127, n. 1, p. 125–132, 2005.

SOHN, H. **Effects of environmental and operational variability on structural health monitoring.** *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society, v. 365, n. 1851, p. 539–560, 2007. Disponível em: <[Effects of environmental and operational variability on structural health monitoring | Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences \(royalsocietypublishing.org\)](#)> . Acesso em: 24 de mai. 2022.

WOLD, H. (1954). **A study in the analysis of stationary time series**. 2nd edition Estocolmo: Almquist & Wiksel.

WORDEN, K, & DULIEU-BARTON, J. M. (2004). **An Overview of Intelligent Fault Detection in Systems and Structures**. International Journal of Structural Health Monitoring, 3(1), 85–98.

WORDEN, K. et al. **The fundamental axioms of structural health monitoring**. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Science, The Royal Society, v. 463, n. 2082, p. 1639–1664, 2007. Disponível em: <[The fundamental axioms of structural health monitoring | Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences \(royalsocietypublishing.org\)](#)>. Acesso em: 15 de mai. 2022.

XU, YOU-LIN; XIA, YONG. **Structural Health Monitoring of Long-Span Suspension Bridges**. Taylor e Francis Group, 2012.

ZENNARO, L (2019). **What caused the Genoa bridge collapse – and the end of an Italian national myth?** Disponível em: <[What caused the Genoa bridge collapse – and the end of an Italian national myth? | Cities | The Guardian](#)>. Acesso em: 4 de mar. 2022.

Apêndice A – Resultados da classificação- Pórtico 3SS

Tabela A.1– Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - Pórtico 3SS

AR	Class.	AR 5	AR 10	AR 15	AR 20	AR 25	AR 30
	Tempo (h)	0,009	0,020	0,035	0,061	0,097	0,273

Tabela A.2– Resultado da classificação de todos os sensores do modelo AR - Pórtico 3SS

AR 5	S1	S2	S3	S4
AR 10	S1	S2	S3	S4
AR 15	S1	S2	S3	S4
AR 20	S1	S2	S3	S4
AR 25	S1	S2	S3	S4
AR 30	S1	S2	S3	S4

Tabela A.3– Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada - Pórtico 3SS

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,031	0,037	0,050	0,058	0,078	0,119
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,033	0,047	0,064	0,093	0,168	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,187	0,199	0,266	0,301	0,327	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,150	0,191	0,220	0,281		

Tabela A.4 – Resultado da classificação de todos os sensores do modelo ARMA - Pórtico 3SS

ARMA 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 5 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 5 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 5 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 5 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 5 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 10 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 15 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 20 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 25 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 10 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 15 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 20 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMA 25 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4

Tabela A.5 – Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada - Pórtico 3SS

ARX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,014	0,021	0,034	0,058	0,090	0,265
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,024	0,040	0,067	0,107	0,279	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,283	0,291	0,291	0,389	0,297	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,2720	0,2715	0,275	0,286		

Tabela A.6 – Resultado da classificação de todos os sensores do modelo ARX - Pórtico 3SS

ARX 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 5 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 5 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 5 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 5 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 5 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 10 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 15 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 20 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 25 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 10 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4

ARX 15 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 20 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARX 25 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4

Tabela A.7 – Resultado da classificação do modelo ARMAX e do tempo gasto de cada ordem simulada - Pórtico 3SS

ARMAX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,042	0,060	0,073	0,099	0,130	0,192
	Class.	5.10.5	5.15.5	5.20.5	5.25.5	5.30.5	
	Tempo	0,060	0,073	0,113	0,127	0,248	
	Class.	10.5.5	15.5.5	20.5.5	25.5.5	30.5.5	
	Tempo	0,062	0,076	0,102	0,140	0,278	
	Class.	30.30.5	30.30.10	30.30.15	30.30.20	30.30.25	30.30.30
	Tempo (h)	0,429	0,479	0,510	0,584	0,619	0,679
	Class.	30.5.30	30.10.30	30.15.30	30.20.30	30.25.30	
	Tempo	0,565	0,672	0,600	0,628	0,688	
	Class.	5.30.30	10.30.30	15.30.30	20.30.30	25.30.30	
	Tempo	0,543	0,492	0,506	0,587	0,654	

Tabela A.8 – Resultado da classificação de todos os sensores do modelo ARMAX - Pórtico 3SS

ARMAX 5 5 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 5 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 5 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 5 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 5 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 5 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 10 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 15 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 20 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4

ARMAX 5 25 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 30 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 10 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 15 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 20 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 25 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 5 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 5	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 10	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 15	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 20	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 25	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 5 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 10 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 15 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 20 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 30 25 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 5 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 10 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 15 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 20 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4
ARMAX 25 30 30	Sensor 1	Sensor 2	Sensor 3	Sensor 4

Apêndice B – Resultados da classificação- Pórtico *YF*

Tabela A.9 – Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - Pórtico *YF*

AR	Class.	AR 5	AR 10	AR 15	AR 20	AR 25	AR 30
	Tempo (h)	0,042	0,181	0,375	0,721	1,862	6,650

Tabela A.10 – Resultado da classificação de todos os sensores do modelo AR - Pórtico *YF*

AR 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
AR 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Tabela A.11 – Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada - Pórtico *YF*

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,053	0,066	0,091	0,116	0,236	0,926
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,065	0,079	0,111	0,196	0,316	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,385	0,450	0,472	0,464	1,697	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,825	1,064	1,295	1,453		

Tabela A.12 – Resultado da classificação de todos os sensores do modelo ARMA - Pórtico *YF*

ARMA 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 10 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARMA 15 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 20 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 25 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 10 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 15 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARMA 20 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMA 25 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Tabela A.13 – Resultado da classificação do modelo ARX e do tempo gasto de cada ordem simulada - Pórtico *YF*

ARX	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,063	0,190	0,318	0,670	1,137	2,179
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,261	0,422	0,082	1,429	2,403	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	2,413	2,480	2,587	2,698	2,880	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	2,201	2,372	2,516	2,619		

Tabela A.14 – Resultado da classificação de todos os sensores do modelo ARX - Pórtico *YF*

ARX 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARX 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 10 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 15 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 20 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 25 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 10 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARX 15 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 20 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARX 25 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Tabela A.15 – Resultado da classificação do modelo ARMAX e do tempo gasto de cada ordem simulada - Pórtico YF

ARMAX	Class.	5.5.5	5.5.10	5.5.15	5.5.20	5.5.25	5.5.30
	Tempo (h)	0,006	0,081	0,111	0,156	0,265	0,428
	Class.	5.10.5	5.15.5	5.20.5	5.25.5	5.30.5	
	Tempo	0,073	0,085	0,116	0,169	0,179	
	Class.	10.5.5	15.5.5	20.5.5	25.5.5	30.5.5	
	Tempo	0,072	0,105	0,143	0,236	0,406	
	Class.	30.30.5	30.30.10	30.30.15	30.30.20	30.30.25	30.30.30
	Tempo (h)	0,412	0,623	0,550	0,664	0,678	0,766
	Class.	30.5.30	30.10.30	30.15.30	30.20.30	30.25.30	
	Tempo	0,777	0,922	0,839	0,847	0,773	
	Class.	5.30.30	10.30.30	15.30.30	20.30.30	25.30.30	
	Tempo	0,486	0,580	0,751	0,689	0,827	

Tabela A.16 – Resultado da classificação de todos os sensores do modelo ARMAX - Pórtico *YF*

ARMAX 5 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 10 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 15 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 20 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 25 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 30 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 10 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARMAX 15 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 20 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 25 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 10 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

ARMAX 30 15 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 20 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 30 25 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 5 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 10 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 15 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 20 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14
ARMAX 25 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
	S10	S11	S12	S13	S14

Apêndice C – Resultados da classificação - Viaduto Ferroviário PK 075+317 – TGV

Tabela A.17 – Resultado da classificação do modelo AR e do tempo gasto de cada ordem simulada - viaduto PK 075+317

AR	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,0188	0,0483	0,1507	0,2511	0,4771	0,6535

Tabela A.18 – Resultado da classificação de todos os sensores do modelo AR - viaduto PK 075+317

AR 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
AR 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10

Tabela A.19 – Resultado da classificação do modelo ARMA e do tempo gasto de cada ordem simulada - viaduto PK 075+317

ARMA	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,0392	0,0553	0,1584	0,1884	0,2944	0,2944
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,0562	0,1067	0,1561	0,2869	0,4169	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	0,4307	0,4976	0,5516	0,6158	0,6509	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,4706	0,5623	0,5572	0,5683		

Tabela 4 – Resultado da classificação de todos os sensores do modelo AR - viaduto PK 075+317

ARMA 5 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 5 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 10 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 15 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 20 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 25 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 30 5	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 30 10	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 30 15	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10

ARMA 30 20	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 30 25	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 30 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 10 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 15 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 20 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10
ARMA 25 30	S1	S2	S3	S4	S5
	S6	S7	S8	S9	S10

Apêndices D – Resultados da classificação - TYB

Tabela A.21 – Resultado da classificação do modelo AR, com 20 Samples, e do tempo gasto de cada ordem simulada - TYB

AR - 20S	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,0983	0,4878	1,0424	1,7775	3,6241	6,346

Tabela A.22 – Resultado da classificação de todos os sensores do modelo AR com 20 Samples – TYB

AR 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

Tabela A.23 – Resultado da classificação do modelo AR, com 30 Samples, e do tempo gasto de cada ordem simulada - TYB

AR - 30S	Class.	AR5	AR10	AR 15	AR 20	AR25	AR 30
	Tempo (h)	0,143	0,748	1,498	2,761	5,213	7,826

Tabela A.24 – Resultado da classificação de todos os sensores do modelo AR com 30 Samples - TYB

AR 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
AR 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

Tabela A.25 – Resultado da classificação do modelo ARMA, com 20 Samples, e do tempo gasto de cada ordem simulada - TYB

ARMA-20S	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,0626	0,1041	0,1631	0,2562	0,4361	0,7288
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,1131	0.1593	0,2672	0,4203	0,6287	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	2,3682	0,8464	0,7709	0,7678	0,8489	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	0,8958	0,8838	0,8777	0,7564		

Tabela A.26 – Resultado da classificação de todos os sensores do modelo ARMA com 20 Samples - TYB

ARMA 5 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

ARMA 5 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 10 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 15 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 20 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 25 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

ARMA 30 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 10 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 15 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 20 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 25 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

Tabela A.27 – Resultado da classificação do modelo ARMA, com 30 Samples, e do tempo gasto de cada ordem simulada - TYB

ARMA-30S	Class.	5.5	5.10	5.15	5.20	5.25	5.30
	Tempo (h)	0,1006	0,181	0,288	0,4496	0,7548	1,1257
	Class.	10.5	15.5	20.5	25.5	30.5	
	Tempo	0,1608	0,2558	0,4456	0,6806	1,0462	
	Class.	30.10	30.15	30.20	30.25	30.30	
	Tempo	1,0093	1,1987	1,207	1,2691	1,3753	
	Class.	10.30	15.30	20.30	25.30		
	Tempo	1,4081	1,3583	1,4236	1,3609		

Tabela A.28 – Resultado da classificação de todos os sensores do modelo ARMA com 30 Samples - TYB

ARMA 5 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 5 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

ARMA 5 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 10 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 15 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 20 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 25 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 5	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 10	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 15	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 20	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		

ARMA 30 25	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 30 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 10 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 15 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 20 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		
ARMA 25 30	S1	S2	S3	S4
	S5	S6	S7	S8
	S9	S10	S11	S12
	S13	S14		