

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS**  
**UNIDADE ACADÊMICA DE GRADUAÇÃO**  
**CURSO DE ENGENHARIA DE COMPUTAÇÃO**

**LUCAS MANIQUE LEAL**

**PREDIÇÃO DE DESALINHAMENTO EM MOTORES ELÉTRICOS ATRAVÉS DE  
ANÁLISE DOS SINAIS DE VIBRAÇÃO COM REDES NEURAS ARTIFICIAIS**

**São Leopoldo**

**2019**

LUCAS MANIQUE LEAL

**PREDIÇÃO DE DESALINHAMENTO EM MOTORES ELÉTRICOS ATRAVÉS DE  
ANÁLISE DOS SINAIS DE VIBRAÇÃO COM REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso  
apresentado como requisito parcial para  
obtenção do título de Graduado em  
Engenharia da Computação, pelo Curso de  
Engenharia da Computação da  
Universidade do Vale do Rio dos Sinos -  
UNISINOS

Orientador: Prof. Dr. Rodrigo Marques de Figueiredo

São Leopoldo  
2019

Dedico este trabalho à minha família e à minha noiva, Júlia, que sempre me deram todo apoio e suporte necessários durante minha trajetória acadêmica.

## **AGRADECIMENTOS**

Em primeiro lugar, gostaria de agradecer ao Fundo Loyola de Apoio Acadêmico que me permitiu cursar a graduação em Engenharia da Computação na Unisinos com bolsa integral durante cinco anos. Sem este benefício não seria possível iniciar essa trajetória tão jovem e concluir o curso em apenas cinco anos e meio.

Além disso, agradeço profundamente a todos os professores que ajudaram a construir a minha formação acadêmica, pois além de todos os conteúdos transmitidos, muitos deles me inspiraram pessoalmente, a ser pessoa mais comprometida, estudiosa e empática. Aqui não vou citar nomes, mas tenho certeza que cada um que participou dessa trajetória fez a sua parte de forma essencial e relevante.

Ao meu orientador e amigo, Rodrigo, gostaria de expressar imensa gratidão pelo apoio constante durante o desenvolvimento desta pesquisa e pelo exemplo de Engenheiro e ser humano que sempre foi em todos os momentos em que tive o prazer de compartilhar a convivência. Além dele, agradeço ao mestrando Guilherme Piaia pelo apoio fundamental, cooperação e troca de conhecimento durante todo o trabalho.

Por fim, agradeço à minha família e à minha noiva que sempre foram o alicerce para que cada passo fosse dado ao longo de todos esses anos. Nada no mundo é mais importante do que o suporte e o amor de vocês.

“Só é verdadeiramente digno da liberdade, bem como da vida, aquele que se empenha em conquistá-la.”  
(Johann Goethe)

## RESUMO

Tendo em vista o grande impacto que a paralisação de motores elétricos pode causar nos processos produtivos em geral, este trabalho teve como objetivo criar um modelo de predição de falha de desalinhamento em motores de indução através da análise dos sinais de vibração gerados durante seu funcionamento. Para a aquisição dos dados, foi utilizado um equipamento de simulação de falhas chamado *Machinery Fault Simulator*<sup>®</sup>, que dispõe de sete sensores de vibração espalhados pela sua estrutura. Através das informações coletadas, foram extraídos espectros de energia dos sinais de motor sem falhas e motor desalinhada que formaram a entrada de um sistema preditor. Utilizando uma técnica de aprendizado de máquinas chamada de Redes Neurais Artificiais, as informações foram processadas e um modelo que atinge 100% de acerto na classificação do estado do motor foi construído. Esta acurácia pôde ser observada tanto utilizando todos os canais do equipamento de simulação, como também utilizando apenas o canal mais eficiente, cumprindo assim os objetivos propostos.

**Palavras-chave:** Manutenção Preditiva. Motores elétricos. Energia. Aprendizado de Máquinas. Redes Neurais Artificiais.

## LISTA DE FIGURAS

Figura 1 - Campo magnético de um ímã permanente em barra.....	13
Figura 2 – Campo magnético em torno de um condutor retilíneo transportando corrente elétrica.....	13
Figura 3 – Princípio de funcionamento do motor.....	14
Figura 4 – Regra da mão direita para o motor.....	15
Figura 5 – Classificação dos motores comuns.....	16
Figura 6 – Componentes principais de um motor CC.....	17
Figura 7 – Corrente induzida no rotor.....	18
Figura 8 – Representação de uma célula neural biológica.....	25
Figura 9 - Representação de uma rede neural.....	25
Figura 10 – Estrutura Física do MFS®.....	33
Figura 11 - Sensores do MFS®.....	36
Figura 12 - Fluxograma de configuração do <i>VibraQuest PRO</i> ®.....	36
Figura 13 - Estrutura do MFS® com canais numerados.....	38
Figura 14 - Representação trigonométrica do desalinhamento.....	38
Figura 15 - Gráfico de aceleração dos canais 1 a 4.....	39
Figura 16 - Gráfico de aceleração dos canais 5 a 7.....	40
Figura 17 - FFT dos canais 1 a 6.....	41
Figura 18 - FFT do canal 7.....	42
Figura 19 - FFT por falha e energia do espectro.....	43
Figura 20 - Espectros de energia dos canais 1 a 4.....	45
Figura 21 - Espectros de energia dos canais 5 a 7.....	46
Figura 22 - Resultados da RNA com sete sensores.....	48
Figura 23 – Resultados da RNA por sensor.....	49
Figura 24 - Resultados da RNA do canal 3.....	50
Figura 25 - Resultados da RNA sem o canal 3.....	51

## LISTA DE QUADROS

Quadro 1 - Definições de IA a partir sob diferentes pontos de vista.....	21
Quadro 2 - Especificações técnicas do acelerômetro 608A11 .....	34
Quadro 3 - Sensores de vibração do MFS ® .....	35
Quadro 4 - Parâmetros da RNA .....	47
Quadro 5 - Matriz de treinamento RNA sem canal 3 com 3% para treinamento .....	51
Quadro 6 - Matriz de confusão da RNA sem o canal 3 com 3% para treinamento ...	52

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>10</b>
1.1 OBJETIVOS .....	11
<b>1.1.1 Objetivo Geral</b> .....	<b>11</b>
<b>1.1.2 Objetivos Específicos</b> .....	<b>11</b>
1.2 ORGANIZAÇÃO DO TEXTO.....	11
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>12</b>
2.1 CONCEITOS BÁSICOS .....	12
<b>2.1.1 Motores Elétricos</b> .....	<b>12</b>
2.1.1.1 Classificação de Motores Elétricos.....	15
2.1.1.1.1 <i>Motores Elétricos de Corrente Contínua</i> .....	16
2.1.1.1.2 <i>Motores Elétricos de Corrente Alternada</i> .....	17
2.1.1.2 Falhas em Motores Elétricos de Indução .....	18
<b>2.1.2 Defeito x Falha</b> .....	<b>19</b>
<b>2.1.3 Manutenção</b> .....	<b>19</b>
2.1.3.1 Manutenção Corretiva .....	20
2.1.3.2 Manutenção Preventiva.....	20
2.1.3.3 Manutenção Preditiva.....	20
<b>2.1.4 Inteligência Artificial e Aprendizado de Máquina</b> .....	<b>21</b>
2.1.4.1 Métodos Baseados em Distâncias .....	23
2.1.4.2 Métodos Probabilísticos .....	23
2.1.4.3 Métodos Baseados em Procura .....	24
2.1.4.4 Métodos Baseados em Otimização .....	24
2.1.4.4.1 <i>Redes Neurais Artificiais</i> .....	24
2.2 ESTADO DA ARTE .....	26
<b>2.2.1 Previsão da Manutenção</b> .....	<b>26</b>
<b>2.2.2 Previsão da Manutenção em Motores</b> .....	<b>28</b>
<b>2.2.3 Previsão da Manutenção em Motores Elétricos</b> .....	<b>29</b>
<b>2.2.4 Previsão de Falhas em Motores Elétricos de Indução</b> .....	<b>30</b>
<b>3 METODOLOGIA</b> .....	<b>33</b>
3.1 SENSORES DE VIBRAÇÃO DO MFS® .....	34
3.2 AQUISIÇÃO DOS DADOS DE VIBRAÇÃO.....	36
<b>3.2.1 Configuração do Software</b> .....	<b>36</b>

<b>3.2.2 Configuração do Hardware.....</b>	<b>37</b>
3.3 PRÉ-PROCESSAMENTO DOS DADOS.....	39
3.4 PROCESSAMENTO DOS DADOS.....	47
<b>4 ANÁLISE DOS RESULTADOS .....</b>	<b>48</b>
<b>5 CONSIDERAÇÕES FINAIS .....</b>	<b>53</b>
<b>REFERÊNCIAS.....</b>	<b>54</b>
<b>APÊNDICE A – MATRIZ DE VALIDAÇÃO RNA COMPLETA .....</b>	<b>58</b>
<b>APÊNDICE B - MATRIZ DE VALIDAÇÃO RNA CANAL 3 .....</b>	<b>59</b>
<b>APÊNDICE C – SCRIPT PROCESSAMENTO E RNA.....</b>	<b>60</b>

## 1 INTRODUÇÃO

Os motores elétricos representam equipamentos imprescindíveis na produção industrial do mundo moderno. Segundo Petruzella (2013), estima-se que 50% de toda a eletricidade consumida nos Estados Unidos seja utilizada para operá-los. Sua vasta aplicabilidade em processos produtivos de diferentes segmentos estimula especialistas e pesquisadores a evoluírem continuamente estudos de métodos de diagnóstico e monitoramento de falhas em motores elétricos. De encontro a isso, algoritmos de inteligência artificial (IA) e aprendizado de máquinas (AM) vem sendo aprimorados e otimizados, e se mostram grandes aliados em potencial para a criação de sistemas inteligentes de manutenção, que tenham a capacidade de induzir hipóteses de falha a partir da análise de experiências passadas.

O conceito de manutenção pode ser definido como o conjunto de ações preventivas e intervenções técnicas necessárias para garantir o estado íntegro de funcionamento e o reparo de máquinas, peças, moldes, ferramentas e instalações. A origem da palavra provém do latim *manus tenere*, que significa “manter o que se tem” (ALMEIDA, 2016). Tal prática está presente no dia-a-dia das indústrias ao redor do mundo há muito tempo, e ao longo dos anos fica mais evidente a necessidade de tratar essa ação de forma proativa, sem esperar que uma máquina seja paralisada para ser reparada.

A manutenção preditiva vem sendo objeto de estudo em diversos artigos científicos ao longo dos últimos anos. Corrigir problemas é, na maior parte dos casos, mais simples do que prever sua ocorrência. Porém, sob a ótica de um processo produtivo, reparar uma máquina com defeito que ainda não parou de funcionar é muito mais vantajoso do que esperar que sua operação seja interrompida. Mapear a ocorrência desses defeitos silenciosos gera custo, mas esperar a equipe de manutenção atuar enquanto uma linha de produção está ociosa gera muito mais.

A partir desses fatos, é possível enxergar um grande potencial na busca de alternativas que auxiliem as indústrias a prever a necessidade de manutenção dos seus motores elétricos. Para suprir essa necessidade, neste trabalho será aplicada uma técnica preditiva de aprendizado de máquina definida como redes neurais artificiais (RNAs) para prever a iminência de desalinhamento em um motor elétrico de indução.

## 1.1 OBJETIVOS

A partir da necessidade identificada, pode-se definir os objetivos do trabalho, que estão descritos a seguir.

### 1.1.1 Objetivo Geral

Construir um modelo de predição de desalinhamento angular em um motor elétrico de indução através da análise de sinais de vibração utilizando a técnica de aprendizado de máquinas chamada Redes Neurais Artificiais.

### 1.1.2 Objetivos Específicos

- Avaliar o índice acerto, tendo como meta atingir 85% na classificação da RNA acerca do estado do motor (desalinhado ou sem falha).
- Avaliar o sensor com maior impacto na efetividade do modelo de predição.

## 1.2 ORGANIZAÇÃO DO TEXTO

Este trabalho escrito foi dividido em cinco itens. Na introdução o tema é apresentado e os objetivos expostos. Na revisão bibliográfica, os conceitos e trabalhos correlatos a esta proposta estão descritos e referenciados. Em seguida, são apresentados os métodos utilizados no desenvolvimento da pesquisa e no item subsequente, a análise dos resultados obtidos. E por fim, o quinto e último item possui as considerações finais do trabalho realizado.

## 2 FUNDAMENTAÇÃO TEÓRICA

A fim de contextualizar este estudo acerca dos conhecimentos necessários para seu entendimento, este capítulo apresenta os conceitos básicos relacionados ao trabalho e um estado da arte, com os artigos científicos correlatos relevantes.

### 2.1 CONCEITOS BÁSICOS

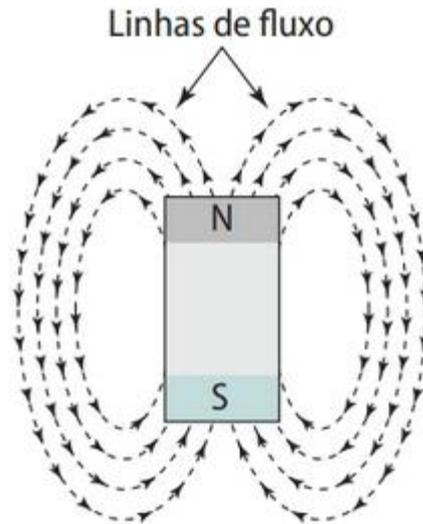
Neste capítulo são apresentados conceitos que servem como base de conhecimento para o estudo deste trabalho. A abordagem possui enfoque na definição de motores elétricos e suas classificações, passando pelos conceitos de defeito, falha e tipos de manutenção existentes (corretiva, preventiva e preditiva). Por fim, caracteriza inteligência artificial, aprendizado de máquinas e redes neurais artificiais, discutindo sobre os aspectos fundamentais de cada uma dessas áreas.

#### 2.1.1 Motores Elétricos

Os motores elétricos têm como objetivo a conversão de energia elétrica em energia mecânica. Seu princípio de funcionamento baseia-se em fenômenos de magnetismo e na circulação de correntes elétricas através da sua bobina. Esse tipo de máquina é dividido em duas classificações básicas, que possuem elementos fundamentais em comum: motor de corrente contínua (CC) e motor de corrente alternada (CA). Conforme Petruzella (2013), as duas categorias têm diferenças estruturais que lhes permitem trabalhar com tipos diferentes de fontes de alimentação.

Antes de explorar os componentes principais de um motor elétrico, é importante contextualizar o magnetismo - força responsável por produzir a rotação de um motor (PETRUZELLA, 2013). Um ímã permanente atrai materiais com propriedades magnéticas quando se encontra próximo ou em contato com eles. Este fenômeno ocorre pela existência de um campo magnético atrelado ao ímã, que pode ser representado através de linhas de fluxo que se movem do polo norte ao polo sul do objeto, conforme a figura 1.

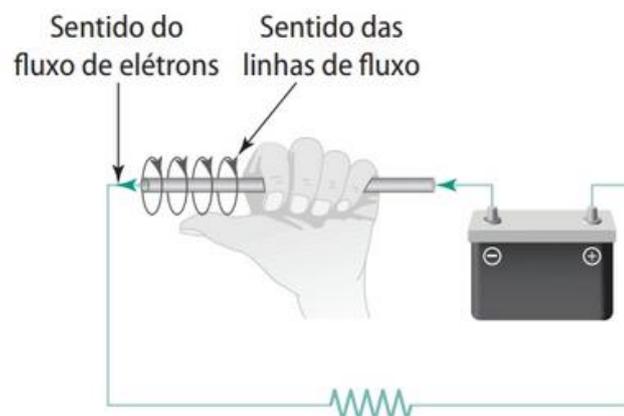
Figura 1 - Campo magnético de um ímã permanente em barra



Fonte: Petruzella (2013, p. 114).

De forma semelhante ao que ocorre com um ímã permanente, condutores que transportam corrente elétrica produzem um campo magnético em seu entorno. Este processo é classificado como eletromagnetismo, e sua intensidade está diretamente relacionada à quantidade de elétrons que percorre o condutor. Quanto maior a corrente, maior o campo magnético produzido (PETRUZELLA, 2013). O sentido das linhas de fluxo geradas pode ser identificado através de uma relação usualmente conhecida como regra da mão esquerda, que se baseia no sentido dos elétrons percorrendo o condutor da carga negativa para a carga positiva, conforme a figura 2.

Figura 2 – Campo magnético em torno de um condutor retilíneo transportando corrente elétrica

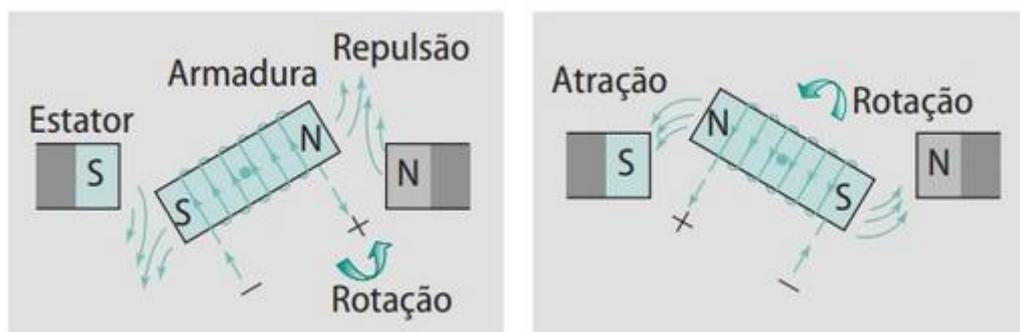


Fonte: Petruzella (2013, p. 114).

Como forma de maximizar o campo magnético produzido pelas linhas de fluxo, o condutor pode ser enrolado em forma de uma bobina, e na parte interna das espiras geradas pode ser injetado um núcleo de ferro, que apresenta menor resistência às linhas de fluxo do que o ar. É exatamente esta a composição da bobina do estator de um motor elétrico (PETRUZELLA, 2013).

A rotação de um motor elétrico se dá como resultado da interação de dois campos magnéticos. Os fenômenos de atração e repulsão dos polos magnéticos de duas partes básicas do motor – armadura e estator – atuam em conjunto, fazendo com que o movimento de rotação aconteça. A armadura é equivalente a um eletroímã, enquanto o estator é equivalente a um ímã permanente. A figura 3 mostra como o processo ocorre.

Figura 3 – Princípio de funcionamento do motor



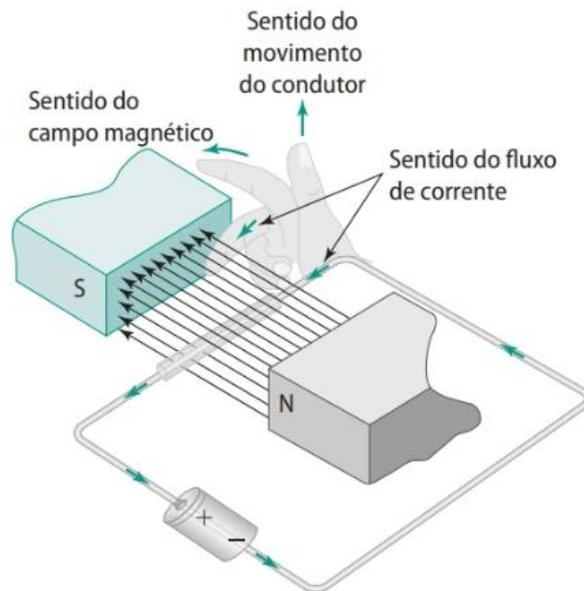
Fonte: Petruzella (2013, p. 115).

Quando os polos magnéticos não estão alinhados, o eletroímã gira até que os polos opostos se encontrem. Neste momento, o rotor tende a parar já que a força de atração está atuando e os pares N-S, S-N estão alinhados, porém é quando um processo de inversão da corrente de armadura ocorre, chamado de comutação. Isso faz com que se inverta a polaridade do campo induzido e os polos, agora iguais, se repelam, mantendo a armadura em modo de rotação. (PETRUZELLA, 2013).

Considerando que a passagem de corrente elétrica por um condutor produz um campo magnético, quando esse condutor é submetido a um meio que possui outro campo magnético circulando, ambos os campos interagem, provocando uma força que tende a movimentar o condutor. O sentido desse movimento pode ser determinado através de um método chamado “regra da mão direita”, que pode ser aplicado posicionando o polegar, o indicador e o dedo médio perpendiculares entre si,

onde cada um aponta para o sentido de uma grandeza existente na interação, conforme a figura 4.

Figura 4 – Regra da mão direita para o motor



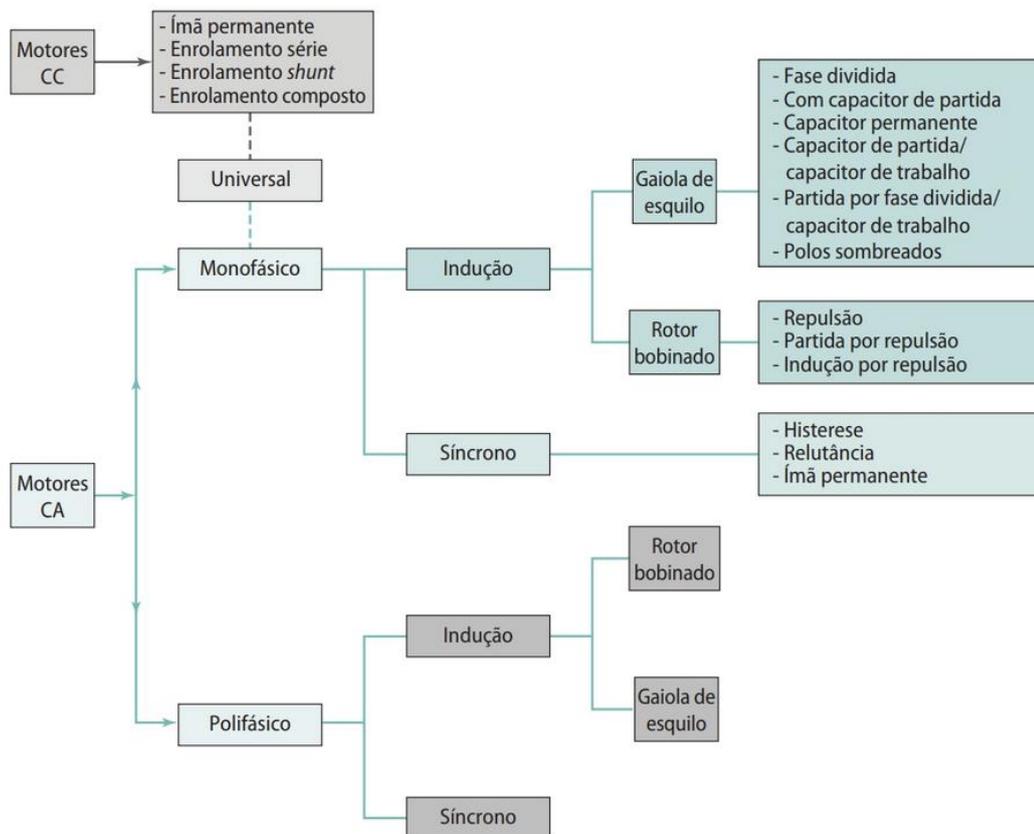
Fonte: Petruzella (2013, p. 116).

Neste caso, o movimento do condutor será para cima, para onde aponta o polegar da mão direita. O dedo indicador aponta para o sentido das linhas de força do campo magnético, enquanto o dedo médio aponta para o sentido percorrido pela corrente (- para +). Se o sentido da corrente que o percorre for invertido, o condutor passa a se mover para baixo. (PETRUZELLA, 2013).

#### 2.1.1.1 Classificação de Motores Elétricos

Os motores elétricos são comumente classificados de acordo com o tipo de energia utilizada no seu funcionamento (CA ou CC). Algumas aplicações possuem nomes mais específicos, conforme diagrama representado na figura 5.

Figura 5 – Classificação dos motores comuns



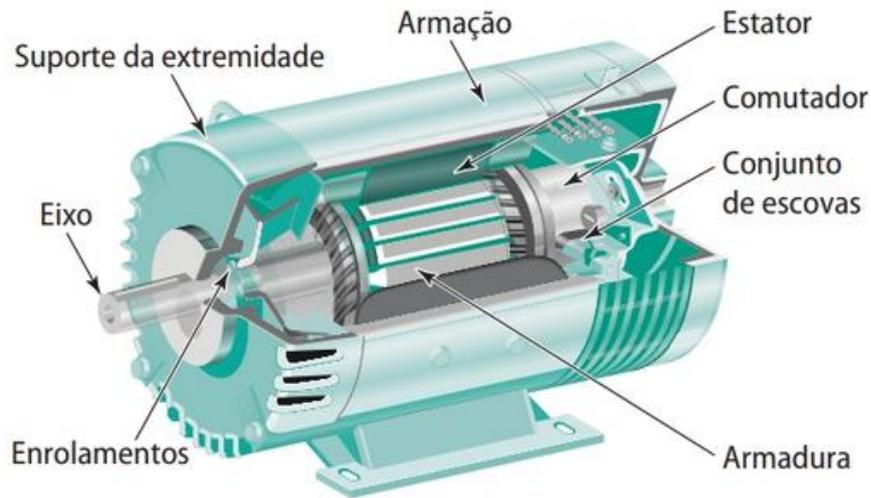
Fonte: Petruzella (2013, p. 117).

Todas essas variantes dos motores CA e CC possuem características fundamentais em comum, que estão apresentadas nos capítulos seguintes.

#### 2.1.1.1.1 Motores Elétricos de Corrente Contínua

Conforme Petruzella (2013), ainda que sejam menos utilizados do que os motores de corrente alternada devido ao tipo de energia fornecida em todos os sistemas de energia elétrica, os motores CC possuem aplicações especiais que justificam a conversão de energia para utilização em sua alimentação. Tais casos podem ser exemplificados com situações em que é necessário um torque preciso e acionamento de velocidade, como guindastes e elevadores. A construção de um motor desta natureza é mais complexa e demorada do que a do motor CA devido a três aspectos fundamentais: o comutador, as escovas e o enrolamento da armadura (PETRUZELLA, 2013). Os componentes principais de um motor CC estão representados na figura 6.

Figura 6 – Componentes principais de um motor CC



Fonte: Petruzella (2013, p. 118).

Considerando a importância do desempenho em motores CC, existem três parâmetros utilizados para aferir tal característica: velocidade, torque e potência (hp), definidos abaixo:

- Velocidade: relacionado à quantidade de rotações por unidade de tempo que o eixo do motor realiza. Normalmente medida em rotações por minuto (RPM).
- Torque: relacionado à força atrelada ao eixo do motor. Normalmente representado na indústria em unidades de libra-polegadas (lb-pol.) ou libra-pé (lb-pé).
- Potência: relacionada à taxa em que o trabalho é realizado. Normalmente representada na indústria em hp. Um hp, por exemplo, é o equivalente a levantar 15 kg a uma altura de um metro em um minuto. Pode ser convertido para a unidade do sistema internacional (Watt).

#### 2.1.1.1.2 Motores Elétricos de Corrente Alternada

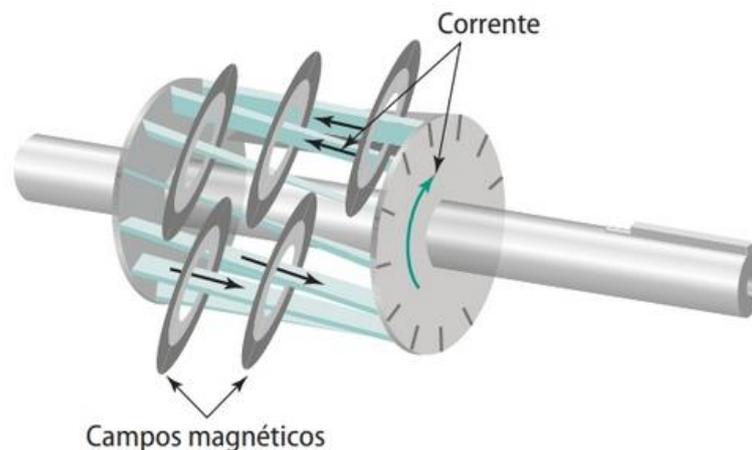
De acordo com Petruzella (2013), a principal diferença entre os motores CA e CC, sob o aspecto físico, está no campo magnético do estator. No caso dos motores de corrente alternada, o campo movimenta-se eletricamente em torno de uma circunferência, o que influencia o campo magnético do rotor pelas interações dos polos magnéticos. A consequência disso é um movimento de rotação do rotor.

Um dos parâmetros mais importantes de serem medidos no funcionamento de um motor é a sua velocidade de rotação. No caso do motor CA, a velocidade é dividida

em duas classificações: síncrona e real. Elas referem-se, respectivamente, à velocidade do campo magnético do estator e à velocidade com que o eixo do motor gira. A velocidade real é informada pelos fabricantes e sempre será menor do que a velocidade síncrona (PETRUZELLA, 2013).

Dentre os tipos de motor CA disponíveis no mercado, o mais utilizado entre todos é o motor de indução. Sua popularidade está diretamente relacionada a duas questões fundamentais: estrutura simplificada e baixo custo de construção. Sua denominação provém da inexistência de quaisquer anéis deslizantes ou fonte externa de corrente contínua conectada ao rotor para seu acionamento. A figura 7 ilustra como as grandezas se relacionam no motor de indução, gerando o processo de rotação.

Figura 7 – Corrente induzida no rotor



Fonte: Petruzella (2013, p.140).

O movimento é causado pela indução de tensão em uma abertura de ar no enrolamento, que gera uma corrente no rotor e um campo magnético associado. A combinação entre os campos magnéticos do estator e do rotor é o que faz o motor rotacionar.

#### 2.1.1.2 Falhas em Motores Elétricos de Indução

A importância dos motores elétricos nos processos produtivos das empresas demanda a busca de soluções que garantam o máximo de disponibilidade possível desses equipamentos. Inatividade, mesmo que por tempos reduzidos, é sinônimo de perda de dinheiro. Dado este cenário, Hand (2015) entende que programas de

manutenção preditiva e preventiva vêm substituindo a manutenção corretiva e trazendo melhores resultados financeiros para diversas indústrias.

Para que este tipo de programa possa ser implementado, se faz necessário o estudo de onde são originadas as falhas que costumam ocorrer neste tipo de equipamento. No caso do motor de indução, segundo Karmakar *et al.* (2016), as falhas possuem três naturezas:

1. Natureza elétrica: falhas como alterações nos parâmetros de tensão e corrente do motor, reversão de fase, curto-circuito interno e faseamento único.
2. Natureza mecânica: falhas como quebra da barra do rotor, desalinhamento, deformações no rolamento, desequilíbrio de massa e excentricidade na abertura de ar.
3. Natureza ambiental: falhas como alterações de umidade e temperatura e vibrações externas.

### **2.1.2 Defeito x Falha**

Os conceitos de defeito e falha possuem ideias complementares, porém são dois termos com significados distintos.

Defeito: comportamento inesperado que não está de acordo com especificações ou requisitos do sistema. O defeito não necessariamente causa uma incapacidade de operação no equipamento (SPACEY, 2017).

Falha: é um defeito que afeta o funcionamento de um equipamento. Causa uma incapacidade em cumprir uma função para a qual ele foi projetado (SPACEY, 2017).

### **2.1.3 Manutenção**

No início da era da industrialização, a necessidade de manter as linhas de produção em funcionamento fez com que a prática de manutenção industrial fosse concebida. No princípio, apenas a manutenção corretiva era praticada. Depois, surgiram os conceitos de manutenção preventiva e preditiva. Essas três classificações serão definidas neste capítulo.

### 2.1.3.1 Manutenção Corretiva

A Associação Brasileira de Normas Técnicas (ABNT) NBR 5462/1994 define que manutenção corretiva é aquela praticada depois de ocorrer a paralisação de um produto/sistema e tem como objetivo restaurar sua operação, para que volte a ter condições de realizar sua tarefa. Levando ao ambiente industrial, ela é responsável por sanar um problema de produção, quando um equipamento apresenta falha capaz de interromper seu funcionamento e a equipe de manutenção atua para consertá-lo (ALMEIDA, 2016).

### 2.1.3.2 Manutenção Preventiva

O propósito da manutenção preventiva é evitar que paradas imprevistas e pequenas falhas causem prejuízos maiores às máquinas em operação. Nesta classificação, é criado um programa de manutenção que visa prevenir a ocorrência de paradas, através de uma análise do histórico de manutenções corretivas e da vida útil das peças. Cada processo produtivo define um ciclo preventivo de acordo com seu cenário de falhas. Segundo Almeida (2016), tal prática pode ajudar no diagnóstico de defeitos que prejudicam a vida útil das peças, mas que se manifestam em outras partes da máquina.

### 2.1.3.3 Manutenção Preditiva

A manutenção preditiva tem como finalidade prever a necessidade de intervenção em um equipamento, através da inspeção periódica dos seus parâmetros de funcionamento. Essa prática permite o planejamento da manutenção a partir da condição apresentada pela máquina, sem a ocorrência da paralisação de seu funcionamento. Além disso, permite monitorar o tempo de vida útil dos seus componentes e auxilia na busca por modos de maximizá-lo.

Para que a previsão da manutenção possa ser realizada, são necessários instrumentos específicos de análise e diagnóstico de acordo com a natureza dos defeitos mapeados. Almeida (2016) cita três exemplos de equipamentos que são utilizados na indústria com esse propósito: analisador de vibrações, estetoscópio e termômetro.

As vantagens que esse tipo de prática é capaz de trazer são significativas. Almeida (2016) destaca:

- Diminuição dos custos com indisponibilidade e reparos.
- Maximização da eficiência e da vida útil das peças.
- Melhoria nos indicadores de eficiência e produtividade.

Ao passo que os sistemas industriais de medição e análise evoluem rapidamente no cenário tecnológico do século XXI e busca-se aliar baixo custo de manutenção a alta disponibilidade dos equipamentos, a manutenção preditiva vem se tornando um ponto focal das empresas para otimizar seus processos produtivos.

#### 2.1.4 Inteligência Artificial e Aprendizado de Máquina

Rich e Knight (1994) definiram inteligência artificial (IA) como o estudo que visa tornar os computadores capazes de executar tarefas que, até o momento, os humanos fazem melhor. Rosa (2008) resume que IA abrange tudo que envolve aprendizado computacional. Distinguir o material de um objeto, por exemplo, é algo simples para um ser humano através da “inteligência”, mas não há um algoritmo computacional que permita a realização dessa tarefa.

No final do século XX, diversos estudiosos publicaram definições de IA sob quatro aspectos distintos, conforme mostrado na tabela abaixo.

Quadro 1 - Definições de IA a partir sob diferentes pontos de vista

Sistemas que pensam como humanos	Sistemas que pensam racionalmente
<p>“O novo e excitante esforço para fazer computadores pensarem... máquinas com mentes, no sentido literal e completo” (Haugeland, 1985).</p> <p>“A automação de atividades que nós associamos com o pensamento humano, atividades como tomada de decisões, solução de problemas, aprendizado...” (Bellmann, 1978).</p>	<p>“O estudo de faculdades mentais através do uso de modelos computacionais” (Charniak e McDermott, 1985).</p> <p>“O estudo de computações que tornem possível perceber, raciocinar e agir (Winston, 1992).”</p>
Sistemas que agem como humanos	Sistemas que agem racionalmente
<p>“A arte de criar máquinas que realizam funções que requerem inteligência quando realizadas por pessoas” (Kurzwell, 1990).</p> <p>“O estudo de como fazer os computadores realizarem as tarefas as quais, até o momento, as pessoas fazem melhor” (Rich e Knight, 1994).</p>	<p>“Um campo de estudo que busca explicar e emular comportamento inteligente em termos de processos computacionais” (Schalkoff, 1990).</p> <p>“O ramo da ciência da computação que se preocupa com a automação do comportamento inteligente” (Lugar e Stubbiefeld, 1993).</p>

Fonte: Rosa (2008, p. 3).

Diretamente relacionado a inteligência artificial está o conceito de aprendizado de máquina (AM). Esse termo está relacionado à capacidade de induzir uma hipótese com base em experiências adquiridas a partir do conhecimento de eventos passados (CARVALHO *et al.*, 2011). Em computação, os algoritmos com esse propósito aplicam um princípio de inferência em que, com base em exemplos específicos, o sistema chega a conclusões genéricas.

Um algoritmo de AM preditivo é um sistema que gera uma estimativa a partir de um agregado de exemplos rotulados (CARVALHO *et al.*, 2011). Existem dois tipos de algoritmos desta natureza, conforme descritos abaixo.

- a) Problema de classificação: quando o rótulo possui valores nominais. Também chamado de aprendizado de conceitos, tem como resultado um classificador.
- b) Problema de regressão: quando o rótulo possui valores ordenados e infinitos, tem como resultado um regressor.

Ambos possuem uma expressão fundamental que define seu comportamento, conforme a equação 1:

$$D = \{(x_i, f(x_i)), i = 1, \dots, n\} \quad (1)$$

Onde:

$f$  = função desconhecida,

$i$  = número do ponto de observação,

$x_i$  = observação no ponto  $i$ .

Um algoritmo de AM estima um novo valor  $f'$  a partir da função desconhecida  $f$ . Nos próximos capítulos serão definidos alguns métodos preditivos de AM, baseados em quatro classificações: distância, probabilidade, procura e otimização.

Em IA, o aprendizado de máquinas pode ser supervisionado ou não-supervisionado. Redes de aprendizado supervisionado são treinadas com dados pré-classificados e aprendem modificando os pesos de cada conexão dentro da rede, para então criar uma categorização mais precisa dos dados de entrada. Já o aprendizado não-supervisionado consiste em aprender a classificar um conjunto de dados de entrada sem ter sido informado um *dataset* de saídas pré-definido.

#### 2.1.4.1 Métodos Baseados em Distâncias

Este tipo de mecanismo de AM utiliza como base a proximidade entre os dados para realizar as estimativas. Seu princípio considera que dados semelhantes estarão dispostos em locais próximos entre si no domínio (CARVALHO *et al.*, 2011). O método mais utilizado dessa natureza é o algoritmo dos vizinhos mais próximos. Essa técnica é a mais simples de todas as existentes em AM e pode ser utilizada tanto em problemas de classificação, como em problemas de regressão. Ela classifica uma nova informação com base em uma amostra de treinamento que está próxima a ele. Por considerar apenas o conjunto dos vizinhos, podemos defini-lo como um algoritmo preguiçoso (CARVALHO *et al.*, 2011).

#### 2.1.4.2 Métodos Probabilísticos

Existem cenários em que os dados de uma tarefa são aproximados ou incompletos. Nesse tipo de situação, uma alternativa para prever eventos em AM são os métodos probabilísticos bayesianos. Essa técnica tem como princípio que a probabilidade de um evento A ocorrer, dado um evento B, não se limita apenas a relação entre eles, como também à probabilidade do evento A ocorrer independentemente do evento B (MITCHELL, 1997).

A recorrência com que o evento B é observado é capaz de servir como base para realizar uma estimativa da probabilidade de sua ocorrência. De modo similar, é possível estimar o evento B com base na observação de A. Mas como inverter essa lógica e estimar A a partir de B? Nesse ponto está a aplicação do teorema de Bayes, representado matematicamente na equação 2.

$$P(A|B) = \frac{P(B|A)*P(A)}{P(B)} \quad (2)$$

O teorema provê uma forma de calcular a probabilidade de um evento estar contido em uma classe  $P(A|B)$ , com base em três elementos: na probabilidade pura da classe  $P(A)$ , na probabilidade de diversos dados estarem contidos na classe  $P(B|A)$ , e na probabilidade de ocorrência desses objetos ( $P|B$ ).

#### 2.1.4.3 Métodos Baseados em Procura

Supondo a existência de um espaço de possíveis soluções pré-determinado, um problema de AM dessa natureza pode ser definido como um problema de busca em um universo de hipóteses. Um dos métodos de procura mais utilizados é a árvore de decisão e regressão. Uma árvore de decisão divide um problema maior em fatias mais simples, aplicando o princípio de “dividir para conquistar” (CARVALHO *et al.*, 2011). Cada solução menor é disposta em uma árvore que pode resultar, ao final, em uma solução combinada para o problema como um todo.

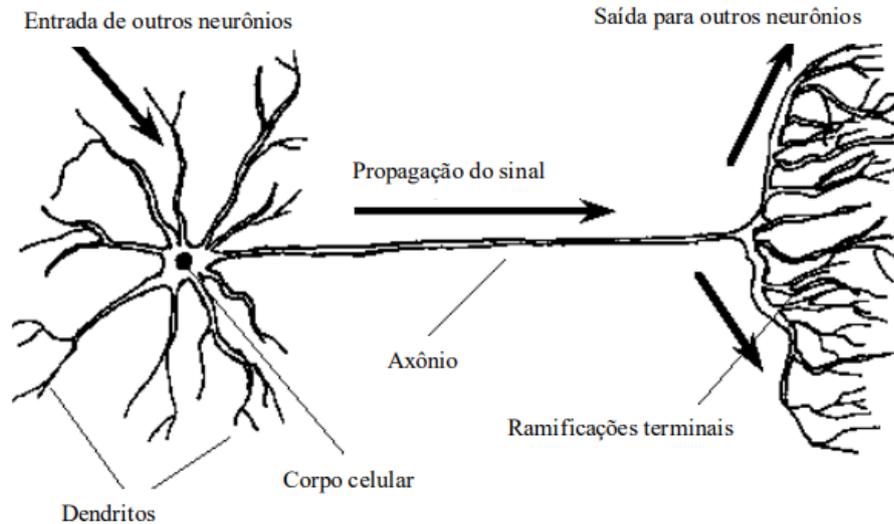
#### 2.1.4.4 Métodos Baseados em Otimização

Um problema de AM pode ser modelado para selecionar uma hipótese a partir da otimização de uma função, em que a solução é encontrada através da maximização ou minimização de uma função objetivo (CARVALHO *et al.*, 2011). Dentre as técnicas mais difundidas que visam treinar um algoritmo de AM através de otimização, estão as redes neurais artificiais (RNAs).

##### 2.1.4.4.1 *Redes Neurais Artificiais*

As RNAs têm como base as redes neurais biológicas. Sua construção é inspirada na forma de funcionamento do sistema nervoso de um indivíduo, e visa adquirir conhecimento de forma semelhante ao cérebro humano. Seu algoritmo de aprendizado utiliza uma técnica de correção de erros, em que é realizada a otimização de uma função quadrática de erro comparando os resultados da rede neural com as amostras de experiências prévias. Na figura 8 está representada uma célula neural biológica:

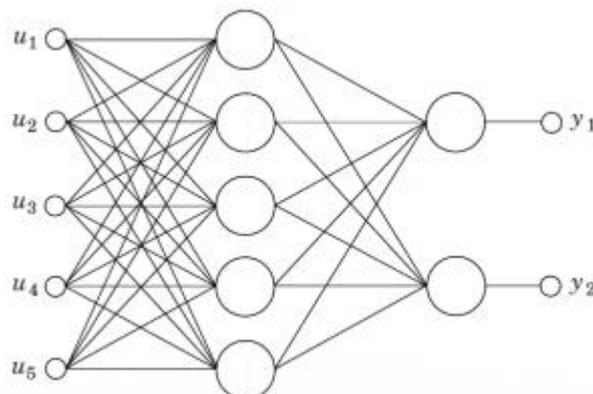
Figura 8 – Representação de uma célula neural biológica



Fonte: adaptado de Haykin (2008).

Essas redes consistem em nós computacionais com unidades de processamento simples, interconectadas entre si (CARVALHO *et al.*, 2011). Tais unidades são os neurônios da RNA, e na maior parte das aplicações possuem pesos associados, que podem ser positivos ou negativos e consideram as entradas de cada neurônio da rede. Os pesos são aferidos durante o processo de aquisição do conhecimento e codificam a informação descoberta pela rede (CARVALHO *et al.*, 2011). Na figura 9 está representado um exemplo de rede neural com cinco entradas e duas saídas:

Figura 9 - Representação de uma rede neural



Fonte: adaptado de Astrom e Hägglund (1995).

Pode-se concluir, portanto, que uma rede neural artificial possui dois elementos fundamentais: arquitetura e aprendizado. Os aspectos estruturais, como quantidade

de neurônios da rede e o modo como eles estão conectados, dizem respeito à arquitetura. Já o aprendizado está relacionado à forma como os pesos são aferidos e quais dados são utilizados pela RNA (CARVALHO *et al.*, 2011).

Um elemento fundamental de qualquer RNA é a sua função de ativação, que define a saída de um neurônio baseada nas informações que estão sendo passadas a ele. Como o nome já diz, ela é responsável por ativar ou ignorar um dado pelo neurônio com base numa relação entre pesos e entradas da rede. Atualmente, os principais tipos conhecidos de funções de ativação são: Sigmoides, ReLU, TanH, Linear e SoftMax. A ReLU, que significa Unidade Linear Retificada, é o tipo de função de ativação mais utilizado atualmente nos algoritmos de redes neurais de classificação disponibilizados pelas linguagens de programação em geral. Sua definição é dada pelas equações 3 e 4:

$$ReLU(x) = \max\{0, x\} \quad (3)$$

$$ReLU'(x) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{c.c.} \end{cases} \quad (4)$$

Onde:

$ReLU(x)$  = saída da função de ativação,

$x$  = dado de entrada,

$ReLU'(x)$  = derivada da função de ativação.

O *Scikit-Learn*, por exemplo, ferramenta de AM da linguagem *Python*, implementa na sua rede neural artificial a função de ativação ReLU.

## 2.2 ESTADO DA ARTE

Para orientar o leitor sobre o cenário científico atual e explorar possíveis resultados que possam ter impacto no cumprimento dos objetivos, se faz necessário um estudo de artigos publicados que tenham relação com o tema e os conceitos abordados.

### 2.2.1 Previsão da Manutenção

A manutenção preditiva é uma prática presente em equipamentos das mais diversas áreas da ciência, como por exemplo a medicina. Em estudo publicado na 2ª

Feira Internacional em Avanços na Engenharia Biomédica, Jezzini *et al.* (2013) compararam dois grupos de instrumentos médicos, onde no primeiro grupo foi implementado um programa de manutenções programadas (proativa, preditiva e preventiva) e o segundo foi operado até a falha, sendo realizadas apenas manutenções corretivas conforme a necessidade. O objetivo dos pesquisadores era comprovar a diferença de tempo de operação e quantidade de falhas inesperadas que os equipamentos do grupo de manutenção corretiva teriam em relação ao grupo de manutenções programadas. Após a execução dos testes e análise dos dados coletados, os resultados foram taxativos: o primeiro grupo apresentou tempo de inatividade e número de falhas muito menor do que o segundo grupo.

E não só nas áreas diretamente ligadas a tecnologia estão presentes estudos para otimizar e minimizar falhas com base em processos de manutenção preditiva. Conforme Shimada e Sakajo (2016), que propuseram uma abordagem estatística para reduzir falhas em instalações prediais, é possível determinar quando direcionar trabalhadores de manutenção para uma construção através do monitoramento do estado de saúde das instalações, realizado por meio de dados de sensibilidade coletados em determinadas séries de tempo. Os resultados obtidos provaram que o método proposto é capaz de diminuir o número de falhas e mitigar a quantidade de profissionais de manutenção nas instalações.

Outra grande aliada da manutenção preditiva nos tempos atuais é a sustentabilidade, mais especificamente relacionada à evolução das alternativas de energia limpa. Em artigo publicado para o “*2018 IEE Data Science Workshop*”, Huuhtanen e Jung (2018) aplicaram uma técnica de IA conhecida como Redes Neurais por Convolução para prever a curva de potência diária de painéis fotovoltaicos funcionais, baseada nas curvas dos painéis vizinhos. Para identificar um equipamento com defeito, são avaliados desvios significativos entre a curva esperada e a medida, levando em consideração objetos próximos (causando sombras) e as condições climáticas. Como resultado, foi observada uma grande precisão nos prognósticos gerados pela técnica proposta.

Quanto menos tolerante a períodos de indisponibilidade seja um processo ou serviço, maior é o impacto da inexistência de planejamento e previsão da manutenção, pois a ocorrência de falhas é sempre inesperada. E se paramos para pensar em setores altamente sensíveis a imprevistos e que impactam milhões de pessoas diariamente, certamente um dos mais lembrados será a aviação. Segundo Vianna e

Yoneyama (2017), que desenvolveram uma ampla técnica de otimização preditiva para sistemas de aeronaves submetidos a múltiplos perfis de desgaste, quando uma aeronave deixa de ter condições de operação, o custo atrelado é consideravelmente alto e impacta significativamente a disponibilidade do serviço como um todo. Com base nisso, os pesquisadores propõem uma metodologia de manutenção preventiva focada na minimização dos custos operacionais, com base em um modelo matemático chamado filtro de Kalman, para estimar valores futuros de degradação do sistema. O filtro de Kalman é um conjunto de equações matemáticas capazes de estimar o estado de um processo, minimizando a média do erro quadrático (WELCH e BISHOP, 2006). Através de testes de campo em sistemas hidráulicos, os autores comprovaram a eficiência e os benefícios da técnica proposta.

Além de aplicações específicas como as citadas até agora, existem também estudos mais amplos de aplicações da manutenção preditiva no cenário científico. É o caso da abordagem proposta por Lazarescu *et al.* (2017), que descreve métodos para realizar um diagnóstico preciso da condição de dispositivos elétricos comutáveis de alta tensão, baseado em algoritmos de lógica difusa. O resultado alcançado nos testes com diferentes equipamentos foi o aumento da eficiência funcional, reduzindo os tempos de indisponibilidade dos dispositivos. Segundo os autores, a aplicação pode ser estendida para qualquer equipamento de alta tensão, aumentando sua confiabilidade e eficiência.

### **2.2.2 Previsão da Manutenção em Motores**

Considerando todos os custos de manutenção de uma aeronave, a parcela mais significativa está relacionada a reparos no motor. Jiayang *et al.* (2015) realizaram uma análise minuciosa dos modos de falha apresentados pelos motores dos aviões e, com base nela, buscaram uma alternativa para prever potenciais problemas antes que eles ocorressem, além de estimar o tempo de vida útil restante (RUL) do equipamento. A partir disso, os pesquisadores criaram um modelo baseado em máquina de vetores de suporte – ferramenta de *machine learning* que analisa dados e reconhece padrões – capaz de descobrir tendências de desgaste do motor. Outra aplicação semelhante foi estudada por Mathew *et al.* (2017), que utilizaram dez algoritmos existentes de previsão do tempo de vida útil (RUL) para definir o mais preciso aplicado ao motor de propulsão denominado *turbofan*. A partir deles,

desenvolveram uma bateria de testes e compararam os resultados reais com os previstos, para então eleger o melhor modelo.

Voltando ao ambiente terrestre, existem ainda aplicações que visam o prognóstico de falhas em motores a combustão de automóveis. É o caso do artigo de Landolsi, Jammoussi e Makki (2017), que propõe uma técnica de monitoramento da saúde do filtro de ar em motores de combustão interna baseado em modelos de fluxo de ar para avaliar a integridade do filtro e estimar a pressão a jusante. A partir de dados experimentais coletados, foi possível identificar a eficácia do modelo proposto.

### **2.2.3 Previsão da Manutenção em Motores Elétricos**

A indústria de mineração possui diversas máquinas críticas em funcionamento por meio de motores elétricos e falhas inesperadas podem trazer impactos fortemente nocivos aos processos. Por esse motivo, Antonino-Daviu *et al.* (2018) buscaram alternativas para um diagnóstico confiável do estado de motores de grande porte operando em instalações de mineração. Neste estudo, os pesquisadores observaram que o monitoramento de grandezas elétricas do equipamento em operação é capaz de traduzir a condição de diversos componentes do motor, como o rotor e os rolamentos. Para tanto, os autores propuseram aprimorar o método tradicional de análise de correntes conhecido como MSCA (*Motor Signature Current Analysis*) com uma técnica baseada em transitórios, que se mostrou mais eficaz e vantajosa nos testes comparativos.

Falhas inesperadas em motores que atuam em processos críticos podem causar grande impacto em toda a produção de uma empresa. Com base nisso, Chang, Hong e Chang (2018) desenvolveram um programa de manutenção preventiva baseado em uma máquina de vetores de suporte. O programa classifica automaticamente os defeitos e os resultados demonstraram uma taxa de acerto de 98%.

A termografia infravermelho é uma tecnologia que recentemente vem sendo utilizada para análise da condição de motores elétricos. Conforme Perez e Daviu (2017), ao longo dos últimos anos essa tecnologia vem sendo frequentemente aplicada em instalações elétricas e equipamentos estáticos e os resultados a respeito da detecção de comportamentos estranhos são comprovadamente eficazes. Em seu

estudo, os autores destacam que para incrementar programas de manutenção preditiva utilizando a tecnologia infravermelho, é necessária a concepção de novos métodos que facilitem a interpretação das imagens, e com base nelas, sejam tomadas decisões quanto ao estado do motor. Para tanto, o artigo propõe um método baseado no estudo das isotermas relacionadas às imagens infravermelho e os resultados indicam a detecção correta de diversos tipos de falha.

Os motores de corrente contínua classificados como *Brushless* (sem escovas) destacam-se pela sua longevidade, eficiência e extrema confiabilidade em termos de integridade funcional. Tais características influenciam os usuários desse tipo de equipamento a negligenciarem o diagnóstico de falhas de longo prazo, decorrentes do desgaste e decomposição dos seus componentes. Baseado nisso, Xuan *et al.* (2017) utilizaram uma técnica de análise vibratória do motor sem escovas com o objetivo de identificar as falhas apresentadas. A partir disso, os pesquisadores desenvolveram um modelo que determina a severidade das falhas de forma quantitativa e auxilia na avaliação do estado do motor.

#### **2.2.4 Previsão de Falhas em Motores Elétricos de Indução**

Considerando sua vasta gama de aplicabilidades, o baixo custo e a alta eficiência, segundo Abdullah (2017), o motor de indução é o mais utilizado na indústria dentre todas as classificações disponíveis. Para Hsiao e Liu (2017), que desenvolveram uma análise das falhas em motores de indução utilizando abordagens de diagnóstico existentes na literatura, a propensão desse tipo de equipamento sofrer falhas prematuras quando operado em carga industrial motivou a criação de diversos sistemas de monitoramento da sua condição. Eles defendem, porém, que para construir um modelo preditivo realmente coeso e eficiente, é necessário utilizar meios computacionais de simulação para entender seu comportamento.

Um dos modelos computacionais probabilísticos já utilizados em um estudo de previsão de falhas para motores de indução é o Bayesiano, proposto por Lakehal e Ramdane (2017). Após identificar os elementos fundamentais de funcionamento do motor, como o comportamento do sistema interno e seus mecanismos de degradação, os autores definiram a estrutura gráfica do modelo Bayesiano, capaz de calcular o valor de probabilidade das falhas. Os resultados coletados demonstraram uma alta taxa de acerto nas previsões de falha realizadas.

A evolução dos veículos automotivos elétricos está diretamente relacionada ao avanço nos estudos de análise e previsão das condições dos motores que fazem parte da sua composição. Segundo Praneeth e Williamson (2017), quando os motores de indução de alto desempenho utilizados para movimentar veículos elétricos e veículos híbridos apresentam falhas no estator, uma anomalia generalizada ocorre no controle de velocidade e torque do equipamento, causando a paralisação imediata do veículo. Dado este cenário, os pesquisadores propuseram um algoritmo que, com base em previsões do nível de criticidade das falhas e na otimização do controle de comutação do motor, tem como objetivo evitar o desligamento do sistema em ocasiões de falha. Para identificar os níveis de corrente do motor em modo de operação estável e em modo de falha, é utilizado o método MCSA (*Motor Current Signature Analysis*). Baseado na comparação dos valores descobertos, os parâmetros de funcionamento são reconfigurados para uma região segura em que a condução é operada em baixa velocidade, mantendo o motor em funcionamento.

Sen e Kul (2017) desenvolveram um sistema de monitoramento e previsão de desvios para o motor de indução através de IoT (Internet das coisas), baseado no protocolo TCP/IP sem fio. Utilizando sensores de corrente de Efeito *Hall*, construíram os periféricos de hardware que foram acoplados aos motores e um software supervisor que recebe as informações de todas as máquinas e exibe através de uma interface de monitoramento. O sistema foi testado em uma fábrica com produção ininterrupta e os resultados demonstraram melhorias significativas no processo de produção quando comparados ao cenário anterior.

Ainda que atualmente existam diversos estudos de diagnóstico e previsão da manutenção para motores de indução, um tipo de falha que a maior parte das soluções conhecidas não consegue identificar é a chamada falha de baixa energia, como por exemplo as que ocorrem nos rolamentos mecânicos do equipamento. Por isso, Ghods e Lee (2014) propõem uma solução baseada na transformada discreta de *Wavelets* (DWT) para detectar e principalmente prever falhas de baixa energia no domínio da frequência.

Outro estudo que analisa um tipo específico de falha no motor de indução é o de Subha, Kumar e Veni (2018), que propõe um método capaz de identificar a falha de curto-circuito no enrolamento do estator do motor de indução trifásico. A técnica de lógica difusa é utilizada para definir o estado do motor baseado nos valores instantâneos de corrente no estator, classificando assim o tipo de falha ocorrido no

motor. Os testes foram realizados através de simulação computacional com o *software MATLAB - Simulink*, e os autores concluíram que o método se mostrou eficiente e seguro. A mesma falha explorada pelos autores supracitados é estudada por Lashkari *et al.* (2016), que utilizam redes neurais artificiais para detectar cenários de curto-circuito no estator. Em seguida, é utilizada a lógica Fuzzy para reduzir significativamente o efeito das variações de carga no monitoramento das anomalias. Como resultado foi destacada a facilidade de implementação do sistema proposto, além do ótimo desempenho na previsão de falhas simulado e experimentalmente medido.

Além do trifásico, o motor de indução monofásico também foi alvo de estudo para previsão de falhas utilizando RNA (redes neurais artificiais). Morsalin *et al.* (2014) propuseram uma técnica para detectar a falha de curto-circuito inter-turno do estator através do modelo heurístico não-invasivo por RNA. O experimento atingiu resultados altamente satisfatórios, com melhorias na eficiência, confiabilidade, economia e inteligência em relação ao sistema existente.

Seguindo o estudo de aplicações de previsão de falhas com inteligência artificial, Patel e Bhalja (2015) tratam o diagnóstico de quebra da barra do rotor de um motor de indução em seu artigo. Os pesquisadores dividem o problema em dois modelos matemáticos, simulados computacionalmente: motor saudável e motor com defeito. São utilizados números variados de barras defeituosas em diversas condições de falha. Tais dados alimentam a rede neural, que tem como resultado final a análise da condição do motor. Testes realizados comprovaram a eficácia do modelo proposto, segundo os autores.

A partir da leitura dos artigos científicos citados neste capítulo, é possível definir os procedimentos teórico-práticos que serão realizados para cumprir os objetivos deste trabalho, bem como planejar a análise dos resultados após seu desenvolvimento.

### 3 METODOLOGIA

Para explorar as consequências da falha no funcionamento do motor, bem como construir o algoritmo de previsão, a metodologia teve como base a utilização de um equipamento simulador de falhas construído pela empresa *SpectraQuest*<sup>®</sup> chamado *Machinery Fault Simulator*<sup>®</sup> (MFS), que possui um motor AC de 0,5 HP de potência acoplado a uma estrutura mecânica, conforme representado na Figura 8. Segundo o manual do fabricante, o MFS<sup>®</sup> é uma ferramenta criada com o objetivo de auxiliar na definição de uma rotina de manutenção preditiva sem necessidade de interromper processos produtivos reais.

Ainda que possua uma estrutura física simplificada, as principais características do MFS<sup>®</sup> são a robustez e a versatilidade. Todos os seus componentes foram projetados com alta margem de segurança para que pudessem ser operados sem influências vibratórias nocivas ao seu funcionamento. Além disso, a ferramenta é capaz de ser configurada não só para trabalhar com uma única falha, como também para simular diversas falhas combinadas em um ambiente controlado. Sua estrutura física está representada na figura 10.

Figura 10 – Estrutura Física do MFS<sup>®</sup>



Fonte: *SpectraQuest*<sup>®</sup> (s.d.)

Para coletar e analisar os dados associados à operação do MFS<sup>®</sup>, será utilizado um software da *SpectraQuest*<sup>®</sup> chamado *VibraQuest Pro*<sup>®</sup>. Ele permite a aquisição simplificada das informações de funcionamento do equipamento monitorado, além de análise e geração de relatórios da operação. O principal propósito do *VibraQuest*<sup>®</sup> é permitir comparações rápidas de sinais tanto no domínio do tempo quanto no domínio da frequência.

Uma das falhas compatíveis com o MFS<sup>®</sup> e que foi explorada neste trabalho é a de desalinhamento. O MFS<sup>®</sup> foi configurado para simular a operação do motor com o eixo da estrutura mecânica desalinhado em relação ao acoplamento, para que a vibração de cada um dos sensores pudesse ser medida e posteriormente analisada. Através do monitoramento desses elementos com o MFS<sup>®</sup> em operação, foram coletadas as informações úteis para diagnóstico do seu estado e para construção do modelo de predição.

### 3.1 SENSORES DE VIBRAÇÃO DO MFS<sup>®</sup>

O equipamento de simulação de falhas MFS<sup>®</sup> possui sete acelerômetros integrados à sua estrutura física, responsáveis por captar os sinais de vibração da máquina. O modelo de todos os acelerômetros é o mesmo: 608A11 do fabricante *IMI Sensors*<sup>®</sup>. Suas especificações estão descritas no quadro 2:

Quadro 2 - Especificações técnicas do acelerômetro 608A11

Sensibilidade ( $\pm 15\%$ )	$100 \frac{\text{mV}}{\text{g}}$
Intervalo de medição	$\pm 50 \text{ g} = 490 \frac{\text{m}}{\text{s}^2}$
Intervalo de frequência	0,5 Hz a 10 kHz
Tensão de excitação	18 V <sub>dc</sub> a 28 V <sub>dc</sub>
Intervalo de temperatura	-65 °F a 250 °F
Impedância de saída	< 150 $\Omega$
Não-linearidade	$\pm 1 \%$
Ruído espectral (10 Hz   100 Hz   1 kHz)	$8 \mu \frac{\text{g}}{\sqrt{\text{Hz}}}   5 \mu \frac{\text{g}}{\sqrt{\text{Hz}}}   4 \mu \frac{\text{g}}{\sqrt{\text{Hz}}}  $

Fonte: elaborado pelo autor.

Os dois primeiros canais estão conectados ao motor elétrico, na parte frontal e superior de sua estrutura. Outros cinco sensores estão ligados aos dois acoplamentos da estrutura mecânica; três ao acoplamento que conecta o motor ao eixo e dois ao acoplamento da extremidade oposta ao motor. O último acelerômetro fica sobre o redutor do MFS<sup>®</sup>. O mapeamento dos sensores no simulador está descrito no quadro 3:

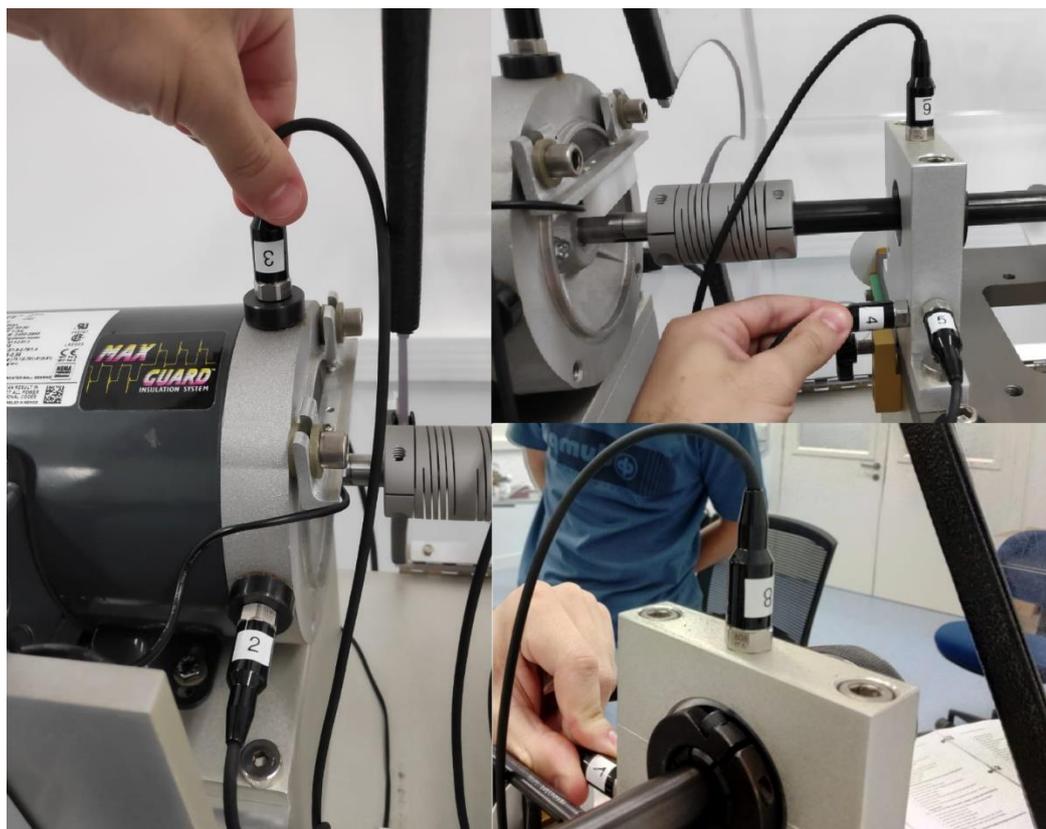
Quadro 3 - Sensores de vibração do MFS<sup>®</sup>

Canal	Posição	Nome utilizado
1	Superior ao motor	MotorUp
2	Frontal ao motor	MotorFront
3	Lateral ao acoplamento 1	Acop1Side
4	Frontal ao acoplamento 1	Acop1Front
5	Superior ao acoplamento 1	Acop1Up
6	Frontal ao acoplamento 2	Acop2Front
7	Superior ao acoplamento 2	Acop2Up

Fonte: elaborado pelo autor.

No equipamento simulador, o canal 1 é um amperímetro conectado ao motor elétrico. Como neste trabalho o enfoque está na análise de vibração, converteremos os canais de vibração iniciando a contagem no primeiro sensor de vibração. Na figura 11 estão as fotos detalhando os canais do MFS<sup>®</sup>:

Figura 11 - Sensores do MFS®



Fonte: elaborada pelo autor.

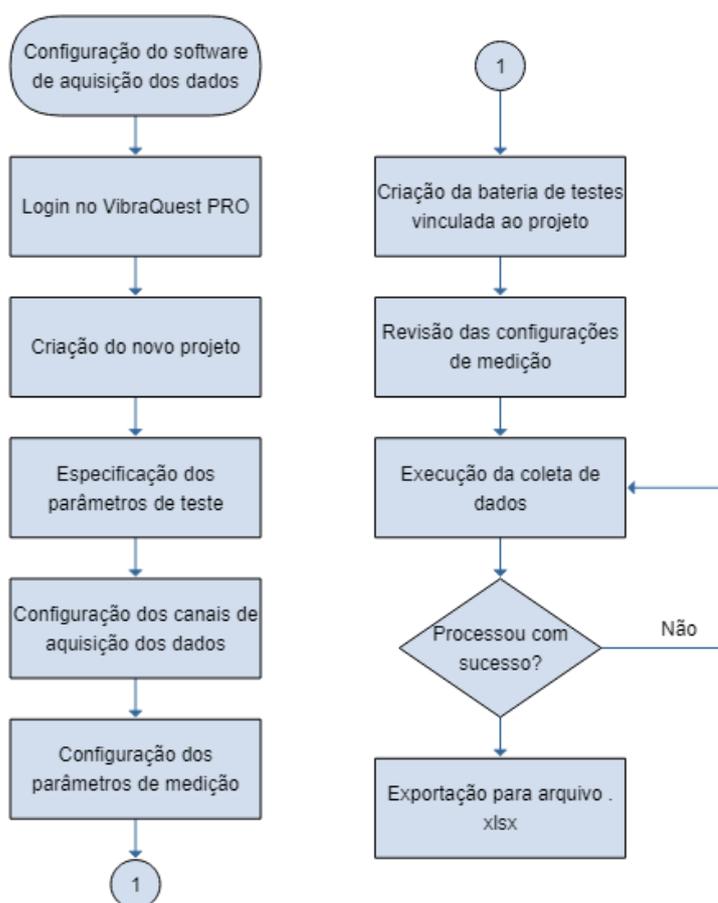
### 3.2 AQUISIÇÃO DOS DADOS DE VIBRAÇÃO

Para construir o preditor de desalinhamento, foi necessário extrair as informações de vibração para um ambiente externo ao do MFS®. Com isso, foi possível plotar e processar os dados de diversas formas, sem depender apenas dos recursos que a ferramenta disponibiliza. Com esse propósito, *software* e *hardware* foram configurados conforme descrito a seguir.

#### 3.2.1 Configuração do Software

A configuração do ambiente de aquisição dos dados utilizado para coletar os sinais de vibração do motor sem falhas e do motor desalinhado está representada na figura 12:

Figura 12 - Fluxograma de configuração do *VibraQuest PRO*®



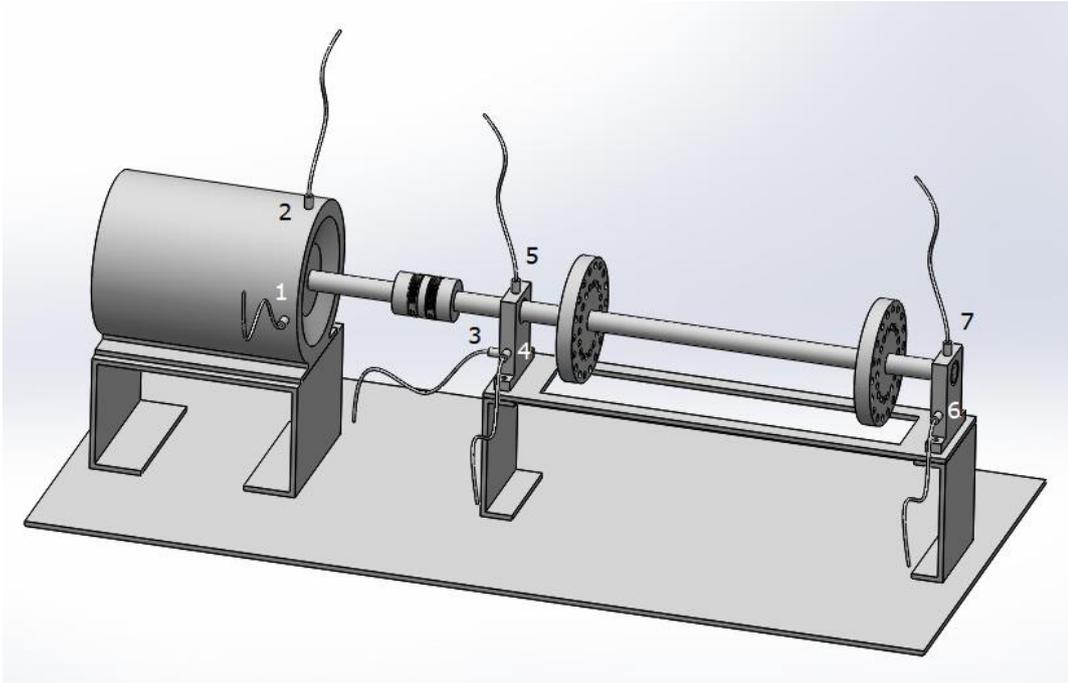
Fonte: elaborada pelo autor.

O software foi configurado para executar um ciclo de testes com uma taxa de amostragem de 4 kHz, totalizando 327.680 valores de aceleração medidos para cada um dos sensores presentes no MFS®.

### 3.2.2 Configuração do Hardware

O primeiro ensaio no equipamento de simulação foi realizado sem nenhuma falha presente na estrutura. Após isso, um desalinhamento angular foi forçado em um dos acoplamentos da máquina. A figura 13 ilustra os componentes principais do MFS®, bem como os seus canais de vibração identificados numericamente:

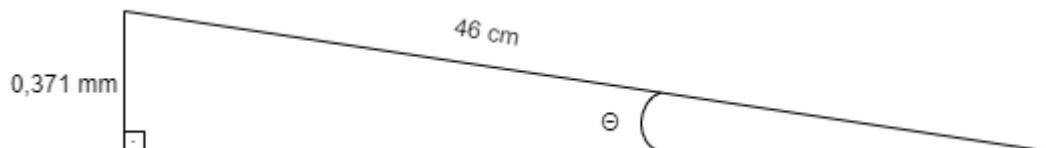
Figura 13 - Estrutura do MFS<sup>®</sup> com canais numerados



Fonte: elaborada pelo autor.

A extremidade conectada ao acoplamento 1 da base metálica localizada abaixo do eixo de rotação do MFS<sup>®</sup> foi deslocada em 15 milésimos de polegada através de um parafuso, gerando um desalinhamento angular paralelo ao eixo. O ângulo de desalinhamento foi calculado através da figura 14:

Figura 14 - Representação trigonométrica do desalinhamento



Fonte: elaborada pelo autor.

O ângulo  $\Theta$  pode ser calculado utilizando identidades trigonométricas:

$$\sin \Theta = \frac{0,371 \text{ mm}}{46 \text{ cm}} = 8,065 * 10^{-4} \quad (5)$$

$$\Theta = \arcsin(8,065 * 10^{-4}) = 0,0462^\circ \quad (6)$$

Onde:

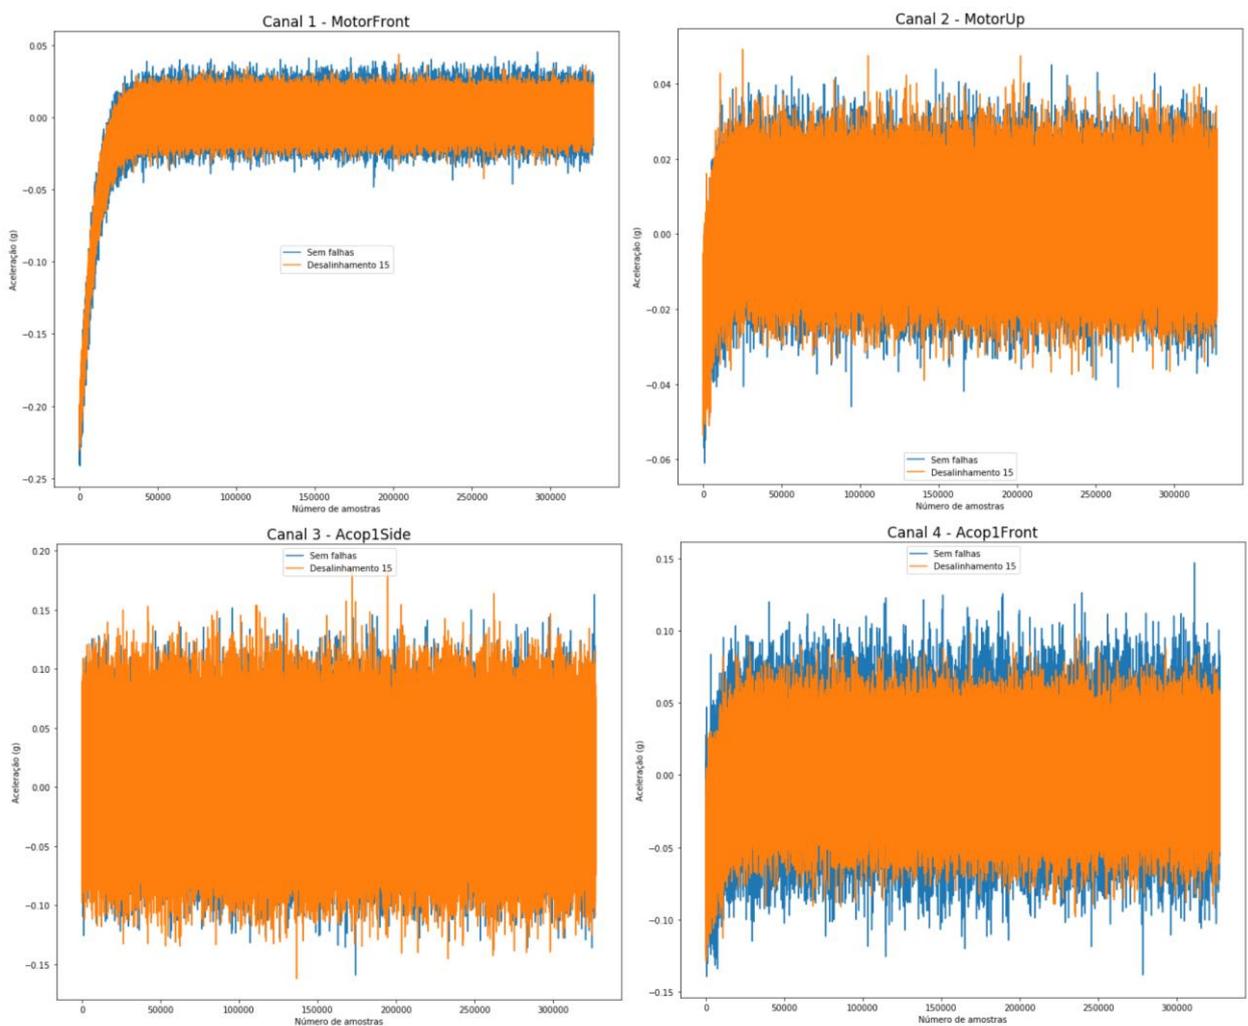
$\Theta$  = ângulo de desalinhamento.

O desalinhamento simulado, portanto, não foi um valor exagerado ou irrealista, e sim um valor praticamente imperceptível a olho nu, para tratar o princípio do defeito. Antes de iniciar a coleta dos dados, o motor foi preparado a uma frequência de rotação de 20 Hz.

### 3.3 PRÉ-PROCESSAMENTO DOS DADOS

Após a extração dos dados do MFS<sup>®</sup>, foi utilizada a linguagem de programação Python e o *software* Jupyter Notebook para plotar os gráficos de aceleração de cada um dos sensores em função do número de amostras para motor bom e motor desalinhado. O resultado dos canais 1 a 4 está na figura 15:

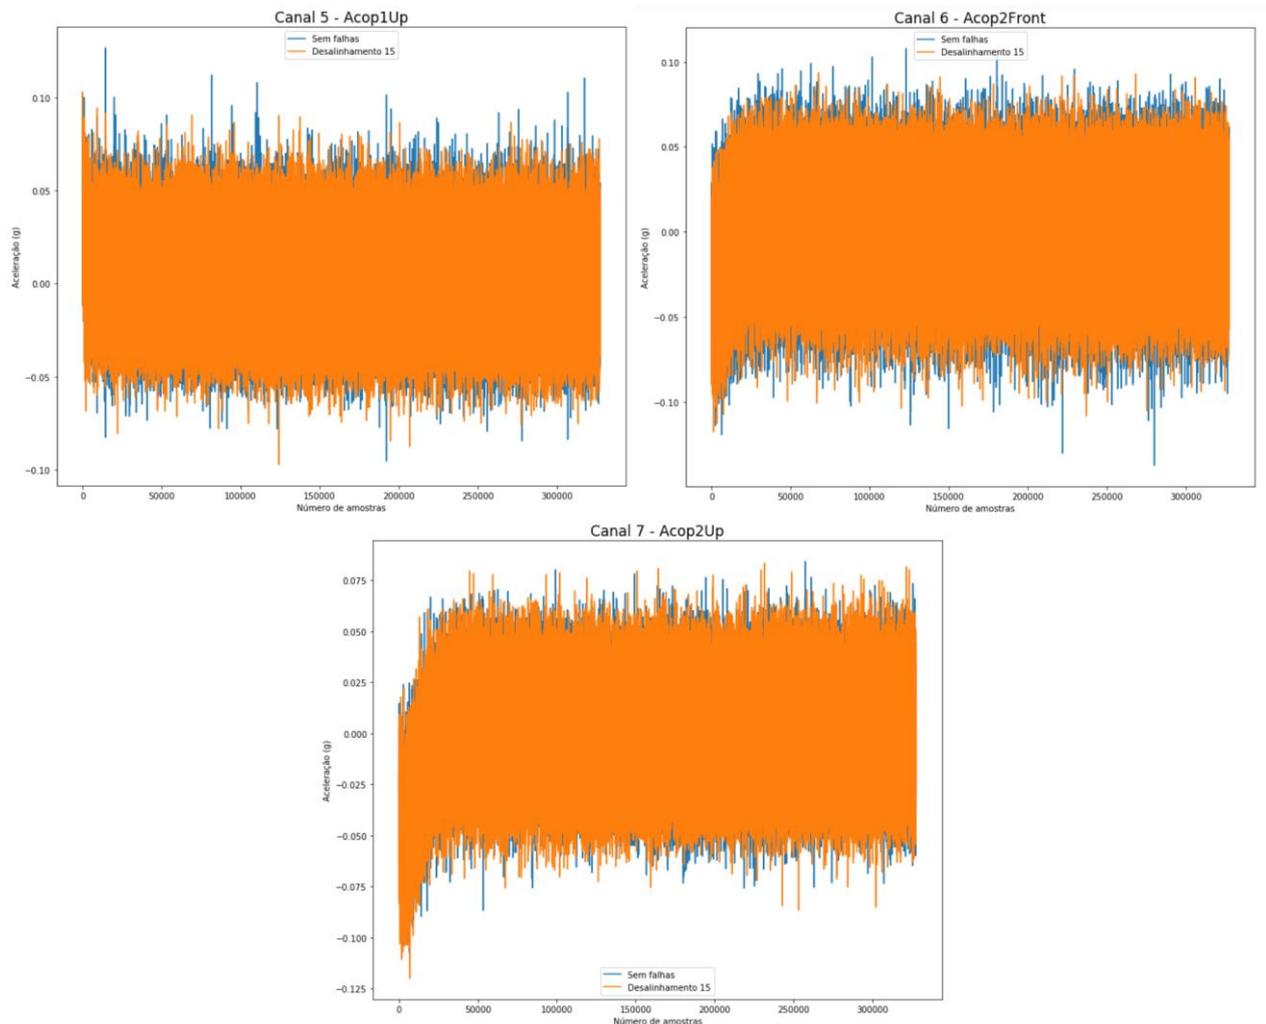
Figura 15 - Gráfico de aceleração dos canais 1 a 4



Fonte: elaborada pelo autor.

Dos quatro canais acima, apenas o 4 apresenta diferenças visíveis de aceleração no domínio plotado. Na figura 16 estão representados os demais canais:

Figura 16 - Gráfico de aceleração dos canais 5 a 7



Fonte: elaborada pelo autor.

Como pode ser observado, os gráficos de vibração puros não demonstram diferenças claras entre o motor sem falhas e o motor desalinhado. Com isso, os sinais foram decompostos em transformadas de Fourier (FFT) para analisar os espectros no domínio da frequência. Abaixo a expressão base da FFT, representado na equação 7:

$$\mathcal{F}\{f(x)\} = \int_{-\infty}^{\infty} f(x)e^{-iwx} dx \quad (7)$$

Onde:

$\mathcal{F}\{f(x)\}$  = transformada de Fourier,

$f(x)$  = função no espaço amostral,

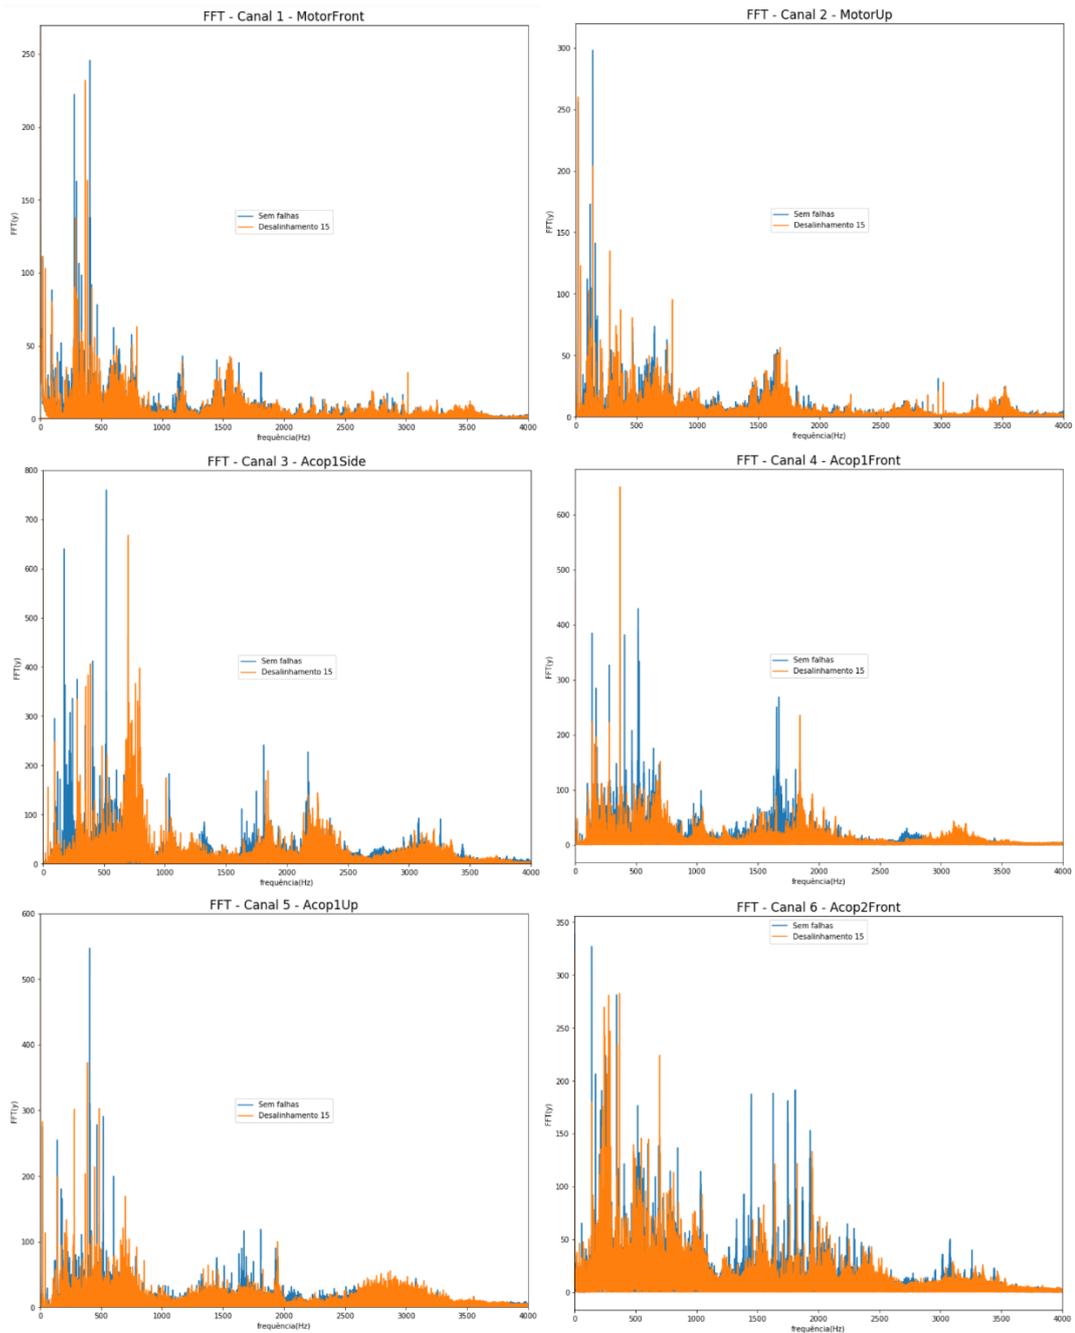
$e$  = número de Euler,

$i = \sqrt{-1}$ ,

$w$  = frequência angular.

Os espectros gerados nos canais 1 a 6 estão representados na figura 17:

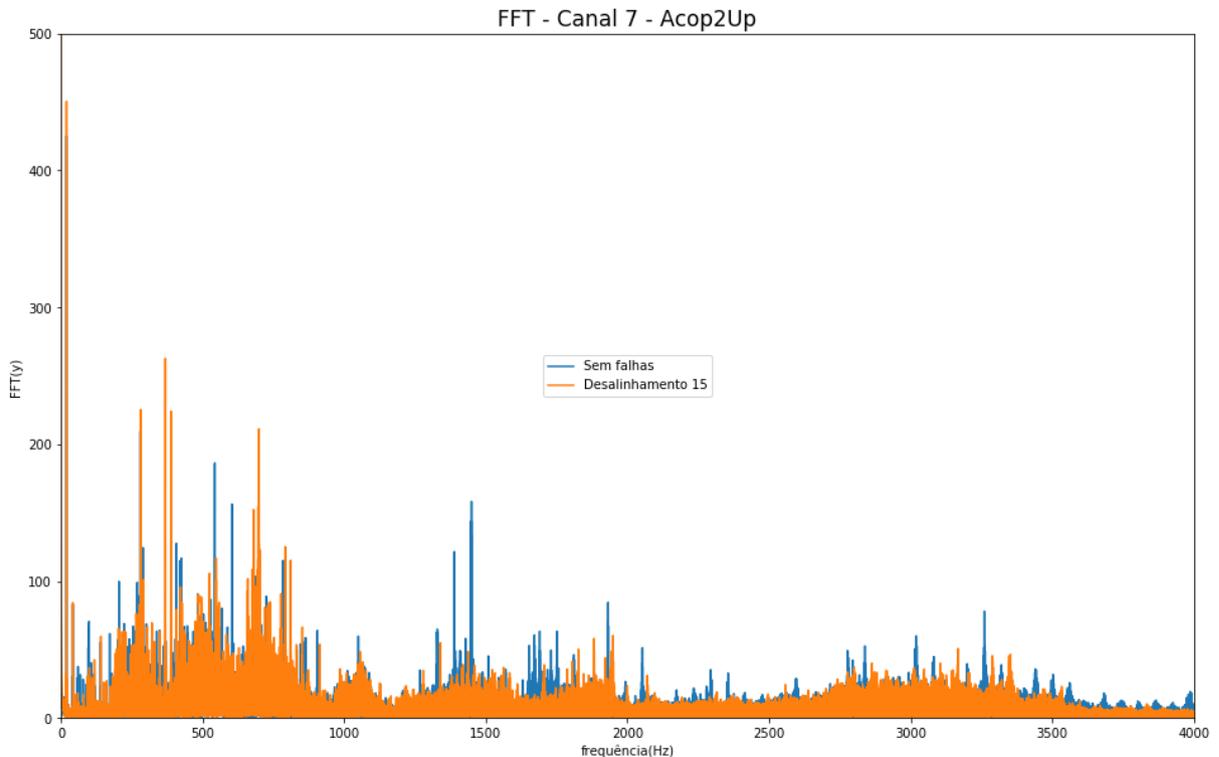
Figura 17 - FFT dos canais 1 a 6



Fonte: elaborada pelo autor.

A FFT do sétimo e último sensor apresentou o comportamento ilustrado na figura 18:

Figura 18 - FFT do canal 7



Fonte: elaborada pelo autor.

Através dos espectros, foi possível verificar diferenças significativas entre a operação do motor com e sem defeito. A partir desta percepção, os espectros de cada canal, com e sem a falha, foram separados em gráficos distintos e a energia dos sinais de vibração foi calculada através do Teorema de Parseval (equação 8):

$$E = \frac{\sum_k^n \mathcal{F}\{f(x)\}^2}{n} \quad (8)$$

Onde:

$E$  = energia do espectro,

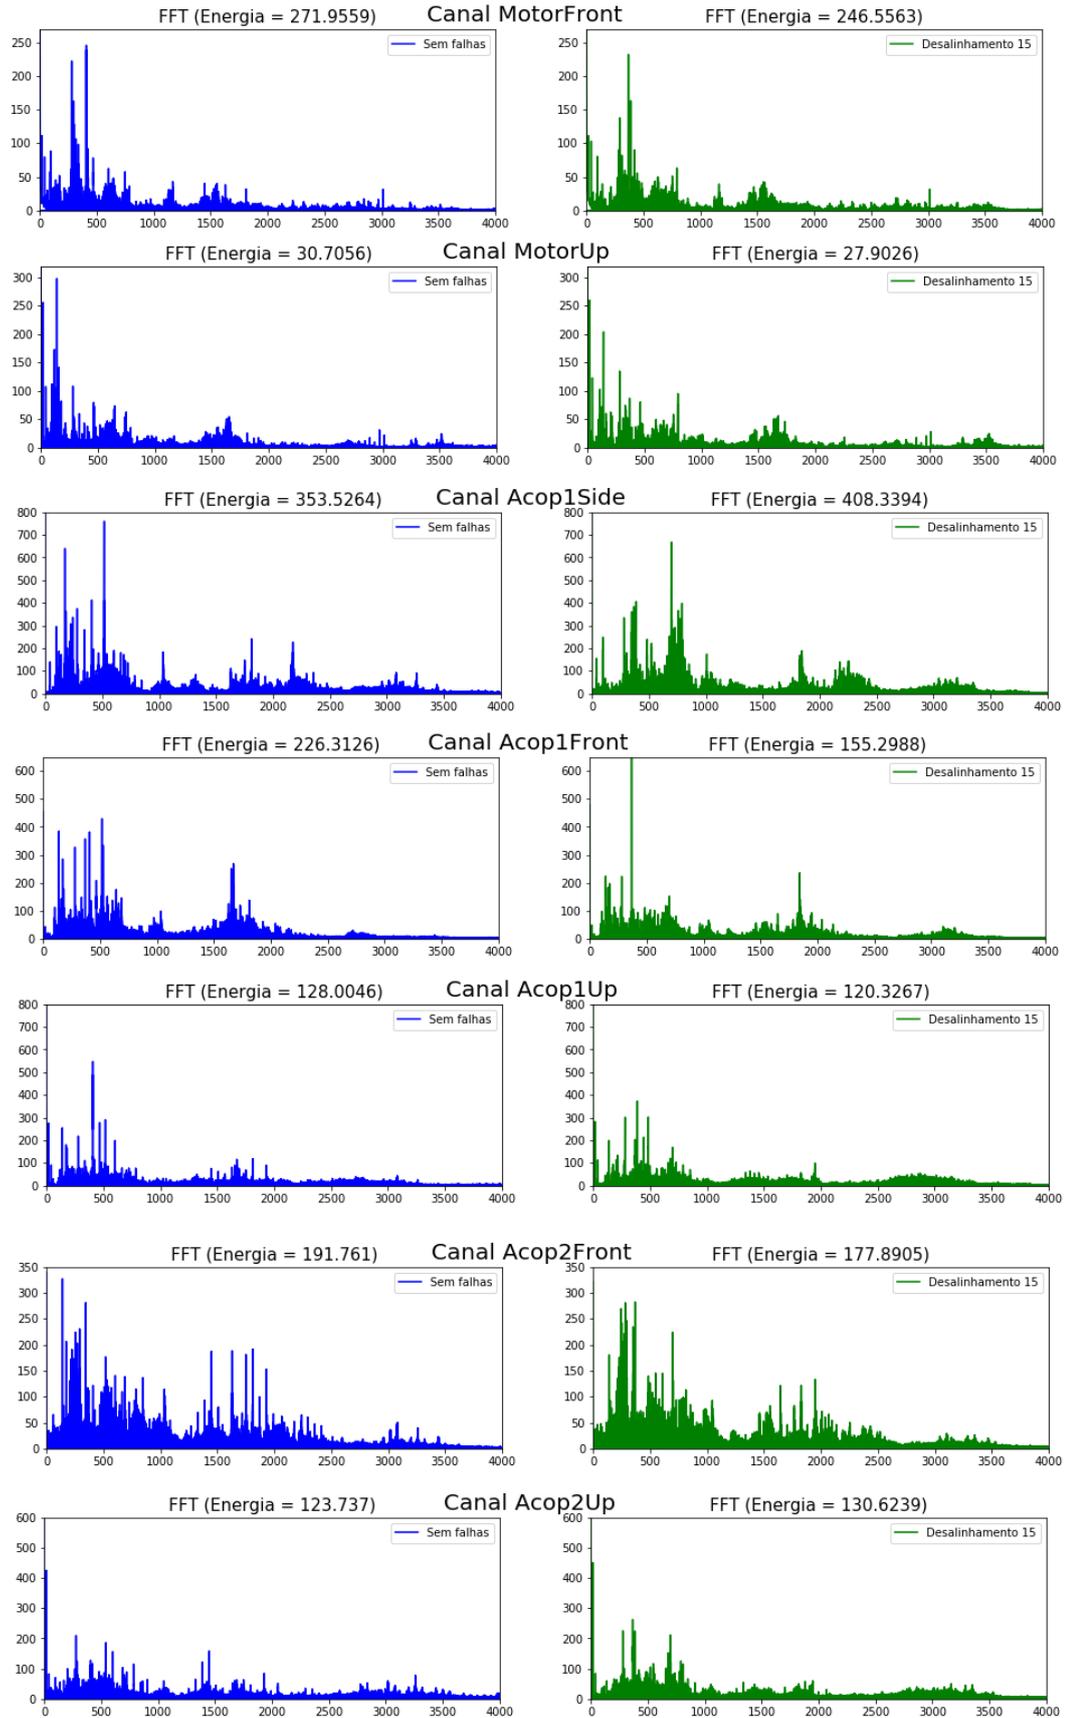
$k$  = limite mínimo do somatório,

$n$  = número de amostras,

$\mathcal{F}\{f(x)\}$  = transformada de Fourier

Os gráficos gerados, bem como o valor de energia calculado para cada um deles estão demonstrados na figura 19:

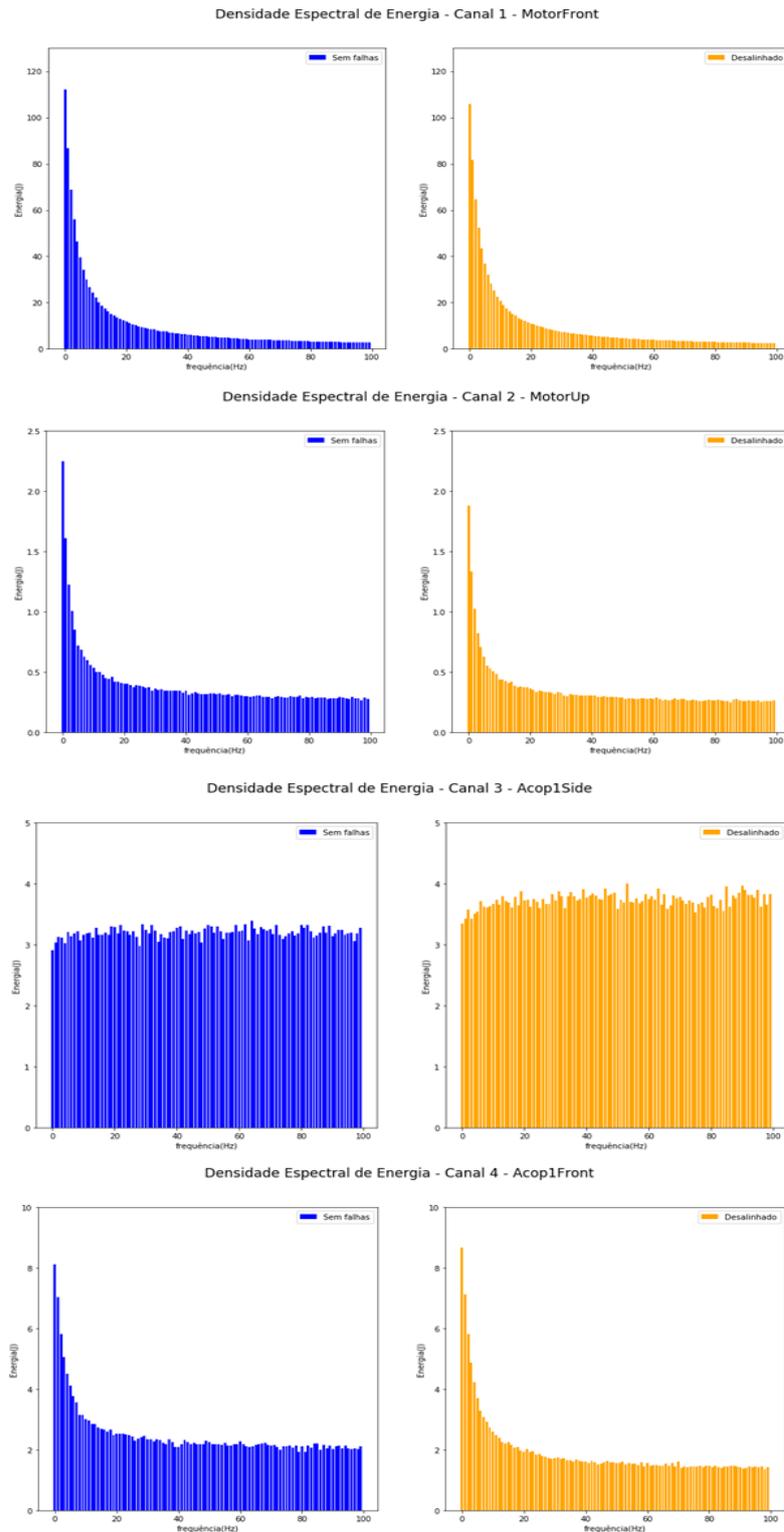
Figura 19 - FFT por falha e energia do espectro



Fonte: elaborada pelo autor.

Em todos os canais, diferenças nos valores de energia puderam ser observados entre o motor desalinhado e sem falha. Para limitar a quantidade de informações associada aos sinais, a quantidade de amostras foi dividida em 100 grupos para cada um dos sensores, para então calcular as densidades espectrais de energia em cada grupo. Os gráficos contendo os agrupamentos de energia dos canais 1 a 4 estão demonstrados na figura 20:

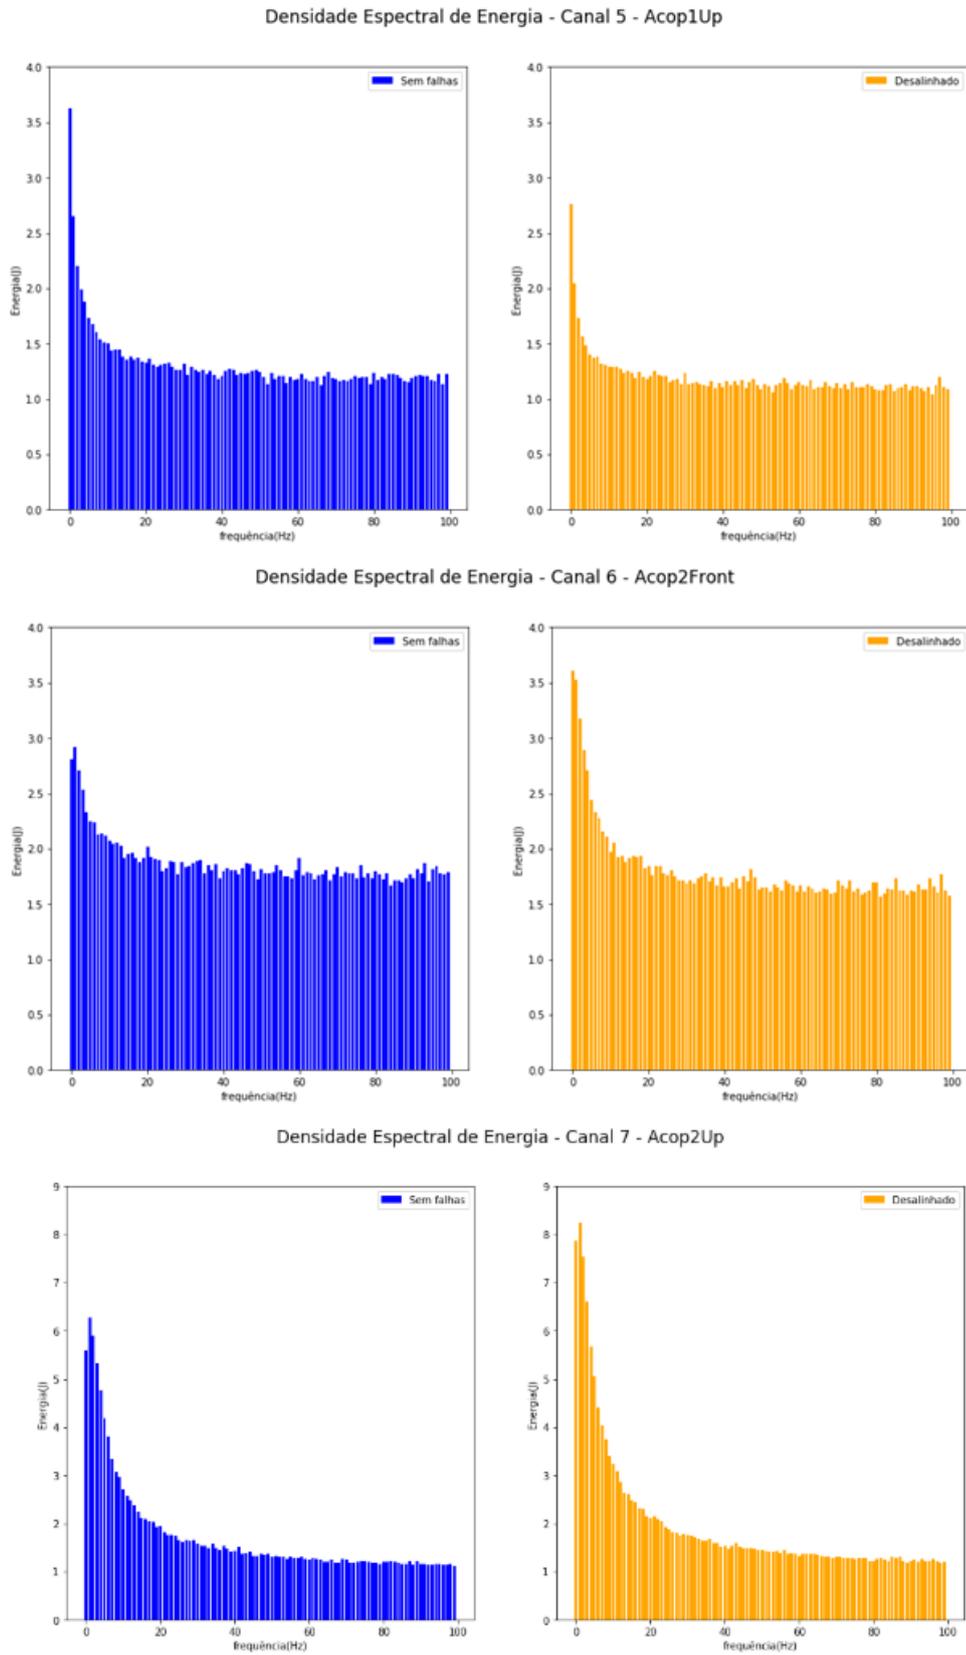
Figura 20 - Espectros de energia dos canais 1 a 4



Fonte: elaborada pelo autor.

É possível identificar que, dentre os quatro primeiros canais, o 3 apresenta o comportamento mais uniforme de energia ao longo do espectro. Abaixo estão ilustrados os canais 5 a 7, na figura 21:

Figura 21 - Espectros de energia dos canais 5 a 7



Fonte: elaborada pelo autor.

Com base nos valores de energia calculados, foi construída uma matriz de 200 linhas (100 valores para motor sem falha e 100 valores para motor desalinhado) e sete colunas (uma para cada canal) para alimentar o aprendizado de máquina, que será explicado no próximo texto.

### 3.4 PROCESSAMENTO DOS DADOS

Para classificar o estado do motor em duas categorias (0 – bom, 1 – desalinhado), foi utilizada uma técnica de aprendizado de máquina chamada de Redes Neurais Artificiais. Esta RNA recebe como entrada para treinamento uma matriz com 160 linhas (80% de todo o dataset) e sete colunas (número de canais), contendo os valores de energia calculados para cada canal, com cenários de motor com e sem falhas misturados. Após o treinamento, os 20% de dados restantes foram utilizados para validar o índice de acerto da rede. A biblioteca de aprendizado de máquina utilizada, a qual é totalmente desenvolvida para a linguagem Python, é chamada de Scikit-Learn. Os parâmetros utilizados para criar a RNA estão listados no quadro 4:

Quadro 4 - Parâmetros da RNA

Parâmetro	Valor utilizado
Número de neurônios	14
Número de camadas	1
Tipo de RNA	Classificação
Número de épocas	200
Função de ativação	relu
Taxa de aprendizado	0,01

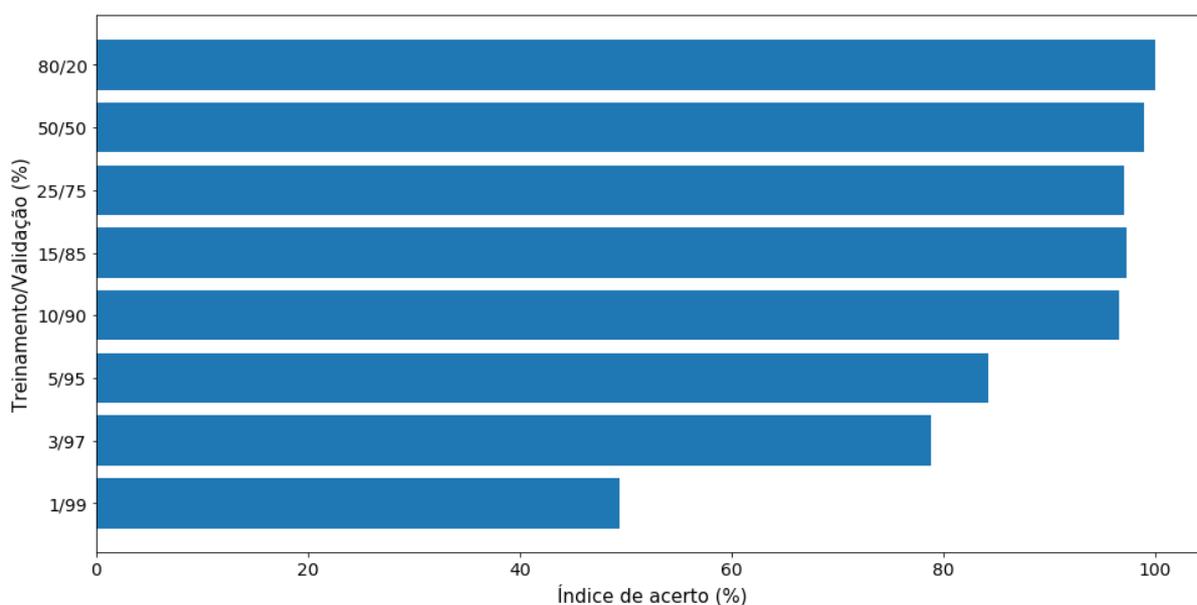
Fonte: elaborado pelo autor.

Após o treinamento da rede, foi realizada a predição do *dataset* de validação, que apresentou um índice de acerto de 100% nas 40 classificações realizadas. A partir do modelo encontrado, foi possível avaliar os resultados obtidos conforme o objetivo proposto.

## 4 ANÁLISE DOS RESULTADOS

Após a execução do *dataset* inicial ter resultado em 100% de acerto, a rede neural foi reinicializada duas vezes com os mesmos percentuais distribuição entre treinamento e validação (80% e 20%), porém com os dados randomizados de formas diferentes, para garantir a efetividade da predição. O índice de acerto se manteve idêntico em todos os casos, classificando corretamente as 40 amostras validadas. Para analisar a acurácia do modelo com menos informações para treinamento, o *dataset* foi então dividido com menos dados para treinamento e mais dados para validação. O resultado em cada uma das execuções encontra-se no gráfico da figura 22:

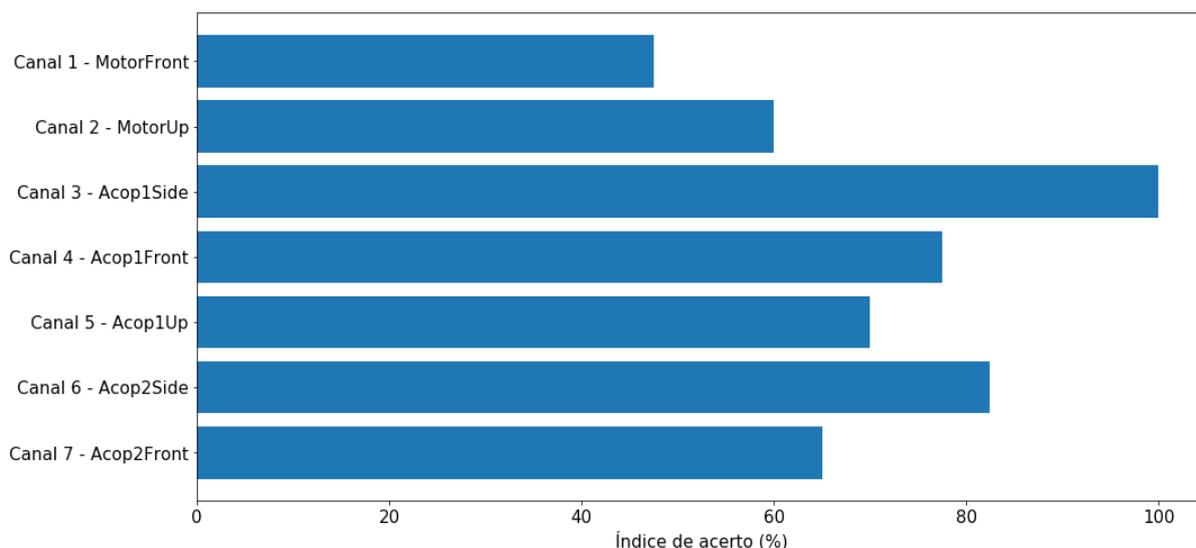
Figura 22 - Resultados da RNA com sete sensores



Fonte: elaborada pelo autor.

Mesmo utilizando 90% das amostras para validação, a RNA teve um resultado de 96,6% de acerto, que é um valor plenamente satisfatório. Contudo, resultados tão expressivos demonstraram a possibilidade de otimizar o sistema criado, de modo a utilizar menos sensores para diagnosticar a falha. Com este propósito, isolamos cada um dos sete canais em redes neurais separadas e avaliamos o índice de acerto de cada uma delas. A figura 23 descreve os resultados alcançados:

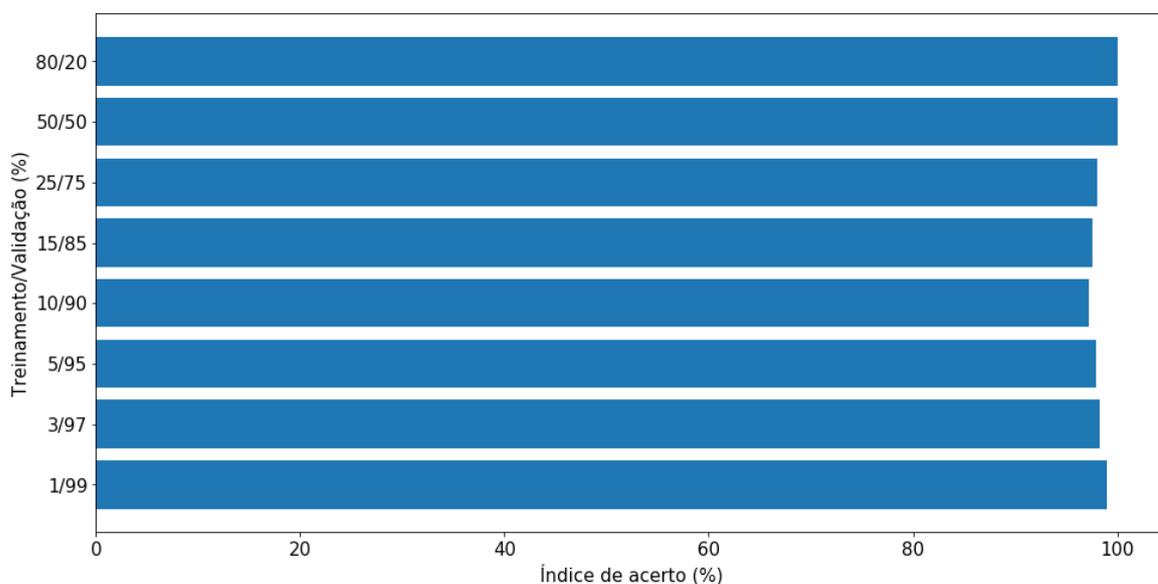
Figura 23 – Resultados da RNA por sensor



Fonte: elaborada pelo autor.

O gráfico demonstra que o canal 3 possui o maior impacto na eficácia da predição da RNA. Utilizando apenas o espectro de energias do sensor *Acop1Side*, é possível diagnosticar o motor desalinhado com 100% de precisão. É importante ressaltar, porém, que este acelerômetro está conectado ao acoplamento onde o desalinhamento foi forçado. Caso a falha ocorresse na extremidade oposta, não é possível prever que o mesmo canal carregasse toda a informação necessária para o modelo preditivo funcionar perfeitamente. Para explorar a eficiência e as limitações de utilizar exclusivamente o canal 3, os mesmos testes de redistribuição dos dados realizados para a RNA com sete sensores foram replicados utilizando a rede alimentada apenas pelo canal 3, modificando os *datasets* de treinamento e validação conforme apresentado no gráfico da figura 24:

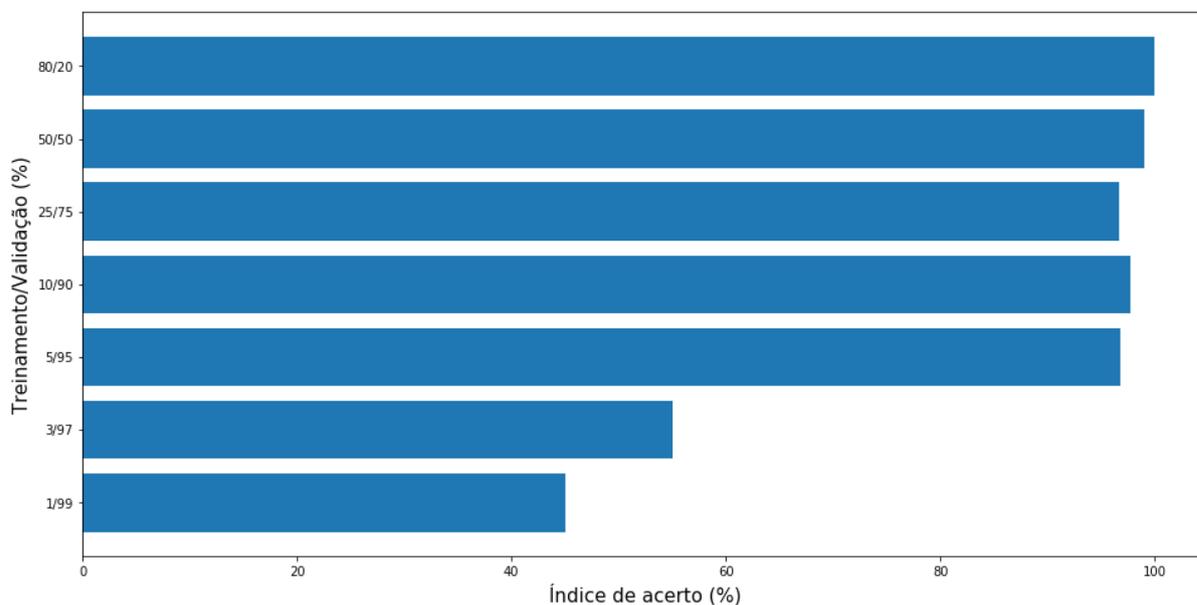
Figura 24 - Resultados da RNA do canal 3



Fonte: elaborada pelo autor.

A uniformidade da energia ao longo de todo espectro, tanto para o motor sem falhas quanto para o motor desalinhado, fez com que a acurácia da RNA fosse muito alta mesmo que o *dataset* de treinamento tivesse poucos valores. Os oito cenários simulados apresentaram um índice de acerto muito próximo a 100%. O menor valor (97%) foi encontrado com um *dataset* distribuído entre 90% para treinamento e 10% para validação. O fato de a rede com menos dados de treinamento não ter apresentado o pior resultado ocorreu devido ao fato de os dados serem reembaralhados a cada vez que a RNA foi inicializada. Com isso, a matriz de treinamento não se repetia, e estava sujeita a um desbalanceamento das informações (por exemplo: receber nove valores de motor sem falhas e apenas um valor de motor desalinhado). Para avaliar a dependência do canal 3 para a eficiência do sistema, uma RNA com os mesmos parâmetros foi treinada sem os dados deste sensor. Sua precisão está demonstrada no gráfico 25:

Figura 25 - Resultados da RNA sem o canal 3



Fonte: elaborada pelo autor.

Mesmo sem o canal 3, a RNA prediz corretamente mais de 97% das saídas utilizando um *dataset* de treinamento de 80% até 5% do total de informações. Se comparado aos testes com apenas o canal 3, uma diferença visível é o baixo índice de acerto utilizando apenas seis linhas de energias (3%) para treinamento. Neste cenário, a RNA foi treinada com a seguinte matriz, representada no quadro 5:

Quadro 5 - Matriz de treinamento RNA sem canal 3 com 3% para treinamento

Canal 1	Canal 2	Canal 4	Canal 5	Canal 6	Canal 7	Bom = 0 / Falha =1
3.986	0.308	2.116	1.164	1.726	1.211	0
8.847	0.367	2.370	1.286	1.878	1.662	0
46.449	0.855	4.505	1.884	2.333	4.762	0
4.307	0.301	2.193	1.175	1.803	1.270	0
2.466	0.260	1.458	1.200	1.767	1.224	1
3.451	0.296	2.127	1.208	1.735	1.234	0

Fonte: elaborado pelo autor.

Com a matriz exposta acima, uma única linha de energias do motor desalinhado foi informada no treinamento da rede neural. Isso fez com que o índice de erro aumentasse muito, e naturalmente ela tendesse a classificar a maior parte dos dados

como motor sem falhas. No total, foram 89 classificações erradas, que foram expostas em uma matriz de confusão descrita no quadro 6:

Quadro 6 - Matriz de confusão da RNA sem o canal 3 com 3% para treinamento

	Motor sem falhas	Motor desalinhado
Motor sem falhas	87	8
Motor desalinhado	81	18

Fonte: elaborado pelo autor.

A matriz comprova que o fato de apenas um dado de motor desalinhado ter sido utilizado para treinar a RNA causou uma alta incidência de falsos negativos, ou seja, a rede previu que o motor não possui falha, quando na verdade ele está sim desalinhado. Contudo, tal análise foi aprofundada em um cenário extremo de distribuição dos dados de entrada da RNA, o que não invalida seus resultados extremamente satisfatórios no contexto do objetivo proposto. Com base em todos os levantamentos realizados, é possível construir as considerações finais do trabalho.

## 5 CONSIDERAÇÕES FINAIS

A primeira etapa do trabalho apresentou a importância do bom funcionamento dos motores elétricos no contexto atual das indústrias. Em seguida, além de definir conceitos como defeito, falha, manutenção preditiva, aprendizado de máquinas e redes neurais, discorreu sobre diversas aplicações científicas que trabalham a previsão de falhas em motores das mais diversas naturezas. A partir dessas informações e do objetivo proposto, o trabalho foi desenvolvido buscando desenvolver um sistema de predição do desalinhamento com redes neurais artificiais.

O principal desafio encontrado foi pré-processar os dados de vibração coletados, de forma a extrair informações relevantes e que de fato teriam algum significado para modelar uma RNA. A decomposição do sinal no espectro de frequência foi o primeiro grande avanço para compreender as diferenças carregadas pelas vibrações do motor operando sem falhas comparado ao motor desalinhado. A partir disso, a divisão em grupos de energias caracterizou através de um número mais limitado de valores o comportamento dos sinais, o que possibilitou a visualização das diferenças de forma clara e foi a grande contribuição da pesquisa.

Após todo esse trabalho de tratamento dos dados, o aprendizado de máquina teve resultados excelentes de predição do estado do motor, atingindo uma acurácia de 100% com o sistema otimizado a apenas um sensor, dos sete medidos no MFS. Mesmo retirando o canal de maior impacto na eficiência da rede, a solidez do sistema como um todo é capaz de sustentar a eficiência do modelo, que mantém resultados expressivos de predição.

Para trabalhos futuros, a partir do experimento desenvolvido podem ser coletados dados de outras falhas como desbalanço e deformação, e o método pode ser repetido para analisar a capacidade de diagnosticar as demais falhas através da energia do sinal. Em uma outra linha, as informações de energia da vibração poderiam ser combinadas com medidas de corrente no motor, para melhorar o sistema tornando-o mais expansível e eficiente.

## REFERÊNCIAS

- ALMEIDA, Paulo Samuel. **Manutenção Mecânica industrial–Princípios técnicos e operações**. Editora Érica. 1ª Edição, 2016.
- ANTONINO-DAVIU, Jose *et al.* **Advanced analysis of motor currents for the diagnosis of the rotor condition in electric motors operating in mining facilities**. IEEE Transactions on Industry Applications, 2018.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462: Confiabilidade e manutenibilidade**. ABNT, 1994.
- ÅSTRÖM, Karl Johan; HÄGGLUND, Tore. **PID controllers: theory, design, and tuning**. Research Triangle Park, NC: Instrument society of America, 1995.
- CARVALHO, André *et al.* **Inteligência Artificial–uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011.
- CHANG, Ching-Yuan; HONG, Jyun-You; CHANG, Wei-Chieh. **Preventive Maintenance of Motors and Automatic Classification of Defects using Artificial Intelligence**. In: 2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA). IEEE, 2018. p. 1-6.
- GHODS, Amirhossein; LEE, Hong-hee. **A frequency-based approach to detect bearing faults in induction motors using discrete wavelet transform**. In: Industrial Technology (ICIT), 2014 IEEE International Conference on. IEEE, 2014. p. 121-125.
- HAND, August. **Electric motor maintenance and troubleshooting**. McGraw-Hill, 2015.
- HAYKIN, Simon S. *et al.* **Neural networks and learning machines**. Upper Saddle River: Pearson education, 2009.
- HSIAO, Cheng-Hsuan; LIU, Meng-Kun. **Failure mode analysis of induction motor model**. In: Applied System Innovation (ICASI), 2017 International Conference on. IEEE, 2017. p. 25-28.

HUUHTANEN, Timo; JUNG, Alexander. **Predictive maintenance of photovoltaic panels via deep learning**. In: 2018 IEEE Data Science Workshop (DSW). IEEE, 2018. p. 66-70.

JEZZINI, Ali *et al.* **Effects of predictive maintenance (PdM), Proactive maintenance (PoM) & Preventive maintenance (PM) on minimizing the faults in medical instruments**. In: Advances in Biomedical Engineering (ICABME), 2013 2nd International Conference on. IEEE, 2013. p. 53-56.

KARMAKAR, Subrata *et al.* **Induction motor fault diagnosis**. Publisher Springer Singapore, 2016.

LAKEHAL, Abdelaziz; RAMDANE, Ahmed. **Fault prediction of induction motor using Bayesian network model**. In: Electrical and Information Technologies (ICEIT), 2017 International Conference on. IEEE, 2017. p. 1-5.

LASHKARI, Negin *et al.* **Asynchronous motors fault detection using ANN and fuzzy logic methods**. In: Energy Conversion Congress and Exposition (ECCE), 2016 IEEE. IEEE, 2016. p. 1-5.

LAZARESCU, Emil *et al.* **A new approach to predictive maintenance of high voltage switching devices**. In: Electric Power Engineering (EPE), 2017 18th International Scientific Conference on. IEEE, 2017. p. 1-4.

LOPEZ-PEREZ, D.; ANTONINO-DAVIU, J. **Failure detection in industrial electric motors through the use of infrared-based isothermal representation**. In: Industrial Electronics Society, IECON 2017-43rd Annual Conference of the IEEE. IEEE, 2017. p. 3822-3827.

LV, Zhi *et al.* **Prognostics health management of condition-based maintenance for aircraft engine systems**. In: Prognostics and Health Management (PHM), 2015 IEEE Conference on. IEEE, 2015. p. 1-6.

MATHEW, Vimala *et al.* **Prediction of Remaining Useful Lifetime (RUL) of turbofan engine using machine learning**. In: Circuits and Systems (ICCS), 2017 IEEE International Conference on. IEEE, 2017. p. 306-311.

MORSALIN, Sayidul et al. **Induction motor inter-turn fault detection using heuristic noninvasive approach by artificial neural network with levenberg marquardt algorithm**. In: 2014 International Conference on Informatics, Electronics & Vision (ICIEV). IEEE, 2014. p. 1-6.

PATEL, Rakeshkumar A.; BHALJA, B. R. **Induction motor rotor fault detection using Artificial Neural Network**. In: Energy Systems and Applications, 2015 International Conference on. IEEE, 2015. p. 45-50.

PETRUZELLA, Frank. **Motores Elétricos e Acionamentos: Série Tekne**. Bookman Editora, 2013.

PRANEETH, A. V. J. S.; WILLIAMSON, Sheldon S. **Algorithm for prediction and control of induction motor stator interturn faults in electric vehicles**. In: Transportation Electrification Conference and Expo (ITEC), 2017 IEEE. IEEE, 2017. p. 130-134.

RICH, Elaine; KNIGHT, Kevin. **Artificial intelligence**. Tata McGraw-Hill, 1991.

ROSA, João Luís Garcia. **Fundamentos da inteligência artificial**. Rio de Janeiro: LTC, 2011.

ŞEN, Mehmet; KUL, Basri. **IoT-based wireless induction motor monitoring**. In: Scientific Conference Electronics (ET), 2017 XXVI International. IEEE, 2017. p. 1-5.

SHIMADA, Junya; SAKAJO, Satoko. **A statistical approach to reduce failure facilities based on predictive maintenance**. In: Neural Networks (IJCNN), 2016 International Joint Conference on. IEEE, 2016. p. 5156-5160.

SPACEY, John. Defect vs Failure. **Simplicable**, 2017. Disponível em <<https://simplicable.com/new/defect-vs-failure>>. Acesso em: 12 de out. de 2018.

SUBHA, M.; KUMAR, N. Senthil; VENI, KS Krishna. **Artificial Intelligence Based Stator Winding Fault Estimation in Three Phase Induction Motor**. In: 2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA). IEEE, 2018. p. 1929-1933.

VIANNA, Wlamir Olivares Loesch; YONEYAMA, Takashi. **Predictive Maintenance Optimization for Aircraft Redundant Systems Subjected to Multiple Wear Profiles**. IEEE Systems Journal, v. 12, n. 2, p. 1170-1181, 2018.

XUAN, Jinquan *et al.* **Fault prediction and damage determination method for brushless DC motor based on ES-GM**. In: Reliability and Maintainability Symposium (RAMS), 2017 Annual. IEEE, 2017. p. 1-8.

## APÊNDICE A – MATRIZ DE VALIDAÇÃO RNA COMPLETA

Canal 1	Canal 2	Canal 3	Canal 4	Canal 5	Canal 6	Canal 7	Saída	RNA
16.200	0.408	3.802	2.266	1.272	1.933	2.630	1	1
2.986	0.285	3.199	2.058	1.159	1.733	1.154	0	0
2.458	0.258	3.660	1.356	1.109	1.621	1.180	1	1
2.657	0.264	3.897	1.383	1.114	1.674	1.256	1	1
14.400	0.462	3.164	2.675	1.380	1.964	2.102	0	0
4.400	0.283	3.698	1.614	1.116	1.616	1.419	1	1
2.659	0.268	3.067	2.058	1.226	1.774	1.136	0	0
3.091	0.262	3.670	1.449	1.111	1.583	1.286	1	1
22.638	0.486	3.642	2.747	1.308	2.106	3.400	1	1
6.402	0.345	3.209	2.263	1.213	1.862	1.472	0	0
2.677	0.275	3.275	2.124	1.226	1.790	1.117	0	0
2.983	0.265	3.788	1.467	1.112	1.694	1.218	1	1
6.787	0.344	3.116	2.189	1.226	1.852	1.450	0	0
10.231	0.374	3.233	2.521	1.292	1.901	1.761	0	0
3.975	0.276	3.712	1.594	1.093	1.670	1.396	1	1
4.627	0.315	3.228	2.167	1.182	1.850	1.278	0	0
3.795	0.286	3.262	2.244	1.242	1.716	1.187	0	0
6.235	0.305	3.794	1.624	1.114	1.704	1.689	1	1
25.088	0.505	3.611	2.918	1.317	2.154	3.751	1	1
3.503	0.285	3.653	1.472	1.156	1.635	1.310	1	1
22.065	0.534	3.164	3.029	1.498	2.070	2.718	0	0
9.959	0.336	3.631	1.938	1.255	1.845	2.090	1	1
17.455	0.430	3.660	2.405	1.291	1.924	2.870	1	1
5.218	0.297	3.807	1.589	1.159	1.735	1.590	1	1
5.037	0.325	3.268	2.310	1.266	1.720	1.364	0	0
4.741	0.296	3.836	1.596	1.185	1.739	1.469	1	1
20.207	0.501	3.189	2.966	1.437	2.047	2.578	0	0
4.844	0.313	3.205	2.196	1.138	1.781	1.310	0	0
12.858	0.423	3.161	2.668	1.377	1.875	2.030	0	0
6.088	0.308	3.732	1.683	1.159	1.737	1.595	1	1
6.806	0.318	3.600	1.731	1.155	1.731	1.688	1	1
8.474	0.335	3.752	1.801	1.151	1.807	1.836	1	1
52.497	0.825	3.433	4.889	1.568	2.891	6.603	1	1
8.847	0.367	3.130	2.370	1.286	1.878	1.662	0	0
3.986	0.309	3.393	2.116	1.164	1.726	1.211	0	0
3.144	0.260	3.528	1.449	1.103	1.643	1.262	1	1
4.081	0.293	3.238	2.190	1.227	1.756	1.299	0	0
2.801	0.263	3.598	1.479	1.077	1.593	1.291	1	1
5.482	0.305	3.811	1.571	1.163	1.659	1.484	1	1
24.191	0.557	3.076	3.168	1.510	2.117	2.963	0	0

**APÊNDICE B - MATRIZ DE VALIDAÇÃO RNA CANAL 3**

Canal 3	Saída	RNA
3.66956871	1	1
3.2155234	0	0
3.23550346	0	0
3.92588346	1	1
3.14351037	0	0
3.18557238	0	0
3.14224764	0	0
3.79609489	1	1
3.22029828	0	0
3.19926697	0	0
3.11966514	0	0
3.77908	1	1
3.77162875	1	1
3.18866593	0	0
3.30077353	0	0
3.8761367	1	1
3.32577361	0	0
3.55935732	1	1
3.17934188	0	0
3.71240926	1	1
3.11751657	0	0
3.20051699	0	0
3.84320813	1	1
3.15722927	0	0
3.76016369	1	1
3.30201349	0	0
3.26181271	0	0
3.32387931	0	0
3.91657862	1	1
3.23131189	0	0
3.71926401	1	1
3.74727943	1	1
3.74444885	1	1
3.1868237	0	0
3.43262581	1	1
3.81299177	1	1
3.65975248	1	1
3.62685984	1	1
3.19882976	0	0
3.22155446	0	0

## APÊNDICE C – SCRIPT PROCESSAMENTO E RNA

```
import tensorflow as tf;
import keras;
import pandas;
import sklearn;
import matplotlib;
import matplotlib.pyplot as plt;
import csv;
import scipy.fftpack as fft;
import numpy as np;

from sklearn.neural_network import MLPClassifier
```

```
energiasBom = np.zeros((100,1));
energiasDesalinhado = np.ones((100,1));
```

```
yBom, yDesalinhado = [], [];
parsevalBomGrupos, parsevalDesalinhadoGrupos = [], [];

with open('MotorBom.csv', 'r') as csvfile:
    plots = csv.reader(csvfile, delimiter=',')
    first_row = next(plots)
    for row in plots:
        yBom.append(float(row[6]))

with open('MotorDesalinhado15.csv', 'r') as csvfile:
    plots = csv.reader(csvfile, delimiter=',')
    first_row = next(plots)
    for row in plots:
        yDesalinhado.append(float(row[6].replace(',','.')))

i, j = 3000, 100;
yBomGrupos = [[yBom[(x+1)*(y+1)] for x in range(i)] for y in range(j)]
yDesalinhadoGrupos = [[yDesalinhado[(x+1)*(y+1)] for x in range(i)] for y in range(j)]

for x in range(j):
    parsevalBomGrupos.append(np.sum(np.abs(fft.fft(yBomGrupos[x]))**2) / i);
    parsevalDesalinhadoGrupos.append(np.sum(np.abs(fft.fft(yDesalinhadoGrupos[x]))**2) / i);

energiasBom = np.insert(energiasBom, 0, np.array(parsevalBomGrupos), 1);
energiasDesalinhado = np.insert(energiasDesalinhado, 0, np.array(parsevalDesalinhadoGrupos), 1);
```

```
pandas.set_option('display.max_rows', 500);
pandas.set_option('display.max_columns', 500);
pandas.set_option('display.width', 1000);
datasetRna = np.concatenate((energiasBom, energiasDesalinhado), 0);
np.random.shuffle(datasetRna);

df = pandas.DataFrame(datasetRna);
export_csv = df.to_csv (r'C:\Users\pc\Desktop\export_dataframe.csv', index = None, header=True);
```

```
datasetTreinamento = datasetRna[range(2),];
datasetValidacao = datasetRna[range(2,200),];

df1 = pandas.DataFrame(datasetTreinamento);
df2 = pandas.DataFrame(datasetValidacao);

export_csv1 = df1.to_csv (r'C:\Users\pc\Desktop\export_dataframe_treinamento.csv', index = None, header=True);
export_csv2 = df2.to_csv (r'C:\Users\pc\Desktop\export_dataframe_validacao.csv', index = None, header=True);
```

```
clf = MLPClassifier(solver='lbfgs', alpha=1e-5, hidden_layer_sizes=14, random_state=1);
clf.fit(datasetTreinamento[:,range(7)], np.squeeze(np.asarray(datasetTreinamento[:,7])));

dfValidacao = pandas.DataFrame(clf.predict(datasetValidacao[:,range(7)]));
export_csv3 = dfValidacao.to_csv (r'C:\Users\pc\Desktop\export_dataframe_validado.csv', index = None, header=True);
```