



Programa de Pós-Graduação em

Computação Aplicada

Mestrado Acadêmico

Eduardo Silveira da Trindade

Opqualigen - Um Modelo para Geração de Índices de Qualidade
para Máquinas Wirebonders

São Leopoldo, 2020

Eduardo Silveira da Trindade

**OPQUALIGEN - UM MODELO PARA GERAÇÃO DE ÍNDICES DE QUALIDADE
PARA MÁQUINAS WIREBONDERS**

Dissertação apresentada como requisito parcial
para obtenção do título de Mestre, submetido
ao Programa de Pós-Graduação em
Computação Aplicada da Universidade do Vale
do Rio dos Sinos — UNISINOS

Orientador:
Prof. Dr. Cristiano André da Costa

Coorientador:
Prof. Dr. Rodrigo Iván Goytia Mejía

São Leopoldo
2020

T833o

Trindade, Eduardo Silveira da.

Opqualigen : um modelo para geração de índices de qualidade para máquinas wirebonders / Eduardo Silveira da Trindade. – 2020.

113 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2020.

“Orientador: Prof. Dr. Cristiano André da Costa ; coorientador: Prof. Dr. Rodrigo Iván Goytia Mejía”.

1. Wirebonding. 2. Vibrações. 3. Templates de operação. 4. Índice de qualidade. 5. Indústria 4.0. 6. Internet das coisas. I. Título.

CDU 004.9

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecário: Flávio Nunes – CRB 10/1298)

Dedico este trabalho à minha esposa, ao meu irmão e aos meus pais.

AGRADECIMENTOS

Agradeço primeiramente ao grande criador, ao universo e à vida. Agradeço imensamente a minha esposa Raquel, que sempre me apoiou e incentivou a continuar, sendo muito compreensiva comigo neste período. Agradeço aos meus pais e ao meu irmão pela compreensão e carinho. Agradeço também a todos os professores e funcionários do ITT Chip, pela ajuda e pelos ensinamentos. Além disso, quero agradecer ao meu orientador Dr. Cristiano André da Costa e meu coorientador Dr. Rodrigo Iván Goytia Mejía, por todo apoio e orientação para conclusão deste trabalho.

“Você tem que ter uma atitude positiva e tirar o melhor da situação na qual se encontra.”
(Stephen Hawking)

RESUMO

Qualquer maquinário industrial em seu estado de funcionamento, produz vibrações que podem ser lidas mediante o uso de sensores de vibração, ou também conhecidos como acelerômetros. Este ciclo de vibração pode ocorrer milhares de vezes por segundo, o que ocasionará em um grande volume de dados gerados a serem coletados, caracterizando séries temporais de dados. Sendo assim, e de acordo com algumas pesquisas já realizadas, durante uma operação de trabalho do equipamento, onde ele realizará suas etapas de processo, e partindo da premissa que a operação quando for realizada novamente irá repetir as mesmas etapas de processo, é possível identificar padrões de vibrações que descrevem aquela operação sendo executada no equipamento. Em outras pesquisas relacionadas, alguns modelos de predição de falhas são propostos, seja utilizando redes neurais ou algum outro algoritmo de inteligência artificial, mas nem sempre o modelo proposto pode ser aplicado de forma universal, deixando alguns equipamentos muito específicos de fora destas implementações. E mesmo que o modelo se aplique, para que uma rede neural seja eficaz, ela precisa ser treinada com uma base de dados de referência. Desta forma, o modelo proposto sugere inicialmente a criação de templates de operação para equipamentos industriais do tipo *wirebonders*, utilizando como base apenas os dados de vibração do equipamento. Com a criação destes templates através da catalogação, quantificação e sequenciamento das assinaturas de vibração, foi possível gerar um índice para medir a qualidade das operações do equipamento avaliado, neste modelo de sistema não supervisionado, mas que demonstrou grande potencial para tornar-se um sistema supervisionado, seja para predição de falhas ou predição de normalidades, dependendo do tipo de template de operação catalogado.

No caso do experimento aplicado, optou-se por catalogar uma operação qualquer e compará-la a outras operações que estiveram executando os mesmos processos que a operação catalogada, com o propósito de gerar um índice escalar de qualidade, baseando-se não apenas na similaridade das assinaturas de vibração, mas também no sequenciamento e quantificação das mesmas. Desta forma, ao comparar o template catalogado com as outras duas operações, foram obtidos dois índices escalares de qualidade: a primeira operação comparada obteve um índice de qualidade de 87,25% e a segunda obteve um índice de 95,36%.

Sendo assim, este trabalho atingiu o objetivo proposto, tendo como principal contribuição científica a capacidade de gerar os índices de qualidade por operação em máquinas do tipo *wirebonders*, abrindo outras possibilidades de pesquisas que poderão estar relacionadas a outros tipos de equipamentos.

Palavras-chave: Wirebonding. Vibrações. Templates de Operação. Índice de Qualidade. Indústria 4.0. Internet das Coisas.

ABSTRACT

Any industrial machinery in its working state produces vibrations that can be read out using vibration sensors, or also known as accelerometers. This vibration cycle can occur thousands of times per second, which will cause a large volume of data to be collected, characterizing time series of data. Thus, during any operation of the equipment, and based on some research already carried out in the area of Industry 4.0 and Internet of Things, it is possible to identify patterns of cyclic vibrations that characterize the operation of the equipment being performed. In other related research, some fault prediction models are proposed, whether using neural networks or some other artificial intelligence algorithm, but the proposed model cannot always be applied universally, leaving some very specific equipment outside of these implementations. And even if the model is applied, for a neural network to be effective, it needs to be trained with a reference database. Thus, the proposed model suggests the creation of operating templates for industrial equipment of the wirebonders type, using as a basis only the equipment's vibration data. With the creation of these templates through the cataloging, quantification and sequencing of vibration signatures, it was possible to generate an index to measure the quality of the operations of the evaluated equipment, in this unsupervised system model, but which demonstrated great potential to become a system supervised, either to predict failures or predict normalities, depending on the type of operation template cataloged.

In the case of the applied experiment, it was decided to catalog any operation and compare it or other operations that were executing the same processes as the cataloged operation, with the purpose of generating a scalar quality index, based not only on the similarity of vibration signatures, but also in their sequencing and quantification. Thus, when comparing the cataloged template with the other two operations, two scalar quality indexes were obtained: the first compared operation obtained a quality index of 87.25% and the second obtained an index of 95.36%.

Thus, this work achieved the proposed objective, having as its main scientific contribution the ability to generate quality indexes per operation in machines of the wirebonders type, opening other possibilities of research that may be related to other types of equipment.

Keywords: Wirebonding. Vibration. Operations Templates. Quality Index. Industry 4.0. Internet of Things.

LISTA DE FIGURAS

Figura 1 – Os principais facilitadores subjacentes ao movimento de Big Data.	29
Figura 2 – Evolução Histórica do Sensor 1.0 para o Sensor 4.0	34
Figura 3 – <i>Cyber Physical System</i>	35
Figura 4 – Pilares de Análises em Séries Temporais	36
Figura 5 – Representação dos dados coletados, referente aos 3 eixos de deslocamento com alguns modos de operação destacados.	37
Figura 6 – Eixo Y com algumas comparações visuais entre os modos de operação. . .	37
Figura 7 – Representação dos dados coletados, destacando o modo de vibração contido em um dos modos de operação.	38
Figura 8 – Representação dos dados coletados, destacando as assinaturas de vibração a serem comparadas pela sua similaridade.	39
Figura 9 – Visão Geral das Etapas de Mineração de Dados	40
Figura 10 – Integração dos dados de manufatura	40
Figura 11 – Fluxo do processo da ligação termossônica padrão de fio de ouro.	41
Figura 12 – Gráfico estatístico referente aos tempos de produção para equipamentos de semicondutores	42
Figura 13 – Visão Geral do Modelo Proposto.	52
Figura 14 – Arquitetura do Modelo Proposto.	53
Figura 15 – Definição de camadas de limite para segmento de operação	56
Figura 16 – Definição de camadas de limite para segmento de assinatura de vibração . .	56
Figura 17 – Avaliação da Qualidade da Operação do Equipamento - $Q = 100\%$	59
Figura 18 – Avaliação da Qualidade da Operação do Equipamento - $Q > 100\%$	59
Figura 19 – Arquitetura da Infraestrutura Utilizada, Composta por Uma <i>Workstation</i> e Uma Máquina Virtual, com suas Respectivas Tecnologias Implementadas. . .	62
Figura 20 – Amostra de Dados - 6 Milhões de Registros	63
Figura 21 – Dados Reorganizados - 350 mil pontos	64
Figura 22 – Comparativo dos Dados Reorganizados com Valor Absoluto	65
Figura 23 – Comparativo do Valor Absoluto com o Envelope nas Operações	65
Figura 24 – Comparativo do Envelope nas Operações com a Divisão da Amplitude do Sinal em Camadas	66
Figura 25 – Segmentação dos Dados de Operações com Filtros Aplicados Sendo Transferida para os Dados sem Filtros	67
Figura 26 – Comparativo da Operação Segmentada Escolhida sem Filtros e com Filtro de Valor Absoluto Aplicado	68
Figura 27 – Comparativo do Valor Absoluto com o Envelope nas Assinaturas de Vibração	68
Figura 28 – Comparativo com <i>Zoom</i> do Valor Absoluto com o Envelope nas Assinaturas de Vibração	69
Figura 29 – Definição das Camadas ao Longo da Amplitude do Sinal	69
Figura 30 – Definição das Camadas ao Longo da Amplitude do Sinal com <i>Zoom</i>	70

Figura 31 – Segmentação das Assinaturas de Vibração com Filtros Aplicados Sendo Transferida para os Dados sem Filtros	70
Figura 32 – Segmentação das Assinaturas de Vibração com Filtros Aplicados Sendo Transferida para os Dados sem Filtros com Zoom	71
Figura 33 – <i>Operation Template</i> Mapeado com 259 Assinaturas de Vibração	73
Figura 34 – Comparativo dos dois Tipos de Assinaturas de Vibração Encontradas	74
Figura 35 – Sequência das assinaturas de vibração do template escolhido.	75
Figura 36 – Comparativo das 5 primeiras posições de Assinaturas de Vibração do Tipo A	75
Figura 37 – Comparativo das 5 primeiras posições de Assinaturas de Vibração do Tipo B	76
Figura 38 – Seleção das operações que foram comparadas com o template de operação.	76
Figura 39 – Sequência das assinaturas de vibração da operação 1.	77
Figura 40 – Comparativo da Assinatura de Vibração do Tipo A do Template de Operação, com 5 Assinaturas de Vibração do Tipo A da Operação 1.	78
Figura 41 – Comparativo da Assinatura de Vibração do Tipo B do Template de Operação, com 5 Assinaturas de Vibração do Tipo B da Operação 1.	78
Figura 42 – Sequência das assinaturas de vibração da operação 2.	79
Figura 43 – Comparativo da Assinatura de Vibração do Tipo A do Template de Operação, com 5 Assinaturas de Vibração do Tipo A da Operação 2.	80
Figura 44 – Comparativo da Assinatura de Vibração do Tipo B do Template de Operação, com 5 Assinaturas de Vibração do Tipo B da Operação 2.	80
Figura 45 – Comparativo das Posições das Assinaturas de Vibração em Suas Respectivas Operações.	82
Figura 46 – <i>Slam Stick X</i>	97
Figura 47 – <i>TimeScaleDB comparisson with NoSQL Architecture</i>	99
Figura 48 – <i>Hypertable architecture</i>	100

LISTA DE TABELAS

Tabela 1 – O crescente volume de dados	28
Tabela 2 – Estatística de Palavras Chaves Utilizadas nos Últimos 5 Anos, anteriores a 2018.	44
Tabela 3 – Tabela comparativa de metodologias utilizadas para análise de séries temporais.	48
Tabela 4 – Lista de ferramentas utilizadas para avaliação do experimento.	62
Tabela 5 – Tabela Contendo Quantidade das Assinaturas de Vibração do Template de Operação, Utilizando DTW com um Índice de Similaridade de 17.	74
Tabela 6 – Tabela Comparativa Entre o Template de Operação (Operation Template) e a Operação 1 para Identificar as Assinaturas de Vibração já Catalogadas, e as que estão fora do padrão.	77
Tabela 7 – Tabela Comparativa Entre o Template de Operação (Operation Template) e a Operação 2 para Identificar as Assinaturas de Vibração já Catalogadas, e as que estão fora do padrão.	79
Tabela 8 – Tabela Comparativa Final entre o Template de Operação e as Operações 1 e 2, apresentando as quantidades de assinaturas de vibração encontradas em cada tipo de assinatura.	81
Tabela 9 – Tabela Comparativa das Diferenças entre o Template de Operação e a Operação 1	84
Tabela 10 – Tabela Comparativa das Diferenças entre o Template de Operação e a Operação 2	85
Tabela 11 – Tabela Comparativa dos Índices de Qualidade de Operação Observados. . .	85
Tabela 12 – Tabela Comparativa do Sequenciamento e Quantificação das Operações 1 e 2 em Relação ao Template de Operação, para Geração do Índice de Qualidade por Operação.	113

LISTA DE ALGORITMOS

1	<i>Segmentation</i>	57
2	<i>Catalog</i>	58
3	<i>Operation Template Extraction</i>	60

LISTA DE ABREVIATURAS

min. minutos
milisseg. milissegundos

LISTA DE SIGLAS

BD	<i>Big Data</i>
DM	<i>Data Mining</i>
DW	<i>Data Warehouse</i>
BI	<i>Business Inteligence</i>
CPS	<i>Cyber Physical System</i>
CI	<i>Circuitos Integrados</i>
IoT	<i>Internet of Things</i>
IIoT	<i>Industrial Internet of Things</i>
DTW	<i>Dynamic Time Warping</i>
ML	<i>Machine Learning</i>
CSV	<i>Comma-Separated Values</i>
EMG	<i>Electromyography</i>
MAV	<i>Mean Absolute Value</i>
TS	<i>Time Series</i>
DB	<i>Data Base</i>
DBMS	<i>Database Management System</i>
ERP	<i>Enterprise Resource Planning</i>
MES	<i>Manufacturing Execution System</i>
FE	<i>Feature Extration</i>
Tb	<i>Terabytes</i>
Pb	<i>Petabytes</i>
Zb	<i>Zettabytes</i>
KHz	<i>Kilohertz</i>
Mi	<i>Milhão</i>
Bi	<i>Bilhão</i>
IC	<i>Intervalo de Confiança</i>
RUL	<i>Remaining Usefulness Lifetime</i>

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Motivação	28
1.2	Questão de pesquisa	30
1.3	Objetivos	30
1.3.1	Objetivos específicos	31
1.4	Estrutura do texto	31
2	FUNDAMENTAÇÃO TEÓRICA	33
2.1	Indústria 4.0	33
2.2	Internet das Coisas (IoT)	34
2.3	Séries Temporais	36
2.3.1	Representação	37
2.3.2	Medição da Similaridade	38
2.3.3	Indexação	39
2.4	Processamento de Grandes Volumes de Dados	39
2.5	Wirebonding	41
3	TRABALHOS RELACIONADOS	43
3.1	Modelos de Diagnósticos Baseados em Séries Temporais de Dados	44
3.2	Análise das Técnicas Utilizadas nos Modelos Propostos	45
3.3	Análise comparativa	46
3.4	Lacunas de pesquisa	49
4	MODELO PROPOSTO	51
4.1	Visão Geral do Modelo	51
4.2	Arquitetura do Modelo	53
4.2.1	Raw Data	54
4.2.2	Preprocessing	54
4.2.3	Data Preparation	55
4.2.4	Processing	56
4.2.5	Catalog	57
4.2.6	Operation Template	58
4.2.7	Operation Quality Index Generation	58
5	METODOLOGIA	61
5.1	Ferramentas	61
5.2	Amostra de Dados	63
5.3	Reorganização	63
5.4	Extração das Operações - <i>Operation Feature Extraction</i>	64
5.4.1	Valor Absoluto	64
5.4.2	Envelope	64
5.4.3	Divisão da Amplitude do Sinal em Camadas	66
5.4.4	Segmentação	66
5.5	Extração das Assinaturas de Vibração - <i>Vibration Signature Feature Extraction</i>	67
5.5.1	Valor Absoluto	67
5.5.2	Envelope	67
5.5.3	Divisão da Amplitude do Sinal em Camadas	69

5.5.4	Segmentação	70
6	RESULTADOS E DISCUSSÃO	73
6.1	Sequenciamento e Quantificação das Assinaturas de Vibração no Template de Operação	73
6.1.1	Avaliação da Similaridade Utilizando <i>Dynamic Time Warping</i> (DTW) entre as Assinaturas de Vibração	73
6.2	Comparação do Template de Operação com outras Operações	76
6.2.1	<i>Comparativo entre Operation Template e Operação 1</i>	77
6.2.2	<i>Operation Template <-> Operação 2</i>	79
6.3	Gerando o Índice de Qualidade de Operação	81
6.4	Discussão dos Resultados	86
7	CONCLUSÃO	89
7.1	Contribuições	89
7.2	Trabalhos Futuros	90
	REFERÊNCIAS	91
	APÊNDICE A – ACELERÔMETRO UTILIZADO NA AVALIAÇÃO INICIAL	97
	APÊNDICE B – POSTGRESQL DATABASE WITH TIMESCALE DB	99
	APÊNDICE C – CÓDIGO PYTHON	101
	APÊNDICE D – TABELA COMPARATIVA DAS OPERAÇÕES	103

1 INTRODUÇÃO

Nos últimos anos, o conceito de *Big Data* (BD) deixou de ser apenas um bordão, para se tornar a chave para o aprimoramento do desempenho das operações, economia, e empresas. Muitas empresas têm investido em ferramentas de *Business Intelligence* (BI), para poder extrair informação dos seus dados, armazenados em grandes volumes, buscando por erros cometidos, padrões de comportamentos, etc (GOEL; DATTA; MANNAN, 2017). Neste contexto de *Big Data*, também está fortemente correlacionado o conceito de Indústria 4.0, na qual podemos citar o *Cyber Physical System* (CPS), usado para criar sistemas de fabricação flexíveis e reconfiguráveis nas fábricas, através da digitalização dos processos de fabricação, que envolvem o uso de diversos sensores/atuadores, que coletam dados em tempo real, para posteriormente serem processados (POSADA et al., 2015).

Um efeito colateral da transição dos processos de produção tradicionais para a fabricação inteligente e a Indústria 4.0 é um aumento constante da complexidade, não apenas em relação à variedade e diversidade de produtos a serem fabricados, mas também em termos de operação e manutenção de plantas de produção em geral (IBER et al., 2020). Neste contexto, pode-se destacar o processo de encapsulamento de microchips, realizado por máquinas Wirebonders.

Wirebonding tem como principal aplicação o processo de criação de interconexões elétricas entre circuitos integrados (FISCHER et al., 2019). De forma resumida, são máquinas de solda extremamente precisas, utilizadas largamente na indústria de microchips e semicondutores, e que exigem altos níveis de padrões qualidade. Possuem diversos mecanismos para prevenção de falhas, porém em alguns casos, esta prevenção não demonstra ser eficiente, tornando o que deveria ser uma manutenção preventiva (realizada periodicamente com o intuito de evitar que falhas ocorram), em manutenção corretiva (realizada após a falha acontecer, com o intuito de corrigir).

Tratando-se de padrões de qualidade, a palavra "qualidade" é usada em vários contextos por engenheiros, profissionais de marketing, líderes empresariais, autoridades, advogados, mídia, arquitetos, pessoas comuns, etc. Ela tem como definição o padrão de algo medido em relação a outras coisas de tipo semelhante, ou também, o grau de excelência de algo (ANTTILA; JUSSILA, 2017; PRESS, 2020).

Desta forma, o objetivo desta pesquisa é capturar dados de vibração deste equipamento, para mapear seus processos de operação, e extrair estas informações para criação de templates de operação. E uma vez que se tenha uma base de dados de templates de operações, poderá ser avaliada a qualidade da operação do equipamento, através de métodos comparativos de similaridade, sequenciamento e quantificação dos padrões encontrados.

1.1 Motivação

Um estudo realizado em Nordrum (2017) e Hossain et al. (2019) prevê que as projeções para o ano de 2020 referente a dispositivos interconectados no conceito de IoT são astronômicas, e poderão chegar a trinta bilhões de unidades, e que por consequência disso gerará uma quantidade de dados incalculável. Alguns exemplos podem ser destacados aqui como é o caso de uma subsidiária da empresa *Alibaba* que gera dezenas de *Terabytes* (Tb) de dados de negociações *online*. Outro exemplo é o caso do *Facebook*, que gera em média 10 *Petabytes* (Pb) de dados de registro por mês (CHEN; MAO; LIU, 2014).

Na Tabela 1, encontram-se mais alguns dados coletados e referentes a esta expansão de dados gerados.

O Fenômeno Big Data	
Dados gerados em 2 dias no ano de 2011	1.8 Zb
Total de imagens carragedas no Facebook	750 Mi
Número de TAGs RFID em 2021	209 Bi
Dados gerados em uma cidade inteligente projetada na China	200 Pb
Custo médico economizado na América utilizando big data analysis	\$300 Bi

Tabela 1: O crescente volume de dados
Fonte: Adaptado de Chen, Mao e Liu (2014)

Diante do grande volume de dados sendo gerado a cada segundo que passa, por diversos sensores, atuadores e unidades de aquisição de dados, que são configurados para realizar a captura e coleta destes dados, se faz necessário o processamento para extração das informações desejadas nos equipamentos industriais em funcionamento. Sendo assim, aqui entra uma variação do conceito de Internet das Coisas, do inglês *Internet of Things* (IoT) que tem por finalidade interconectar coisas e objetos, mas que neste caso é aplicado especificamente na indústria, denominado de Internet das Coisas Industriais, ou *Industrial Internet of Things* (IIoT) e tem por finalidade interconectar os equipamentos industriais (CHEN et al., 2015; OYEKANLU, 2017).

Na Figura 1, proposta em Reis e Gins (2017), são previstos três pontos facilitadores para o *Big Data* na Indústria 4.0, considerados fundamentais para a condução desta pesquisa.

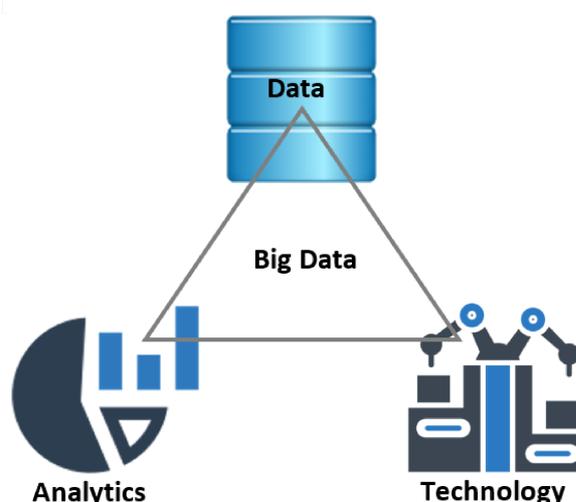


Figura 1: Os principais facilitadores subjacentes ao movimento de Big Data.
 Fonte: Adaptado de Reis e Gins (2017)

Diversas propostas de soluções vêm sendo sugeridas, e direcionadas para aplicações específicas, como é o caso da manutenção preditiva (*Predictive Maintenance* (PM)), onde se propõe monitorar e avaliar um equipamento em tempo real, alertando o sistema administrador de anomalias que venham a ocorrer ou até mesmo para verificar o *status* do equipamento (JUNG; ZHANG; WINSLETT, 2017; GANGA; RAMACHANDRAN, 2018). Mas para identificar estas anomalias, é necessário ter uma base de conhecimento para comparação e identificação, partindo da premissa que, se não é possível dizer com certeza o que é uma anomalia, se espera ao menos que se diga o que não é.

A motivação desta pesquisa teve início com discussões sobre metodologias de predição de falha, relatadas por uma empresa parceira da universidade, onde foi apontada a dificuldade em identificar problemas que ocorrem durante o processo de fabricação de microchips em equipamentos de solda, denominados *wirebonders*. Partindo desta premissa, foram realizadas algumas pesquisas na literatura para identificar algumas metodologias já existente e entender seus comportamentos, não só para tentar atender a necessidade apontada no processo da empresa, mas principalmente para identificar as dificuldades encontradas e contribuir para resolvê-las.

Dentre os trabalhos encontrados na literatura e relacionados ao tema predição de falhas em *wirebonders*, observa-se que ainda não se tem uma metodologia consolidada para a solução esperada, mas que alguns trabalhos propõem modelos para outros temas e com metodologias semelhantes, denominada *Vibration Feature Extraction* (ZENG; LU; YAN, 2019; RIAZ et al., 2017). Outros trabalhos encontrados utilizam uma nomenclatura com o propósito oposto a predição de falhas, que seria a "predição de normalidade" (LAZAKIS; GKEREKOS; THEOTOKATOS, 2019; IWASAKI et al., 2008; JIANG; PAPAVALASSILIOU, 2003). Ambos se utilizam da metodologia de *Vibration Feature Extraction*, entretanto na predição de falha o propósito é comparar a vibração dos processos em execução com falhas já conhecidas, enquanto que na predição de normalidade, o propósito é comparar os processos em execução com *templates* de

processos que foram realizados anteriormente e considerados sem anormalidades.

Com isso, a motivação desta pesquisa foi, além de criar uma metodologia para desenvolver uma base de conhecimento composta por templates de operação do equipamento avaliado, que serviu como referência comparativa, foi também a geração de um índice escalar de qualidade de operação, servindo como referência em análise de anomalias e monitoramento industrial, não limitado apenas a máquinas do tipo *wirebonders*, mas qualquer tipo de equipamento industrial que possua armazenada em sua assinatura de vibração a informação do correto funcionamento do equipamento durante seus processos de execução.

1.2 Questão de pesquisa

Através de uma parceria realizada entre a universidade e uma indústria de encapsulamento de microchips, foi possível realizar um estudo introdutório, referente aos problemas relatados pelos engenheiros da empresa, relatados sobre as falhas que ocorriam nos equipamentos do parque fabril. Desta forma, foi possível chegar à questão de pesquisa:

"Como definir e calcular um índice escalar de qualidade de operação em máquinas wirebonders utilizando como dados a vibração do equipamento?"

Tratando-se de monitoramento das operações do equipamento industrial, entende-se por qualidade de operação um valor mínimo e satisfatório, definido como índice de 0 a 100%, que comprove que o equipamento realizou suas operações conforme o previsto e que isto não comprometeu sua cadeia de produção, seja por paradas não programadas ou qualquer outro tipo de anomalia.

Inicialmente, para se calcular este índice escalar de qualidade de operação, o principal requisito necessário foi extrair as informações das operações realizadas pelo equipamento, através de técnicas de *Vibration Feature Extraction*, conforme apresentado na literatura, mas que precisaram ser adequadas para atender a este trabalho (HUANG et al., 2017; RIAZ et al., 2017; MOHANTY; GUPTA; RAJU, 2015; PLAZA; LÓPEZ; GONZÁLEZ, 2019). Após esta etapa, com as operações a serem monitoradas já extraídas e mapeadas como *templates*, foi possível compará-las com as demais operações, para gerar o índice escalar de qualidade, utilizando técnicas de similaridade para comparar as assinaturas de vibração do equipamento, com foco em monitoramento da normalidade da operação.

1.3 Objetivos

Este trabalho teve por finalidade investigar o comportamento de um equipamento industrial através do monitoramento de sua vibração. Partindo desta premissa, o objetivo foi desenvolver um modelo eficiente e eficaz para quantificar a qualidade da operação de solda e detectar anomalias em máquinas *wirebonders* por meio da análise das séries temporais multivariadas de

sinais de vibração.

1.3.1 Objetivos específicos

- Determinar as especificações para configurar o sistema de aquisição de dados.
- Conceber e implementar técnicas de processamento de dados para segmentação de séries temporais da operação cíclica de soldagem em máquinas wirebonders.
- Conceber e implementar técnicas para identificar as assinaturas de vibração contidas nas séries temporais com base em indicadores de similaridade.
- Quantificar e sequenciar as assinaturas de vibração, criando um catálogo de templates de operação do equipamento.
- Validar e comparar o modelo proposto com estratégias avançadas reportadas na literatura.

1.4 Estrutura do texto

Este trabalho está dividido em sete capítulos que apresentam o estudo para as contribuições ao sistema de avaliação da qualidade e avaliação de anomalias em máquinas *wirebonder* por meio da análise das séries temporais de sinais de vibração. Os capítulos estão dispostos e estruturados na seguinte ordem:

Capítulo 1 - Introdução: Este capítulo apresenta a definição do problema, o escopo do projeto, os objetivos gerais e específicos e a justificativa junto com a motivação e importância deste trabalho.

Capítulo 2 - Fundamentação Teórica: Este capítulo apresenta uma síntese dos fundamentos teóricos que direcionam este trabalho e sustentam suas contribuições científicas.

Capítulo 3 - Trabalhos Relacionados: Este capítulo apresenta alguns modelos sugeridos na literatura, destacando as dificuldades encontradas e lacunas de pesquisa.

Capítulo 4 - Modelo Proposto: Este capítulo apresenta o modelo proposto neste trabalho, destacando suas contribuições científicas para o preenchimento das lacunas de pesquisa identificadas.

Capítulo 5 - Metodologia: Este capítulo apresenta a metodologia utilizada na implementação do experimento, para o cumprimento dos requisitos na obtenção dos resultados esperados.

Capítulo 6 - Resultados e Discussão: Este capítulo apresenta os resultados obtidos com o experimento, bem como a metodologia de avaliação dos resultados.

Capítulo 7 - Conclusão: Este capítulo apresenta uma discussão sobre a avaliação dos resultados obtidos, das contribuições científicas e dos trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, é abordada a base conceitual da pesquisa em questão, com uma breve introdução aos aspectos da indústria 4.0, internet das coisas, time séries, *data mining (DM)* e *wirebonding*.

Tendo como foco nesta pesquisa o conceito de indústria 4.0, foram encontradas na literatura algumas pesquisas relacionadas com o tema, no que tange à infraestrutura do conceito de indústria 4.0, trazendo também a evolução dos sensores responsáveis por realizar a coleta de informações neste ambiente.

Referente à internet das coisas, a seção aborda alguns modelos sugeridos na literatura, de como acontece a integração da infraestrutura da indústria 4.0 com modelos de sistemas propostos, contemplando desde a coleta de informações dos sensores, até o seu armazenamento, ou processamento dos dados coletados.

A seção de séries temporais traz da literatura uma abordagem das técnicas utilizadas para representar e organizar as informações coletadas, visando a padronização dos *datasets* a serem trabalhados.

Na seção de mineração de dados, são abordados alguns modelos propostos na literatura, sobre como preparar a arquitetura de processamentos dos *datasets*, com o propósito de transformar dado em informação.

E na última seção deste capítulo, uma abordagem sobre *wirebonders* que é o tipo de equipamento avaliado inicialmente neste experimento da pesquisa, bem como seu processo de funcionamento.

2.1 Indústria 4.0

A quarta revolução industrial envolve várias tecnologias nesta tendência global, como a Internet das Coisas e Serviços, automação industrial, cibersegurança, conectividade e informação onipresente, inteligência robótica, gerenciamento do ciclo de vida do produto, tecnologia semântica e big data industrial (POSADA et al., 2015). E para coleta desta quantidade significativa de informações, se faz necessário aprimorar o desenvolvimento de sensores, sistemas de aquisição de dados e redes de computadores, para implementar metodologias de alta tecnologia, direcionando as indústrias para uma natureza mais competitiva em sua cadeia produtiva (LEE; BAGHERI; KAO, 2015). Desta forma, explorar todo este volume de dados coletados é de grande interesse da indústria, para diversos fins de exploração da informação, como o controle de qualidade do produto, manutenção preditiva, etc (VILLALOBOS et al., 2018). Mas para que isto ocorra, o monitoramento inteligente de equipamentos usando sensores é de extrema importância para aquisição de dados relevantes que representem a caracterização de falhas operacionais, de um sistema no qual sua condição está sendo observada (DIEZ-OLIVAN et al., 2019).

Assim como na indústria 4.0, os sensores também passaram por evoluções, justamente para poder acompanhar esta evolução tecnológica que vem ocorrendo (FATALIYEV; MEHDIYEV, 2018). E nesta revolução de sensores, alguns fatos podem ser observados:

- Sensor 1.0 - Primeira revolução de sensores que ocorreu no final do século 18, onde foi introduzido o Transdutor Mecânico.
- Sensor 2.0 - Segunda revolução, que ocorreu no início do século 20, introduzindo o sensor elétrico.
- Sensor 3.0 - Terceira revolução, que ocorreu na década de 1970, e introduziu o sensor eletrônico.
- Sensor 4.0 - Quarta e atual revolução, que introduz os sensores inteligentes.

Na Figura 2, sugerida por Fataliyev e Mehdiyev (2018), pode-se visualizar o gráfico desta evolução dos sensores.

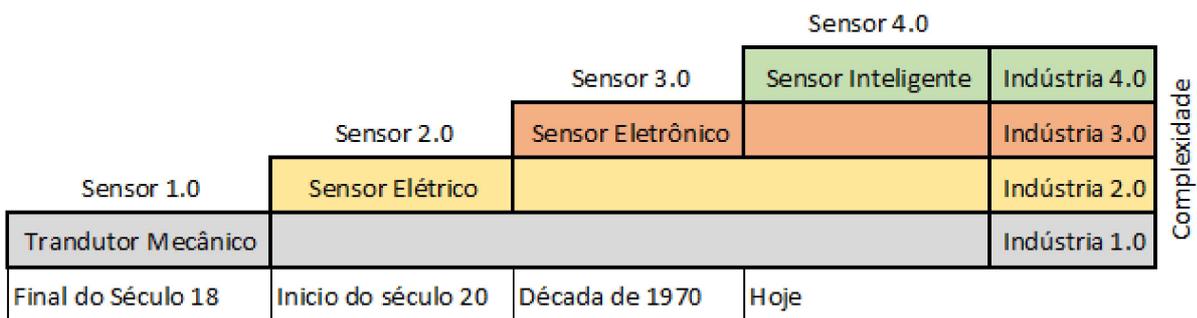


Figura 2: Evolução Histórica do Sensor 1.0 para o Sensor 4.0
Fonte: Adaptado de Fataliyev e Mehdiyev (2018)

Contextualizando com esta evolução de sensores, está esta pesquisa, pois para que fosse possível capturar um grande volume de dados e que tivessem precisão suficiente para gravar as informações de operação das máquinas *wirebonders* em suas assinaturas de vibração, foi de extrema importância estas evoluções tecnológicas acontecerem. Desta forma, os sensores utilizados, que podem ser consultados no **Apêndice A**, puderam cumprir com os seus requisitos de alta performance.

2.2 Internet das Coisas (IoT)

De acordo com Ganz et al. (2015), a Internet das Coisas (IoT) visa criar infraestruturas e desenvolver tecnologias que permitam a integração de bilhões de dispositivos sensoriais e objetos do mundo real que fornecem diferentes capacidades e produzem e trocam dados. Dados estes que após coletados, podem ainda não ser caracterizados como "informação", pois precisam

ser pré-processados para que se extraia o conhecimento desejado e através dele sejam tomadas decisões. Entretanto, de acordo com Di Martino et al. (2019), coletar e armazenar este enorme volume de dados gerados pelos maquinários de uma fábrica é um cenário muito desafiador, pois envolve diversas variantes, como por exemplo, a maneira como os dados são coletados e armazenados, de forma a permitir seu acesso sem comprometer o desempenho do modelo como um todo.

Em Niggemann et al. (2015), é feita uma abordagem orientada a dados, trazendo um modelo de monitoramento e diagnóstico observando e analisando o comportamento de um determinado Sistema Ciber Físico (CPS), que pode ser melhor compreendida na Figura 3.

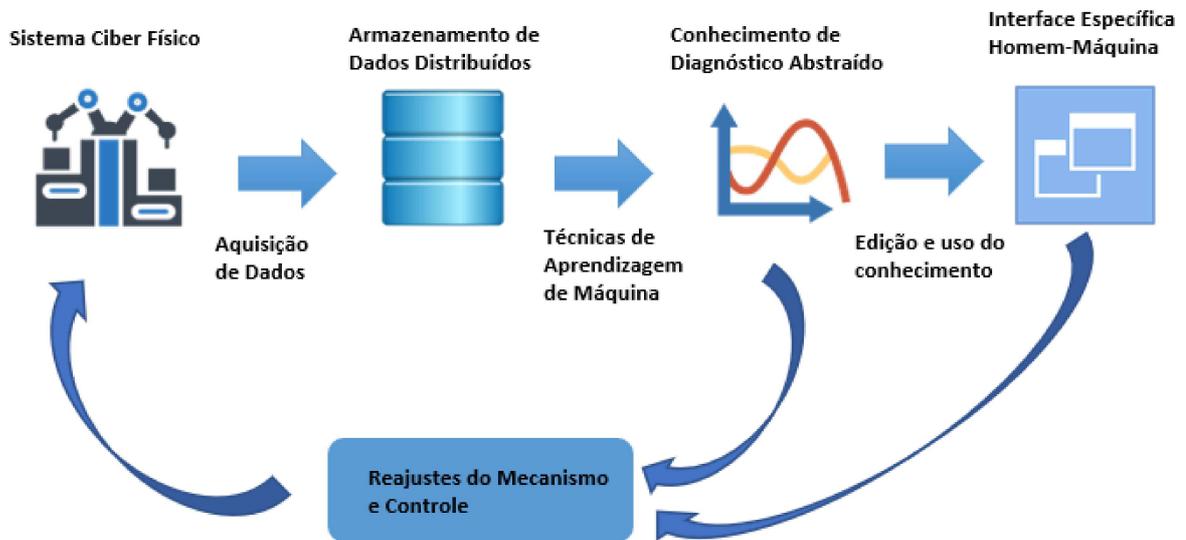


Figura 3: *Cyber Physical System*
 Fonte: Adaptado de Niggemann et al. (2015)

De forma resumida, o modelo propõe que na medida em que os dados são coletados do ambiente físico, eles sejam armazenados em uma arquitetura preparada para receber um grande volume de dados, que posteriormente serão processados, com o uso de algoritmos de *Machine Learning* (ML), podendo ou não ainda receber parâmetros através de interface humana, para que o sistema se auto-ajuste com base nas informações extraídas e/ou parametrizadas.

Outra abordagem realizada quanto ao armazenamento das informações capturadas por sensores é a de Di Martino et al. (2019). Nesta abordagem, são relatadas algumas formas de armazenar as informações dos sensores como, por exemplo, o uso de arquivos no formato de *Comma-Separated Values* (CSV) ou *Database Management System* (DBMS). Porém, em ambos os casos, dependendo da natureza dos dados, o armazenamento dos mesmos obteve problemas de gravação, justamente pelo fato de não conseguir acompanhar o tempo de gravação, na mesma velocidade em que os sensores realizavam suas leituras, gerando enorme gargalo de processamento.

No caso desta pesquisa, apesar do conceito de internet das coisas ser totalmente aderente a

ela, optou-se por um experimento *offline*, justamente para focar no conceito do modelo, e não na arquitetura dele.

2.3 Séries Temporais

Uma série temporal é uma sequência ordenada de valores registrados em intervalos de tempo. Sua análise pode ser dividida em duas partes, onde na primeira a função é obter o comportamento dos dados coletados, e na segunda, com base no comportamento, fazer previsões no comportamento futuro. São muitas aplicações que podem ser utilizadas com a análise de séries temporais, como por exemplo controle de processos, predição de falhas e previsões financeiras (DEB et al., 2017).

Através das séries temporais, é possível descobrir, com alguma margem de erro, valores futuros de um série, baseado no comportamento observado em valores passados, com grande interesse prático por diversas disciplinas (TEALAB, 2018).

A Figura 4 apresenta três pilares de análises baseadas em séries temporais (*time séries*), de acordo com Chen et al. (2015).

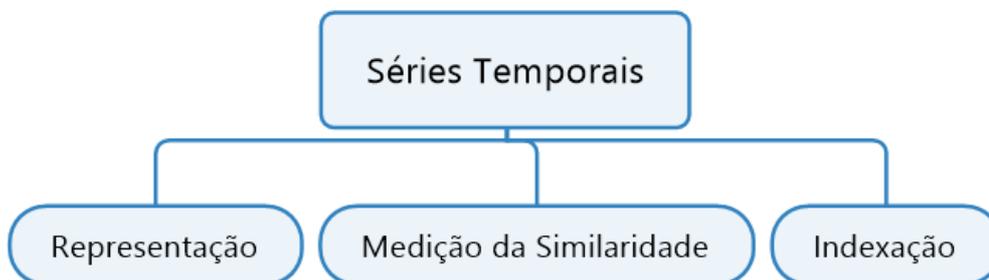


Figura 4: Pilares de Análises em Séries Temporais

Fonte: Adaptado de Chen et al. (2015)

De acordo com este modelo, existem 3 pilares principais que regem as metodologias para se trabalhar com séries temporais de dados:

- Representação
- Medição da Similaridade
- Indexação

Com base nestes 3 pilares, os *datasets* coletados devem ser transformados, de forma a extrair toda a informação necessária para se chegar ao resultado esperado pela pesquisa.

2.3.1 Representação

Para a representação dos dados, o sensor utilizado na coleta (abordado no **Apêndice A**) registrou o deslocamento provocado nos três eixos do plano cartesiano (X, Y e Z). E para esta atividade o sensor de vibração foi fixado estrategicamente em um local no maquinário que melhor capturasse estes movimentos. Desta forma, os dados coletados estão representados com um *dataset* para cada eixo, conforme Figura 5. Além disso, foram destacados alguns exemplos de modos de operação, para os quais foi comparada sua similaridade (Figura 6), utilizando no experimento apenas o eixo Y. Na Figura 7, foi destacado o modo de vibração, que fica contido dentro do modo de operação.

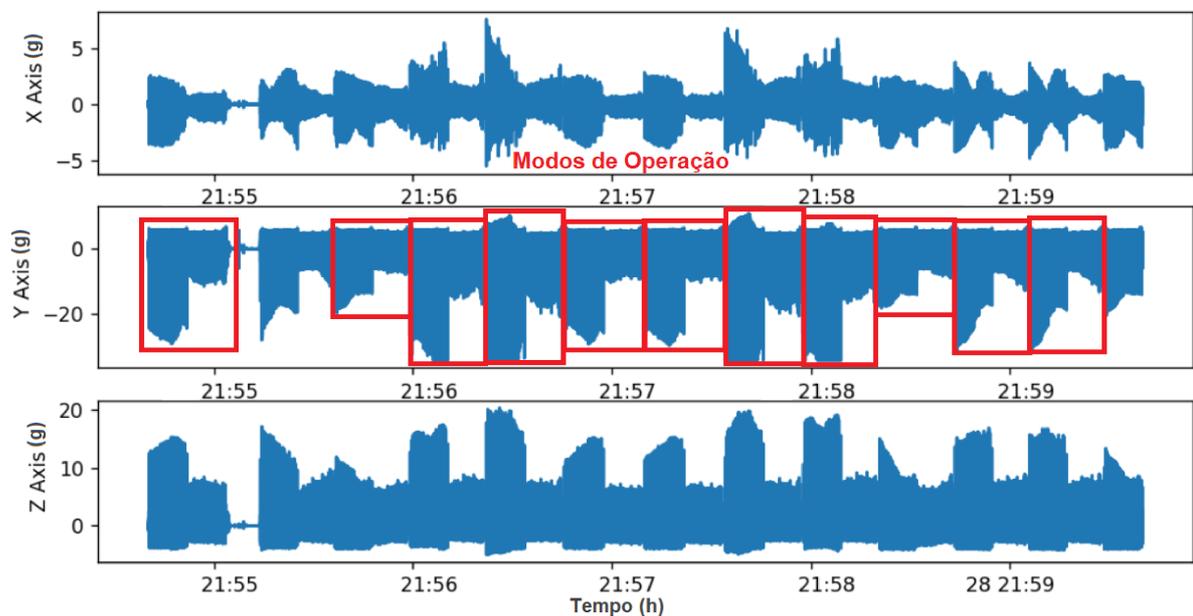


Figura 5: Representação dos dados coletados, referente aos 3 eixos de deslocamento com alguns modos de operação destacados.

Fonte: O Próprio Autor

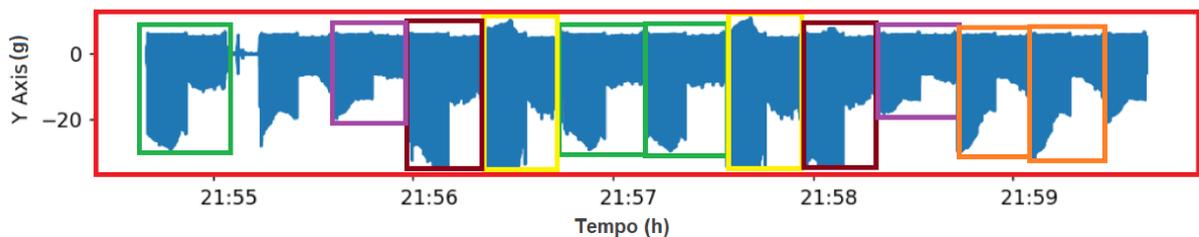


Figura 6: Eixo Y com algumas comparações visuais entre os modos de operação.

Fonte: O Próprio Autor

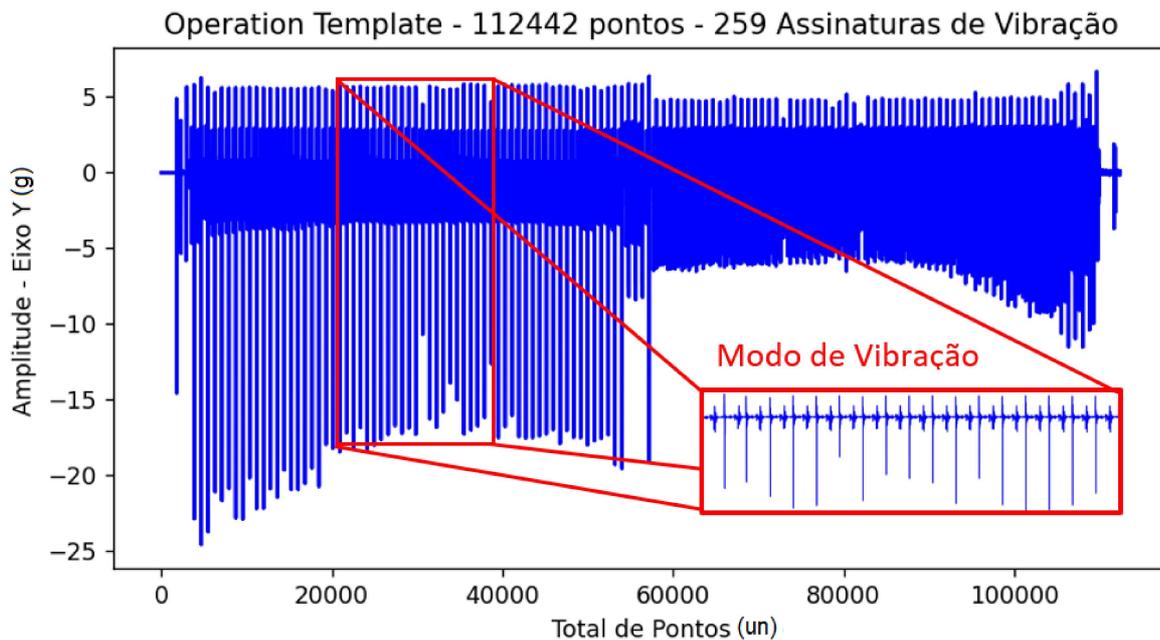


Figura 7: Representação dos dados coletados, destacando o modo de vibração contido em um dos modos de operação.

Fonte: O Próprio Autor

2.3.2 Medição da Similaridade

Para esta etapa da pesquisa, a metodologia utilizada para realizar a medição da similaridade entre assinaturas de vibração é baseada na normalização do tempo em que elas ocorrem, podendo medir suas distâncias, foi a técnica de *Dynamic Time Warping* (DTW), proposta por Sakoe e Chiba (1978). Esta técnica consiste em uma abordagem de programação dinâmica para alinhar a série temporal e um modelo de assinatura específico para que alguma medida de distância seja minimizada, sendo que, uma vez que o eixo do tempo é alongado (ou comprimido) para atingir um ajuste razoável, um modelo pode corresponder a uma ampla variedade de séries temporais reais (SAKOE; CHIBA, 1978).

Apesar de inicialmente ter sido proposta para o reconhecimento de fala, a técnica evoluiu bastante, bem como suas aplicações também foram expandidas na literatura, que podem ser vistas em alguns exemplos (KEOGH; PAZZANI, 2000, 2001; RATH; MANMATHA, 2003; SENIN, 2008; RAKTHANMANON et al., 2012; PETITJEAN et al., 2014; MUEEN; KEOGH, 2016; YU et al., 2019).

E para medir a similaridade entre os modos de operação, o DTW foi aplicado na camada do modo de vibração, comparando as assinaturas de vibração entre si (Figura 8).

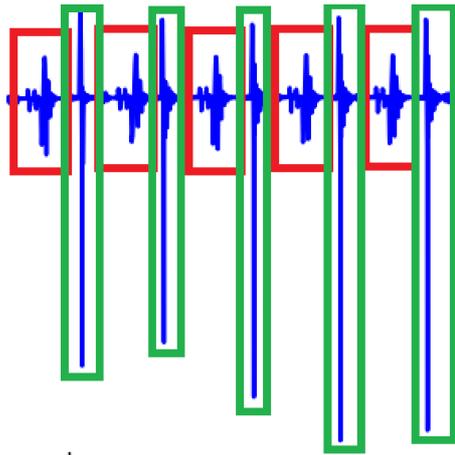


Figura 8: Representação dos dados coletados, destacando as assinaturas de vibração a serem comparadas pela sua similaridade.

Fonte: O Próprio Autor

2.3.3 Indexação

Nesta etapa, foram identificados os padrões de assinatura, bem como seu sequenciamento e quantificação, que também fazem parte do processo de avaliação da similaridade. Embora se utilize o DTW no modo de vibração da série temporal (onde as assinaturas de vibração são formadas), ele não será o único componente na avaliação da similaridade entre os modos de operação, que serão avaliados pela quantidade de padrões encontrados e também pela posição em que os padrões se encontram.

2.4 Processamento de Grandes Volumes de Dados

O conceito de *Big Data* vem agregando muito valor neste últimos anos, possibilitando o aprimoramento do desempenho das operações de empresas e na economia de vários países e organizações, que enxergaram este valor e têm iniciado vários projetos para aproveitar ao máximo este recurso (GOEL; DATTA; MANNAN, 2017). Mas não basta apenas ter os dados armazenados, pois é necessário saber extrair as informações desejadas de forma inteligente: e é neste momento que se faz necessário o emprego de técnicas de processamento de grandes volumes de dados, como por exemplo a "mineração de dados".

Conforme Chen et al. (2015), uma visão ampla da funcionalidade de mineração de dados pode-se dizer que envolve a descoberta de padrões de dados interessantes e potencialmente úteis, através da aplicação de algoritmos para extração de informações ocultas e armazenadas em *Datawarehouse* (DW), banco de dados ou qualquer outro repositório de armazenamento.

Com base neste conceito, a Figura 9 exemplifica as etapas por onde os dados passam, até se transformarem no conhecimento esperado:

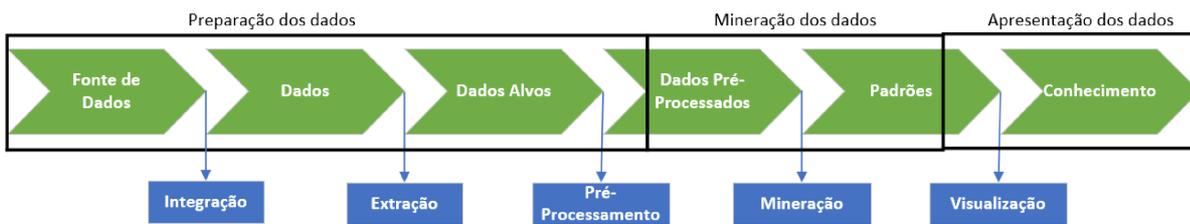


Figura 9: Visão Geral das Etapas de Mineração de Dados
 Fonte: Adaptado de Chen et al. (2015)

Outro modelo de mineração de dados é sugerido por Zhou, Yao e Zhang (2017), onde o uso do conceito de *Big Data* para manufatura não consiste apenas nos processos de fabricação, mas também para processos de venda, análise de mercado, serviços e manutenção, exemplificado na Figura 10:

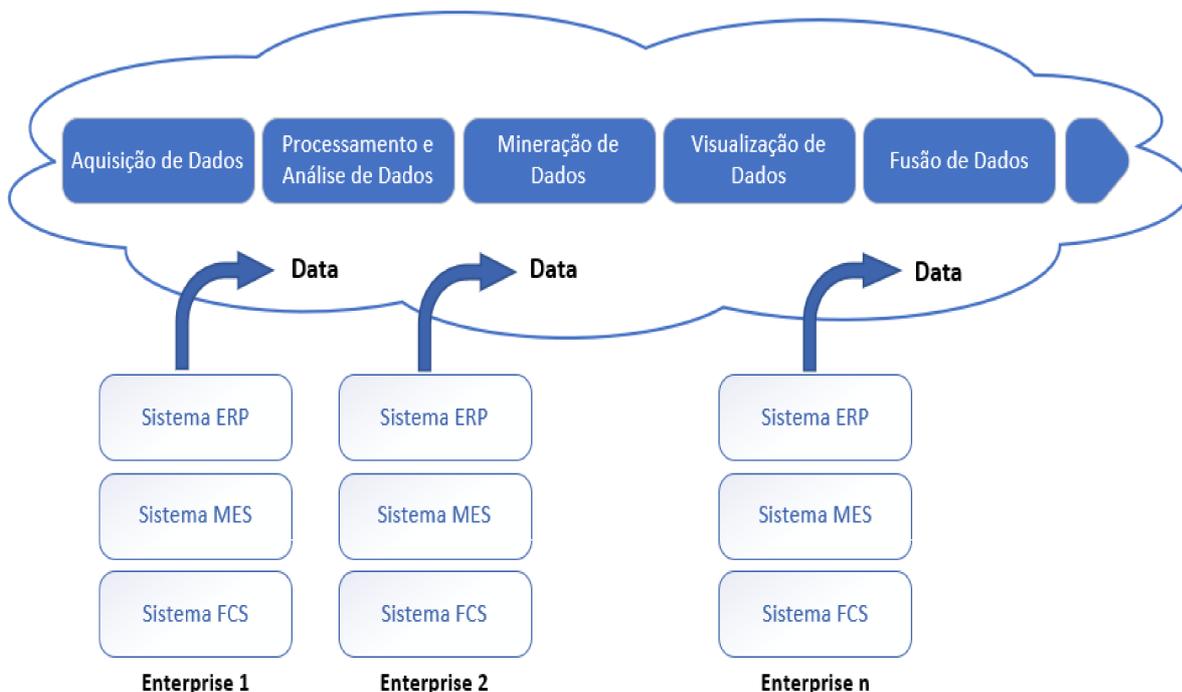


Figura 10: Integração dos dados de manufatura
 Fonte: Adaptado de Zhou, Yao e Zhang (2017)

Partindo deste premissa, para garantir a normalidade das operações que serão executadas pelas máquinas *wirebonders*, inicialmente foi preciso mapear algumas das operações que não causaram nenhum tipo de anomalia, para que desta forma fosse possível extrair seus modos de operações e modos de vibrações, para transformá-los em templates, que serviram de base comparativa para a mineração das operações subsequentes e mensurando a normalidade das operações sendo executadas, com base nos templates previamente extraídos.

É importante destacar que para extração das informações, a maioria dos algoritmos foram

desenvolvidos durante a execução do experimento, e alguns foram trazidos da literatura, com é o caso dos filtros de normalização e envelope (TAVENARD, 2019; TSE; PENG; YAM, 2001).

2.5 Wirebonding

Wirebonding é o processo de soldagem na microeletrônica utilizando fio de ouro para ligação do circuito eletrônico. O fio é colocado sob a ponta de uma ferramenta de ligação fina, semelhante a uma haste, onde ao se aplicar uma força no fio em contato com a superfície do eletrodo, é causada uma tensão inicial a frio. Através de um transdutor ultrassônico que gera vibrações mecânicas em uma faixa de frequência de cerca de 60 kHz e por um período de tempo de 100 milisseg., ocorre a deformação do fio e a ligação entre o fio e o substrato progridem constantemente durante esse processo de atrito a frio, até que um composto intermetálico puro entre o fio e a superfície seja formado, que ocorre em temperatura ambiente (RUOFF, 2016).

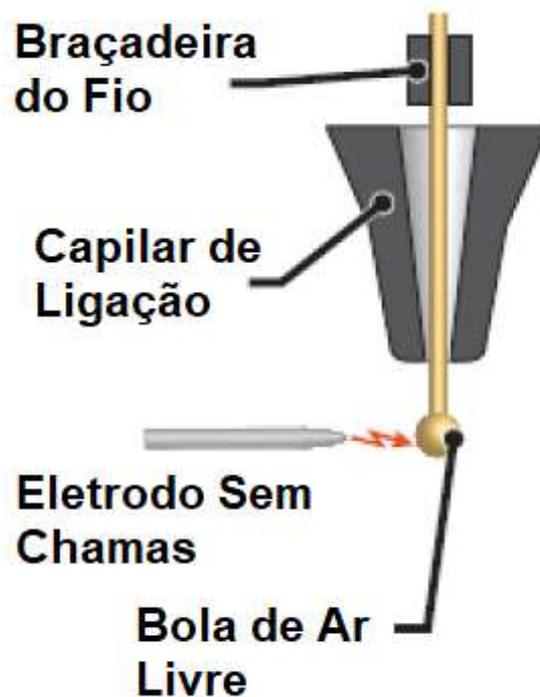


Figura 11: Fluxo do processo da ligação termossônica padrão de fio de ouro.
Fonte: Adaptado de Fischer et al. (2019)

De acordo com a Figura 11, o fio de ouro é alimentado através de um capilar de ligação cerâmica onde uma chama elétrica apagada derrete o fio até formar uma esfera em ouro. Esta esfera formada então é puxada pela ponta do capilar e posteriormente posicionada acima do local desejado. A ferramenta então pressiona a esfera de ouro com uma força definida, contra o local desejado, formando a conexão. Logo após, a ferramenta se desloca em direção a segunda posição desejada, para realizar a segunda conexão, interligando as duas regiões desejadas. Ao final, o fio é arrancado, fechando a braçadeira e movendo a ferramenta para cima (FISCHER

et al., 2019).

Contextualizando com esta pesquisa, estudos estatísticos na indústria de semicondutores mostram que a maioria dos equipamentos utilizados na manufatura deste segmento sofrem pelo menos 8% em paradas não programadas, e gastam mais 7% do tempo em manutenções programadas. Além disso, existe ainda o tempo de preparação e análise (outros 27%) e equipamento ocioso (14%), restando apenas 44% de estimativa de tempo de produção, que podem ser melhor visualizados na Figura 12, adaptada de Munirathinam e Ramadoss (2016). Além disso, para realização das manutenções, ainda existe uma grande dependência do uso de conhecimento humano, para condução e tomadas de decisão (TAN, 2008).

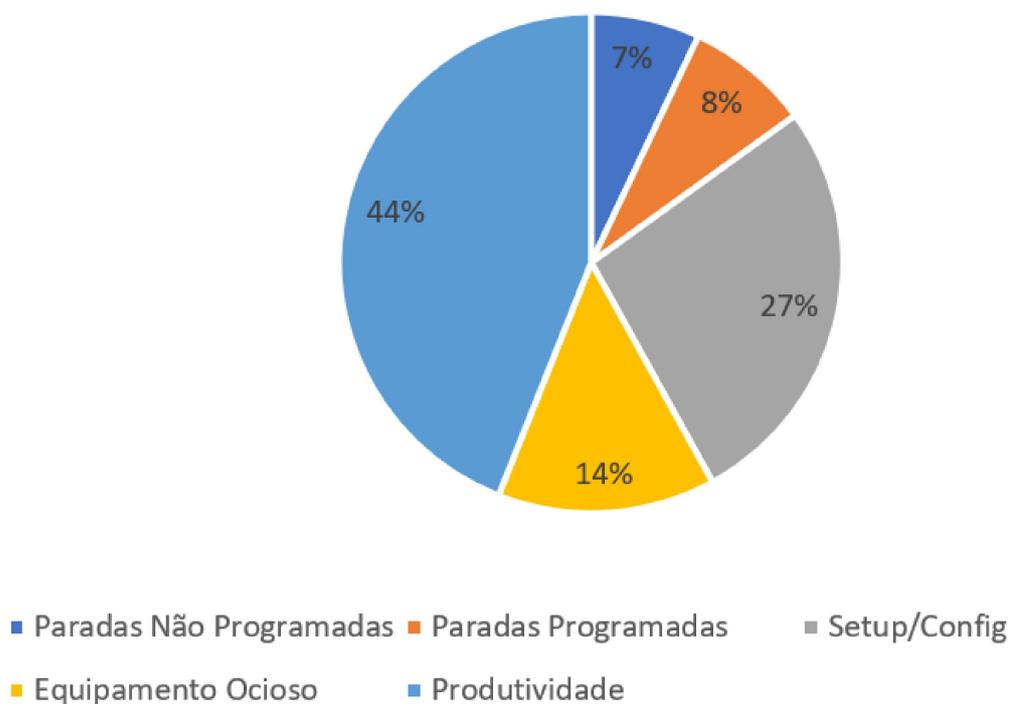


Figura 12: Gráfico estatístico referente aos tempos de produção para equipamentos de semicondutores
Fonte: Adaptado de Munirathinam e Ramadoss (2016)

Neste caso, o foco principal desta pesquisa foi o de atacar o problema das paradas não programadas dos equipamentos de manufatura, e que também se reflete na redução das paradas programadas para manutenção, uma vez que se saiba com maior precisão qual seria o momento certo para realizar tal manutenção. Desta forma, com a premissa de manter o monitoramento das operações para geração de um índice escalar de qualidade, que realiza comparações por similaridades entre os templates de operação mapeados e as operações em execução, foi possível acompanhar a degradação da qualidade das operações, sempre que um limite pré-determinado foi definido como regra de negócio. Esta regra que pode variar de equipamento para equipamento e também de empresa para empresa, mas em ambas as situações o foco é apenas um: com base neste índice escalar de qualidade, o monitoramento deve avaliar se a qualidade das demais operações estão acima deste índice.

3 TRABALHOS RELACIONADOS

Neste capítulo, são apresentados os trabalhos relacionados que direcionam esta pesquisa quanto à aplicação de técnicas de pré-processamento e processamento dos dados coletados para a avaliação inicial, explicado no capítulo sub-sequente. Nele, são abordadas algumas técnicas para preparação e segmentação do sinal de vibração, com a finalidade de extrair as informações relevantes para construção do modelo proposto, que tem por finalidade a criação de uma base de conhecimento de templates de operação do equipamento baseados em sinais de vibração para máquinas *wirebonders*, e a partir deles a geração de um índice escalar de qualidade de operação, através de comparações por similaridade.

Para escolha dos trabalhos relacionados, a base utilizada foi o repositório da *Google Scholar*. Nele foram procurados por artigos que estivessem relacionados com:

- "*vibration analysis*"
- "*wire bonder*"
- "*operation template*"
- "*operation modes*"
- "*machine data acquisition*"
- "*machine data collection*"
- "*manufacturing execution system*"
- "*feature extraction*"

Inicialmente, se utilizou a seguinte combinação de termos com filtro de ano a partir de 2017:

"vibration analysis"AND "feature extraction"AND "wire bond"

No retorno da busca por esta *string*, apesar dos poucos artigos que abordam o assunto correlacionado, pode-se destacar o modelo proposto por Joseph et al. (2018).

Para este modelo, referente a abordagem tradicional, que utiliza como parâmetros, sensores e dados de vibração, e como parte dos métodos de avaliação, a "análise de vibração" e a "análise de assinatura (de vibração)", são ambas pontos-chaves para esta pesquisa. Pois a análise de vibração provou ser um método eficiente para obter soluções baseadas em frequência, seja ela em alta ou baixa (HUANG et al., 2017).

Na Tabela 2, de acordo com Volkov, Shilova e Kachanov (2018), são listados alguns termos que foram utilizados nas publicações dos últimos 5 anos, tendo como base o ano de 2018 em que o artigo foi publicado.

Keywords \Year	2013	2014	2015	2016	2017	2018*
Cyberphysical Systems	42	43	85	87	115	41
Industry 4.0	114	217	349	743	1349	679
Manufacturing Execution System	174	197	196	232	200	92
Machine Data Collection	480	519	590	674	821	382
Machine Data Acquisition	619	726	816	920	1187	531

Tabela 2: Estatística de Palavras Chaves Utilizadas nos Últimos 5 Anos, anteriores a 2018.

Fonte: (VOLKOV; SHILOVA; KACHANOV, 2018)

Baseado nesta tabela, utilizou-se outra combinação de termos com filtro de ano para 2017:

("machine data acquisition"OR "machine data collection"OR "manufacturing execution system") AND "vibration analysis"

Dos artigos retornados como resultado desta busca, destaca-se o modelo proposto por Jung, Zhang e Winslett (2017). Neste modelo, são combinados parâmetros de fábrica com dados de sensores que monitoram os equipamentos em execução, passando por etapas de coleta, transformação, pré-processamento, extração das informações relevantes, até chegar no resultado proposto pelo autor.

De forma geral, existem vários modelos mencionados na literatura quando se trata de processamento de sinal (JABLONSKI; BARSZCZ, 2013; SARKODIE-GYAN et al., 2017; CHRISTOPHER; MDRASEDUL, 2018; ZHANG; LING, 2003; D'EMILIA; GASPARI; NATALE, 2019; LEE et al., 2020). Na sua grande maioria, eles são muito similares nas etapas de preparação e pré-processamento dos dados, mas com algumas variações que podem ser definidas de acordo com a análise de dados a ser feita, e o diagnóstico esperado. Ou seja, no final o resultado esperado é o diagnóstico daquilo que foi avaliado, seja para detecção de falhas ou anomalias que fogem do comportamento padrão do equipamento monitorado (D'EMILIA; GASPARI; NATALE, 2019).

Para os trabalhos relacionados, foram escolhidos alguns modelos que contemplassem etapas de aquisição de dados, preparação, pré-processamento e extração de informações relevantes, para que desta forma fosse possível avaliar as técnicas e metodologias aplicadas.

3.1 Modelos de Diagnósticos Baseados em Séries Temporais de Dados

No modelo proposto por Sarkodie-Gyan et al. (2017), após a leitura dos sensores, é definida uma etapa para extração de informação, passando por um motor de inferência, que irá comparar os recursos extraídos com uma base de dados, para que desta forma, decisões possam ser

tomadas, com base na grade de similaridade.

Já no outro modelo proposto por Jablonski e Barszcz (2013), além das etapas mencionadas no modelo anterior, são adicionadas etapas para combinação dos dados com parâmetros de máquina, para complementar a metodologia, tendo como base de conhecimento as configurações cinemáticas da máquina.

Em outro modelo proposto por Christopher e MdRasedul (2018), a etapa de pré-processamento ocorre após a etapa de segmentação, subdividida em 3 etapas: domínio do tempo, domínio da frequência, e domínio do tempo-frequência, que ocorre individualmente por segmento. Desta forma, o modelo é capaz de extrair informações, que são de interesse para a etapa seguinte, que é a classificação dos padrões extraídos. E neste caso, diversas técnicas de classificação de padrões foram utilizadas. Por fim, a etapa de controle, consolidada com o resultado comparativo entre as técnicas utilizadas. Entretanto, o modelo não sugere a comparação das informações obtidas por ele, com uma base de dados previamente criada.

Um outro modelo, proposto por Zhang e Ling (2003), prevê o monitoramento de *Wirebonders* através de uma análise de tempo-frequência, baseada na vibração do equipamento. Neste modelo, o autor sugere um método para avaliar a qualidade da solda realizada pelas máquinas *wirebonders*, através da análise da sua vibração. E baseado neste contexto, foram muito poucos os trabalhos encontrados para avaliar a qualidade da solda através da análise vibratória do equipamento.

Já Feng et al. (2009) propõem que as máquinas *wirebonders* sejam monitoradas através do sinal elétrico ao invés das vibrações, propondo um modelo mais recente posteriormente (FENG et al., 2011).

Outros modelos são propostos na literatura, como solução para análise de falhas baseado em sinal de vibração de um equipamento, cada um com sua aplicação específica (CHEN et al., 2013; ZHILI et al., 2005; FENG, 2014; LEE et al., 2020).

3.2 Análise das Técnicas Utilizadas nos Modelos Propostos

Na etapa de pré-processamento proposta por Sarkodie-Gyan et al. (2017), algumas técnicas como filtros, retificadores de sinal e envelopes lineares foram empregados para preparação dos dados a serem processados. Isto possibilitou simplificar os dados coletados, sem comprometer a qualidade dos mesmos, e facilitando a interpretação do comportamento do sinal. Embora no referido trabalho o objetivo não seja analisar a saúde de um equipamento e sim o comportamento do corpo humano submetido a determinados ambientes, foi possível observar que houve uma preparação dos dados antes deles de fato serem processados e comparados.

Em outro modelo, proposto por Christopher e MdRasedul (2018), também foram utilizadas técnicas de filtro de sinal, como a "raiz quadrada média" e o "valor absoluto médio" (*Mean Absolute Value* - MAV). Neste modelo, embora os dados analisados fossem de batimentos cardíacos, pode-se observar também a utilização de técnicas para preparação dos dados a serem

processados.

Já na etapa de processamento que é composta pela etapa de segmentação, este modelo propõe duas técnicas para segmentação:

- Segmentação Desmembrada: Usa segmentos separados com tamanho pré-definido para extração de recursos.
- Segmentação Sobreposta: O novo segmento desliza sobre o segmento atual, onde o intervalo de tempo entre dois segmentos consecutivos é menor que o comprimento do segmento e maior do que o tempo de processamento.

Entretanto, para esta pesquisa e tratando-se de análise de vibração em máquinas *wirebon- ders*, estes dois exemplos de técnicas de segmentação não são aderentes ao modelo proposto por esta pesquisa, que tem por finalidade avaliar sinais de vibração no domínio do tempo em que as assinaturas ocorrem.

No modelo de Jablonski e Barszcz (2013), foram sugeridas algumas metodologias de pré-processamento de sinal, como por exemplo "*data filtration according to operational states definition*" e "*data filtration according to fluctuation of operational parameters*" mas sem representação gráfica das técnicas. Também foram utilizadas técnicas de segmentação baseadas no tamanho do ciclo para processamento dos dados.

Em Lee et al. (2020), é proposta uma série de etapas de processamento de sinal: *sampling data, feature calculation, feature selection or extraction, classification and representation*.. E desta forma, consolidando que as melhores práticas para o processamento de séries temporais, é subdividir as etapas de tratamento dos dados.

3.3 Análise comparativa

Para a análise comparativa entre os trabalhos relacionados, foi necessário considerar modelos mais abrangentes, que não tratavam apenas de análise de sinal de vibração, mas que tiveram suas técnicas para pré-processamento, processamento, pós-processamento e extração de informação muito similares, apresentadas na Tabela 3. Nela é possível verificar todas as técnicas e metodologias aplicadas aos seus respectivos modelos propostos.

Em Sarkodie-Gyan et al. (2017) e Christopher e MdRasedul (2018), são compartilhadas algumas técnicas entre as etapas, entretanto as características dos dados e o ambiente em que eles são coletados são diferentes do ambiente deste trabalho, sendo parcialmente aderente ao modelo proposto nesta pesquisa.

Já em Jablonski e Barszcz (2013), também compartilham algumas técnicas entre as etapas, entretanto, a comparação é parcial, contemplado apenas fragmentos de sinal, e por consequência disso, também é parcialmente aderente ao modelo proposto nesta pesquisa.

Continuando com a análise, em Feng et al. (2011) e Zhang e Ling (2003) o ambiente de monitoramento é exatamente o mesmo deste trabalho. No primeiro caso, compartilham algu-

mas técnicas entre as etapas, e apesar de realizar reconhecimento de padrões, não contempla o reconhecimento por operações de trabalho, além de ser uma pesquisa de quase dez anos. Além disso, no segundo caso, compartilham algumas técnicas, mas este modelo está bastante desatualizado, por possuir quase vinte anos desde a data de sua publicação. E em ambos os casos, não estão totalmente aderentes ao modelo proposto nesta pesquisa.

E para finalizar, em Lee et al. (2020), apesar da proposta ser recente, que aborda diversas técnicas de processamento de sinal, não realiza comparações em bases de conhecimento, e nem contempla o reconhecimento por operações de trabalho, tornando-se também parcialmente aderente ao modelo proposto nesta pesquisa.

Autor	Ano	Tipo de Dado	Pré-Processamento	Processamento	Pós-Processamento	Comparação com Base de Conhecimento	Ambiente
(SARKODIE-GYAN et al., 2017)	2017	Cinemático e eletromiográfico do corpo humano	filtros, normalizações, envelope	clusterização, extração de característica (feature extraction)	medida por padrões de características, medida por similaridade difusa	reference feature matrix	corpo humano
(JABLONSKI; BARSZCZ, 2013)	2013	vibração mecânica	filtros aplicados de acordo com a flutuação dos parâmetros operacionais.	classificação pelo intervalo do tempo, classificação pelo estado operacional	análise dos parâmetros de processo de máquina, análise do domínio da frequência	comparação de fragmento de sinal	operação de máquinas pesadas
(FENG et al., 2011)	2011	sinal elétrico de solda	filtrados por um banco de filtros passa-banda, envelope	extração de característica (feature extraction)	feature selection, neural network	reconhecimento de padrões	máquina wirebonder
(CHRISTOPHER; MDRASEDUL, 2018)	2018	eletromiográfico do corpo humano	valor da média absoluta, integral do quadrado simples, tamanho da forma de onda	segmentação, extração de característica, classificação, rede neural, máquina de vetor de suporte(SVM)	nenhum	nenhum	corpo humano
(ZHANG; LING, 2003)	2003	vibração mecânica	transformada de Fourier de curta duração	extração de característica, classificação, rede neural	nenhum	correlação	máquina wirebonder
(LEE et al., 2020)	2020	vibração mecânica	diversos filtros e normalizações	seleção ou extração de característica (feature selection or extraction)	classificação(SVM)	nenhum	máquinas rotatórias

Tabela 3: Tabela comparativa de metodologias utilizadas para análise de séries temporais.

3.4 Lacunas de pesquisa

De todos os modelos que compõem os trabalhos relacionados, apenas um utilizou uma base de dados para comparação por similaridade com os dados extraídos, e não foi o modelo que analisava dados de vibrações de equipamentos, mas sim dados gerados pelo corpo humano. Ainda, esta base de dados mencionada foi superficialmente explanada, referente a sua construção e validação das informações armazenadas.

Partindo desta premissa, foi identificado a necessidade de explorar mais detalhadamente as metodologias de predição de falhas em máquinas do tipo *wirebonders*, mas observou-se também a necessidade de construir uma base de dados com operações de trabalho padrão, denominados de "templates de operações do equipamento", que foram catalogados de acordo com as operações em execução, para validação do experimento.

Além disso, esta pesquisa também teve por finalidade desenvolver uma metodologia para extrair estas informações, a partir dos dados de vibração do equipamento. Embora alguns destes trabalhos relacionados sejam referentes a *wirebonders*, apenas um deles apresentou metodologias para extração de informação (*feature extraction*) em máquinas *wirebonders*, mas utilizando dados elétricos ao invés de dados mecânicos, propondo o uso de uma rede neural, mas sem uma base de conhecimento para treiná-la.

Em todos os modelos dos trabalhos relacionados, o propósito principal das pesquisas foram sempre a predição de falha durante as análises comparativas, não sendo cogitada a possibilidade de investigar a situação contrária, que estaria realizando a predição de normalidade, partindo da premissa de predizer o que está fora do normal.

4 MODELO PROPOSTO

Neste capítulo, é apresentado o modelo proposto desta pesquisa, que engloba a extração de templates de operações de equipamentos industriais através de dados de vibração coletados com o uso de acelerômetro (Apêndice A). Uma vez que estes templates sejam catalogados, será possível gerar o índice de qualidade de operação do equipamento, comparando como referência os templates existentes com as operações em tempo real, por exemplo. Estes templates também poderão ser usados para predição de normalidade de operação ou detecção de anomalias, nas quais as operações avaliadas não condizem com o template de operação em questão, embora o equipamento esteja realizando a mesma operação em que o template foi extraído, mas com algumas pontuais diferenças na sua composição.

A arquitetura do modelo foi apresentada com base em fluxo de tarefas, com entradas e saídas específicas, que exemplificam em cada etapa como o dado é tratado, em todas as etapas previstas que vão desde a coleta dos dados no equipamento, passando pelas etapas de pré-processamento, preparação, processamento, catalogação e extração do template de operação e por fim, na geração do índice de qualidade da operação sendo avaliada.

4.1 Visão Geral do Modelo

De forma geral, o modelo propõe a criação de templates de operação de equipamentos industriais através dos dados de vibração coletados manualmente. São realizadas algumas etapas de pré-processamento nos dados, até que eles estejam preparados para passar pelo modelo sugerido, que engloba uma arquitetura especificamente elaborada para atender a equipamentos específicos neste momento, explicando todas as etapas de processamento, catalogação e extração dos templates de operação. No caso do tipo de equipamento escolhido, este foi uma *Wirebonder*, mais conhecida como máquina de solda para microchips, utilizada na indústria eletrônica.

Na Figura 13, é apresentada a visão geral do modelo proposto, de forma resumida, e que possui inicialmente as seguintes fases: a escolha da operação que serviu como template comparativo, e a comparação por similaridade com operações realizadas posteriormente. Para ambas as fases, as operações precisaram ser mapeadas quanto ao tipo de assinatura de vibração, quantidade e sequenciamento das mesmas, visto que a comparação por similaridade levou em conta todas estas informações, já que não bastava apenas saber se as assinaturas de vibração contidas em uma operação eram similares. Era necessário saber o quão similares estas operações podiam ser, uma vez que, se existe uma operação mapeada e dentro dos padrões de qualidade esperados, espera-se que as operações seguintes sejam similares, e caso não sejam, fazendo com que esta similaridade esteja se distanciando, foi possível dizer que aquela operação comparada estava com os níveis de qualidade abaixo do esperado, que dependendo do tamanho da diferença pode se tornar um problema, resultando em falhas na operação.

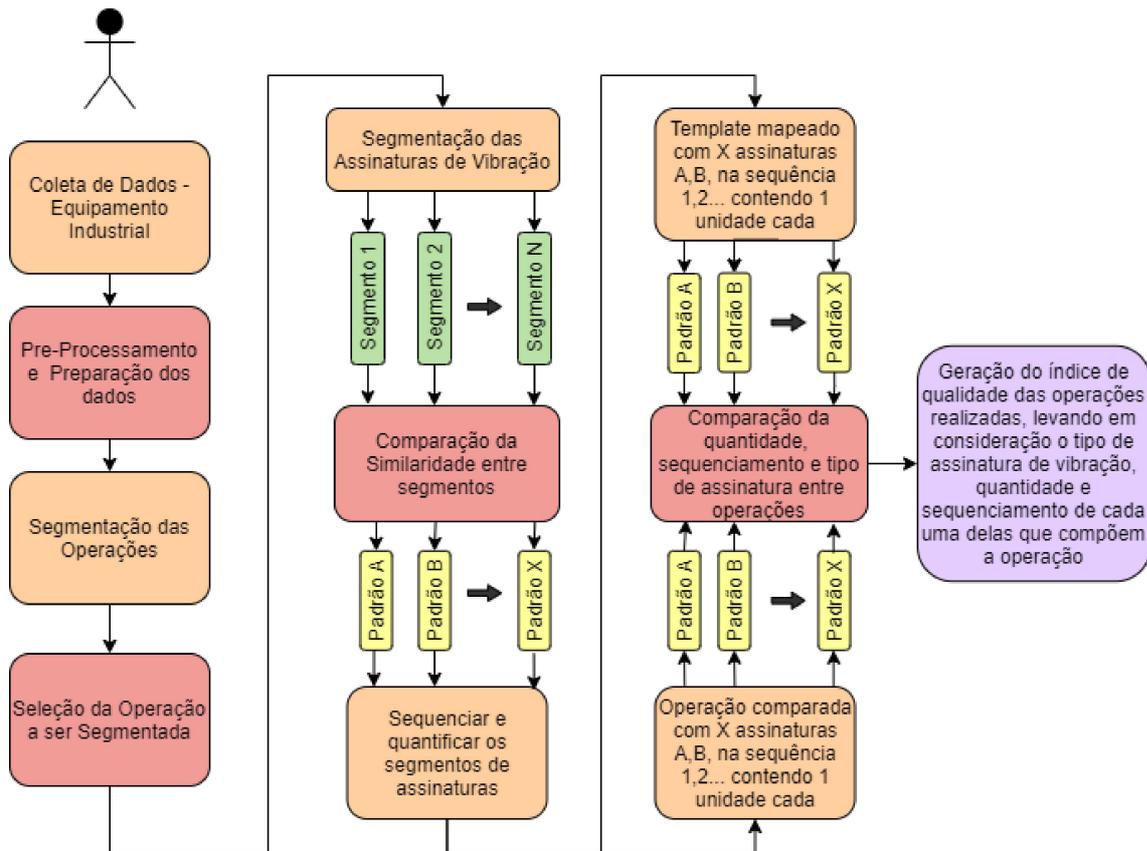


Figura 13: Visão Geral do Modelo Proposto.
Fonte: O Próprio Autor

Na arquitetura final do modelo (Figura 14), é apresentado detalhadamente o que é feito em cada uma das etapas (distintas também por cores), que contemplam a aplicação de filtros, normalizações, segmentações, separação por tipo de assinatura, quantificação e sequenciamento das mesmas, que compõem uma operação. Após todas estas etapas serem realizadas, e finalizando o mapeamento das operações (tanto o template quanto a operação a ser comparada), é possível calcular o índice escalar de qualidade de operação.

4.2 Arquitetura do Modelo

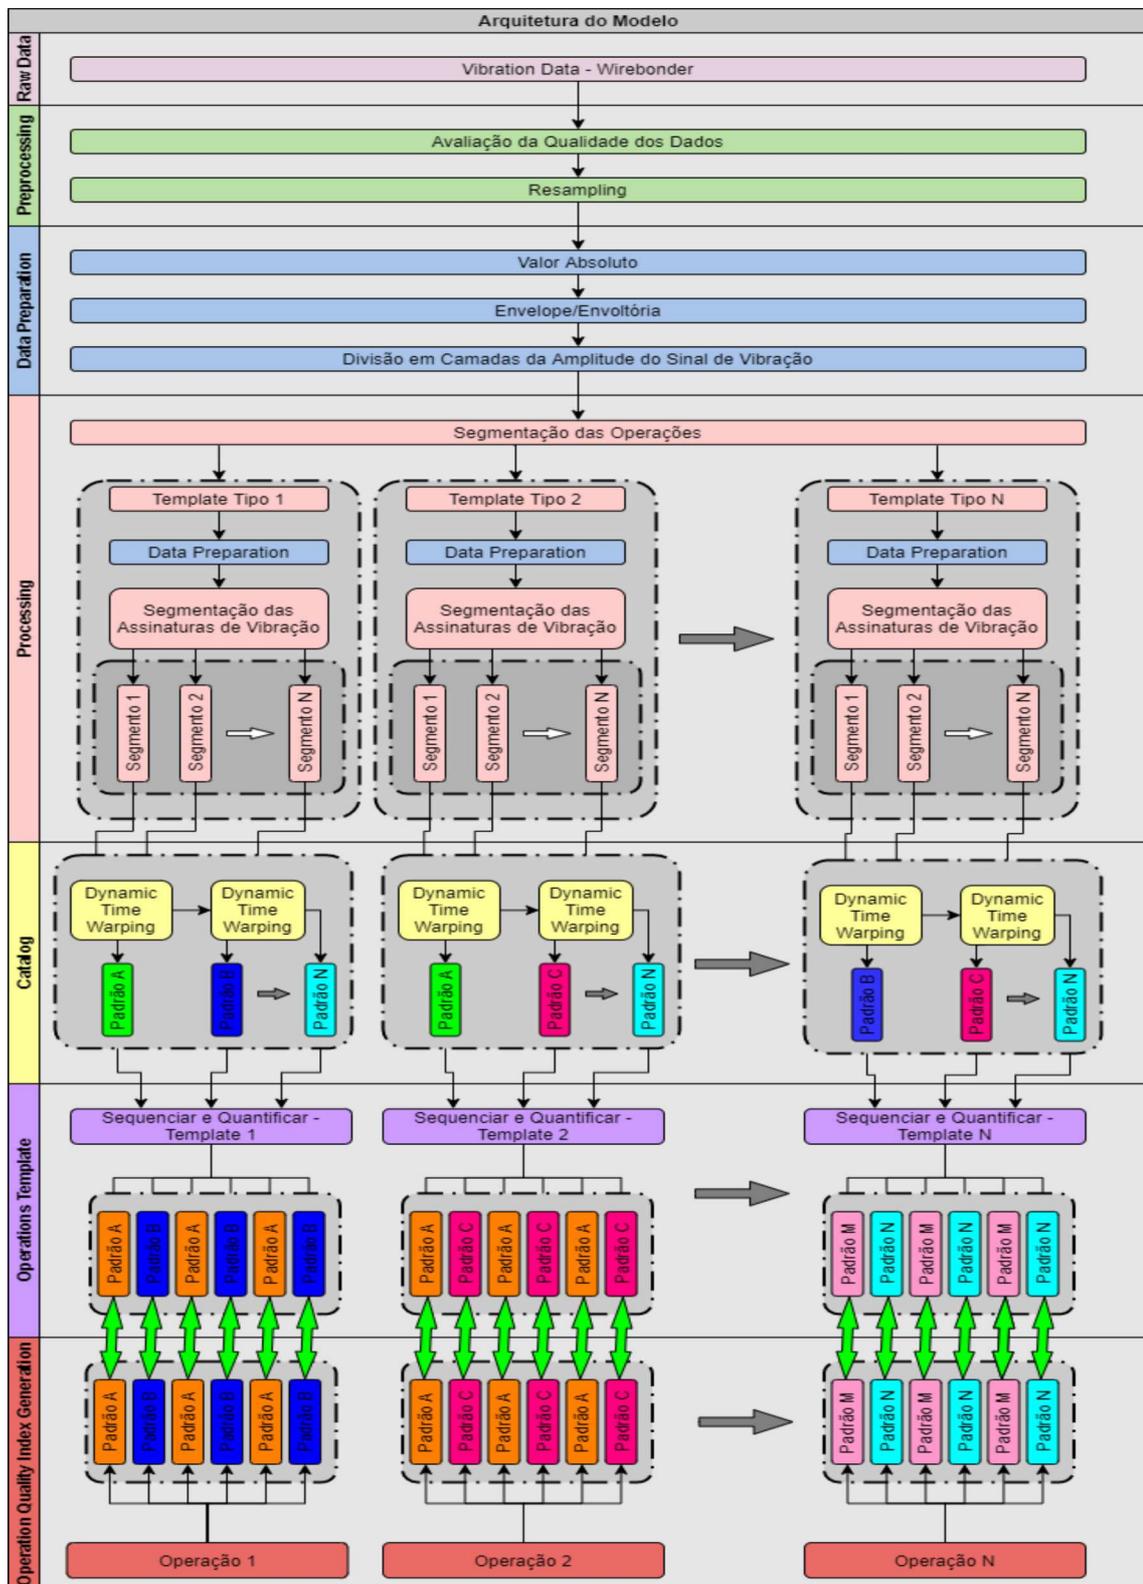


Figura 14: Arquitetura do Modelo Proposto.

Fonte: O próprio Autor

Para o modelo proposto, foram definidas 7 etapas, para modelagem e extração dos templates de operação propostos, bem como a metodologia para geração do índice de qualidade de operação. Em cada uma das 7 etapas foram definidos procedimentos e aplicações de metodologias, em uma sequência lógica para que a etapa em questão pudesse ser concluída, pois o resultado obtido na etapa atual seria uma dependência para início da etapa seguinte.

De forma geral, na primeira etapa (*raw data*), ocorre a preparação da infraestrutura para coleta dos dados. Na segunda etapa, os dados são validados e simplificados com o propósito de reduzir o custo computacional e sem comprometer a qualidade dos resultados que pode ser feito reduzindo a quantidade de pontos sem alterar significativamente o formato de onda da série temporal. Dando continuidade para a etapa seguinte, ocorre uma preparação dos dados, com a utilização de alguns filtros (valor absoluto, envelope e divisão em camadas da amplitude do sinal) para se obter o resultado esperado neste momento. Já na etapa quatro, ocorre uma intersecção dos dados filtrados na etapa anterior, para extração dos índices de segmentação das assinaturas. E com os dados segmentados, na etapa cinco inicia-se o processo de catalogação, para identificar dentro do template de operação, os tipos de assinaturas existentes. Na penúltima etapa, são conhecidas as posições que cada tipo de assinatura ocupa, e suas quantidades, finalizando o mapeamento do template de operação. E na última etapa, responsável por gerar o índice de qualidade de operação, o template é comparado com outras operações, gerando assim o índice de qualidade.

4.2.1 *Raw Data*

Nesta etapa, tratando-se de um sistema que neste primeiro momento não será um sistema supervisionado, se faz necessário realizar a coleta manual das informações do equipamento. Para coleta dos dados de vibração, é necessário a utilização de um sensor do tipo acelerômetro, para capturar as ondas de vibração do equipamento em todas as direções, com uma precisão de 5Khz a 10Khz, possibilitando capturar todo o espectro de vibração do equipamento. Para o registro visual (que serviu de material de apoio) das operações e posterior identificação das mesmas, foi utilizado um aparelho celular para realizar as gravações em vídeo. É importante ressaltar neste momento, que o vídeo precisa ter registros de hora, minuto e segundo, para poder confrontar com as séries temporais das vibrações.

4.2.2 *Preprocessing*

Na etapa de *Preprocessing*, os dados são validados para utilização no experimento, mediante o uso de métodos para processamento de sinais. Alguns destes métodos são baseados em regras definidas por Jablonski e Barszcz (2013):

- Continuidade visual mandatória (para longos períodos).

- Exigida certa complexidade (oposta a uma onda senoidal gerada por computador).
- Níveis racionais de amplitude.
- Quantização imperceptível (para longos períodos).
- Nitidez suficiente da forma de onda do tempo (devido às expectativas de componentes de alta frequência).
- Mudanças bruscas de sinal presentes apenas em um grau permitido pelo comportamento real da máquina.
- Valor médio esperado (base zero de aceleração).

Levando em consideração a precisão da forma de onda do tempo, os dados deverão ser reorganizados, de forma a reduzir a quantidade de pontos por segundo, sem comprometer a qualidade da precisão da onda. Para isto, os dados foram tratados com o uso de funções de reorganização (*resampling*) proposto por Tavenard (2019), para simplificar e reduzir o custo computacional do experimento. Desta forma, é possível reduzir a variabilidade dos resultados, conforme descrito em D’Emilia, Gaspari e Natale (2019), que traz uma abordagem industrial baseada em ações experimentais de simulação e análise virtual.

4.2.3 *Data Preparation*

Uma vez que os dados estejam validados para seguir com as etapas seguintes, nesta próxima etapa serão utilizados mais alguns algoritmos, com o propósito de preparar os dados para a etapa de segmentação das operações. Mas antes disso, caso os dados possuam valores negativos, os mesmos deverão ser transformados em valores positivos, aplicando mais um tratamento com o uso de funções que transformam todos os dados em valores absolutos, proposto também por Tavenard (2019) e pré-requisito para a próxima etapa do processo.

Com esta etapa, será possível aumentar a precisão do próximo algoritmo, que é o envelope, também conhecido por envoltória, e responsável por destacar os picos de energia contidos no sinal de vibração (TSE; PENG; YAM, 2001). E como ela é aplicada apenas a um único sentido da amplitude, foi necessário realizar esta transformação nos dados do sinal de vibração.

Em Sistemas Ibéricos (2020), é apresentado um exemplo de envoltória tradicional, e mais abrangente, que identifica apenas os grupos de assinatura de vibração que compõem um ciclo de operação do equipamento. Também é abordado um exemplo onde a precisão da envoltória é maior que na aplicada anteriormente, possibilitando envolver não só a operação como um todo, mas as assinaturas de vibração individualmente.

Embora a técnica aplicada seja a mesma para ambas as situações, o que muda basicamente é um parâmetro de precisão, que dependendo do valor abrange o modo de vibração ou o modo de operação.

Neste ponto, devem ser definidas camadas que servirão como limites na definição dos segmentos, sejam de operação (Figura 15) ou assinatura de vibração (Figura 16). Quanto maior a quantidade de camadas, maior será a precisão da segmentação, sendo que o objetivo principal é utilizar como limite, a camada mais próxima do estado estacionário da vibração, ou a que melhor representar a assinatura de vibração.

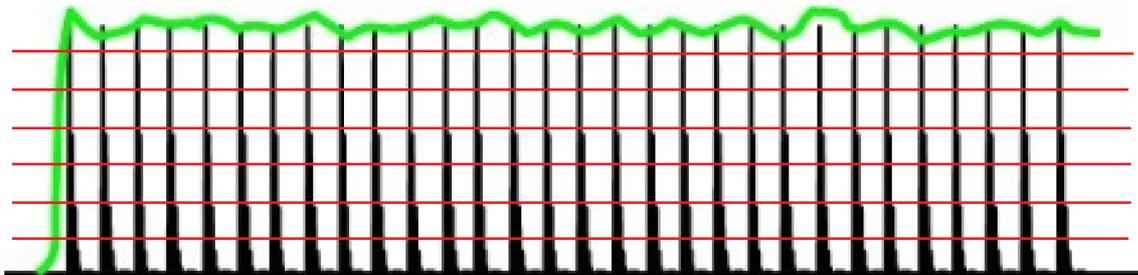


Figura 15: Definição de camadas de limite para segmento de operação
Fonte: Adaptado de Sistemas Ibéricos (2020)

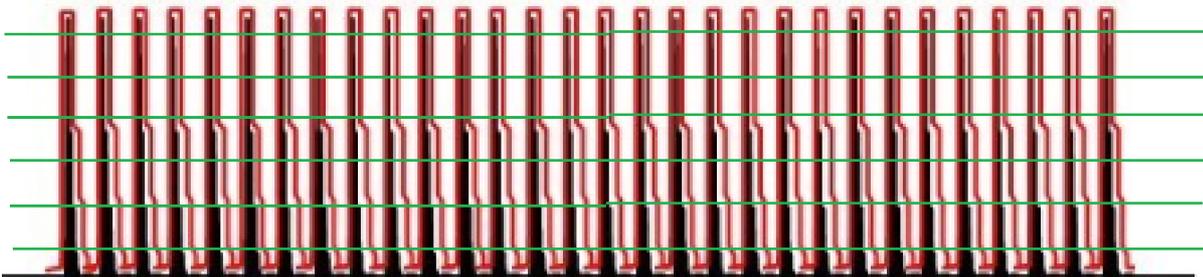


Figura 16: Definição de camadas de limite para segmento de assinatura de vibração
Fonte: Adaptado de Sistemas Ibéricos (2020)

Chegando nesta etapa, os dados já encontram-se preparados para serem segmentados por operação, e posteriormente por assinatura de vibração.

4.2.4 Processing

Para esta etapa de processamento de segmentação, pode-se utilizar o mesmo algoritmo proposto para ambos os casos. O que irá diferenciar a segmentação de operação da segmentação de assinatura de vibração, é a forma de como a envoltória é aplicada, se é mais abrangente ou refinada. No caso do algoritmo 1, a ideia é delimitar os dados entre os índices encontrados na segmentação, seja de operação ou assinatura de vibração. Para isto, serão coletados os pontos de intersecção entre a envoltória (também chamada de *envelope*) e a camada escolhida como limite dentro da amplitude do sinal e mais próxima de zero.

Algorithm 1: Segmentation

Input: *envelope, layer*
Output: *idxarr*

```

1 begin
2   idxarr = []
3   seg = True;
4   for each point in envelope do
5     if point > layer then
6       if not seg then
7         idxarr.append(point);
8       seg = True;
9     else
10      seg = False;
11  return idxarr;

```

Fonte: O Próprio Autor

Estando segmentada a operação e também suas assinaturas de vibração, a próxima etapa será a de catalogar as assinaturas de vibração, bem como seu sequenciamento e suas respectivas quantidades de cada tipo de assinatura encontrada.

4.2.5 Catalog

Neste processo de catalogação das assinaturas de vibração, será possível identificar os padrões de assinatura que irão compor um modelo de template de operação proposto nesta pesquisa. E para realização do comparativo entre os segmentos, foi utilizada a técnica *Dynamic Time Warping*, que compara se os dados fornecidos são similares, numa escala de 0 a ∞ , sendo que quanto mais próximo de 0 significa maior precisão nos dados onde serão encontrados mais tipos de assinaturas, e mais crescente e distante de 0 significa menor precisão nos dados onde serão encontrados menos tipos de assinaturas. Neste caso, para validação da similaridade será utilizado um Intervalo de Confiança (IC) a ser definido na avaliação inicial do modelo, conforme o algoritmo 2.

Algorithm 2: Catalog

Input: $timesries, IC, segment_1, segment_2$ **Output:** $pattern_A, pattern_B$

```

1 begin
2    $pattern_A = []$ 
3    $pattern_B = []$ 
4   for each  $seg$  in  $timesries$  do
5      $similarity = DTW(segment_1, segment_2);$ 
6     if  $similarity < IC$  then
7        $pattern_A.append(segment_1);$ 
8        $pattern_B.append(segment_2);$ 
9     else
10       $pattern_A.append(segment_1);$ 
11       $pattern_A.append(segment_2);$ 
12  return  $pattern_A, pattern_B;$ 

```

Fonte: O Próprio Autor

Após o algoritmo passar por todos os segmentos da operação e identificar os segmentos padrões, está finalizada a etapa de catalogação dos padrões de assinatura de vibração, restando agora apenas montar e definir os templates de operação.

4.2.6 Operation Template

Uma vez que já se saiba quais são os padrões de assinatura de vibração, nesta etapa será realizado o sequenciamento e a quantificação dos mesmos, tendo como objeto final um dos templates de operação do equipamento.

Com isso, o modelo proposto pode ser utilizado para catalogação das operações de trabalho dos equipamentos monitorados, desde que confrontados com os parâmetros do equipamento para garantir a integridade da operação. Será construída uma base de dados de templates de operação por equipamento, e desta forma possibilitará que sejam avaliadas suas respectivas qualidades de operações.

4.2.7 Operation Quality Index Generation

Neste momento, é realizada a comparação dos templates extraídos, com as operações a serem avaliadas. E através deste comparativo, será possível calcular o índice de qualidade das operações avaliadas.

No exemplo da Figura 17, é realizada a comparação de uma operação do equipamento mo-

comparado com o template previamente catalogado na base de conhecimento, obtendo neste caso específico um índice de qualidade de operação de 100%, levando em consideração o número de padrões coincidentes em tipo, quantidade e posição.

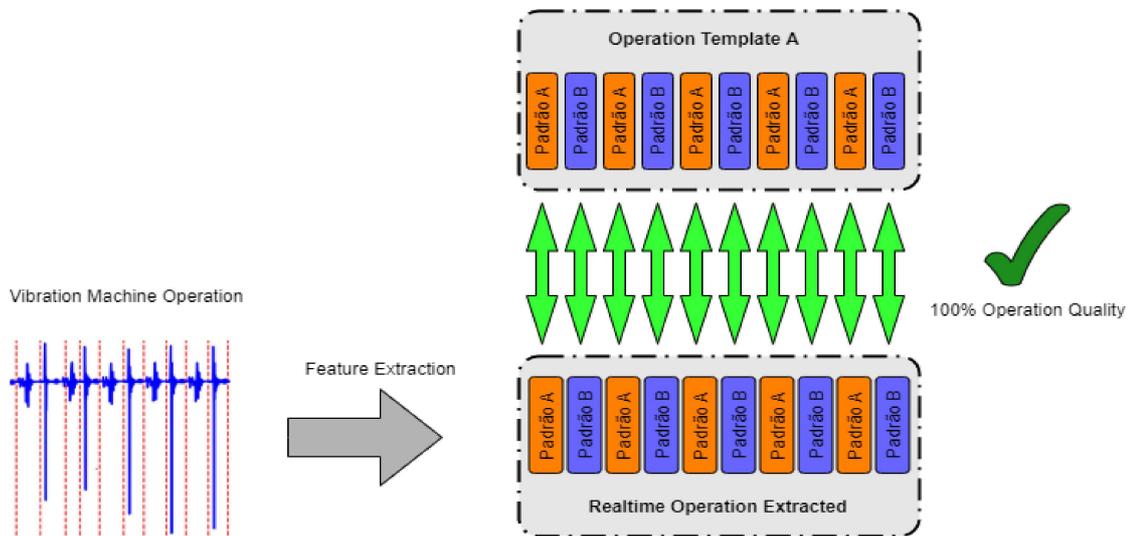


Figura 17: Avaliação da Qualidade da Operação do Equipamento - $Q = 100\%$
Fonte: O Próprio Autor

Já no exemplo da Figura 18, apesar de também realizar os mesmos procedimentos de comparação entre a operação realizada e o template previamente catalogado na base de conhecimento, foi obtido um índice de qualidade de operação de 90%, devido à ocorrência de alguma anomalia ou comportamento fora do padrão.

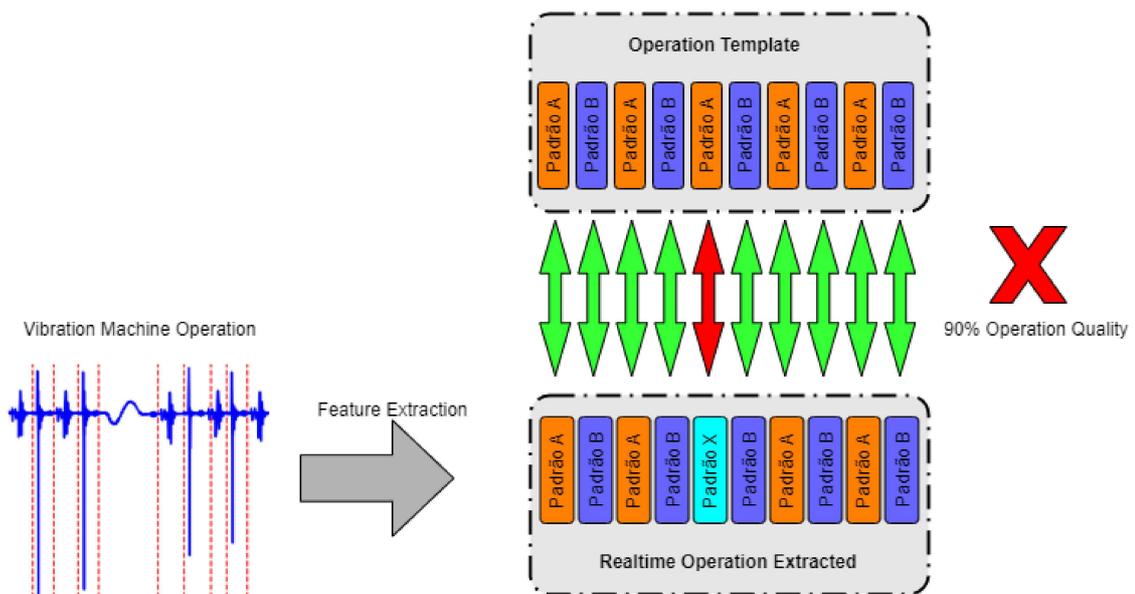


Figura 18: Avaliação da Qualidade da Operação do Equipamento - $Q > 100\%$
Fonte: O Próprio Autor

Desta forma, esta pesquisa trás uma outra abordagem de predição, que seria a "predição de normalidade" (LAZAKIS; GKEREKOS; THEOTOKATOS, 2019; IWASAKI et al., 2008; JI-

ANG; PAPAVALASSILIOU, 2003). Ou seja, com base em um template extraído de uma operação normal de trabalho, ao realizar o comparativo com outras operações, espera-se que o comportamento da operação sendo avaliada seja o mais próximo possível do normal, e que qualquer perturbação desta normalidade poderá ser caracterizado como fora do normal de uma operação de trabalho, degradando a qualidade esperada na operação.

No algoritmo 3, está a visão geral do pseudocódigo para extração do template de operação do equipamento monitorado.

Algorithm 3: *Operation Template Extraction*

Input: *timesries*

Output: *template*

```

1 begin
2   Preprocessing(timesries);
3   DataPreparation(timesries);
4   OperationSegmentation(timesries);
5   for each operation in timesries do
6     VibrationSegmentation(operation);
7     for each segment in operation do
8       if not Catalog(segment) then
9         Catalog(Pattern);
10        Count(Pattern);
11        SaveIdx(Pattern);
12      template = SequenceAndQuantify(Pattern);
13    return template;

```

Fonte: O Próprio Autor

5 METODOLOGIA

Neste capítulo, são apresentadas as ferramentas utilizadas para implementação do experimento, bem como a infraestrutura montada, que possibilitou a geração dos resultados e avaliação dos mesmos. Como etapa inicial desta avaliação, e para geração do índice escalar de qualidade de operação, foi necessário pré-processar e organizar os dados de uma forma que possibilitasse a comparação por similaridade de operação, que leva em conta não só a similaridade da assinatura de vibração, mas também a quantidade de vezes que ela ocorre dentro de uma operação, e também as posições em que ela aparece. Sendo assim, para que as operações pudessem ser comparadas, foi necessário mapeá-las referente a três características: tipos de assinaturas de vibração, quantidades e sequencia de cada uma delas por operação. Este mapeamento foi necessário tanto para definição do template de operação que serviu de referência para comparação, quanto para as operações subsequentes, sendo definido em duas etapas: Extração das Operações, e Extração das Assinaturas de Vibração.

5.1 Ferramentas

Para que esta avaliação inicial fosse efetiva, foi utilizado um acelerômetro com capacidade de leitura de 20KHz (especificações disponível no **Apêndice A**). E a partir dos dados coletados, devido ao grande volume de informações a serem processadas, algumas técnicas específicas de armazenagem de dados foram empregadas (especificações disponíveis no **Apêndice B**). Desta forma, foi possível trabalhar com os dados, sem a necessidade de utilizar um hardware de alto desempenho, realizando as atividades sob demanda, para se chegar ao resultado esperado.

No desenvolvimento do modelo em linguagem *python*, foi utilizada a distribuição Anaconda, bem como uma série de bibliotecas que auxiliaram no desenvolvimento do protótipo (ANACONDA DISTRIBUTION, 2012; BAYER, 2012; VAN DER WALT; COLBERT; VAROQUAUX, 2011; MCKINNEY, 2010; Virtanen et al., 2020). Todos os resultados gráficos foram obtidos através da ferramenta *Jupyter Notebook* em conjunto com o *matplotlib* (JUPYTER - OPEN STANDARDS FOR INTERACTIVE COMPUTING, 2015; HUNTER, 2007). Todo o pré-processamento foi realizado utilizando a biblioteca *TSLearn* (TSLEARN - A PYTHON MACHINE LEARNING TOOLS, 2017). Na figura 19, está a arquitetura utilizada para o experimento, que basicamente é dividida em dois ambientes, sendo uma workstation que é responsável pelo processamento computacional principal, e uma máquina virtual que hospeda o banco de dados e sua arquitetura para clusterização de tabelas, que pode ser melhor compreendida no **Apêndice B**. Na Tabela 4, está a lista de todas as ferramentas utilizadas, com suas respectivas versões.

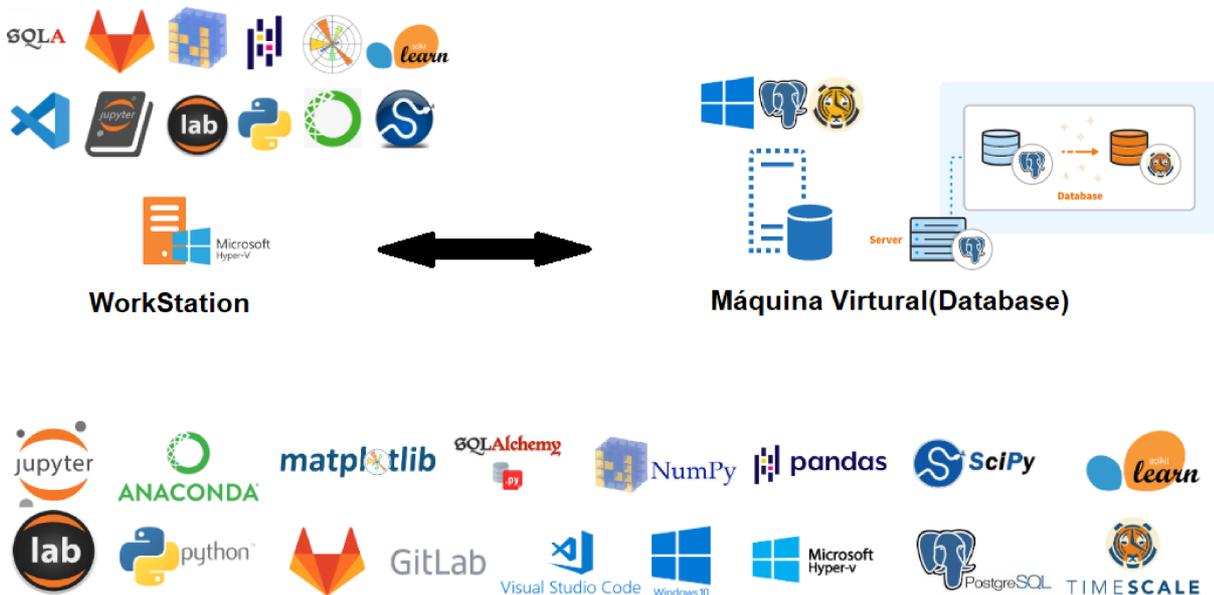


Figura 19: Arquitetura da Infraestrutura Utilizada, Composta por Uma Workstation e Uma Máquina Virtual, com suas Respectivas Tecnologias Implementadas.

Fonte: O Próprio Autor

Tecnologia	Versão	Função
PostgreSQL	10	Database
TimeScale DB	10	Clustering Database
SQLAlchemy	1.3.16	Object Relation Mapping(ORM)
Python	3.7.6	Language
Anaconda	4.8.4	Python Distribution
VS Code	1.50	IDE
GitLab	2.22	Git Repository
Scikit-Learn	0.22.2	Lib
Scipy	1.3.2	Lib
Numpy	1.18.1	Lib
Pandas	1.0.3	Lib
Matplotlib	3.2.1	Lib
Jupyter Notebook	2.1.0	Interactive Computing
Jupyter Lab	1.1.1	Interactive Computing

Tabela 4: Lista de ferramentas utilizadas para avaliação do experimento.

5.2 Amostra de Dados

Foram coletados 2 *datasets* com aproximadamente 8 horas de captura cada um, com taxa de amostragem entre 5 mil e 20 mil registros por segundo, totalizando mais de 2 bilhões de registros a serem analisados em cada eixo de deslocamento do equipamento em vibração, durante suas operações de trabalho. Vale ressaltar aqui, tanto a importância da fixação do sensor quanto a posição em que ele será fixado para coleta dos dados. É necessário garantir que ele não se soltará com a vibração do equipamento, e também que sua posição seja capaz de capturar todos os movimentos realizados pelo equipamento.

Na Figura 20, está uma plotagem com intervalo de 6 milhões de registros, contemplando algumas operações sendo executadas pela máquina, em um intervalo de 5 min.

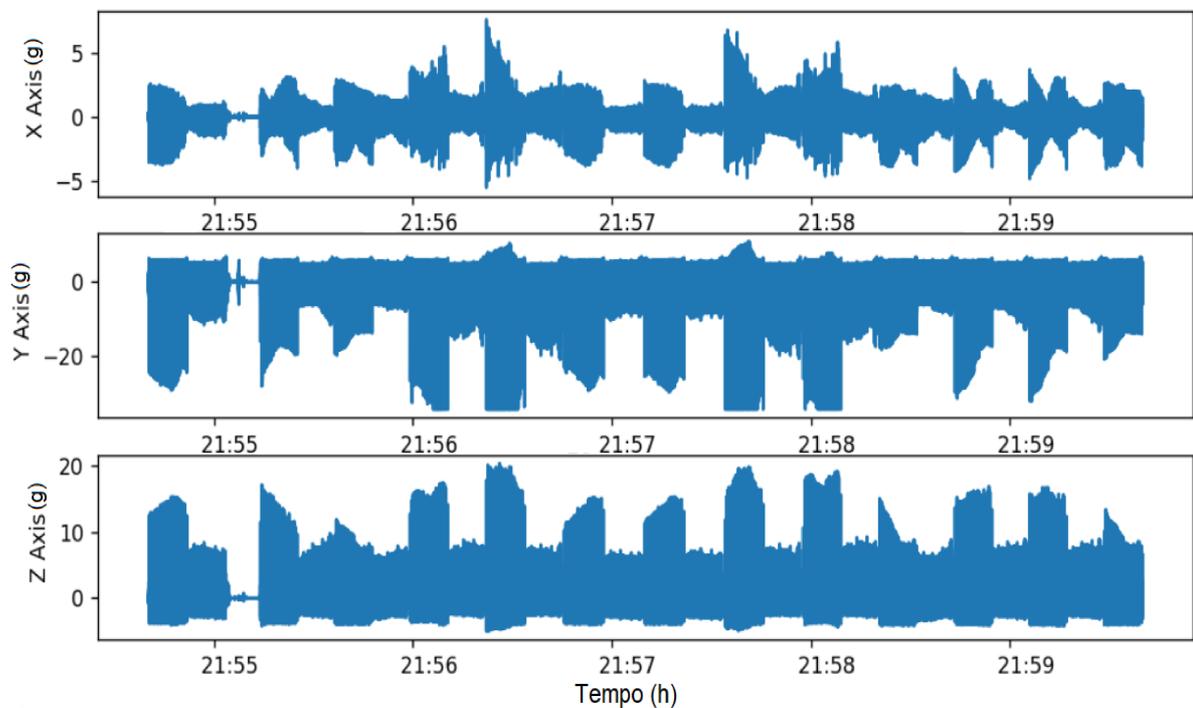


Figura 20: Amostra de Dados - 6 Milhões de Registros
Fonte: O Próprio Autor

5.3 Reorganização

Devido à taxa de amostragem ser consideravelmente elevada, foi necessário aplicar um filtro para reorganizar os dados, de forma a reduzir para uma taxa menor (5 mil registros por segundo) cada *dataset* coletado, sem comprometer a qualidade das amostras.

Na Figura 21, foi utilizado um intervalo de 350 mil pontos, após os dados serem reorganizados. Pode-se observar nesta figura que existe um intervalo entre uma operação de trabalho e outra. E para extrair uma única operação deste *dataset*, foram empregadas algumas técnicas de

pré-processamentos que serão abordadas a seguir.

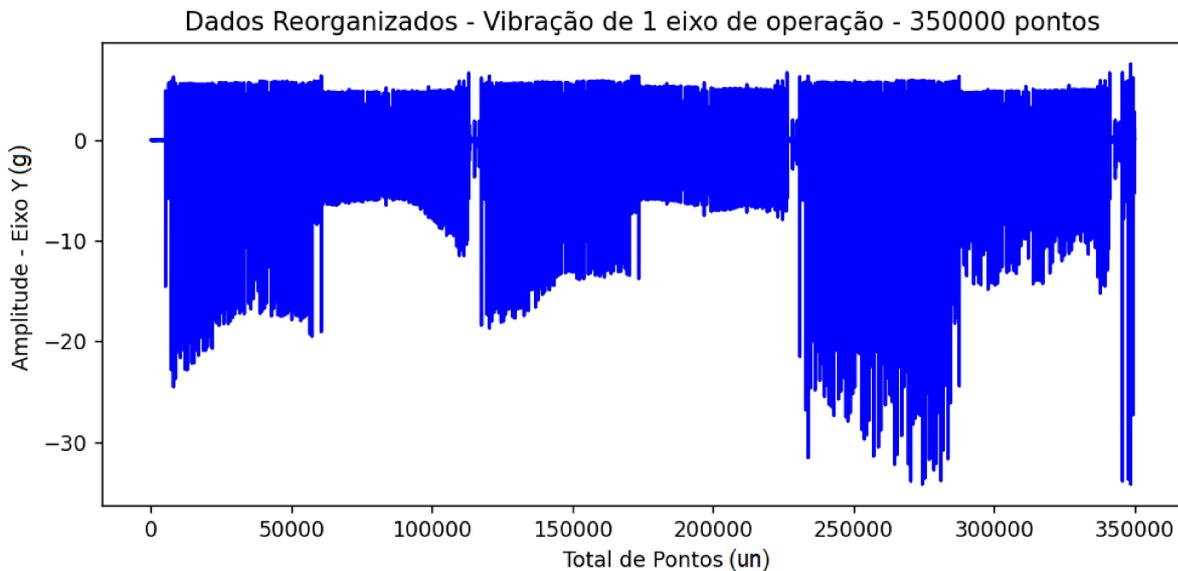


Figura 21: Dados Reorganizados - 350 mil pontos
Fonte: O Próprio Autor

5.4 Extração das Operações - *Operation Feature Extraction*

Nesta etapa, as operações serão fracionadas para melhor classificação das assinaturas de vibração posteriormente.

5.4.1 Valor Absoluto

Como parte do processo de pré-processamento, todos os valores negativos foram convertidos para valores positivos, ou seja, convertidos para valores absolutos. Este é um pré-requisito para as próximas etapas do pré-processamento. No primeiro gráfico da Figura 22, estão os dados sem alterações de valor absoluto, ou seja com dados positivos e negativos, e no segundo gráfico, estão as alterações aplicadas como pré-requisito para a etapa de envelope, conhecida também como envoltória.

5.4.2 Envelope

Para que as assinaturas de vibração pudessem ser segmentadas, foi utilizada a técnica de envelope, também conhecida como envoltória, que consiste basicamente em suavizar os dados do modelo, de forma a simplificar o modelo. Na Figura 23, o primeiro gráfico está com os dados sem a aplicação do envelope, e no segundo gráfico, está o gráfico com a técnica de envelope aplicada de forma abrangente, para suavizar os dados das operações.

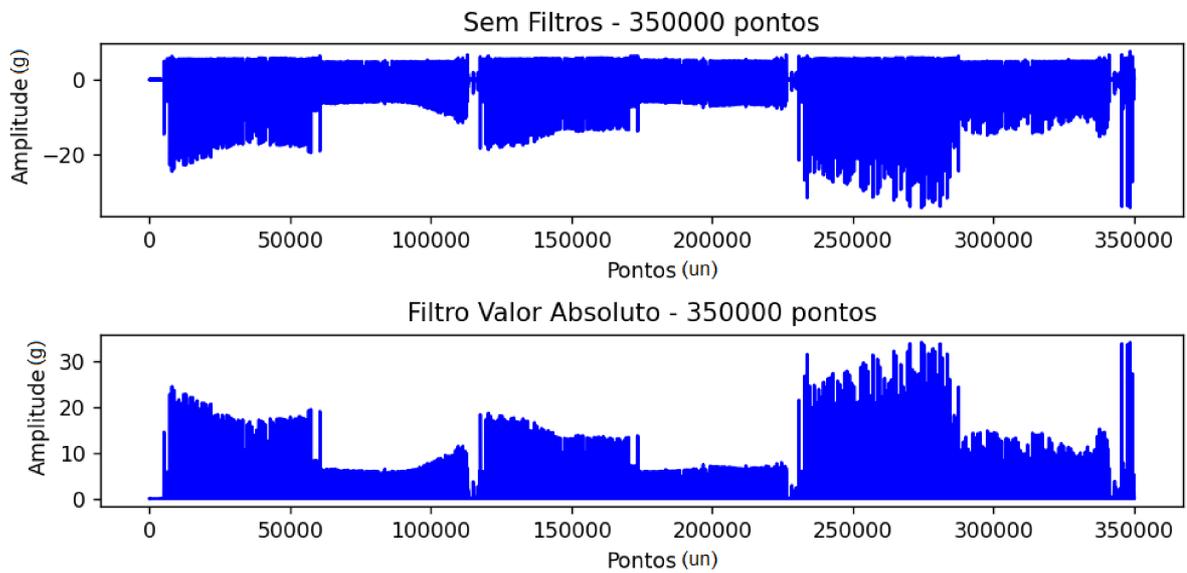


Figura 22: Comparativo dos Dados Reorganizados com Valor Absoluto
 Fonte: O Próprio Autor

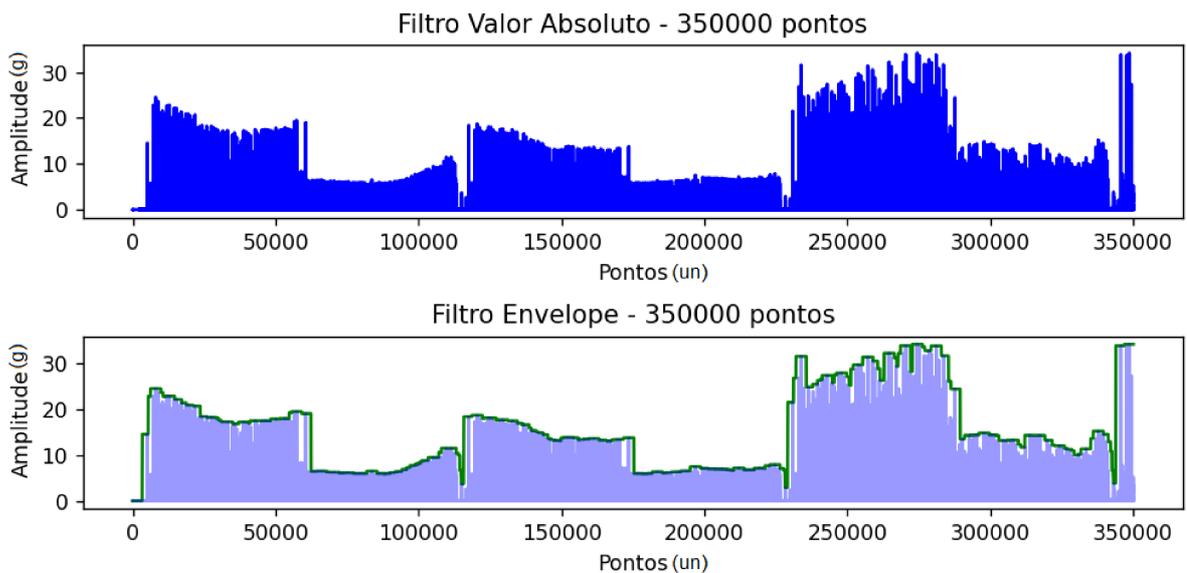


Figura 23: Comparativo do Valor Absoluto com o Envelope nas Operações
 Fonte: O Próprio Autor

5.4.3 Divisão da Amplitude do Sinal em Camadas

Esta técnica consiste basicamente em dividir a amplitude do sinal em camadas horizontais, delimitando desta forma um índice de simplificação dos dados, de acordo com a região em que o dado estiver alocado. Na Figura 24, o primeiro gráfico está com o envelope aplicado nas operações e o segundo gráfico, além do envelope aplicado, possui uma divisão por camadas que separa os dados por regiões delimitadas. Neste caso, quanto maior for a quantidade de camadas, maior será a precisão para encontrar a intersecção do envelope com a camada escolhida para segmentação. E para esta etapa do experimento, a quantidade de camadas utilizada no experimento foi trinta, sendo uma precisão suficiente para encontrar o ponto de intersecção com o filtro de envoltória.

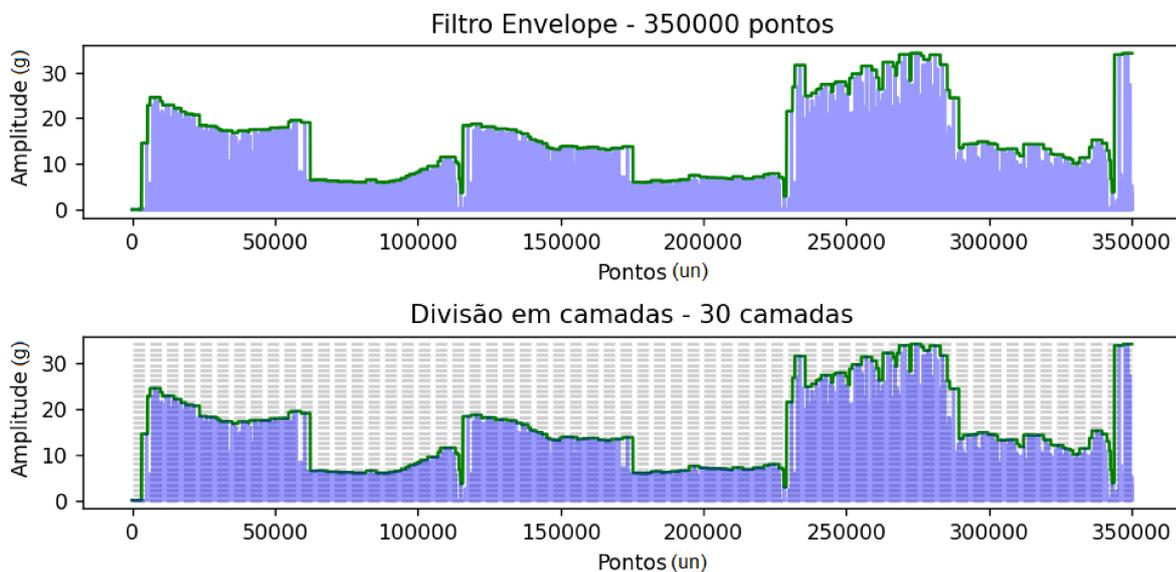


Figura 24: Comparativo do Envelope nas Operações com a Divisão da Amplitude do Sinal em Camadas
Fonte: O Próprio Autor

5.4.4 Segmentação

Para criação da segmentação, foi desenvolvido um algoritmo que gera índices para fracionar o local a ser segmentado, baseado em limites, quando determinada camada das que foram definidas é ultrapassada. A posição da camada a ser monitorada precisa ser informada (parâmetro variável), para que desta forma, os índices sejam marcados com uma linha vertical vermelha conforme Figura 25. De forma geral, os índices serão basicamente os pontos de intersecção entre o filtro do envelope com a camada escolhida.

Desta forma, dentro deste *Dataset* de dados escolhido inicialmente para o experimento, existirão 3 operações segmentadas, onde uma delas servirá de base para criação do Template de operação.

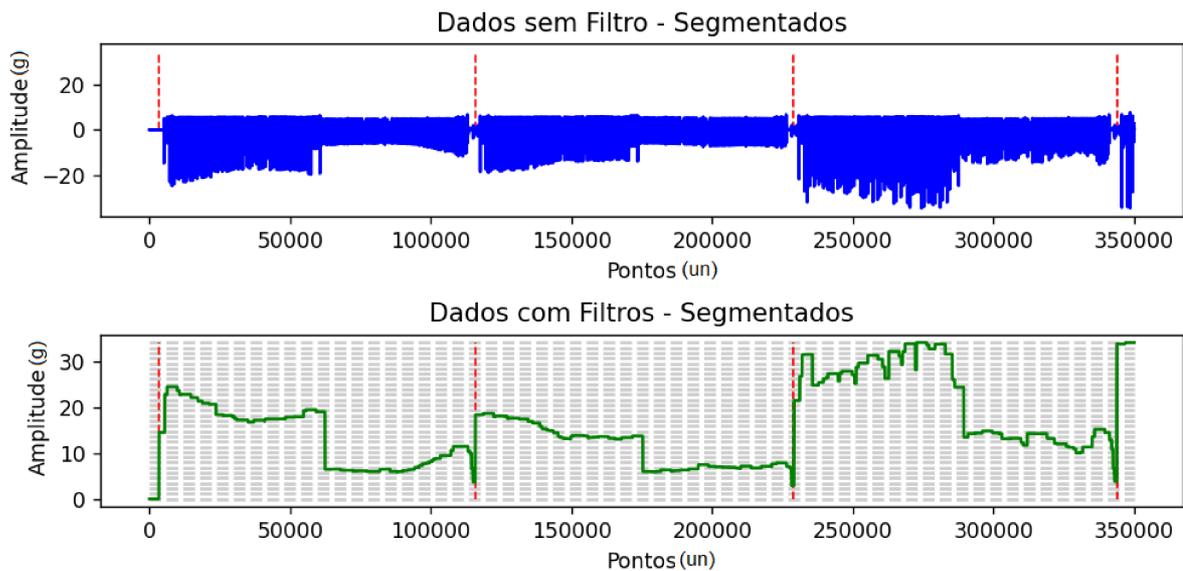


Figura 25: Segmentação dos Dados de Operações com Filtros Aplicados Sendo Transferida para os Dados sem Filtros

Fonte: O Próprio Autor

5.5 Extração das Assinaturas de Vibração - *Vibration Signature Feature Extraction*

Uma vez que a operação segmentada é escolhida como base para a criação do template de operação, o processo de pré-processamento se repete, mas desta vez com o propósito de segmentar as assinaturas de vibração que compõem a operação escolhida.

5.5.1 Valor Absoluto

Da mesma forma que os dados precisaram ser convertidos para valores absolutos no pré-processamento das operações, aqui este processo também é necessário, e requisito para utilização do filtro de envelope na sequência. Na Figura 26, estão os dados sem filtros e com filtro de valor absoluto.

5.5.2 Envelope

Nesta etapa de envelope, os parâmetros são ajustados para possibilitar a extração das assinaturas de vibração, deixando o envelope mais preciso para delimitar as assinaturas. Na Figura 27, estão os dados com valor absoluto e também com o envelope aplicado, que poderá ser melhor visível com *zoom*, na Figura 28

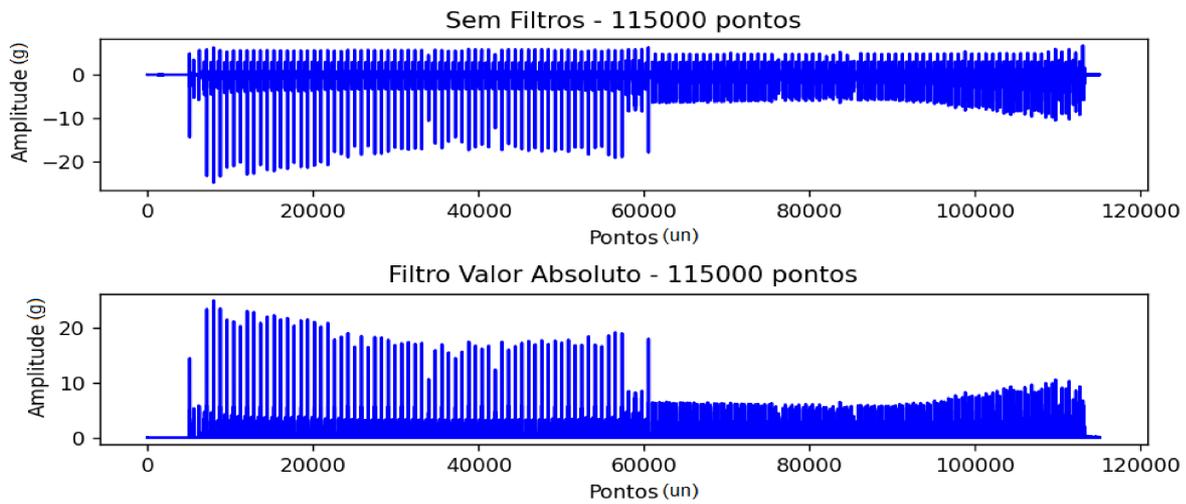


Figura 26: Comparativo da Operação Segmentada Escolhida sem Filtros e com Filtro de Valor Absoluto Aplicado

Fonte: O Próprio Autor

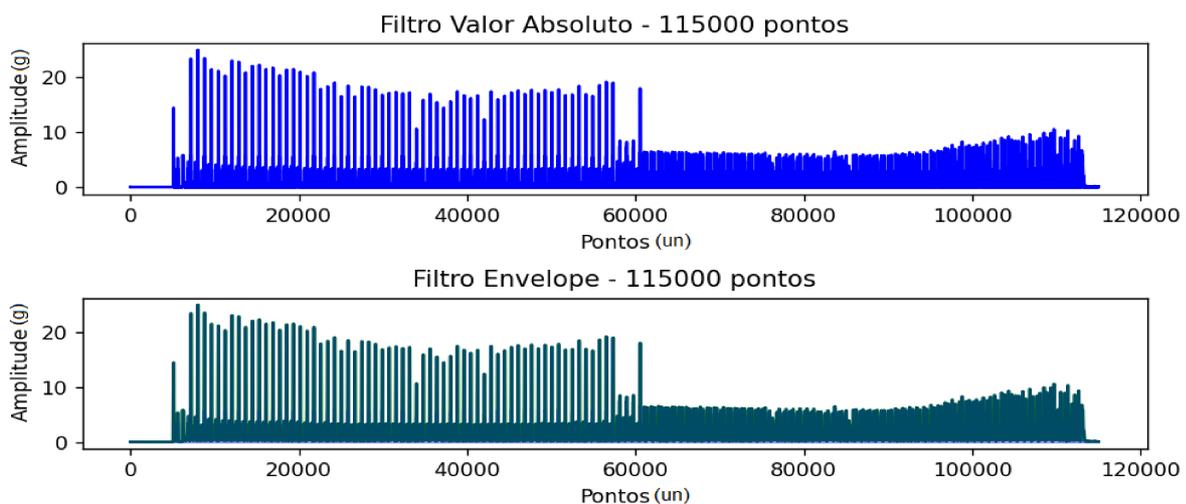


Figura 27: Comparativo do Valor Absoluto com o Envelope nas Assinaturas de Vibração

Fonte: O Próprio Autor

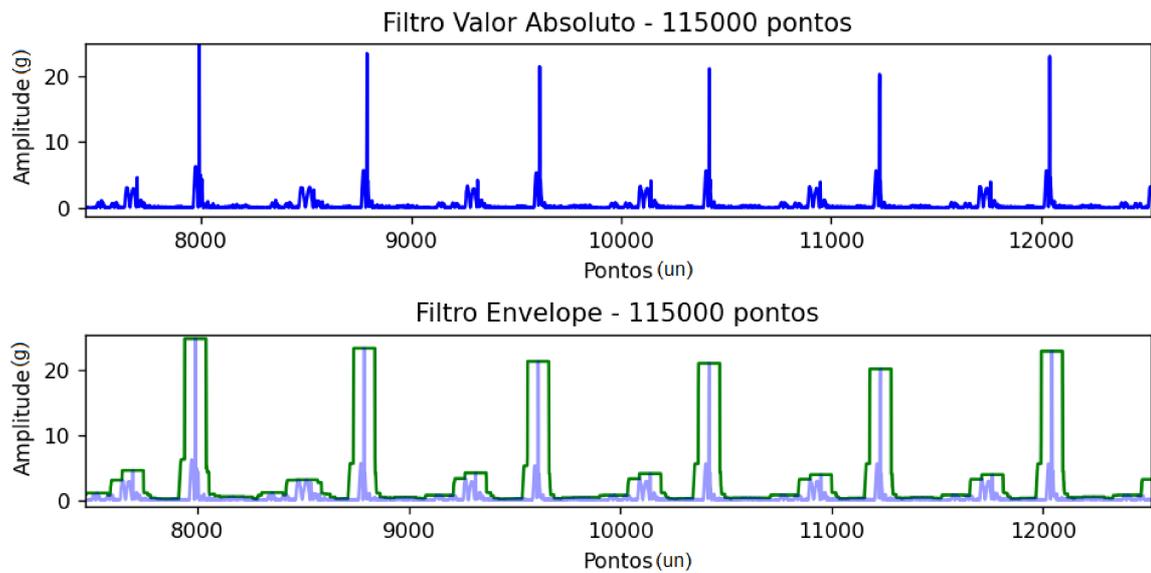


Figura 28: Comparativo com *Zoom* do Valor Absoluto com o Envelope nas Assinaturas de Vibração
Fonte: O Próprio Autor

5.5.3 Divisão da Amplitude do Sinal em Camadas

Novamente esta técnica é aplicada, com a mesma precisão definida para extração das operações (30 camadas), sendo também suficiente para esta etapa do experimento.

Na Figura 29, o primeiro gráfico está com o envelope aplicado nas assinaturas de vibração e o segundo gráfico, além do envelope aplicado, possui sua divisão por camadas que separa os dados por regiões delimitadas, que podem ser melhor visualizadas na Figura 30.

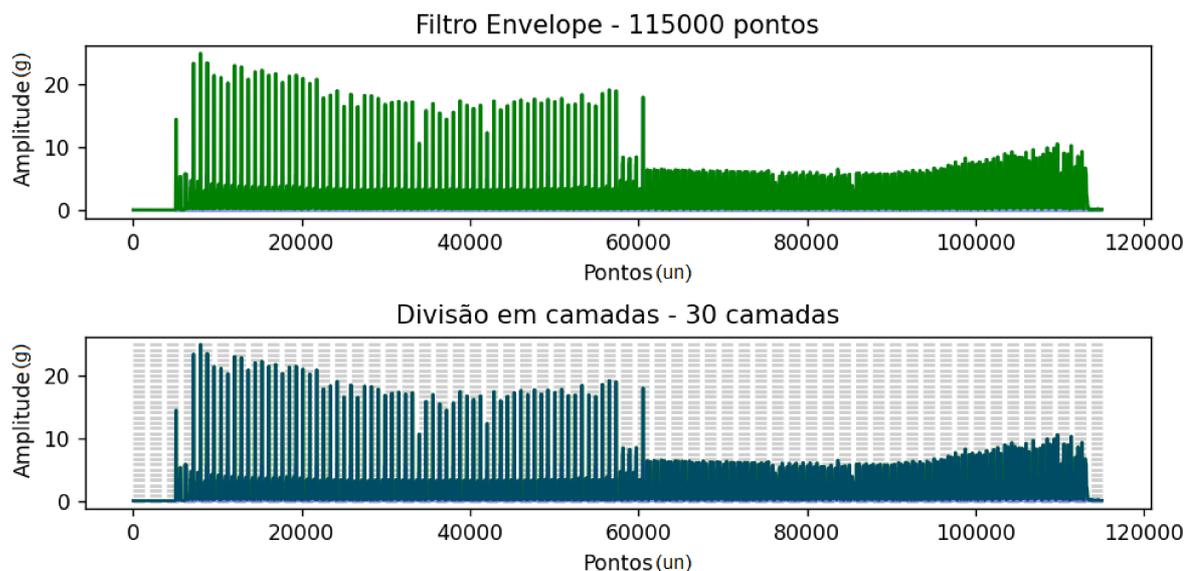


Figura 29: Definição das Camadas ao Longo da Amplitude do Sinal
Fonte: O Próprio Autor

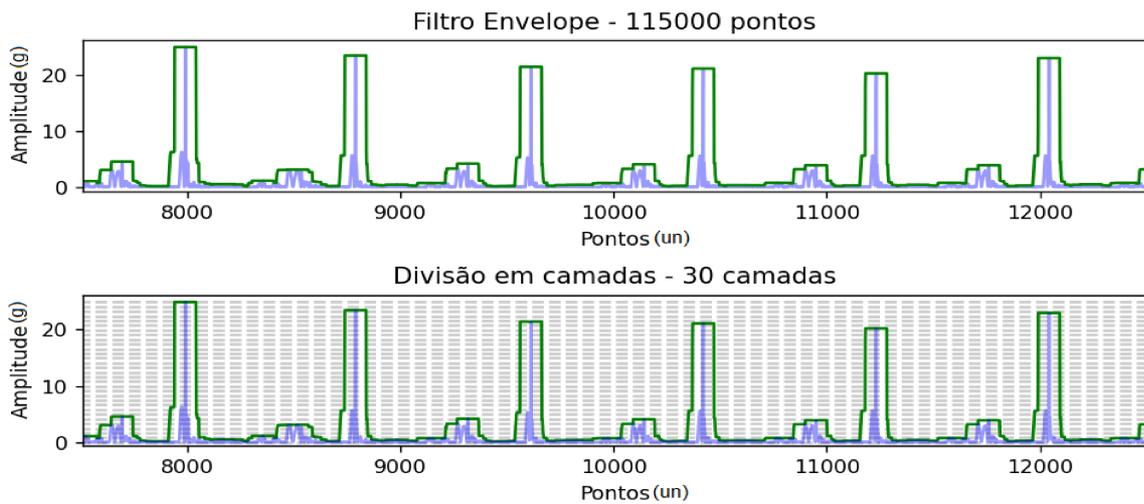


Figura 30: Definição das Camadas ao Longo da Amplitude do Sinal com Zoom
 Fonte: O Próprio Autor

5.5.4 Segmentação

Para esta segmentação que envolve a extração das assinaturas de vibração, a metodologia utilizada na extração das operações é a mesma, pois envolve encontrar o ponto de intersecção entre o filtro de envelope e a camada definida como ponto de controle. Na Figura 31, estão os dados com filtros e segmentados e também os dados sem filtros, com a sobreposição da segmentação, que podem ser melhor visualizados na Figura 32 com *zoom*.

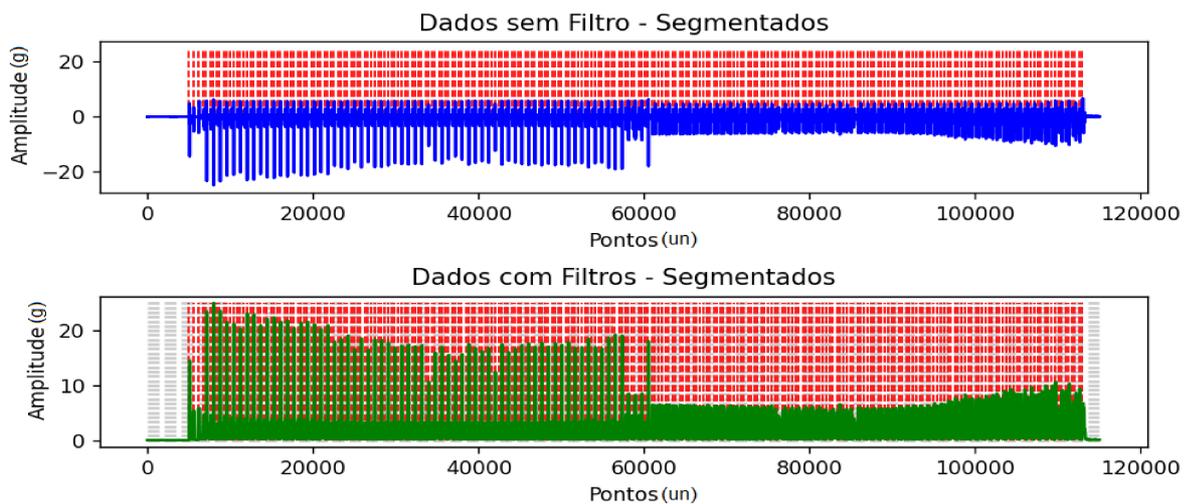


Figura 31: Segmentação das Assinaturas de Vibração com Filtros Aplicados Sendo Transferida para os Dados sem Filtros

Fonte: O Próprio Autor

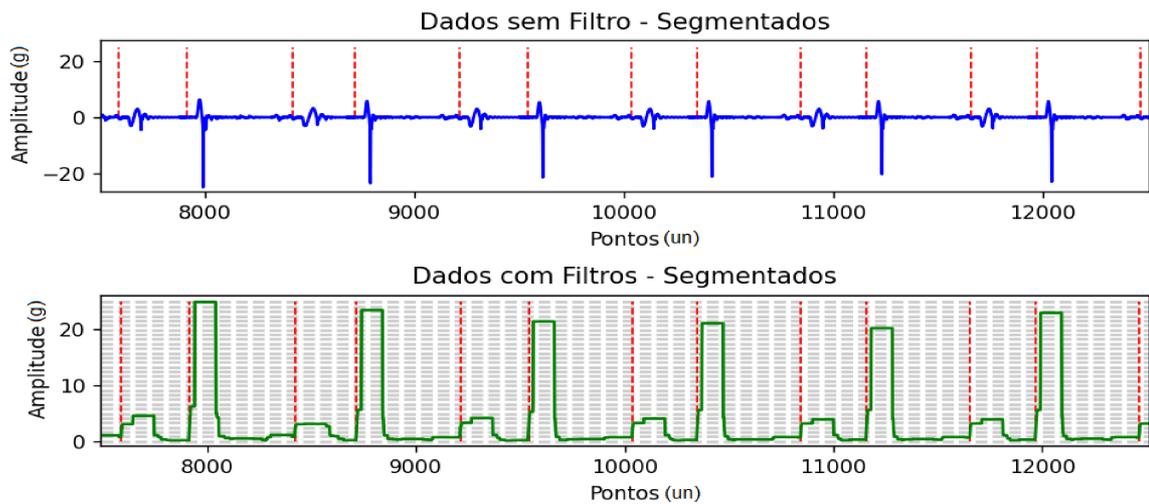


Figura 32: Segmentação das Assinaturas de Vibração com Filtros Aplicados Sendo Transferida para os Dados sem Filtros com Zoom

Fonte: O Próprio Autor

Com estes índices gerados, eles são correlacionados com os dados originais, para que a segmentação ocorra da mesma forma neles. E desta forma, os dados estão preparados para iniciar a avaliação da similaridade entre as operações.

6 RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados os resultados obtidos no experimento, que tiveram como objetivo a validação do modelo proposto neste trabalho. Inicialmente, com os dados pré-processados, é apresentado o mapeamento de uma operação segmentada, que teve como objetivo, extrair, sequenciar e quantificar as assinaturas de vibração contidas nesta operação, definida como template de operação e referência comparativa por similaridade com as demais operações.

6.1 Sequenciamento e Quantificação das Assinaturas de Vibração no Template de Operação

Com a operação segmentada em 259 assinaturas de vibração (Figura 33), nesta próxima etapa estas assinaturas de vibração serão agrupada por similaridade, utilizando como ferramenta de comparação o algoritmo DTW.

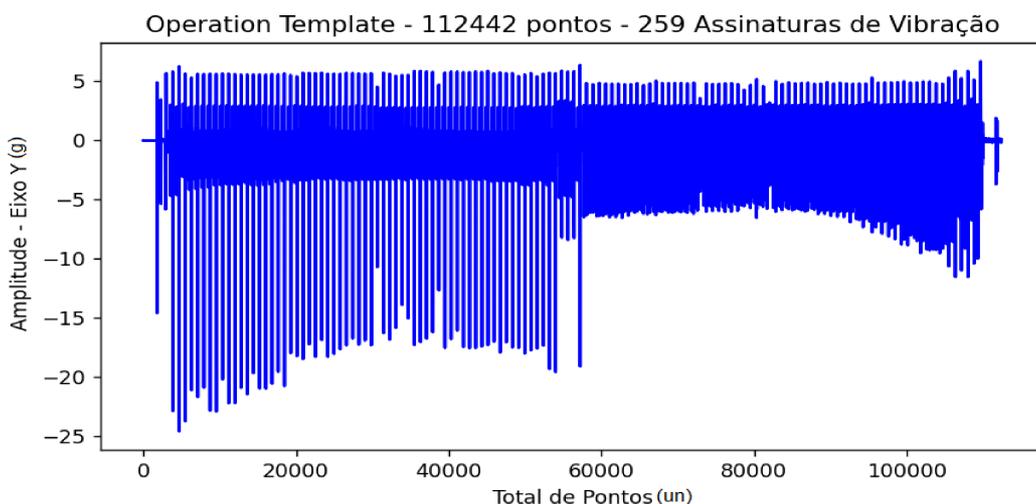


Figura 33: *Operation Template* Mapeado com 259 Assinaturas de Vibração
Fonte: O Próprio Autor

6.1.1 Avaliação da Similaridade Utilizando *Dynamic Time Warping* (DTW) entre as Assinaturas de Vibração

Considerando uma escala em que um índice de similaridade igual a **0** encontrará a maior quantidade de grupos similares, e um índice de similaridade maior que **28** encontrará a menor quantidade de grupos similares, para o estudo a seguir, foi utilizado um índice de similaridade de **17**, que possibilitou encontrar dois tipos de assinatura de vibração, conforme Figura 34.

Na Tabela 5, são apresentados os dois tipos de assinaturas de vibração encontradas, bem

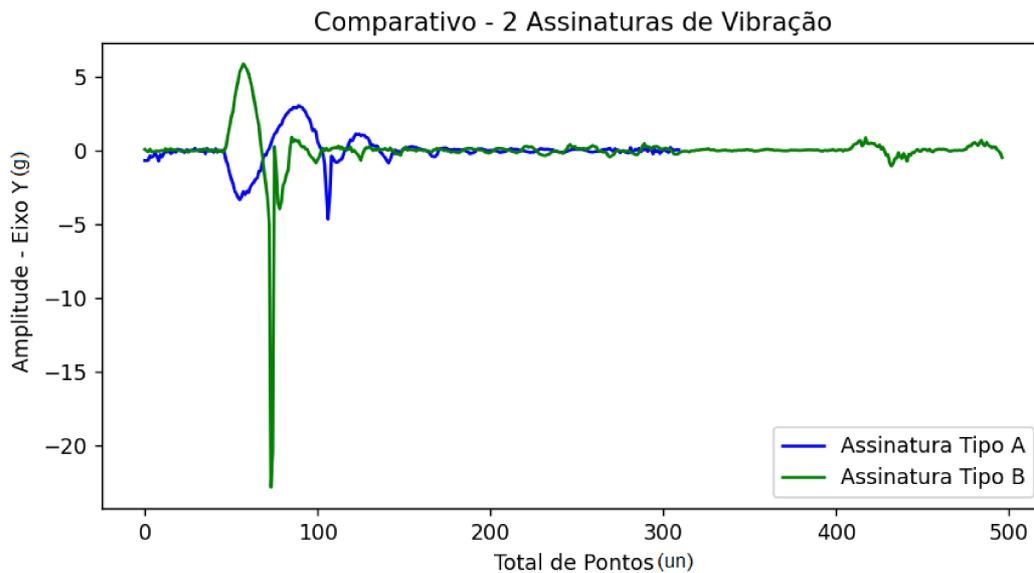


Figura 34: Comparativo dos dois Tipos de Assinaturas de Vibração Encontradas
Fonte: O Próprio Autor

como suas respectivas quantidades dentro do Template de Operação, finalizado neste momento e disponível para comparação com as demais operações que ocorrerem. Na Figura 35, é apresentada a sequência com as posições das assinaturas de vibração encontradas na operação, denominadas tipo A e tipo B.

Operation Template - Índice de Similaridade DTW = 17	
Tipo de Assinatura	Quantidade
A	197
B	62

Tabela 5: Tabela Contendo Quantidade das Assinaturas de Vibração do Template de Operação, Utilizando DTW com um Índice de Similaridade de 17.

Para comprovar a eficácia de sequenciamento e quantificação das assinaturas de vibração, foi realizada uma amostragem coletando as 5 primeiras ocorrências de cada tipo de assinatura, dentro dos seus respectivos grupos no template de operação, conforme as Figuras 36 e 37.

Sequência das Assinaturas de Vibração - Template de Operação

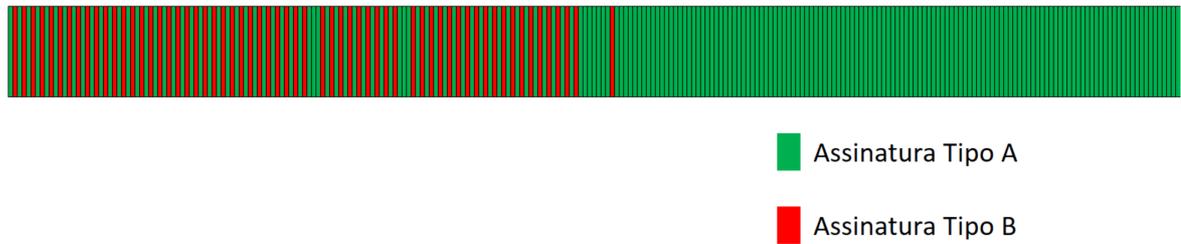


Figura 35: Sequência das assinaturas de vibração do template escolhido.

Fonte: O Próprio Autor

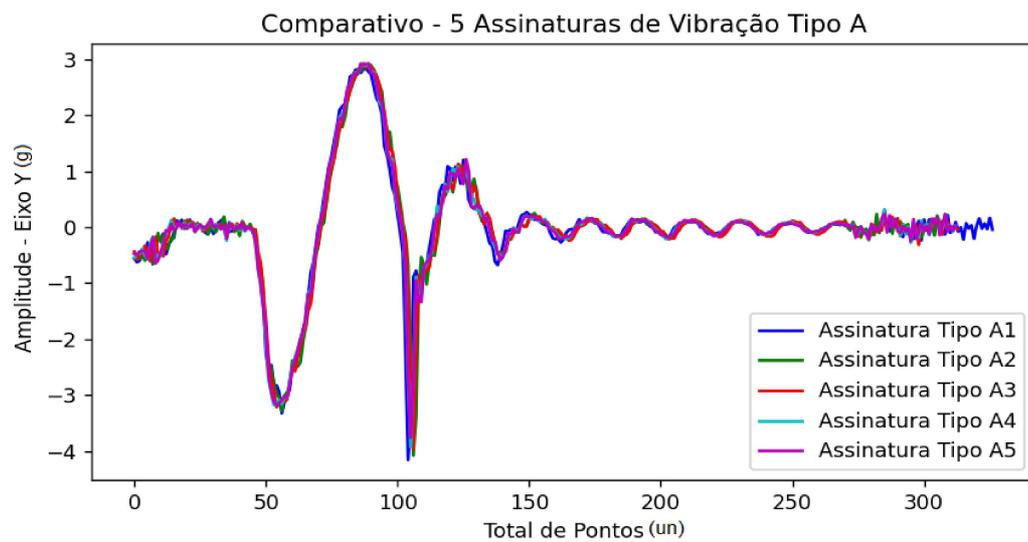


Figura 36: Comparativo das 5 primeiras posições de Assinaturas de Vibração do **Tipo A**

Fonte: O Próprio Autor

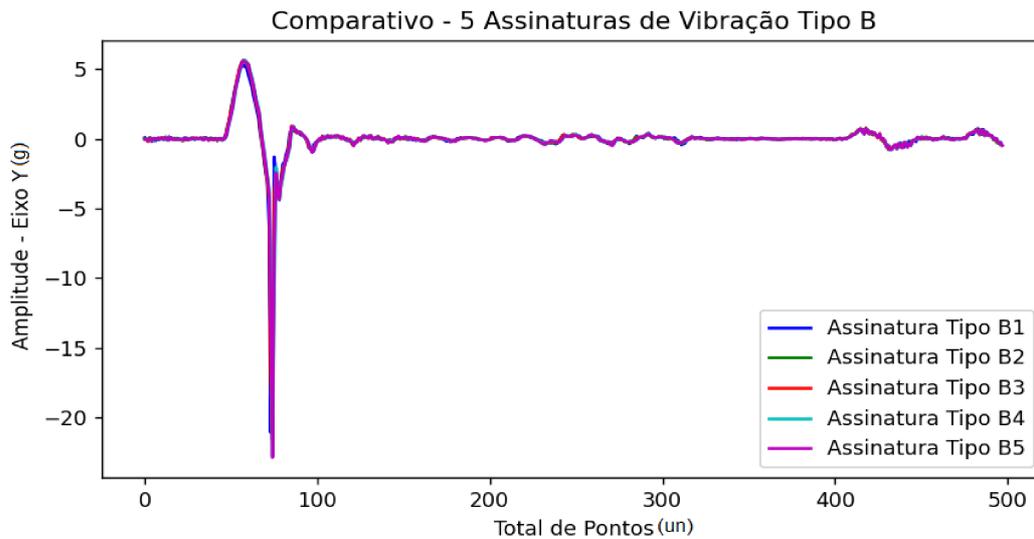


Figura 37: Comparativo das 5 primeiras posições de Assinaturas de Vibração do **Tipo B**
 Fonte: O Próprio Autor

6.2 Comparação do Template de Operação com outras Operações

Para a prova de conceito, foram escolhidas as duas operações na sequência do Template e que foram segmentadas durante o pré-processamento, para compará-las com o Template gerado inicialmente.

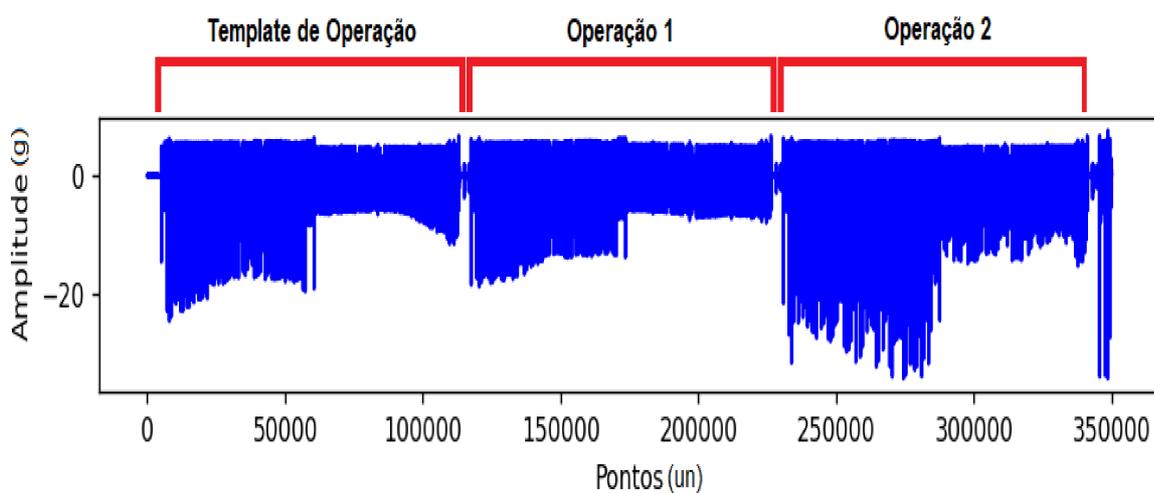


Figura 38: Seleção das operações que foram comparadas com o template de operação.
 Fonte: O Próprio Autor

6.2.1 Comparativo entre Operation Template e Operação 1

Nesta etapa de comparação, a proposta foi de procurar nas operações seguintes as duas assinaturas de vibração encontradas no template de operação, separando as assinaturas diferentes das encontradas no template, e também aquelas que estavam em posições erradas na sequência. Começando pela operação 1, conforme a Tabela 6 que apresenta as quantidades de assinaturas encontradas de cada tipo, e na Figura 39, o sequenciamento das assinaturas, que também mostra as assinaturas desconhecidas encontradas, que são diferentes das assinaturas de vibração do tipo A e B.

Operation Template <-> Operação 1 - Índice de Similaridade DTW = 17	
Tipo de Assinatura	Quantidade
A	197
B	29
Desconhecida (X)	33

Tabela 6: Tabela Comparativa Entre o Template de Operação (Operation Template) e a Operação 1 para Identificar as Assinaturas de Vibração já Catalogadas, e as que estão fora do padrão.

Sequência das Assinaturas de Vibração - Operação 1

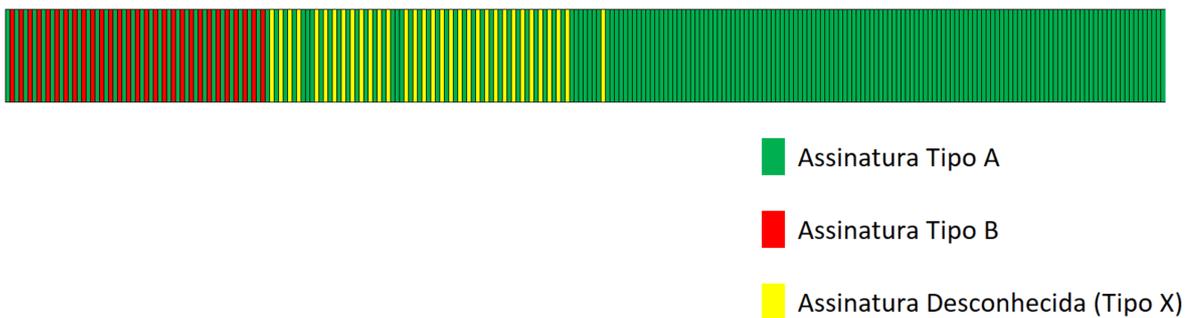


Figura 39: Sequência das assinaturas de vibração da operação 1.

Fonte: O Próprio Autor

Foi possível perceber que as mesmas **197 assinaturas de vibração do tipo A**, que foram **mapeadas no Template de Operação, estão presentes na Operação 1**. Entretanto, das 62 assinaturas de vibração do Tipo B contidas no Template de Operação, **apenas 29** foram encontradas na Operação 1. Além disso, **33 assinaturas desconhecidas** e nomeadas como "X", foram encontradas na Operação 1, mas que não fazem parte do Template de Operação.

Neste caso, isto significa que em todas as ocasiões em que estas assinaturas desconhecidas ocorreram, houve um comportamento na Operação 1 diferente do normal e do esperado

no Template de Operação, e que a partir dos próximos passos, foi possível mensurar esta diferença de comportamento entre as operações, denominada neste trabalho como um indicador de qualidade de operação.

Na Figura 40, como prova de conceito nesta parte do experimento, foi realizado um comparativo da assinatura de vibração do Tipo A que compõe o Template de Operação mapeado, com 5 assinaturas de vibração, também do Tipo A, mas da Operação 1. Na Figura 41, foi realizado o mesmo comparativo, mas desta vez com a assinatura de vibração do Tipo B.

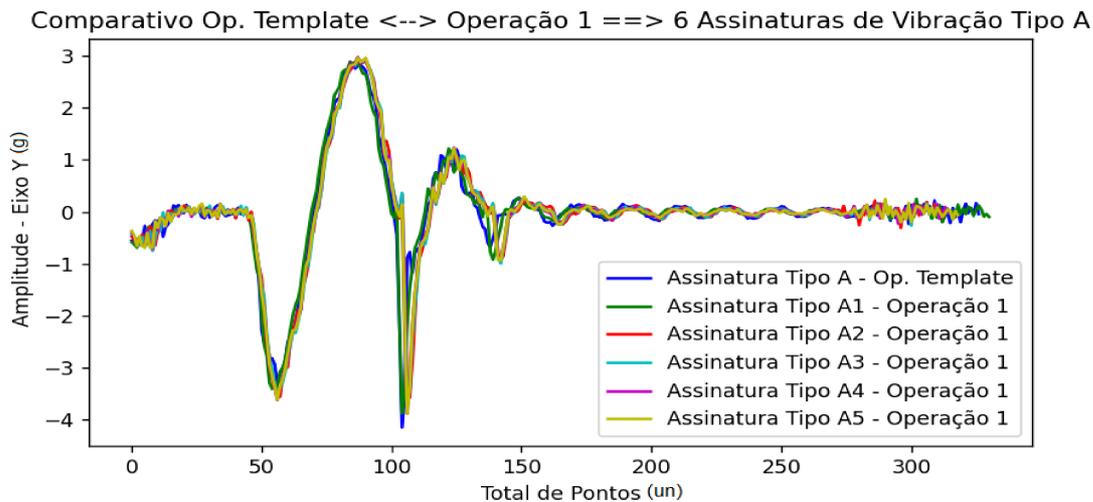


Figura 40: Comparativo da Assinatura de Vibração do Tipo A do Template de Operação, com 5 Assinaturas de Vibração do Tipo A da Operação 1.

Fonte: O Próprio Autor

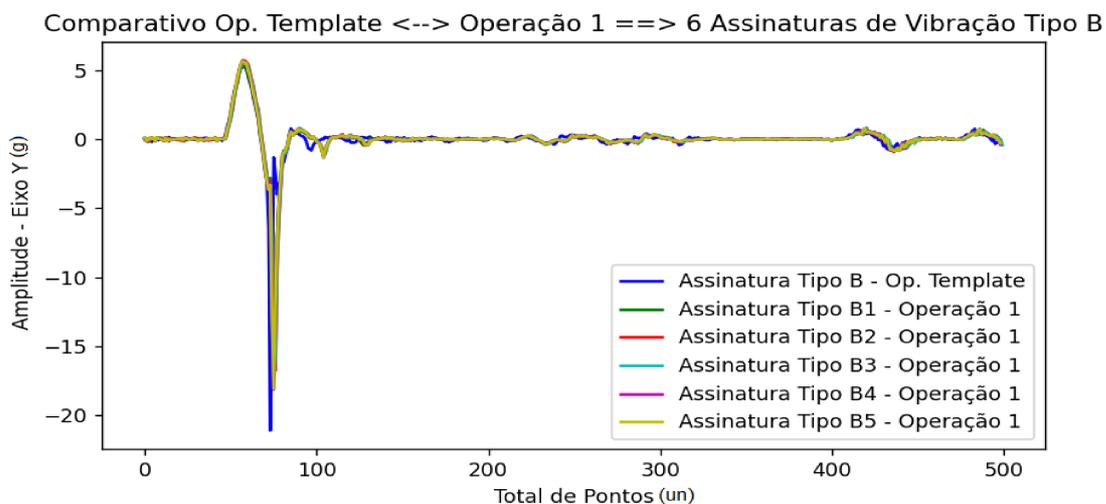


Figura 41: Comparativo da Assinatura de Vibração do Tipo B do Template de Operação, com 5 Assinaturas de Vibração do Tipo B da Operação 1.

Fonte: O Próprio Autor

6.2.2 Operation Template \leftrightarrow Operação 2

Da mesma forma que na comparação anterior, aqui é realizada a comparação entre o Template de Operação e desta vez, a Operação 2. Nesta comparação, foram encontradas **190** das 197 assinaturas de vibração do **Tipo A**, **59** das 62 assinaturas de vibração do **Tipo B**, e **10** assinaturas **desconhecidas** e nomeadas como "X", que não fazem parte do Template de Operação, conforme Tabela 7, apresentando as quantidades encontradas por tipo e na Figura 42, com o sequenciamento das assinaturas.

Operation Template \leftrightarrow Operação 2 - Índice de Similaridade DTW = 17	
Tipo de Assinatura	Quantidade
A	190
B	59
Desconhecida (X)	10

Tabela 7: Tabela Comparativa Entre o Template de Operação (Operation Template) e a Operação 2 para Identificar as Assinaturas de Vibração já Catalogadas, e as que estão fora do padrão.

Sequência das Assinaturas de Vibração - Operação 2

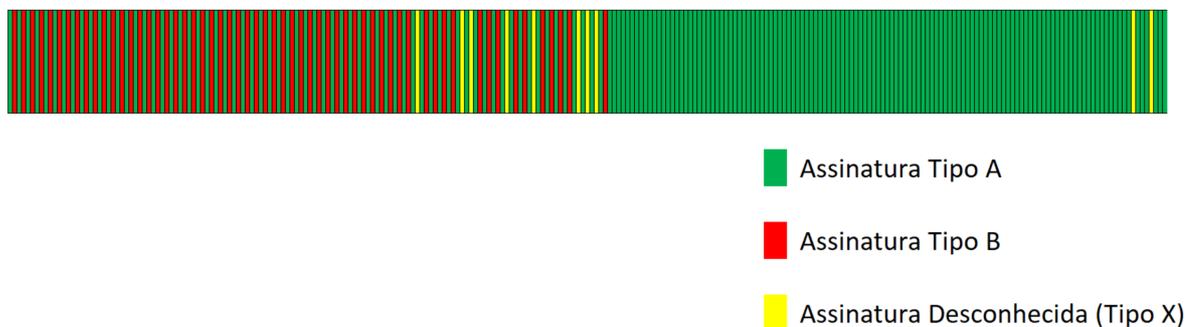


Figura 42: Sequência das assinaturas de vibração da operação 2.

Fonte: O Próprio Autor

Da mesma forma que na Operação 1, na Operação 2 também significa que em todas as ocasiões em que estas assinaturas desconhecidas ocorreram, houve um comportamento na Operação 2 diferente do normal e do esperado no Template de Operação, e como já dito anteriormente, a partir dos próximos passos, foi possível mensurar esta diferença de comportamento entre as operações, para gerar o índice de qualidade de operação.

Na Figura 43, foi realizado como prova de conceito um outro comparativo da assinatura de vibração do Tipo A que compõe o Template de Operação mapeado, com 5 assinaturas de vibração, também do Tipo A, mas da Operação 2. O mesmo ocorre na Figura 44, mas desta vez com assinaturas de vibração do Tipo B.

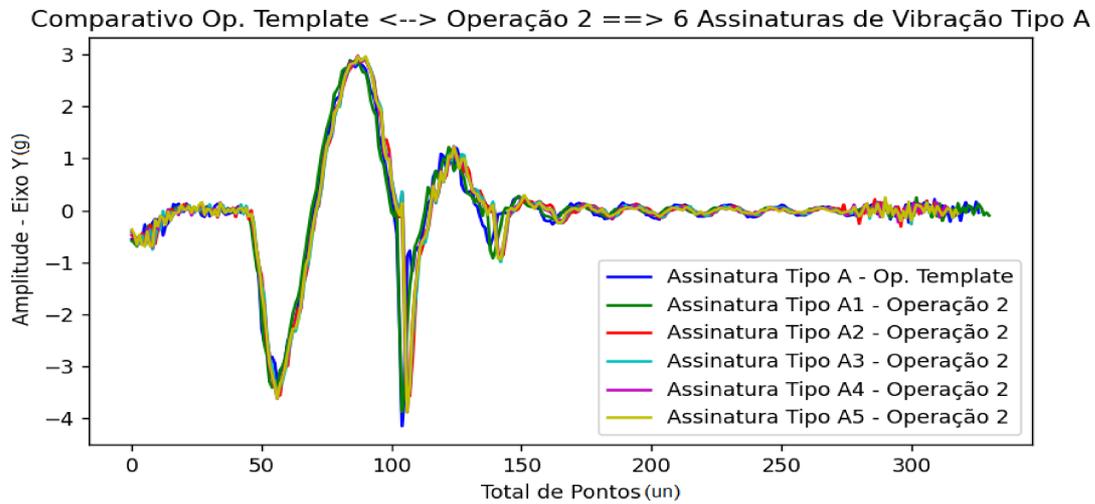


Figura 43: Comparativo da Assinatura de Vibração do Tipo A do Template de Operação, com 5 Assinaturas de Vibração do Tipo A da Operação 2.

Fonte: O Próprio Autor

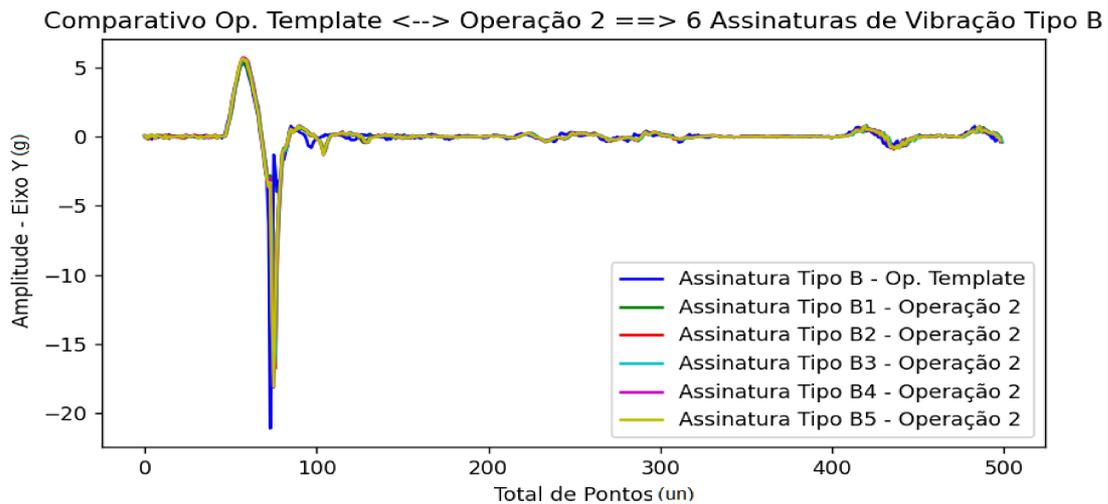


Figura 44: Comparativo da Assinatura de Vibração do Tipo B do Template de Operação, com 5 Assinaturas de Vibração do Tipo B da Operação 2.

Fonte: O Próprio Autor

Na Tabela 8, está o comparativo das quantidades encontradas das assinaturas de vibração entre as operações, bem como as assinaturas desconhecidas, que não fazem parte do Template de Operação.

Operation Template <-> Operação1, Operação 2			
Tipos	Template de Operação	Operação 1	Operação 2
A	197	197	190
B	62	29	59
Desconhecida (X)	-	33	10

Tabela 8: Tabela Comparativa Final entre o Template de Operação e as Operações 1 e 2, apresentando as quantidades de assinaturas de vibração encontradas em cada tipo de assinatura.

6.3 Gerando o Índice de Qualidade de Operação

Para se calcular o índice de qualidade de uma operação, não basta apenas saber a quantidade de cada tipo de assinatura de vibração. É necessário também conhecer o sequenciamento de cada uma das assinaturas, para que além da quantidade, se verifique também sua posição. Ou seja, para cada tipo de assinatura de vibração que compõe o sequenciamento do template de operação, espera-se o mesmo tipo de assinatura na mesma posição quando comparado com uma outra operação em que se deseja avaliar a sua qualidade. Na Figura 45, é apresentado o comparativo dos tipos de assinaturas de vibração encontradas, em suas respectivas posições dentro de cada uma das operações, sendo o template de operação a base comparativa para as demais operações que foram avaliadas. E nesta comparação, foram evidenciadas assinaturas do Tipo A, assinaturas do Tipo B, assinaturas desconhecidas (que não fazem parte do template de operação) e assinaturas conhecidas mas em posições erradas e que não seguiram o padrão de sequenciamento esperado.

De forma geral, após o mapeamento das operações, este comparativo avalia o seguinte cenário: espera-se que a assinatura de vibração alocada na primeira posição do template de operação seja do mesmo tipo que a assinatura de vibração alocada na primeira posição das operações sendo avaliadas (neste caso do experimento, Operação 1 e Operação 2), realizando recursivamente esta comparação com todas as 259 assinaturas de vibração que compõem uma operação.

Comparativo das Posições de Todas as Assinaturas de Vibração



Figura 45: Comparativo das Posições das Assinaturas de Vibração em Suas Respectivas Operações.

Fonte: O Próprio Autor

De posse destas informações, já é possível calcular a qualidade de cada uma das operações, quando comparadas com o template de operação. Para isto, considerando que o template de operação possui 100% de qualidade de operação, considerando também que uma operação possui um total de 259 assinaturas de vibração, e que as demais operações sendo comparadas precisam acompanhar este padrão de qualidade definida, uma fórmula precisa ser aplicada. E nesta fórmula, para calcular a qualidade (Q) da operação, foi utilizada a quantidade de assinaturas que tiveram os requisitos atendidos de tipo e posição (QtdRA), que pode ser calculado subtraindo o total de assinaturas diferentes e fora de posição, do total de assinaturas de vibração da operação (QtdTA) e que também faz parte da equação, conforme segue:

$$Q = \frac{QtdRA \times 100}{QtdTA}$$

Uma tabela completa e geral contendo o comparativo das diferenças entre o template e as duas operações pode ser consultada no **Apêndice D**.

Na Tabela 9, estão as diferenças das assinaturas de vibração entre o Template de Operação e a Operação 1, seja por Tipo de Assinatura, ou sequência em que ela se encontra, totalizando **33 assinaturas diferentes**, das 259 do Template de Operação, **gerando um Índice de Qualidade de Operação de 87,25%** quando comparado com o template de operação.

Sequência na Operação	Assinatura Esperada	Assinatura Encontrada
59	B	Desconhecida(X)
61	B	Desconhecida(X)
63	B	Desconhecida(X)
65	B	Desconhecida(X)
69	B	Desconhecida(X)
71	B	Desconhecida(X)
73	B	Desconhecida(X)
75	B	Desconhecida(X)
77	B	Desconhecida(X)
79	B	Desconhecida(X)
81	B	Desconhecida(X)
83	B	Desconhecida(X)
85	B	Desconhecida(X)

Table 9 continued from previous page

Sequência na Operação	Assinatura Esperada	Assinatura Encontrada
89	B	Desconhecida(X)
91	B	Desconhecida(X)
93	B	Desconhecida(X)
95	B	Desconhecida(X)
97	B	Desconhecida(X)
99	B	Desconhecida(X)
101	B	Desconhecida(X)
103	B	Desconhecida(X)
105	B	Desconhecida(X)
107	B	Desconhecida(X)
109	B	Desconhecida(X)
111	B	Desconhecida(X)
113	B	Desconhecida(X)
115	B	Desconhecida(X)
117	B	Desconhecida(X)
119	B	Desconhecida(X)
121	B	Desconhecida(X)
123	B	Desconhecida(X)
125	B	Desconhecida(X)
133	B	Desconhecida(X)
TOTAL		33 assinaturas não correspondentes

Tabela 9: Tabela Comparativa das Diferenças entre o Template de Operação e a Operação 1

Na Tabela 10, estão as diferenças das assinaturas de vibração entre o Template de Operação e a Operação 2, seja por Tipo de Assinatura, ou sequência em que ela se encontra, totalizando **10 assinaturas diferentes e 2 assinaturas na posição errada**, das 259 do Template de Operação. O ponto a destacar aqui, é que, diferente da Operação 1, na Operação 2, além de encontrar

assinaturas diferentes dos Tipos A e B, algumas sequências estavam com os Tipos na posição errada, comprovando a importância de também observar o sequenciamento das assinaturas. Neste caso, com base nestas informações, o **Índice de Qualidade gerado foi de 95,36%**.

Sequência na Operação	Assinatura Esperada	Assinaturas Encontrada
67	A	B
87	A	B
91	B	Desconhecida(X)
101	B	Desconhecida(X)
103	B	Desconhecida(X)
111	B	Desconhecida(X)
117	B	Desconhecida(X)
127	A	Desconhecida(X)
129	A	Desconhecida(X)
131	A	Desconhecida(X)
251	A	Desconhecida(X)
255	A	Desconhecida(X)
TOTAL		12 assinaturas não correspondentes

Tabela 10: Tabela Comparativa das Diferenças entre o Template de Operação e a Operação 2

Na Tabela 11, está o resultado final deste experimento, apresentando os Índices de Qualidade de Operação obtidos das 2 operações avaliadas em comparação com o template de operação definido, que foram obtidos através da aplicação da fórmula apresentada anteriormente, que leva em consideração o tipo e a quantidade de assinaturas encontradas, bem como suas posições dentro das operações.

Índice de Qualidade de Operação	
Template de Operação	100%
Operação 1	87,25%
Operação 2	95,36%

Tabela 11: Tabela Comparativa dos Índices de Qualidade de Operação Observados.

6.4 Discussão dos Resultados

Os resultados obtidos com este experimento comprovaram que é possível sim avaliar o comportamento esperado de uma operação mapeada nas operações subsequentes, definindo assim um padrão de qualidade esperado para que cada operação atinja. Desta forma, ao invés de focar na predição de falhas, visto que para prever uma falha ela precisa ter ao menos uma ocorrência para posteriormente ser monitorada, os resultados aqui focam em um monitoramento de um padrão de normalidade do sistema como um todo, utilizando como referência aquelas operações que tiveram sucesso ou ao menos o padrão mínimo de qualidade exigida para ser realizada e garantir a conclusão com sucesso daquela etapa na cadeia de manufatura de produtos.

Com base nos seis trabalhos relacionados apresentados no Capítulo 3, apesar de todos se aproximarem das técnicas de processamento aplicadas, apenas dois deles utilizam elas no contexto de máquinas do tipo *wirebonders*, sendo uma delas com foco em dados elétricos e uma delas com foco em dados mecânicos (FENG et al., 2011; ZHANG; LING, 2003). Em ambos os casos, o foco das pesquisas foi de avaliar especificamente a qualidade da solda realizada pelo equipamento, que neste caso era do tipo *wirebonder*. Entretanto, em ambos os modelos o foco principal foi o de predição de falhas, e como dito anteriormente, neste método de monitoramento se faz necessário que a falha ocorra ao menos uma vez, para que desta forma possa ser monitorada caso ocorra novamente, criando uma dependência no sistema. Além disso, em nenhum destes modelos propostos se procurou conhecer e mapear as operações que agrupam as assinaturas de vibração, sendo uma outra forma de realizar comparações de similaridades (padrões de normalidade), ao invés de apenas comparar assinaturas de vibrações individuais e sem relação entre grupos.

Após a implementação deste experimento, é possível destacar alguns fatores positivos neste trabalho:

- A base de dados de templates de operação poderá ser criada de acordo com as regras de negócio de cada empresa que desejar implementar o modelo de monitoramento. Elas poderão ser classificadas, neste momento, por tipo de *wirebonder* e tipo de operação.
- O modelo pode ser expandido a outros tipos de equipamentos e máquinas operatrizes que realizam em suas operações movimentos nos 3 eixos de um sistema de coordenadas tridimensional.
- Possibilidade de implementação para coleta de dados e processamento em tempo real (sistema *online*), levando em consideração a arquitetura da infraestrutura para suportar este ambiente.
- Com o sistema *online*, um único indicador de informação por equipamento é o suficiente para monitorar a saúde de todo o parque fabril, e disparar alertas quando necessário.

Foi possível identificar também algumas limitações e fatores dificultantes para colocar o sistema em prática:

- Arquitetura para implementação extremamente complexa, exigindo conhecimentos multidisciplinares em infraestrutura, banco de dados e *frameworks* de programação para concepção do modelo.
- Devido à taxa de amostragem ser elevada, o custo computacional para realizar todas as etapas de processamento também é elevado, podendo levar alguns minutos para processar uma única operação, exigindo um *hardware* de alto desempenho, para realizar as atividades.
- Após conversões e armazenamento em banco de dados, gera-se uma média de 40Gb de informações por dia.

E para contornar estes fatores sugere-se o seguinte:

- Ao invés de uma única pessoa realizar esta implementação, as atividades poderão ser divididas em mais pessoas.
- O recomendado aqui seria a utilização de um *cluster* para gerar os resultados, ou pelo menos deixar eles pré-processados.
- Após os dados serem processados, e suas informações serem extraídas, pensando em escalabilidade, o recomendado é também clusterizar o banco de dados com rotinas de balanceamento de carga caso necessite armazenar históricos, ou liberar este espaço em disco.

7 CONCLUSÃO

Através do presente trabalho foi possível apresentar um modelo de processamento de séries temporais capaz de gerar um índice escalar de qualidade de operação utilizando dados de vibração do equipamento em funcionamento. Partindo desta premissa, este modelo tem por finalidade monitorar a saúde de operação do equipamento sendo avaliado, de forma a mapear inicialmente aquelas operações que estão dentro dos padrões de qualidade esperados, para que posteriormente sirvam como base comparativa para as demais operações, gerando um índice escalar que poderá ser medido sempre que houver a necessidade de monitorar quaisquer operações. Desta forma, sempre que as operações subsequentes ultrapassarem o limite de qualidade definido (baseado em regras de negócio), isto indicará que possíveis falhas poderão ocorrer naquele equipamento, caso alguma ação não seja tomada, como por exemplo, uma manutenção preventiva. Sendo assim, ao invés de ocorrer um monitoramento de predição de falhas, a proposta foi propor um sistema de monitoramento de predição da normalidade, visto que seria mais lógico mapear operações que já são conhecidas e ocorrem com maior frequência, para posteriormente calcular e monitorar esta queda no índice responsável pelos padrões de qualidade, do que aguardar falhas ocorrerem para sinalizá-las e monitorá-las. Sendo assim, com este experimento, foi possível responder a questão de pesquisa, apontada na introdução deste trabalho.

7.1 Contribuições

Como contribuição principal para a comunidade científica e também para a empresa parceira da universidade, pode-se destacar o modelo para geração do índice escalar de qualidade da operação avaliada, em máquinas do tipo *wirebonders*, trazendo a abordagem de predição de normalidade, ao invés da já conhecida predição de falha. Além disso, é proposta a possibilidade de criar um modelo de repositório contendo operações catalogadas de máquinas *wirebonders* que são consideradas dentro dos padrões de qualidade esperados e de acordo com as regras de negócio definidas. Diante disso e com base nos resultados obtidos, um artigo científico está em vias de publicação.

Agora, como contribuição tecnológica deste trabalho, pode-se destacar o desenvolvimento de uma metodologia específica para extração de templates (*feature extraction*) de operação em máquinas *wirebonders*, que poderá ser estendida a outros tipos de maquinários, bem como na aplicação de um sistema supervisionado ou não supervisionado. Esta metodologia, como já dito anteriormente, sugere uma outra abordagem de monitoramento, que envolve outros parâmetros a serem considerados, como o tipo e a quantidade de vezes que uma assinatura de vibração ocorre dentro de uma operação de trabalho, bem como suas respectivas posições dentro desta operação, expandindo a capacidade de identificar não só os tipos de assinaturas de vibração que ocorrem, mas também os respectivos tipos de operações executadas.

E para finalizar, apesar de ser um protótipo para ser implementado de modo *offline*, suas ca-

racterísticas possibilitarão que ele também possa ser implementado *online*, tendo a capacidade de gerar novos templates de operações, em tempo de execução das mesmas.

7.2 Trabalhos Futuros

Aqui são destacados alguns trabalhos futuros que poderão expandir ainda mais o campo de pesquisa e continuidade deste trabalho:

- **Avaliação do impacto na mudança de posição do sensor que realiza a coleta de dados:** Apesar do posicionamento dos sensores não ser levado em consideração neste trabalho, um estudo pode ser direcionado se para cada tipo de equipamento monitorado, existe uma posição ideal para coleta dos dados de vibração.
- **Substituição do DTW por outras metodologias para avaliação de similaridade das assinaturas de vibração:** Neste estudo, foi utilizada para avaliação da similaridade das assinaturas de vibração a técnica de DTW, mas devido ao fato do modelo deste trabalho ser modularizado, é possível utilizar outras técnicas no lugar da DTW, e inclusive compará-las entre si para avaliação do custo computacional por exemplo, que neste trabalho foi um fator dificultante, e poderia ser melhor explorado para melhorar o desempenho do modelo.
- **Correlação dos dados de vibração com os chips sendo soldados:** Neste trabalho, foram utilizados apenas os dados de vibração coletados pelos sensores. Nesta linha de pesquisa, poderia tentar correlacionar as operações extraídas e comparadas com outras informações como por exemplo o tipo de microchip sendo soldado, a quantidade e sequência em que eles são manufaturados, etc.
- **Implementação do modelo proposto em outros tipos de equipamentos que não sejam máquinas *wirebonders*:** Apesar do modelo proposto neste trabalho ser aplicado em máquinas do tipo *wirebonders*, e contanto que os devidos parâmetros sejam ajustados, ele poderá ser aderente a outros tipos de equipamentos que realizam deslocamento provocado nos três eixos do espaço cartesiano tridimensional (X, Y e Z), restando avaliar se os resultados obtidos serão satisfatórios ou não.
- **Adequação do modelo para implementação *online*:** Nesta linha de pesquisa, contanto que seja possível melhorar o custo computacional, o modelo proposto nesta pesquisa poderia ser readequado para uma proposta de monitoramento em tempo real (*online*).

REFERÊNCIAS

- ANACONDA distribution. <<https://www.anaconda.com/>>. Acessado em 17 jun. 2019.
- ANTTILA, J.; JUSSILA, K. Understanding quality–conceptualization of the fundamental concepts of quality. **International Journal of Quality and Service Sciences**, [S.l.], 2017.
- BAYER, M. Sqlalchemy. In: BROWN, A.; WILSON, G. (Ed.). **The architecture of open source applications volume ii: structure, scale, and a few more fearless hacks**. [S.l.]: aosabook.org, 2012.
- CHEN, F. et al. Data mining for the internet of things: literature review and challenges. **International Journal of Distributed Sensor Networks**, [S.l.], v. 11, n. 8, p. 431047, 2015.
- CHEN, J. et al. Compound faults detection of rotating machinery using improved adaptive redundant lifting multiwavelet. **Mechanical Systems and Signal Processing**, [S.l.], v. 38, n. 1, p. 36–54, 2013.
- CHEN, M.; MAO, S.; LIU, Y. Big data: a survey. **Mobile networks and applications**, [S.l.], v. 19, n. 2, p. 171–209, 2014.
- CHRISTOPHER, S.; MDRASEDUL, I. M assad-uz z, mohammad hr. a comprehensive study on emg feature extraction and classifiers. *op acc j bio eng & bio sci* 1 (1)-2018. **OAJBEB. MS. ID**, [S.l.], v. 104, 2018.
- DEB, C. et al. A review on time series forecasting techniques for building energy consumption. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 74, p. 902–924, 2017.
- DI MARTINO, S. et al. Industrial internet of things: persistence for time series with nosql databases. In: IEEE 28TH INTERNATIONAL CONFERENCE ON ENABLING TECHNOLOGIES: INFRASTRUCTURE FOR COLLABORATIVE ENTERPRISES (WETICE), 2019., 2019. **Anais...** [S.l.: s.n.], 2019. p. 340–345.
- DIEZ-OLIVAN, A. et al. Data fusion and machine learning for industrial prognosis: trends and perspectives towards industry 4.0. **Information Fusion**, [S.l.], v. 50, p. 92–111, 2019.
- D’EMILIA, G.; GASPARI, A.; NATALE, E. Integration of model and sensor data for smart condition monitoring in mechatronic devices. In: II WORKSHOP ON METROLOGY FOR INDUSTRY 4.0 AND IOT (METROIND4. 0&IOT), 2019., 2019. **Anais...** [S.l.: s.n.], 2019. p. 365–370.
- FATALIYEV, T. K.; MEHDIYEV, S. A. Analysis and new approaches to the solution of problems of operation of oil and gas complex as cyber-physical system. **International Journal of Information Technology and Computer Science (IJITCS)**, [S.l.], v. 10, n. 11, p. 67–76, 2018.
- FENG, W. Vibration characteristic researching of capillary of ultrasonic wire bonding. In: COMPUTER MODELLING AND NEW TECHNOLOGIES, 2014. **Anais...** [S.l.: s.n.], 2014.

FENG, W. et al. Online quality evaluation of ultrasonic wire bonding using input electrical signal of piezoelectric transducer. In: WRI WORLD CONGRESS ON COMPUTER SCIENCE AND INFORMATION ENGINEERING, 2009., 2009. **Anais...** [S.l.: s.n.], 2009. v. 5, p. 462–466.

FENG, W. et al. Wire bonding quality monitoring via refining process of electrical signal from ultrasonic generator. **Mechanical systems and signal processing**, [S.l.], v. 25, n. 3, p. 884–900, 2011.

FISCHER, A. C. et al. Unconventional applications of wire bonding create opportunities for microsystem integration. **Journal of Micromechanics and Microengineering**, [S.l.], v. 23, n. 8, p. 083001, set 2019.

GANGA, D.; RAMACHANDRAN, V. Iot-based vibration analytics of electrical machines. **IEEE Internet of Things Journal**, [S.l.], v. 5, n. 6, p. 4538–4549, 2018.

GANZ, F. et al. A practical evaluation of information processing and abstraction techniques for the internet of things. **IEEE Internet of Things journal**, [S.l.], v. 2, n. 4, p. 340–354, 2015.

GOEL, P.; DATTA, A.; MANNAN, M. S. Application of big data analytics in process safety and risk management. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIG DATA), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1143–1152.

HOSSAIN, E. et al. Application of big data and machine learning in smart grid, and associated security concerns: a review. **IEEE Access**, [S.l.], v. 7, p. 13960–13988, 2019.

HUANG, S. et al. Overview of condition monitoring and operation control of electric power conversion systems in direct-drive wind turbines under faults. **Frontiers of Mechanical Engineering**, [S.l.], v. 12, n. 3, p. 281–302, 2017.

HUNTER, J. D. Matplotlib: a 2d graphics environment. **Computing in Science & Engineering**, [S.l.], v. 9, n. 3, p. 90–95, 2007.

IBER, M. et al. Auditory augmented process monitoring for cyber physical production systems. **Personal and Ubiquitous Computing**, [S.l.], p. 1–14, 2020.

IWASAKI, A. et al. Damage and fault diagnosis of in-service structure via statistical comparison of relation between sensor measurements. **Journal of Solid Mechanics and Materials Engineering**, [S.l.], v. 2, n. 8, p. 1114–1125, 2008.

JABLONSKI, A.; BARSZCZ, T. Validation of vibration measurements for heavy duty machinery diagnostics. **Mechanical Systems and Signal Processing**, [S.l.], v. 38, n. 1, p. 248–263, 2013.

JIANG, J.; PAPAVALASSILIOU, S. A network fault diagnostic approach based on a statistical traffic normality prediction algorithm. In: GLOBECOM'03. IEEE GLOBAL TELECOMMUNICATIONS CONFERENCE (IEEE CAT. NO. 03CH37489), 2003. **Anais...** [S.l.: s.n.], 2003. v. 5, p. 2918–2922.

JOSEPH, T. et al. Asset management strategies for power electronic converters in transmission networks: application to hvdc and facts devices. **IEEE Access**, [S.l.], v. 6, p. 21084–21102, 2018.

JUNG, D.; ZHANG, Z.; WINSLETT, M. Vibration analysis for iot enabled predictive maintenance. In: IEEE 33RD INTERNATIONAL CONFERENCE ON DATA ENGINEERING (ICDE), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1271–1282.

JUPYTER - open standards for interactive computing. <<https://jupyter.org/>>. Acessado em 17 jun. 2019.

KEOGH, E. J.; PAZZANI, M. J. Scaling up dynamic time warping for datamining applications. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 2000. **Proceedings...** [S.l.: s.n.], 2000. p. 285–289.

KEOGH, E. J.; PAZZANI, M. J. Derivative dynamic time warping. In: SIAM INTERNATIONAL CONFERENCE ON DATA MINING, 2001., 2001. **Proceedings...** [S.l.: s.n.], 2001. p. 1–11.

LAZAKIS, I.; GKEREKOS, C.; THEOTOKATOS, G. Investigating an svm-driven, one-class approach to estimating ship systems condition. **Ships and Offshore Structures**, [S.l.], v. 14, n. 5, p. 432–441, 2019.

LEE, J.; BAGHERI, B.; KAO, H.-A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. **Manufacturing letters**, [S.l.], v. 3, p. 18–23, 2015.

LEE, W.-K. et al. Performance improvement of feature-based fault classification for rotor system. **International Journal of Precision Engineering and Manufacturing**, [S.l.], p. 1–10, 2020.

MCKINNEY Wes. Data Structures for Statistical Computing in Python. In: PROCEEDINGS OF THE 9TH PYTHON IN SCIENCE CONFERENCE, 2010. **Anais...** [S.l.: s.n.], 2010. p. 56 – 61.

MOHANTY, S.; GUPTA, K. K.; RAJU, K. S. Vibration feature extraction and analysis of industrial ball mill using mems accelerometer sensor and synchronized data analysis technique. **Procedia Computer Science**, [S.l.], v. 58, n. 2, p. 217–224, 2015.

MUEEN, A.; KEOGH, E. Extracting optimal performance from dynamic time warping. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016. **Proceedings...** [S.l.: s.n.], 2016. p. 2129–2130.

MUNIRATHINAM, S.; RAMADOSS, B. Predictive models for equipment fault detection in the semiconductor manufacturing process. **IACSIT International Journal of Engineering and Technology**, [S.l.], v. 8, n. 4, p. 273–285, 2016.

NIGGEMANN, O. et al. Data-driven monitoring of cyber-physical systems leveraging on big data and the internet-of-things for diagnosis and control. In: DX@ SAFEPROCESS, 2015. **Anais...** [S.l.: s.n.], 2015. p. 185–192.

NORDRUM, A. Popular internet of things forecast of 50 billion devices by 2020 is outdated (2016). **Dosegljivo: <https://spectrum.ieee.org/tech-talk/telecom/internet/popular-internet-ofthings-forecast-of-50-billion-devices-by-2020-is-outdated>**. [Dostopano: 11. 8. 2017], [S.l.], 2017.

- OYEKANLU, E. Predictive edge computing for time series of industrial iot and large scale critical infrastructure based on open-source software analytic of big data. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIG DATA), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1663–1669.
- PETITJEAN, F. et al. Dynamic time warping averaging of time series allows faster and more accurate classification. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING, 2014., 2014. **Anais...** [S.l.: s.n.], 2014. p. 470–479.
- PLAZA, E. G.; LÓPEZ, P. N.; GONZÁLEZ, E. B. Efficiency of vibration signal feature extraction for surface finish monitoring in cnc machining. **Journal of Manufacturing Processes**, [S.l.], v. 44, p. 145–157, 2019.
- POSADA, J. et al. Visual computing as a key enabling technology for industrie 4.0 and industrial internet. **IEEE computer graphics and applications**, [S.l.], v. 35, n. 2, p. 26–40, 2015.
- POSTGRESQL: the world's most advanced open source relational database. <<https://www.postgresql.org/>>. Acessado em 17 jun. 2019.
- PRESS, O. U. **Definition of quality**. <<https://www.lexico.com/en/definition/quality>>. Acessado em 15 dez. 2020.
- RAKTHANMANON, T. et al. Searching and mining trillions of time series subsequences under dynamic time warping. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 18., 2012. **Proceedings...** [S.l.: s.n.], 2012. p. 262–270.
- RATH, T. M.; MANMATHA, R. Word image matching using dynamic time warping. In: IEEE COMPUTER SOCIETY CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2003. PROCEEDINGS., 2003., 2003. **Anais...** [S.l.: s.n.], 2003. v. 2, p. II–II.
- REIS, M. S.; GINS, G. Industrial process monitoring in the big data/industry 4.0 era: from detection, to diagnosis, to prognosis. **Processes**, [S.l.], v. 5, n. 3, p. 35, 2017.
- RIAZ, S. et al. Vibration feature extraction and analysis for fault diagnosis of rotating machinery-a literature survey. **Asia Pacific Journal of Multidisciplinary Research**, [S.l.], v. 5, n. 1, p. 103–110, 2017.
- RUOFF, C. **A closer look at wire bonding**. Disponível em: <<https://chargedevs.com/features/a-closer-look-at-wire-bonding/>>. Acesso em: 30 de agosto de 2019.
- SAKOE, H.; CHIBA, S. Dynamic programming algorithm optimization for spoken word recognition. **IEEE transactions on acoustics, speech, and signal processing**, [S.l.], v. 26, n. 1, p. 43–49, 1978.
- SARKODIE-GYAN, T. et al. Application of multiple sensor data fusion for the analysis of human dynamic behavior in space: assessment and evaluation of mobility-related functional impairments. **Journal of Biomedical Science and Engineering**, [S.l.], v. 10, n. 04, p. 182, 2017.

SENIN, P. Dynamic time warping algorithm review. **Information and Computer Science Department University of Hawaii at Manoa Honolulu, USA**, [S.l.], v. 855, n. 1-23, p. 40, 2008.

SISTEMAS IBÉRICOS, L. DMC Engeraria e. **Análise de vibrações e envelope**. Disponível em: <<https://www.dmc.pt/analise-de-vibracoes-e-envelope/>>. Acesso em: 30 de janeiro de 2020.

SLAM stick x accelerometer. <<https://www.mide.com/>>. Acessado em 17 jun. 2019.

TAN, C.-F. A prototype of knowledge-based system for fault diagnosis in automatic wire bonding machine. **Turkish Journal of Engineering and Environmental Sciences**, [S.l.], v. 32, n. 4, p. 235–244, 2008.

TAVENARD, R. **Tslearn documentation**. Disponível em: <<https://tslearn.readthedocs.io/en/latest/>>. Acesso em: 30 de dezembro de 2019.

TEALAB, A. Time series forecasting using artificial neural networks methodologies: a systematic review. **Future Computing and Informatics Journal**, [S.l.], 2018.

TIMESCALEDB - the power of sql for time-series data. <<https://www.timescale.com/>>. Acessado em 17 jun. 2019.

TSE, P.; PENG, Y.; YAM, R. Wavelet analysis and envelope detection for rolling element bearing for rolling element bearing fault diagnosis-their affectivities and flexibilities. **Journal of Vibration and Acoustic**, [S.l.], v. 123, p. 303–310, 2001.

TSLEARN - a python machine learning tools. <<https://pypi.org/project/tslearn/>>. Acessado em 17 jun. 2019.

VAN DER WALT, S.; COLBERT, S. C.; VAROQUAUX, G. The numpy array: a structure for efficient numerical computation. **Computing in Science & Engineering**, [S.l.], v. 13, n. 2, p. 22, 2011.

VILLALOBOS, K. et al. I4tsps: a visual-interactive web system for industrial time-series pre-processing. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIG DATA), 2018., 2018. **Anais...** [S.l.: s.n.], 2018. p. 2012–2018.

Virtanen, P. et al. Scipy 1.0: fundamental algorithms for scientific computing in python. **Nature Methods**, [S.l.], v. 17, p. 261–272, 2020.

VOLKOV, A.; SHILOVA, L.; KACHANOV, S. Monitoring of intellectual manufacturing as a main factor of the cyber-physical building systems development. In: GLOBAL SMART INDUSTRY CONFERENCE (GLOSIC), 2018., 2018. **Anais...** [S.l.: s.n.], 2018. p. 1–6.

YU, Z. et al. Deep learning for daily peak load forecasting—a novel gated recurrent neural network combining dynamic time warping. **IEEE access**, [S.l.], v. 7, p. 17184–17194, 2019.

ZENG, S.; LU, G.; YAN, P. Vibration feature extraction using local temporal self-similarity for rolling bearing fault diagnosis. In: IEEE INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT (ICPHM), 2019., 2019. **Anais...** [S.l.: s.n.], 2019. p. 1–5.

ZHANG, D.; LING, S.-F. Monitoring wire bonding via time-frequency analysis of horn vibration. **IEEE transactions on electronics packaging manufacturing**, [S.l.], v. 26, n. 3, p. 216–220, 2003.

ZHILI, L. et al. Joint time-frequency analysis of capillary tip vibration in thermosonic wire bonding. In: CONFERENCE ON HIGH DENSITY MICROSYSTEM DESIGN AND PACKAGING AND COMPONENT FAILURE ANALYSIS, 2005., 2005. **Anais...** [S.l.: s.n.], 2005.

ZHOU, J.; YAO, X.; ZHANG, J. Big data in wisdom manufacturing for industry 4.0. In: INTERNATIONAL CONFERENCE ON ENTERPRISE SYSTEMS (ES), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 107–112.

APÊNDICE A – ACELERÔMETRO UTILIZADO NA AVALIAÇÃO INICIAL

Para cada coleta realizada, o acelerômetro gerou um arquivo compactado e proprietário, com extensão ".ide", que se fez necessário convertê-lo para outra extensão mais universal que é a ".csv". Para ter acesso a este arquivo, bastou conectar o acelerômetro ao computador. No próprio site do fabricante é possível encontrar o software que realiza o acesso às informações coletadas, bem como este processo de conversão para arquivos do tipo csv.

Nesta avaliação inicial, foi utilizado o Slam Stick X que incorpora um acelerômetro piezoeletrônico de 3 eixos, sensor de temperatura, sensor de pressão e sistema de aquisição de dados em um produto fácil de usar. Sua capacidade de medir uma ampla faixa de amplitude de aceleração, taxas de amostragem rápidas (até 20 kHz), bateria de longa duração (acima de 15 horas), memória grande (até 4 bilhões de amostras) e fator de forma pequeno e portátil o tornam ideal para muitas aplicações de medição de vibrações e testes de impacto. O Slam Stick X também vem com um segundo acelerômetro triaxial para atender a uma ampla gama de aplicações de choque e vibração (SLAM STICK X ACCELEROMETER, 1989).

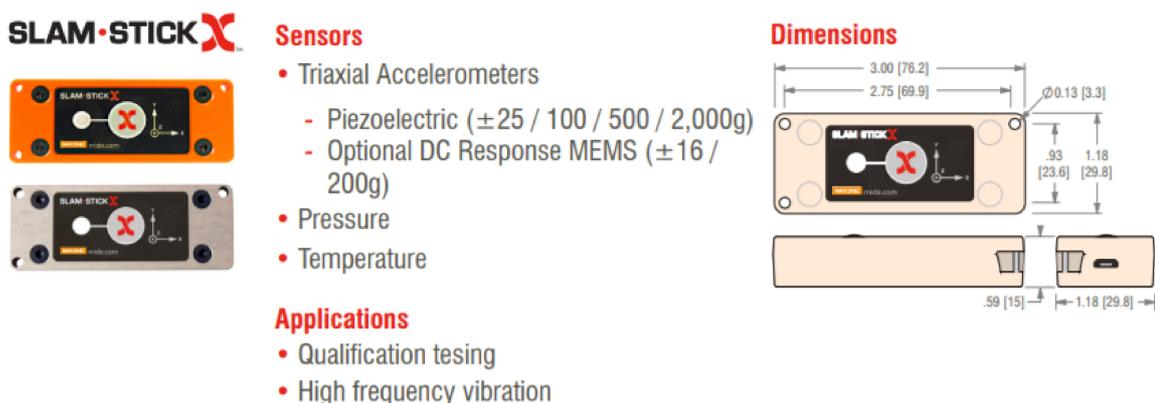


Figura 46: *Slam Stick X*

Fonte: (SLAM STICK X ACCELEROMETER, 1989)

APÊNDICE B – POSTGRESQL DATABASE WITH TIMESCALE DB

O *PostgreSQL* é um poderoso sistema de banco de dados objeto-relacional de código aberto com mais de 30 anos de desenvolvimento ativo que lhe garantiu uma forte reputação de confiabilidade, robustez de recursos e desempenho (POSTGRESQL: THE WORLD'S MOST ADVANCED OPEN SOURCE RELATIONAL DATABASE, 1996).

Devido ao grande volume de dados a serem analisados neste modelo, não foi possível trabalhar com eles carregados em memória. Portanto, foi necessário inicialmente importá-los para um banco de dados, que neste caso foi o *PostgreSQL*. Entretanto, antes de iniciar o processo de importação dos dados para o banco, foi necessário prepará-lo para clusterização vertical, com o uso de uma extensão denominada *TimeScale Database*.

O TimescaleDB é um banco de dados de séries temporais de código aberto otimizado para inclusão rápida e consultas complexas. Ele é "*Full SQL*", e muito fácil de usar exatamente como um banco de dados relacional tradicional, mas é dimensionado de maneiras anteriormente reservadas para bancos de dados *NoSQL* (TIMESCALEDB - THE POWER OF SQL FOR TIME-SERIES DATA, 2017).

Caso fosse necessário criar relacionamentos com metadados, além do uso de um banco de dados *NoSQL*, seria necessário o uso de um banco de dados relacional, dificultando as buscas relacionadas entre séries temporais e metadados.

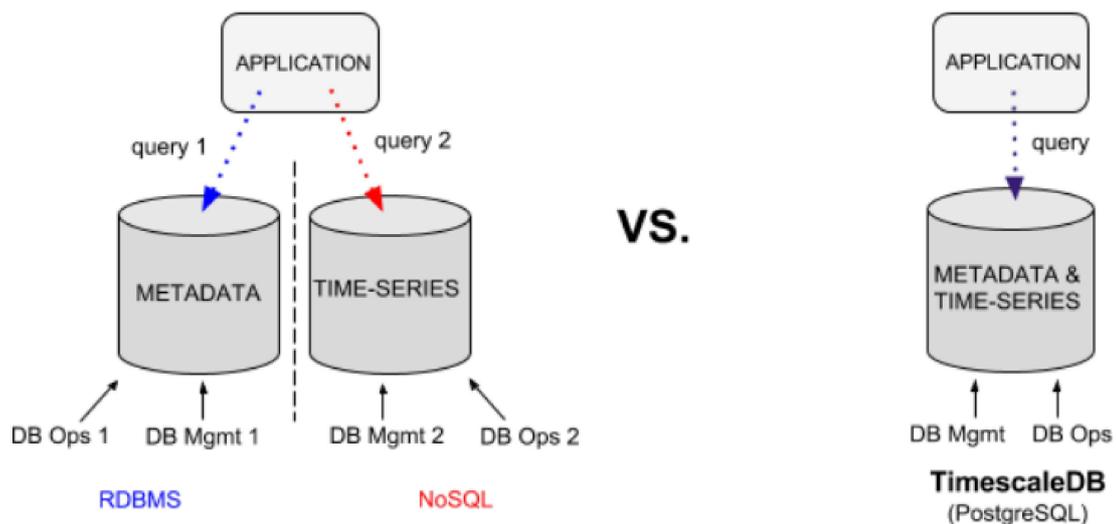


Figura 47: *TimeScaleDB* comparisson with *NoSQL* Architecture

Fonte: (TIMESCALEDB - THE POWER OF SQL FOR TIME-SERIES DATA, 2017)

Basicamente, o conceito do *TimescaleDB* é transformar uma grande tabela, em *chunks* (pequenos fragmentos) de tabelas, otimizando significativamente o acesso à informação. E por ser de uso específico para séries temporais, esta fragmentação ocorre definindo o tempo que

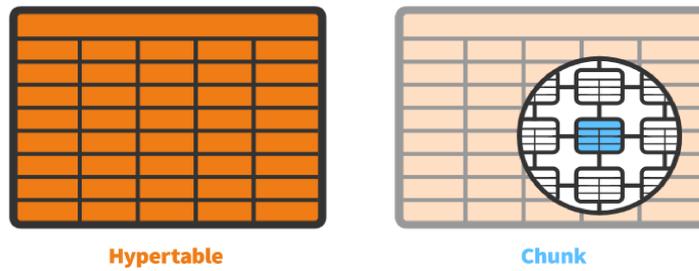


Figura 48: *Hypertable architecture*

Fonte: (TIMESCALEDB - THE POWER OF SQL FOR TIME-SERIES DATA, 2017)

cada fragmento terá, como parâmetro de tamanho.

Uma vez ativada a extensão do *TimeScaleDB*, é recomendado o uso do importador de csv customizado (*timescaledb-parallel-copy*), que pode ser encontrado no *site* (TIMESCALEDB - THE POWER OF SQL FOR TIME-SERIES DATA, 2017). Com este importador, é possível multiplicar a velocidade de importação, dependendo do *hardware* sendo utilizado.

APÊNDICE C – CÓDIGO PYTHON

O repositório do experimento pode ser encontrado em:

<https://gitlab.com/silveiratrindade/time-séries-wirebonders>.

APÊNDICE D – TABELA COMPARATIVA DAS OPERAÇÕES

A convenção utilizada aqui é baseada no atendimento do seguinte requisito: se ao comparar o template de operação com outra operação similar, tanto o tipo de assinatura de vibração quanto a posição no sequenciamento devem ser exatamente iguais. Sendo assim, o requisito será cumprido e a comparação receberá um "OK". Caso contrário, se algum dos requisitos não for cumprido, a comparação receberá um "NOK" (Não OK).

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
0	A	A	A	OK	OK
1	B	B	B	OK	OK
2	A	A	A	OK	OK
3	B	B	B	OK	OK
4	A	A	A	OK	OK
5	B	B	B	OK	OK
6	A	A	A	OK	OK
7	B	B	B	OK	OK
8	A	A	A	OK	OK
9	B	B	B	OK	OK
10	A	A	A	OK	OK
11	B	B	B	OK	OK
12	A	A	A	OK	OK
13	B	B	B	OK	OK
14	A	A	A	OK	OK
15	B	B	B	OK	OK
16	A	A	A	OK	OK
17	B	B	B	OK	OK
18	A	A	A	OK	OK
19	B	B	B	OK	OK
20	A	A	A	OK	OK
21	B	B	B	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
22	A	A	A	OK	OK
23	B	B	B	OK	OK
24	A	A	A	OK	OK
25	B	B	B	OK	OK
26	A	A	A	OK	OK
27	B	B	B	OK	OK
28	A	A	A	OK	OK
29	B	B	B	OK	OK
30	A	A	A	OK	OK
31	B	B	B	OK	OK
32	A	A	A	OK	OK
33	B	B	B	OK	OK
34	A	A	A	OK	OK
35	B	B	B	OK	OK
36	A	A	A	OK	OK
37	B	B	B	OK	OK
38	A	A	A	OK	OK
39	B	B	B	OK	OK
40	A	A	A	OK	OK
41	B	B	B	OK	OK
42	A	A	A	OK	OK
43	B	B	B	OK	OK
44	A	A	A	OK	OK
45	B	B	B	OK	OK
46	A	A	A	OK	OK
47	B	B	B	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
48	A	A	A	OK	OK
49	B	B	B	OK	OK
50	A	A	A	OK	OK
51	B	B	B	OK	OK
52	A	A	A	OK	OK
53	B	B	B	OK	OK
54	A	A	A	OK	OK
55	B	B	B	OK	OK
56	A	A	A	OK	OK
57	B	B	B	OK	OK
58	A	A	A	OK	OK
59	B	X	B	NOK	OK
60	A	A	A	OK	OK
61	B	X	B	NOK	OK
62	A	A	A	OK	OK
63	B	X	B	NOK	OK
64	A	A	A	OK	OK
65	B	X	B	NOK	OK
66	A	A	A	OK	OK
67	A	A	B	OK	NOK
68	A	A	A	OK	OK
69	B	X	B	NOK	OK
70	A	A	A	OK	OK
71	B	X	B	NOK	OK
72	A	A	A	OK	OK
73	B	X	B	NOK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
74	A	A	A	OK	OK
75	B	X	B	NOK	OK
76	A	A	A	OK	OK
77	B	X	B	NOK	OK
78	A	A	A	OK	OK
79	B	X	B	NOK	OK
80	A	A	A	OK	OK
81	B	X	B	NOK	OK
82	A	A	A	OK	OK
83	B	X	B	NOK	OK
84	A	A	A	OK	OK
85	B	X	B	NOK	OK
86	A	A	A	OK	OK
87	A	A	B	OK	NOK
88	A	A	A	OK	OK
89	B	X	B	NOK	OK
90	A	A	A	OK	OK
91	B	X	X	NOK	NOK
92	A	A	A	OK	OK
93	B	X	B	NOK	OK
94	A	A	A	OK	OK
95	B	X	B	NOK	OK
96	A	A	A	OK	OK
97	B	X	B	NOK	OK
98	A	A	A	OK	OK
99	B	X	B	NOK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
100	A	A	A	OK	OK
101	B	X	X	NOK	NOK
102	A	A	A	OK	OK
103	B	X	X	NOK	NOK
104	A	A	A	OK	OK
105	B	X	B	NOK	OK
106	A	A	A	OK	OK
107	B	X	B	NOK	OK
108	A	A	A	OK	OK
109	B	X	B	NOK	OK
110	A	A	A	OK	OK
111	B	X	X	NOK	NOK
112	A	A	A	OK	OK
113	B	X	B	NOK	OK
114	A	A	A	OK	OK
115	B	X	B	NOK	OK
116	A	A	A	OK	OK
117	B	X	X	NOK	NOK
118	A	A	A	OK	OK
119	B	X	B	NOK	OK
120	A	A	A	OK	OK
121	B	X	B	NOK	OK
122	A	A	A	OK	OK
123	B	X	B	NOK	OK
124	A	A	A	OK	OK
125	B	X	B	NOK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
126	A	A	A	OK	OK
127	A	A	X	OK	NOK
128	A	A	A	OK	OK
129	A	A	X	OK	NOK
130	A	A	A	OK	OK
131	A	A	X	OK	NOK
132	A	A	A	OK	OK
133	B	X	B	NOK	OK
134	A	A	A	OK	OK
135	A	A	A	OK	OK
136	A	A	A	OK	OK
137	A	A	A	OK	OK
138	A	A	A	OK	OK
139	A	A	A	OK	OK
140	A	A	A	OK	OK
141	A	A	A	OK	OK
142	A	A	A	OK	OK
143	A	A	A	OK	OK
144	A	A	A	OK	OK
145	A	A	A	OK	OK
146	A	A	A	OK	OK
147	A	A	A	OK	OK
148	A	A	A	OK	OK
149	A	A	A	OK	OK
150	A	A	A	OK	OK
151	A	A	A	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
152	A	A	A	OK	OK
153	A	A	A	OK	OK
154	A	A	A	OK	OK
155	A	A	A	OK	OK
156	A	A	A	OK	OK
157	A	A	A	OK	OK
158	A	A	A	OK	OK
159	A	A	A	OK	OK
160	A	A	A	OK	OK
161	A	A	A	OK	OK
162	A	A	A	OK	OK
163	A	A	A	OK	OK
164	A	A	A	OK	OK
165	A	A	A	OK	OK
166	A	A	A	OK	OK
167	A	A	A	OK	OK
168	A	A	A	OK	OK
169	A	A	A	OK	OK
170	A	A	A	OK	OK
171	A	A	A	OK	OK
172	A	A	A	OK	OK
173	A	A	A	OK	OK
174	A	A	A	OK	OK
175	A	A	A	OK	OK
176	A	A	A	OK	OK
177	A	A	A	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
178	A	A	A	OK	OK
179	A	A	A	OK	OK
180	A	A	A	OK	OK
181	A	A	A	OK	OK
182	A	A	A	OK	OK
183	A	A	A	OK	OK
184	A	A	A	OK	OK
185	A	A	A	OK	OK
186	A	A	A	OK	OK
187	A	A	A	OK	OK
188	A	A	A	OK	OK
189	A	A	A	OK	OK
190	A	A	A	OK	OK
191	A	A	A	OK	OK
192	A	A	A	OK	OK
193	A	A	A	OK	OK
194	A	A	A	OK	OK
195	A	A	A	OK	OK
196	A	A	A	OK	OK
197	A	A	A	OK	OK
198	A	A	A	OK	OK
199	A	A	A	OK	OK
200	A	A	A	OK	OK
201	A	A	A	OK	OK
202	A	A	A	OK	OK
203	A	A	A	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
204	A	A	A	OK	OK
205	A	A	A	OK	OK
206	A	A	A	OK	OK
207	A	A	A	OK	OK
208	A	A	A	OK	OK
209	A	A	A	OK	OK
210	A	A	A	OK	OK
211	A	A	A	OK	OK
212	A	A	A	OK	OK
213	A	A	A	OK	OK
214	A	A	A	OK	OK
215	A	A	A	OK	OK
216	A	A	A	OK	OK
217	A	A	A	OK	OK
218	A	A	A	OK	OK
219	A	A	A	OK	OK
220	A	A	A	OK	OK
221	A	A	A	OK	OK
222	A	A	A	OK	OK
223	A	A	A	OK	OK
224	A	A	A	OK	OK
225	A	A	A	OK	OK
226	A	A	A	OK	OK
227	A	A	A	OK	OK
228	A	A	A	OK	OK
229	A	A	A	OK	OK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
230	A	A	A	OK	OK
231	A	A	A	OK	OK
232	A	A	A	OK	OK
233	A	A	A	OK	OK
234	A	A	A	OK	OK
235	A	A	A	OK	OK
236	A	A	A	OK	OK
237	A	A	A	OK	OK
238	A	A	A	OK	OK
239	A	A	A	OK	OK
240	A	A	A	OK	OK
241	A	A	A	OK	OK
242	A	A	A	OK	OK
243	A	A	A	OK	OK
244	A	A	A	OK	OK
245	A	A	A	OK	OK
246	A	A	A	OK	OK
247	A	A	A	OK	OK
248	A	A	A	OK	OK
249	A	A	A	OK	OK
250	A	A	A	OK	OK
251	A	A	X	OK	NOK
252	A	A	A	OK	OK
253	A	A	A	OK	OK
254	A	A	A	OK	OK
255	A	A	X	OK	NOK

Table 12 continued from previous page

Sequência	Assinaturas Template OP	Assinaturas OP1	Assinaturas OP2	Template OP x OP1	Template OP x OP2
256	A	A	A	OK	OK
257	A	A	A	OK	OK
258	A	A	A	OK	OK

Tabela 12: Tabela Comparativa do Sequenciamento e Quantificação das Operações 1 e 2 em Relação ao Template de Operação, para Geração do Índice de Qualidade por Operação.