



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFRAESTRUTURA E DESENVOLVIMENTO
ENERGÉTICO

VANESSA CORDEIRO DE BONA

**IDENTIFICAÇÃO DE DANOS EM ESTRUTURAS USANDO MODELO PREDITOR
BASEADO EM TÉCNICAS DE APRENDIZAGEM DE MÁQUINAS**

Tucuruí-PA

2019

VANESSA CORDEIRO DE BONA

**IDENTIFICAÇÃO DE DANOS EM ESTRUTURAS USANDO MODELO PREDITOR
BASEADO EM TÉCNICAS DE APRENDIZAGEM DE MÁQUINAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Infraestrutura e Desenvolvimento Energético do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Infraestrutura e Desenvolvimento Energético. Área de concentração: Estruturas.

Orientador: Alexandre Luiz Amarante Mesquita.
Coorientador: Rafael Suzuki Bayma.

VANESSA CORDEIRO DE BONA

**IDENTIFICAÇÃO DE DANOS EM ESTRUTURAS USANDO MODELO PREDITOR
BASEADO EM TÉCNICAS DE APRENDIZAGEM DE MÁQUINAS**

Dissertação apresentada a o Programa de Pós-Graduação em Engenharia de Infraestrutura e Desenvolvimento Energético do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Infraestrutura e Desenvolvimento Energético. Área de concentração: Estruturas.

Orientador: Alexandre Luiz Amarante Mesquita.
Coorientador: Rafael Suzuki Bayma.

Aprovado em 04 de outubro de 2019.

BANCA EXAMINADORA:

Dr. Alexandre Luiz Amarante Mesquita/ UFPA – Orientador

Dr. Rafael Suzuki Bayma / UFPA – Coorientador

Dr. Plinio Glauber Carvalho dos Prazeres / UFPA – Examinador Interno

Dr. Marcus Vinicius Girão de Moraes / UNB – Examinador Externo

BONA, VANESSA CORDEIRO DE

Identificação de danos em estruturas usando modelo preditor baseado em técnicas de aprendizagem de máquinas. / VANESSA CORDEIRO DE BONA. — 2019.

88 f. : il. color.

Orientador(a): Prof. Dr. Alexandre Luiz Amarante Mesquita

Coorientador(a): Prof. Dr. Rafael Suzuki Bayma

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia de Infraestrutura e Desenvolvimento Energético, Núcleo de Desenvolvimento Amazônico em Engenharia, Universidade Federal do Pará, Tucuruí, 2019.

1. Identificação de danos . 2. Vibrações . 3. Aprendizagem de Maquinas . 4. Máquina de Vetores de Suporte . I. Título.

CDD 624

Dedico este trabalho ao meu pai Vilmar
de Bona, a minha mãe Maria e minha irmã
Beatriz.

AGRADECIMENTOS

Agradeço inicialmente a Deus pela vida. Agradeço aos meus pais, por tudo que fizeram para minha vida e formação profissional, minha irmã sempre me incentivando nos momentos difíceis.

Agradeço a professora Andrea Barata, que durante o término da graduação em Engenharia Civil nos informou sobre o processo seletivo de mestrado e destacou a importância da continuação dos estudos e qualificação profissional. Assim como os demais professores que seguem contribuindo para a formação de profissionais qualificados.

Agradeço ao meu orientador Prof. Dr. Alexandre Mesquita, por disponibilizar este tema de trabalho e dar todo apoio durante esse período de desenvolvimento da dissertação. Assim como, agradeço aos professores Plínio Glauber e Rafael Bayma pela ajuda em temas específicos relacionados a modelagem de estruturas.

Agradeço a Jusley Souza pela amizade, por toda ajuda e apoio durante o período de desenvolvimento da dissertação. E também aos demais colegas de mestrado que tive a oportunidade de conhecer.

RESUMO

O aumento na quantidade de novas edificações e a existência de inúmeras construções antigas, sejam de pequeno médio ou grande porte, chamam a atenção para a necessidade de medidas que mantenham a qualidade, segurança e vida útil das estruturas. A realização de inspeções e monitoramentos independentemente da idade da edificação, tornam-se indispensáveis para detectar a existência de danos principalmente na sua fase inicial, evitando a sua propagação ou consequências graves que se originam devido a um colapso da estrutura, por conta do elevado grau de deterioração e inexistência de técnicas para recuperação. Baseando-se nesses aspectos, a presente dissertação tem como objetivo geral realizar a detecção de danos em estruturas usando a abordagem de aprendizagem de máquinas (*machine learning*) que integra três técnicas: inicialmente aplica-se o *Ensemble Empirical Mode Decomposition (EEMD)* que faz um processamento dos sinais e busca adequá-los para aplicação do Modelo Auto Regressivo (AR) gerando os atributos, que servirão como padrões de entrada para o classificador *Support Vector Machine (SVM)*. Os dados utilizados para aplicação dos métodos são provenientes da modelagem de vigas de aço bi-apoiadas, íntegras e com regiões danificadas, pelo *Software* de Análise Estrutural *SAP 2000*. Tendo como referência a criação das estruturas por elementos finitos, foram aplicados dois tipos de carregamentos. O primeiro caso de carregamento aleatório atuando em apenas um ponto da viga e o segundo caso com três carregamentos simultâneos em três pontos da viga. Conforme as variações de localização e grau de severidade dos danos, o estudo buscou avaliar a capacidade dos modelos preditores em classificar os dados corretamente. Nas análises com maiores perdas de massa, os valores de acurácia são mais elevados, diminuindo de acordo com a redução da geometria do dano, pois os sinais de deslocamento se tornam similares ao da estrutura íntegra. Em relação a quantidade de carregamentos, o método demonstrou melhor desempenho e acurácia nos casos com três cargas simultâneas.

Palavras-Chave: Identificação de danos; Vibrações; Aprendizagem de Máquinas; Máquina de vetores de suporte.

ABSTRACT

The increase in the number of new buildings and the existence of countless old buildings, whether small or large, call attention to the need for measures that maintain the quality, safety and useful life of the structures. Inspections and monitoring, regardless of the age of the building, are essential to detect the existence of damage, especially in its initial phase, avoiding its propagation or serious consequences that originate due to a collapse of the structure, due to the high degree deterioration and no recovery techniques. Based on these aspects, this dissertation has the general objective of detecting damage in structures using the machine learning approach, which integrates three techniques: initially the Ensemble Empirical Mode Decomposition (EEMD) is applied a processing of the signals and seeks to adapt them for the application of the Auto Regressive Model (AR) generating the attributes, which will serve as input patterns for the Support Vector Machine (SVM) classifier. The data used to apply the methods come from the modeling of bi-supported steel beams, intact and with damaged regions, by the SAP 2000 Structural Analysis Software. With reference to the creation of the structures by finite elements, two types of loads were applied . The first case of random loading acting in only one point of the beam and the second case with three simultaneous loads in three points of the beam. According to variations in the location and degree of severity of the damage, the study sought to assess the ability of the predictive models to classify the data correctly. In the analyzes with greater mass losses, the accuracy values are higher, decreasing according to the reduction of the damage geometry, as the signs of displacement become similar to the integral structure. Regarding the number of loads, the method demonstrated better performance and accuracy in cases with three simultaneous loads.

Keywords: Damage identification; Vibrations; Machine Learning; Support vector machine.

LISTA DE FIGURAS

Figura 2.1 - Origem das manifestações patológicas na construção civil. (Adaptado de HENRIQUES, 2001; <i>apud</i> SACCHI, SOUZA, 2016).....	19
Figura 2.2 - Configurações genéricas de fissuras em função do tipo de solicitação predominante. Fonte: Souza e Ritter (1998).	20
Figura 2.3 - Configuração do modelo de edifício: elevação e modelo real. Fonte: Xu e Chen (2004)..	24
Figura 2.4 - Modelo Experimental do Prédio. Fonte: Pines e Salvino (2010).....	25
Figura 2.5 - Simulação de elemento finito da viga em balanço com sensores de entalhe intermediário e piezocerâmicos. Fonte: Rezaei e Taheri (2010).....	26
Figura 2.6 - Configuração experimental da viga em balanço. Fonte: Rezaei e Taheri (2010).	27
Figura 2.7 - Modelo de viga danificado. Fonte: Meredith <i>et al.</i> (2012).....	28
Figura 2.8 - Seções dos elementos viga-coluna. Fonte: Amari e Darvishan (2015).....	28
Figura 2.9 - Obtenção das IMFs pela decomposição do sinal s usando o EMD. Fonte: WANG <i>et al.</i> (2012).....	30
Figura 2.10 - Obtenção das IMFs pela decomposição do sinal s usando o EEMD. Fonte: WANG <i>et al.</i> (2012).....	30
Figura 2.11 - Espectro tempo-frequência fatiado a 300 Hz baseado (a) no EMD e (b) no EEMD. Fonte: Wang <i>et al.</i> (2012).....	31
Figura 2.12 - Processo de análise de séries temporais. Fonte: Autoria Própria.....	33
Figura 2.13 - Modelos para séries temporais. Fonte: Autoria Própria.	34
Figura 2.14 - Quatro componentes responsáveis pela não-estacionariedade de séries temporais. Fonte: Autoria Própria.....	34
Figura 2.15 - Principais grupos no Machine Learning. Fonte: Autoria Própria.	36
Figura 2.16 - Realização do Treinamento.Fonte: Autoria Própria.	36
Figura 2.17 - Realização da predição. Fonte: Autoria Própria.	36
Figura 2.18 - Características das SVMs. Fonte: Adaptado de Smola <i>et al.</i> (1999b <i>apud</i> LORENA E CARVALHO, 2003).	38
Figura 3.1 - Fluxograma do processo EMD. Fonte: Adaptado de Lei <i>et al.</i> (2013).....	43
Figura 3.2 - Fluxograma do processo EEMD. Fonte: Adaptado de Lei <i>et al.</i> (2013).....	46
Figura 3.3 - Cálculo da distância d entre os hiperplanos $w \cdot x + b = 1$ e $w \cdot x + b = -1$. Fonte: Lorena e Carvalho (2003).....	48
Figura 3.4 - (a) Conjuntos de dados não linear; (b) Fronteira não linear no espaço de entradas; (c) Fronteira linear no espaço de características. Fonte: Lorena e Carvalho (2007).....	54
Figura 4.1 - Definições de parâmetros para a modelagem das estruturas. Fonte: Autoria Própria.	58
Figura 4.2 - Estudo de convergência para uma viga em balanço. Fonte: Ajeje <i>et al.</i> (2011).	59
Figura 4.3 -Esquema para análise com aplicação da carga no centro. Fonte: Autoria própria, 2019. ..	60
Figura 4.4 - Refinamento da malha de elementos sólidos. Fonte: Autoria própria, 2019.	60
Figura 4.5 - Esquema da viga íntegra e aplicação do carregamento. Fonte: Autoria Própria, 2019.	61
Figura 4.6 - Esquema da viga danificada e aplicação do carregamento. Fonte: Autoria Própria, 2019.61	
Figura 4.7 - Vista inferior da viga com geometria de dano triangular. Fonte: Autoria Própria,2019.	61
Figura 4.8 - Sinal aleatório aplicado na estrutura. Fonte: Autoria Própria, 2019.	62
Figura 4.9 - Esquema de aplicação com três carregamentos na viga íntegra. Fonte: Autoria própria, 2019.	63
Figura 4.10 - Etapas principais do <i>Classification Learner</i> . Fonte: Autoria Própria, 2019.	65
Figura 5.1 - Gráfico de convergência da malha. Fonte: Autoria Própria, 2019.....	69
Figura 5.2 - Primeira IMF da análise de 2.8% de perda de massa. Fonte: Autoria própria, 2019.	70
Figura 5.3 - Segunda IMF da análise de 2.8% de perda de massa. Fonte: Autoria própria, 2019.	71
Figura 5.4 - Primeira IMF da análise com 2.0% de perda de massa. Fonte: Autoria própria, 2019.	72

Figura 5.5 - Segunda IMF da análise com 2.0% de perda de massa. Fonte: Autoria própria, 2019.	73
Figura 5.6 - Primeira IMF da análise com 1.0% de perda de massa. Fonte: Autoria própria, 2019.	74
Figura 5.7 - Segunda IMF da análise com 1.0% de perda de massa. Fonte: Autoria própria, 2019.	74
Figura 5.8 - Primeira IMF da análise (2.8%). Fonte: Autoria Própria, 2019.....	76
Figura 5.9 - Segunda IMF da análise (2.8%). Fonte: Autoria Própria, 2019.....	76
Figura 5.10 - Primeira IMF da análise (2.0%). Fonte: Autoria Própria, 2019.....	78
Figura 5.11 - Segunda IMF da análise (2.0%). Fonte: Autoria Própria, 2019.....	78
Figura 5.12 - Primeira IMF da análise (1.0%). Fonte: Autoria Própria, 2019.....	79
Figura 5.13 - Segunda IMF da análise (1.0%). Fonte: Autoria Própria, 2019.....	80

LISTA DE TABELAS

Tabela 2.1 - Classificação de anomalias quanto à espessura das aberturas. Fonte: Oliveira (2012).	21
Tabela 3.1 - Principais funções Kernel aplicadas. Fonte: Adaptado de DATAFLAIR TEAM (2017).	56
Tabela 4.1 - Propriedades gerais das vigas. Fonte: Aatoria própria, 2019.	59
Tabela 4.2 - Definição da geometria dos danos. Fonte: Aatoria própria, 2019.	62
Tabela 5.1 - Frequências das malhas com diferentes números de elementos. Fonte: Aatoria própria 2019.	68
Tabela 5.2 - Discretização e deslocamentos verticais das malhas. Fonte: Aatoria Própria, 2019.	68
Tabela 5.3 - Descrição dos dados aplicados na análise. Fonte: Aatoria Própria, 2019.	70
Tabela 5.4 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	71
Tabela 5.5 - Descrição dos dados aplicados na análise. Fonte: Aatoria Própria.	72
Tabela 5.6 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	73
Tabela 5.7 - Descrição dos dados aplicados na análise. Fonte: Aatoria Própria, 2019.	74
Tabela 5.8 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	75
Tabela 5.9 - Descrição dos dados no segundo caso de análise (2.8%). Fonte: Aatoria Própria, 2019. .	76
Tabela 5.10 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	77
Tabela 5.11 - Descrição dos dados no segundo caso de análise (2.0%). Fonte: Aatoria Própria, 2019.	77
Tabela 5.12 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	78
Tabela 5.13 - Descrição dos dados no segundo caso de análise (1.0%). Fonte: Aatoria Própria, 2019.	79
Tabela 5.14 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.	80

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Considerações Gerais	14
1.2	Objetivos do Trabalho	17
1.2.1	Objetivo Geral.....	17
1.2.2	Objetivos Específicos.....	17
1.3	Estrutura do Trabalho	18
2	REVISÃO BIBLIOGRÁFICA	19
2.1	Danos em estruturas da Construção Civil	19
2.2	Métodos Tradicionais para avaliação da integridade de estruturas	22
2.3	Breve histórico das principais aplicações do EMD e EEMD	23
2.3.1	Pesquisas e Aplicações em Estruturas da Construção Civil.....	23
2.3.2	Principal desvantagem do método <i>EMD</i> e comparação com o <i>EEMD</i>	29
2.4	Séries temporais e os Modelos Auto Regressivos (<i>AR</i>)	32
2.5	<i>Machine Learning</i>	35
2.5.1	<i>Support Vector Machine (SVMs)</i>	37
3	FUNDAMENTAÇÃO TEÓRICA	40
3.1	<i>Empirical Mode Decomposition (EMD)</i>	40
3.2	<i>Ensemble Empirical Mode Decomposition (EEMD)</i>	44
3.2.1	Algoritmo <i>EEMD</i>	44
3.3	Modelo Auto Regressivo (<i>AR</i>)	47
3.4	<i>Support Vector Machine (SVM)</i>	47
3.4.1	<i>SVM</i> - Linear com Margens Rígidas	47
3.4.2	<i>SVM</i> - Margens Suaves	52
3.4.3	<i>SVM</i> - Não Lineares	53
3.4.3.1	Funções Kernel.....	56
4	ESTUDO DE CASO	57
4.1	Modelagem das vigas pelo SAP 2000	57
4.2	Etapas da modelagem.....	58
4.3	Esquema para análise de convergência da Malha	58
4.4	Esquema para análise com modelos preditores	61
4.5	Esquema de aplicação do código com as técnicas <i>EEMD</i> , <i>AR</i> e <i>SVM</i>	63
4.5.1	<i>Classification Learner – Toolbox (MATLAB)</i>	65
5	ANÁLISES E RESULTADOS.....	68
5.1	Análise de Convergência da Malha.....	68

5.2	Identificação de danos usando modelos preditores.....	69
5.2.1	Primeira análise EEMD, AR e SVM.....	69
5.2.1.1	Análise com 2.8% de perda de massa	70
5.2.1.2	Análise com 2.0% de perda de massa	72
5.2.1.3	Análise com 1.0% de perda de massa	73
5.2.2	Segundo caso de análise: <i>EEDM</i> , AR e <i>SVM</i>	75
5.2.2.1	Análise com 2.8% de perda de massa	75
5.2.2.2	Análise com 2.0% de perda de massa.....	77
5.2.2.3	Análise com 1.0 % de perda de massa	79
6	CONCLUSÃO.....	81
6.1	Sugestões para trabalhos futuros	82
7	REFERÊNCIAS.....	83

1 INTRODUÇÃO

1.1 Considerações Gerais

O desenvolvimento e execução de projetos nas diferentes áreas de engenharia devem ser subsidiados em aspectos essenciais como segurança, funcionalidade e durabilidade. A inexistência ou negligência em alguns desses aspectos possibilitam a geração de consequências para a estrutura, como a ocorrência de regiões danificadas e a diminuição do seu desempenho. Esses danos podem ser considerados como fenômenos que tendem a ocasionar prejuízos ou até incidentes inesperados ou catastróficos, sua identificação e análise são imprescindíveis para determinação das origens, características e gravidade, visando facilitar o emprego de medidas corretivas que possam manter o desempenho e segurança da estrutura.

Doebbling *et al.* (1996) consideram que um método de inspeção deve satisfazer algumas condições básicas, como: a robustez, confiabilidade e objetividade; a competência para identificar a existência, localidade e o grau dos danos, poder fornecer dados para estimar o período restante de serviço, ou seja, independente do objeto a ser inspecionado devem ser adotados alguns requisitos básicos para garantir a qualidade dos resultados e fornecer informações suficientes para tomada de decisões futuras.

Nesse âmbito, a maioria dos métodos de detecção de danos desenvolvidos e em estudo baseiam-se em quatro pressupostos básicos, tais como detecção, localização, avaliação e consequência, essenciais para o controle geral de uma estrutura que esteja em manutenção ou sendo monitorada pela presença de danos. Chen *et al.* (2014) definem ainda o sistema de monitoramento da saúde estrutural como “o processo de estabelecer algum conhecimento das condições estruturais atuais ou implementar uma estratégia de detecção de danos [...]”.

Tendo em vista a importância de se manter a qualidade e desempenho de qualquer tipo de estrutura da construção civil e a existência de inúmeras construções antigas, que necessitam de manutenção e monitoramento para garantir sua integridade estrutural, o presente trabalho tem como intuito empregar um método que tem sido estudado e aplicado como indicador de falhas em componentes mecânicos, tal como engrenagens e mancais (CHENG *et al.*, 2008).

O método no presente trabalho para indicar danos em componentes estruturais de edificações usa como dados principais as respostas de deslocamentos das estruturas. Este método faz uso da modelagem de sinal da estrutura usando séries temporais, tal como os

modelos Auto Regressivos (AR), resultando em uma representação com um menor número de critérios. Entretanto, estes modelos AR aplicáveis a sinais estacionários e sistemas lineares, buscam analisar o dano que traz alguma não linearidade ao sistema. Sendo necessário assim um prévio processamento de sinais para então realizar a aplicação do método AR com eficiência.

Desta maneira, é aplicada inicialmente no sinal de vibração a técnica *Ensemble Empirical Mode Decomposition (EEMD)*, em português Conjunto de Decomposição em Modos Empíricos), que é considerada como o melhoramento da técnica tradicional *Empirical Mode Decomposition (EMD)*, Decomposição em Modos Empíricos). A técnica tradicional *EMD* decompõe um sinal de vibração em vários sinais elementares, denominados como *Intrinsic Mode Functions (IMFs - Funções de Modo Intrínseco)*. Conforme Rajeswari *et al.* (2015), uma das principais vantagens do *EMD* é que a decomposição é auto-adaptativamente determinada pela natureza do sinal obtido, porém a técnica possui uma série de desvantagens que podem tornar os resultados da análise duvidosos, um dos principais problemas é denominado como *Mode Mixing* (mistura de modos). Como forma de superar esse problema citado do *EMD*, o método melhorado *EEMD* faz a adição de um ruído no sinal original, partindo do princípio que “o ruído branco adicionado povoaria todo o espaço de tempo-frequência uniformemente com os componentes constituintes de diferentes escalas [...]” (WU e HUANG, 2009).

Lei *et al.* (2012) afirmam ainda que esse ruído branco adicionado na *EEMD* acaba sendo considerado como o possível ruído aleatório que seria encontrado no processo de medição. Desta maneira, o ruído branco adicionado fornece uma distribuição de escala de referência relativamente uniforme para facilitar o *EMD*, mesmo que a adição desse ruído resulte em uma menor relação “sinal-ruído”, o que não afetará no método de decomposição, irá de fato aprimorar para evitar a mistura de modos. Assim, o ruído branco adicionado que é a principal característica do *EEMD* irá apenas ajudar a extrair os verdadeiros sinais nos dados.

Com a aplicação da técnica *EEMD* no sinal, têm-se os sinais adequados para a modelagem *AR*, resultando em parâmetros para indicar a presença de danos. Esses parâmetros encontrados são utilizados como dados de entrada para um classificador denominado *Support Vector Machine (SVM)*, Máquina de Vetores de Suporte). Esse classificador é bastante usado em inteligência computacional, sendo considerado uma técnica com grande potencial com a capacidade de prever corretamente uma nova classe de dados com o mesmo domínio dos disponíveis na pesquisa e fornecê-los em uma descrição compacta, aplicando o princípio da indução (LORENA e CARVALHO, 2007).

Através do *Software* de Análise Estrutural *SAP 2000*, o desenvolvimento dos elementos estruturais deu-se inicialmente com a simulação da estrutura bi-apoiada íntegra, servindo como

referência para criação dos casos de estruturas danificadas. Antes de modelar as vigas, foi realizado um estudo de convergência da malha para definir uma média adequada de elementos finitos sólidos que trariam resultados precisos para ambas as modelagens e então poder obter séries de deslocamentos utilizadas para aplicação nos modelos preditores.

As estruturas danificadas por sua vez, foram definidas de acordo com a porcentagem do dano em relação a altura da viga, sendo considerado que as larguras dos danos são as mesmas em ambos os casos. Assim, o maior dano possui 70% da altura da viga, o segundo corresponde a 50% e o terceiro 25%, gerando perdas de massa de 2.8%, 2.0% e 1.0%, em que para cada um desses casos foram modeladas três estruturas com localizações de danos diferentes. Além disso, as análises foram realizadas inicialmente em estruturas com apenas um carregamento atuante e em seguida em estruturas com três carregamentos atuantes sobre as vigas.

Dessa forma, serão realizadas no total seis análises cada uma com quatro sinais de deslocamentos das vigas. Estas análises tem o intuito de verificar a capacidade dos métodos em identificar os danos conforme as perdas de massa, sua competência em distinguir as localidades em que foram inseridos na estrutura e avaliá-los conforme a aplicação de um ou mais carregamentos. Esses resultados serão verificados principalmente por meio dos resultados de acurácia do modelo SVM de classificação.

1.2 Objetivos do Trabalho

1.2.1 Objetivo Geral

O trabalho tem como objetivo geral realizar a identificação e localização de danos a partir de um conjunto de técnicas, denominadas como *Ensemble Empirical Mode Decomposition (EEMD)*, Modelo Auto Regressivo (AR) e *Support Vector Machine (SVM)* em estruturas lineares modeladas por elementos finitos de casca tipo “sólidos” através do software de análise estrutural SAP 2000.

1.2.2 Objetivos Específicos

- Modelar pelo *Software SAP 2000* as estruturas íntegras e danificadas de acordo com a altura do dano em relação a altura das vigas e conforme as perdas de massa definidas.
- Adquirir os sinais de deslocamentos de cada uma das vigas, gerando análises com aplicação sequencial das técnicas EEMD, AR e SVM para obter os valores finais de acurácia do modelo *Quadratic SVM*.
- Analisar através dos resultados de acurácia dos dados classificados a capacidade dos modelos preditores em identificar e localizar danos, em que altos resultados indicam uma boa classificação.

1.3 Estrutura do Trabalho

Os capítulos seguintes deste trabalho estão estruturados da seguinte forma:

O capítulo 2 referente a Revisão Bibliográfica versa ao entendimento de aspectos gerais relacionados à detecção de danos em estruturas e alguns dos métodos tradicionais de Integridade Estrutural. Assim como as principais pesquisas e aplicações das técnicas *EMD* e *EEMD*, *AR* e *SVM*, relacionadas às estruturas da construção civil.

O capítulo 3, Fundamentação Teórica, descreve as técnicas usadas no trabalho, nas duas primeiras subseções são expostos os algoritmos *EMD* e *EEMD*, em seguida a modelagem *AR* e o classificador *SVM*.

O capítulo 4, Estudo de Caso, descreve inicialmente a sequência de tarefas para modelagem da estrutura por meio do software de análise estrutural SAP2000 e as características geométricas das vigas. Além disso, mostra como foram definidos os esquemas de modelagem das vigas, e como foram escolhidos os casos de modelagem das estruturas danificadas.

O quinto capítulo refere-se aos resultados obtidos, apresentando a análise de convergência da malha e sua discretização conforme diferentes quantidades de elementos finitos. Posteriormente são mostrados os casos de análise do *EEMD*, *AR* e *SVM* de acordo com as porcentagens de perdas de massa definidas.

O sexto capítulo relata as conclusões do estudo e da capacidade desses métodos aplicados, assim como as dificuldades de realização da pesquisa e perspectivas que ainda podem ser alcançadas com a continuação desse estudo.

2 REVISÃO BIBLIOGRÁFICA

2.1 Danos em estruturas da Construção Civil

A construção civil é um dos ramos essenciais para o desenvolvimento social e econômico de qualquer região. Em virtude do aumento do número de obras e da grande quantidade de construções antigas, faz-se necessário um sistema de manutenção e monitoramento para que possam ser identificados a existência de qualquer mudança nos elementos estruturais, que originem danos e prejudiquem a rigidez e segurança de toda estrutura. Henriques (2001, *apud* SACHI e SOUZA, 2016) afirma que a maioria dos danos ou manifestações patológicas nas estruturas, são ocasionadas por erros durante o desenvolvimento do projeto (Figura 2.1).

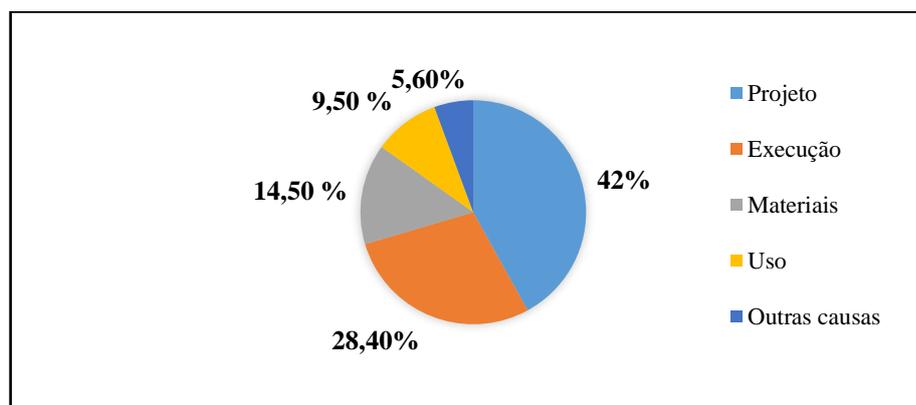


Figura 2.1 - Origem das manifestações patológicas na construção civil. (Adaptado de HENRIQUES, 2001; *apud* SACCHI, SOUZA, 2016).

No entanto, vale notar também que a degradação da estrutura pode estar relacionada a erros na execução da obra, como deficiência na concretagem ou nas armaduras, inadequação de formas e escoramentos, má utilização dos materiais de construção e inexistência do controle de qualidade ou aspectos relacionados ao uso da estrutura (TRINDADE, 2015). Outra questão importante se trata do envelhecimento estrutural, qualquer tipo de edificação sofre com a ação do tempo, que conseqüentemente leva a degradação dos materiais que compõem a estrutura.

Souza e Ripper (1998) citam uma série de fatores intrínsecos e extrínsecos ligados as causas dos processos de deterioração das estruturas, como falhas humanas, causas naturais próprias ao material ou ações externas. No que tange, aos processos físicos de deterioração

dessas estruturas de concreto, podem ser listados cinco principais problemas, a perda de aderência, a carbonatação, o desgaste ou desagregação do concreto, e um dos mais frequentes que são as fissurações.

A partir desse processo físico de deterioração, percebe-se a grande quantidade de problemas que dão origem as fissurações e que todas as estruturas de concreto podem estar sujeitas a esse tipo de manifestação. É necessário sempre a verificação da origem dessas manifestações e intensidade do grau de fissuração, avaliando o seu comportamento com o passar do tempo. Como são comuns a existência de fissuras principalmente em vigas, são determinadas algumas configurações básicas de acordo com o tipo do esforço que está atuando no elemento (Figura 2.2).

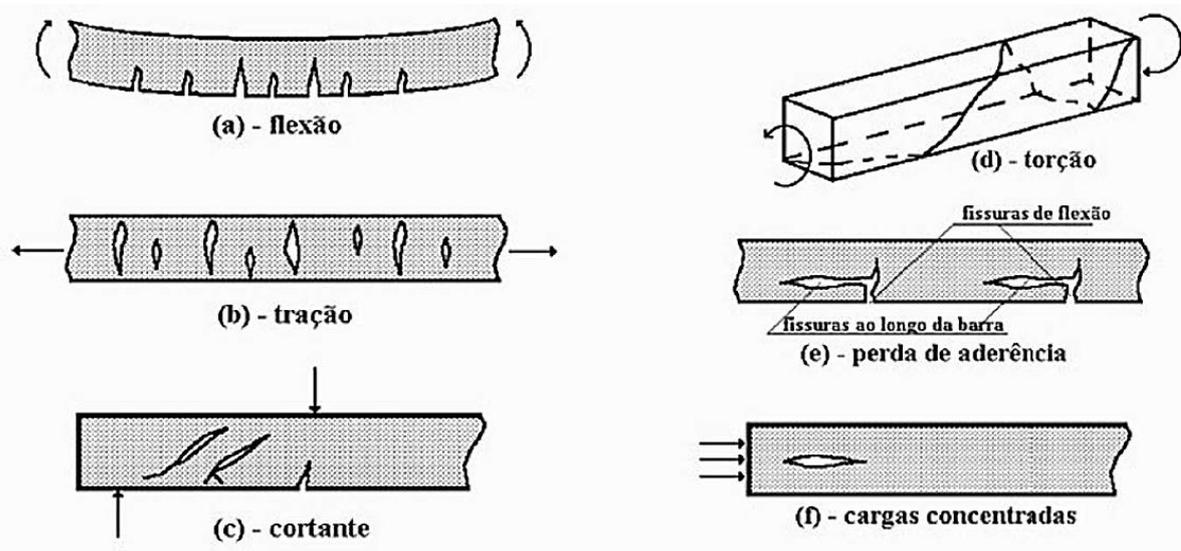


Figura 2.2 - Configurações genéricas de fissuras em função do tipo de sollicitação predominante.
Fonte: Souza e Ritter (1998).

A NBR 6118 estabelece que esse problema de fissuração ocorre principalmente por conta da “grande variabilidade e à baixa resistência do concreto à tração”, a norma constitui um Estado Limite de Abertura das Fissuras (ELS-W), onde é verificado se as fissuras estão com as aberturas iguais aos máximos determinados pela norma, estabelecendo limitações para haver um controle e o devido tratamento.

Outras manifestações patológicas comuns em estruturas são denominadas como trincas, rachaduras, fendas e brechas. Para distingui-las são delimitadas as aberturas máximas para cada uma dessas anomalias conforme Tabela (2.1).

Tabela 2.1 - Classificação de anomalias quanto à espessura das aberturas. Fonte: Oliveira (2012).

ANOMALIAS	ABERTURAS (mm)
Fissura	Até 0,5
Trinca	De 0,5 a 1,5
Rachadura	De 1,5 a 5,0
Fenda	De 5,0 a 10,0
Brecha	Acima de 10,0

Além da necessidade de considerar essas ações sobre as estruturas durante a criação dos projetos, é necessário ter uma atenção especial voltada para as estruturas que já estão construídas e em fase de uso. A NBR 5674 (1999), relacionada à manutenção de edificações, enfatiza a importância da realização de inspeções, definida pela norma como a “Avaliação do estado da edificação e de suas partes constituintes, realizada para orientar as atividades de manutenção”, e a manutenção dessas estruturas por sua vez sendo o “Conjunto de atividades a serem realizadas para conservar ou recuperar a capacidade funcional da edificação e de suas partes constituintes de atender as necessidades e segurança de seus usuários”.

A NBR 6118 (2014) que trata do Projeto de estruturas de concreto – Procedimento, descreve todas as ações a ser considerada em uma análise estrutural, descritas como ações permanentes, variáveis e excepcionais, e ainda “levando-se em conta os possíveis estados limites últimos e os de serviço”. Além disso, a norma afirma que as análises feitas em um elemento ou em toda a estrutura, possibilitam “estabelecer as distribuições dos esforços internos, tensões, deformações e deslocamentos”.

Um dos principais elementos usados na resolução de problemas e em diferentes tipos de análises são as vigas, definida pela NBR 6118 (2014) como “elementos lineares em que a flexão é preponderante”. São elementos que tem a função de suportar carregamentos, como de lajes ou pavimentos superiores, em conjunto com outros elementos estruturais como os pilares e respectivamente as fundações.

De acordo com a função que a viga exercerá na estrutura, seus apoios podem ser móveis, fixos ou engastados, intervindo diretamente nos movimentos de translação vertical, horizontal ou rotação. As vigas podem ser descritas como engastadas, simplesmente apoiadas, bi-apoiadas, dentre outras, estando sujeitas a carregamentos concentrados ou distribuídos.

Nessa perspectiva, em virtude da eficiência e desempenho de uma estrutura, qualquer tipo de projeto, seja de pequeno ou grande porte, deve possuir um planejamento e gestão desde a etapa inicial até a sua etapa de utilização. Sacchi e Souza (2016) afirmam que “A vida útil de uma estrutura nasce no projeto e se consolida na execução”, assegurando que projetar é uma

das etapas essenciais que garante a eficiência da edificação, evitando perdas e buscando prevenir falhas durante um bom período de tempo.

2.2 Métodos Tradicionais para avaliação da integridade de estruturas

Na construção civil, para avaliação das condições estruturais os ensaios são divididos normalmente em dois grupos denominados Ensaios Destrutivos (ED) e Ensaios Não-Destrutivos (END). Nos ensaios destrutivos são realizadas análises e verificação da capacidade resistente do elemento estrutural com base em seus estados limites, como por exemplo ensaios de compressão e de tração, ou ensaios de testemunhos extra. Já os ensaios não-destrutivos possuem ampla aplicação e não interferem na estrutura, alguns exemplos são: esclerometria; ensaio de medição da maturidade do concreto; ensaio de resistência a penetração; ensaio de absorção e permeabilidade do concreto; ensaio de ultrassom; ensaio de termografia infravermelha; ensaio de pacometria do concreto.

Outros tipos de métodos utilizados para avaliar uma estrutura, podem estar relacionados às mudanças nas propriedades das vibrações. Normalmente, as estruturas excitadas por vibrações servem como base para estudo de suas propriedades dinâmicas e modais, possibilitando a verificação de mudanças tanto na rigidez e amortecimento, quanto na massa do elemento. Tais modificações nas propriedades das vibrações, como modos de vibração ou frequências naturais, é uma das principais ferramentas para avaliar as alterações estruturais, em especial no processo de detecção de danos. Farrar *et al.* (2001) afirmam ainda que esse processo depende de elementos como: a aquisição e limpeza de dados, a seleção de recursos e compreensão de dados, e o desenvolvimento de um modelo estatístico.

Alvandi (2003) classifica os métodos de detecção de danos conforme as alterações nas propriedades modais e em parâmetros derivados de alterações nas propriedades dinâmicas. Em relação às propriedades dinâmicas, são citados três métodos, baseados na curvatura dos modos de vibração, na mudança da flexibilidade e na curvatura da flexibilidade. O primeiro, faz uma análise da variação na curvatura dos modos de vibração através de suas derivadas, pelo fato de existir uma ligação entre estes modos e as deformações por flexão. O segundo, devido a existência de danos diminuir a rigidez estrutural, a flexibilidade da estrutura acaba aumentando e pode ser utilizada para identificar o dano e sua localização. O terceiro método mencionado, é uma combinação dos dois primeiros, relacionando as alterações na flexibilidade da estrutura que irão gerar falhas e deformações que poderão ser analisadas posteriormente.

Grande parte desses métodos citados para detecção de danos e técnicas para a análise da saúde e segurança das grandes estruturas civis baseiam-se em vibrações (XU e CHEN, 2004). Amiri e Darvishan (2015) afirmam que a ideia desses métodos se baseiam nas mudanças em propriedades como rigidez, massa e amortecimento, pertinente à resposta da estrutura sob excitação.

A agilidade na detecção da estrutura danificada, pode contribuir significativamente para a redução de danos causados pelo incidente às obras. Necessariamente, o monitoramento da integridade estrutural abrange as estimativas das frequências de vibração da estrutura por meio dos dados medidos e a comparação destes com dados pré-existentes para a identificação de quaisquer alterações provenientes dos danos. Grande parte dessas técnicas se deparam com dificuldades devido as medidas terem baixa sensibilidade à resposta do dano local na estrutura ou baixa exatidão das medidas do sensor e as limitações técnicas do processamento de dados com os sinais transientes ou sistemas não lineares (LIU e NGUYEN, 2012).

2.3 Breve histórico das principais aplicações do EMD e EEMD

2.3.1 Pesquisas e Aplicações em Estruturas da Construção Civil

O acúmulo de danos estruturais pode causar uma série de mudanças nas características dinâmicas das estruturas (Rytter, 1993). Por conseguinte, a medição dessas características através de uma inspeção baseada em vibrações, durante o tempo de vida da estrutura, podem servir como base para a identificação de danos estruturais, tendo em vista que a detecção precoce dessas deteriorações, são fundamentais para garantir a segurança da estrutura e reduzir os custos de reparos.

Buscando a solução de problemas durante o desenvolvimento e aplicação de técnicas de detecção de danos, Huang *et al.* (1996) desenvolveram uma técnica de tempo-frequência, denominada como Transformação de Hilbert-Huang, adequada para realizar o processamento de sinais não-estacionários e não-lineares. A técnica básica é fundamentada no método *Empirical Mode Decomposition* (EMD), a qual possibilita a decomposição do sinal recebido em um conjunto de IMFs (Funções de Modo Íntrínseco, do inglês *Intrinsic Mode Function*), que conseqüentemente descrevem a resposta vibratória do sistema.

Cabe notar que muitas pesquisas foram realizadas com foco na detecção de danos estruturais usando tanto estruturas reais quanto modelos experimentais, realizando então o emprego de técnicas como a Transformada de *Hilbert-Huang* e *Empirical Mode Decomposition*, em alguns casos fazendo a junção de outras técnicas existentes para o melhoramento dos resultados.

Xu e Chen (2004), apresentaram uma análise experimental sobre o *EMD* e sua aplicação na detecção de danos estruturais, assim como uma discussão a respeito da influência da gravidade do dano, frequência de amostragem e sobre o desempenho desse método. A análise e comparação dos resultados mostraram que os instantes de tempo de dano poderiam ser detectados com precisão em termos de picos de danos retirados dos dados de avaliação pela técnica *EMD*. E ainda, o local do dano pode ser determinado pela avaliação da distribuição dos picos de danos ao longo do edifício. Dentre outras conclusões, a pesquisa relata que a abordagem *EMD* é uma ferramenta bastante promissora para detectar danos em estruturas reais, tendo em vista que trata-se de um sinal baseado e modelo de método livre que não requer um conhecimento prévio da estrutura. A Figura (2.3) mostra a configuração utilizada por Xu e Chen (2004) em suas diversas pesquisas para aplicação do método *EMD*.

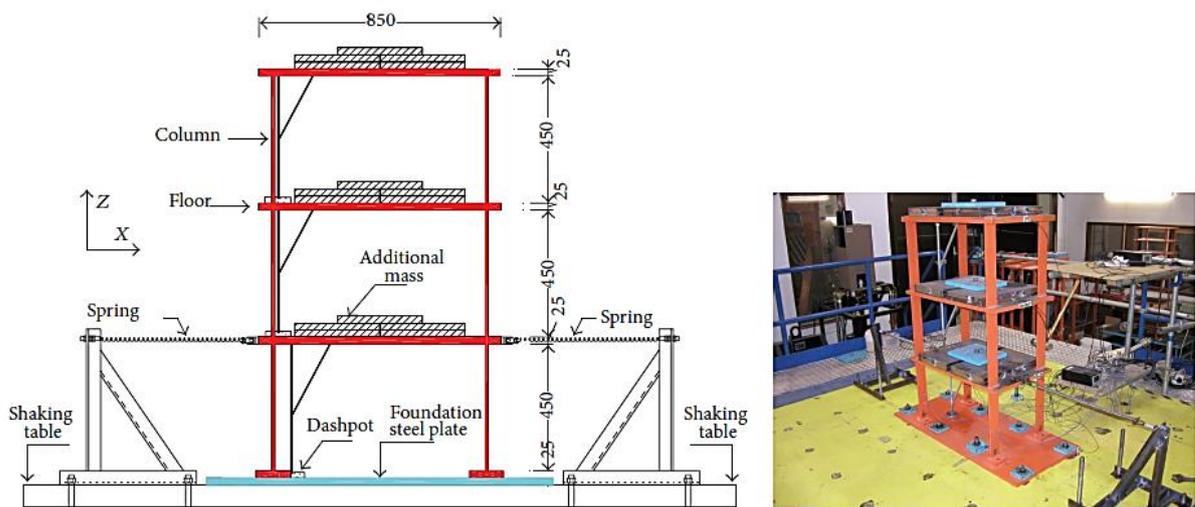


Figura 2.3 - Configuração do modelo de edifício: elevação e modelo real. Fonte: Xu e Chen (2004).

Outra pesquisa com estrutura experimental similar a citada anteriormente, foi realizada por Pines e Salvino (2006), que discutiram a aplicação do instrumento de processamento de sinais envolvendo a utilização do *EMD*, em conjunto com a Transformação de Hilbert. Os resultados ilustraram a capacidade desse método de série de tempo em rastrear recursos na resposta vibratória das estruturas. A partir do uso de modelos de estruturas 1-D, obtiveram a

possibilidade de determinar a localização e a extensão do dano por propriedades de fase de rastreamento entre graus sucessivos de liberdade. Além disso, através de um modelo de edifício escalonado com três andares e com piso térreo ligado a um sistema de agitação hidráulico como mostra a Figura (2.4), os dados de vibração no domínio de tempo foram analisados de duas formas, sem a existência de danos e com a simulação da presença de danos em diferentes casos, modificando fisicamente as características das estruturas.

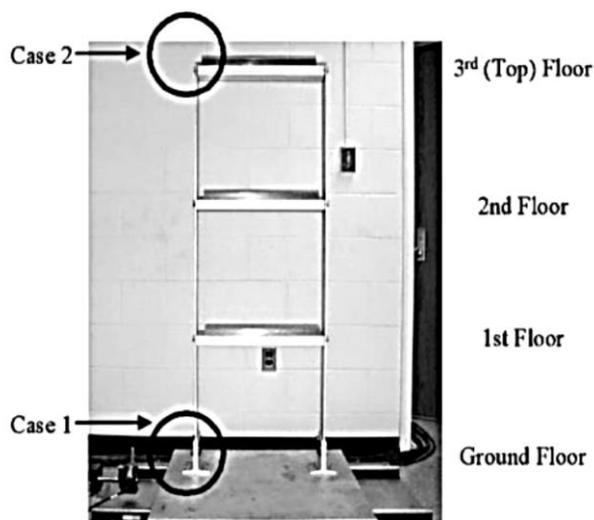


Figura 2.4 - Modelo Experimental do Prédio. Fonte: Pines e Salvino (2010).

Yinfeng *et al.* (2009) também realizaram a aplicação do método baseado no *EMD* onde agregaram à pesquisa o uso do modelo *Autoregressive Moving Average Model (VARMA)*, como proposta para detecção de danos estruturais. Propuseram a ideia de que os danos pudessem ser identificados pelas mudanças abruptas na distribuição de energia das respostas estruturais em altas frequências. E usando o modelo variável no tempo *VARMA* as *IMFs* obtidas através da decomposição do sinal de vibração pudessem ser representadas, definindo assim o índice de danos de acordo com os coeficientes *VARMA* encontrados. Utilizaram na pesquisa duas estruturas de referência, o *Imperial County Services Building* e *Van Nuys Hotel*, para avaliar a eficácia da proposta de identificação do dano em ambientes reais com a presença de ruídos reais. Na primeira estrutura, o sinal de aceleração gravado durante o terremoto 1979 *Imperial Valley*, foram analisados usando o método original e melhorado da Transformada de Hilbert-Huang para demonstrar as mudanças abruptas na distribuição do sinal de energia. Na segunda estrutura a resposta de aceleração durante três eventos de terremotos foram usadas para avaliar a sensibilidade e robustez do índice de danos proposto. Os resultados das análises realizadas demonstraram e comprovaram que o índice de danos encontrados pelas técnicas, pode indicar

a ocorrência e severidade relativa dos danos estruturais em vários locais de forma eficiente e pode ser potencialmente usado para o monitoramento da saúde estrutural, uma vez que é derivado diretamente dos coeficientes *VARMA* variáveis no tempo.

Neste ponto ainda, Lin *et al.* (2009) desenvolveram um método de processamento de sinais fundamentados na utilização do método *EMD* e na transformada de Hilbert-Huang (HHT) para testes de eco impactos. Realizaram a aplicação do método *EMD* para decompor o sinal de eco impacto em *IMFs* e posteriormente realizaram a análise de Fourier em cada *IMF*. Examinando os seus comportamentos no domínio do tempo e da frequência, e obtiveram as *IMFs* que representavam o ruído, a onda de eco, a onda de superfície ou as vibrações modais. Além disso, utilizaram simulações numéricas e testes de modelo demonstrando que o método proposto pode ser promissor na detecção de trincas internas no concreto, mesmo quando os sinais de vibração e ruído são fortes.

Rezaei e Taheri (2010) apresentaram um estudo da detecção de danos em componentes vitais em muitas estruturas, as vigas. Utilizaram como proposta a técnica *EMD* para avaliação de saúde do sistema com base em seus dados vibracionais, demonstrando por meio de um conjunto de investigações numéricas e experimentais a eficiência do índice de dano de energia *EMD*. Primeiramente, no estudo numérico foi realizada a análise da simulação de elementos finitos de uma viga de aço em balanço com entalhe transversal intermediário (Figura 2.5), assim como a localização dos sensores associados denominados como PZT1, PZT2, e PZT3, e a função de carregamento aplicando uma carga de impulso (*impulse load*) na extremidade livre para estudar a vibração livre do feixe. Além disso, desenvolveram um código MATLAB para decompor os sinais de vibração baseados no *EMD*, para derivar os *IMFs* e calcular a energia do primeiro *IMF* para cada sensor.

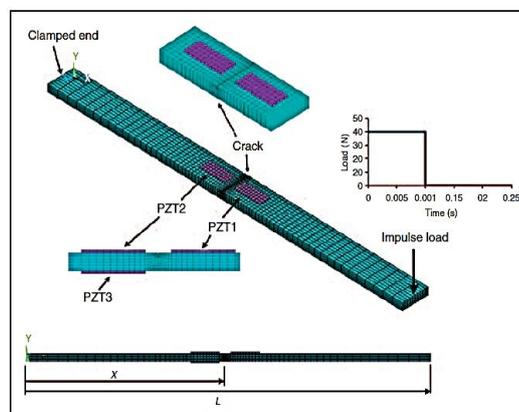


Figura 2.5 - Simulação de elemento finito da viga em balanço com sensores de entalhe intermediário e piezocerâmicos. Fonte: Rezaei e Taheri (2010).

Na análise experimental, as mesmas dimensões da viga do estudo numérico foram utilizadas. A Figura (2.6) mostra a configuração experimental da viga em balanço, suportada pelas garras de uma pinça hidráulica, com três sensores ligados a viga para monitoramento das respostas dinâmicas e com um martelo de impulso para observar a vibração livre, essas respostas foram simultaneamente recolhidas por meio de um sistema de aquisição de dados (DAQ), onde seus arquivos de texto produzidos eram lidos por um código MATLAB desenvolvido internamente (Rezaei e Taheri, 2010).

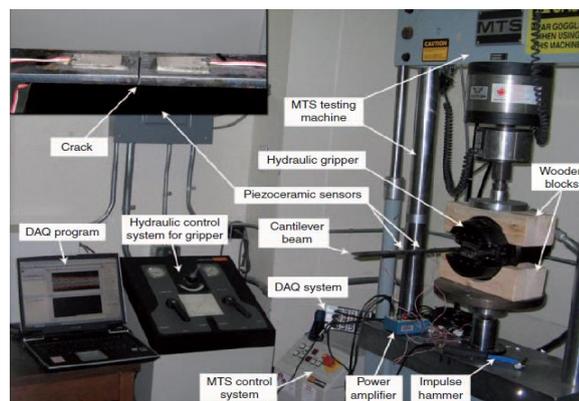


Figura 2.6 - Configuração experimental da viga em balanço. Fonte: Rezaei e Taheri (2010).

Nas duas análises, numérica e experimental, os sinais obtidos pelos sensores a partir das estruturas em estados íntegros e danificados, foram processados e decompostos para encontrar o índice de danos. Rezaei e Taheri (2010) obtiveram resultados satisfatórios que comprovaram a capacidade do índice de danos de energia *EMD* para identificar e quantificar entalhes existentes nas vigas. Observaram também que a localização dos sensores na região do entalhe não afeta a proposta de detecção de danos e que a tendência crescente no índice de danos em função da dimensão do entalhe constata a efetividade da metodologia proposta na análise da gravidade do dano. Em síntese, o conhecimento das condições estruturais ou a implementação de estratégias para identificação de danos como a desenvolvida por Hilbert Huang, sejam para estruturas aeroespaciais, de engenharia civil ou mecânicas, são fundamentais para o aperfeiçoamento de técnicas para o monitoramento da saúde da estrutura.

Meredith *et al.* (2012) fazem análise de uma viga por elementos finitos, discretizados com múltiplas seções danificadas sendo modeladas como locais aonde ocorrerão perdas de rigidez, como pode ser observado na Figura (2.7). Em síntese, o estudo buscou investigar a probabilidade de aplicar o *EMD* na resposta de aceleração dessa estrutura sujeita a uma carga móvel para a detecção de danos.

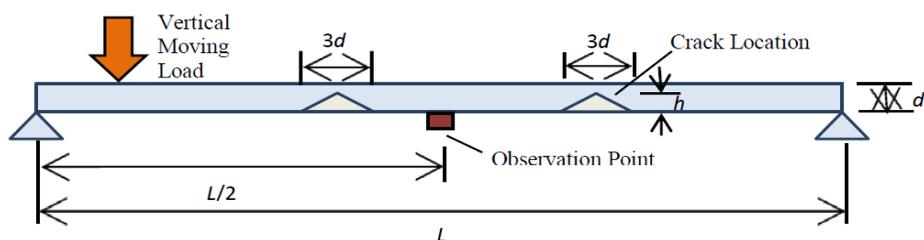


Figura 2.7 - Modelo de viga danificada. Fonte: Meredith *et al.* (2012).

Como resultado, Meredith *et al.* (2012) obtiveram que o *EMD* é capaz de detectar múltiplas fissuras, porém, os resultados foram mais precisos quando aplicado um Filtro de Média Móvel antes do *EMD*, mostrando-se capaz de detectar uma rachadura de 10% da profundidade da viga em um sinal gerado a 10 m/s mesmo sendo corrompidos por ruídos brancos SNR de 5 (*SNR* – *Signal to Noise Ratio*). Notando-se assim a capacidade do método *EMD* em detectar danos e a possibilidade dos resultados serem melhorados com a junção de sensores que facilitem a distinção de discontinuidades pertinentes a danos e não-danos aprimorando a precisão do dano previsto.

Amari e Darvishan (2015) realizaram sua pesquisa voltada para a detecção de danos em momentos *Frames* usando o método *EEMD* e a Técnica de Clusterização, que faz a classificação de dados por um aprendizado não supervisionado. Para a análise foi utilizado um elemento do tipo *Frame* (elemento unidimensional simulando um pórtico) de aço e com três andares (Figura 2.8). Consideraram a localização do edifício em uma área sísmica, com propriedades geométricas do modelo iguais a 4,00 m de comprimento e 3,2 m de altura, aço com o limite de escoamento de 2400 Kg/cm², cargas mortas e vivas do piso iguais a 600 Kg/m² e 200 Kg/m², e um período dominante da estrutura de 0,81 segundos.

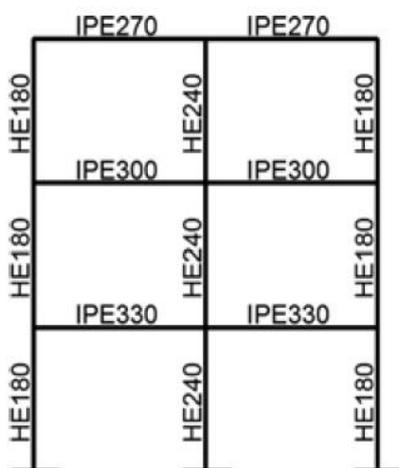


Figura 2.8 - Seções dos elementos viga-coluna. Fonte: Amari e Darvishan (2015).

Para dar seguimento a metodologia de detecção de danos, Amari e Darvishan (2015) determinaram uma sequência de etapas baseadas na combinação de processamento de sinais e dados de mineração, para os quais realizaram uma comparação entre as estruturas não lineares e lineares com base na análise dinâmica para diferentes níveis de intensidade, onde concluíram que a clusterização ajuda no monitoramento das vibrações em certo período de tempo buscando obter o comportamento cumulativo da estrutura. Além disso, observaram a capacidade que o *EEMD* possui em decompor sinais com diferentes escalas, indicando também que a amplitude medida é mais adequada para detecção de danos em estruturas não lineares, diferentemente da frequência.

2.3.2 Principal desvantagem do método *EMD* e comparação com o *EEMD*

O *Empirical Mode Decomposition (EMD)*, mesmo sendo considerado um método adaptativo na análise de dados tempo-frequência e possuir versatilidade em suas aplicações, tem uma grande desvantagem ocasionada pelo aparecimento de uma frequência denominada *Mode Mixing* (mistura ou mixagem de modos). Wu e Huang (2009) definem esse problema como “Quando ocorre a mistura de modos, um IMF pode deixar de ter significado físico por si só, sugerindo falsamente que pode haver diferentes processos físicos representados em um modo”. Esse problema é normalmente uma consequência da descontinuidade do sinal, o que poderia originar nas respostas de tempo-frequência um crítico *aliasing*, que nada mais é do que um efeito que torna os sinais amostrados indistinguíveis ou sem informações suficientes, originando também uma modificação do significado físico individual do *IMF*, tornando o mesmo duvidoso.

Como forma de superar esse problema, Huang *et al.* (1996) tiveram como proposta a realização de um teste de intermitência, para amenizar algumas dificuldades, porém o mesmo baseava-se em uma escala subjetivamente selecionada, o que faz com que o *EMD* deixe de ser adaptativo. Os autores citam ainda outra questão referente a esse teste, que está relacionada a seleção subjetiva de escalas de tempo, que devem ser claramente separáveis e definíveis nos dados, caso isso não ocorra, como por exemplo na maioria dos sinais naturais ou artificiais, o algoritmo com escalas de tempo subjetivamente separáveis do teste de intermitência não irá apresentar um bom funcionamento.

Wang *et al.* (2012) realizaram em sua pesquisa uma comparação das aplicações do *EMD* e *EEMD* na análise de tempo-frequência de um sinal sísmico, buscando resolver esse problema

de misturas de modos, que ocorrem no método tradicional *EMD*. Inicialmente, consideraram os seguintes sinais:

(a) Sinal sinusoidal: $s_1 = \sin(20\pi t)$

(b) Sinal intermitente: $s_2 = \begin{cases} 0,2 \times \sin(300\pi t) & \text{onde } 0,05 \leq t \leq 0,1 \\ 0,4 \times \sin(100\pi t) & \text{onde } 0,15 \leq t \leq 0,25 \end{cases}$

(c) Soma dos sinais: $s = s_1 + s_2$

Realizando a decomposição dos sinais pelos dois métodos *EMD* e *EEMD*, a comparação dos resultados pode ser observada pelas figuras (2.9) e (2.10), em que são obtidas as IMFs (a,b,c,d) e os demais espectros de tempo-frequência.

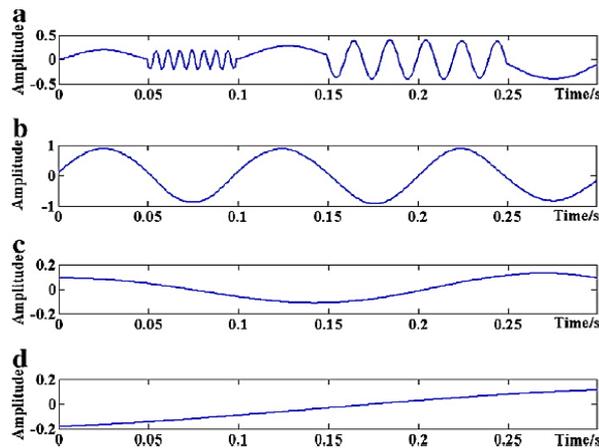


Figura 2.9 - Obtenção das IMFs pela decomposição do sinal s usando o *EMD*. Fonte: WANG *et al.* (2012).

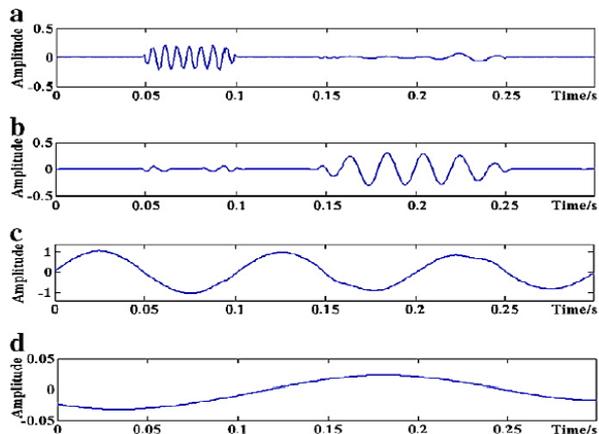


Figura 2.10 - Obtenção das IMFs pela decomposição do sinal s usando o *EEMD*. Fonte: WANG *et al.* (2012).

Além desse exemplo mostrado, utilizaram também dados reais relacionados a um levantamento sísmico compensado, realizado em uma região de exploração visando identificar a existência de sumidouros subterrâneos. Para todos os casos com 1000 pontos de amostragem e um intervalo de amostragem igual a 0,1 ms. A Figura (2.11) mostra os dois espectros resultantes do perfil sísmico comum em 300 Hz, onde expõe o resultado (a) referente a aplicação do método *EMD* apresentando irregularidades e dispersões; e o resultado (b) do espectro de tempo-frequência fatiado usando o *EEMD*, que por sua vez indica visivelmente a localização das dois sumidouros, o que mostra uma maior capacidade e precisão para os resultados obtidos.

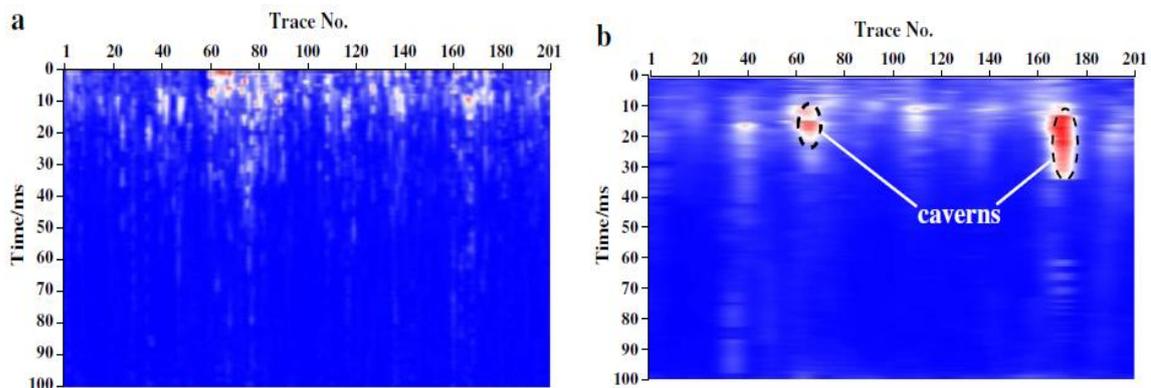


Figura 2.11 - Espectro tempo-frequência fatiado a 300 Hz baseado (a) no EMD e (b) no EEMD. Fonte: Wang *et al.* (2012).

Desta maneira, Lei (2013) afirma que como cada uma das decomposições de ruído consiste no sinal e no ruído branco adicional, cada teste individual pode certamente produzir resultados muito ruidosos. Mas o barulho em cada tentativa é diferente em testes separados. No método *EEMD*, um *IMF* é, portanto, definido como a média de um conjunto de tentativas. Cada tentativa consiste nos resultados de decomposição do sinal mais um ruído branco de amplitude finita.

Outra aplicação usando método *EEMD*, foi realizada por Kim *et al.* (2014), em que estudaram a detecção de dados de colisão de tráfego usando o *EEMD*. Em seu estudo descreveram todo o processo de transformação dos dados antes de serem decompostos, e após obterem os *IMFs* e o resíduo correspondentes, as propriedades dos *IMF* foram então analisadas para minimização dos dados e construídos os Perfis de Risco Contínuo (RPC), os quais foram comparados com outros perfis. Definiram que a importância desse estudo está relacionada a eliminação do ruído nos dados de colisão de tráfego, buscando uma redução nos chamados falsos positivos (informações falsas) e ajudar as agências governamentais que voltam-se para

essa temática. Os autores tiveram como perspectiva a capacidade com que o método *EMD* pode filtrar os ruídos nos dados de colisão e sem usar nenhum tipo de média móvel.

Gaci (2016) cita resumidamente que o método *EEMD* oferece uma melhor aptidão de separação em escala comparando com o método tradicional *EMD*, pois adicionando as diferentes séries de ruído branco em várias tentativas, os *IMFs* resultantes não exibem qualquer correlação com os *IMFs* correspondentes de um teste para outro. Dessa forma, caso se encontre um número adequado de tentativas, o ruído que foi adicionado pode ser eliminado pela média dos conjuntos dos *IMFs* obtidos relacionados aos ensaios.

Tendo em vista os problemas relacionados aos períodos de inundações e aos desafios para obtenção de previsões precisas do escoamento a médio e longo prazo, Tan *et al.* (2018) estudaram a possibilidade de aprimorar o desempenho das previsões aplicando uma abordagem híbrida através de um método adaptado *EEMD – ANN* (Rede Neural Artificial, do inglês *Artificial Neural Network*), com o objetivo de prever o fluxo de um mês a frente de três estações na China. O método *EEMD* foi usado para realizar a decomposição da série temporal original e o *ANN* voltado para prever cada sub-série. Afirma-se que após serem feitas as aplicações destes métodos de decomposição e previsão, seus resultados e desempenho foram comparados com outros métodos, tais como *ANFIS* (*Adaptive Neuro Fuzzy Inference System*), *SVM* (*Support Vector Machine*) e *SAR* (*Seasonal Autoregressive*). Tiveram a conclusão que o modelo seria apropriado para realizar previsões apenas em estações chuvosas, aplicando para os casos de estações secas o modelo *SAR*, que melhor se adapta a época em que se pretende aplicá-lo.

2.4 Séries temporais e os Modelos Auto Regressivos (AR)

Na análise de séries temporais é importante e esperado que haja alguma motivação ligada ao tempo, que tenham influenciado ou que irão continuar influenciando nos dados (XAVIER, 2016). Ragsdale (2018) define as séries temporais como “um conjunto de observações em uma variável quantitativa coletada no decorrer do tempo”, ou seja, essas séries são ordenadas em períodos ou pontos durante algum intervalo de tempo, tratando-se de uma sequência de números simbólicos relacionados a algum fenômeno que pode ser mensurado. Tais séries são analisadas por um grupo de procedimentos e técnicas matemáticas que possibilitam abordar estatisticamente os dados adquiridos.

Normalmente, para realizar a representação de uma série temporal, é comum o uso da notação Y , onde em dado momento t é considerado uma função Y_t , em que $t= 1, 2, \dots, n$ indica o tamanho da série.

A descrição de séries temporais podem ser feitas por padrões de processos estocásticos, os quais são monitorados por leis probabilísticas. Conforme Granger (1977, *apud* XAVIER, 2016), a finalidade preliminar da análise de séries temporais é retirar implicações nas propriedades básicas do mecanismo formador do processo estocástico das observações da série. Assim, o desenvolvimento e aplicação de um modelo adequado para análise destas séries temporais, dependem de fatores como comportamento do fenômeno, informações a respeito da sua origem e sobretudo o objetivo da análise.

Os principais objetivos do estudo de séries temporais estão relacionados a possibilidade de descrever as características iniciais das informações obtidas, propriedades das séries, padrões, oscilações, modificações estruturais, dentre outras. Sendo assim, necessário achar um modelo estatístico apropriado que estude o comportamento da série em um período determinado, visando explicar os motivos de suas variações. De maneira geral, os objetivos do estudo de séries temporais resumem-se no processo mostrado na Figura (2.12).



Figura 2.12 - Processo de análise de séries temporais. Fonte: Autoria Própria.

Normalmente, a modelagem de uma série temporal depende primeiramente da condição de estacionariedade ou não estacionariedade da mesma. No caso de séries estacionárias são aplicados modelos auto regressivos lineares estacionários, tais como o modelo Auto Regressivo (AR), modelo de Médias Móveis (MA), e Auto Regressivos e de Médias Móveis (ARMA). Em casos de modelos lineares não-estacionários, são aplicados modelos Auto-Regressivo Integrado Médias Móveis (ARIMA), e o Modelo Média Móvel Integradas Auto-Regressivas Sazonais (SARIMA). A Figura (2.13) mostra sucintamente essa divisão dos modelos para séries temporais e os respectivos parâmetros.



Figura 2.13 - Modelos para séries temporais. Fonte: Autoria Própria.

Frequentemente as séries temporais pressupostas como estacionárias, se desenvolvem no tempo em torno de uma média constante aleatoriamente, que conforme Morettin *et al.* (2004), refletem uma estabilidade de equilíbrio. Em contrapartida, afirmam que grande parte das séries temporais analisadas a partir de casos reais demonstram alguma não-estacionariedade, devido a presença de todos ou um dos padrões de tendência, sazonalidade, ciclo ou ruído aleatório (Figura 2.14).

TENDÊNCIA	• Analisa o deslocamento da série ao longo do tempo
SAZONALIDADE	• Flutuações nos valores da variável com duração inferior a um ano.
CICLO	• Tendência a possuir periodicidade pois as flutuações possuem duração superior a um ano.
RUÍDO ALEATÓRIO	• São variações irregulares, as quais não podem ser modeladas.

Figura 2.14 - Quatro componentes responsáveis pela não-estacionariedade de séries temporais. Fonte: Autoria Própria.

Nessa perspectiva, a modelagem de uma série temporal depende primeiramente da condição de estacionariedade ou não-estacionariedade da mesma. No caso deste trabalho é aplicado o modelo estacionário Auto Regressivo (AR) de ordem (p), devido possuir uma ampla utilização principalmente quando não há uma grande quantidade de parâmetros das séries

temporais, o que o torna mais adequado especialmente em situações práticas que fazem uso destas séries.

2.5 *Machine Learning*

Arthur Samuel (1901–1990), cientista e um dos pioneiros no campo de *Machine Learning* (em português Aprendizado de Máquinas), desenvolveu em 1952 o primeiro programa baseado em Inteligência Artificial usando um jogo de damas. Segundo o site *History of Machine Learning*, “o programa observava os movimentos que estavam ganhando estratégias e adaptou sua programação para incorporar tais estratégias”. No ano de 1959, o cientista definiu essa área como um "campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados".

Ao referir-se a tal assunto Mitchell (1997), descreveu que o aumento no interesse na mineração de dados, ou a utilização de dados históricos para descobrir irregularidades e melhorar decisões futuras, deriva da ligação de diversas tendências recentes, para a qual destaca-se o desenvolvimento de algoritmos de aprendizado de máquina robustos e eficientes para realizar o processamento destes dados.

O *Machine Learning* é uma das áreas de estudo com incessantes pesquisas científicas, voltadas principalmente para o desenvolvimento de algoritmos que tenham um grande potencial para análise de dados e informações relacionados a um assunto específico. Essa técnica oferece uma alternativa hábil, uma vez que obtém conhecimento a partir dos dados disponíveis e gradativamente aprimora o desempenho dos modelos de previsão para tomada de decisões.

Em síntese essa técnica possui algumas características relacionadas diretamente com o tratamento e tipo de aprendizado que serão aplicados nos dados. Normalmente, são divididas em aprendizagem supervisionadas e não supervisionadas (Figura 2.15). No caso deste trabalho é empregado um tipo de aprendizagem supervisionada por meio da classificação dos dados, em que o algoritmo passa inicialmente por um treinamento e posteriormente adquire a capacidade de classificar novos dados a partir dos exemplos de dados rotulados, diferentemente do tipo de aprendizagem não-supervisionada mais comum que é a Análise de *Cluster*, onde seus algoritmos são usados para análises exploratórias visando encontrar padrões ocultos ou agrupamentos de dados (MathWorks,1990-2018).



Figura 2.15 - Principais grupos no Machine Learning. Fonte: Autoria Própria.

O processo de aplicação de uma técnica do *Machine Learning* se resume inicialmente nas etapas de realização do treinamento para que o modelo atinja um desempenho satisfatório (Figura 2.16) e posteriormente aplicar os modelos treinados de predição por meio de aplicativos ou códigos (Figura 2.17).

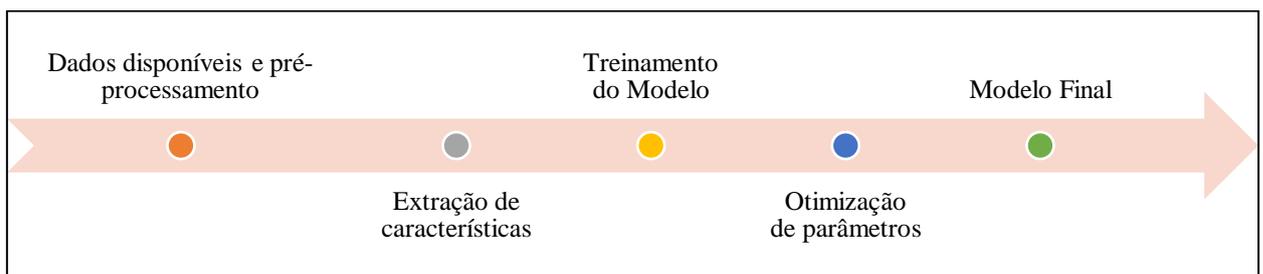


Figura 2.16 - Realização do Treinamento. Fonte: Autoria Própria.

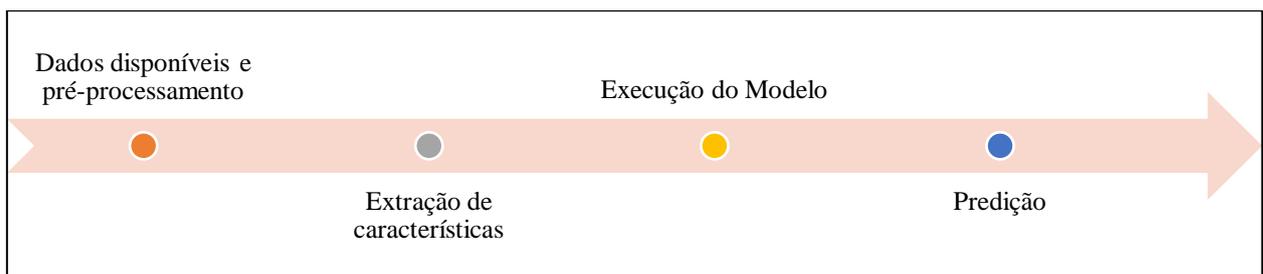


Figura 2.17 - Realização da predição. Fonte: Autoria Própria.

Além da possibilidade de uso do algoritmo do classificador *Support Vector Machine* (SVM, Máquina de Vetores de Suporte) por meio de códigos, o *Software Matlab* possui uma forma iterativa de classificação de dados, através do aplicativo *Classification Learner* (Aprendiz de Classificação), que também permite o treinamento de modelos para classificação de dados utilizando o aprendizado supervisionado, onde estão disponíveis diversos tipos de classificadores, possibilitando a escolha do que apresente melhor resultado.

2.5.1 *Support Vector Machine (SVMs)*

Dentre os algoritmos de aprendizagem supervisionada, o *Support Vector Machine (SVM)* é uma das técnicas com alto desempenho na identificação e resolução de problemas desconhecidos, aplicado em classificações de textos, no reconhecimento de digitais, previsões meteorológicas, identificação de fraudes, dentre outras. É usada com maior frequência em classificações binárias, porém podem ser aplicadas também para multiclases. Sendo usado tanto em problemas de classificação quanto de regressão.

A técnica SVM foi proposta inicialmente por Vapnik (1995), com seus princípios baseados em teorias como Vapnik-Chervonenkis (VC), Teoria do Aprendizado Estatístico (TAE), que estabelece as condições matemáticas para a escolha do classificador (LORENA, CARVALHO; 2007), como também pela *Theory of the Empirical Risk Minimization* (Teoria de minimização do risco empírico).

A minimização de riscos estruturais usadas pelas SVMs que foram desenvolvidas nas últimas décadas, trata-se de um princípio indutivo, quando o aprendizado é realizado através de conjuntos reduzidos de dados que trazem como sugestão a escolha de um classificador por meio de uma sequência de conjuntos de classificadores. As estruturas complexas tendem a reduzir o erro empírico no custo de precisão de generalização. Essa minimização busca o equilíbrio desse *trade-off*. Assim, as formulações dos SVMs consideram tanto os riscos estruturais quanto empíricos no processo de aprendizagem, gerando uma função que minimiza o risco total baseada na forma de representação e em uma medida do *trade-off* entre os dois riscos, estruturais e empíricos (SCHOLKOPF e SMOLA, 2001; CRISTIANINI e SHAW-TAYLOR, 2000; VAPNIK, 1998; *apud* AYTUG e SAYIN, 2009).

Algumas características básicas das SVMs podem ser descritas na Figura (2.18).

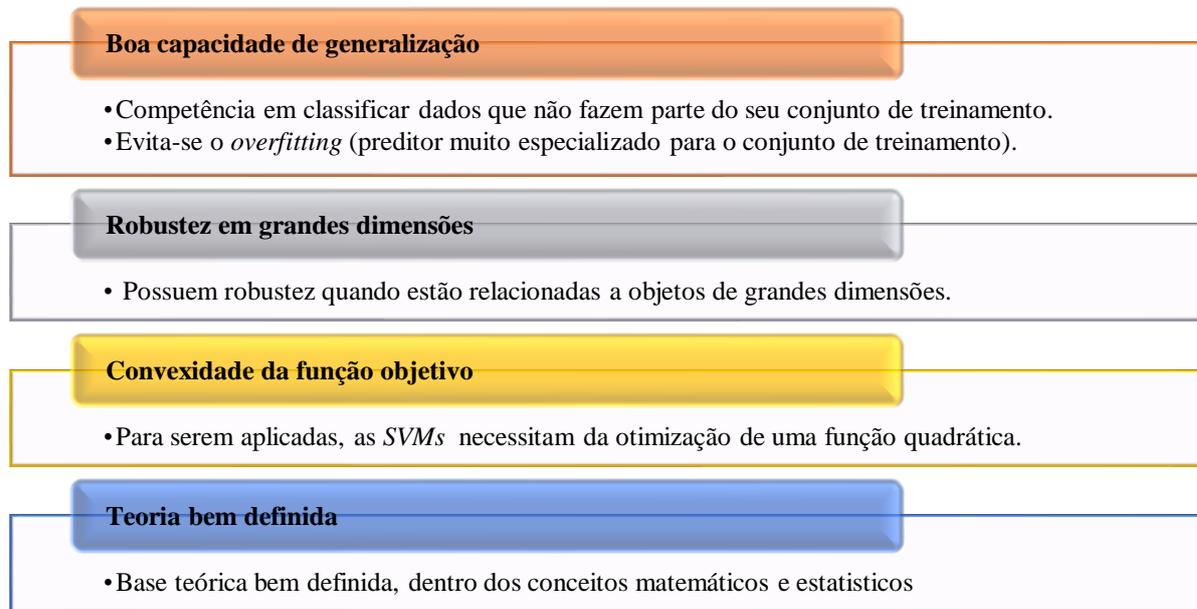


Figura 2.18 - Características das SVMs. Fonte: Adaptado de Smola *et al.* (1999b *apud* LORENA E CARVALHO, 2003).

Ao referir-se às *SVMs*, Lorena e Carvalho (2007) enfatizaram o uso do método supervisionado lidando somente com problemas de classificação binários. Definindo os três tipos de *SVM* usados em tarefas de classificações como:

- *SVMs* Lineares - Direcionados para a resolução de problemas de dados linearmente separáveis;
- *SVMs* com Margens Suaves - Trabalham com dados que possuem a presença de ruídos ou outros aspectos que tornam o treinamento mais generalizado;
- *SVMs* Não Lineares - Trabalham com problemas não lineares, fazendo o mapeamento dos dados a partir de uma transformação realizada no espaço denominado *feature*, ou seja, espaço de características.

Ainda nessa mesma linha de considerações, Aytug e Sayin (2009) ressaltam que a formulação básica do SVM cria um problema de otimização convexa em que o principal objetivo é achar o hiperplano de separação que faça a maximização da margem, e embora a teoria dessa técnica seja desenvolvida para problemas linearmente separáveis, a mesma possui a capacidade de adaptação para realizar o trabalho de separação com dados não lineares em um novo espaço transformado. Assim, Aghamohammadi e Analoui (2012) afirmam que caso não haja a possibilidade de separação desses dados linearmente, é feita a aplicação de uma função

Kernel, no que tange o mapeamento dos “dados de entrada para um espaço dimensional maior onde pode encontrar um hiperplano que possa separar duas classes de dados linearmente”.

Outro aspecto levantado por Guenther e Schonlau (2016), é que este classificador pode ser usado em três tipos diferentes de dados para regressão, denominados como Bernoulli ou binários, resultados para os quais são indicados como classificadores em aprendizagem estatística; outros tratam-se da regressão com resultados multinomiais (classificação multiclasse) e regressão com resultados contínuos. Nota-se assim a possibilidade de ampla aplicação dessa técnica em diversos campos de estudos para diferentes tipos de dados. De acordo com Ghaddar e Naoum-Sawaya (2018) os *SVMs* “formam uma classe de algoritmos de aprendizado de máquina supervisionados que treinam a função de classificador usando dados pré-rotulados”.

Um exemplo de aplicação no campo da engenharia civil, é o estudo realizado por Gui *et al.* (2017) aplicando o classificador e métodos de otimização, orientado por dados obtidos a partir de um protótipo de uma estrutura feita em alumínio com três andares, aonde foram introduzidos danos não lineares intencionalmente, dando ênfase ao monitoramento estrutural e detecção de danos. Obtiveram como resposta a alta precisão na distinção entre casos com e sem danos, mesmo apresentando algum tipo de interferência externa sobre a estrutura, verificando quais dos algoritmos de otimização apresentariam melhores resultados em conjunto com o *SVM*.

Em outro modelo, Diao *et al.* (2018), apresentam a aplicação da técnica *SVM* no campo de identificação de danos estruturais em conjunto com a função de transmissibilidade, a partir das respostas de aceleração da estrutura com danos essa função de transmissibilidade pode ser calculada, e então duas características do dano obtidas e posteriormente aplicados os algoritmos de classificação e regressão, verificando assim a sua capacidade e precisão em comparação ao método de *Wavelet*.

Outras pesquisas mostram não só a aplicação do *SVM* mais também a tentativa de aperfeiçoamento da técnica, como o estudo realizado por Kourehli (2017) que trata do diagnóstico de danos estruturais com base em respostas estáticas incompletas e a partir da aplicação de uma versão avançada do *SVM* denominada *LS-SVM* (Máquina de Vetor de Suporte de Mínimos Quadrados).

3 FUNDAMENTAÇÃO TEÓRICA

3.1 *Empirical Mode Decomposition (EMD)*

A expressão “decomposição” pode ser definida como um processo de separação de elementos que formam ou constituem determinado processo, podendo estar relacionados a análises de sinais ou de diferentes sequências. Segundo Meredith *et al.* (2012), *Empirical Mode Decomposition (EMD)* é uma técnica que converte o sinal medido em um número de funções básicas conhecidas como *Intrinsic Mode Function (IMF)*, onde o algoritmo de identificação de danos ou falhas, deve obedecer ao princípio de que uma perda repentina de rigidez em algum elemento estrutural originará uma descontinuidade na resposta medida, a qual pode ser encontrada por meio de um pico distintivo na função de modo intrínseco filtrada.

A decomposição de determinado sinal de vibração irá gerar um conjunto de componentes da *IMF* requisitado por frequência, e cada *IMF* encontrada sucessivamente possui oscilações de frequência mais baixas que a anterior. Assim, determina-se à função de modo intrínseco a representação do modo de oscilação introduzido no sinal original. O processo de decomposição da *IMF* pode ser denominado como “peneiração”. Essas funções são definidas por meio do cumprimento de dois requisitos iniciais:

1^a - O número de extremos e o número de cruzamentos de zero, dentro de um intervalo de dados, acabam sendo iguais ou apenas um deles se diferencia.

2^a - Está relacionada aos envelopes definidos pelos máximos e mínimos locais que devem ser simétricos em relação à uma determinada média.

Essa técnica realiza o processamento de sinais de inúmeros tipos de estruturas com e sem a presença de danos, o que a torna uma técnica inovadora e adaptativa. Pode ser designada também como decomposição em escala característica, que acaba sendo configurada como uma forma de processamento para obter funções de oscilação simples através do sinal. O processo de decomposição fundamenta-se nas seguintes pressuposições (CHEN *et al.* 2014):

(1) o sinal tem pelo menos dois extremos: um máximo e um mínimo;

- (2) a escala de tempo característica é definida pelo lapso de tempo entre os extremos;
- (3) se os dados fossem totalmente exclusivos, podendo ser diferenciados uma ou mais vezes para revelar os extremos.

O algoritmo EMD é baseado na produção de dois envelopes definidos pelos máximos e mínimos locais. O procedimento para decompor um sinal original $X(t)$, inicia-se no processo de encontrar todos os extremos locais desse sinal. As localizações dos picos máximos e mínimos são definidas. Esses picos são interpolados por uma spline cúbica, onde conectam-se todos os máximos locais e determina-se o envelope superior $X_{máx}(t)$, e posteriormente realiza-se o mesmo procedimento para os mínimos locais determinando o envelope inferior $X_{mín}(t)$.

A média desses dois envelopes, $X_{m1}(t)$, pode ser definida pela Equação (3.1):

$$X_{m1}(t) = \frac{X_{máx}(t) + X_{mín}(t)}{2} \quad (3.1)$$

A diferença entre o sinal original $X(t)$ e o envelope médio $X_{m1}(t)$ é dada pela Equação (3.2), a qual resultará na primeira estimativa de uma função de modo intrínseco, que possui frequência mais baixa que o sinal original.

$$h_1(t) = X(t) - X_{m1}(t) \quad (3.2)$$

Analisando o valor encontrado do primeiro componente $h_1(t)$, é necessário verificar se o mesmo cumpre os dois requisitos iniciais para ser determinado como um IMF. Se $h_1(t)$ cumprir os requisitos, define-se a primeira função de modo intrínseco (IMF 1) que pode ser denominado $c_i(t)$, assim $h_1(t) = c_i(t)$. No entanto, se o componente não cumprir com os requisitos, deve ser realizado um novo processo de peneiração até que se encontre uma melhor estimativa para o primeiro componente IMF 1.

No segundo processo de peneiração (decomposição sucessiva dos sinais), o valor de $X(t)$ é substituído. Considera-se no seu lugar o valor de $h_1(t)$ como sendo o sinal para que a próxima estimativa seja encontrada, e $X_{m11}(t)$ a nova média entre os envelopes superior e inferior de $h_1(t)$, então:

$$h_{11}(t) = h_1(t) - X_{m11}(t) \quad (3.3)$$

Após a realização dos processos de peneiramentos, a primeira IMF é definida como c_1 , e assim sucessivamente para as demais. Após encontrar o “IMF 1”, é preciso achar um resíduo $r_1(t)$, dado pela expressão (3.4), que resulta da diferença entre $c_1(t)$ e o valor do sinal original $X(t)$:

$$r_1(t) = X(t) - c_1(t) \quad (3.4)$$

Este procedimento pode ser aplicado continuamente para obter cada resíduo subsequente, assim considera-se:

$$r_2(t) = r_1(t) - c_2(t)[\dots], r_n(t) = r_{n-1}(t) - c_n(t) \quad (3.5)$$

Esse processo vai sendo realizado até que o resíduo $r_n(t)$ seja menor que um valor pré-determinado ou até que não haja máximos e mínimos locais suficientes e se torne uma constante. Após realizar todo o processo de decomposição, o sinal original pode ser reconstruído através da seguinte expressão:

$$X(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (3.6)$$

sendo n o número total de IMFs extraídas, $r_n(t)$ o resíduo final encontrado, e $c_i(t)$ é i th componente IMF.

Com a finalidade de garantir um sentido físico suficiente de modulações de amplitude e frequência, Huang *et al.* (1996) definiram um critério para finalizar o processo de peneiração através da determinação de um limite para o tamanho do desvio padrão (SD), que pode ser calculado a partir dos dois resultados de peneiração sucessivo (equação 3.7).

$$SD = \sum_{t=1}^T \left[\frac{|h_{1(k-1)}(t) - h_{1k}(t)|}{h_{1(k-1)}^2(t)} \right] \quad (3.7)$$

O fluxograma do *EMD* mostrado na Figura (3.1) resume todos esses passos:

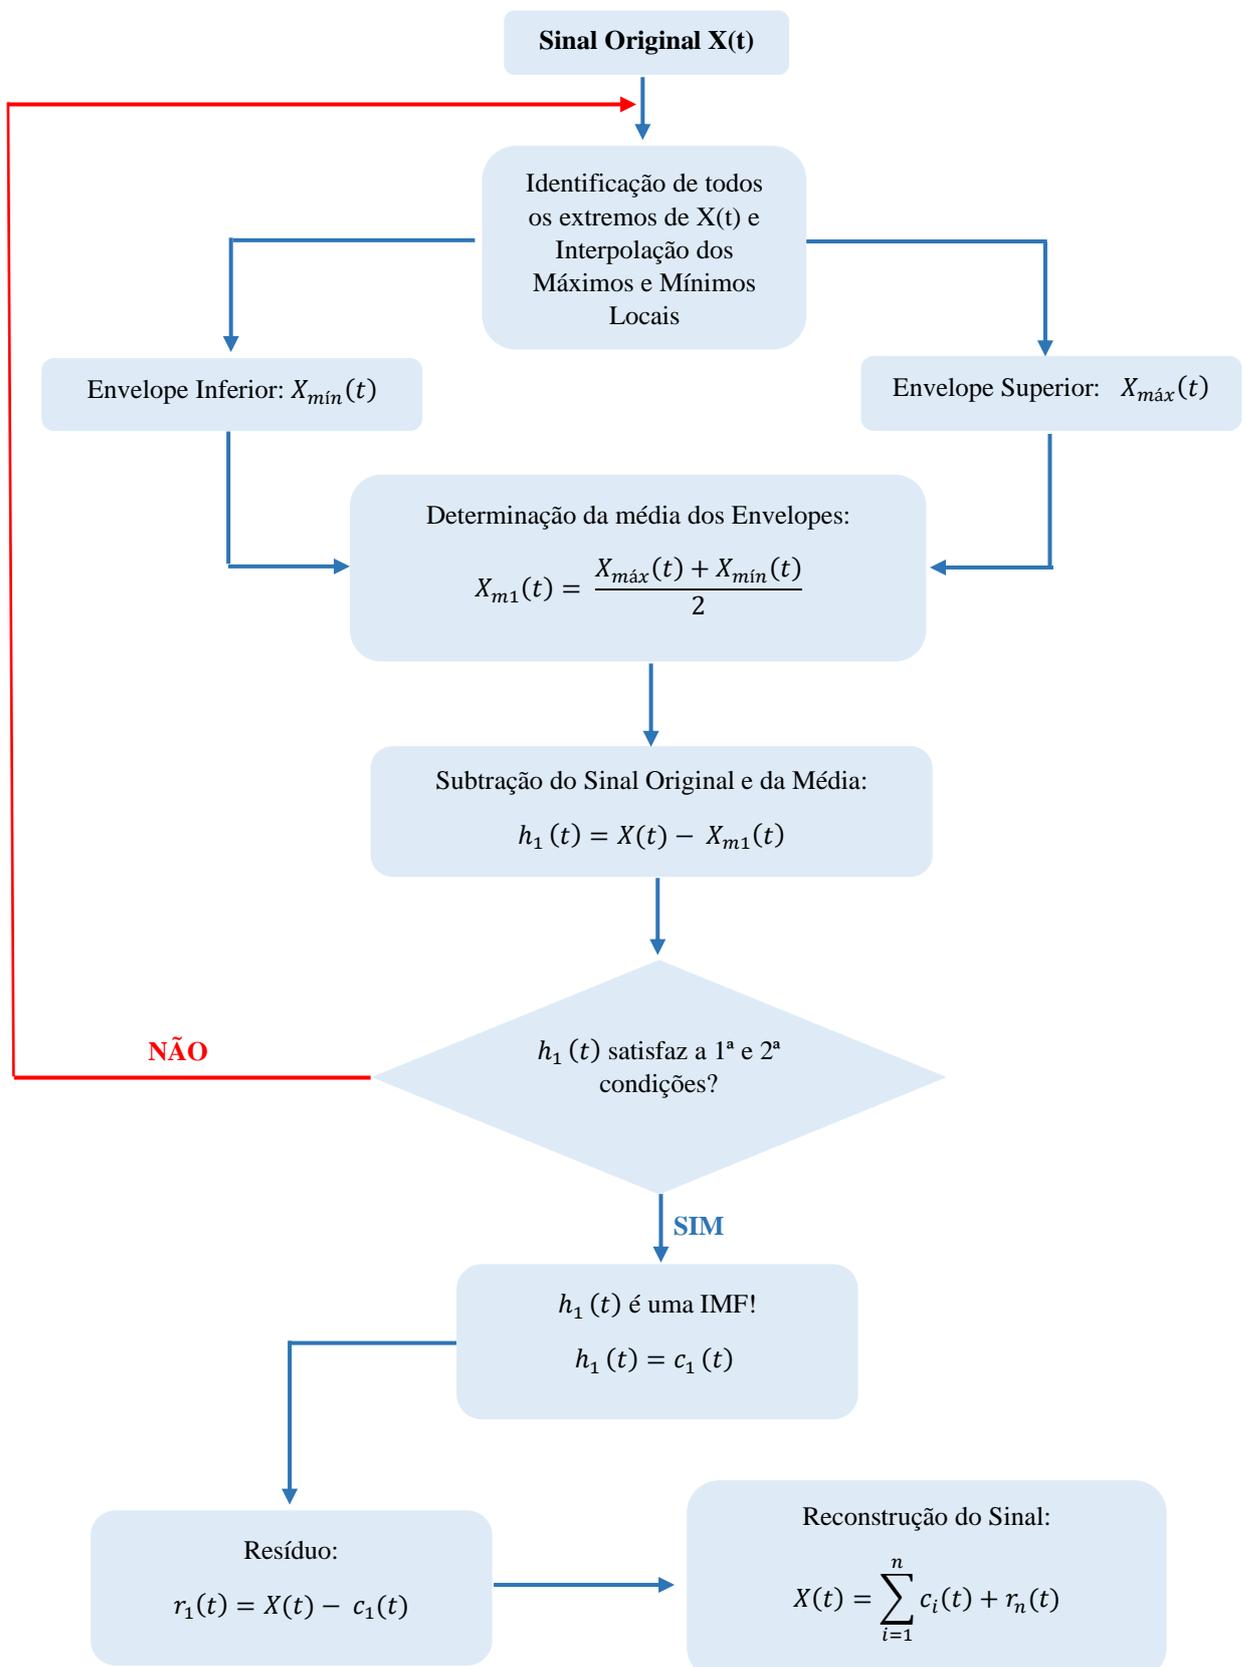


Figura 3.1 - Fluxograma do processo EMD. Fonte: Adaptado de Lei *et al.* (2013).

3.2 Ensemble Empirical Mode Decomposition (EEMD)

Com o surgimento do *Mode Mixing* e de outros problemas relacionados ao método tradicional *EMD*, foi apresentada uma nova proposta metodológica de decomposição que aborda a aplicação de um sinal de ruído branco adicionado aos dados, denominado como *Ensemble Empirical Mode Decomposition (EEMD)*. Essa proposta tem como finalidade fazer com que o ruído preencha completamente e uniformemente o espaço tempo-frequência, para promover a separação natural das escalas de frequência e reduzir significativamente o problema da mistura de modo. Assim, esse sinal de ruído automaticamente se anularia na média final das IMFs.

Wu e Huang (2009) resumiram um conceito crítico desse método em algumas observações, tais como:

- Inicialmente determina que uma coleção de ruído branco se anula em uma média de tempo-espaço, onde somente o sinal pode sobreviver e persistir na média final do conjunto de sinais de ruído;
- A aplicação desse ruído branco finito, não infinitesimal, de amplitude é importante para forçar o conjunto e esgotar todas as soluções possíveis;
- A resposta verdadeira e fisicamente significativa ao EMD não é aquela sem ruído, é designada como conjunto médio de um grande número de tentativas consistindo ao sinal de ruído adicionado;

Tendo em vista a capacidade da média do conjunto e que os dados são coletados por observações separadas, cada uma com um ruído diferente. A generalização dessa ideia parte do princípio que o ruído é introduzido no conjunto de dados único, $x(t)$, como se observações separadas estivessem de fato sendo feitas como um análogo a um experimento físico que poderia ser repetido muitas vezes.

3.2.1 Algoritmo EEMD

O Algoritmo *EEMD* é definido resumidamente por Lei *et al.* (2013) nos seguintes passos:

- Passo 1 – O número de tentativas no conjunto pode ser inicializado, M , a amplitude do ruído branco adicionado e o número do teste $m = 1$.
- Passo 2 - Execute o julgamento m th no sinal adicionado com ruído branco:
 - (a) Gerar uma série de ruído branco com a amplitude inicializada e adicioná-lo ao sinal investigado $X_m(t) = X(t) + n_m(t)$, onde $n_m(t)$ indica a m th série de ruído branco adicionado e $X_m(t)$ representa o sinal de ruído adicionado da tentativa m th.
 - (b) Decomponha o sinal de ruído adicionado $X_m(t)$, em I *IMFs* $c_{i,m}$ ($i = 1, 2, \dots, I$) usando o método *EMD* tradicional, onde $c_{i,m}$ denota o i th *IMF* da tentativa m th, e I é o número de *IMFs*.
 - (c) Se o número do teste for menor que o número requerido, ou seja, $m < M$, então vá para o passo (a) com $m = m + 1$. Repita os passos (a) e (b) novamente, mas com uma nova série de ruído branco gerada aleatoriamente cada vez.
- Passo 3 – Cálculo da média \bar{c}_i dos ensaios M para cada *IMF* $y_i = \frac{1}{M} \sum_{m=1}^M c_{i,m}$, $i = 1, 2, \dots, I$, $m = 1, 2, \dots, M$.
- Passo 4 – Reportar a média y_i ($i = 1, 2, \dots, I$) de cada um dos I *IMF* como os *IMFs* finais.

A Figura (3.2) mostra um fluxograma resumido desse processo:

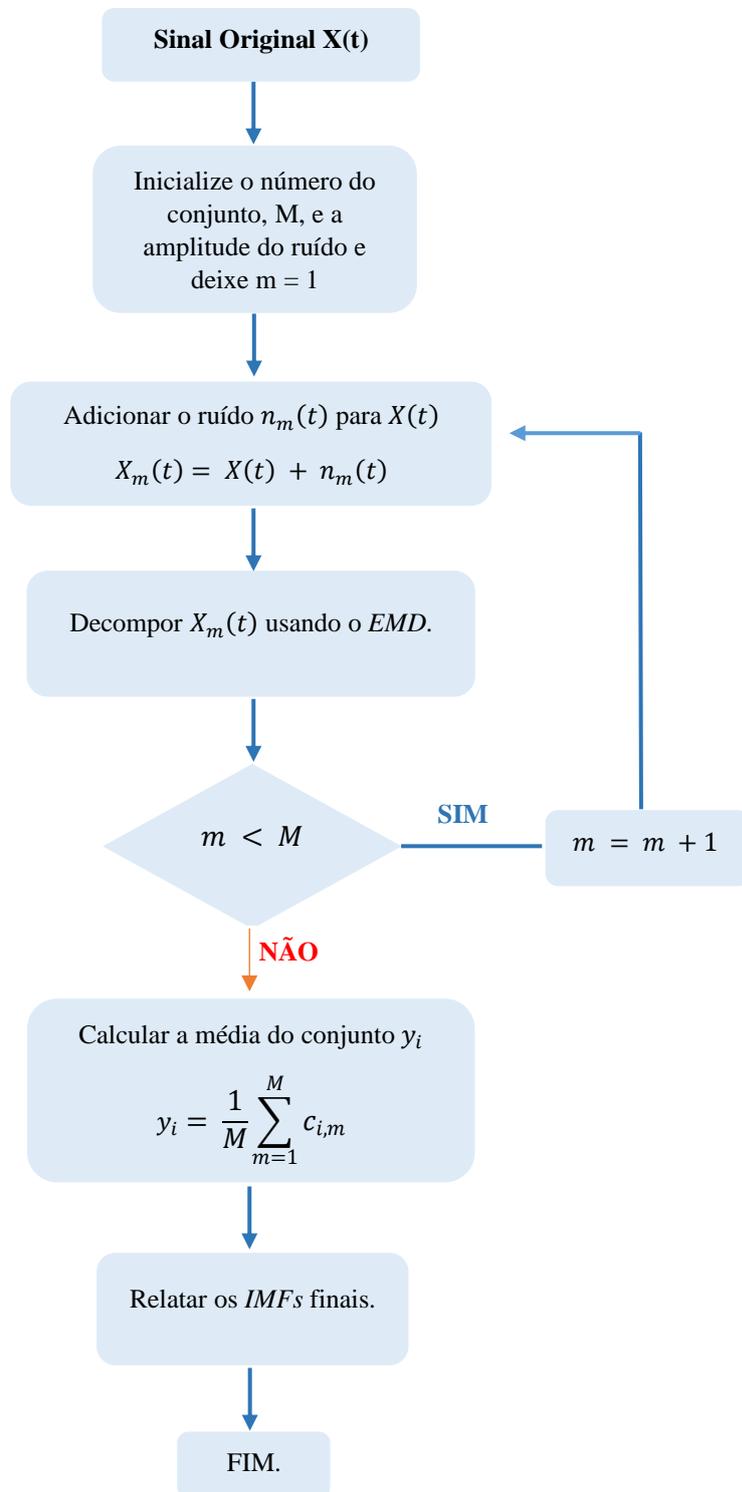


Figura 3.2 - Fluxograma do processo EEMD. Fonte: Adaptado de Lei *et al.* (2013).

3.3 Modelo Auto Regressivo (AR)

Considerando, um caso particular simples e de grande importância, o processo autorregressivo AR de ordem p pode ser descrito a partir da seguinte equação geral:

$$Y_t = \Psi + \Psi_1 Y_{t-1} + \Psi_2 Y_{t-2} + \dots + \Psi_p Y_{t-p} + \varepsilon_t \quad (3.8)$$

sendo

Ψ_i – parâmetros auto-regressivos da estrutura, $i = 1, \dots, p$ (ordem da estrutura);

Y_{t-1} - série de tempo defasado um período;

ε_t – termo de erro aleatório do modelo;

Assim, $\Psi_0, \Psi_1, \dots, \Psi_p$ tratam-se de parâmetros reais, para os quais a soma dos mesmos deve ser menor ou igual a 1 para que o processo seja estacionário. Os valores de Y_{t-1}, \dots, Y_{t-p} são independentes de ε_t . Dessa maneira considera-se que “no processo auto regressivo de ordem p a observação Y_t é gerada por uma média ponderada de observações passadas que recua p períodos, junto com a perturbação aleatória no período corrente” (Pindyck, Rubinfeld, 2004). E ainda, Zaiantz (2013-2018) afirma que “semelhante ao modelo de regressão linear comum, assumimos que os termos de erro são distribuídos independentemente com base em uma distribuição normal com média zero e uma variância σ^2 e que os termos de erro são independentes dos valores de y ”.

3.4 Support Vector Machine (SVM)

3.4.1 SVM - Linear com Margens Rígidas

Tomando como exemplo um conjunto de treinamento D com classificação na forma $\{x_i, y_i\}$, $i = (1, 2, \dots, D)$, para os quais tem-se a representação vetorial $x_i \in \mathbb{R}$ e a classe correspondente $y_i \in \{-1, 1\}$ que são usadas como rótulos que identificam as classes positivas e

negativas. O principal objetivo do SVM é definir o hiperplano que tenha a capacidade de classificar esse conjunto em duas classes distintas (conjunto binário), que só é linearmente separável caso separem essas classes por pelo menos um hiperplano.

Como ilustra a Figura (3.3), tem-se a representação de duas classes de dados, para as quais podem ser traçadas várias linhas de separação. No entanto, a melhor escolha é a que representa a margem máxima de ambas as classes. Essa margem corresponde a distância entre o hiperplano e os elementos mais próximos.

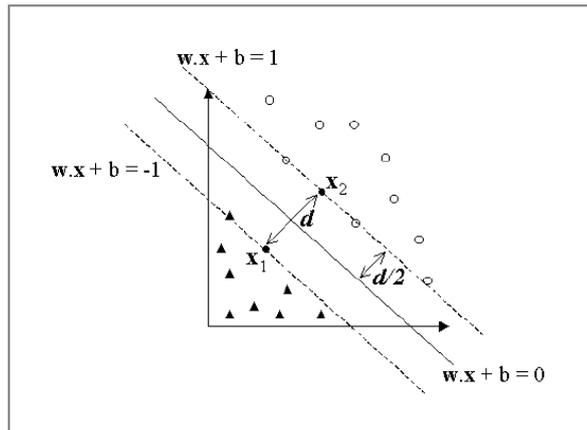


Figura 3.3 - Cálculo da distância d entre os hiperplanos $w \cdot x + b = 1$ e $w \cdot x + b = -1$. Fonte: Lorena e Carvalho (2003).

Esse hiperplano pode ser definido pela Equação (3.9), onde tem-se o produto escalar entre x e w somado ao termo b :

$$x \cdot w + b = 0 \tag{3.9}$$

Dividindo o plano em regiões negativas e positivas:

$$\begin{cases} y_i = +1 & \text{caso } x_i \cdot w + b > 0 \\ y_i = -1 & \text{caso } x_i \cdot w + b < 0 \end{cases} \tag{3.10}$$

Em uma definição formal Müller *et al.* (2001) supõe que uma amostra de dados para treinamento seja separada pelo hiperplano representado pela equação:

$$f(x) = (x \cdot w) + b \quad (3.11)$$

Müller *et al.* (2001) afirma que “a margem de um classificador linear é a distância mínima de qualquer ponto de treinamento para o hiperplano [...], é a distância entre as linhas pontilhadas e a linha grossa”. Assim, a margem pode ser então mensurada pelo vetor de peso w da equação anterior, os valores de w e b podem ser então redimensionados para os pontos mais próximos do hiperplano satisfaçam a chamada representação canônica do hiperplano:

$$(x \cdot w) + b = 1 \quad (3.12)$$

A partir de duas amostras de classes distintas x_1 e x_2 , temos o seguinte sistema:

$$x_1 \rightarrow (x_1 \cdot w) + b = +1 \quad (3.13)$$

$$x_2 \rightarrow (x_2 \cdot w) + b = -1 \quad (3.14)$$

De acordo com Lorena e Carvalho (2003), desse sistema obtém-se a Equação (3.15),

$$w \cdot (x_2 - x_1) = 2 \quad (3.15)$$

Esses valores de w e $x_2 - x_1$ são ortogonais ao hiperplano que separa os dados e paralelos entre si. Pode então ser feita a dedução da Equação (3.16), onde tem se a representação da norma de um vetor pelo $\| \cdot \|$:

$$|w \cdot (x_2 - x_1)| = \|w\| \times \|x_2 - x_1\| \quad (3.16)$$

Realizando a substituição de (3.15) em (3.16), é obtido a equação (3.17):

$$\|x_2 - x_1\| = \frac{2}{\|w\|} \quad (3.17)$$

Nessa perspectiva, o valor de $\frac{2}{\|w\|}$ representa a largura da margem e a distância entre os dois hiperplanos representados pela equação (3.13) e (3.14) que geram a margem máxima são encontrados a partir da minimização de $\|w\|^2$. Esse tipo de situação corresponde ao objetivo principal do algoritmo do *SVM*, formulando-se como um problema de otimização quadrática, assumindo a seguinte forma da Equação (3.18) e possuindo a seguinte restrição:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ onde } y_i(w \cdot x_i + b) \geq 1, i = 1, \dots, n \quad (3.18)$$

Normalmente para essa problemática faz-se a introdução de multiplicadores de Lagrange, visando facilitar essa minimização, obtendo assim uma otimização dual do problema, que pode ser descrito pela equação:

$$L(\alpha, w, b) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^D \alpha_i [y_i(x_i \cdot w + b) - 1] \quad (3.19)$$

sendo que, α_i são os multiplicadores Lagrangeanos, $i = 1, 2, \dots, D$ e $\alpha_i \geq 0$. A função Lagrangeana precisa então ser minimizada, o que resulta na maximização das variáveis α_i e minimização de w e b . Através da resolução das igualdades (3.20) e (3.21) obtém-se os pontos da equação:

$$\frac{\partial L}{\partial b} = 0 \quad (3.20)$$

$$\frac{\partial L}{\partial w} = 0 \quad (3.21)$$

Estas equações (3.20) e (3.21) resultam em:

$$\sum_{i=1}^D \alpha_i y_i = 0 \quad (3.22)$$

$$w = \sum_{i=1}^D \alpha_i y_i x_i \quad (3.23)$$

Substituindo (3.22) e (3.23) na equação (3.19), obtém-se o problema de otimização dual descrito como:

$$\sum_{i=1}^D \alpha_i - \frac{1}{2} \sum_{i=1}^D \sum_{j=1}^D y_i y_j \alpha_i \alpha_j x_i x_j \quad (3.24)$$

sob as restrições:

$$\sum_{i=1}^D y_i \alpha_i = 0 \quad , \quad \text{onde} \quad \alpha_i \geq 0, i = 1, \dots, D \quad (3.25)$$

Após a realização desses processos, o hiperplano ótimo é definido pelas equações (3.26) e (3.27):

$$w^* = \sum_{i=1}^D \alpha_i^* y_i x_i \quad (3.26)$$

$$b^* = -\frac{1}{2} \left[\max_{\{i|y_i=-1\}} (w^* \cdot x_i) + \min_{\{i|y_i=+1\}} (w^* \cdot x_i) \right] \quad (3.27)$$

3.4.2 SVM - Margens Suaves

Com os inúmeros casos de dados com existência de ruídos, outliers ou outros aspectos que impeçam a sua total linearidade, os SVMs Lineares com margens rígidas são adaptados para trabalharem com dados de treinamentos que sejam mais generalizados, aplicando um método de suavização de margens. No intuito de lidar com esse tipo de situação, são introduzidas variáveis de relaxamento ζ , (Equações 3.28 e 3.29) tendendo a suavizar as restrições impostas na determinação do hiperplano ótimo, porém admitindo a existência de erros (LORENA, CARVALHO, 2001).

$$y_i = +1 \quad \zeta_i(w, b) = \begin{cases} 0 & \text{se } w \cdot x_1 + b \geq 1 \\ 1 - w \cdot x_1 + b & \text{se } w \cdot x_1 + b < 1 \end{cases} \quad (3.28)$$

$$y_i = -1 \quad \zeta_i(w, b) = \begin{cases} 0 & \text{se } w \cdot x_1 + b \leq -1 \\ 1 + w \cdot x_1 + b & \text{se } w \cdot x_1 + b > -1 \end{cases} \quad (3.29)$$

Essas variáveis de relaxamento ζ buscam encontrar (x_1, y_1) em função do hiperplano $w \cdot x_1 + b = \pm 1$. “Caso o valor seja 0, o exemplo está fora da região entre estes hiperplanos e caso seja positivo, mede a distância do padrão em relação aos mesmos. Outra questão está relacionada aos dados classificados erroneamente, onde o valor do ζ_i assume valor maior que 1, através desse artifício é evitado que a SVM ajuste o hiperplano segundo ruídos nos dados.”

Nos casos de conjuntos linearmente separáveis, o melhor classificador é aquele que possui a menor quantidade de erros em seu treinamento e uma boa generalização a partir da maximização da margem de separação entre as classes. Já nesses casos onde buscam-se conjuntos mais gerais, o classificador deve atender a alguns requisitos, tais como:

- 1º As Variáveis ζ_i devem possuir valor mínimo para todo o conjunto de treinamento;
- 2º É realizada a minimização de $\|w\|$.

Considerando C como uma constante que impõe um peso diferente para o treinamento em relação a generalização, sendo determinada empiricamente. Por meio da equação (3.30) os valores a serem minimizados podem ser encontrados pela combinação:

$$\varepsilon(w, b) = \|w\|^2 + C \sum_{t=1}^n \zeta_t(w, b) \quad (3.30)$$

Assim, o hiperplano ótimo se resume em encontrar o par (w^*, b^*) que faça a minimização da equação anterior. Como as funções $\zeta_t(w, b)$ não são diferenciados em w e b , o problema é reformulado com a minimização de (3.31) sob as restrições:

$$\|w\|^2 + C \sum_{t=1}^n \xi_t \quad \text{Restrições} \rightarrow \xi_t \geq \zeta_t(w, b), t = 1, \dots, n \quad (3.31)$$

A partir das equações (3.28) e (3.29) a restrição pode ser reescrita da forma:

$$\begin{cases} \xi_t \geq 0 \\ y_t(w \cdot x_t + b) \geq 1 - \xi_t \end{cases} \quad (3.32)$$

Tem-se então um problema de otimização quadrática, onde as condições são apresentadas em (i), (ii) e (iii), onde $y_t f(x_t)$ é a margem de classificação do exemplo t :

$$(i) \alpha_t = 0 \rightarrow y_t f(x_t) \geq 1 \text{ e } \xi_t = 0$$

$$(ii) 0 < \alpha_t < C \rightarrow y_t f(x_t) = 1 \text{ e } \xi_t = 0 \quad (3.33)$$

$$(iii) \alpha_t = C \rightarrow y_t f(x_t) < 1 \text{ e } \xi_t \geq 0$$

3.4.3 SVM - Não Lineares

Levando em consideração a facilidade de classificar os dados a partir de problemas linearmente separáveis, sua aplicação pode ser considerada restrita. Muitas vezes em decorrência dos tipos de dados o hiperplano torna-se insatisfatório, sendo necessário um espaço de maior dimensão para realizar o mapeamento do conjunto de treinamento. Esse espaço é denominado como *feature space* (espaço de características).

Considerando o seguinte conjunto de treinamento S (LORENA, CARVALHO, 2003):

$$\begin{cases} S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \\ x_i = (x_{i1}, x_{i2}, \dots, x_{im}) \text{ e } x_i = (x_{i1}, x_{i2}, \dots, x_{im}) \end{cases} \quad (3.34)$$

São consideradas no domínio do espaço de entrada, as funções reais Φ_1, \dots, Φ_M , dando início ao mapeamento do conjunto de treinamento S para o novo *feature space*.

$$\begin{cases} \Phi(S) = \{(\Phi(x_1), y_1), (\Phi(x_2), y_2), \dots, (\Phi(x_n), y_n))\} \\ x_i (i = 1, \dots, n) \rightarrow \Phi(x_i) = (\Phi_1(x_i), \Phi_2(x_i), \dots, \Phi_M(x_i)) \end{cases} \quad (3.35)$$

Após a escolha de uma função Φ adequada ao mapeamento, o conjunto de treinamento não-linear pode ser linearmente separável, como mostra a figura a seguir:

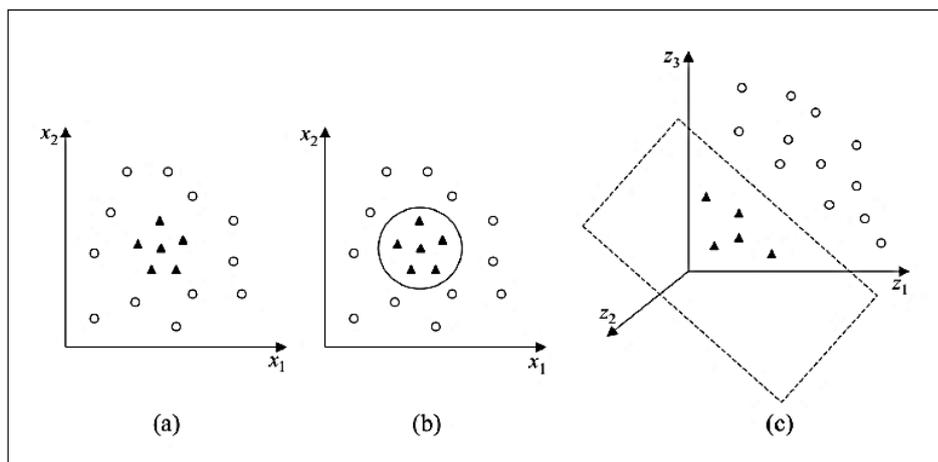


Figura 3.4 - (a) Conjuntos de dados não linear; (b) Fronteira não linear no espaço de entradas; (c) Fronteira linear no espaço de características. Fonte: Lorena e Carvalho (2007).

Segundo Müller (2001) as condições para uma perfeita classificação no *feature space* são descritas como:

$$y_i(w \cdot \Phi(x_i)) + b \geq 1, \quad (i = 1, \dots, n) \quad (3.36)$$

Nesse caso, procura-se fazer a minimização do termo de complexidade minimizando $\|w\|^2$, onde pode ser formulado como o problema de otimização quadrática:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (3.37)$$

Porém, só é possível acessar o *feature space* através da aplicação de funções *Kernels*, assim o problema (3.37) não pode ser resolvido de forma direta. Aplica-se então a solução através dos multiplicadores Lagrangianos:

$$L(\alpha, w, b) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^D \alpha_i [y_i(\Phi(x_i) \cdot w + b) - 1] \quad (3.38)$$

Com a seguinte transformação:

$$\frac{\partial L}{\partial b} = 0 \quad \rightarrow \quad \sum_{i=1}^D \alpha_i y_i = 0 \quad (3.39)$$

$$\frac{\partial L}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^D \alpha_i y_i \Phi(\mathbf{x}_i) \quad (3.40)$$

Para a equação (3.40) transformada, o valor de w é encontrado no subespaço medido por $\Phi(\mathbf{x}_i)$. Substituindo os valores transformados de (3.39) e (3.40) na equação (3.38) e substituindo $(\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$ com as funções *kernel* $\mathbf{k}(\mathbf{x}_i, \mathbf{x}_j)$, resulta no problema de otimização dupla quadrática:

$$\max_{\alpha} \quad \sum_{i=1}^D \alpha_i - \frac{1}{2} \sum_{i,j=1}^D \alpha_i \alpha_j y_i y_j \mathbf{k}(\mathbf{x}_i, \mathbf{x}_j) \quad (3.41)$$

Onde, estão sujeitas:

$$\alpha_i \geq 0, \quad i = 1, \dots, n \quad e \quad \sum_{i=1}^D \alpha_i y_i = 0 \quad (3.42)$$

Dessa forma, pela solução do problema de otimização dupla, são obtidos os coeficientes α_i , $i = 1, \dots, n$, qual deles precisa expressar o w que resolve o sistema (3.37). Isso leva a função de decisão não linear, descrita como:

$$f(x) = \text{sgn}(\sum_{i=1}^D \alpha_i y_i (\Phi(x) \cdot \Phi(\mathbf{x}_i)) + b)$$

$$f(x) = \text{sgn}(\sum_{i=1}^D \alpha_i \alpha_j k(\mathbf{x}_i, \mathbf{x}_j) + b) \quad (3.43)$$

3.4.3.1 Funções Kernel

As funções *kernels* podem ser definidas como um conjunto de funções matemáticas usadas nos algoritmos SVM, pegando dados como entrada e transformando-os no novo formato, uma das suas principais características é a “capacidade em representar espaços abstratos” (LORENA, KARVALHO, 2007).

Os dados em casos não lineares, são mapeados automaticamente para um espaço de dimensão superior H por uma função $\Phi(\mathbf{x}) \in H$, onde são capturados com eficiência as dependências não lineares e são dados os valores necessários para calcular são da forma $\Phi(\mathbf{x}) \cdot \Phi(\mathbf{y})$, realiza-se o mapeamento por uma função $K(\mathbf{x}, \mathbf{y}) = \Phi(\mathbf{x}) \cdot \Phi(\mathbf{y})$ (EVGENIOU, *et al.*, 2005; SCHOELKOPF e SMOLA, 2002; *apud* MALDONADO *et al.*, 2015).

Algumas das funções *kernels* mais empregadas são descritas na tabela a seguir:

Tabela 3.1 - Principais funções Kernel aplicadas. Fonte: Adaptado de DATAFLAIR TEAM (2017).

Tipo de Kernel	Função $k(\mathbf{x}_i, \mathbf{x}_j)$
Polinomial	$k(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^d$
Gaussian (RBF)	$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \ \mathbf{x}_i - \mathbf{x}_j\ ^2)$
Sigmoid	$k(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\alpha \mathbf{x}_i^T \mathbf{x}_j + c)$

De acordo com Müller *et al.* (2001) um dos pontos interessantes em relação as funções *Kernels* é que o produto escalar pode ser implicitamente computado, sem usar explicitamente ou mesmo conhecer o mapeamento (Φ). Desta maneira, os kernels permitem calcular produtos escalares em determinados espaços, onde provavelmente outro modelo dificilmente conseguiria.

4 ESTUDO DE CASO

4.1 Modelagem das vigas pelo SAP 2000

As simulações computacionais, são ferramentas essenciais tanto para o dimensionamento de estruturas quanto para os cálculos de seus esforços atuantes. Grande parte dos softwares para análises estruturais fazem uso do Método dos Elementos Finitos, os quais permitem a criação da estrutura com as propriedades geométricas, dos materiais, delimitações de parâmetros, coeficientes de segurança, e outras características similares a uma estrutura real.

Dentre os softwares que fazem uso dos Elementos Finitos, destaca-se o *SAP2000* que é um programa de Análise Estrutural da *CSI Computers & Structures*, fundada por Ashraf Habibullah em 1975. Este software possui uma interface ampla que traz a possibilidade de executar modelagem, análise, design e geração de relatórios. Além de realizar análises estruturais e dinâmicas, lineares e não lineares.

Dentre os vários componentes estruturais disponibilizados pelo programa, destacam-se: *Joints* (juntas de interseção); *Shells* (objeto de área, usado para a modelagem do comportamento da membrana, placas e casca em estruturas planares e tridimensionais); e os *Solids*, são definidos como elementos de oito nós, indicado para a modelagem de estruturas e sólidos tridimensionais; dentre outros componentes.

Para realização das análises, o *SAP 2000* possui métodos estáticos e dinâmicos, dependendo da necessidade de cada análise estrutural. Neste trabalho será empregado um método para análise dinâmica através da criação de um caso de análise Dinâmica/Linear e do tipo *Time History* (histórico de tempo), para a qual permite a criação de uma função, podendo ser gerada automaticamente pelo programa como por exemplo, funções seno, cosseno, rampa, ou criadas e inseridas pelo próprio usuário. Conforme o *CSI Computers & Structures*, a função *Time History* realiza uma análise através da captação detalhada das respostas da estrutura a movimentos básicos provenientes de ações como explosões, equipamentos, terremotos, vento, onda, impactos, dentre outras. Além disso, “a análise pode recorrer a uma sobreposição modal ou a métodos de integração direta, tanto lineares quanto não lineares”.

4.2 Etapas da modelagem

Para a modelagem, considerou-se uma chapa de aço simulando uma estrutura bi-apoiada com e sem regiões danificadas, para as quais foram consideradas a determinação de algumas características e a sequência de trabalho mostrada na Figura (4.1).

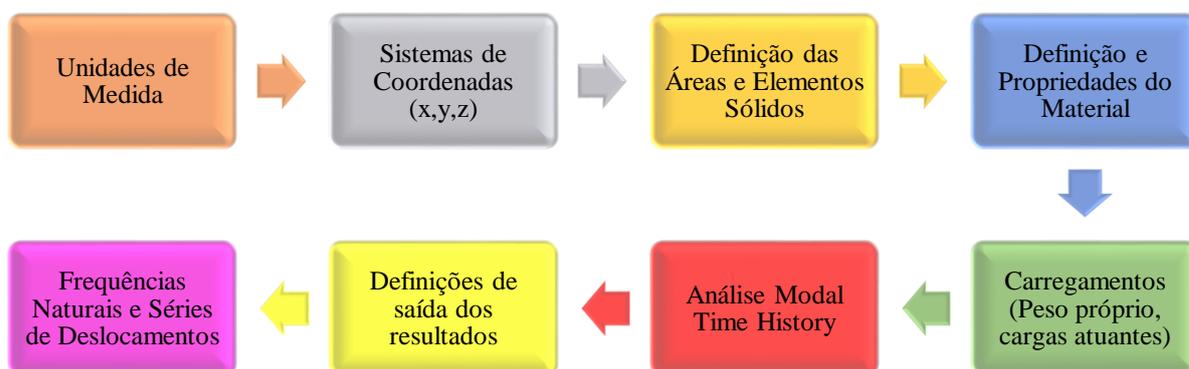


Figura 4.1 - Definições de parâmetros para a modelagem das estruturas. Fonte: Autoria Própria.

Inicialmente foram definidas as unidades de medidas, as coordenadas (x, y, z) de acordo com as medidas da peça de altura, largura e comprimento, que originarão as áreas e os elementos finitos. Em seguida o material pôde ser escolhido, no caso Aço ASTM 36, onde o programa lança automaticamente as suas propriedades, possibilitando a realização de ajustes ou mudança de alguns dos seus valores. Em continuação, as cargas juntamente com as funções de análises puderam ser determinadas para obtenção dos valores de frequências naturais e séries de deslocamentos.

4.3 Esquema para análise de convergência da Malha

A malha de uma estrutura trata-se de uma das ferramentas das modelagens computacionais através do Método dos Elementos Finitos para garantir a precisão dos resultados obtidos, normalmente quanto maior o grau de refinamento da malha, maior é a precisão da análise, em contrapartida, eleva-se também o custo computacional e o tempo de

cálculo. Normalmente, busca-se verificar a capacidade da malha em gerar os resultados, a partir de um estudo de convergência da malha, como mostrado por Ajeje *et al.* (2011) a partir da discretização de uma viga em balanço, com quatro malhas diferentes ($N = 2, 4, 8$ e 16) e obtendo os valores referentes aos deslocamentos transversais em um ponto na extremidade da viga, como mostra a Figura (4.2).

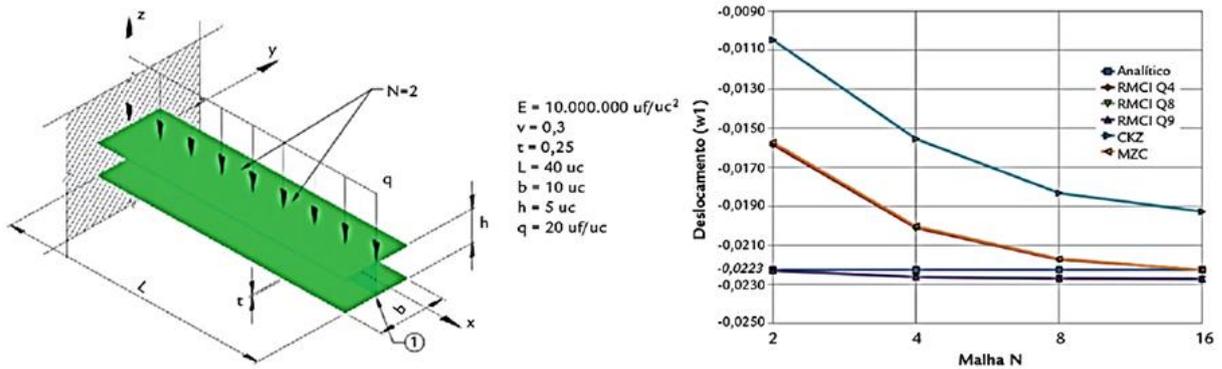


Figura 4.2 - Estudo de convergência para uma viga em balanço. Fonte: Ajeje *et al.* (2011).

A estrutura a ser modelada neste trabalho, é composta por elementos sólidos, formando assim a malha por elementos finitos. Para a criação de todas as análises de convergência da malha e com modelos preditores, a estrutura em questão foi modelada com as propriedades contidas na Tabela (4.1).

Tabela 4.1 – Propriedades gerais das vigas. Fonte: Autoria própria, 2019.

Propriedades	
Comprimento da viga	10 m
Largura	1 m
Altura	0,15 m
Material	Aço A36
Densidade do Material	7850 kg/m ³
Módulo de Elasticidade Longitudinal da Viga	200 GPa

Para análise da convergência da malha, é necessário que haja um carregamento na estrutura para que sejam obtidos os seus deslocamentos verticais e então compará-los. Para isso foi criado um tipo de carregamento vertical aplicado no centro da estrutura, chamado de

impulso unitário, onde determinou-se uma carga de 100 kN com duração de 0,1 segundos. O esquema de aplicação é mostrado na Figura (4.3).

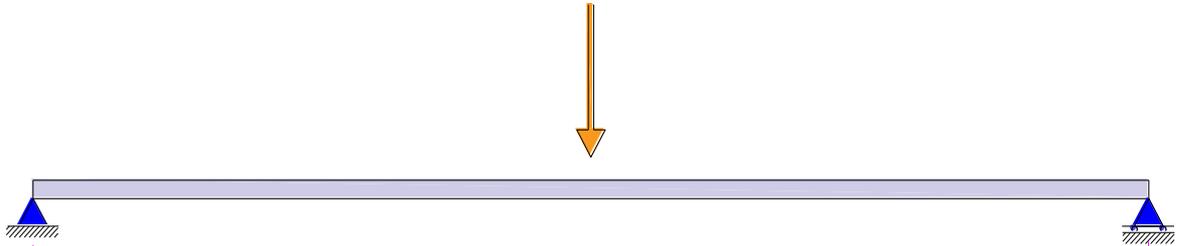


Figura 4.3 – Esquema para análise com aplicação da carga no centro. Fonte: Autoria própria, 2019.

Considerando a análise de convergência da malha apenas em estruturas íntegras, visando identificar a quantidade de elementos sólidos aproximada que se adequaria à modelagem das vigas danificadas, determinou-se análises com sete casos de malhas possuindo diferentes números de elementos ($N=100, 4000, 6000, 8000, 10000, 12000, 14000$), conforme a Figura (4.4).

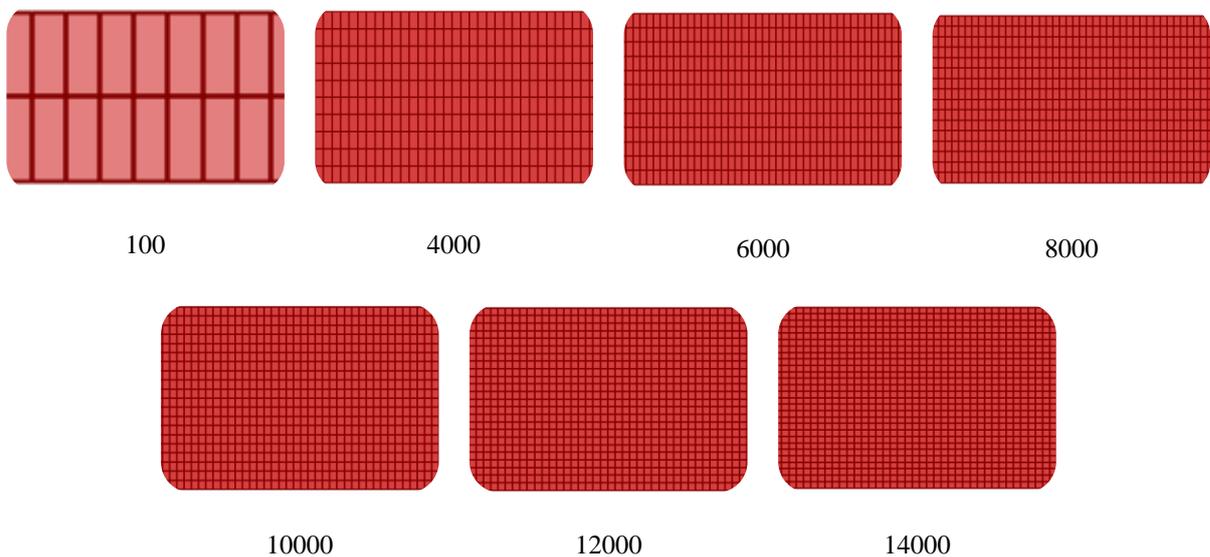


Figura 4.4 – Refinamento da malha de elementos sólidos. Fonte: Autoria própria, 2019.

4.4 Esquema para análise com modelos preditores

Para a criação das análises para aplicação dos modelos preditores, foram utilizadas as propriedades gerais das vigas com e sem regiões danificadas (Tabela 4.1). A Figura (4.5) mostra um esquema de viga bi-apoiada com sua estrutura totalmente íntegra com aplicação de um carregamento aleatório em um ponto da viga. A seta sobre a estrutura indica a localização em que o carregamento vertical foi inserido (6.5 m em relação à extremidade esquerda da viga). Em seguida inseriu-se na estrutura um dano com geometria triangular (Figuras 4.6 e 4.7).



Figura 4.5 – Esquema da viga íntegra e aplicação do carregamento. Fonte: Autoria Própria, 2019.

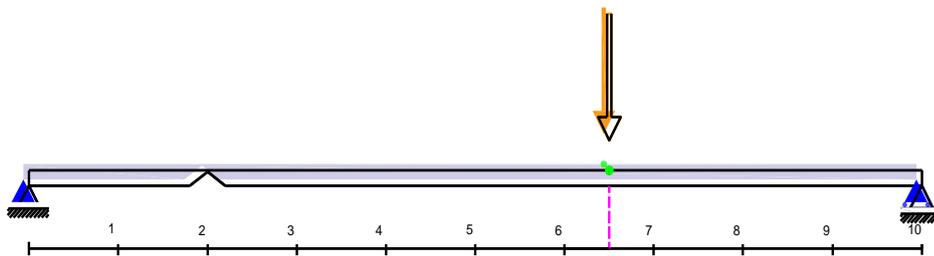


Figura 4.6 – Esquema da viga danificada e aplicação do carregamento. Fonte: Autoria Própria, 2019.

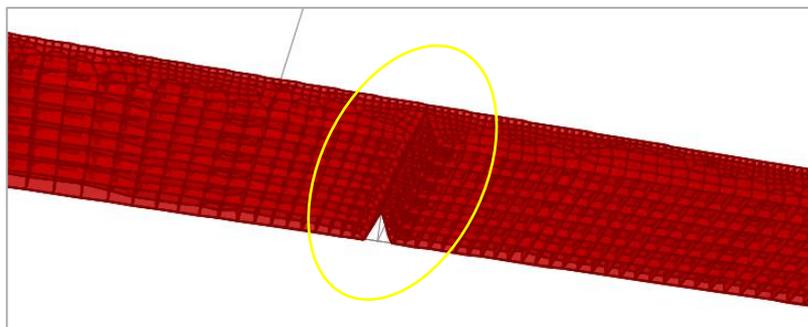


Figura 4.7 - Vista inferior da viga com geometria de dano triangular. Fonte: Autoria Própria, 2019.

O carregamento vertical inserido é um sinal do tipo $F(x) = \text{randn}(1000,1)$ representado pela Figura (4.8). Essa excitação estrutural corresponde a um sinal aleatório de banda larga tipo ruído branco.

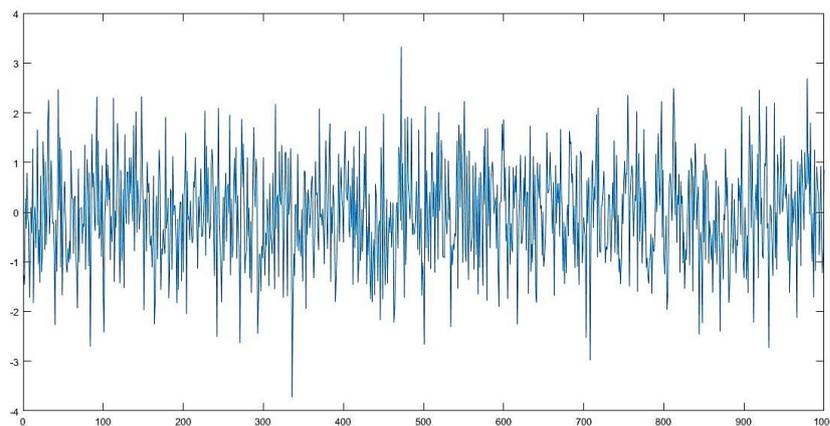


Figura 4.8 – Sinal aleatório aplicado na estrutura. Fonte: Autoria Própria, 2019.

Levando em consideração a altura das vigas de 0.15 metros, a tabela (4.2) descreve as alturas dos danos inseridos nas estruturas. Considerando inicialmente 70% dessa altura para o primeiro caso de região danificada, 50% para o segundo caso e 25% para o terceiro caso, além disso considera a angulação de cada caso de acordo com a base inferior da região danificada e a altura do dano.

Tabela 4.2 – Definição da geometria dos danos. Fonte: Autoria própria, 2019.

Designação do dano	Altura do dano em relação à espessura da viga (m)	Percentual da altura do dano em relação à espessura da viga	Perda de massa na viga devido ao dano
Dano 1	0,105	70 %	2,8 %
Dano 2	0,075	50 %	2,0 %
Dano 3	0,0375	25 %	1,0 %

Para cada um desses casos de regiões danificadas foram determinadas três localizações diferentes para inserção do dano. A primeira região com o centro do dano localizado a 2.0 metros, a segunda localização a 4.35 metros e a terceira a 7.20 metros, todas em relação à extremidade esquerda da extremidade da viga.

Tendo como base os esquemas de modelagem da viga íntegra (Figura 4.5) e danificadas (Figura 4.7), foram criados outros casos de análises com aplicação de três carregamentos

usando sinais aleatórios simultaneamente a 1.5, 5.0 e 8.5 metros como mostra a Figura (4.9), além de considerar as porcentagens de perda de massa da Tabela (4.2).

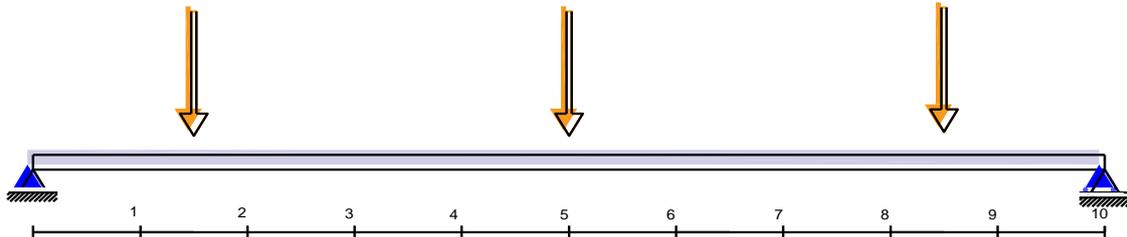


Figura 4.9 – Esquema de aplicação com três carregamentos na viga íntegra. Fonte: Autoria própria, 2019.

4.5 Esquema de aplicação do código com as técnicas EEMD, AR e SVM

Para aplicação sequencial do EEMD, AR e SVM foi desenvolvido um código pelo Matlab baseando-se no entendimento dos algoritmos dessas técnicas, em que algumas partes principais são destacadas nos parágrafos a seguir.

Inicialmente os quatro sinais de deslocamento são carregados e definidos conforme a seguinte descrição:.

- **a**= INC1; (Sinal Sem defeito)
- **b**= D1C1L1; (Sinal Com Defeito na Primeira Localização)
- **c**= D1C1L2; (Sinal Com Defeito na Segunda Localização)
- **d**= D1C1L3; (Sinal Com Defeito na Terceira Localização)

Cada um desses sinais são aplicados na *Fast Fourier Transform* (FFT), exemplificada pela função referente ao sinal da estrutura íntegra $fft_a = \text{abs}(fft(a))$. Antes do processamento dos sinais é definido a série de tempo aplicada na modelagem AR, que por sua vez defasada em dois períodos de tempo em função do tamanho dos sinais de deslocamento:

- $t = (3:1000)'$;

Com essa definição o processamento completo para uma forma de onda é realizado nos sinais **a**, **b**, **c** e **d**. Assim, para o sinal **a** define-se uma nova nomenclatura que corresponde ao

tamanho total (*length*) desse sinal. Como foi determinado para a modelagem AR defasada em dois períodos de tempo, serão obtidas duas IMFs. A obtenção das IMFs é realizada pelo método EEMD em função do sinal em destaque, da quantidade de funções de modo intrínseco requisitadas, do número de conjuntos igual a dois (conjunto de treinamento e de teste) e um valor padrão 0.3 para ruído branco:

- `imf = eemd (x, 2, 2, 0.3);`

Com a obtenção das IMFs são gerados parâmetros theta para cada um dos sinais:

- `theta = [thetaa; thetab; thetac; thetad];`

Estes parâmetros indicarão a existência dos danos. Para isso é realizada a definição das classes (labels) de acordo com a quantidade de dados processados e dos parâmetros encontrados:

- `Y1=1;`
- `Y2=2;`
- `Y3=3;`
- `Y4=4;`

Em seguida é feita a separação dos dados em conjuntos de treinamento e de teste, levando em consideração o tamanho do sinal. Como os sinais de deslocamento de **a**, **b**, **c** e **d** possuem mil pontos de amostragem cada, os conjuntos são criados com pontos escolhidos aleatoriamente dessas classes. Sendo que o conjunto de treinamento além de conter os parâmetros das quatro classes (representada pela letra r) possui uma classe de resposta (representada pela letra z), já o conjunto teste dispõe somente dos parâmetros das classes (representada pela letra s) também chamados de preditores .

- `Treinamento =[r,z] ;`
- `Teste=[s];`

Com os dois conjuntos criados a classificação é realizada pelo aplicativo *Classification Learner* do *Toolbox* (MATLAB). Assim, realiza-se a classificação do conjunto de treinamento e posteriormente classificação do conjunto teste de acordo com o modelo SVM escolhido.

4.5.1 *Classification Learner* – *Toolbox* (MATLAB)

O *Classification Learner* é um dos aplicativos disponíveis pelo *Software Matlab*, que possibilita ao usuário a realização de treinamentos de modelos para classificação de novos dados através de uma aprendizagem supervisionada. As etapas básicas desse tipo de classificador são descritas na Figura (4.11).



Figura 4.10 - Etapas principais do *Classification Learner*. Fonte: Autoria Própria, 2019.

Para dar início ao processo de classificação por meio desse aplicativo é necessário realizar as seguintes atividades:

- Inicialmente realiza-se a escolha dos dados pela opção *New Section*, que podem estar disponíveis no *Workspace* ou para serem importados de uma *File* (pasta comum de trabalho);
- Após os dados serem carregados, importa-se a seleção com os dados em formato de tabela ou matrix (Etapa 1) na nova seção de trabalho. Assim são estabelecidas as *labels* (classes), definindo quais serão os preditores e qual a coluna de resposta, nesse caso referente ao conjunto de treinamento, pois no conjunto teste o arquivo deve conter apenas os preditores.

Para definição do Método de Validação (Etapa 2), o programa disponibiliza três opções:

- *Cross-Validation* (validação cruzada) - possibilita a escolha do número de *folds* (pastas) em que os arquivos serão divididos. Segundo Gui *et al.* (2016) esse processo é usado para estimar efetivamente a acurácia do modelo, voltado principalmente para evitar o problema *overfitting*.
 - *Holdout Validation* (validação de validação) – recomendado para grandes conjuntos de dados.
 - *No validation* (Sem Validação) – não possibilita a proteção contra o *overfitting*.
- c) Através da opção *Start Session*, o treinamento é iniciado e então direciona-se para uma área onde podem ser escolhidos os tipos e quantidades de classificadores. Dentre as opções de classificadores estão disponíveis: *Decision trees*, *Support Vector Machines (SVM)*, *Nearest neighbor classifiers*, *Ensemble classifiers*. Em relação a técnica *SVM*, o usuário dispõe de seis tipos: *Linear SVM*, *fine Gaussian SVM*, *medium Gaussian SVM*, *coarse Gaussian SVM*, *quadratic SVM*, e *cubic SVM*.
- d) Com a realização do treinamento de diferentes tipos de classificadores, a aba *History* disponibiliza todos os resultados em *Accuracy* (porcentagem de eficiência) e indica automaticamente o classificador com melhor acurácia.
- e) Como forma de análise e melhora dos resultados, o *Classification Learner* dispõe de quatro modelos de avaliação e comparação: *Scatter Plot* (Gráfico de Dispersão), *Confusion Matrix* (Matriz de Confusão), *ROC Curve* (Curva ROC) e *Parallel Coordinates Plot* (Gráfico de Coordenadas Paralelas). A precisão do modelo pode ser comparada a partir das taxas de classificação incorreta observadas nesse conjunto de validação. Essa etapa pode ser considerada como uma maneira de otimização do modelo de treinamento, pois os recursos podem ser ajustados de acordo com o classificador escolhido buscando melhorar sua precisão.
- f) Tendo realizado o treinamento, o modelo do classificador com melhor acurácia pode ser exportado pela função *Export Model* para o *Workspace* do *Matlab*, além de possibilitar a geração de um modelo compacto e do código do classificador. Essa etapa possibilita a classificação do conjunto teste, que pode ser realizada pela inserção da seguinte função (Equação 2.5):

$$yfit = C.predictFcn(T) \tag{2.5}$$

sendo que C corresponde a variável que foi treinada, ou seja, o nome do modelo que foi exportado para o *Workspace*, e T representa os novos dados com ordem e formato iguais ao modelo treinado, porém sem incluir uma variável de resposta, como ocorre durante o treinamento.

5 ANÁLISES E RESULTADOS

5.1 Análise de Convergência da Malha

Baseando-se nas estruturas modeladas com base no esquema da Figura (4.3) e refinamento da malha mostrada na Figura (4.4), foi realizada inicialmente uma análise modal das vigas, a tabela (5.1) dispõe de todas as frequências naturais da estrutura para os três primeiros modos de vibração:

Tabela 5.1 – Frequências das malhas com diferentes números de elementos. Fonte: Autoria própria 2019.

Número de Elementos da Malha	Frequências Naturais (Hz)		
	Modo 1	Modo 2	Modo 3
100	5,39702	8,11030	17,48008
4000	5,39003	7,95970	17,45328
6000	5,39123	8,10587	17,45566
8000	5,39101	8,10581	17,45476
10000	5,39089	8,10576	17,45427
12000	5,39081	8,10572	17,45398
14000	5,39077	8,10569	17,45379

Para analisar a convergência de acordo com o número de elementos da malha, foi extraído um valor de deslocamento vertical de um ponto no centro de cada estrutura, conforme Tabela (5.2).

Tabela 5.2 - Discretização e deslocamentos verticais das malhas. Fonte: Autoria Própria, 2019.

Número de Elementos da Malha	Deslocamento Vertical (mm)
100	0,009709
4000	0,006188
6000	0,004327
8000	0,004102
10000	0,003977
12000	0,003904
14000	0,003856

Para a comparação dos resultados das malhas, foi desenvolvido o gráfico de convergência a partir destes deslocamentos verticais e percebe-se que ao aumentar o refinamento da malha os valores de deslocamento tendem a um valor em comum:

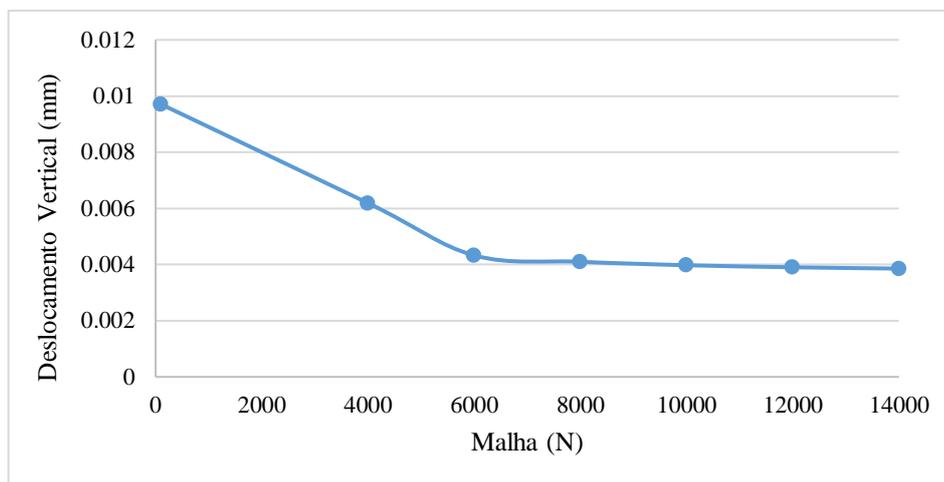


Figura 5.1 - Gráfico de convergência da malha. Fonte: Autoria Própria, 2019.

Assim, em função das diferenças dos valores de deslocamentos verticais possuírem pequenas divergências a partir do refinamento com mais de 8000 sólidos, optou-se por escolher a malha da estrutura íntegra com cerca de 10000 sólidos, pois evitou-se refinar a malha com valores superiores a 14000 sólidos por conta do elevado custo computacional e erros durante o seu refinamento. Em relação as estruturas modeladas com regiões danificadas baseando-se nessa análise de convergência, ajustou-se uma quantidade entre 9000 e 10000 elementos sólidos devido a malha ser gerada automaticamente.

5.2 Identificação de danos usando modelos preditores

5.2.1 Primeira análise EEMD, AR e SVM

Nessas primeiras análises são consideradas os dados de séries de deslocamento das estruturas com apenas um carregamento atuante. A primeira análise se inicia aplicando os dados das estruturas com maior dano de 70% da altura da viga e 2.8% de perda de massa, em seguida a altura do dano é reduzida para 50% e 25%, com perdas consecutivas de 2.0% e 1.0%.

5.2.1.1 Análise com 2.8% de perda de massa

Para avaliar a eficiência das análises de acordo com a perda de massa da estrutura por conta de regiões danificadas, foram obtidas as séries de deslocamento das quatro vigas (uma íntegra e três com danos em localizações diferentes), cada série com mil pontos de amostragem. Dando início a análise com maior perda de massa nas estruturas danificadas, a Tabela (5.3) descreve a organização dos dados para aplicação nas técnicas *EEMD*, *AR* e *SVM*.

Tabela 5.3 – Descrição dos dados aplicados na análise. Fonte: Autoria Própria, 2019.

Sigla das Classes	Tipo de sinal	Referência
<i>INCI</i>	Sem defeito	Estrutura íntegra.
<i>DICIL1</i>	Com defeito	Dano 1 - Carregamento 1 - Primeira localização.
<i>DICIL2</i>	Com defeito	Dano 1 - Carregamento 1 - Segunda localização.
<i>DICIL3</i>	Com defeito	Dano 1 - Carregamento 1 - Terceira localização.

Com a aplicação do método *EEMD*, são adquiridas as *IMFs* conforme as figuras (5.2) e (5.3).

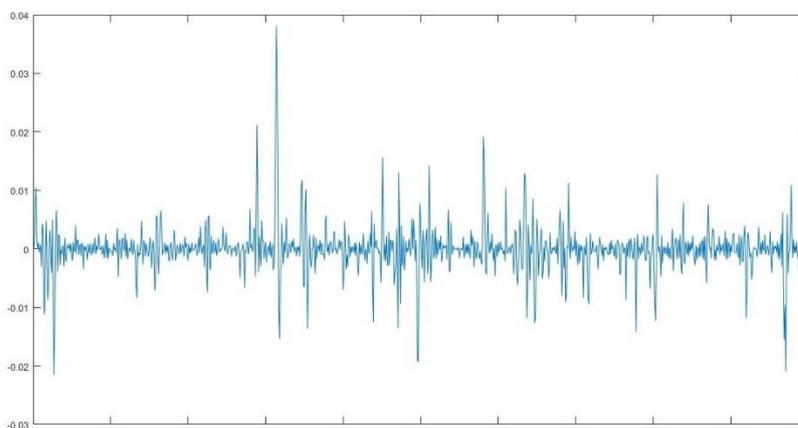


Figura 5.2 – Primeira IMF da análise de 2.8% de perda de massa. Fonte: Autoria própria, 2019.

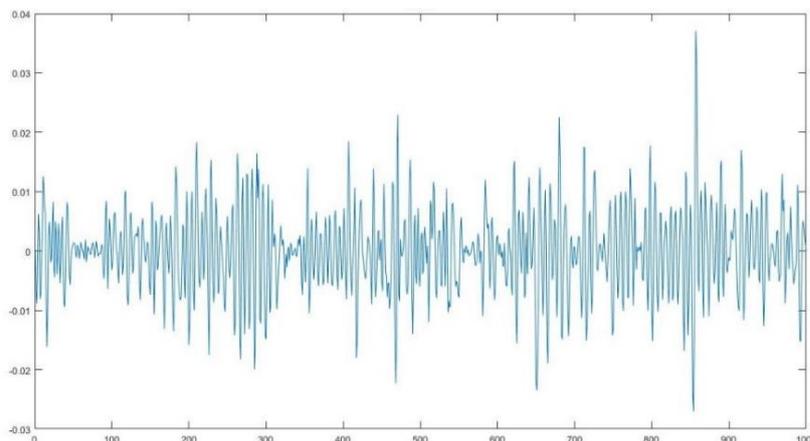


Figura 5.3 – Segunda *IMF* da análise de 2.8% de perda de massa. Fonte: Autoria própria, 2019.

Seguindo os passos de aplicação, cada IMF foi ajustada a um modelo AR de ordem 2, o que resulta em um vetor de atributos de dimensão 4 para ser classificado pelo algoritmo SVM. Considerando o dano fixo e a localização variável, o classificador foi treinado para distinguir entre quatro diferentes classes, incluindo a condição normal. No total, 500 formas de onda pertencentes a cada classe foram geradas para a validação. Os resultados são mostrados na matriz de confusão ilustrada na Tabela (5.4).

Tabela 5.4 - Matriz de confusão do conjunto teste. Fonte: Autoria Própria, 2019.

		<i>Classe Predita</i>			
		<i>INC1</i>	<i>DICIL1</i>	<i>DICIL2</i>	<i>DICIL3</i>
<i>Classe Verdadeira</i>	<i>INC1</i>	448	44	8	0
	<i>DICIL1</i>	38	412	50	0
	<i>DICIL2</i>	1	21	459	19
	<i>DICIL3</i>	0	0	15	485

Com base nos valores preditos positivos da tabela anterior, a precisão média de classificação do método foi de 90.2%. Devido os danos inseridos nas estruturas terem maior geometria, as suas características podem ser diferenciadas com mais facilidade em relação à da estrutura íntegra. No entanto, analisando as classificações separadamente, as maiores taxas de erros estão entre as classes INC1 e DICIL1 e as menores entre as classes DICIL2 e DICIL3, estas por sua vez possuem o dano com localização mais próxima ao ponto de medição.

5.2.1.2 Análise com 2.0% de perda de massa

Nessa análise, foram consideradas os dados da estrutura íntegra e outros três das estruturas danificadas com 2.0% de perda de massa. A Tabela (5.5), descreve as rotulações dos dados.

Tabela 5.5 – Descrição dos dados aplicados na análise. Fonte: Autoria Própria, 2019.

Sigla	Tipo de sinal	Referência
INC1	Sem defeito	Estrutura íntegra
D2C1L1	Com defeito	Dano 2 - Carregamento 1 - Primeira localização.
D2C1L2	Com defeito	Dano 2 - Carregamento 1 - Segunda localização.
D2C1L3	Com defeito	Dano 2 - Carregamento 1 - Terceira localização.

Dando início a análise, são adquiridas as *IMFs* das Figuras (5.4) e (5.5) com a aplicação do EEMD.

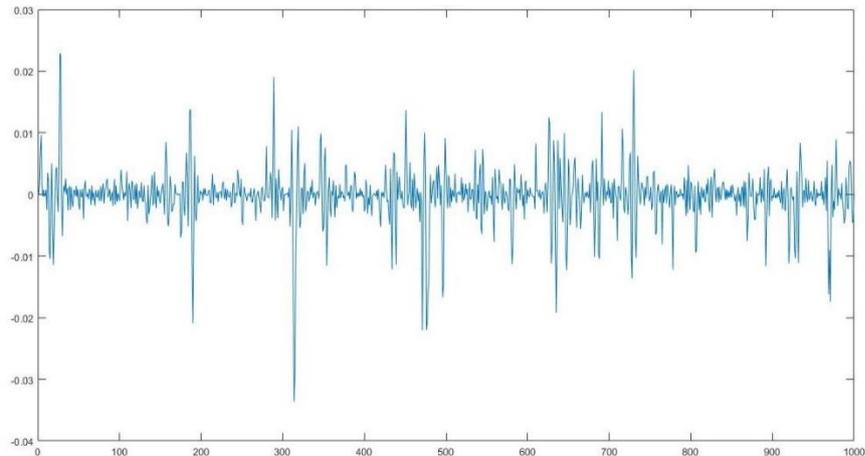


Figura 5.4 – Primeira IMF da análise com 2.0% de perda de massa. Fonte: Autoria própria, 2019.

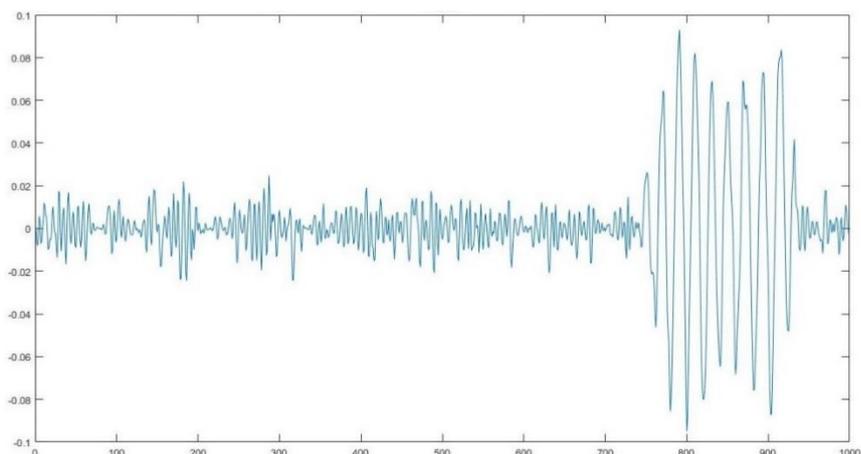


Figura 5.5 - Segunda IMF da análise com 2.0% de perda de massa. Fonte: Autoria própria, 2019.

Os resultados são apresentados na forma de matriz de confusão na Tabela (5.6). A acurácia média no conjunto de validação foi de 79,3%. Essa queda no valor de acurácia é atribuída ao fato de que a redução da geometria do dano produz oscilações semelhantes ao caso da estrutura íntegra, dificultando a distinção entre as classes. Verifica-se novamente que para o dano na posição 3, a mais próxima do ponto de captação da resposta, o método fornece uma precisão melhor, neste caso de 91,8%.

Tabela 5.6 - Matriz de confusão do conjunto teste. Fonte: Autoria Própria, 2019.

		<i>Classe Predita</i>			
		<i>INCI</i>	<i>D2CIL1</i>	<i>D2CIL2</i>	<i>D2CIL3</i>
<i>Classe Verdadeira</i>	<i>INCI</i>	412	64	22	2
	<i>D2CIL1</i>	42	338	107	13
	<i>D2CIL2</i>	10	67	376	47
	<i>D2CIL3</i>	0	6	35	459

5.2.1.3 Análise com 1.0% de perda de massa

Reduzindo a porcentagem da altura referente ao dano para 25%, a perda de massa da estrutura é de apenas 1.0%. Os dados são rotulados conforme a Tabela (5.7).

Tabela 5.7 – Descrição dos dados aplicados na análise. Fonte: Autoria Própria, 2019.

Sigla	Tipo de sinal	Referência
INC1	Sem defeito	Estrutura íntegra
D3C1L1	Com defeito	Dano 3 – Carregamento 1 - Primeira localização.
D3C1L2	Com defeito	Dano 3 – Carregamento 1 - Segunda localização.
D3C1L3	Com defeito	Dano 3 – Carregamento 1 - Terceira localização.

Aplicando a técnica de pré-processamento nas séries de deslocamento, são adquiridas as IMFs das Figuras (5.6) e (5.7).

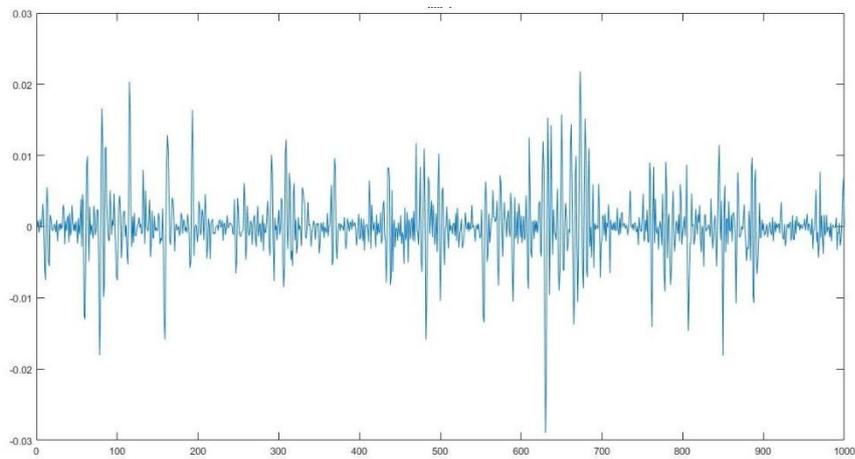


Figura 5.6 – Primeira IMF da análise com 1.0% de perda de massa. Fonte: Autoria própria, 2019.

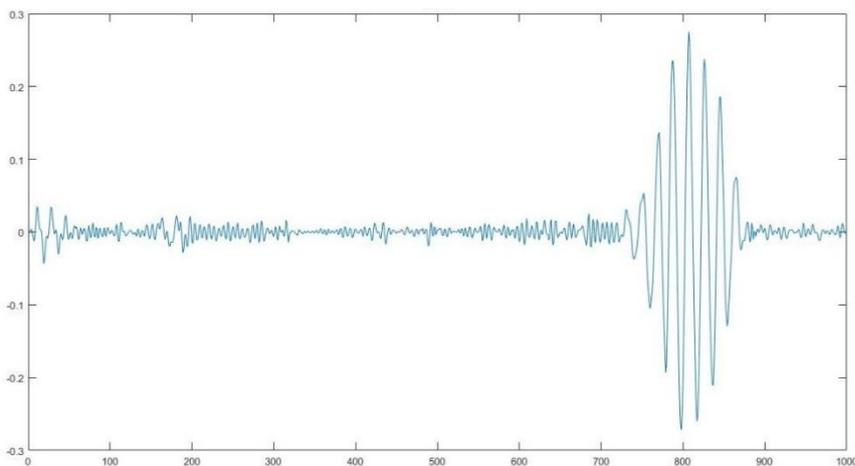


Figura 5.7 - Segunda IMF da análise com 1.0% de perda de massa. Fonte: Autoria própria, 2019.

Após a classificação do conjunto de treinamento, os resultados da análise do conjunto teste é demonstrada na Tabela (5.8), e resultou em acurácia média de 52,3%. Este valor de

acurácia média encontrado está ligado a hipótese de que um dano menor torna a classificação mais difícil, uma vez que as formas de onda defeituosas tendem a se tornar mais semelhantes às da estrutura íntegra. Além disso, observou-se novamente um maior índice de acertos quando a localização do dano é mais próxima do ponto de coleta de sinais.

Tabela 5.8 - Matriz de confusão do conjunto teste. Fonte: Autoria Própria, 2019.

		<i>Classe Predita</i>			
		<i>INCI</i>	<i>D3CIL1</i>	<i>D3CIL2</i>	<i>D3CIL3</i>
<i>Classe Verdadeira</i>	<i>INCI</i>	330	86	65	19
	<i>D3CIL1</i>	142	169	146	43
	<i>D3CIL2</i>	73	129	188	110
	<i>D3CIL3</i>	16	23	103	358

Mesmo obtendo um baixo valor de classificação, o caso de análise com pequenas trincas são importantes pois remetem ao estágio inicial de deterioração das estruturas, que, em longo prazo pode se tornar desastroso.

5.2.2 Segundo caso de análise: *EEDM*, *AR* e *SVM*

Nesse segundo caso de análise utilizando as técnicas *EEMD*, *AR* e *SVM* são considerados os esquemas de modelagem das estruturas conforme as Figuras (4.9), obtendo os dados da estrutura íntegra com os três carregamentos simultâneos e de acordo com as três perdas de massa de 2.8%, 2.0% e 1.0%. Estas análises com carregamentos simultâneos tem como intuito realizar excitações mais próximas ao defeito para produzir oscilações mais evidentes e melhorar a distinção das estruturas danificadas.

5.2.2.1 Análise com 2.8% de perda de massa

A Tabela (5.9) organiza os dados para esse segundo caso de análise com aplicação de três carregamentos simultâneos, sendo que “C3” se refere ao carregamento triplo.

Tabela 5.9 – Descrição dos dados no segundo caso de análise (2.8%). Fonte: Autoria Própria, 2019.

Sigla	Tipo de sinal	Referência
<i>INC2</i>	Sem defeito	Estrutura íntegra – Carregamento triplo.
<i>DIC3L1</i>	Com defeito	Dano 1 – Carregamento Triplo - Primeira localização de dano
<i>DIC3L2</i>	Com defeito	Dano 1 - Carregamento Triplo - Segunda localização de dano
<i>DIC3L3</i>	Com defeito	Dano 1 - Carregamento Triplo - Terceira localização de dano

Assim como nas demais análises, inicia-se a aplicação do EEMD e obtenção das IMFs, Figuras (5.8) e (5.9).

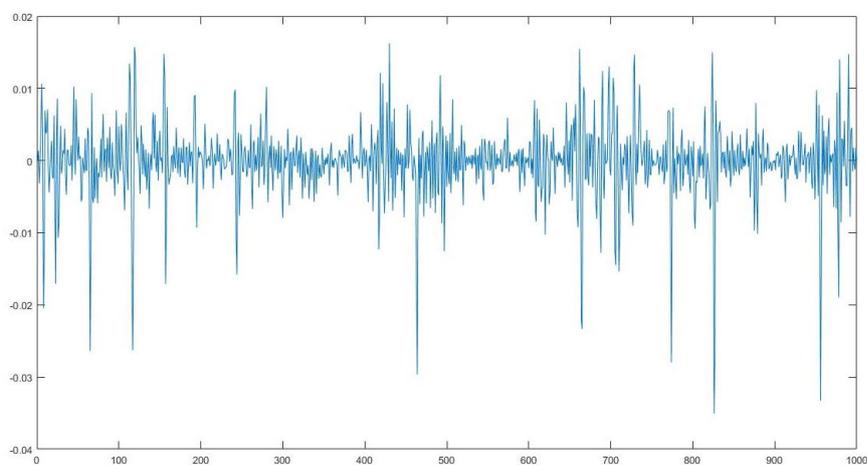


Figura 5.8 – Primeira IMF da análise (2.8%). Fonte: Autoria Própria, 2019.

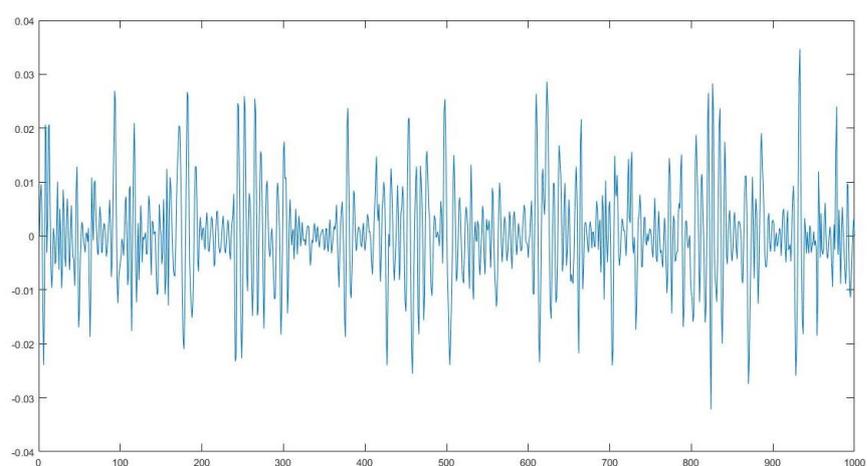


Figura 5.9 – Segunda IMF da análise (2.8%). Fonte: Autoria Própria, 2019.

Após o treinamento dos dados, os resultados sobre o conjunto de teste são apresentados a partir da Tabela (5.10). Considerando os valores preditos positivos, pode ser observada a

melhora nos valores da acurácia média para 94,6%. Essa alta no valor de acurácia, em comparação ao mesmo nível de dano com um carregamento, indica que o uso de mais de uma excitação pode tornar os resultados mais precisos e torna-se uma alternativa viável.

Tabela 5.10 - Matriz de confusão do conjunto teste. Fonte: Aatoria Própria, 2019.

		<i>Classe Predita</i>			
		<i>INC3</i>	<i>DIC3L1</i>	<i>DIC3L2</i>	<i>DIC3L3</i>
<i>Classe Verdadeira</i>	<i>INC3</i>	476	23	1	0
	<i>DIC3L1</i>	20	469	10	1
	<i>DIC3L2</i>	1	2	474	23
	<i>DIC3L3</i>	0	0	27	473

5.2.2.2 Análise com 2.0% de perda de massa

Nesse caso de análise, foram consideradas perdas de massa de 2.0% nas estruturas danificadas e os três carregamentos simultâneos, sendo os dados denominados como *INC3*, *D2C3L1*, *D2C3L2* e *D2C3L3* (Tabela 5.11).

Tabela 5.11 – Descrição dos dados no segundo caso de análise (2.0%). Fonte: Aatoria Própria, 2019.

Sigla	Tipo de sinal	Referência
<i>INC3</i>	Sem defeito	Estrutura íntegra – Carregamento Triplo
<i>D2C3L1</i>	Com defeito	Dano 2 - Carregamento Triplo - Primeira localização.
<i>D2C3L2</i>	Com defeito	Dano 2 - Carregamento Triplo - Segunda localização.
<i>D2C3L3</i>	Com defeito	Dano 2 - Carregamento Triplo - Terceira localização.

Seguindo as etapas de aplicação dos modelos preditores, é realizado o pré-processamento dos sinais de deslocamento e obtidas as duas *IMFs* (figuras 5.10 e 5.11).

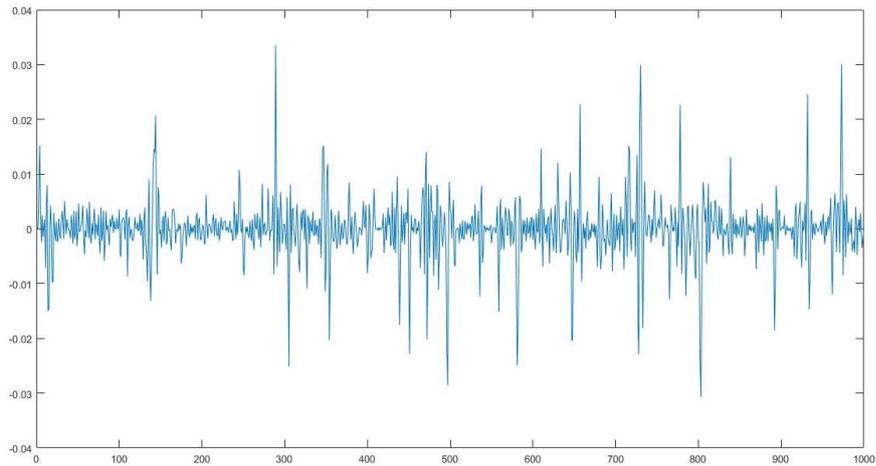


Figura 5.10 – Primeira IMF da análise (2.0%). Fonte: Autoria Própria, 2019.

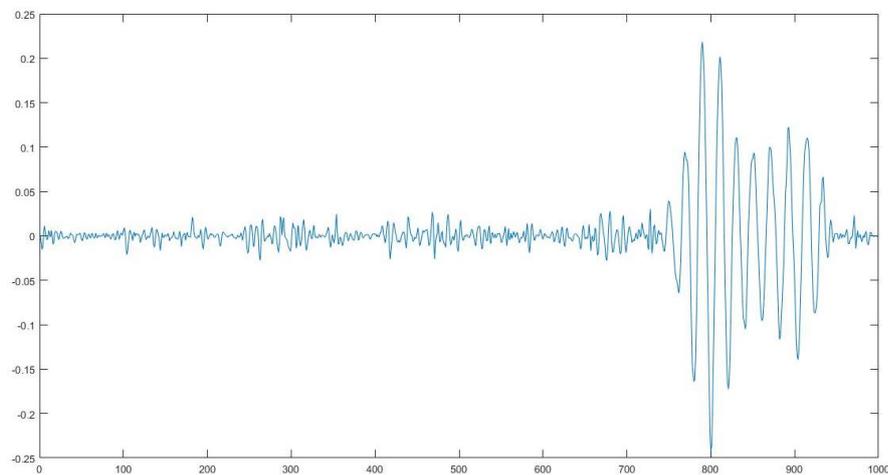


Figura 5.11 – Segunda IMF da análise (2.0%). Fonte: Autoria Própria, 2019.

Nessa análise a precisão média foi de 83,6%, mostrando novamente uma melhoria em comparação com o caso do Item (5.2.1.2). Novamente, a melhor acurácia é encontrada na classe D2C3L3 com valor de 93,6% com a falha próxima ao ponto de medição da resposta de vibração.

Tabela 5.12 - Matriz de confusão do conjunto teste. Fonte: Autoria Própria, 2019.

		<i>Classe Predita</i>			
		<i>INC3</i>	<i>D2C3L1</i>	<i>D2C3L2</i>	<i>D2C3L3</i>
<i>Classe Verdadeira</i>	<i>INC3</i>	419	75	6	0
	<i>D2C3L1</i>	48	382	61	9
	<i>D2C3L2</i>	2	43	403	52
	<i>D2C3L3</i>	0	4	28	468

5.2.2.3 Análise com 1.0 % de perda de massa

Considerando o percentual de perda de massa reduzido para 1.0%, a organização dos dados é mostrado pela Tabela (5.13).

Tabela 5.13 – Descrição dos dados no segundo caso de análise (1.0%). Fonte: Autoria Própria, 2019.

Sigla	Tipo de sinal	Referência
<i>INC3</i>	Sem defeito	Estrutura íntegra – Carregamento Triplo
<i>D3C3L1</i>	Com defeito	Dano 3 - Carregamento Triplo - Primeira localização.
<i>D3C3L2</i>	Com defeito	Dano 3 - Carregamento Triplo - Segunda localização.
<i>D3C3L3</i>	Com defeito	Dano 3 - Carregamento Triplo - Terceira localização.

Com o pré-processamento dos sinais pelo *EEMD*, são adquiridas as duas *IMFs* das figuras (5.12) e (5.13).

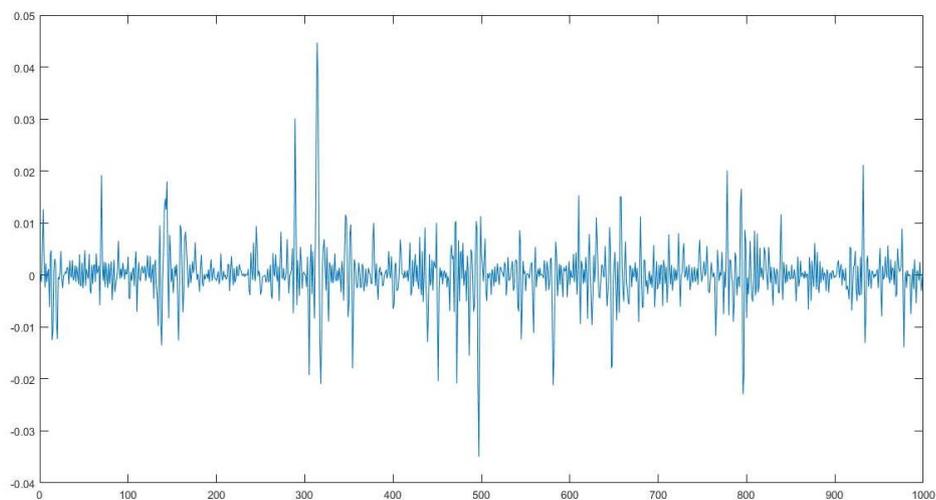


Figura 5.12 – Primeira IMF da análise (1.0%). Fonte: Autoria Própria, 2019.

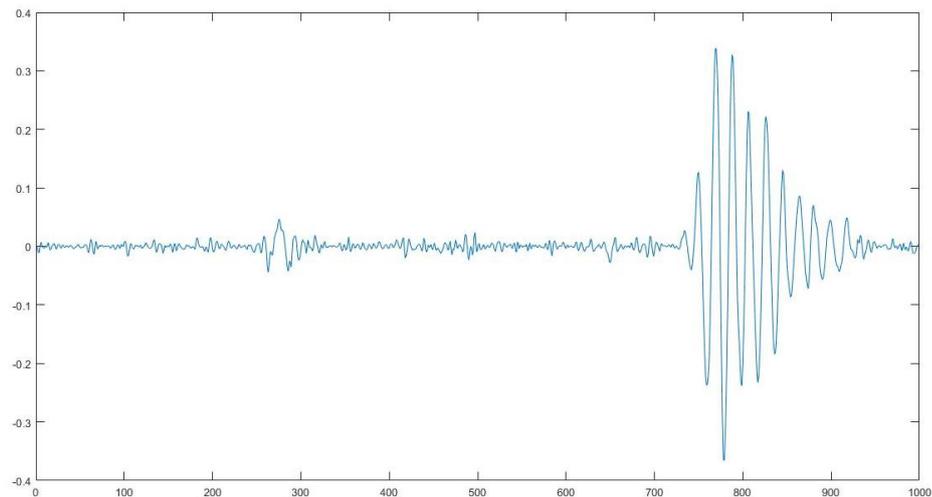


Figura 5.13 – Segunda IMF da análise (1.0%). Fonte: Autoria Própria, 2019.

Aplicando a modelagem AR, são adquiridos os parâmetros de referência para criação e classificação dos conjuntos. Enfatizando a classificação do conjunto teste, a tabela (5.14) mostra a disposição dos pontos de amostragem, em que os valores preditos positivos resultaram em 62,6% de acurácia média. Considerando a suposição de um dano em estágio inicial há um aumento de 10,3% em comparação com o resultado encontrado no Item (5.2.1.3), que apresentou uma média de 52,3%.

Tabela 5.14 - Matriz de confusão do conjunto teste. Fonte: Autoria Própria, 2019.

	<i>Classe Predita</i>			
	<i>INC2</i>	<i>D3C2L1</i>	<i>D3C2L2</i>	<i>D3C2L3</i>
<i>INC2</i>	357	104	10	29
<i>D3C2L1</i>	87	244	93	76
<i>D3C2L2</i>	33	125	259	83
<i>D3C2L3</i>	15	29	64	392

Mesmo o resultado da acurácia média ter apresentado uma melhora por conta da quantidade de carregamentos, não é suficiente para fornecer uma detecção confiável para aplicações reais, embora as hipóteses de que a metodologia funcione bem para detecção local pareça válida e que o uso de múltiplos carregamentos de fato produza padrões mais detectáveis.

6 CONCLUSÃO

O trabalho teve como perspectiva a identificação de danos através de um método de diagnóstico de estruturas baseado em aprendizagem de máquinas. Este método consiste na aplicação sequencial dos algoritmos das técnicas Ensemble Empirical Mode Decomposition (EEMD), Modelo Auto Regressivo (AR) e Support Vector Machine (SVM). Com o processamento dos dados pelo EEMD e posterior aquisição dos atributos pela modelagem AR, a detecção da gravidade do dano e de sua possível localização foi avaliada através de um classificador SVM.

Nas aplicações das técnicas, observou-se a capacidade em distinguir mudanças ou variações nos sinais de deslocamentos de estruturas em casos com danos de grandes e pequenas dimensões, com perdas de massa iguais a 2.8%, 2.0% e 1.0%. As análises foram separadas em grupos com aplicação de um carregamento e posteriormente com aplicação de três carregamentos simultâneos.

Os resultados de acurácia média encontrados com a realização destes testes variaram para o primeiro grupo com valores de 50% a 90% aproximadamente. Para a primeira porcentagem de dano igual a 2.8% a acurácia média foi de 90.2%. Na segunda análise com perda de massa de 2.0% a média de classificação foi de 79.3% e para o terceiro caso com 1.0% referente ao dano a acurácia do método foi igual a 52.3%.

Com o objetivo de tentar melhorar a precisão dos valores de acurácia média do método, foram criados casos de análises com aplicação de três carregamentos simultâneos, criando pontos distintos de excitação. Considerando as perdas de massa de 2.8%, 2.0% e 1.0% os resultados de acurácia média foram iguais a 94.6%, 83.6% e 62.6%.

Constata-se que há de fato uma melhoria nos resultados encontrados através de maiores excitações na estrutura. O aumento de acurácia principalmente no caso de danos com pequenas geometrias é perceptível, pois mantém a coerência no aspecto da dificuldade de sua detecção uma vez que os padrões dos sinais se confundem com os da estrutura íntegra. Porém, esse resultado não pôde ser considerado expressivo o suficiente para o caso de estruturas reais, demonstrando a necessidade de melhoramento ou adaptações das técnicas utilizadas. Nessa perspectiva, o desenvolvimento de novas pesquisas são importantes, visto que os parâmetros de localização e avaliação da gravidade do dano devem ser precisos para possibilitar a implantação de técnicas de recuperação da estrutura.

6.1 Sugestões para trabalhos futuros

Como foi aplicado no presente trabalho, modelagens computacionais com o uso de elementos finitos são sugestões para trabalhos futuros pela possibilidade de criar elementos ou toda a estrutura com suas características reais de projeto, inserindo diferentes tipos de carregamentos, tanto permanentes quanto variáveis. Um exemplo de aplicação são os carregamentos móveis, nos quais gerariam uma vibração contínua sobre a estrutura.

Também são sugestões para trabalhos futuros o emprego em variações experimentais com vigas de aço ou de concreto armado que contenham em sua extensão trincas e fissuras, além de casos utilizando dados reais de estruturas da construção civil. Esse desenvolvimento de novas pesquisas pode possibilitar a análise do desempenho dessas técnicas de forma mais ampla e detalhada.

Além disso, outra questão a ser avaliada trata-se da quantidade de pontos de medição de vibrações, pois normalmente nos métodos de identificação e localização de danos pelas propriedades modais da estrutura, são necessários diversos pontos de medição dos sinais de deslocamento ao longo de sua extensão. Dessa forma, pode ser estudado o uso de uma quantidade maior de pontos de medição para coletar os sinais de vibração da estrutura e adaptar as metodologias utilizadas no presente trabalho.

7 REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6118: Projeto de estruturas de concreto – Procedimento**. Rio de Janeiro, 2014.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 8800: Projetos de Estruturas de Aço e de Estruturas Mistas de Aço e Concreto de Edifícios**. Rio de Janeiro, 2008.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 5674: Manutenção de edificações – Procedimento. Rio de Janeiro, 1999.

AJEJE, F. H.; PENNA, S. S.; PITANGUEIRA, R. L. S. **Elementos Finitos de Casca do sistema computacional INSANE**. REM: R. Esc. Minas, Ouro Preto, 64(4), 399-405, 2011.

ALVANDI, A. **Contribution à l'Utilisation Pratique de l'Evaluation Dynamique pour la Detection d'Endommagements dans les Ponts**. Ecole National de Ponts et Chausseés, Paris, França, 2003.

AGHAMOHAMMADI, M.; ANALOUI, M. **Multi-Level Support Vector Machine**. World of Computer Science and Information Technology Journal (WCSIT), Vol. 2, No. 5, 174-178, 2012.

AMIRI, G. G.; DARVISHAN, E. **Damage Detection of Moment Frames using Ensemble Empirical Mode Decomposition and Clustering Techniques**. KSCE Journal of Civil Engineering, 19(5):1302-1311, 2015.

CHEN, P.-H.; LIN, C.-J.; SCHÖLKOPF, B. **A tutorial on v-support vector machines**. Applied Stochastic Models in Business and Industry, 21 (2), pp. 111-136, 2005.

CHENG, J.; YU, D.; YANG, Y. **A Fault Diagnosis Approach for Gears Based on IMF AR Model and SVM**. EURASIP Journal of Advances in Signal Processing, Article ID 647135, 2008.

CHEN, B.; XU, Y. L. **Integrated vibration control and health monitoring of building structures using semi-active friction dampers.** Part II: numerical investigation. *Engineering Structures*, vol. 30, no. 3, pp. 573–587, 2008.

CHEN, B.; ZHAO, S.; LI, P. **Application of Hilbert-Huang Transform in Structural Health Monitoring: A State-of-the-Art Review.** Academic Editor: Ting-Hua Yi. 2014.

DATAFLAIR TEAM. **Kernel Function – Introduction to SVM Kernel & Examples.** 2017. Disponível em: <<https://data-flair.training/blogs/svm-kernel-functions/>>. Acesso em: 04 dez. 2018.

DIAO, Y.; MEN, X.; SUN, Z.; GUO, K.; WANG, Y. **Structural Damage Identification Based on the Transmissibility Function and Support Vector Machine.** *Shock & Vibration*, p.1-14, 2018.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B.; SHEVITZ, D. W. **Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review.** 1996-1998 Disponível em: <<https://www.osti.gov/scitech/servlets/purl/249299>>. Acesso em: 24 jan. 2018.

FARRAR, C. R.; DOEBLING, S. W.; NIX, D. A. **Vibration-based structural damage identification.** *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 359, 131-149, 2001.

GACI, S. **A new ensemble empirical mode decomposition (EEMD) denoising method for seismic signals.** *Energy Procedia*, 97 (2016) 84 – 91, 2016.

GHADDAR, B.; NAOUM-SAWAYA, J. **High dimensional data classification and feature selection using support vector machines.** *European Journal of Operational Research*. 993-1004, 2018.

GUENTHER, N.; SCHONLAU, M. **Support Vector Machines.** *The Stata Journal*, Number 4, 917-937, 2016.

GUI, G.; PAN, H.; LIN, Z.; LI, Y.; YUAN, Z. **Data-Driven Support Vector Machine with Optimization Techniques for Structural Health Monitoring and Damage Detection.** *KSCE Journal of Civil Engineering*, 21(2):523-534, 2017.

HUANG, N. E.; HUANG, K.; CHIANG, W. **HHT-BASED BRIDGE STRUCTURAL HEALTH-MONITORING METHOD.** Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.468.3204&rep=rep1&type=pdf>>. Acesso em: 15 jan. 2018.

HUANG, N. E.; SHEN, Z.; LONG, S.; WU, M. C.; SHIH, H. H.; ZHENG, Q.; YEN, N. C.; TUNG, C. C.; LIU, H. H. **The empirical mode decomposition and the Hilbert spectrum for nonlinear and-stationary time series analysis.** 904-993. 1996.

KOUREHLI, S.S. **Structural diagnosis using incomplete static responses and LS-SVM.** *Inverse Problems in Science and Engineering*. 2017.

LEI, Y.; LIN, J.; HE, Z.; ZUO, M. J. **A review on empirical mode decomposition in faults diagnosis of rotating machinery.** *Mechanical Systems and Signal Processing*. ELSEVIER, 108-126, 2013.

LIN, C. C.; LIU, P. L.; YEH, P. L. **Application of empirical mode decomposition in the impact-echo test.** *NDT and E International*, vol. 42, no. 7, pp. 589–598, 2009.

LIU, HanBing; NGUYEN, HuuHung. **Damage detection of simply supported beam under effect of moving load by Hilbert-Huang transform.** 2012. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.894.5122&rep=rep1&type=pdf>>. Acesso em: 19 jan. 2018.

LORENA, A. C.; CARVALHO, A. C. P. L. F. **Uma Introdução às Support Vector Machines.** 2007. Disponível em: <http://www.seer.ufrgs.br/rita/article/rita_v14_n2_p43-67/3543>. Acesso em: 9 fev. 2018.

LORENA, A. C.; CARVALHO, A. C. P. L. F. **Introdução às Máquinas de Vetores de Suporte (Support Vectors Machine).** 2003. Instituto de Ciências Aplicadas e Computação.

Disponível em:
<http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos_enviados/BIBLIOTECA_113_RT_192.pdf>. Acesso em: 14 nov. 2018.

MEREDITH, J.; GONZÁLEZ, A.; HESTER, D. **Empirical Mode Decomposition of the acceleration response of a prismatic beam subject to a moving load to identify multiple damage locations**. Shock and Vibration, vol. 19, no. 5, pp. 845–856, 2012.

MITCHELL, T. M. **Machine Learning**. McGraw-Hill Science/Engineering/Math. 1997.

MORETTIN, P. A. & TOLOI, C. M. **Análise de séries temporais**. 1.ed. São Paulo: Edgar Blücher, 550p., 2004.

MÜLLER, K-R.; MIKA, S.; RÄTSCH, G.; TSUDA, K.; SCHÖLKOPF, B. **An Introduction to Kernel-Based Learning Algorithms**. IEEE TRANSACTIONS ON NEURAL NETWORKS, vol. 12, 2001.

OLIVEIRA, A. M.. **Fissuras e rachaduras causadas por recalque diferencial de fundações**. 2012. Monografia (Especialização em Gestão em Avaliações e Perícias) – Universidade Federal de Minas Gerais, Minas Gerais. Disponível em: <<http://pos.demc.ufmg.br/novocecc/trabalhos/pg2/96.pdf>>. Acesso em: 14 dez. 2018.

PINES, D.; SALVINO, L. **Structural health monitoring using empirical mode decomposition and the Hilbert phase**. 2006. Disponível: <<https://www.sciencedirect.com/science/article/pii/S0022460X05007029>>. Acesso em: 23 jan. 2018.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: modelos e previsões**. Ed. 4. São Paulo: Atlas, 2004.

RAGSDALE, C. T. **Modelagem de planilha e análise de decisão uma introdução prática a business analytics**. São Paulo, Cengage Learning, 2018.

REZAEI, D. ; TAHERI, F. **Damage identification in beams using empirical mode decomposition.** Structural Health Monitoring. Vol.10. 2011.

RYTTER, A. **VIBRATIONAL BASED INSPECTION OF CIVIL ENGINEERING STRUCTURES.** 1993.

SACCHI, C. C.; SOUZA, A. S. C. **Manifestações patológicas e controle de qualidade na montagem e fabricação de estruturas metálicas.** REEC – REVISTA ELETRÔNICA DE ENGENHARIA CIVIL. Vol. 13, Nº 1, 20 – 34, 2016.

SOUZA, V. C.; RIPPER, T. **PATOLOGIA, RECUPERAÇÃO E REFORÇO DE ESTRUTURAS DE CONCRETO.** Pini, 1998.

TAN, Q-F.; WANG, X.; WANG, H.; WEN, X.; KANG, A-Q. **An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach.** Journal of Hydrology, 2018.

TRINDADE, D. S. **PATOLOGIA EM ESTRUTURAS DE CONCRETO ARMADO.** 2015. Disponível em: <http://coral.ufsm.br/engcivil/images/PDF/2_2015/TCC_DIEGO%20DOS%20SANTOS%20DA%20TRINDADE.pdf>. Acesso em: 28 jan. 2018.

ZAIONTZ, C. **Processos ARMA.** Estatísticas reais usando o Excel. 2013-2018. Disponível em: <<http://www.real-statistics.com/time-series-analysis/>>. Acesso em: 23 out. 2018.

XAVIER, J. M. N. **ANÁLISE E PREVISÃO DE SÉRIES TEMPORAIS COM MODELOS ARIMA E ANÁLISE ESPECTRAL SINGULAR.** 2016. UNIVERSIDADE ABERTA. Disponível em: <https://repositorioaberto.uab.pt/bitstream/10400.2/5873/1/Disserta%C3%A7%C3%A3o_Jorge.Xavier_%201104916.pdf>. Acesso em: 20 agos. 2018.

XU, Y. L.; CHEN, J. **Structural damage detection using empirical mode decomposition: experimental investigation.** Journal of Engineering Mechanics, J. Eng. Mech., vol.130, 2004.

XU, Y. L.; CHEN, B. **Integrated vibration control and health monitoring of building structures using semi-active friction dampers. Part I: methodology.** Engineering Structures, vol. 30, no. 7, pp. 1789–1801, 2008.

XU, Y. L.; CHEN, J. **Empirical mode decomposition for structural damage detection.** Proceedings of the 8th International Conference on Inspection, Appraisal, Repairs and Maintenance of Structural, pp. 147–154, Singapore, 2003.

YINFENG, D.; YINGMIN, L.; MING, L. **Structural damage detection using empirical-mode decomposition autoregressive moving average model.** Soil Dynamics and Earthquake Engineering. 133-145, 2009.

WANG, T.; ZHANG, M.; YU, Q.; ZHANG, H. **Comparing the applications of EMD and EEMD on time–frequency analysis of seismic signal.** Journal of Applied Geophysics 83, 29–34, 2012.

WU, Z.H.; HUANG, N.E. **Ensemble empirical mode decomposition: a noise assisted data analysis method.** World Scientific Publishing Company Advances in Adaptive Data Analysis 1. 1–41, 2009.