

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO

JOSÉ GARCIA CUSTÓDIO DA COSTA

DETECÇÃO DE BARRAS QUEBRADAS EM MOTORES DE INDUÇÃO
USANDO IMAGENS GERADAS A PARTIR DAS PERTURBAÇÕES DE FLUXO NO
ENTREFERRO

SÃO PAULO

2023

JOSÉ GARCIA CUSTÓDIO DA COSTA

**DETECÇÃO DE BARRAS QUEBRADAS EM MOTORES DE INDUÇÃO USANDO
IMAGENS GERADAS A PARTIR DAS PERTURBAÇÕES DE FLUXO NO
ENTREFERRO**

Texto de dissertação ao programa de Pós-Graduação em
Informática e Gestão do conhecimento da Universidade
Nove de Julho – UNINOVE, como requisito parcial para a
obtenção do grau de Mestre em Informática e Gestão do
conhecimento.

Prof. Cleber Gustavo Dias, Dr. Orientador

SÃO PAULO

2023

Costa, José Garcia Custódio da.

Detecção de barras quebradas em motores de indução usando
imagens geradas a partir das perturbações de fluxo no entreferro. /
José Garcia Custódio da Costa. 2023.

99 f.

Dissertação (Mestrado) - Universidade Nove de Julho -
UNINOVE, São Paulo, 2023.

Orientador (a): Prof. Dr. Cleber Gustavo Dias.

1. Motor de indução trifásico. 2. Barras quebradas. 3. Sensor hall.
4. Redes neurais convolucionais.

I. Dias, Cleber Gustavo.

II. Título.

CDU 004

DEDICATÓRIA

Dedico este trabalho aos meus queridos pais (em memória), que me educaram para ser o que sou e sempre me apoiaram no que se referia ao meu futuro, ao meu irmão mais velho, que foi um exemplo de estudante dedicado, e a minha esposa.

AGRADECIMENTOS

Primeiramente gostaria de agradecer à Deus pois sem Ele nada existiria.

À minha querida esposa, Joana da Costa, que tem sido uma conselheira e motivadora para a continuidade dos meus estudos, pelo seu apoio e compreensão.

Ao meu orientador, Cleber Gustavo Dias, pela dedicação, orientação e apoio em todos os momentos da minha pesquisa, um exemplo de pesquisador sempre disposto a ajudar na formação de pesquisadores e profissionais.

Aos professores do Programa de Pós-Graduação em Informática e Gestão do Conhecimento da UNINOVE por todos os ensinamentos passados a mim.

Aos professores da banca que deram suas contribuições para a melhoria deste trabalho.

À PROSUP/Capes (Modalidade II - Taxa) pelo suporte financeiro.

RESUMO

Durante as últimas décadas, os motores de indução têm sido usados em diversas aplicações industriais e comerciais, particularmente devido à sua construção robusta e manutenção relativamente simples. Hoje, os motores de indução são responsáveis por uma grande quantidade de consumo de energia nas indústrias (cerca de 85%) e capazes de movimentar muitas cargas durante os processos de conversão de energia. Embora os motores de indução trifásico sejam máquinas confiáveis, vários tipos de falhas podem afetar a sua estrutura ou as suas condições operacionais nominais, tais como falhas de rolamento, excentricidade do entreferro, falhas no enrolamento do estator e barras do rotor quebradas. Sabe-se que normalmente as falhas nas barras do rotor estão relacionadas a 10% do total de avarias no motor de indução, e este tipo de condição operacional leva a uma redução do ciclo de vida da máquina. Ademais, quando este tipo de falha acontece as consequências podem ser desastrosas, não apenas para o equipamento, mas também para o processo produtivo a ele associado, e por este motivo o presente estudo focou no desenvolvimento de uma abordagem capaz de detectar o rompimento de barras rotóricas, a fim de evitar altos custos interventivos e os ajustes na programação de manutenção preventiva. Para este estudo foi empregado, de forma invasiva, um sensor de efeito Hall localizado próximo ao entreferro da máquina, a fim de monitorar as variações de densidade de fluxo magnético, para o motor operando em uma condição saudável e também com barras rotóricas quebradas. Para tanto, foram geradas imagens RGB a partir do sinal proveniente do sensor e uma rede neural profunda para classificar a condição estrutural do rotor. O melhor modelo computacional desenvolvido foi capaz de não apenas detectar o referido defeito, com boa acurácia, mas também localizar as barras quebradas em diferentes polos magnéticos do motor. Ademais, o modelo classificou corretamente, na maioria dos casos, a condição do rotor para a máquina operando desde a sua condição a vazio até a condição de plena carga, além de alimentada por tensão senoidal ou por um inversor de frequência.

Palavras-chave: Motor de indução trifásico. Barras quebradas. Sensor Hall. Redes Neurais Convolucionais.

ABSTRACT

During the last few decades, induction motors have been used in a variety of industrial and commercial applications, particularly due to their robust construction and relatively simple maintenance. Today, induction motors are responsible for a large amount of energy consumption in industries (about 85%) and capable of moving many loads during energy conversion processes. Although three-phase induction motors are reliable machines, various types of failures can affect their structure or their operating conditions, such as bearing failures, air gap eccentricity, stator winding failures and broken rotor bars. It is known that, normally, failures in the rotor bars are related to 10% of the total failures in the induction motor, and this type of operating condition leads to a reduction in the life cycle of the motor. Furthermore, when this type of failure occurs, the consequences can be disastrous, not only for the machine, but also for the production process associated with it, and for this reason, the present study focused on the development of an approach capable of detecting the rupture of rotor bars, to avoid high intervention costs and maximize adjustments in the preventive maintenance schedule. To this end, the purpose of this research is quantitative, post-positivist, exploratory in its beginning and later evolved into an experimental and applied phase, to achieve the proposed objectives. For this study, a Hall effect sensor was invasively used on the stator coils so that variations in the magnetic flux density could be monitored, with the occurrence of a defect, mainly on the rotor bars. To extract the defect and healthy features from the images generated from the signal coming from the sensor, different computer vision techniques and machine learning techniques with convulsive neural networks were used. Tools such as TensorFlow and the Keras API were used to develop convolutional neural networks diligently and accurately. The computational model obtained at the end was able to detect the referred defect, with good accuracy, for different operating conditions of the engine, from its no-load condition to the full load condition, in many cases without the need to apply the erosion technique for image generation.

Keywords: Three-phase induction motor. Broken bars. Hall sensor. Convolutional Neural Networks.

LISTA DE ILUSTRAÇÕES

Figura 1 - Classificação para os motores elétricos.....	14
Figura 2 - Parcela de consumo de energia elétrica dada pelos motores elétricos em alguns países.....	15
Figura 3 - Consumo de energia elétrica na indústria brasileira.....	15
Figura 4 - Aplicação de motores elétricos na indústria.....	15
Figura 5 - Estrutura interna do MIT com rotor de gaiola de esquilo.....	16
Figura 6 - Falhas normalmente encontradas nos MIT.....	18
Figura 7 - Rotor de um motor de 1200 kW e 6 polos.....	19
Figura 8 - Rotor de um motor 3.3 kV 450 kW.....	21
Figura 9 - Publicações com defect dectetion neural network na base Scopus.....	22
Figura 10 - Espectro de frequências de um motor sem defeito (a) e um moto em barras rompidas (b) obtidos pelo método MCSA.....	31
Figura 11 - Desenho do primeiro motor de indução projetado por Tesla.....	33
Figura 12 - Motor de Indução Trifásico.....	34
Figura 13 - Esquema do motor de indução com seis terminais.....	35
Figura 14 - Corrente elétrica passando sobre um condutor.....	36
Figura 15 - Bobina trifásica.....	36
Figura 16 - Correntes elétrica deslocadas no tempo.....	37
Figura 17 - Campos magnéticos gerados a partir das correntes trifásicas.....	37
Figura 18 - Variação de rotação com a conjugado de carga.....	38
Figura 19 - Relação entre as áreas de estudo segundo Chollet.....	43
Figura 20 - Estrutura básica de uma rede neural.....	45
Figura 21 - Estrutura básica de uma rede neural.....	45
Figura 22 - Problemas de classificação linear e não linear.....	46
Figura 23 - Função de ativação sigmoide.....	46
Figura 24 - Função de ativação tanh.....	47
Figura 25 - Função de ativação ReLU.....	48
Figura 26 - Curva típica de comportamento da taxa de aprendizagem.....	52
Figura 27 - Operações convolucionais para reconhecer padrões em imagem de gato.....	54
Figura 28 - Operação de downsampling em uma camada de pooling.....	55
Figura 29 - Aplicação de max pooling para atingir o downsampling.....	55
Figura 30 - Aparato montado no laboratório para a condução dos experimentos.....	61

Figura 31 - Motor de indução usado para testes e coleta dos dados.....	62
Figura 32 - Perturbações no fluxo do entreferro do MIT, com barras quebradas, detectadas pela Sonda Hall.....	62
Figura 33 - Local onde a sonda Hall está posicionada no estator.....	63
Figura 34 – Sinal no domínio do tempo para imagem RGB.....	67
Figura 35 – Dados 1D (uma dimensão) convertidos em imagens 2D (duas dimensões).....	67
Figura 36 - Conversão da imagem RGB para tons Cinza.....	68
Figura 37 - Conversão do sinal em imagem RGB e Cinza.....	69
Figura 38 - Uma imagem radiográfica em níveis de cinza 448×425 pixels. (b) Erosão usando um disco plano com um raio de 2 pixels.....	70
Figura 39 – Principais etapas utilizadas neste trabalho.....	72
Figura 40 - Ilustrações de um rotor saudável e com uma barra quebrada.....	75
Figura 41 - Ilustrações de um rotor com barras quebradas em polos adjacentes e não adjacentes.....	76
Figura 42 - Técnica MCSA aplicada para um rotor sem avaria e outro com 2BB.....	83

LISTA DE TABELAS

Tabela 1 - Métodos empregados na detecção de barras quebradas nos últimos anos.....	29
Tabela 2 - Dados do conjunto motor, freio e ventilador usado nos testes.....	63
Tabela 3 - Diferentes cenários operacionais avaliados para o MIT.....	65
Tabela 4 - Matriz de confusão da validação do cenário 1 sem erosão.....	77
Tabela 5 - Matriz de confusão da validação do cenário 2 com e sem erosão.....	78
Tabela 6 - Teste de validação com e sem erosão.....	78
Tabela 7 - Matriz de confusão da validação do cenário 3 com e sem erosão.....	79
Tabela 8 - Teste de validação para imagens com e sem erosão.....	80
Tabela 9 - Matriz de confusão da validação do cenário 4 para as imagens geradas sem erosão..	81
Tabela 10 - Teste de validação para imagens sem erosão.....	81
Tabela 11 - Matriz de confusão da validação do cenário 4 para as imagens geradas com erosão.....	81
Tabela 12 - Teste de validação para imagens com erosão.....	82
Tabela 13 - Técnica MCSA aplicada em casos de baixa carga ou barras separadas em 90°.....	84
Tabela 14 - Resultados obtidos após o processamento do sinal da sonda e estimativa do modelo CNN.....	85

LISTA DE ABREVIATURAS E SIGLAS

ANN	Artificial Neural Network
CNN	Rede Neural Convolucional
DL	Deep Learning
EOSTI	Erosion Operation
EPE	Empresa de Pesquisas Energéticas
EUA	Estados Unidos da América
FDD	Detecção e Diagnóstico de Falhas
FEM	Força Eletromotriz
FFT	Transformada Rápida de Fourier
GAN	Generative Adversarial Network
GPU	Graphics Processing Unit
IA	Inteligência Artificial
IEEE	Instituto de Engenheiros Eletrônicos e Eletricistas
LSTM	Long Short Term Memory
MCSA	Análise da Assinatura da Corrente do Motor
ME	Motores eléctricos
MIT	Motor de Indução Trifásico
ML	Machine Learning
NAG	Nesterov Accelerated Gradient
PC	Computador Pessoal
RAM	Random-Access Memory
ReLu	Rectified Linear Unit
RGB	Vermelho Verde Azul
RN	Rede Neural
SGD	Stochastic Gradient Descent
STI	Sequence to Image
S	Escorregamento do motor de indução
f_{amost}	Frequência de amostragem
nr	Velocidade de rotação da máquina
ns	Velocidade do sincronismo

SUMÁRIO

1 INTRODUÇÃO	13
1.1 A DEMANDA PELOS MOTORES DE INDUÇÃO TRIFÁSICOS	14
1.2 AS FALHAS NO MOTOR DE INDUÇÃO TRIFÁSICO	16
1.3 JUSTIFICATIVA E MOTIVAÇÃO	19
1.4 DELIMITAÇÃO DO TEMA	24
1.5 IDENTIFICAÇÃO DE OPORTUNIDADES DE PESQUISA	24
1.6 PROBLEMA DE PESQUISA	25
1.7 OBJETIVOS	25
1.7.1 Objetivo geral.....	25
1.7.2 Objetivos específicos.....	25
1.8 ORGANIZAÇÃO DO TRABALHO	26
2 REVISÃO DA LITERATURA	27
3 FUNDAMENTAÇÃO TEÓRICA.....	33
3.1 O MOTOR DE INDUÇÃO TRIFÁSICO COM ROTOR GAIOLA DE ESQUILO	33
3.1.1 Escorregamento e operação da máquina em condições de baixa carga	38
3.2 APRENDIZADO DE MÁQUINA E APRENDIZAGEM PROFUNDA	40
3.2.1 Aprendizado de Máquina	40
3.3 REDES NEURAIIS	43
3.3.1 Definição e história	43
3.3.2 Estrutura de redes neurais	44
3.3.3 Funcionamento das redes neurais	49
3.3.3.1 Divisão dos conjuntos de dados	49
3.3.3.2 Aplicação da propagação direta.....	50
3.3.3.3 Cálculo da função de perda total.....	50
3.3.3.4 Atualização dos pesos e vieses da rede.....	50
3.3.3.5 Hiperparâmetros de redes neurais.....	51
3.4 PRINCIPAIS TIPOS DE REDE NEURAL	52
3.4.1 Redes neurais convolucionais	53
3.4.2 Desenvolvimento e implementação dos algoritmos de interesse em código	55
3.5 CONCEITOS SOBRE PROCESSAMENTO DE IMAGENS E MORFOLOGIA MATEMÁTICA	56

3.5.1 Definições básicas sobre imagens	56
3.5.2 Imagens discretas.....	57
3.6 OPERADORES MORFOLÓGICOS EM IMAGENS MONOCROMÁTICAS.....	57
Dilatação e Erosão	59
3.7 Operadores de imagens.....	59
4 MATERIAIS E METODOS	60
4.1 CARACTERIZAÇÃO METODOLÓGICA	60
4.1.1 Etapa 1: Montagem do aparato experimental.....	61
4.1.2 Etapa 2: Coleta de dados da sonda Hall e experimentos programados	64
4.1.3 Etapa 3: Transformação do sinal no domínio do tempo para imagens RGB.....	66
4.1.4 Etapa 4: Uso da CNN para detectar a condição do rotor	73
5 DISCUSSÃO E ANÁLISE DOS RESULTADOS OBTIDOS	75
5.1 INTRODUÇÃO.....	75
5.2 A COLETA DOS DADOS DA Sonda HALL E A GERAÇÃO DE IMAGENS RGB	76
5.3 ANÁLISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 1.	77
5.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 2.	78
5.4 ANALISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 3.	79
5.5 ANALISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 4.	80
5.6 COMPARAÇÃO DO MÉTODO DESENVOLVIDO FRENTE À TÉCNICA CONVENCIONAL POR ASSINATURA DA CORRENTE (MCSA)	82
6 CONCLUSÕES.....	87
REFERÊNCIAS	88
ANEXOS	96
ANEXO A– BIBLIOTECAS USADAS NO DESENVOLVIMENTO.....	96
ANEXO B – CONVERSÃO DA IMAGEM RGB PARA TONS DE CINZA.....	97
ANEXO C – APLICANDO CNN.....	98
ANEXO D– ÉPOCAS DE TREINAMENTO E ACURÁCIA DO MODELO.....	99

1 INTRODUÇÃO

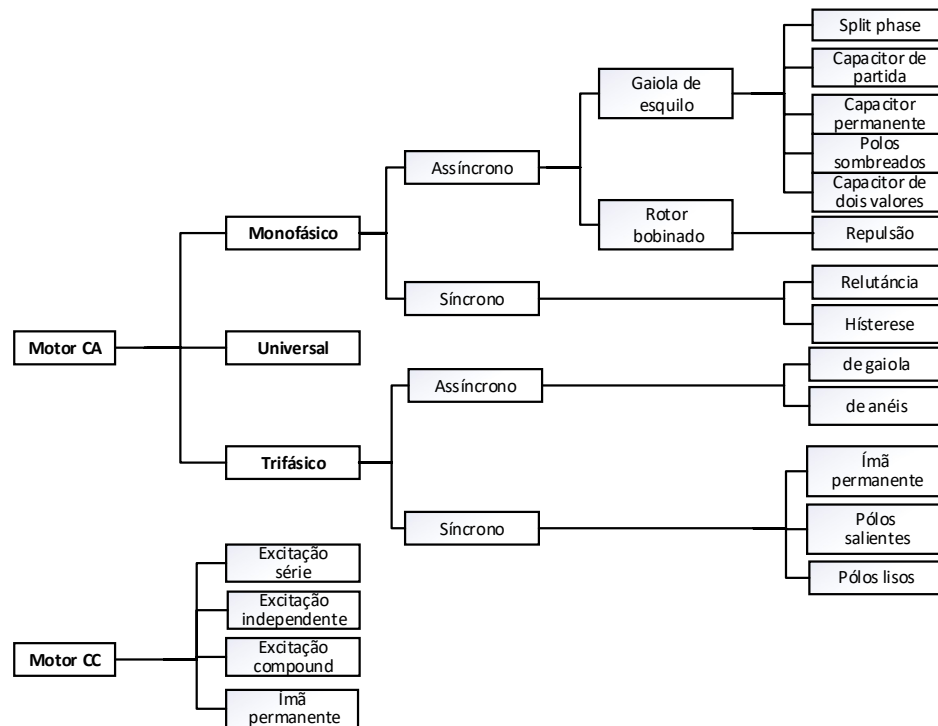
Os Motores de Indução Trifásicos (MIT) são um dos pilares da indústria mundial; contudo, assim como qualquer outro equipamento de conversão eletromecânica, estão susceptíveis a diferentes tipos de falhas durante a sua operacionalidade. Pesquisas relacionadas a monitoração e identificação de falhas nas máquinas elétricas rotativas representam um tópico desafiador para a comunidade científica. As buscas cada vez maiores no diagnóstico precoce de falhas nos MIT por conta das consequências técnicas e econômicas têm sido cada vez mais profundas. Os MIT em gaiola de esquilo estão entre as mais comuns máquinas rotativas utilizadas na indústria, representando cerca de 85% do consumo de energia nas instalações industriais (GARCIA-BRACAMONTE *et al.*, 2019).

Os motores eléctricos (ME) são máquinas rotativas cujo intuito é converter energia elétrica em energia mecânica rotacional. Os motores de corrente alternada, nos quais estão presentes os motores de indução, são os mais usados por conta das diversas vantagens que apresentam, como o baixo custo de fabricação, bem como montagem e manutenção relativamente mais simples em relação aos motores de corrente contínua, por exemplo. Ao contrário do anterior, o motor de corrente contínua possui preço e tamanho mais elevados para a mesma potência (MATTEDE, 2014).

Os motores de indução trifásicos (MIT's) podem ainda ser subdivididos em motores síncronos e assíncronos, assim como monofásicos e trifásicos. Os motores síncronos são aqueles que giram em uma velocidade constante, independentemente da variação de carga, e a velocidade do campo magnético girante depende da frequência da corrente alternada. No caso dos motores assíncronos, existe uma diferença de velocidade entre o rotor e o campo magnético girante, sendo tal condição conhecida como escorregamento do motor.

Assim, os motores assíncronos giram em uma velocidade relativamente menor que a velocidade de rotação do campo girante com relação ao estator, logo, a velocidade do rotor não está sincronizada com o campo girante. Conforme pode ser visto na Figura 1, os motores de indução podem ser monofásicos ou trifásicos; sendo os mesmos monofásicos quando as bobinas do estator além de serem interligadas, são alimentados apenas por um par de fios e os trifásicos alimentados por três fases (EPE, 2019).

Figura 1 - Classificação para os motores elétricos



Fonte: Elaborado pelo autor (2022), com base em Weg (2021)

1.1 A DEMANDA PELOS MOTORES DE INDUÇÃO TRIFÁSICOS


Por conta da diversidade de aplicações, além de baixo custo e tamanho diversificado, o motor de indução tornou-se uma referência para a indústria. Porém, por conta das condições operacionais a que ele está sujeito, muitas vezes fora das suas especificações nominais, o MIT pode estar susceptível a várias falhas sendo que muitas delas podem até se tornar catastróficas prejudicando assim uma cadeia de outros equipamentos acoplados a ele, na medida em que tais falhas não sejam detectadas com certa antecedência (SINHA *et al.*, 2021).

Os motores de indução trifásicos são considerados como as máquinas elétricas com maior aplicabilidade na indústria. Como já mencionado, elas consomem aproximadamente 85% do total de energia disponibilizada na indústria (DIAS; SILVA; ALVES, 2020).

O trabalho de Sauer *et al.*, (2015), por exemplo, apresenta o papel dos motores no consumo de energia elétrica na indústria em diversos países, como pode ser observado na Figura 2, e os MIT contribuem com um peso maior nesta estatística de consumo. As estimativas

indicam que na indústria Brasileira temos 12 milhões de motores em operação, o que representa algo próximo a 35% do total de consumo de energia.

Figura 2 – Parcela de consumo de energia elétrica dada pelos motores elétricos em alguns países



Fonte: Adaptado de (SAUER *et al.*, 2015)

No Brasil, foi identificado no ano de 2019 um consumo de energia elétrica distribuído em cada setor em termos percentuais, conforme ilustrado na Figura 3. Como pode ser visto, o setor industrial ainda continua sendo o que mais consome por meio do uso dos motores elétricos. Em outro gráfico, isto é, na Figura 4, são mostradas as principais aplicações dentro da indústria.


Logo, as Figuras 3 e 4 ratificam o que anteriormente fora afirmado, ou seja, que o setor industrial é responsável pela maior demanda de energia elétrica e o motor elétrico dentre os demais equipamentos, é aquele que mais consome.

Figura 3 - Consumo de energia elétrica por setor.



Fonte: (EPE, 2019)

Figura 4 - Aplicação de motores elétricos na indústria.



Fonte: Adaptado de SAUER *et al.*, 2015


Por conta disso, faz-se necessária a monitoração do seu funcionamento como um todo, para que se possa maximizar o seu tempo de vida, reduzindo danos advindos de sua ineficácia e/ou potenciais avarias (SINHA *et al.*, 2021).

1.2 AS FALHAS NO MOTOR DE INDUÇÃO TRIFÁSICO

As falhas nos motores de gaiola de esquilo são conhecidas por serem comuns no momento de partida/parada da máquina e/ou ainda para amplas variações de carga. Os MITs com falhas iniciais nos rotores poderão manter a sua operação, porém é crucial detectar de maneira precoce este tipo de falha, a fim de prevenir outros problemas em série. (PARK *et al.*, 2020).

A Figura 5 ilustra detalhadamente a composição de um motor de indução trifásico para melhor compreensão de sua estrutura e operação. Entre as principais partes e características do MIT, pode-se destacar:

Figura 5 – Estrutura interna do MIT com rotor de gaiola de esquilo



Fonte: <<https://www.portaleletricista.com.br/motor-de-inducao-funcionalidade-significado-dicas-passo-a-passo/>>

(Acessado em 01/11/2021)

- O rotor é a parte móvel do motor que gira em torno de seu próprio eixo, de forma a produzir movimentos de rotação. Os rotores estão presentes em qualquer máquina rotativa, como turbinas e compressores por exemplo;
- Por outro lado, o estator é a parte de um motor ou gerador elétrico que se mantém fixa à carcaça de um motor e tem por função gerar o fluxo magnético. Assim como nas

bobinas, é formado no estator um campo magnético capaz de induzir uma corrente elétrica nos enrolamentos do rotor. Logo, a corrente elétrica que circula nos enrolamentos do estator deve produzir a força magneto-motriz necessária à geração de um fluxo magnético;

- Placa de identificação disponibiliza as especificações do motor, tais como, tensão nominal, potência, fator de potência, regime, corrente de partida, rotação, tipo de motor etc;
- Carcaça é a estrutura que suporta o estator e os mancais;
- Olhal serve para içar o motor em condições de transporte ou movimentação;
- Ventoinha contribui para a dissipação de calor da carcaça;
- Caixa de ligação do motor é o local onde são conectados os cabos de alimentação do motor;
- Eixo do motor é um elemento mecânico utilizado para articular um ou mais elementos de máquinas, uma vez que o eixo transmite potência por meio do movimento de rotação;
- Rolamentos tem a função de reduzir o atrito entre partes móveis da máquina, ou seja, transmitir uma ação de rotação entre um eixo e outros elementos, além de centralizar o rotor; e
- Chaveta é um elemento que serve para realizar a trava de peças entre eixos e polias ou entre eixos e engrenagens.

Os motores elétricos ainda têm desempenhado um papel preponderante na indústria, sendo a grande fonte de potência mecânica. Muitos esforços e técnicas têm sido aplicados para se encontrar equipamentos capazes de desempenhar o mesmo papel com menor custo e consumo de energia (DIAS; PEREIRA, 2018).


Apesar dos estudos e desenvolvimentos de sistemas para a identificação de falhas em motores trifásicos, ainda se observa dentre outras falhas, as de barras quebradas no rotor em gaiola de esquilo, durante o seu estado de operacionalidade, muitas delas acarretando outras falhas em sequência e até mesmo a parada por completo da máquina com prejuízos elevados comparado aos custos de manutenção.

A vida útil de um motor pode ser afetada por diversas condições nas quais ele é submetido. Isso se deve a fatores externos e internos, sejam eles ambientais, mecânicos e/ou elétricos (SINHA *et al.*, 2021).

No caso do MIT, apesar das falhas rotóricas ocorrerem em aproximadamente 10% dos casos, se não identificadas com antecedência podem levar a perda completa do mesmo (SILVA, 2019).

Conforme gráfico mostrado na Figura 6, as falhas nos MITs encontram-se distribuídas e descritas da seguinte forma:

Figura 6 - Falhas normalmente encontradas nos MIT



Fonte: Adaptada de Silva (2019)

Em referência à Figura 6 ainda, cabe mencionar que:

1. As falhas relacionadas ao estator representam cerca de 38% do total de avarias, e podem estar associadas na maior parte das vezes por curto-circuito nas bobinas, causando desequilíbrios que se refletem no torque, no fluxo de campo, nas correntes do estator, entre outras. Entre as mais frequentes, pode-se destacar: curto-circuito entre fase-terra e fase-fase, curto-circuito entre os enrolamentos da mesma bobina ou de diferentes fases. Vale lembrar que no curto-circuito, a corrente é cerca de duas vezes a corrente de rotor bloqueado e ocasionando assim, não apenas um aquecimento localizado, mas também uma elevação de temperatura em outras áreas das bobinas, causando danos, e muitos deles até mesmo irreversíveis ao motor. (SILVA, 2019);
2. As falhas relacionadas com rotor representam cerca de 10%, e podem advir dos enrolamentos (nos rotores bobinados), dos anéis e das barras quebradas (nos rotores de gaiola de esquilo). Esta última são as mais comuns, sendo que as rachaduras nos anéis de curto-circuito causam vibrações excessivas, ruídos e faísca no momento da partida do motor. Uma inspeção visual, por exemplo, mostra que apesar dos motores estarem com barras quebradas ou trincadas, ainda assim podem continuar a sua operação. No entanto, uma barra quebrada pode atingir o enrolamento do estator, originando curto-circuito entre as espiras ou até mesmo entre as fases, além de produzir vibrações e uma

elevação na corrente que flui através das barras vizinhas àquela que se rompeu. É comum observar ainda o rompimento das barras adjacentes à barra inicialmente fraturada, por causa da redistribuição da corrente a elas, aumentando assim o estresse mecânico durante o funcionamento do MIT (PARK *et al.*, 2020);


3. As falhas relacionadas aos rolamentos representam em torno de 40% e são capazes de provocar um travamento do eixo rotor. De modo geral, essas falhas podem ocorrer tanto com o motor ligado a uma rede de alimentação trifásico, quanto a um inversor de frequência; e
4. Outras falhas representam cerca de 12%, que podem ser internas ou externas, mecânicas ou elétricas.

1.3 JUSTIFICATIVA E MOTIVAÇÃO

Como já mencionado, normalmente, as avarias nas barras do rotor estão relacionadas a 10% do total de falhas no motor de indução, e este tipo de condição operacional leva a uma redução do ciclo de vida do MIT.

Em muitos casos, as falhas podem ser verificadas na gaiola do rotor por um longo intervalo de tempo, podendo atingir anos, sem afetar substancialmente o funcionamento do motor. Outrossim, o atraso em uma interrupção programada do motor e do processo, por conta de uma falha secundária causada por fragmentos da gaiola é comum. Uma das falhas encontradas na gaiola é a quebra de uma ou mais barras que se ligam aos anéis de curto-circuito como pode ser visto nas Figuras 7a e 7b.

Figura 7 - Rotor de um motor de 1200 kW e 6 polos



Fonte: Cristiano (2017)

As falhas do rotor, em geral, podem ser classificadas como falhas na estrutura do anel terminal, ou de curto-circuito, e de barras quebradas. Esses tipos de falhas são causados principalmente por uma ou uma combinação das seguintes razões:

- Tensões dinâmicas devido a torques pulsantes, forças centrífugas e oscilação de torção do eixo;
- Tensões térmicas causadas por pontos quentes, sobrecargas, faísca devido à fabricação imperfeita do rotor e frequente partida forçada;
- Tensões mecânicas causadas por laminações soltas;
- Estresses ambientais devido à contaminação por produtos químicos; e
- Tensões magnéticas por causa do desequilíbrio de força eletromagnética. (ATTA; IBRAHIM; GILANY, 2022).

Alguns dos efeitos secundários mais comuns das barras quebradas do rotor são:

- Barras quebradas podem causar faíscas, sendo tal condição preocupante quando relacionada a áreas de risco, como aquelas sujeitas a explosões, por exemplo;
- Se uma ou mais barras do rotor forem quebradas, as barras saudáveis são forçadas a conduzir uma corrente adicional, causando danos ao núcleo do rotor devido a temperaturas elevadas persistentes nas proximidades das barras quebradas;
- Barras quebradas causam oscilações de torque e na velocidade no rotor, provocando desgaste prematuro dos rolamentos e outros componentes;
- À medida que o rotor gira em alta rotação, as barras quebradas do rotor podem levantar-se da ranhura devido à força centrífuga e atingir o enrolamento do estator, causando assim a pane do equipamento;
- A assimetria do rotor (o rotor descentralizado), estática ou dinâmica, pode fazer com que o rotor entre em contato com o enrolamento do estator, causando danos ao mesmo e ao próprio rotor, podendo ocasionar uma potencial parada da máquina. (ATTA; IBRAHIM; GILANY, 2022).

Nas Figuras 8a e 8b é ilustrado um caso no qual o motor desarmou durante a operação causada pelo rompimento do isolamento do enrolamento do estator, por conta da barra rotórica quebrada e projetada. Logo, as falhas do rotor, como uma barra rompida, não somente causam

uma parada forçada da máquina, mas também aumentam os riscos de segurança na indústria como um todo (ANTONINO-DAVIU; PONS-LLINARES; LEE, 2016).

Figura 8 – Rotor de um motor 3.3 kV 450 kW



Fonte: (ANTONINO-DAVIU; PONS-LLINARES; LEE, 2016)


Um dos métodos mais usados para o diagnóstico de barras quebradas, em tempo real, é a chamada Análise da Assinatura da Corrente do Motor (sigla MCSA em inglês – *Motor Current Signature Analysis*) que, segundo (DIAS; PEREIRA, 2018) é uma das mais importantes técnicas usadas para a identificação deste tipo de falha, porém com algumas desvantagens relacionadas à identificação de barras quebradas quando o MIT está operando em baixo escorregamento, por exemplo, ou seja, com pouca ou nenhuma carga.

Ademais, a técnica MCSA exige ao menos uma resolução em frequência em torno de 0,01 Hz, a fim de garantir uma medição precisa das bandas laterais harmônicas necessárias para a detecção da falha no rotor, além de apresentar muitas vezes casos de falso positivo e/ou falso negativo para casos de barras quebradas não adjacentes, dada ainda a necessidade de se estimar com precisão a velocidade de eixo do motor, sendo tal procedimento normalmente difícil em um ambiente industrial (DIAS; PEREIRA, 2018; DIAS; IGLESIAS-MARTÍNEZ, et al., 2019; SILVA; ALVES, 2020).

Cabe destacar que, o tema ora escolhido, em particular o uso de redes neurais artificiais para a detecção de defeitos, por exemplo, desperta ainda um interesse crescente por parte da comunidade científica, no seu campo de conhecimento, como pode ser visto na Figura 9. No gráfico é possível observar a quantidade de publicações recuperadas no período de 2018 a 2023, em uma busca realizada na base Scopus, utilizando as palavras-chave “*defect detection convolutional neural network*”. Conclui-se que as publicações que exploram a utilização das redes neurais, como é o caso do presente trabalho, para identificar defeitos ou falhas em

diferentes tecnologias aumentaram de forma considerável durante os últimos 5 anos, o que demonstra a relevância crescente do assunto.

Figura 9 – Publicações com a expressão “*defect detection convolutional neural network*” na base Scopus.



Fonte: Adaptado de Silva (2022)

Em outra consulta realizada recentemente na base da IEEE (*IEEE Xplore*), mais especialmente no mês de junho de 2023, usando a combinação de palavras "*BROKEN BARS*", resultou em um número considerável de trabalhos associados a quebra de barras nos motores de indução trifásicos, quais sejam:

- 1467 publicações, considerando trabalhos em congressos e *journals*, desde o ano de 1910;
- 446 publicações nos últimos 6 anos, ou seja, entre 2017 e 2023, também considerando congressos e *journals*;
- Ao considerar apenas as publicações em *journals* temos os seguintes números:
 - 339 Artigos publicados sobre "*Broken Bars*" em toda a base da IEEE.
 - 103 Artigos nos últimos 6 anos, ou seja, 30%.

Esses números mostram a relevância atual do tema para esta pesquisa; sendo que uma outra informação importante é o número de citações nos trabalhos publicados nos últimos 5 anos, conforme pode ser observado abaixo:

- Número total de citações recebidas pelos 92 trabalhos publicados em *Journals*: 1257
- Média de citações por trabalho: 15,91 (um número importante para trabalhos publicados desde o ano de 2017 até agora).

Em resumo, algumas escolhas para a condução do trabalho foram ponderadas, a fim de justificar a presente abordagem, quais sejam:

1. Por quê foi avaliado este tipo de defeito/falha no motor de indução trifásico?

Como destacado pelos trabalhos levantados na literatura, além de outros (GANA; ACHOUR; LAGHROUCHE, 2023), a detecção do rompimento de barras nos motores de indução trifásicos ainda se mostra de grande interesse pela comunidade científica, dadas as importantes consequências relacionadas ao seu surgimento, como os custos e prejuízos advindos da manutenção da própria máquina, caso a avaria não seja detectada precocemente e/ou a perda da produção associada à parada do equipamento.

2. Por quê razão se optou por investigar o uso de um sensor instalado no interior da máquina, posicionado próximo ao seu entreferro, e não o sinal oriundo da corrente do estator, para contribuir para a detecção da quebra de barras rotóricas?

Muito embora o uso da corrente do estator seja caracterizada por uma abordagem não invasiva e abordada por muitos estudos, outros trabalhos recentes tem demonstrado o interesse pelo monitoramento do fluxo magnético no interior da máquina (DIAS; PEREIRA, 2018) e (DIAS; SILVA, 2022), em especial pelo fato do sinal medido nesses casos ser menos suscetível a interferências externas e capaz de detectar alterações no seu comportamento dinâmico em função das alterações significativas de amplitude muitas vezes observada para os casos de barras quebradas, como é o objetivo da presente pesquisa.

3. Por quê usar informações como imagem e redes neurais (RNs) para a detecção da falha rotórica?

Devido aos bons resultados alcançados pelas RNs em diversas tarefas nos últimos anos, tais como: classificação de imagens; reconhecimento de fala e tradução de caligrafia humana com precisão humana, é possível constatar que as RNs são simples porque são modelos treináveis e escaláveis, além do fato de serem facilmente aplicados hoje em um ambiente de processamento paralelo das Unidades de Processamento Gráfico (GPUs) e, por último, mas não menos importante, os modelos são facilmente reutilizáveis, sendo os mesmos possíveis de serem treinados em novos dados sem reiniciar (CHOLLET, 2021).

Neste sentido, o presente estudo é motivado pela possibilidade de oferecer uma contribuição para a detecção de barras rotóricas quebradas no MIT, em casos de barras defeituosas adjacentes e não-adjacentes, sem a necessidade de se estimar a rotação de eixo da

máquina e ainda que seja aplicada em toda a faixa operacional de carga do equipamento de forma eficiente e em tempo real.

1.4 DELIMITAÇÃO DO TEMA

Para esta pesquisa, o foco é a detecção de uma, ou mais barras rotóricas quebradas, para um motor de indução trifásico, do tipo gaiola de esquilo trifásico, operando em uma ampla faixa de carga, mas em regime permanente e alimentado por tensão nominal. Ademais, o trabalho investigou ainda a identificação de barras quebradas não-adjacentes. Logo, não foi objeto de estudo na presente pesquisa investigar a detecção da referida falha para o MIT operando na condição transitória e/ou em condições de alimentação desbalanceada.

1.5 IDENTIFICAÇÃO DE OPORTUNIDADES DE PESQUISA

As barras do rotor geralmente quebram na conexão com o anel de curto-circuito, onde se verifica um maior estresse termomecânico. É comum que as barras adjacentes às barras danificadas também se rompam por conta da redistribuição da corrente que por elas passam aumentando o estresse operacional sobre elas. Entretanto, estudos têm mostrado que as falhas das barras rotóricas não-adjacentes são de difícil detecção uma vez que a assimetria magnética verificada a partir do estator é cancelada se duas barras quebradas estiverem separadas por 90° (elétrico) ou por 1/2 polo magnético (ou se 3 barras quebradas se encontram separadas por 120° Elétrico) (PARK *et al.*, 2020).

Adicionalmente, outros trabalhos ainda enfatizam a necessidade de se investigar outras técnicas capazes de detectar a falha no rotor para o motor operando em baixa carga (DIAS; PEREIRA, 2018).

Portanto, o trabalho ora desenvolvido é orientado para contribuir com a detecção de barras rotóricas quebradas, investigando o uso dos sinais coletados de uma sonda de efeito Hall instalada próxima ao entreferro da máquina e convertendo tais sinais como imagens discretizadas, como foi melhor descrito no Capítulo 4. Deste modo, a seguir é apresentado a questão de pesquisa a ser respondida por este trabalho.

1.6 PROBLEMA DE PESQUISA

Como é possível detectar com eficácia o rompimento de barras rotóricas em um MIT, usando as perturbações de fluxo no entreferro da máquina como sinais de imagem?

As proposições que se seguem são consideradas para efeito da presente abordagem:

- Presença de alterações pertinentes, ou variação na densidade de fluxo magnético do entreferro, observada na sonda de efeito Hall, como consequência da presença de barras quebradas no rotor do MIT;
- Tais alterações podem ser medidas a partir da sonda Hall e os sinais convertidos em imagens discretizadas são capazes de agregar características importantes para diferentes condições estruturais do rotor; e
- Uma rede neural profunda é capaz de classificar a condição do rotor, face a presença ou não de defeito.

1.7 OBJETIVOS

1.7.1 Objetivo geral

O presente trabalho tem como objetivo geral desenvolver um modelo computacional, fundamentado em uma rede neural profunda, para a detecção de barras rotóricas rompidas em um motor de indução trifásico para uma ampla faixa de carga a partir de imagens geradas do sinal obtido da sonda Hall.

1.7.2 Objetivos específicos

Os objetivos específicos do estudo são:

- Identificar barras quebradas (uma ou mais barras adjacentes e não adjacentes) a partir de sinais provenientes de uma sonda de efeito Hall instalada próximo ao entreferro do motor;
- Gerar imagens a partir do sinal obtido da sonda Hall, com e sem o operador morfológico de erosão, e usar um modelo baseado em uma rede neural profunda para a classificação da condição estrutural do rotor (saudável ou barras quebradas);

- Implementar e testar o modelo desenvolvido, usando o banco de imagens criado como entradas, a fim de identificar as barras quebradas para o motor operando em uma ampla faixa de carga (desde a vazio até a sua condição nominal);
- Avaliar a eficácia do classificador modelado para a detecção e identificação de barras quebradas adjacentes e não-adjacentes, considerando ainda casos de barras defeituosas distribuídas em diferentes pólos magnéticos da máquina;
- Avaliar a eficácia do classificador para o motor alimentado por um inversor de frequência; e
- Comparar o modelo classificador com a tradicional técnica MCSA.

1.8 ORGANIZAÇÃO DO TRABALHO

A presente dissertação está estruturada como se segue abaixo, ou seja, nos capítulos enumerados na seguinte sequência:

- I. O capítulo de número um, apresenta uma abordagem global contextualizando a grande relevância no âmbito nacional e internacional no que concerne o uso dos motores de indução trifásicos;
- II. O capítulo de número dois, é-nos apresentado uma revisão da literatura no que se refere as principais técnicas aplicadas nos últimos anos para a identificação de falhas no rompimento parcial e até mesmo total de barras na conexão com o anel de curto-circuito;
- III. O capítulo de número três é demonstrado o alicerce teórico do trabalho, debruçando-se minuciosamente a estrutura do MIT, as técnicas de transformação do sinal em imagens, assim como a técnica de *Deep learning* aplicada para a detecção das falhas implementado neste trabalho;
- IV. O capítulo de número quatro, debruça-se nos detalhes os principais materiais usados, assim como a metodologia escolhida;
- V. O capítulo de número cinco, apresenta os possíveis resultados alcançados e uma discussão;
- VI. O capítulo de número seis, apresenta as conclusões provenientes deste estudo.

2 REVISÃO DA LITERATURA

A demanda pelos MIT's nas últimas décadas provocou a geração de esforços de pesquisas tanto no monitoramento das suas condições operacionais regulares, quanto ao diagnóstico de eventuais falhas. Bindu;Thomas (2014) e MORINIGO-SOTELO *et al.*, (2018) mostraram que as falhas do rotor incluem falhas no anel e nas barras conforme ilustrado no Capítulo 1. Esses tipos de falhas têm origem em um ou na combinação de vários fatores, como se segue abaixo:

- i. - Tensões dinâmicas devido a torques pulsantes, forças centrífugas concentradas e oscilação de torção do eixo;
- ii. - Estresses térmicos causados por pontos quentes, sobrecargas, faíscas devido à fabricação imperfeita do rotor, e partidas frequentes e transientes de conexão;
- iii. - Tensões mecânicas causadas por laminações soltas etc.;
- iv. - Estresses ambientais devido à contaminação por produtos químicos; e
- v. - Estresses magnéticos devido a desequilíbrios de forças eletromagnéticas.

Conforme já anteriormente descrito, as abordagens empregadas atualmente para o diagnóstico e detecção de falhas rotóricas podem ser classificadas como invasivas e não-invasivas. As técnicas invasivas utilizam sensores que são instalados no interior do motor, ao passo que as não-invasivas normalmente monitoram grandezas na carcaça do equipamento ou em conexões elétricas/mecânicas externas. Em grande medida, pode-se afirmar que o monitoramento e diagnóstico de barras quebradas nos MIT baseiam-se em métricas não-invasivas, mais concretamente, na coleta e avaliação de grandezas obtidas por meios não intrusivos nos equipamentos, por conta da facilidade de instalação dos sensores responsáveis pela coleta de dados, quer seja em campo, ou em uma planta industrial, por exemplo.

Nos últimos 70 anos alguns trabalhos de pesquisa foram desenvolvidos para observar parâmetros funcionais do motor, como a elevação de temperatura nas diversas partes da máquina, com intuito de aumentar a compreensão do seu comportamento (HEIDBREder, 1958), porém, foi a partir da década de 60 que foram desenvolvidas e aplicadas algumas técnicas de observação e detecção de falhas pontuais nos motores de indução trifásico. (SMITH; HANSON, 1975) surgiu com a sugestão de usar sensores de temperatura com o objetivo de observar a variação de temperatura nas barras de um MIT para que se pudesse aferir as reais condições da gaiola em todas as fases do funcionamento dos equipamentos, isto é, partida, funcionamento normal e aceleração do motor.

Os requisitos para a identificação de falhas nos motores variam, e podemos assim verificar de que as abordagens usadas atualmente para a detecção de falhas no rotor podem empregar de simples sensores com técnicas de amostragem como corrente e tensão, sendo que para sensores invasivos é possível aplicar técnicas especiais de amostragem como é o caso de sensores de fluxo de entreferro.

Nas últimas duas décadas, muitos trabalhos aplicaram diferentes técnicas de detecção de diagnóstico de falhas (FDD) nos MIT, falhas descritas nas literaturas tais como, (CAPOLINO; ANTONINO-DAVIU; RIERA-GUASP, 2015), (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2015), (LIU; BAZZI, 2017), (HASSAN *et al.*, 2018), (A. BELLINI *et al.*, 2008) e (HENAO *et al.*, 2014). No entanto, (CAPOLINO; ANTONINO-DAVIU; RIERA-GUASP, 2015), (RIERA-GUASP; ANTONINO-DAVIU; CAPOLINO, 2015), (A. BELLINI *et al.*, 2008) e (HENAO *et al.*, 2014) forneceram ampla revisões de técnicas FDD de sistemas acionados por motor, incluindo vários tipos de máquinas elétricas e tipos de falhas (falhas nas barras do rotor - BBF, falhas no estator, excentricidade etc.)

Da mesma forma, tem-se um levantamento abrangente dos métodos FDD para as quatro principais falhas nos IM, quais sejam: falhas de barra quebrada, falhas entre espiras do estator, falhas de excentricidade, e falhas nos rolamentos (LIU; BAZZI, 2017). Neste trabalho, diferentes métodos de FDD antes de 2016 foram usados e comparados em vários aspectos. Em contrapartida, e uma tentativa para dar mais atenção às falhas de barras quebradas nos MITs, uma revisão mais detalhada de métodos de detecção e diagnóstico antes de 2017 foram demonstradas no trabalho de (HASSAN *et al.*, 2018).

A Tabela 1 apresenta as principais categorias de métodos para a detecção de falhas das barras rotóricas destacadas por alguns trabalhos recentes, sendo possível observar que a assinatura BBF é ainda o método mais comum na literatura, em comparação com outros estudos.

Tabela 1 – Métodos empregados na detecção de barras quebradas nos últimos anos

	Y. Liu and A. M. Bazzi, ``A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art,"	O. E. Hassan, M. Amer, A. K. Abdelsalam, and B. W. Williams, ``Induction motor broken rotor bar fault detection techniques based on fault signature analysis: A review,"	MOHAMED ESAM EL-DINE ATTA 1, DOAA KHALIL IBRAHIM 2, AND MAHMOUD I. GILANY "Broken Bar Fault Detection and Diagnosis Techniques for Induction Motors and Drives: State of the Art"
DATA DA PESQUISA	2017	2018	2022
Maquinas de interesse	Motores de indução gaiola de esquilo alimentados por linha e inversores	Principalmente motores de indução de gaiola de esquilo alimentados por linha e alimentados por inversor	Motores de indução gaiola de esquilo alimentados por linha e inversores
Falhas relacionadas	Falhas de barra quebrada, falhas entre espiras, falhas de rolamento e excentricidade	Falhas de barra quebrada	Falhas de barra quebrada incluindo barras quebradas parciais e barras quebradas não adjacentes sob condições de partida e estado estacionário
Métodos relacionados a falhas de barras quebradas	<ul style="list-style-type: none"> • Métodos baseados em domínio de frequência • Métodos baseados em domínio de frequência e de tempo • Métodos baseados no domínio do tempo • Métodos baseados em dados 	<ul style="list-style-type: none"> • Métodos baseados em domínio de frequência • Métodos baseados em domínio de frequência e de tempo • Métodos baseados em dados 	<ul style="list-style-type: none"> • Métodos baseados em estimativa de resistência • Métodos baseados em estimativa de parâmetros • Métodos baseados em gêmeos digitais • Métodos baseados em domínio de frequência • Métodos baseados em domínio de frequência e de tempo • Métodos baseados no domínio do tempo • Métodos baseados em dados
Estudo de assinaturas de falhas de barras quebradas	<ul style="list-style-type: none"> • Assinatura de corrente • Assinatura de fluxo • Assinatura de vibração 	<ul style="list-style-type: none"> • Assinatura de corrente • Assinatura de tensão • Assinatura de vibração • Assinatura Acústica 	<ul style="list-style-type: none"> • Assinatura de corrente • Assinatura de tensão • Assinatura de fluxo • Assinatura de vibração • Assinatura Acústica

Fonte: Adaptado de (ATTA; IBRAHIM; GILANY, 2022)

Apesar de muitas pesquisas terem afirmado de que a técnica MCSA é a de maior uso nos dias de hoje no que concerne ao diagnóstico e identificação de falhas de barras rotóricas em um MIT, principalmente para motores de grande capacidade, por conta da sua natureza não invasiva, diversos trabalhos sinalizaram problemas, ou desvantagens decorrentes do seu uso, quais sejam:

1. Indicações de um falso alarme para o caso de quebra de barras em rotores formados por muitas barras, frequentemente devido a uma estimativa incorreta da velocidade de eixo, ou ainda para o caso de barras quebradas não-adjacentes e variações de carga (LEE *et al.*, 2016);
2. Em motores de grande porte, ou seja, com escorregamento muito baixo, o MCSA tem dificuldades para detectar falhas no rotor, uma vez que os componentes da banda lateral estão

muito próximos da frequência fundamental, e tais motores na maior parte das vezes operam com escorregamento muito baixo durante a sua condição de carga nominal, geralmente inferior a 1%. (PUCHE-PANADERO *et al.*, 2009);

3. A grande necessidade em se monitorar a rotação, ou estimar com precisão o escorregamento do motor, para que seja possível detectar ou prever as harmônicas que podem aparecer no momento em que houver a quebra de uma ou mais barras do rotor (LEE *et al.*, 2016) e (KIA; HENAO; CAPOLINO, 2009);

4. A grande imprecisão de se detectar as barras quebradas em motores sujeitos a cargas inconstantes, sendo que a solução MCSA deve ser realizada em motores operando em regime permanente, ou carga constante (Lee *et al.*, 2016);

5. Dificuldade na detecção do defeito na gaiola dos motores de grande e médio porte, uma vez que em tais máquinas normalmente existe um número elevado de barras rotóricas e uma simples falha não é verificável aplicando a técnica MCSA com precisão (ZHANG *et al.*, 2011); e

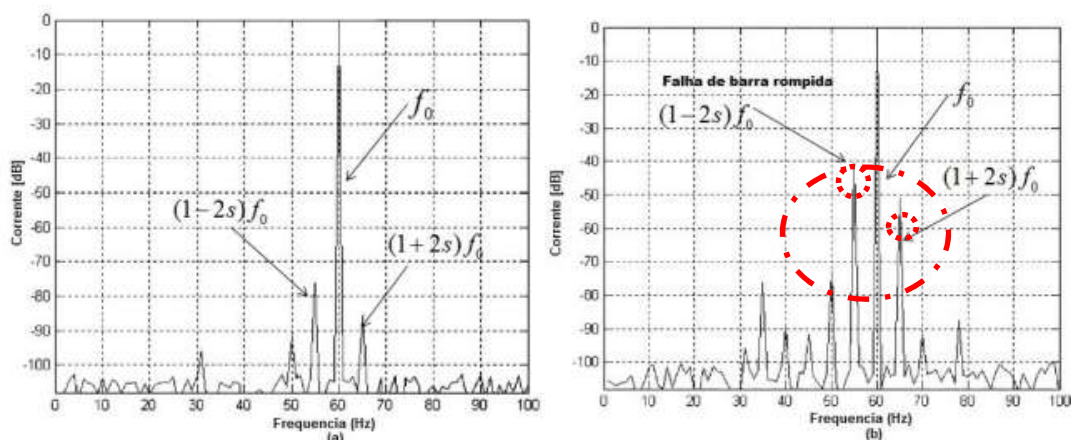
6. Quando a falha no rotor está presente e com a técnica aplicada não é possível identificar o defeito (falso negativo), como nas situações de quebra de barras não adjacentes, mais particularmente para aquelas espaçadas de 90° elétricos, sendo que a componente de frequência de interesse, prevista no método MCSA, está muitas vezes ausente (SIZOV *et al.*, 2009) e (RIERA-GUASP *et al.*, 2010).

O trabalho publicado por (LEE *et al.*, 2016) caminha na mesma linha de pensamento no que concerne as complicações descritas acima, e relacionadas com as causas mais comuns relacionados aos casos de falsos negativos e positivos, quando da observação e identificação de barras quebradas em um MIT, com a aplicação do método MCSA.

Outro ponto relevante é a necessidade de um sistema de coleta e processamento de dados ser capaz de armazenar os sinais com janelas de amostragem em 100s para a corrente de fase do motor, pois neste caso, torna-se necessário empregar com método MCSA uma resolução em frequência de 0,01 Hz para prever com precisão o escorregamento da máquina. Esta demanda só é possível com o uso de um hardware de maior custo para a implementação desta solução (VALLES-NOVO *et al.*, 2015) e (MOUSSA; BOUCHERMA; KHEZZAR, 2017).

.Na Figura 10 podemos observar as duas frequências responsáveis pela identificação do rompimento de barras (b), especialmente pelo surgimento da frequência localizada a esquerda da fundamental, no caso um sinal em 55,72 Hz. Quando esta frequência não está presente, entende-se que o rotor está saudável, isto é, sem barras quebradas (a). Uma comparação do presente método com o uso da técnica MSCA é apresentada no Capítulo 5.

Figura 10 – Espectro de frequências de um motor sem defeito (a) e um motor com barras rompidas (b) obtidos pelo método MCSA



Fonte: ABCM Série de Simpósios em Mecatrônica - Vol. 6

Devido à crescente importância dos motores de indução na indústria e aos altos requisitos de confiabilidade, novas abordagens surgiram nos últimos anos, principalmente aquelas que utilizam as chamadas técnicas de Inteligência Computacional (CI), a fim de apoiar um sistema de tomada de decisão no setor produtivo para o diagnóstico de eventuais falhas, tais como os sistemas especialistas, as redes neurais artificiais (ANN), os sistemas de inferência fuzzy, entre outras, muitos dos quais sendo acompanhados por técnicas de processamento de sinais que visam pré-processar o sinal de entrada para posteriormente construir as bases para o entendimento das características extraídas que representam as diferentes condições do motor.

Liu *et al.*, (2023) converteu os sinais elétricos acústicos brutos unidimensionais (1-D) no domínio do tempo em imagens usando métodos de processamento de imagens, sem usar os métodos atualmente usados, como FFT e WT.

Kumar; Hati (2022) propõem uma nova técnica de detecção de falhas de rolamento e detecção de barras no rotor usando o modelo baseado em uma rede neural convolucional dilatada. Uma técnica simples de conversão do sinal 1-D em imagem é aplicada, isto é, uma abordagem voltada para transformar o sinal de vibração 1-D adquirido de vários acelerômetros em imagens.

No trabalho de Ayas (2022) primeiramente se converteu os sinais no domínio do tempo em imagens por uma abordagem proposta de conversão sinal-imagem. Em seguida, as imagens convertidas em escala de cinza foram alimentadas em uma nova rede de aprendizado residual profundo (DRL), estruturada para aprender o mapeamento de ponta a ponta entre as imagens e a condição de integridade do rolamento do motor. Na mesma linha, o trabalho de (NIE *et al.*,

2023) propôs converter os sinais obtidos de duas fontes diferentes para imagens em tons de cinza combinando o método de conversão de sinal para imagem. Em seguida, uma rede neural convolucional (CNN) aprimorada foi usada para treinar as imagens em escala de cinza e, em seguida, implementar a detecção de falhas.

Portanto, nota-se que alguns trabalhos recentes procuraram abordar o tratamento de sinais no domínio do tempo na forma de imagens, a fim de detectar eventuais avarias nos motores de indução, porém, sem abordar ainda as condições operacionais propostas neste trabalho, como a detecção de barras em baixo escorregamento, ou ainda em condições de barras defeituosas não-adjacentes.

3 FUNDAMENTAÇÃO TEÓRICA


Os motores de indução são o tipo de motor elétrico com ampla utilização em diversas áreas tais como, nas indústrias de óleo e gás, cimento, petroquímicos, tração elétrica etc., devido à sua robustez e baixo custo (ATTA; IBRAHIM; GILANY, 2022).

Pelo seu elevado grau de utilização e importância, diversas pesquisas realizadas por diversos autores foram extremamente relevantes em suas avaliações na observância do comportamento do motor, com o objetivo de explorar em detalhes o seu funcionamento.

3.1 O MOTOR DE INDUÇÃO TRIFÁSICO COM ROTOR GAIOLA DE ESQUILO

O conceito fundamental do motor de indução trifásico foi idealizado por Nikola Tesla, ao final do século 19. A Figura 11 mostra o primeiro modelo de motor elétrico assíncrono de indução desenvolvido por Nikola Tesla (1888).

Figura 11 – Desenho do primeiro motor de indução projetado por Tesla



Fonte: (FALCHENKO, 2022)


Conforme o histórico deste motor, ele se tornou um dos mais importantes inventos do homem com relação ao desenvolvimento tecnológico.

Em uma máquina de indução as correntes alternadas (CA), os enrolamentos da parte fixa (estator) são basicamente os mesmos de uma máquina síncrona. Por outro lado, os enrolamentos da parte girante (rotor) estão eletricamente em curto-circuito e boa parte das vezes

não apresentam conectividades externas. As correntes são induzidas, isto é, há uma ação de transformador a partir dos enrolamentos do estator (UMANS, 2014).

O corte mostrado na Figura 12 contribui para um melhor entendimento das principais partes de um MIT. Assim sendo, os enrolamentos do rotor são na verdade barras sólidas de cobre ou alumínio fundidas, em muitos casos, acomodadas nas ranhuras da parte girante e por meio dos anéis de alumínio estarão curtos-circuitados, em suas extremidades, permitindo que as correntes induzidas possam fluir em um circuito fechado e assim gerar um campo magnético rotórico (UMANS, 2014).

Figura 12 – Motor de Indução Trifásico



Fonte: Adaptado de Fitzgerald (2015)

Umans (2014) descreve que diferentemente do motor síncrono, o motor assíncrono gira em uma velocidade bem mais reduzida que a velocidade de rotação do campo girante do estator. Assim sendo, o rotor não tem a mesma velocidade (não está sincronizado) com esse campo girante, por este motivo recebe o nome de motor assíncrono. Essa diferença entre as velocidades (entre a velocidade do rotor e a velocidade do campo magnético) é chamada de escorregamento do motor.

Muito embora o rotor opere de forma assíncrona, a onda de fluxo provenientes das correntes induzidas do rotor giram em sincronismo com a onda de fluxo do estator. Pode-se afirmar que isso é um requisito e está coerente com a capacidade de uma máquina de indução produzir conjugado, ou torque, líquido. Uma vez que os motores de indução operam com uma velocidade relativamente abaixo da velocidade mecânica síncrona, caso em que o fluxo de

armadura no motor de indução está à frente daquele do rotor, consequentemente é gerado um conjugado eletromecânico que traciona o rotor como no caso de um motor síncrono.

Como é sabido, com o circuito fechado, surge uma corrente, de modo que esta mesma corrente induzida gera em volta dos condutores um campo magnético com a tendência de se alinhar com o campo girante produzido pelo estator. No estator, o seu campo magnético gira em velocidade síncrona, e por isso o campo do rotor consegue acompanhá-lo.

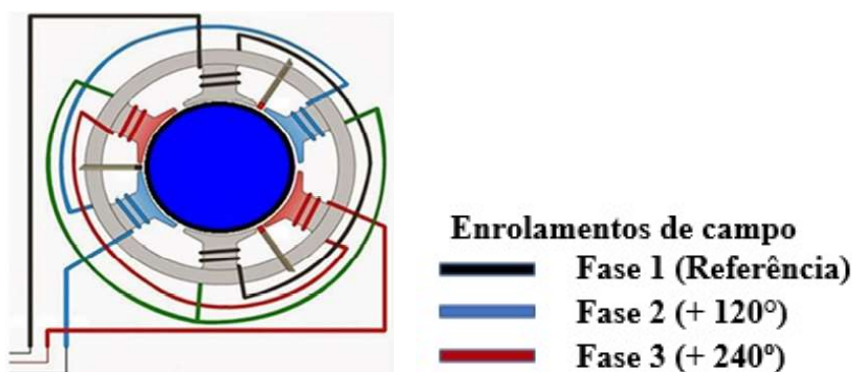
Apesar de estarem presentes ambos os campos magnéticos, o campo magnético do rotor segue o campo magnético do estator, porém, com um atraso em relação a este. Se as velocidades do estator e do rotor fossem as mesmas, não haveria entre eles um movimento relativo, ou seja, não haveria a presença de uma força eletromotriz (f.e.m.). Assim sendo, o rotor deve “escorregar” em relação ao estator, a fim de produzir o torque (MATTEDE, 2014).

Logo, no MIT o rotor com gaiola de esquilo é a parte móvel (rotativa) apoiado por rolamentos em ambas as extremidades instalados em flanges do MIT, e o estator (parte não rotativa) é responsável por gerar o campo capaz de induzir correntes nas barras do rotor. Isso produzirá uma força magnética, ou torque, que com a f.e.m. aplicada a um objeto estacionário, proporciona/induz a rotação.

É por esta a razão que ele recebe o nome de Motor de Indução, uma vez que a eletricidade é induzida no rotor por indução magnética ao invés de conexão elétrica direta por meio de cabos ou outros meios físicos.

A Figura 13 mostra uma distribuição dos enrolamentos de campo e as fases separadas em 120° , e as cores preta, azul e vermelha representam os enrolamentos das bobinas em cada fase que o motor recebe do fornecimento elétrico trifásico da fonte de energia elétrica. É por meio destas bobinas que é gerado o campo magnético que induz o rotor a produzir o movimento de rotação.


Figura 13 – Esquema do motor de indução com seis terminais



Fonte: Adaptado de (DINIZ; ARAÚJO, 2019)

O motor elétrico de indução trifásico tem a construção e o funcionamento simples, por conta disso este tipo de motor de alta eficiência é altamente utilizado na indústria. Para a fácil compreensão do seu funcionamento, vale lembrar que uma regra importante do eletromagnetismo, toda vez que uma corrente elétrica passa por um condutor elétrico é formado um campo eletromagnético neste condutor. Na Figura 14 podemos observar a criação do campo magnético por meio da passagem da corrente elétrica; se enrolarmos um condutor em várias espiras/bobinas e por meio dela passarmos uma corrente elétrica, será observado um campo magnético ainda maior.

Figura 14 – Corrente elétrica passando sobre um




Fonte: (MATTEDE, 2014)

Na Figura 15 é mostrado o esquema de uma bobina trifásica, sendo possível combiná-las e ligá-las em uma rede trifásica para a produção de um campo magnético proveniente da passagem da corrente elétrica em seus condutores.

Na Figura 15 temos um estator com 3 bobinas, recebendo a bobina 1 as pontas 1 e 4, a bobina 2 as pontas 2 e 5 e a bobina 3 as pontas 3 e 6.

Figura 15 – Bobina trifásica




Fonte: (MATTEDE, 2014)

Ao se unir as pontas 4, 5 e 6 entre si haverá a presença de uma ligação estrela e restam as pontas 1, 2 e 3, as quais serão conectadas as fases de um sistema trifásico.

Na Figura 16 está ilustrada a alimentação trifásica de um MIT, a qual se origina a partir de três corrente alternadas iguais, contudo, tais correntes encontram-se deslocadas umas das outras no tempo, sendo que tal deslocamento apresenta uma diferença de um terço de ciclo, ou seja, quando uma corrente está no seu valor máximo as outras duas não se encontrarão na sua máxima amplitude.


Figura 16 – Correntes elétrica deslocadas



Fonte: (MATTEDE, 2014)

Na Figura 17, observa-se três correntes I_1 , I_2 e I_3 de um sistema trifásico na parte superior e na parte mais abaixo é observado os campos magnéticos que são originados pelas bobinas do estator em cada instante.

Figura 17 – Campos magnéticos gerados a partir das correntes trifásicas



Fonte: (MATTEDE, 2014)

Em razão disso, tem-se o campo girante e sua velocidade de rotação dada por:

$$\omega_s = \frac{2\pi f}{p} \quad (1)$$

Na qual:

ω_s é a velocidade angular do campo girante (rad/s);

f é a frequência da rede (Hz);

p é o número de pares de polos

A velocidade de rotação do campo girante conhecida como velocidade síncrona e sua unidade de medida é rpm (rotações por minuto).

$$n_s = \frac{60f}{p} \quad (2)$$

Na qual:


n_s é a velocidade síncrona (rpm)

3.1.1 Escorregamento e operação da máquina em condições de baixa carga

Como já descrito, o funcionamento de um motor de indução se dá por meio da formação de um campo girante, sendo este formado por correntes induzidas no rotor, os quais contribuem de forma decisiva para a produção do chamado trabalho mecânico do motor. Como apresentado anteriormente, a rotação de eixo sempre será inferior a velocidade síncrona do campo girante do motor de indução. (MATTEDE, 2014).

A Figura 18 mostra a curva de variação do conjugado com a rotação para um MIT.

Figura 18 – Variação de rotação com a conjugado de carga



Fonte: (WEG, 2021)

A rotação do rotor sempre é menor do que a velocidade do campo magnético por conta de vários fatores, dentre eles podemos ressaltar o atrito que é gerado entre os rolamentos e o eixo do motor e principalmente por conta das cargas conectadas ao motor e por algumas perdas relacionadas a sua operação.

Neste sentido, o escorregamento em um MIT é definido como a diferença de rotação entre a velocidade síncrona e aquela observada no eixo da máquina, sendo tal grandeza resultante muitas vezes fornecida em porcentagem pela maioria dos fabricantes, podendo ser calculada como:

$$s = \frac{(ns - n)}{ns} \times 100\% \quad (3)$$

s = Escorregamento em porcentagem (%)

ns = Velocidade síncrona do motor em RPM

n = Velocidade medida no rotor em RPM

Logo, em um motor de indução trifásico que opera em vazio em sua partida, a sua velocidade estará muito próxima à velocidade síncrona. O movimento relativo é pequeno, desta feita, a tensão induzida na barra rotórica e o fluxo da corrente serão também pequenas. Sendo que a frequência é bem menor, sua reatância é quase zero e a corrente está quase em fase com a tensão do rotor. Assim sendo, a corrente consequentemente produz um campo magnético pequeno e com um ângulo acima de 90° atrás do campo magnético resultante (CHAPMAN, 2013).

Ao incrementarmos à carga do motor, seu escorregamento aumenta e diminui a velocidade, uma vez que são inversamente proporcionais. Sendo que a velocidade é menor, existe um movimento relativo mais evidenciado entre os campos magnéticos e o rotor da máquina. Um maior movimento relativo produz uma tensão maior, que consequentemente vai produzir uma corrente maior. Quanto maior for a corrente, maior será o seu campo magnético.

Portanto, o ângulo entre a corrente e o campo magnético no rotor muda na mesma forma. Como o escorregamento é maior, o aumento da sua frequência apresenta um atraso maior em relação à tensão. Portanto, a corrente se atrasa muito mais em relação à tensão e o campo magnético se defasa em relação à corrente. Desta forma, há um incremento da corrente e o ângulo entre o campo magnético resultante e o rotor também aumenta. O torque é diretamente

proporcional a corrente, ou seja, se aumentarmos a corrente o torque também aumenta, mesmo que o aumento no ângulo caminhe no sentido de diminuir o torque (CHAPMAN, 2013).

3.2 APRENDIZADO DE MÁQUINA E APRENDIZAGEM PROFUNDA

3.2.1 Aprendizado de Máquina

Diversas aplicações do cotidiano têm sido beneficiadas com a Inteligência Artificial (IA) para a resolução de problemas, com é o caso da economia e da pesquisa científica e tecnológica, também com várias aplicações bem-sucedidas na gestão pública e atividades que levem a benefícios sociais. Dentro da IA, uma área de estudo que merece destaque é a de Aprendizado de Máquina (AM). Dentro do AM, existem tarefas descritivas e tarefas preditivas. Em tarefas descritivas, busca-se o desenvolvimento de algoritmos que descreverão os dados. Entre as tarefas descritivas, uma das principais é o agrupamento de dados, que busca separar os dados que se assemelham dos que não se assemelham de maneira que os mesmos fiquem em diferentes grupos. De maneira geral, buscam-se grupos cujas distâncias entre seus membros sejam minimizadas, maximizando, ao mesmo tempo, a distância entre os grupos. Assim, as distâncias entre os dados de um mesmo grupo devem ser menores do que as distâncias entre dados em grupos diferentes. (CERRI; CARVALHO, 2017).

Segundo Taylor (2017), o aprendizado de máquina é uma ciência que visa fazer com que as máquinas executem determinadas tarefas sem precisar programá-las explicitamente. Chollet (2021) observou que a pesquisa nesta área tem um novo paradigma de programação. Ele explica que no modelo clássico de programação, o sistema recebe dados e regras como entrada e gera uma resposta como saída. No modelo de aprendizado de máquina o sistema recebe dados e respostas como entrada e crie uma regra como saída. Em outras palavras, a máquina é treinada e aprende determinados padrões para aplicar esse conhecimento adquirido na automação de uma tarefa (CHOLLET, 2021; RUNGTA, 2018).

Aprendizado de máquina aparece como um paradigma no qual os algoritmos são capazes de extrair informações dos dados disponibilizados sem serem explicitamente programados (MEDEIROS *et al.*, 2019). Assim sendo, é possível reduzir a necessidade de conhecimento prévio sobre o domínio no qual são empregados (DEISENROTH *et al.*, 2019).

Essa característica torna as técnicas de aprendizado de máquina indispensável para problemas que envolvem grandes massas de dados, possivelmente de difícil formalização, cuja programação manual de algoritmos tradicionais pode ser custosa ou até mesmo impossível (Goodfellow *et al.*, 2016).

O aumento da popularidade do uso das técnicas de aprendizado de máquina justifica-se pelo casamento entre os cenários atuais, que fazem uso de massas de dados cada vez maiores, e pela evolução na infraestrutura computacional (uso da GPU na nuvem e não só), que oferece o aporte necessário para a execução de técnicas mais avançadas. O pré-requisito fundamental para os algoritmos que compõem o paradigma do aprendizado de máquina é a capacidade que os mesmos têm de “aprender”. Mitchell define que um programa está aprendendo se seu desempenho na execução de um conjunto de tarefas, medido a partir de uma métrica de interesse, melhora com a experiência desse conjunto (Mitchell, 1997).

O processo pela qual o algoritmo tem seus parâmetros ajustados a fim de aprender a realizar uma tarefa é chamado de treinamento, que pode ser feito de diferentes maneiras, dependendo da construção dos dados em relação ao mapeamento entre entradas e saídas. Como consequência, os algoritmos de aprendizado de máquina podem ser divididos em supervisionado, não supervisionado e por reforço.

- **Aprendizado supervisionado:** os algoritmos têm acesso a um conjunto de dados Rotulados, ou seja, existem exemplos do mapeamento entre entradas e saídas. A presença dos rótulos possibilita que os algoritmos possam ajustar seus parâmetros para reproduzirem as mesmas saídas caso entradas semelhantes sejam apresentadas. Assim sendo, em uma analogia ao aprendizado humano, o algoritmo de aprendizado supervisionado tem acesso às respostas corretas das perguntas de um teste e aprende com o acesso a essas respostas. As respostas corretas das perguntas do teste são análogas ao mapeamento entre entradas e saídas promovido pelo rotulamento dos dados.

- **Aprendizado não supervisionado:** o conjunto de dados carece de rótulos, não existindo um mapeamento entre entradas e saídas. Nesse cenário, os algoritmos buscam relações e características (“*features*” em inglês) presentes no conjunto de dados que possam ser exploradas para classificar internamente os elementos. Assim sendo, essa classificação pode levar a grupos de dados que compartilhem características semelhantes ou a grupos de dados que possuam algum tipo de correlação. As relações inferidas são mensuradas por métricas que verificam se a classificação obtida é adequada, possibilitando que os algoritmos ajustem os seus parâmetros. Analogamente ao aprendizado humano, os algoritmos de aprendizado não supervisionado avaliam padrões, da mesma forma um bebê observa o comportamento e as características que definem uma pessoa conhecida, por exemplo. Observando os padrões de comportamento e características de uma pessoa qualquer, o bebê é capaz de associar aquele conjunto de entradas de dados à saída que determina se a pessoa é conhecida ou não. Não é necessário, nesse caso, que seja informado previamente ao bebê que ele conhece a pessoa.

- Aprendizado por reforço: os algoritmos atuam em um modelo de recompensas e punições à medida que o modelo interage com o ambiente onde está inserido.


Assim sendo, em vez de existir um mapeamento direto entre entradas e saídas, os resultados são obtidos a partir da realimentação (feedback loop) entre o sistema de aprendizado e o ambiente. A cada iteração, as ações disponíveis são apresentadas ao modelo no seu estado atual e, após a mudança de estado, recebe um sinal de reforço. De forma similar ao aprendizado humano, os algoritmos de aprendizado por reforço buscam instigar um conjunto de comportamentos desejados, como o uso correto de talheres para uma criança, através de recompensas, como palavras de reforço ou um prêmio. O objetivo dessa abordagem é escolher ações que maximizem a recompensa a longo prazo (KAELBLING et al., 1996).

De acordo com Chollet (2021), o aprendizado profundo é uma maneira de aprender a figurar dados sequencialmente por meio de camadas. Na maioria das vezes, esse aprendizado em camadas é alcançado por redes neurais. De acordo com Rungta (2018), *deep learning* é um algoritmo que imita a rede de neurônios do cérebro humano. No entanto, os modelos de *deep learning* não replicam tal igual ao cérebro humano, mas alguns conceitos fundamentais de *deep learning* são inspirados no modelo de funcionamento de como o cérebro funciona (CHOLLET, 2021). Além disso, Goodfellow, Bengio e Courville (2016) observam que o aprendizado profundo cria e replica apresentações e conceitos complexos de outras apresentações mais simples.

Por outro lado, Trask (2019) oferece outra maneira de visualizar como os domínios mencionados anteriormente estão relacionados entre si. Na Figura 19 é possível observar que, segundo o autor, o aprendizado de máquina contém a aprendizagem profunda, assim como na Figura 20 de Chollet (2021). No entanto, a IA não engloba as outras duas áreas, mas sim possui uma interseção entre o aprendizado de máquina e aprendizagem profunda.

Assim, Trask (2019) descreve aprendizado de máquina como o campo ou ramo da inteligência artificial dedicado em estudar e desenvolver máquinas que podem aprender. Também pontua aprendizagem profunda como um conjunto de métodos, os quais são normalmente representados por meio de redes neurais artificiais. Além disso, Trask (2019) destaca que as redes *deep learning* são utilizadas para resolver diversos tipos de problema, os quais estão presentes em diversas áreas de estudo, como computação visual, processamento de linguagem natural e reconhecimento de fala.

Figura 19 – Relação entre áreas de estudo segundo Trask



Fonte: Adaptado de Trask (2019).

3.3 REDES NEURAIS

3.3.1 Definição e história

Segundo Taylor (2017), as redes neurais artificiais (ANs) são algoritmos de aprendizado de máquina inspirados no cérebro humano. Haykin (2010) também apresentou uma ideia semelhante, observando que os RNs são arquiteturas computacionais ou máquinas projetadas para modelar com base em como o cérebro humano realiza determinadas tarefas. Os autores também apontam que as redes passam por um processo de aprendizado por meio de múltiplas conexões entre unidades de processamento simples conhecidas como neurônios. Por outro lado, é importante considerar que as redes neurais artificiais não podem jamais ser comparadas ao ponto de equipará-lo ao poder do cérebro humano HAGAN MARTIN et al., (2014). Os neurônios artificiais são apenas uma simples abstração em comparação com os neurônios biológicos. No entanto, RNs podem ser treinadas para realizar tarefas computacionais complexas, como reconhecimento de imagem e processamento de linguagem natural (HAGAN MARTIN et al., 2014; TAYLOR, 2017).

Nesse sentido, a evolução do estudo da RNs ao longo dos anos tem sido assegurada por acadêmicos de diversas áreas, que desenvolveram novos conceitos e métodos que geraram melhores resultados. O trabalho que marcou o início da rede foi feito por Warren McCulloch e Walter Pitts no início da década de 1940. Eles mostram que, em princípio, as redes neurais podem computar funções coerentes ou aritméticas. Na década subsequente o conhecimento teórico foi posto em prática, e a primeira rede neural foi desenvolvida por Frank Rosenblatt, do tipo Perceptron, sendo esta uma RN básica composta por alguns neurônios. Portanto, a criação

do modelo Perceptron permitiu uma importante contribuição no sentido de aumentar o interesse no campo das redes em desenvolvimento. No entanto, alguns anos depois, Marvin Minsky e Seymour Papert publicaram um livro no qual apontavam que uma rede do tipo Perceptron tinha limitações e que, com ela, não seria possível resolver diversos problemas. Na década de 1960, devido à influência de Marvin e Seymour e à escassez de computadores com maior capacidade, a área de estudo das RNs atravessou por um período de desenvolvimento mais lento (HAGAN MARTIN et al., 2014; MINSKY; PAPERT, 1969).

No entanto, os estudos continuaram e, na década de 1980, as pesquisas sobre redes neurais começaram a crescer novamente. Isso aconteceu por vários motivos. Por um lado, computadores e estações, de trabalho tornaram-se mais acessíveis. Outra razão é a introdução do conceito de novos mecanismos estatísticos por John Hopfield. Além disso, muitos pesquisadores descobriram o algoritmo de backpropagation usado para treinar redes de neurônios multicamadas (HAGAN MARTIN et al., 2014).


Em anos posteriores, ao tentar usar o backpropagation para treinar redes neurais profundas, outros pesquisadores não foram bem-sucedidos como se esperava. Consequentemente, o estudo das RNs teve um novo período de esfriamento de aproximadamente vinte anos (KARPATHY, 2016). Apesar disso, as pesquisas continuaram, embora em ritmo mais lento, e em 2006 Geoffrey Hinton e Ruslan Salakhutdinov publicaram um estudo sobre como treinar RNs profundas com o uso do backpropagation (HINTON; SALAKHUTDINOV, 2006).

Alguns fatores que permitiram esse crescimento recente são: foram descobertas melhores funções de ativação, que permitem um aprendizado mais veloz das redes neurais; mais dados estão disponíveis, permitindo uma rede mais eficiente; e a disponibilidade de unidades de processamento gráfico, as chamadas GPUs, encarregadas de realizar o processamento paralelo, o que agiliza o processo de treinamento de uma RN (KARPATHY, 2016).

3.3.2 Estrutura de redes neurais

Segundo Taylor (2017), uma rede neural consiste em neurônios que estão interconectados e distribuídos em três tipos de camadas: camadas de entrada, ocultas e de saída. Na Figura 20 vemos a estrutura básica de uma RN.

Figura 20 – Estrutura básica de uma rede neural.




Fonte: Adaptado de Taylor (2017)

Mas é importante ressaltar que uma rede neural não necessariamente possui camadas ocultas. Esse foi o caso dos Perceptrons, ou seja, as primeiras RN desenvolvidas na década de 1950. Pode-se observar que este tipo de rede continha apenas dois neurônios na camada de entrada e um neurônio na camada de saída (LEIJNEN; VEEN, 2020).

Além disso, como afirma Rungta (2018), o número de camadas ocultas que uma rede possui determinará se ela é rasa ou profunda. RNs rasas têm no máximo uma camada oculta e RNs profundas têm duas ou mais. Portanto, como acrescenta Chollet (2021), quanto mais camadas ocultas a rede possui, mais profunda ela é.

Nessa perspectiva, os neurônios, como unidades de processamento de informações, são cruciais para o funcionamento das redes neurais. Na Figura 21, nota-se que um neurônio consiste em quatro elementos básicos: um conjunto de conexões chamadas de pesos sinápticos; um viés (ou “bias” em inglês), que pondera a soma do sinal de entrada com os pesos; e, por fim, uma função de ativação cujo objetivo é criar restrições nas saídas dos neurônios (HAYKIN, 2010).

Figura 21 – Estrutura de um neurônio artificial




Fonte: Adaptado de Haykin (2010).

Em relação às funções de ativação, Karpathy (2016) cita algumas funções aplicadas às redes neurais: sigmoid, tangente hiperbólica ou tanh, *Rectified Linear Unit* ou ReLU e *Leaky ReLU*. Segundo Taylor (2017), as funções de ativação são a base das RNs porque aplicam transformações não lineares aos sinais dos neurônios. As operações realizadas apenas por entradas, pesos e vieses são lineares. No entanto, na maioria dos casos, as redes são utilizadas para resolver problemas não lineares, como a classificação de imagens. A Figura 22 mostra duas classes de problemas: classificação linear à esquerda e classificação não linear à direita.

Ambos destacam dois tipos de gráficos com a intenção de separá-los. No exemplo linear, uma linha reta é usada para separação, o que sugere que é um problema mais simples. Por outro lado, no caso não linear, é impossível obter uma boa separação com linhas retas. Neste caso, outros tipos de curvas são necessários. Portanto, fica claro que o problema não linear é mais complexo. As RNs lidam com o último tipo de problema, onde as funções de ativação são essenciais para “quebrar” a linearidade das redes para treiná-las com sucesso (TAYLOR, 2017).


Figura 22 – Problemas de classificações linear e não linear.



Fonte: Adaptado de (TAYLOR, 2017).

Trask (2019) descreve o sigmóide como uma função de ativação tradicional que mapeia qualquer valor de entrada e converte a saída em um número entre 0 e 1 (Figura 23). Isso permite que seja possível interpretar a saída dessa função como uma probabilidade.

Figura 23 – Função de ativação sigmoide.




Fonte: Adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).

Karpathy (2016) também menciona que, historicamente, o sigmóide tem sido a função não linear mais utilizada. Por outro lado, o autor levanta alguns pontos negativos relacionados a esse método de ativação. Em alguns casos, os neurônios podem ficar saturados - com valores muito próximos de 0 ou 1 - o que fará com que os gradientes realmente se cancelem durante a etapa de backpropagation. Esse processo basicamente garante o aprendizado da rede e será discutido com mais detalhes na Seção 3.4.3.3 (AGGARWAL; OUTROS, 2018). Além disso, a saída sigmóide não é centrada em 0, mas varia entre 0 e 1. No entanto, ao realizar o pré-processamento de alguns dados, é importante que eles estejam centrados em 0. Por fim, a fórmula sigmóide (equação 4) possui uma função exponencial, o que resulta em um custo de ativação um pouco maior do ponto de vista computacional. Ou seja, torna o processamento mais lento em comparação com outras funções de ativação (KARPATHY, 2016).

$$f(x) = \frac{1}{1+e^{-x}} \quad (4)$$

Nesse sentido, Trask (2019) também descreve a função de ativação da tangente hiperbólica ou tanh. Segundo o autor, tanh supera sigmoid para camadas ocultas porque varia de -1 a 1, conforme é mostrado na Figura 24, permitindo correlações negativas.

Figura 24 – Função de ativação tanh.



Fonte: Adaptado de (TRASK, 2019).


Karpathy (2016) enfatiza que a tangente hiperbólica tem uma vantagem sobre a sigmóide, que é fornecer uma saída centrada em 0. Por outro lado, outros problemas apresentados pelo sigmóide também existem no tanh: backpropagation de neurônios saturados

que elimina gradientes e funções exponenciais na formulação tanh da expressão (5), o que retarda o processamento.

$$\Phi(v) = \frac{e^{2v} - 1}{e^{2v} + 1} \quad (5)$$

Em seguida, Chollet (2021) discute a função de ativação, *Rectified Linear Unit* ou ReLU. Tal função produz um valor de saída igual a zero quando a entrada é menor que zero, e uma saída maior do que zero para uma entrada maior que zero, conforme mostrado na Figura 25.

Figura 25 – Função de ativação ReLU.



Fonte: Adaptado de (CHOLLET, 2021).

Goodfellow, Bengio e Courville (2016) enfatizam que ReLU é atualmente a função mais recomendada para treinar redes neurais. Karpathy (2016) também ratifica essa visão e destaca algumas características positivas dessa função de ativação. Primeiramente, os neurônios não estão saturados, pelo menos na região positiva da função onde x é maior que zero. Por outro lado, pela expressão (6), pode-se observar que a fórmula ReLU é computacionalmente eficiente, ou seja, não contém, por exemplo, uma função exponencial. Finalmente, outros pesquisadores empregaram uma unidade linear retificada em suas redes neurais, sendo possível constatar que esse tipo de ativação permite que a RN convirja, ou seja, tenha a capacidade de aprendizagem mais rápida que outras (KARPATHY, 2016).

$$\Phi(v) = \max \{v, 0\} \quad (6)$$

Por outro lado, Karpathy (2016) também aponta alguns aspectos negativos do ReLU. Assim como no sigmóide, a *Rectified Linear Unit* não gera saídas centradas em zero. Além disso, ao observar a Figura 26, é possível visualizar que para valores de x menores que zero, as saídas serão iguais a zero. Os gradientes dos neurônios com saída zero são canceladas pelo processo de *backpropagation*.

3.3.3 Funcionamento das redes neurais

Taylor (2017) e Karpathy (2016) em forma resumida detalham o funcionamento e treinamento de uma rede neural conforme pode ser verificada nos passos, ou etapas, relacionadas a seguir:

- a) Etapa 1: dividir os conjuntos de dados;
- b) Etapa 2: aplicar a propagação direta;
- c) Etapa 3: calcular a função de perda total;
- d) Etapa 4: aplicar o *backpropagation* para calcular os gradientes; e
- e) Etapa 5: atualizar os parâmetros da rede a partir do gradiente.

3.3.3.1 Divisão dos conjuntos de dados

Leijnen e Veen (2020) e Goodfellow, Bengio e Courville (2016) enfatizam a importância da era da big data, ou seja, de grandes volumes de dados no desenvolvimento de pesquisas no campo do aprendizado de máquina. Para que uma rede neural alcance um desempenho satisfatório em sua tarefa, é importante que ela seja treinada com uma grande quantidade de dados (CHOLLET, 2021; RUNGTA, 2018).

Assim, Taylor (2017) descreve uma forma de dividir um grande banco de dados em três conjuntos, para que possam ser aplicados em uma rede neural de diferentes formas. O primeiro são os dados de treinamento, que são usados para ajustar os parâmetros da rede, permitindo que ela aprenda. Em seguida, temos um conjunto de validação que é útil para minimizar o chamado problema de *overfitting*. Chollet (2021) afirma que o *overfitting* ocorre quando o desempenho de uma rede neural em dados anteriormente não relacionados se degrada em comparação com seu desempenho em dados de treinamento. Além disso, o principal objetivo de um modelo de aprendizado de máquina é a generalização, ou seja, conseguir bons resultados a partir de dados com os quais o algoritmo não interagiu anteriormente. Assim, o *overfitting* é um grande obstáculo no desenvolvimento de bons modelos de redes neurais (CHOLLET, 2021). Por fim,

Taylor (2017) cita um conjunto de testes projetados para prever e avaliar o uso de um modelo de RN ensinado.

3.3.3.2 Aplicação da propagação direta

No caso da chamada etapa de propagação direta, o fluxo de informações no RN é da esquerda para a direita, ou seja, da camada de entrada para a saída. A função de ativação recebe o resultado da soma e o transforma na saída final do neurônio. Aplicando repetidamente essas operações, a rede neural obtém uma saída final, ou seja, os neurônios da última camada possuem valores calculados a partir dessas operações (TAYLOR, 2017).

3.3.3.3 Cálculo da função de perda total

Taylor (2017) especifica que o próximo passo no treinamento de uma rede neural é calcular o erro total ou, como mencionado por Karpathy (2016), a função de perda total, esta função é a diferença entre a saída real da rede e a saída alvo calculada a partir do processo de propagação direta, ou seja, o resultado que a rede deveria realmente ter como saída para alcançar bons resultados. Nesse sentido, o objetivo de uma rede neural é minimizar a função de perda. Em outras palavras, quanto menor a diferença entre os resultados reais e alvo, concluiremos que a rede está bem treinada. (TAILEIRA, 2017).

Taylor (2017) afirma que existem vários tipos diferentes de cálculo de perda de rede ou erro total, tais como: erro quadrático médio, erro quadrático, raiz quadrada do erro médio e soma dos erros quadráticos. Cada função tem sua própria fórmula. Chollet (2021) também menciona duas propriedades: *Categorical Cross Entropy*, utilizada em problemas de diversas classes e *Sparse Categorical Cross Entropy*.

3.3.3.4 Atualização dos pesos e vieses da rede

Segundo Taylor (2017), o passo final no treinamento de rede é atualizar os pesos e vieses. Assim, após a backpropagation, a RN calculou os gradientes e determinou quais mudanças fazer em cada peso e viés da rede, sempre procurando otimizar de forma mais eficiente possível os pesos e vieses da rede.


3.3.3.5 Hiperparâmetros de redes neurais

Além de pesos, vieses, funções de ativação e perda, é importante considerar muitos outros parâmetros relacionados à criação de um modelo de rede neural. Nesse sentido, existem os chamados hiperparâmetros. Uma boa escolha de hiperparâmetros é essencial para otimizar o treinamento da RN e obter bons resultados com o modelo. Alguns deles são: otimizador, frequência de aprendizado (*learning rate*) ou taxa de aprendizado, tamanho do conjunto ou tamanho do lote (*batch size*), épocas (*epochs*) (CHOLLET, 2021; SMITH, 2018). Além disso, é importante ressaltar que não existe uma maneira fácil e predefinida de determinar os valores exatos de cada hiperparâmetro. No entanto, existem valores padrão que são recomendados para iniciar a prática do treinamento de uma RN. A partir desses valores iniciais, são feitos ajustes precisos e manuais para melhorar o desempenho da rede (KARPATHY, 2016). Em outras palavras, como Taylor (2017) apontou, uma RN não pode aprender de uma forma que ajuste automaticamente os hiperparâmetros como é feito com pesos e vieses. Em seguida, são apresentados os principais conceitos e algumas das recomendações dos pesquisadores para cada um dos hiperparâmetros mencionados.

Em relação ao otimizador, Chollet (2021) observa que a importância desse hiperparâmetro é determinar como a rede utiliza o gradiente calculado pela função de perda para atualizar os pesos e o viés. Nesse sentido, Karpathy (2016) menciona vários tipos de otimização: Stochastic Gradient Descent ou SGD, momentum, Nesterov Accelerated Gradient ou NAG, Adagrad, Adadelta, Adam e RMSProp. Além disso, o autor enfatiza que a taxa de aprendizado é um parâmetro amplamente utilizado em diversos otimizadores.

Taylor (2017) definiu a taxa de aprendizado como o tamanho do passo da RN para atingir o mínimo global. Em outras palavras, o objetivo de treinar uma rede neural é minimizar a função de perda. Portanto, a taxa de aprendizado é responsável pela rapidez ou lentidão com que o algoritmo aprende a atingir o mínimo global. Pode-se escolher um valor para essa taxa que permanecerá constante durante o treinamento ou pode-se programar o valor da taxa de aprendizado para diminuir à medida que o treinamento avança. Outra possibilidade é sugerida por Karpathy (2016) e é chamada de degeneração da taxa de aprendizagem (*learning rate decay*). A partir da Figura 26, é possível entender mais claramente o funcionamento desse hiperparâmetro e a importância de escolher um valor suficiente para atingir o mínimo da função de perda.

Figura 26 – Curva típica de comportamento da taxa de aprendizagem.



Fonte: Adaptado de Chollet (2021).

O tamanho do lote ou *batch size* tende a determinar a quantidade de dados de treinamento passados pela rede neural para atualizar os pesos e os vieses. Por exemplo, se houver 1.000 imagens no conjunto de dados de treinamento e o tamanho do lote for definido como 10, os pesos e pesos serão atualizados cem vezes (TAYLOR, 2017).

Por fim, uma época definida por Taylor (2017) define um ciclo completo na rede, ou seja, toda vez que a RN passa por todos os dados de treinamento enquanto treina a rede, uma época é finalizada.

3.4 PRINCIPAIS TIPOS DE REDE NEURAL

Segundo Taylor (2017), as redes neurais geralmente podem ser classificadas em duas categorias: diretas ou recorrentes. Na primeira, também conhecida como *forward*, os dados ou sinais trafegam da RN em uma direção, das entradas às saídas da rede. Amplamente utilizadas para reconhecimento e classificação de imagens, as redes convolucionais, também conhecidas como convnet, pertencem à categoria de RNs diretas. O convnet é caracterizado pela convolução, a aplicação de uma operação matemática em pelo menos uma de suas camadas (BONA KAMANO; BENGIO; COURVILLE, 2016). Por conseguinte, nas redes recorrentes as informações passam pela rede nos dois sentidos, podendo ocorrer laços, ou *loops*, durante o processo. Segundo Taylor (2017), essa arquitetura é um tipo de RN mais complexa e eficaz do que as redes neurais diretas.

No entanto, Leijnen e Veen (2020) apresentam um conjunto maior que inclui várias arquiteturas de redes neurais desenvolvidas ao longo dos anos. Além das redes direta e recorrentes, é mencionada a LSTM - *Long Short Term Memory*. Este tipo de RN possui neurônios especiais que trabalham na parte de memória do sistema para armazenar os sinais

vindos dos neurônios durante o treinamento da rede, o que evita a perda dessa informação durante a passagem entre camadas (CHOLLET, 2021). De acordo com Goodfellow, Bengio e Courville (2016), o LSTM é amplamente utilizado para resolver muitos problemas de processamento de linguagem natural.

Outro tipo de RN é a de Hopfield. Nesta arquitetura, cada neurônio está conectado a todos os outros, e cada um desempenha funções de entrada e saída no sistema. Um modelo de rede do tipo Hopfield é uma máquina de Boltzmann. Nesse caso, nem todos os neurônios são ativados porque alguns são mantidos ocultos. Outra rede que merece destaque é a GAN, que consiste em dois sistemas de rede. Um que tem a tarefa de gerar dados enquanto o outro, o discriminador, avalia sua autenticidade. (LEIJNEN; VEEN, 2020).

3.4.1 Redes neurais convolucionais


Karpathy (2016) apresenta algumas das principais aplicações das redes neurais convolucionais (RNC), quais sejam: classificação de imagens, detecção de objetos, reconhecimento facial e processamento de fala, entre outras. Adicionalmente, Hongtao e Qinchuan (2016) enfatizam que as redes convolucionais produzem resultados surpreendentes no domínio visual de processamento de dados. Chollet (2021) define a estrutura básica do RNC com duas camadas distintas: convolucional e pooling.

A camada de convolução é responsável por realizar a operação de convolução. Por exemplo, no contexto de uma rede treinada para classificar imagens, a convolução permite que o programa reconheça e aprenda padrões locais de uma imagem de entrada da amostra. Para ilustrar a importância e o desempenho da camada convolucional, a Figura 27 mostra um exemplo de aplicação de uma rede convolucional para classificar uma imagem de gato. A imagem deve ser lida de baixo para cima. A princípio, o programa aceita uma imagem de um gato e adiciona a primeira camada convolucional. Essa primeira camada foi capaz de detectar pequenos padrões e bordas na imagem.

Depois disso, uma segunda camada de convolução é aplicada na rede, o que permite reconhecer padrões ainda maiores e mais claros, como a orelha e o olho de um gato. Por fim, a partir dessas duas camadas convolucionais que reconhecem padrões hierarquicamente, a rede pode mostrar que a classificação da imagem de entrada é a classificação de um gato. Outra característica chave da CNN é que os modelos aprendidos são invariantes por translação. Isso significa que, uma vez que uma rede convolucional tenha aprendido um determinado padrão no canto superior esquerdo de uma imagem, ela pode reconhecer o mesmo padrão em qualquer

outro lugar da imagem, como no canto superior direito. Graças a isso, o modelo aprende mais rápido e processa as imagens com mais assertividade (CHOLLET, 2021).

Figura 27 – Operações convolucionais para reconhecer padrões em imagem de gato.




Fonte: Adaptado de Chollet (2021).

Nesse contexto, é importante enfatizar como os filtros e mapas de características funcionam em operações convolucionais. Os filtros são responsáveis por capturar determinadas características da entrada. Depois disso, um mapa de características é criado como saída. Um mapa é um tensor tridimensional que agrupa todos os detalhes extraídos a partir da convolução. Assim, esse processo é repetido de acordo com o número de camadas convolucionais no modelo (CHOLLET, 2021).

No entanto, a camada de *pooling* é responsável por realizar a operação de *downsampling*, cujo conceito está relacionado à redução ou compressão. Nessa operação, as representações da rede convolucional são reduzidas para tornar o modelo menor e mais gerenciável (KARPATHY, 2016). Para ilustrar essa operação, a Figura 28 ilustra como ocorre a *downsampling* na camada de *pooling*. À esquerda está o mapa de ativação com dimensões 256 x 256 x 64 que é comprimento, largura e profundidade. Pode-se ver que após a compressão o comprimento e a largura são reduzidos para 128x128, porém a profundidade permanece inalterável, 64 (CHOLLET, 2021).

Figura 28 – Operação de *downsampling* em uma camada de *pooling*.




Fonte: Autor

Além disso, é possível usar o *max pooling* ou *average pooling* para aplicar o *pooling*. Como menciona Chollet (2021), a primeira opção funciona melhor que a segunda para atingir o *downsampling*. Assim, a partir da Figura 29 é possível visualizar como funciona a função *max pooling*. Neste exemplo, um filtro 2 x 2 é aplicado com um passo de 2. Assim, o quadrado à esquerda é dividido em quadrados menores, conforme mostrado pelo círculo vermelho. Para cada um desses quadrados, o maior valor é escolhido para substituir todos os outros.

O quadrado arredondado tem valor máximo de 3. Nesse sentido, após o *max pooling*, os quadrados são substituídos pelo quadrado de maior valor, conforme descrito no elemento à direita. Também é importante notar como o tamanho do quadrado diminuiu de 4 x 4 para 2 x 2 após a operação de *max pooling*, porque esse é exatamente o objetivo desta operação.

Figura 29 – Aplicação de *max pooling* para atingir o *downsampling*.



Fonte: Autor

3.4.2 Desenvolvimento e implementação dos algoritmos de interesse em código

Primeiramente, para uma implementação dos algoritmos de interesse para o presente estudo, deve-se importar as dependências ou pacotes necessários; as bibliotecas utilizadas são a biblioteca do *TensorFlow* e o módulo do *Keras*. A biblioteca “*tensorflow*”, nomeada como “tf”, provê acesso às funções de manipulação e treinamento da rede neural. A módulo *Keras*

permite a criação dos modelos e o uso da base de dados. Também são importadas outras bibliotecas importantes para manipulação de imagens, como a biblioteca do “OpenCV”, importada como “cv2”, que permite o uso de *haarcascade* prontos para localização de características visuais críticas dentro da imagem. A versão do *TensorFlow* utilizada para o desenvolvimento dessa aplicação foi a versão 2.0.0, já a versão do *OpenCV* foi a versão 3.4.3.

3.5 CONCEITOS SOBRE PROCESSAMENTO DE IMAGENS E MORFOLOGIA MATEMÁTICA

3.5.1 Definições básicas sobre imagens

Um mapeamento retangular finito $\mathcal{D} \subset \mathbb{Z} \times \mathbb{Z}$ pode ser usado para definir a imagem f em conjunto de inteiros $\mathbb{K} = \{0, \dots, K\}$ onde $K = 2^b - 1$ que estaria representando o nível de cinza máximo para uma determinada imagem com profundidade $b > 0$ bits. Portanto, quando $b = 1$, f é considerada imagem binária e para $b > 1$, consideramos que f apresenta tons de cinza (SOILLE, 2003).

A intensidade ou nível é atribuído a uma imagem através de uma função bidimensional, $f(x, y)$, onde as coordenadas espaciais (plano) são representadas por x e y . Esta função define a amplitude em qualquer par de coordenadas (x, y) . Quantidades finitas e discretas de x , y e valores de intensidade de f formam uma imagem digital, que aparece como uma imagem cinza. (Gonzalez, 2010).

As imagens multiespectrais podem ser consideradas como um vetor de imagens em tons de cinza (f^1, f^2, \dots, f^N) , em que f^1, f^2, \dots, f^N são referentes às bandas 1, 2, ..., N , que diferem no número de bandas, onde uma imagem multiespectral geralmente consiste em uma faixa entre 3 e 20 bandas., sem necessariamente estarem coladas, e a imagem hiperespectral consiste em diversas bandas próximos umas das outras.

Pixels são elementos do espaço da imagem, ou seja, $p = (p_x, p_y) \in \mathcal{D}$ onde p_x, p_y estão as coordenadas horizontais p_x e p_y verticais do pixel p . Assim sendo, podemos considerar $f(p)$ como o valor da intensidade da cor ou nível de cinza associado a um pixel p . Um pixel p pode se conectar a outros pixels em seu ambiente. E este conceito de conectividade entre pixels refere-se às relações de adjacência (ou vizinhança): adjacências horizontais e perpendiculares denotado por $A_4(p) = \{(p_x, p_y), (p_x + 1, p_y), (p_x - 1, p_y), (p_x, p_y + 1), (p_x, p_y - 1)\}$ e as adjacências horizontais, diagonais e perpendiculares são denotadas por

$A_8(p) = \{(p_x, p_y), (p_x + 1, p_y), (p_x - 1, p_y), (p_x, p_y + 1), (p_x, p_y - 1), (p_x + 1, p_y + 1), (p_x + 1, p_y - 1), (p_x - 1, p_y + 1), (p_x - 1, p_y - 1)\}$. Começando com uma imagem binária X e uma relação de adjacência A , podemos definir um componente conexo (CC) como um subconjunto maximal C de pixels de X de modo que para \forall qualquer par de pixels p e q em C existe um caminho (p_1, p_2, \dots, p_n) tal que $p_1 = p, p_n = q$ e $p_i \in A_{(p_{i-1})}$ com $2 \leq i \leq n$. Assim sendo, podemos considerar que $CC(X, A)$ é o conjunto de CCs para a adjacência A , tal que A denota A_4 ou A_8 .

Em geral, o valor da imagem em qualquer coordenada (x, y) é formulado por $f(x, y)$, onde x e y são inteiros. A seção do plano real que abrange as coordenadas de uma imagem é chamada de domínio espacial, onde x e y são variáveis espaciais e coordenadas espaciais. A representação gráfica é útil ao trabalhar com conjuntos de tons de cinza cujos elementos são expressos em um grupo de três variáveis na forma (x, y, z) , onde x e y são coordenadas espaciais e z é o valor da intensidade f nas coordenadas (x, y) , se a intensidade for normalizada no intervalo $[0, 1]$, cada ponto da imagem terá o valor 0, 0,5 ou 1.

3.5.2 Imagens discretas

Diferentes tipos de imagens discretas aparecem dependendo do tipo de informação digital associada a cada pixel da imagem. As imagens binárias e em tons de cinza são diferenciadas pela faixa de valores atribuídos a pontos ou pixels na grade de digitalização. Ambas são imagens de canal único porque apenas um valor escalar é armazenado para cada pixel. O conceito de imagens multicanal refere-se as imagens onde um vector de valores escalares está associado a cada pixel, como os componentes vermelho, verde e azul das imagens coloridas.

3.6 OPERADORES MORFOLÓGICOS EM IMAGENS MONOCROMÁTICAS

Imagens binárias: cada pixel numa imagem binária tem apenas dois valores possíveis, normalmente representados como 0 (preto) e 1 (branco). Embora esta representação seja comum, existem também variações em que os valores são representados como "verdadeiro" e "falso", "ligado" e "desligado", ou outras combinações de pares opostos, que são frequentemente utilizadas no processamento de imagens para tarefas como a segmentação de

objetos, a detecção de bordos e o reconhecimento de padrões, são fáceis de aplicar aos algoritmos de processamento de imagem.

Além disso, as imagens binárias requerem menos espaço de memória do que as imagens a cores ou em tons de cinzento, uma vez que cada pixel tem apenas um bit de informação (0 ou 1), e são também mais fáceis de interpretar visualmente, uma vez que a região de interesse (normalmente apresentada a preto) e a região de fundo (normalmente apresentada a branco) podem ser claramente separadas.

Imagens em tons de cinzento: uma imagem em tons de cinzento pode ter tons que vão do preto (0) ao branco (255), com 0 a representar a ausência de luz (preto) e 255 a representar a luz máxima (branco). Os valores intermédios representam os tons de cinzento entre estes extremos. Neste tipo de imagem, cada pixel apenas armazena informação sobre o brilho da cena nessa posição, mas não informação sobre a cor. Isto significa que a imagem representa as diferenças de luminosidade da cena e que a imagem original é representada a preto e branco.

As imagens em escala de cinzentos são amplamente utilizadas no processamento de imagens, visão por computador, radiologia médica e fotografia a preto e branco. As imagens em escala de cinzentos não requerem informação de cor, mas são particularmente úteis em situações em que a análise das variações de brilho é importante. Existem várias formas de converter uma imagem a cores numa imagem em escala de cinzentos, incluindo o cálculo da média dos canais de cor (vermelho, verde e azul) e da luminância percebida para preservar características visuais importantes.

As imagens em escala de cinzentos são frequentemente utilizadas na análise visual e no processamento de imagens devido à sua simplicidade. As variações da escala de cinzentos podem realçar características importantes de uma cena, como arestas, texturas e gradientes de intensidade.

Por outras palavras, uma imagem em escala de cinzentos é uma representação visual que utiliza diferentes tons de cinzento para representar variações no brilho de uma cena, ao contrário de uma imagem a cores, que representa informações sobre a cor. Estas imagens são amplamente utilizadas numa variedade de aplicações em que a análise da luminância é fundamental.

As operações morfológicas de dilatação, erosão, em vez de apenas valores iguais a 0 ou 1, os pixels podem agora assumir valores em um intervalo de $[L_{min}, L_{max}]$.

Dilatação e Erosão

A dilatação de uma imagem monocromática f por um elemento estruturante b é definida como pode ser observada na Equação 7:

$$(f \oplus b)(x, y) = \max\{f(x - m, y - n) + b(m, n)\} \quad (7)$$

Na dilatação, o elemento estruturante é transladado por todas as posições da imagem e, em cada posição transladada, o valor do elemento estruturante é adicionado ao valor do pixel da imagem e o valor máximo é obtido.

A erosão de uma imagem monocromática f por um elemento estruturante b é definida do seguinte modo:

$$(f \ominus b)(x, y) = \min\{f(x - m, y - n) - b(m, n)\} \quad (8)$$

Tal como acontece com a dilatação, na erosão o elemento estruturante é transladado para todas as posições na imagem e, em cada posição transladada, o valor do elemento estruturante é subtraído do valor do pixel na imagem e o valor mínimo é obtido.

3.7 Operadores de imagens

O pré-processamento dos dados do sensor é essencial e consiste em extrair informações do sinal bruto de uma grande quantidade de dados, o que dificulta a operação. O conceito é converter o sinal de frequência de vibração numa imagem de tamanho de pixel $M \times M$ [30, 32] e anexar um contorno colorido à imagem que representa os valores de temperatura do motor. (KUMAR; HATI, 2022)

4 MATERIAIS E METODOS

4.1 CARACTERIZAÇÃO METODOLÓGICA

A metodologia proposta neste trabalho pode ser dividida respectivamente quanto ao seu objetivo, natureza, procedimento e abordagem da seguinte forma:

- 1) Realização em seu começo de uma pesquisa exploratória a fim de melhor conhecer o estado da arte acerca das principais técnicas voltadas para o diagnóstico de barras quebradas adjacentes e não adjacentes nos motores de indução trifásicos e também sobre as técnicas de aprendizagem de máquina mais empregadas em problemas de classificação usando imagens para a extração de características de um sinal;
- 2) Realização de uma pesquisa aplicada e experimental, uma vez que o objeto de estudo será mais bem compreendido por meio da experimentação de algumas condições de operação do motor em ambiente laboratorial; e
- 3) Realização de uma pesquisa quantitativa, pois haverá uma avaliação acerca dos dados a serem coletados e da sua relação com o objetivo primeiro da pesquisa, no caso a detecção da falha nas barras rotóricas, ou seja, se o motor está saudável ou com defeito.

Vale frisar que, a pesquisa experimental envolve submeter um fato a um experimento sob condições controladas e avaliá-lo coerentemente com critérios rígidos, medindo a constância da incidência e suas exceções, demonstrado por medições e legitimado pela experimentação (CHIZZOTTI, 2018).

Por conseguinte, este trabalho foi dividido nas etapas seguintes:

- Etapa 1: Definição e montagem da bancada para a realização dos experimentos;
- Etapa 2: Definição dos cenários operacionais e coleta de dados a partir do sensor Hall acomodado próximo ao entreferro da máquina, considerando o motor em condição saudável, ou seja, sem qualquer avaria, e com defeito na gaiola rotórica, operando em diferentes condições de carga, bem como em diferentes níveis de falha;
- Etapa 3: Transformação do sinal no domínio do tempo do sensor Hall para uma imagem RGB, com e sem o uso do operador morfológico de erosão;
- Etapa 4: A partir das imagens geradas e armazenadas na base de dados, aplicar uma rede neural do tipo CNN (Rede Neural Convolucional), a fim de classificar a condição do rotor do MIT, entre saudável e com defeito nas diferentes condições de avaria; e
- Etapa 5: Apresentar e discutir os resultados achados na presente abordagem.

A seguir será feito um detalhamento acerca de cada fase do trabalho:

4.1.1 Etapa 1: Montagem do aparato experimental


Como mencionado anteriormente, a primeira fase do estudo consistiu em avaliar os equipamentos experimentais necessários para obter dados para o motor operando sob várias condições de falha e torque carga, bem como em operação de rotor saudável.

Todos os experimentos foram realizados em laboratório, utilizando um motor especialmente fabricado para este estudo, pela empresa Equacional Elétrica e Mecânica Ltda.

O equipamento montado no laboratório para testes experimentais é mostrado na Figura 30, sendo que o MIT e demais instrumentos foram adquiridos por meio de fomentos obtidos junto à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) sob números 2016/02525-1 e 2018/05214-2. Conforme mostrado na Figura 31, o motor e especialmente a estrutura do seu rotor permitem conectar e/ou desconectar facilmente as barras com parafusos e porcas para simular barras do rotor danificadas, ou seja, a falha associada ao rompimento da barra com o anel de curto-circuito. Todo os equipamentos utilizados nesta etapa incluem ainda um sistema de alimentação de freio para a aplicação de carga no eixo da máquina, a sonda de efeito Hall instalada entre duas ranhuras do estator e próxima ao entreferro do motor e instrumentos para a aquisição e análise dos dados.


Conforme mostrado ainda na Figura 31, o motor de indução possui um sistema interno de frenagem eletromagnética por correntes parasitas capaz de aplicar uma carga mecânica ao seu eixo, e um ventilador cuja função é resfriar internamente o referido freio.

Figura 30 – Aparato montado no laboratório para a condução dos experimentos



Fonte: Autor

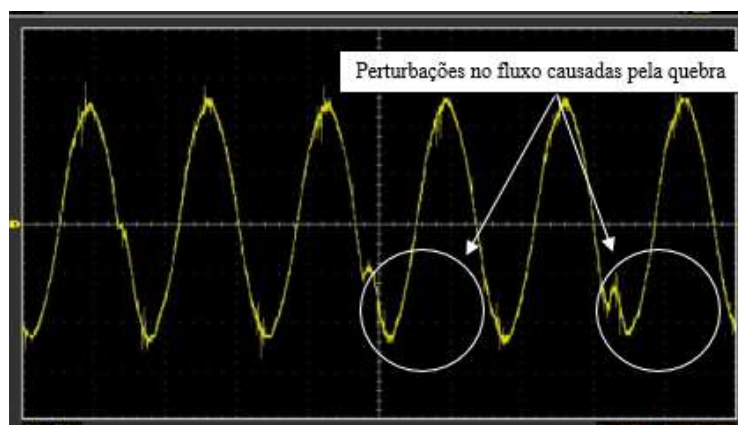
Figura 31 – Motor de indução usado para testes e coleta dos dados



Fonte: (SOUSA, 2017)

O sensor de efeito Hall foi utilizado para detectar alterações, ou perturbações no fluxo magnético do entreferro, em especial para aquelas causadas por barras quebradas (DIAS et al., 2018). A Figura 32 ilustra as perturbações causadas no fluxo do entreferro medidas pela sonda Hall e o seu transdutor, em particular os distúrbios gerados nos picos do sinal de tensão coletados pelo osciloscópio. Cabe mencionar que o sinal no domínio do tempo amostrado pela sonda, mais particularmente pelo transdutor, é um sinal em tensão na frequência de 60 Hz.

Figura 32 – Perturbações no fluxo do entreferro do MIT, com barras quebradas, detectadas pela Sonda Hall



Fonte: Autor

Essa variação ocorre porque as barras quebradas não contribuem para o fluxo magnético gerado no sensor, e essa característica pode ser detectada e avaliada para posterior diagnóstico da condição estrutural do rotor. A vantagem em usar sensores Hall para medir campos

magnéticos, por exemplo, é a possibilidade de se coletar campos contínuos ou alternados em um único instrumento (SOUSA, 2017).

A Figura 33 ilustra em mais detalhes a instalação da sonda Hall próxima ao entreferro da máquina entre as ranhuras do estator. O motor em questão tem um total de 38 barras de rotor, numeradas de 1 a 38. A Figura 34 ainda mostra uma imagem do sensor Hall instalado no motor, de modo que o campo magnético a ser medido estará perpendicular à superfície útil do aludido sensor. A Tabela 2 apresenta as principais características do aparato experimental empregado nesta pesquisa.

Figura 33 – Local onde a sonda Hall está posicionada no estator



Fonte: (SOUSA, 2017)

Tabela 2-Dados do conjunto motor, freio e ventilador usado nos testes

Motor	Freio	Ventilador
Marca: Equacional	Marca: Equacional	Marca: WEG
Modelo: EA2.180SE	Modelo: EFC -180	Modelo: W22
Tensão: 220 V	Velocidade: 1740 rpm	Tensão: 220 V
Potência: 7,5 KW	Corrente: 1 A	Potência: 3 KW
Velocidade: 1740 rpm	Carga nominal: 41 N.m	Velocidade: 3420 rpm
Corrente: 25,2 A	Tensão de freio: 240 Vdc	Corrente: 2,91 A
Quantidade de barras: 38 barras		
Número de polos: 4 polos		
Número de ranhuras estator: 48		
Escorregamento nominal: 0,033		
Frequência: 60 Hz		

Fonte: Autor

4.1.2 Etapa 2: Coleta de dados da sonda Hall e experimentos programados

Nesta etapa foram definidos diferentes cenários de operação do motor, levando em consideração que o objetivo geral do trabalho é classificar ao final se o rotor está em estado íntegro ou defeituoso. O cenário de operação escolhido nesta etapa foi implementado para um motor ainda alimentado por tensão senoidal pura, ou seja, conectado diretamente à rede elétrica do laboratório. Portanto, para as amostras coletadas do motor funcionando no estado saudável, nada foi alterado, ou seja, todas as barras foram conectadas ao anel de curto. Para avaliar o desempenho da abordagem ora proposta em cenários operacionais distintos, isto é, para uma ampla faixa de carga e condições de defeito relacionadas a barras quebradas adjacentes e não adjacentes, foram definidos os experimentos e cenários apresentados na Tabela 3. Vale mencionar ainda que em muitos casos o motor foi submetido a uma baixa carga, a fim de avaliar a performance do modelo computacional em baixo escorregamento, uma vez que tal condição oferece muitos desafios para uma análise por assinatura da corrente estatórica (MCSA).

Para simular cada condição de defeito, foram desconectadas diversas barras ao longo da circunferência do rotor. Para aplicar diferentes condições de carga no eixo do motor, a sua estrutura conta com um freio magnético tipo Foucault, o qual permite a aplicação de uma tensão contínua para designar uma condição sem carga, e neste caso o freio não é alimentado por tensão, até um valor em torno de 240 Vdc, o que representa uma carga mais próxima a nominal da máquina.

A Tabela 3 apresenta uma distribuição dos cenários estudados no trabalho, até o presente momento, tomando em consideração as diferentes condições estruturais do rotor. Os níveis de tensão de freio aplicados ao eixo do motor correspondem a um escorregamento entre 0,11% e aproximadamente 3,2%, sendo que o escorregamento nominal da máquina testada é de 3,3%. Ainda é possível observar na Tabela 3 que cada condição do rotor gerou um conjunto de imagens, mas tal condição foi melhor detalhada no Capítulo 5.

De todo o modo, vale mencionar que, para gerar a biblioteca de imagens, os dados adquiridos no domínio do tempo foram amostrados em uma frequência de 10 kHz e em uma janela de tempo igual a 4s, gerando assim 40.000 amostras por experimento.

Tabela 3. Diferentes cenários operacionais avaliados para o MIT

Cenário	Descrição	Tipo de alimentação	Variação de carga no eixo	Processamento da imagem (Morfologia)
1	Rotor saudável, 1 barra quebrada (1BB) e duas barras adjacentes quebradas (2BB)	Senoidal (rede elétrica)	Freio não acionado (sem carga) até uma carga próxima a nominal, ou seja, em 40 N.m (freio alimentado em 160 V)	Imagens geradas com o operador de erosão e sem o operador de erosão
2	Rotor saudável, barras quebradas em um pólo magnético (1P) e barras quebradas em dois pólos magnéticos adjacentes (2PA)	Senoidal (rede elétrica)	Freio não acionado (sem carga) até uma carga próxima a nominal, ou seja, em 40 N.m (freio alimentado em 160 V)	Imagens geradas com o operador de erosão e sem o operador de erosão
3	Rotor saudável, barras quebradas em um pólo magnético (1P), barras quebradas em dois pólos magnéticos adjacentes (2PA), 2 pólos não adjacentes (2PNA), três pólos (3P) e quatro pólos (4P)	Senoidal (rede elétrica)	Freio não acionado (sem carga) até uma carga próxima a nominal, ou seja, em 40 N.m (freio alimentado em 160 V)	Imagens geradas com o operador de erosão e sem o operador de erosão
4	Rotor saudável, barras quebradas em um pólo magnético (1P) e barras quebradas em dois pólos magnéticos adjacentes (2PA)	Inversor de frequência	Freio acionado para uma baixa carga (em 20V) até uma condição de escorregamento próximo a 1% (freio em 60 V)	Imagens geradas com o operador de erosão e sem o operador de erosão

Fonte: Autor

4.1.3 Etapa 3: Transformação do sinal no domínio do tempo para imagens RGB

4.1.3.1 Métodos STI (Sem Erosão) e EOSTI (Com Erosão)

Nos métodos tradicionais de diagnóstico de falhas, a precisão do diagnóstico depende do efeito da extração das características existentes do sinal medido. Muitas vezes, os métodos de diagnóstico de avarias em máquinas não podem trabalhar diretamente os dados brutos coletados dos sensores. Neste caso, deve-se aplicar uma técnica de pré-processamento de sinais com a finalidade de extrair as características de interesse da grandeza mensurada.

A extração de características adequadas para um problema de classificação ou regressão é um trabalho complexo e tais informações têm um papel importante nos resultados esperados para o diagnóstico de falhas em diferentes aplicações. Nesta pesquisa, um método eficiente para a geração de imagens RGB foi empregado, conforme apresentado por (WANG *et al.*, 2021).

A representação gráfica é útil ao trabalhar com conjuntos em escala de cinza cujos elementos são expressos em um grupo de três variáveis na forma (x, y, z) , onde x e y são coordenadas espaciais e z é o valor da intensidade f nas coordenadas (x, y) .

No trabalho de Wang *et al.* (2021), inicialmente um método denominado STI (sigla em inglês para “*Sequence to Image*”) é realizado para gerar imagens a partir de um sinal de vibração obtido de um MIT, com a finalidade de detectar avarias em rolamentos. O presente método para a geração de imagens RGB foi inspirado naquele artigo e consiste em obter uma imagem de tamanho $n * n$, para um sinal discretizado “ i ” de tamanho ‘ $3n$ ’. Assim, seja $X(i)$, $i = 1, \dots, 3n$ o comprimento do segmento total do sinal, $A(i)$, $i = 1, \dots, n$, $B(j)$, $j = n + 1, \dots, 2n$ e $C(k)$, $k = 2n + 1, \dots, 3n$ representam 3 segmentos consecutivos do sinal X com n . Adicionalmente, tal como definido por Wang *et al.*, (2021), cada equação abaixo, ou seja, as grandezas $P(i,j)$, $P(j,k)$ e $P(k,i)$ correspondem respectivamente as três camadas RGB da imagem gerada. Tal abordagem foi aplicada neste trabalho para gerar as imagens de cada sinal coletado da sonda.

O pré-processamento dos dados provenientes do sensor é essencial, uma vez que consiste em extrair informações do sinal bruto em meio a um grande volume de dados. O conceito fundamental está em converter o sinal original no domínio do tempo para uma imagem de tamanho de pixel $n * n$ conforme pode ser verificada na Figura 34 (XU *et al.*, 2022).

Na construção da imagem, o dado do sensor é normalizado de 0 a 255, que é apenas o valor do pixel da imagem RGB conforme pode ser observado na equação 9:

$$I(i,j) = \text{round} \left\{ \frac{L((i-1) \times n + j) - \min(L)}{\max(L) - \min(L)} \times 255 \right\} \quad (9)$$

Onde n representa o tamanho da imagem RGB, tamanho este que é determinado de acordo a informação do período. Seja $L(k)$, $k = 1, 2, \dots, n$, representa o valor do sinal, e $I(i,j)$, $i = 1, 2, \dots, n$, $j = 1, 2, \dots, n$ representa a matriz remodelada. $\text{round}(\cdot)$ é a função que aproxima o valor mais próximo da intensidade da imagem. Cada valor de pixel é normalizado de 0 até 255.


Conforme pode ser verificado na Figura 37, cada pixel da imagem RGB contém os dados de todos os canais associados a condição de falha proveniente do sensor.

Figura 34 – Sinal no domínio do tempo para imagem RGB



Fonte: Autor

Figura 35 – Dados 1D (uma dimensão) convertidos em imagens 2D (duas dimensões)



Fonte: Autor

No processo STI, o sinal bruto 1D é convertido em imagem RGB e posteriormente em tons de cinza antes de entrar no modelo da CNN conforme pode ser verificado na Figura 36.

As imagens foram convertidas em escala de cinza para reduzir a complexidade do modelo e o tempo de treinamento. Uma imagem RGB possui três canais de cores (vermelho, verde e azul), enquanto uma imagem em tons de cinza possui apenas um canal, isso significa que uma imagem em tons de cinza contém menos informações e dimensões do que uma imagem RGB, o que pode facilitar o processamento e a extração de recursos da CNN. Além disso, algumas imagens podem não ter muita variação de cores ou podem ter cores que não são relevantes para a tarefa desejada, como reconhecimento facial ou detecção de bordas. Neste trabalho, a conversão da imagem para tons de cinza ajudou a remover ruídos e excesso de informações, aprimorando assim o desempenho da CNN conforme pode ser observado na Figura 36.

Figura 36 – Conversão da imagem RGB para tons Cinza



Fonte: Autor

A conversão de uma imagem RGB para tons de cinza é feita calculando a média aritmética dos valores de cada canal de cor. Em termos de fórmulas matemáticas, a conversão de RGB para tons de cinza é:

$$\text{Gray} = (R + G + B) / 3 \quad (10)$$

Onde:

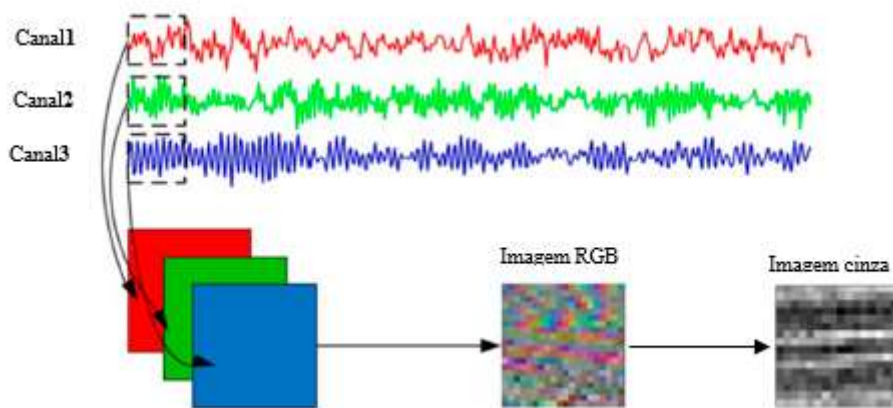
R é o valor do canal vermelho do pixel, de 0 a 255

G é o valor do canal verde do pixel, de 0 a 255

B é o valor do canal azul do pixel, de 0 a 255

Todos os outros valores produzem tons de cinza entre preto e branco. Desta forma, a fórmula transforma uma imagem descolorida RGB em uma imagem em tons de cinza, onde cada píxel é representado por um único valor correspondente à média aritmética de seus canais de cores originais.

Figura 37 – Conversão do sinal em imagem RGB e Cinza



Fonte: Modificado de (XU *et al.*, 2022).

Para um segundo conjunto de imagens, como foi melhor apresentado no próximo capítulo, o método EOSTI foi aplicado, ou seja, um operador morfológico de erosão foi utilizado para a geração das imagens, a fim de incrementar a extração das características de interesse.

A erosão de f por um elemento estruturante plano denotado por b em qualquer posição (x, y) é definida como o mínimo da imagem na região coincidente com b quando a origem de b está em (x, y) . A erosão da imagem f pelo elemento estruturante b em (x, y) é dada pela seguinte equação 11 em que :


$$(f \oplus b)(x, y) = \min\{f(x - m, y - n) - b(m, n)\} \quad (11)$$

tal como no processo de correlação x e y são incrementados usando todos os valores necessários para que a origem de b passe por (varra) cada pixel de f . Por outras palavras, para calcular a erosão de f por b , a origem do elemento estruturante é colocada em cada posição de pixel na imagem. A erosão em qualquer posição é determinada selecionando o mínimo de todos os valores de f contidos na área que coincide com b . Por exemplo, se b for um elemento estruturado quadrado de dimensão 3×3 , para encontrar a erosão de um ponto, é necessário encontrar o valor mínimo entre os nove valores de f contidos na área 3×3 definida por b quando a origem está nesse ponto.

Como a erosão de nível de cinzento com um ES plano calcula o valor mínimo de intensidade de f em cada vizinhança de (x, y) que coincide com b , a imagem de nível de cinzento após a erosão será geralmente mais escura do que a original, o tamanho dos objetos brilhantes será menor (em relação ao tamanho do ES) e o tamanho dos objetos escuros será e o tamanho dos objetos escuros deverá ser maior.

A Figura 38(b) mostra a Figura 38(a) erodida com um ES em forma de disco de altura unitária e 2 pixels de raio. Os efeitos descritos anteriormente são claramente visíveis na imagem erodida. Por exemplo, note-se que na Figura 38(b) a intensidade dos pequenos pontos brilhantes é reduzida ao ponto de se tornarem quase invisíveis, enquanto os pormenores mais escuros são engrossados. O fundo da imagem erodida é também ligeiramente mais escuro do que o fundo da imagem original.

Figura 38 (a) Uma imagem radiográfica em níveis de cinza 448×425 pixels. (b) Erosão usando um disco plano com um raio de 2 pixels.



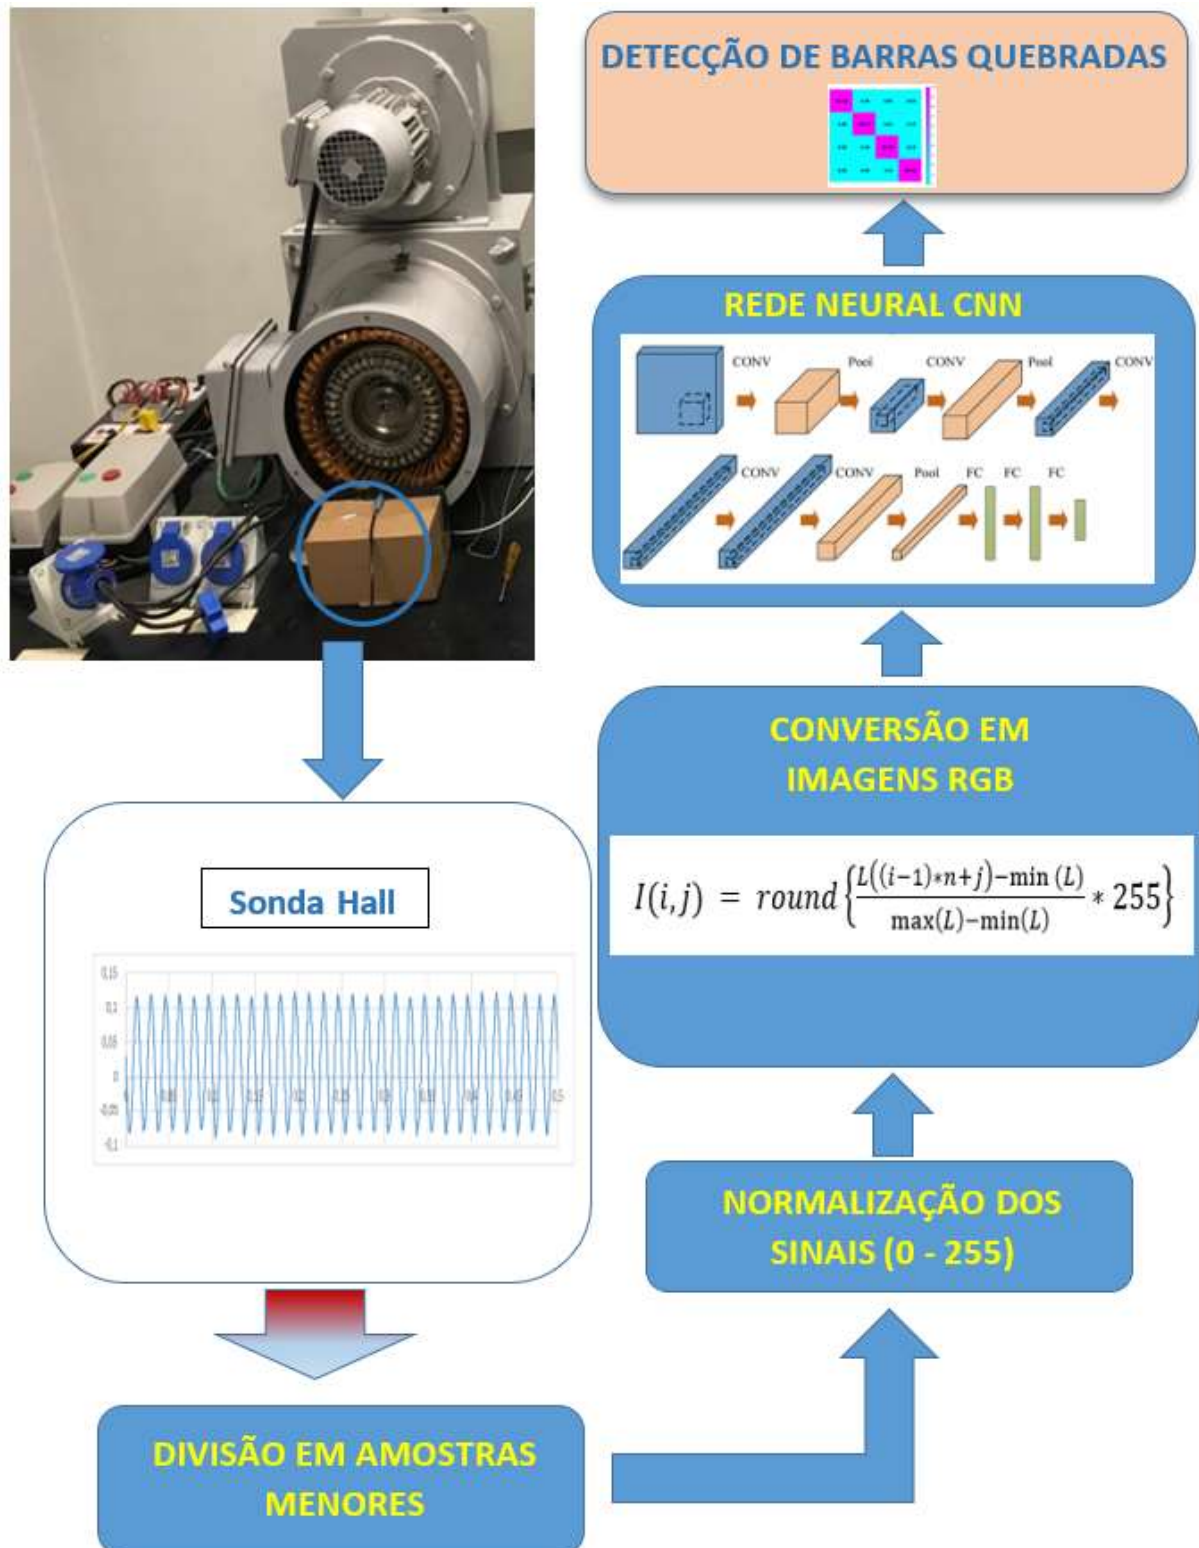
Fonte: Adaptado de (GONZALEZ; WOODS, 2010)

A Figura 39 ilustra as macros etapas executadas nesta pesquisa, incluindo a etapa de conversão dos sinais em imagens RGB, bem como a etapa de classificação do sinal de entrada usando uma rede neural convolucional.

Etapas da figura:

1. Conversão do sinal bruto coletado da sonda Hall no domínio do tempo em imagem 3-D;
2. As imagens foram divididas em amostras menores para que a base de dados fosse aumentada;
3. Um método de pré-processamento simples é aplicado para converter o sinal do sensor de série temporal original 1-D em imagens 2-D, aplicando um mecanismo de janela deslizante ajustável para extrair recursos úteis e reduzir o tempo computacional;
4. O conjunto de dados de imagens RGB gerada foi transformada em tons de cinza antes de ser usada como entrada do modelo da CNN profunda para as fases de treinamento e teste; e
5. Por fim, o modelo mostrou-se capaz de classificar as imagens para as diferentes condições estruturais do rotor.

Figura 39 – Principais etapas utilizadas neste trabalho



Fonte: Autor

4.1.4 Etapa 4: Uso da CNN para detectar a condição do rotor

4.1.4.1 Estrutura da CNN

A última etapa do estudo consistiu na modelagem, implementação e teste das imagens geradas como entradas para uma rede neural do tipo CNN. Como se sabe, as camadas de uma CNN, como “Convolutional + Convolutional + Pooling” são capazes de extrair características de uma imagem de interesse. A CNN é capaz de processar dados de imagem em paralelo com várias GPUs e possui fortes recursos de aprendizado o que também é usado em reconhecimento de imagem, recuperação de imagem, reconhecimento de fala e outros campos.

A camada convolucional e a camada de *pooling* são usados para extrair as propriedades da imagem, organizar todas as camadas associadas. E o *dropout* é usado para eliminar o *overfitting*, substituindo o sigmoide anterior pela unidade Linear Retificada (ReLU) como a função de ativação. Neste estudo, um método bem projetado é introduzido para converter o sinal em imagens 3D, ou seja, três canais RGB. No entanto, as características das primeiras imagens 3D geradas são comparativamente próximas e difíceis de distinguir. Ao manipular a erosão dos elementos associados à imagem suas feições ficam mais nítidas. Este método requer apenas a definição do tamanho do arquivo de imagem gerado, reduzindo o impacto de outras definições de configuração. Portanto, a CNN foi otimizada para formar essas imagens 3D. Os resultados indicam que o método pode ser utilizado no diagnóstico de falhas.

A rede escolhida neste trabalho é uma sequência de camadas usando o modelo Keras, que possui as funções necessárias para construir cada camada de uma rede neural convolucional. Foi definido os parâmetros para o shape dos dados de entrada e a função de ativação, usando 64 features para um array 2D no formato 3*3. As imagens 64 * 64 foram convertidas em um array 3D (pois as imagens são coloridas com 3 canais de cores). Nas primeiras e segundas camadas, foi aplicado o agrupamento (pooling) para reduzir o tamanho do mapa de features, tornando nossa rede um pouco mais profunda. A camada de pooling foi mais uma vez aplicada à saída da camada de convolução anterior. Os dados 2D foram achatados (flatten), ou seja, convertidos em uma estrutura 1D (um vetor). Após conexão das camadas foram aplicadas as funções de ativação retificadora (relu) e a sigmoide, estas últimas para com intuito de obter os resultados probabilísticos de cada imagem conter imagem com defeito ou saudável. No final a rede foi compilada com o otimizador “Adam” baseado em gradiente de funções estocásticas. Foi utilizada a função “log loss” com entropia binária cruzada e como métrica de desempenho a acurácia do modelo.

Com o dataset importado e processado da maneira correta, pode-se finalmente definir a arquitetura da Rede Neural com o *Keras*. De maneira totalmente arbitrária, definiu-se que a Rede Neural final foi definida com 4 camadas ou layers: O primeiro layer receberá como input os valores relativos a cada pixel das imagens.

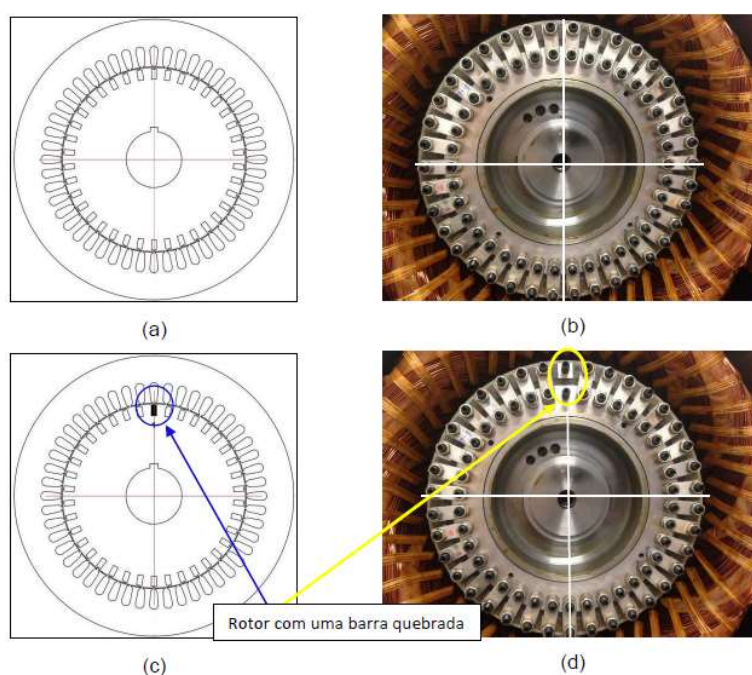
5 DISCUSSÃO E ANÁLISE DOS RESULTADOS OBTIDOS

5.1 INTRODUÇÃO

Neste capítulo são apresentados os resultados obtidos com os experimentos programados para o estudo, usando a metodologia proposta. A biblioteca *TensorFlow*, em conjunto com a API Keras, disponíveis na linguagem Python, foi utilizada para implementar a rede neural convolucional neste trabalho. Para esta finalidade, foi utilizado ainda o ambiente Google Colab e os seus serviços, a fim de permitir um melhor aproveitamento dos recursos de computação em nuvem e a otimização dos processos de treinamento e teste da rede com as imagens geradas. O advento de tais serviços permitiu que cada vez mais pessoas pesquisassem e desenvolvessem aplicativos que antes eram impossíveis devido às limitações de hardware.

Conforme mencionado anteriormente, o motor em questão tem um total de 38 barras de rotor, numeradas de 1 a 38, distribuídas em quatro quadrantes, ou polos magnéticos correspondendo a 9,5 barras por quadrante. As Figuras 40a e 40b ilustram um rotor sem defeito, ou seja, sem barras quebradas (saudável). Por outro lado, as Figuras 40c e 40d ilustra um rotor com apenas uma barra quebra (1BB). O espaço preenchido na cor preta, para a circunferência interna de cada figura, identifica uma barra defeituosa. Em cada foto, a barra quebrada é identificada pela ausência da porca e do parafuso, responsáveis pela conexão elétrica e mecânica com o anel de curto circuito.

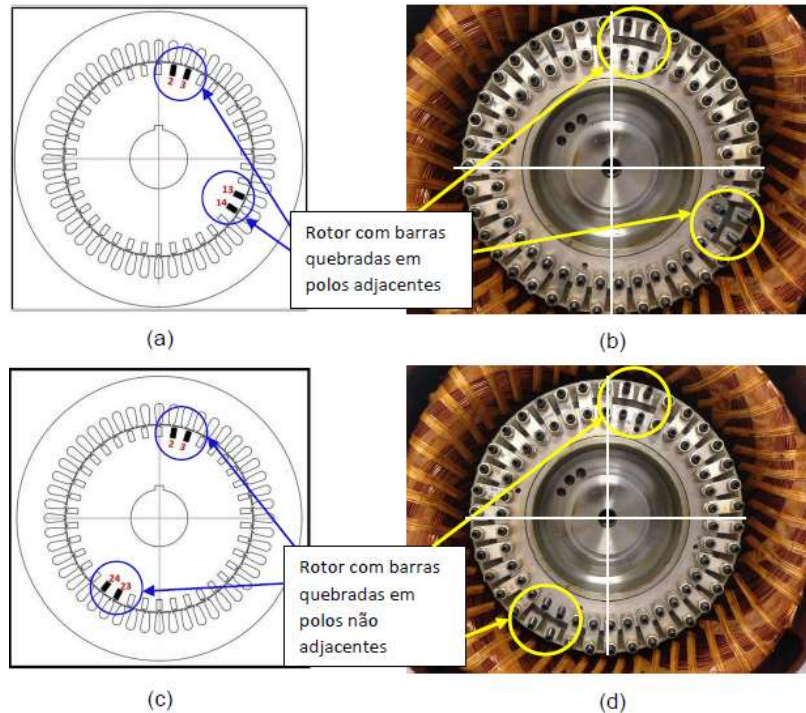
Figura 40 – Ilustrações de um rotor saudável e com uma barra quebrada



Fonte: (SOUSA, 2017)

Por sua vez, as Figuras 41a e 41b mostram um rotor com barras quebradas distribuídas em polos magnéticos, ou quadrantes, adjacentes, uma vez que há duas barras localizadas no primeiro polo e outras duas barras defeituosas no 4º quadrante. As Figuras 41c e 41d ilustram a condição de barras quebradas localizadas em polos não-adjacentes.

Figura 41 – Ilustrações de um rotor com barras quebradas em polos adjacentes e não adjacentes



Fonte: (SOUSA, 2017)

5.2 A COLETA DOS DADOS DA SONDA HALL E A GERAÇÃO DE IMAGENS RGB

Com mencionado no capítulo anterior, cada experimento foi amostrado em uma janela de tempo igual a 4s, na frequência de amostragem igual a 10 kHz, todavia, a fim de detectar o defeito no menor tempo possível e incrementar o número de imagens disponível para o treino e validação da rede convolucional, cada experimento foi dividido em 40 amostras, o que corresponde a 40 imagens RGB.

Inicialmente, isto é, para o primeiro cenário, tais imagens foram geradas sem aplicar a operação morfológica da erosão, conforme proposto inicialmente por (Wang et al., 2021), pois a proposta em um primeiro momento foi testar a acurácia do modelo em uma condição mais desfavorável para a extração das características do sinal da sonda, sendo que a erosão é uma operação de diminuição ou afinamento em uma imagem binária ou seja, uma operação de

filtragem morfológica em que os detalhes da imagem menores que o elemento estruturante são removidos (GONZALEZ; WOODS, 2010).

Na sequência são apresentados os resultados obtidos para cada cenário, usando como entradas as imagens geradas a partir das perturbações de fluxo no entreferro, coletadas com a sonda, tomando por base também as diferentes condições operacionais do motor, a fim de alcançar os objetivos propostos na pesquisa.

5.3 ANÁLISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 1.

O presente cenário utilizou experimentos para o motor operando desde uma condição saudável, até uma situação de avaria para uma única barra quebrada ou mesmo duas barras vizinhas rompidas. Neste caso, as imagens geradas não contaram com o operador morfológico de erosão. Para o treino e validação da rede neural convolucional foram utilizadas 7540 imagens, sendo 4800 imagens para classe defeito e 2740 para a classe saudável. Um total de 70% das imagens foi empregado no treino e o restante, ou seja, 30% para a validação. Conforme pode ser verificado na Tabela 4, após a validação do classificador, o modelo obteve uma acurácia de 100%, e o resultado por classe foi mostrado com a matriz de confusão, para os casos saudável, 1BB e 2BB (classe defeito).

Tabela 4. Matriz de confusão da validação do cenário 1 sem erosão

Classe	Defeito	Saudável
Defeito	100%	0%
Saudável	0%	100%

É possível notar, a partir dos resultados obtidos neste cenário, que mesmo para uma baixa carga aplicada ao eixo da máquina, ou seja, com o freio alimentado em 40V, a presente abordagem foi capaz de identificar os casos de um rotor saudável e aqueles para um rotor avariado, quer seja para uma única barra quebrada ou mesmo para duas barras vizinhas defeituosas. Vale mencionar que, para tal condição de freio, o escorregamento do motor está em torno de 0.66%, sendo que o valor nominal de escorregamento para o motor testado é de 3,3%. Outrossim, para este cenário, dados a acurácia alcançada, não necessário testar o modelo com imagens geradas com o operador erosão.

5.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 2.

Neste caso, os experimentos foram conduzidos para avaliar não apenas a condição saudável e rotor avariado, mas também se havia barras defeituosas distribuídas em pólos magnéticos adjacentes. Para tanto, foram utilizadas 3560 imagens, sendo 2240 imagens para classe defeito (1 polo – 1P e 2 polos adjacentes – 2PA) e 720 imagens para a classe saudável. Um total de 70% das imagens foi empregado no treino e o restante, ou seja, 30% para a validação. Conforme pode ser verificado na Tabela 5 após a validação do classificador foi obtido uma acurácia de teste de 97%, e o resultado por classe foi mostrado como a matriz de confusão, para os casos saudável, 1P e 2PA (classe defeito).

Tabela 5. Matriz de confusão da validação do cenário 2 com e sem erosão

<i>Classe</i>	<i>Defeito</i>	<i>Saudável</i>
<i>Defeito</i>	75%	25%
<i>Saudável</i>	0%	100%

Assim como no cenário anterior, que mesmo para uma baixa carga aplicada ao eixo da máquina, ou seja, com o freio alimentado em 40V, o modelo também foi capaz de identificar os casos de um rotor saudável e os casos com barras quebradas distribuídas em um polo (1P) e dois polos adjacentes (2PA), quer seja para uma única barra quebrada ou mesmo para mais de duas barras vizinhas defeituosas. Vale mencionar que, para este cenário alguns casos foram classificados de maneira incorreta, em particular para as condições de 4 barras e 1 barra quebrada, na proporção de 20% e 55%, em que o modelo identificou falha, porém ao invés de apontar para a classe 1P o mesmo apontou para 2PA (Tabela 6).

Tabela 6. Teste de validação com e sem erosão

TESTE DE VALIDAÇÃO COM E SEM EROSÃO					
	Nº de barras	Carga(V)	Nº de img	Falso positivo	Falso negativo
SAUĐAVEL	38	55 e 100	400	0%	0%
1 Polo	2 (1 e 6)	50	400	0%	0%
	3 (adj)	60	400	0%	0%
	4 (adj)	100	400	0%	20%
	1	130	400	0%	55%
	2 (1 e 6)	150	400	0%	0%
2 Polos Adjacentes	3 (1,2 e 15)	60	400	0%	0%

Fonte: Autor

5.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 3.

Conforme os demais cenários anteriormente descritos, para o cenário 3 foram utilizadas 4400 imagens, sendo 2680 imagens para casos com defeito na gaiola, distribuídos igualmente entre as classes um polo (1P), dois polos adjacentes (2PA), dois polos não adjacentes (2PNA), três polos (3P), quatro polos (4P) e 720 imagens para a classe saudável. Um total de 70% das imagens foram empregadas no treino e as restantes, ou seja, 30% para a validação. Após a validação do classificador foi obtida uma acurácia total de teste de 96%; e um aumento de 2% após gerar as imagens com erosão, ou seja 98%. Dois modelos com os mesmos hiperparâmetros foram treinados, quer para imagens geradas sem erosão e com erosão. As imagens com e sem erosão foram submetidas as mesmas fases de treino e teste, sendo obtidos os mesmos resultados após a classificação. Os resultados são apresentados na matriz de confusão da Tabela 7.

Tabela 7. Matriz de confusão da validação do cenário 3 com e sem erosão

Classe	Saudável	1P	2PA	2PNA	3P	4P
Saudável	100%	0%	0%	0%	0%	0%
1P	0%	100%	0%	0%	0%	0%
2PA	0%	25%	75%	0%	0%	0%
2PNA	0%	0%	0%	100%	0%	0%
3P	0%	0%	0%	0%	100%	0%
4P	0%	0%	0%	0%	0%	100%

Com exceção do casos de 2 polos adjacentes (2PA), em particular para as barras quebradas 1 e 12, na carga de 60V, o modelo alcançou uma acurácia de 100%. De todo o modo, mesmo para a classe 2PA, o modelo indicou falha, ou seja, não uma condição de falso negativo, mas sim uma condição de barra quebrada em um único polo (1P). A Tabela 8 mostra os experimentos por classe, bem como a acurácia obtida com o modelo usando as imagens como entrada com erosão e sem erosão.

Tabela 8. Teste de validação para imagens com e sem erosão

	TESTE DE VALIDAÇÃO COM E SEM EROSÃO					
	Nº de barras	Carga(V)	Nº de img	Falso positivo	Falso negativo	Acurácia
SAUDEL	38	20, 45, 50, 95, 100 e 170	240	0%	0%	100%
1P	2_(1 e 6)	20	40	0%	0%	100%
	1_(1)	100	40	0%	0%	100%
	4 (adj)	100	40	0%	0%	100%
	2_(1 e 6)	115	40	0%	0%	100%
	2 (adj)	130	40	0%	0%	100%
2 PA	2_(1 e 12)	60	40	0%	0%	0%
	4_(2, 3, 13 e 14)	100	40	0%	0%	100%
	3_(1, 2 e 15)	60	40	0%	0%	100%
	3_(1, 2 e 15)	150	40	0%	0%	100%
2PNA	5_(2, 3, 23 e 24)	vazio	40	0%	0%	100%
	5_(2, 3, 23 e 24)	60	40	0%	0%	100%
3P	3_(12, 22 e 32)	vazio	40	0%	0%	100%
	3_(12, 22 e 32)	60	40	0%	0%	100%
	4_(1, 2, 12 e 22)	10	40	0%	0%	100%
	4_(1, 2, 12 e 22)	30	40	0%	0%	100%
	5_(1, 2, 12, 22 e 23)	30	40	0%	0%	100%
	5_(1, 2, 12, 22 e 23)	40	40	0%	0%	100%
4P	4_(2, 12, 22 e 32)	vazio	40	0%	0%	100%
	4_(2, 12, 22 e 32)	60	40	0%	0%	100%

Fonte: Autor

5.5 ANALISE E DISCUSSÃO DOS RESULTADOS PARA OS EXPERIMENTOS DO CENÁRIO 4.

Para o cenário 4 foram geradas imagens para o motor alimentado por um inversor de frequência, diferentemente dos demais cenários tratados anteriormente, nos quais o MIT foi alimentado pela rede do laboratório (alimentação senoidal). A escolha por esta condição operacional reside no fato de que o inversor de frequência normalmente provoca harmônicas indesejadas na conexão trifásica da máquina, ou na sua alimentação, o que implica em maiores desafios para o diagnóstico de barras quebradas, em especial quando se aplica a técnica por assinatura de corrente (MCSA), isto é, no domínio da frequência, como será melhor discutido na próxima seção.

Para este cenário foram geradas um total de 480 imagens numa primeira fase sem aplicar o operador de erosão, onde foram separadas 160 imagens para validação após o treinamento, imagens estas que não foram treinadas em conjunto com as demais. A acurácia obtida no treinamento ficou em torno de 93%, sendo possível notar que para a condição 2PA o modelo classificou as imagens como um rotor danificado com barras quebradas e um único polo (1P). Logo, o modelo foi capaz de identificar defeito na gaiola, mas não localizou corretamente a

posição da barra quebrada. A matriz de confusão mostrada na Tabela 9 destaca o referido resultado e a Tabela 10 apresenta os resultados destacados para cada condição do rotor. Muito embora o modelo de rede neural profunda não tenha localizado corretamente o defeito na gaiola, como mencionado, não houve nenhum caso de falso positivo e falso negativo durante os testes.

Tabela 9. Matriz de confusão da validação do cenário 4 para as imagens geradas sem erosão

<i>Classe</i>	<i>Saudável</i>	<i>1P</i>	<i>2PA</i>
<i>Saudável</i>	100%	0%	0%
<i>1P</i>	0%	100%	0%
<i>2PA</i>	0%	100%	0%

Tabela 10. Teste de validação para imagens sem erosão

TESTE DE VALIDAÇÃO SEM EROSIÃO						
	Nº de barras	Carga(V)	Nº de img	Falso positivo	Falso negativo	Acurácia
SAUDAVEL	38	40	40	0%	0%	100%
1 Polo	1	60	40	0%	0%	100%
	2_ (1 e 5)	40	40	0%	0%	100%
2PA	2_ (1 e 11)	60	40	0%	0%	0%

Fonte: Autor

A fim de alcançar um outro objetivo da presente pesquisa, foi avaliada a geração das imagens com o operador morfológico de erosão, a fim de verificar se tal condição poderia oferecer uma melhor localização do defeito na gaiola para a rede neural convolucional, empregando os mesmos experimentos testados para as imagens geradas sem a erosão. A matriz de confusão da Tabela 11 reitera o fato de que neste caso o modelo CNN foi capaz de localizar corretamente todas as amostras, no caso, para as três condições operacionais da máquina.

Tabela 11. Matriz de confusão da validação do cenário 4 para as imagens geradas com erosão

<i>Classe</i>	<i>Saudável</i>	<i>1P</i>	<i>2PA</i>
<i>Saudável</i>	100%	0%	0%
<i>1P</i>	0%	100%	0%
<i>2PA</i>	0%	0%	100%

A tabela 12 a seguir também ratifica a capacidade do modelo neural em não apenas identificar a falha, mas também localizar corretamente as barras quebradas em diferentes distribuições ao longo da circunferência do rotor, mesmo para a máquina sendo alimentada por

um inversor de frequência e em baixa carga, ou baixo escorregamento. Neste caso também não foi gerada qualquer indicação de falso negativo ou falso positivo, o que reforça a oportunidade em se empregar o presente modelo computacional em futuras ferramentas de detecção e diagnóstico de barras quebradas em um MIT.

Tabela 12. Teste de validação para imagens com erosão

TESTE DE VALIDAÇÃO COM EROÇÃO						
	Nº de barras	Carga(V)	Nº de img	Falso positivo	Falso negativo	Acurácia
SAUDEL	38	40	40	0%	0%	100%
1 Polo	1	60	40	0%	0%	100%
	2_ (1 e 5)	40	40	0%	0%	100%
2PA	2_ (1 e 11)	60	40	0%	0%	100%

Fonte: Autor

5.6 COMPARAÇÃO DO MÉTODO DESENVOLVIDO FRENTE À TÉCNICA CONVENCIONAL POR ASSINATURA DA CORRENTE (MCSA)

Nesta seção é apresentada uma comparação do método desenvolvido na presente pesquisa, em relação a alguns cenários normalmente desfavoráveis para se aplicar a tradicional técnica de assinatura por corrente do estator (MCSA), tais como operação do motor em baixa carga, ou sem carga, e barras não-adjacentes separadas em 90° elétricos. Para melhor entendimento, é apresentada a seguir a abordagem MCSA para o motor testado no laboratório nas condições saudável e duas barras rotóricas adjacentes quebradas.

É importante lembrar que o motor testado no laboratório opera com um escorregamento nominal em torno de 3,33%, para um torque de carga de aproximadamente 40 N.m. Um funcionamento em baixa carga pode ser definido, por exemplo, para um torque de 10 N.m ou inferior, o que corresponde a um escorregamento menor do que 1% ($s = 0,01$).

Como apresentado no Capítulo 2, para detectar uma barra quebrada usando a técnica MCSA é necessário verificar se há a presença de uma componente de frequência lateral localizada à esquerda da fundamental, neste caso em 60 Hz. A frequência lateral é definida como:

$$f_f = (1 - 2s) \cdot f_0 \quad (12)$$

Onde: f_f = frequência de falha lateral (Hz)

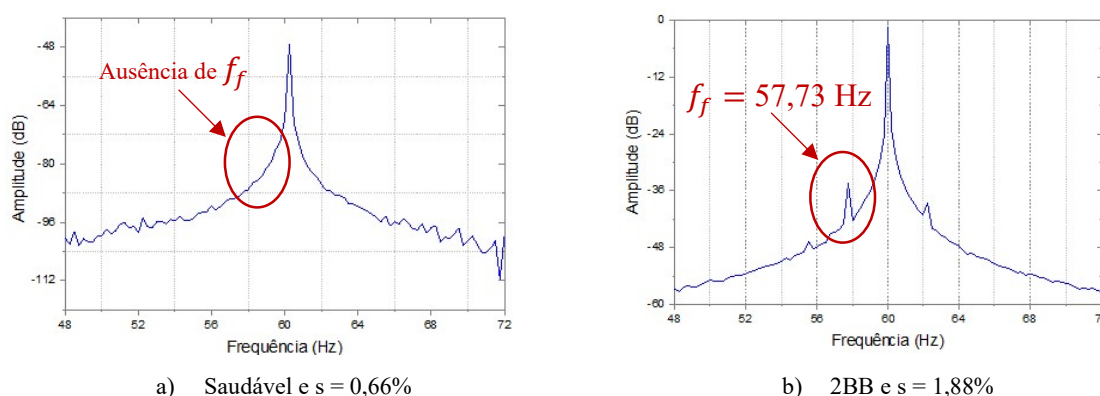
s = escorregamento

f_0 = frequência fundamental (Hz)

Como apresentado anteriormente, para detectar o rompimento de barras na gaiola de esquilo, usando a abordagem MCSA, é necessário medir com precisão a rotação de eixo, a fim de calcular o escorregamento da máquina e aplicar a equação 13. Tal como destacado por alguns pesquisadores, a incorreta medição ou estimativa de rotação pode levar a indicações de falsos positivos, ou falsos negativos, com o uso da técnica por assinatura da corrente (LEE *et al.*, 2016).

Para melhor entendimento, a Figura 42 ilustra uma representação MCSA, para o MIT utilizado em laboratório, considerando uma condição saudável do rotor e outra para o motor operando com duas barras adjacentes quebradas.

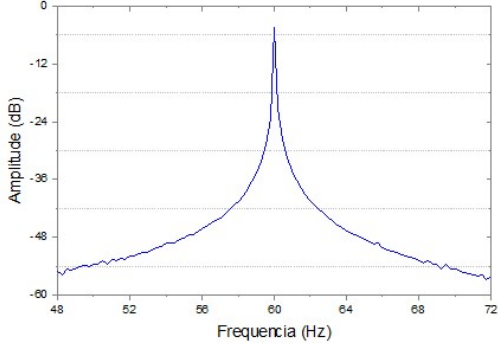
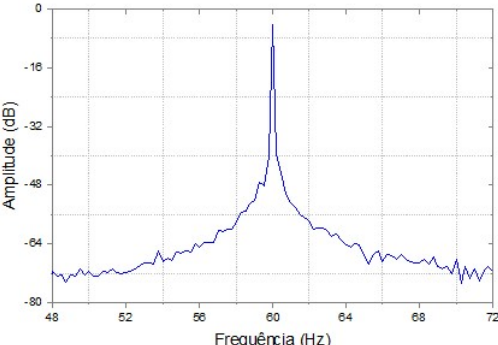
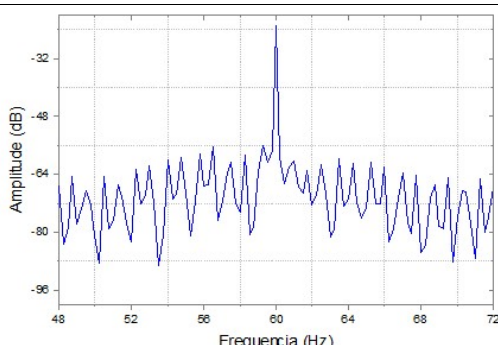
Figura 42 – Técnica MCSA aplicada para um rotor sem avaria e outro com 2BB



Fonte: Autor

Nota-se pela Figura 42a a ausência da frequência de falha ao lado da componente fundamental, o que era esperado para um rotor sem defeito, e na Figura 42b a presença de uma frequência com valor próximo a 57,73 Hz, o que também era esperado para o motor operando com barras rompidas e no escorregamento específico de 1,88% (Equação 13). Todavia, para escorregamentos ainda mais baixos e para o caso de barras separadas em 90° elétricos, como já comentado, a referida técnica oferece muitas dificuldades para se detectar a frequência de falha, ou mesmo não apresenta esta componente como pode ser observado nos casos representados na Tabela 13.

Tabela 13. Técnica MCSA aplicada em casos de baixa carga ou barras separadas em 90°

Condição do rotor e carga	Gráfico obtido com a técnica MCSA (FFT) para a corrente do MIT	Alimentação	Rotação medida e f_f calculada (Hz)	f_f estimada (Hz)
2BB Carga = 1,5 N.m (Cenário 1P)		Senoidal	1796 rpm (s = 0,22%) $f_f = 59,34$ Hz	Frequência de falha não encontrada (possível caso de falso negativo)
Barras quebradas 1 e 11 (Cenário 2PA) Carga = 5 N.m		Senoidal	1791 rpm (s = 0,5%) $f_f = 59,40$ Hz	$f_f = 59,75$ Hz
Barras quebradas 1 e 11 (Cenário 2PA) Carga = 5 N.m		Inversor	1790 rpm (s = 0,55%) $f_f = 59,34$ Hz	$f_f = 59,25$ Hz

Fonte: Autor

Mais uma vez, como pode ser observado na Tabela 13, a avaliação da frequência de falha leva em conta uma boa precisão na medida da rotação de eixo para o cálculo do escorregamento, caso contrário, torna-se ainda mais onerosa a tarefa de identificação da avaria com a técnica MCSA, em especial para torques muito abaixo da condição nominal. A Tabela 14 mostra os resultados obtidos para as mesmas condições, mas agora destacando as informações geradas com o método ora proposto.

Tabela 14. Resultados obtidos após o processamento do sinal da sonda e estimativa do modelo CNN

Condição do rotor e carga	Recorte da forma de onda obtida da sonda Hall	Imagem gerada sem erosão	Imagem gerada com erosão	Estimativa do melhor modelo CNN
2BB Carga = 1,5 N.m (1P)				Identificou a condição correta para o rotor, ou seja, 1P (Melhor modelo com e sem erosão)
Barras quebradas 1 e 11 (2PA) Carga = 5 N.m (Senoidal)				Identificou a condição correta para o rotor e o local da falha, ou seja, 2PA (Melhor modelo com e sem erosão)
Barras quebradas 1 e 11 (2PA) Carga = 5 N.m (Inversor)				Identificou a condição correta para o rotor e o local da falha, ou seja, 2PA (Melhor modelo com erosão)

Fonte: Autor

Muito embora não seja possível identificar visualmente as diferenças entre as imagens geradas com e sem o operador morfológico de erosão, o melhor modelo de rede neural profunda foi capaz de detectar as diversas condições operações do MIT e efetuar a correta localização do defeito, ou seja, se a máquina estava não apenas com a barra rompida, mas a sua distribuição ao longo da circunferência do rotor. Os resultados mostram que o presente método é bastante robusto para a detecção do defeito em baixo escorregamento, ao contrário da técnica MCSA, sendo tal condição operacional comum dos motores de grande porte.

Cabe destacar que, o método desenvolvido nesta pesquisa não necessita da medição ou estimativa da rotação de eixo para identificar a falha, portanto, trata-se de uma contribuição adicional para a avaliação estrutural da gaiola em motores de indução trifásicos. Ademais, para alcançar uma boa precisão na estimativa da frequência de falha, a técnica de assinatura da corrente (MCSA) necessita de uma alta resolução em frequência, em torno de 0,01 Hz, o que

implica em um hardware mais robusto para o processamento das informações e armazenamento de milhões de amostras, quando comparado ao necessário para a presente abordagem, uma vez que foram utilizadas apenas 40.000 amostras por experimento, e uma janela de 0,1s para gerar cada imagem e proceder com o processamento da mesma na rede neural profunda.

6 CONCLUSÕES

Conforme apresentado e discutido neste estudo, uma das possíveis falhas de um motor de indução trifásico com gaiola de esquilo é a quebra de uma ou mais barras que compõem a estrutura do enrolamento do rotor, principalmente nas suas conexões com o anel de curto-circuito. Nos últimos anos, diversos pesquisadores desenvolveram técnicas e novos métodos capazes de detectar o rompimento de barras vizinhas e também aquelas quebradas em diferentes posições do rotor, inclusive em pólos magnéticos distintos. Muitos dos estudos, ainda recentes, destacam a importância em se detectar a falha rotórica em condições de barras não-adjacentes e também em casos nos quais o motor de indução opera em baixa carga ou baixo escorregamento.

Um motor de grande porte, por exemplo, opera em um escorregamento nominal próximo ou abaixo de 1%, o que justifica ainda mais a escolha de uma técnica alternativa para contribuir para a detecção do defeito na gaiola. Segundo alguns dados da literatura, as máquinas com dezenas ou centenas de quilowatts, por exemplo, são aquelas mais sujeitas a este tipo de avaria. Portanto, a técnica apresentada neste trabalho se baseia na classificação das alterações provocadas na densidade de fluxo magnético, usando uma sonda de efeito Hall instalada próximo ao entreferro do motor.

Como uma contribuição teórica para esta abordagem, pode-se citar a geração de imagens RGB a partir dos sinais coletados pela sonda, em duas categorias diferentes, quais sejam, uma aplicando um operador morfológico de erosão e outra sem o seu uso. As imagens geradas foram utilizadas como entradas para uma típica rede neural convolucional, no caso para classificar as diferentes condições estruturais do rotor.

Os resultados obtidos permitiram avaliar que o modelo neural desenvolvido foi capaz de identificar e, na maioria dos casos, localizar a posição das barras defeituosas ao longo da circunferência rotórica. A análise dos resultados permitiu ainda encontrar uma boa acurácia para o modelo desenvolvido (acima de 90% em muitos cenários), mesmo para o motor alimentado por um inversor de frequência e/ou ainda para as condições de baixa carga ou baixo escorregamento. Vale ressaltar mais uma vez que, a técnica usada para a assinatura da corrente do estator (MCSA) encontra muitas dificuldades para identificar a frequência de falha (componente lateral esquerda), quando o motor opera em baixa carga, uma vez que o fenômeno de dispersão espectral contribui para “esconder” o efeito de tal harmônica. Ademais, cabe ressaltar que, diferentemente da MCSA, o método desenvolvido na presente pesquisa não

necessita da medição, ou estimativa, da rotação, fator este bastante limitante em algumas aplicações no meio industrial, pois o acesso ao eixo da máquina muitas vezes é impraticável.

No tocante ao uso do operador morfológico de erosão, para a composição das imagens, foi possível constatar que na maioria dos casos o modelo neural se mostrou eficaz, mesmo para as entradas que não fizeram uso da referida operação de pré-processamento. Todavia, para o motor alimentado por um inversor, a localização do defeito rotórico foi mais assertiva para as imagens geradas com a técnica de erosão, o que sugere que as características extraídas neste caso foram mais descritivas quando comparadas aos casos sem a operação morfológica.

Com os resultados animadores obtidos no curso desta pesquisa, avalia-se que novas abordagens devem ser investigadas no futuro, a fim de aprimorar o método desenvolvido, em especial para outras condições operacionais da máquina, quais sejam: *i-*) funcionamento do motor com cargas oscilatórias; *ii-*) alimentação do motor em situações de sub-tensão e sobre-tensão; e *iii-*) testar a eficácia do modelo para motores dotados de um número maior de barras rotóricas.

REFERÊNCIAS

A. BELLINI *et al.* Advances in diagnostic techniques for induction machines. **IEEE Trans. Ind. Electron.**, 55, n. 12, Dec 2008. 4109-4126.

AGGARWAL, C. C. **Neural Networks and Deep Learning**. [S.l.]: [s.n.], 2018. 497 p.

ANTONINO-DAVIU, J. A. *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**, v. 54, n. 4, p. 3934-3942, July/August 2018.

ANTONINO-DAVIU, J. A.; PONS-LLINARES, J.; LEE, S. B. Advanced Rotor Fault Diagnosis for Medium-Voltage Induction Motors Via Continuous Transforms. **IEEE Transactions on Industry Applications**, 52, n. 5, September 2016. 4503-4509.

ARAÚJO, R. G. C. **Desenvolvimento de um Sistema de Diagnóstico de Falhas em Motores Elétricos de Indução**. Lisboa. 2015.

ATTA, M. E. E.-D.; IBRAHIM, D. K.; GILANY, M. I. Broken Bar Fault Detection and Diagnosis Techniques for Induction Motors and Drives: State of the Art. **IEEE Access**, 10, 18 Aug 2022. 88504-88526.

AYAS, S.; AYAS, M. S. A novel bearing fault diagnosis method using deep residual learning network. **Multimedia Tools and Applications**, p. 22407-22423, 2022.

BINDU, S.; THOMAS, V. V. Diagnoses of internal faults of three phase squirrel cage induction motor — A review. **International Conference on Advances in Energy Conversion Technologies (ICAECT)**, Jan 2014. 48-54.

CAMPOS, W. D. S. **CLASSIFICAÇÃO DE IMAGENS HIPERESPECTRAIS COM BASE EM PERFIS DE ATRIBUTOS: UMA ABORDAGEM SEMIAUTOMÁTICA**. UNIVERSIDADE NOVE DE JULHO - UNINOVE. São Paulo, p. 57. 2020.

CAPOLINO, G. A.; ANTONINO-DAVIU, J. A.; RIERA-GUASP, M. Modern diagnostics techniques for electrical machines, power electronics, and drives. **IEEE Trans. Ind. Electron**, 62, n. 3, Mar 2015. 1738-1745.

CERRI, R.; CARVALHO, A. C. P. D. L. F. D. APRENDIZADO DE MÁQUINA: BREVE INTRODUÇÃO E APLICAÇÕES. **Cadernos de Ciência & Tecnologia**, Brasília, v. 34, n. 3, p. 297-313, set/dez 2017.

CHAPMAN, S. J. **Fundamentos de Máquina Elétricas**. 5ª. ed. Porto Alegre: AMGH, 2013.

CHIZZOTTI, A. **Pesquisa em ciências Humanas e Sociais**. 12ª. ed. Perdizes: CORTEZ, 2018.

CHOLLET, F. **Deep Learning with Python**. 2ª. ed. [S.l.]: Manning, 2021. ISBN B09K81XLN1. Acesso em: 06 novembro 2022.

DIAS, C. G.; PEREIRA, F. H. Broken Rotor Bars Detection in Induction Motors Running at Very Low Slip Using a Hall Effect Sensor. **IEEE Sensors Journal**, 18, n. 11, 1 June 2018. 4602-4613.

DIAS, C. G.; SILVA, L. C. D.; ALVES, W. A. L. A Histogram of Oriented Gradients Approach for Detecting Broken Bars in Squirrel-Cage Induction Motors. **IEEE Transactions on Instrumentation and Measurement**, v. 69, n. 9, p. 6968-6981, September 2020.

DICAS Gerais sobre instalação elétrica. **Portal Eletricista**, 2021. Disponível em: <https://www.portaleletricista.com.br/motor-de-inducao-funcionalidade-significado-dicas-passo-a-passo/>. Acesso em: 01 Novembro 2021.

DINIZ, A. M. F.; ARAÚJO, R. D. Uma abordagem prática para o ensino do eletromagnetismo usando um motor de indução de baixo custo. **Revista Brasileira de Ensino de Física**, v. 41, n. 1, p. 1-9, 2019. Disponível em: www.scielo.br/rbef.

EPE. Portal do Governo Brasileiro. **EPE- Empresa de Pesquisa Energética**, 2019.

Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Consumo-Anual-de-Energia-Eletrica-por-classe-nacional>. Acesso em: 17 Junho 2021.

FALCHENKO, A. AVTOTACHKI, 2022. Disponível em: <https://avtotachki.com/pt/elektricheskaya-mashina-nikola-tesla/>. Acesso em: 31 outubro 2022

·
GANA, M.; ACHOUR, H.; LAGHROUCHE, M. Enhanced motor fault detection system based on a dual-signature image classification method using CNN. **CrossMark**, p. 1-15, Jan 2023. Disponível em: <https://doi.org/10.1088/2631-8695/acae1d>.

GARCIA-BRACAMONTE, J. E. *et al.* An Approach on MCSA-Based Fault Detection Using Independent Component Analysis and Neural Networks. **IEEE Transactions on Instrumentation and Measurement**, 68, n. 5, 2019. 1353-1361.

GLOBALMAG. INSTRUMENTAÇÃO MAGNÉTICA. **GLOBALMAG**, 2022. Disponível em: <https://www.globalmag.com.br/>. Acesso em: 19 Maio 2023.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de Imagens**. 3^a. ed. São Paulo: PEARSON, 2010.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. **The MIT Press**, 2016. 800pp.

GOOGLE. Google Trends, 2022. Disponível em: <https://trends.google.com.br/trends/explore?date=today%205-y&q=tensorflow,pytorch>. Acesso em: 06 novembro 2022.

HAGAN, M.; DEMUTH, H. B.; BEALE, M. H. **Neural Network Design**. 2^a. ed. [S.l.]: [s.n.], 2014.

HASSAN, O. E. *et al.* **IET Electr. Power Appl.**, 12, n. 7, Aug 2018. 895-907.

HAYKIN, S. **Neural Networks And Learning Machines**. 3^a. ed. [S.l.]: PEARSON, 2016.

HEIDBREDER, J. F. Induction Motor Temperature Characteristics. **AIEE Trans. Power Apparatus Systems**, Oct 1958. 800-804.

HENAO, H. *et al.* Trends in fault diagnosis for electrical machines: A review of diagnostic techniques. **IEEE Ind. Electron. Mag.**, 8, n. 2, Jun 2014. 31-42.

HINTON, G. E.; SALAKHUTDINOV, R. R. Reducing the Dimensionality of Data with Neural Networks. **Science**, 2006. 504-507.

IGLESIAS-MARTÍNEZ, M. E. *et al.* Detection of Nonadjacent Rotor Faults in Induction Motors via Spectral Subtraction and Autocorrelation of Stray Flux Signals. **IEEE Transactions on Industry Applications**, v. 55, n. 5, p. 4585-4594, September/October 2019.

KARPATY, A. CS231n Winter 2016, 2016. Disponível em: <https://www.youtube.com/watch?v=NfnWJUyUJYU&list=PLkt2uSq6rBVctENoVBg1TpCC7OQi31A1C&index=2>. Acesso em: 06 novembro 2022.

KERAS. Keras, 2022. Disponível em: <https://keras.io/about/>. Acesso em: 06 novembro 2022.

KIA, S. H.; HENAO, H.; CAPOLINO, G.-A. Diagnosis of Broken-Bar Fault in Induction Machines Using Discrete Wavelet Transform Without Slip Estimation. **IEEE Transactions on Industry Applications**, 45, n. 4, July/August 2009.

KUMAR, A. Neural network based detection of. **Pattern Recognition local textile defects**, 2003. 1645-1659.

KUMAR, P.; HATI, A. S. Dilated convolutional neural network based model for bearing faults and broken rotor bar detection in squirrel cage induction motors. **Expert Systems With Applications**, Dhanbad, n. 191, p. 1-12, 2022.

LEE, S. B. *et al.* Identification of False Rotor Fault Indications Produced by Online MCSA for Medium-Voltage Induction Machines. **IEEE Transactions on Industry Applications**, v. 52, n. 1, p. 729-739, January/February 2016.

LIBONI, L. H. B. *et al.* Efficient feature extraction technique for diagnosing broken bars in three-phase induction machines. **Measurement**, n. 134, p. 825-834, December 2019.

LIU, P. *et al.* A CNN-based transfer learning method for leakage detection of pipeline under multiple working conditions with AE signals. **Process Safety and Environmental Protection**, n. 170, p. 1161-1172, 2023.

LIU, Y.; BAZZI, A. M. A review and comparison of fault detection and diagnosis methods for squirrel-cage induction motors: State of the art. **ISA Trans.**, 70, Sep 2017. 400-409.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models. **Computer Science Department, Stanford University**, 2013. 1-6.

MARCELO, J. D. S. **Uma abordagem inteligente aplicada para a detecção de barras rompidas em motores de indução operando em baixo escorregamento**. Dissertação (Mestrado) — Universidade Nove de Julho, 2017. São Paulo, p. 88. 2020.

MATTEDE, H. Mundo da Elétrica. **Mundo da Elétrica**, 2014. Disponível em: <https://www.mundodaeletrica.com.br/tipos-de-motores-eletricos-quais-sao>. Acesso em: 16 Junho 2021.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**. Expanded Edition. ed. [S.l.]: Mit Press; Expanded ed. edição, 1987.

MORINIGO-SOTELO, D. *et al.* Reliable detection of rotor bars breakage in induction motors via MUSIC and ZSC. **IEEE Trans. Ind. Appl.**, 54, n. 2, Mar 2018. 1224-1234.

MOUSSA, M. A.; BOUCHERMA, M.; KHEZZAR, A. Detection Method for Induction Motor Bar Fault Using Sidelobes Leakage Phenomenon of the Sliding Discrete Fourier Transform Using Sidelobes Leakage Phenomenon of the Sliding Discrete Fourier Transform. **IEEE Transactions on Power Electronics**, 32, n. 7, July 2017. 5560-5572.

NIE, X. *et al.* Ground Fault Detection Based on Fault Data Stitching and Image Generation of Resonant Grounding Distribution Systems. **Energies**, Guiyang, p. 1-19, 2023.

NUTI, S. V. *et al.* The Use of Google Trends in Health Care Research: A Systematic Review. **Plos One**, 9, October 2014. 1-49.

PALÁCIOS, R. H. C. *et al.* Voltage unbalance evaluation in the intelligent recognition of induction motor rotor faults. **Springer**, p. 1-12, Maio 2020.

PANAGIOTOU, P. A. *et al.* A New Approach for Broken Rotor Bar Detection in Induction Motors Using Frequency Extraction in Stray Flux Signals. **IEEE Transactions on Industry Applications**, v. 5, n. 4, p. 3501-3511, July/August 2019.

PARK, Y. *et al.* Search Coil-based Detection of Non-adjacent Rotor Bar Damage in Squirrel Cage Induction Motors. **IEEE Transactions on Industry Applications**, p. 1-10, 2020.

PATEL, S. A.; YILDIRIM, A. Non-stationary neural signal to image conversion framework for image-based deep learning algorithms. **Frontiers in Neuroinformatics**, p. 1-9, March 2023.

PEDRINI, H.; SCHWARTZ, W. R. *In: Análise de imagens digitais: princípios, algoritmos e aplicações*. São Paulo: Cengage Learning, 2008. ISBN 13: 978-85-221-2836-5.

PUCHE-PANADERO, R. *et al.* Improved Resolution of the MCSA Method Via Hilbert Transform, Enabling the Diagnosis of Rotor Asymmetries at Very Low Slip. **IEEE Transactions on Energy Conversion**, 24, n. 1, March 2009. 52-59.

RIERA-GUASP, M. *et al.* Influence of nonconsecutive bar breakages in motor current signature analysis for the diagnosis of rotor faults in induction motors Current Signature

Analysis for the Diagnosis of Rotor Faults in Induction Motors. **IEEE Transactions on Energy Conversion**, 25, n. 1, March 2010. 80-89.

RIERA-GUASP, M.; ANTONINO-DAVIU, J. A.; CAPOLINO, G.-A. Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art. **IEEE Trans. Ind. Electron**, 62, n. 3, Mar 2015. 1746-1759.

ROMERO-TRONCOSO, R. J. *et al.* Rotor unbalance and broken rotor bar detection in inverter-fed induction motors at start-up and steady-state regimes by high-resolution spectral analysis. **Electric Power Systems Research**, n. 133, p. 142-148, 2016.

SALAH, M. *et al.* Predicting Medical Expenses Using Artificial Neural Network. **International Journal of Engineering and Information Systems (IJEAIS)**, 2, October 2018. 11-17.

SAUER, I. L. *et al.* A comparative assessment of Brazilian electric motor performance with minimum efficiency standards. **Renewable and Sustainable Energy Reviews**, n. 41, p. 308-318, 2015.

SILVA, J. A. S. D.; MAIRINK, C. H. P. Inteligência artificial: aliada ou inimiga. **LIBERTAS: Rev. Ciênc. Soc. Apl.**, Belo Horizonte, v. 9, n. 2, p. 64-85, Dez 2019.

SILVA, L. A. M. D. **Redes neurais Convolucionais com python e Google Colab: Estudo de caso de Detecção de Defeitos em Tecidos**. Universidade Federal Fluminense - UFF. Niterói, p. 106. 2022.

SILVA, L. C. D. **Uma Abordagem Baseada em Histograma de Gradientes Orientados para a Detecção de Barras Rompidas em Motores de Indução com Rotor Gaiola de Esquilo**. Tese (Doutorado em Informática) - Universidade Nove de Julho. São Paulo, p. 143. 2019.

SINHA, A. K. *et al.* ANN-Based Pattern Recognition for Induction Motor Broken Rotor Bar Monitoring under Supply Frequency Regulation. **Machines**, v. 9, n. 87, p. 1-19, April 2021.

SIZOV, G. Y. *et al.* Analysis and Diagnostics of Adjacent and Nonadjacent Broken-Rotor-Bar Faults in Squirrel-Cage Induction Machines. **IEEE Transactions on Industrial Electronics**, 56, n. 11, November 2009. 4627-4641.

SMITH, F. D.; HANSON, K. L. Rotor protection of large motors by use of direct temperature monitoring Direct Temperature Monitoring. **IEEE Transactions on Industry Applications**, 11, n. 4, Jul/Aug 1975. 340-343.

SMITH, L. N. A disciplined approach to neural network hyper-parameters: part 1 – Learning rate, batch size, momentum, and weight decaybatch size, momentum, and weight decay. **US Naval Research Laboratory**, 24 April 2018. 1-21. Acesso em: 06 Novembro 2022.

SOILLE, P. Morphological image analysis: principles and applications. *In: Morphological image analysis: principles and applications*. 2^a. ed. Verlag Berlin Heidelberg: Springer, 2003. ISBN 978-3-642-07696-1.

SOUSA, C. M. D. **Uma abordagem inteligente aplicada para a detecção de barras rompidas em motores de indução operando em baixo escorregamento**. Dissertação (Mestrado) - Universidade Nove de Julho. São Paulo, p. 111. 2017.

SRIDHAR, S. *et al.* Real time wireless condition monitoring of induction motor. **IEEE Ind. Electron. Appl. Conf. (IEACon)**, Nov 2016. 173-178.

STEVENS, E.; ANTIGA, L.; VIEHMANN, T. **Deep Learning with Pytorch: Build, Train and Tune Neural Networks Using Python Tools**. 1^a. ed. [S.l.]: Manning Publications, 2020.

TAYLOR, M.; KONING, M. **Machine Learning with Neural Networks: An In-depth Visual Introduction with Python: Make Your Own Neural Network in Python: A Simple Guide on Machine Learning with Neural Networks**. [S.l.]: Blue Windmill Media, 2017.

TRASK, A. W. **Grokking Deep Learning**. 1^a. ed. [S.l.]: Manning, 2019.

UMANS, S. D. **Máquinas Elétricas**. 7^a. ed. Porto Algre: Brookman, 2014.

VALLES-NOVO, R. *et al.* Empirical Mode Decomposition Analysis for Broken-Bar Detection on Squirrel Cage Induction Motors. **IEEE Transactions on Instrumentation and Measurement**, v. 64, n. 5, p. 1118-1128, May 2015.

WANG, T. *et al.* A fast and robust convolutional neural network-based defect detection model in product quality control. **The International Journal of Advanced Manufacturing Technology**, 2018. 3465-3471.

WANG, Z. *et al.* Data-driven fault diagnosis method based on the conversion of erosion operation signals into images and convolutional neural network. **Process Safety and Environmental Protection**, p. 591-601, 2021.

WEG. **GUIA DE ESPECIFICAÇÃO MOTORES ELÉTRICOS**, 2021. Disponível em: <https://www.weg.net/institutional/BR/pt/search/downloadcenter?q=50032749>. Acesso em: 02 novembro 2022.

WEN, L. *et al.* A New Convolutional Neural Network Based Data-Driven Fault Diagnosis Method. **IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS**, p. 1-9, June 2017.

XU, M. *et al.* Bearing-Fault Diagnosis with Signal-to-RGB Image Mapping and Multichannel Multiscale Convolutional Neural Network. **Entropy**, p. 1-20, Oct 2022.

YADAV, S. S.; JADHAV, S. M. Deep convolutional neural network based medical image classification for disease diagnosis. **Journal of Big Data**, 2019. 1-18.

ZHANG, P. *et al.* A survey of condition monitoring and protection methods for medium-voltage induction motors Methods for Medium-Voltage Induction Motors. **IEEE Transactions on Industry Applications**, 47, n. 1, January/February 2011.

ANEXOS

ANEXO A– BIBLIOTECAS USADAS NO DESENVOLVIMENTO

```
[ ] # Bibliotecas gerais para manipulação de imagens
import numpy as np
import matplotlib.pyplot as plt
import os
import cv2
from tqdm import tqdm
```

```
[ ] import tensorflow as tf
import keras
from tensorflow import keras
#from tensorflow.keras import layers
from keras import layers
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Activation, Flatten
from tensorflow.keras.layers import Conv2D, MaxPooling2D
from keras.optimizers import SGD
```

```
[ ] # Funções do módulo Keras a serem utilizados no desenvolvimento do projeto
import tensorflow as tf
import keras
from tensorflow import keras
#from tensorflow.keras import layers
from keras import layers
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Activation, Flatten
from tensorflow.keras.layers import Conv2D, MaxPooling2D
from keras.optimizers import SGD
```

ANEXO B – CONVERSÃO DA IMAGEM RGB PARA TONS DE CINZA

```
for category in CATEGORIES:  
    path = os.path.join(DATADIR,category)  
    for img in os.listdir(path):  
        img_array = cv2.imread(os.path.join(path,img) ,cv2.IMREAD_GRAYSCALE)  
        plt.imshow(img_array,cmap = 'gray')  
        plt.show()  
  
        break  
break
```

Imagem RGB




imagem tons de cinza



ANEXO C – APLICANDO CNN

```

model = Sequential()

model.add(Conv2D(32, (3, 3), input_shape=X.shape[1:]))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Conv2D(64, (3, 3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Conv2D(64, (3, 3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Conv2D(128, (3, 3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Flatten()) # this converts our 3D feature maps to 1D feature vectors
model.add(Dense(3))
model.add(Activation('softmax'))

adam = keras.optimizers.Adam(learning_rate=0.001)

model.compile(loss='sparse_categorical_crossentropy',
              optimizer='adam',
              metrics=['accuracy'])


```

```
[ ] historico = model.fit(X, y, batch_size=64, epochs=50, validation_split=0.2)
```

ANEXO D- ÉPOCAS DE TREINAMENTO E ACURÁCIA DO MODELO


```
[ ] #Visualizando as acurácias de treino e validação por época
plt.plot(historico.history['accuracy'])
plt.plot(historico.history['val_accuracy'])
plt.title('Acurácia por épocas')
plt.xlabel('épocas')
plt.ylabel('acurácia')
plt.legend(['treino', 'validação'])
```

<matplotlib.legend.Legend at 0x7f09cd991370>



```
[ ] #Visualizando as perdas de treino e validação por época
plt.plot(historico.history['loss'])
plt.plot(historico.history['val_loss'])
plt.title('Perda por épocas')
plt.xlabel('épocas')
plt.ylabel('perda')
plt.legend(['treino', 'validação'])
```

<matplotlib.legend.Legend at 0x7f09cd93ed00>



```
[ ] #Avaliando o modelo
perda_teste, acuracia_teste = model.evaluate(X, y)
print('Perda do teste:', perda_teste)
print('Acurácia do teste:', acuracia_teste)
```

236/236 [=====] - 1s 5ms/step - loss: 2.0711e-09 - accuracy: 1.0000
 Perda do teste: 2.0711421466756974e-09
 Acurácia do teste: 1.0