

João Dallamuta
(Organizador)

**Estudos Transdisciplinares
nas Engenharias 2**

Atena
Editora
Ano 2019

João Dallamuta

(Organizador)

Estudos Transdisciplinares nas Engenharias 2

Atena Editora
2019

2019 by Atena Editora
Copyright © Atena Editora
Copyright do Texto © 2019 Os Autores
Copyright da Edição © 2019 Atena Editora
Editora Executiva: Profª Drª Antonella Carvalho de
Oliveira Diagramação: Karine de Lima
Edição de Arte: Lorena Prestes
Revisão: Os Autores

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Conselho Editorial

Ciências Humanas e Sociais Aplicadas

Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Profª Drª Cristina Gaio – Universidade de Lisboa
Prof. Dr. Deyvison de Lima Oliveira – Universidade Federal de Rondônia
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Profª Drª Ivone Goulart Lopes – Istituto Internazionale delle Figlie de Maria Ausiliatrice
Profª Drª Juliane Sant’Ana Bento – Universidade Federal do Rio Grande do Sul
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alan Mario Zuffo – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Prof. Dr. Darllan Collins da Cunha e Silva – Universidade Estadual Paulista
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

Ciências Biológicas e da Saúde

Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. Benedito Rodrigues da Silva Neto – Universidade Federal de Goiás
Prof.^a Dr.^a Elane Schwinden Prudêncio – Universidade Federal de Santa Catarina
Prof. Dr. José Max Barbosa de Oliveira Junior – Universidade Federal do Oeste do Pará
Prof.^a Dr.^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof.^a Dr.^a Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof.^a Dr.^a Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Prof.^a Dr.^a Vanessa Bordin Viera – Universidade Federal de Campina Grande

Ciências Exatas e da Terra e Engenharias

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Prof.^a Dr.^a Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista

Conselho Técnico Científico

Prof. Msc. Abrãao Carvalho Nogueira – Universidade Federal do Espírito Santo
Prof.^a Dr.^a Andreza Lopes – Instituto de Pesquisa e Desenvolvimento Acadêmico
Prof. Msc. Carlos Antônio dos Santos – Universidade Federal Rural do Rio de Janeiro
Prof.^a Msc. Jaqueline Oliveira Rezende – Universidade Federal de Uberlândia
Prof. Msc. Leonardo Tullio – Universidade Estadual de Ponta Grossa
Prof. Dr. Welleson Feitosa Gazel – Universidade Paulista
Prof. Msc. André Flávio Gonçalves Silva – Universidade Federal do Maranhão
Prof.^a Msc. Renata Luciane Polsaque Young Blood – UniSecal
Prof. Msc. Daniel da Silva Miranda – Universidade Federal do Pará

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
E82	Estudos transdisciplinares nas engenharias 2 [recurso eletrônico] / Organizador João Dallamuta. – Ponta Grossa, PR: Atena Editora, 2019. – (Estudos Transdisciplinares nas Engenharias; v. 2) Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-7247-356-9 DOI 10.22533/at.ed.569102905 1. Engenharia – Pesquisa – Brasil. 2. Transdisciplinaridade. I. Dallamuta, João. II. Série. CDD 620
Elaborado por Maurício Amormino Júnior – CRB6/2422	

Atena Editora

Ponta Grossa – Paraná - Brasil

www.atenaeditora.com.br

contato@atenaeditora.com.br

APRESENTAÇÃO

Caro(a) leitor(a),

Nesta obra temos um compendio de pesquisas realizadas por alunos e professores atuantes em ciências exatas, engenharia e tecnologia. São apresentados trabalhos teóricos e vários resultados práticos de diferentes formas de aplicação e abordagens de simulação, projetos e caracterização no âmbito da engenharia e aplicação de tecnologia.

Tecnologia e pesquisa de base são os pilares do desenvolvimento tecnológico e da inovação. Uma visão ampla destes temas é portanda fundamental. É esta amplitude de áreas e temas que procuramos reunir neste livro.

De abordagem objetiva, a obra se mostra de grande relevância para graduandos, alunos de pós-graduação, docentes e profissionais, apresentando temáticas e metodologias diversificadas, em situações reais.

Optamos pela divisão da obra em dois volumes, como forma de organização e praticidade a você leitor. Aos autores, agradecemos pela confiança e espírito de parceria.

Boa leitura.

João Dallamuta

SUMÁRIO

CAPÍTULO 1	1
ESTUDO SEMI PROBABILÍSTICO E SIMULAÇÕES NUMÉRICAS PARA O MÓDULO DE ELASTICIDADE DO CONCRETO APLICADO AO PROBLEMA DE FLEXÃO DE UMA VIGA	
Ana Carolina Carius Bruna Teixeira Silveira Ricardo Franciss Leonardo de Souza Corrêa João Vitor Curioni de Miranda Bruna Nogueira da Silva	
DOI 10.22533/at.ed.5691029051	
CAPÍTULO 2	14
EVOLUÇÃO DIFERENCIAL APLICADA NA ESTIMAÇÃO DE PARÂMETROS DE UM SISTEMA OSCILATÓRIO	
Iolanda Ortiz Bernardes Marcelo Favoretto Castoldi Alessandro Goedel	
DOI 10.22533/at.ed.5691029052	
CAPÍTULO 3	20
GERAÇÃO DE UM ACELEROGRAMA SÍSMICO ARTIFICIAL A PARTIR DE UMA FUNÇÃO DENSIDADE ESPECTRAL DE POTÊNCIA COMPATÍVEL COM UM ESPECTRO DE RESPOSTA DE PROJETO	
Daniela Dalla Chiesa Letícia Fleck Fadel Miguel	
DOI 10.22533/at.ed.5691029053	
CAPÍTULO 4	25
GRUPO DE ESTUDOS E INTERVENÇÕES SOCIOAMBIENTAIS ENQUANTO PRÁTICA EDUCATIVA PARA A ENGENHARIA AMBIENTAL: CICLOS QUE SE RETROALIMENTAM	
Gabriela de Souza Carvalho Julia Dedini Felício Lara Ramos Monteiro Silva Rhennan Mecca Bontempi	
DOI 10.22533/at.ed.5691029054	
CAPÍTULO 5	43
MAPEAMENTO DE LINEAMENTOS ESTRUTURAIS E ESTUDO DA POTENCIALIDADE HÍDRICA DO SISTEMA AQUÍFERO SERRA GERAL NA BACIA DO RIBEIRÃO CAMBÉ EM LONDRINA, PR	
Giselly Peterlini Maurício Moreira dos Santos Thiago Henrique da Silva	
DOI 10.22533/at.ed.5691029055	
CAPÍTULO 6	49
MODELAGEM E IMPLEMENTAÇÃO DE UM INVERSOR FONTE DE TENSÃO PARA ACIONAMENTO DE MOTORES DE INDUÇÃO	
Lucas Niquele Endrice Jakson Paulo Bonaldo	
DOI 10.22533/at.ed.5691029056	

CAPÍTULO 7	67
MODELAGEM E SIMULAÇÃO DO PROCESSO PRODUTIVO DE LEITE EM PÓ INTEGRAL: ÊNFASE NA ETAPA DE SECAGEM POR <i>SPRAY DRYING</i> Gustavo Storte Tonin Régis da Silva Pereira DOI 10.22533/at.ed.5691029057	
CAPÍTULO 8	83
NÍVEIS DE RUÍDO DE UM TRATOR AGRÍCOLA EM CONDIÇÃO ESTÁTICA Maria Rosa Alferes da Silva Letícia Rodrigues da Silva Rônega Boa Sorte Vargas Beethoven Gabriel Xavier Alves DOI 10.22533/at.ed.5691029058	
CAPÍTULO 9	88
O MÉTODO SORM DG E SUAS APLICAÇÕES NA ANÁLISE DE CONFIABILIDADE ESTRUTURAL DE PROBLEMAS DE ENGENHARIA Emmanoel Guasti Ferreira Marcílio Sousa da Rocha Freitas José Antônio da Rocha Pinto Geraldo Rossoni Sisquini DOI 10.22533/at.ed.5691029059	
CAPÍTULO 10	106
PROPOSTA DE INTERVENÇÃO PARA CRIAÇÃO DA ZONA DE SEGURANÇA HÍDRICA DO MUNICÍPIO DE CUIABÁ, MATO GROSSO Ibraim Fantin-Cruz Maria Ivoneide Vital Rodrigues Leandro Obadowiski Bruno Marcel Medinas de Campos DOI 10.22533/at.ed.56910290510	
CAPÍTULO 11	123
PROSPECÇÃO QUÍMICA DA CASCA DO FRUTO E DA SEMENTE DA <i>MAGONIA PUBENSCENS</i> A. ST.-HIL Amanda Silva Oliveira Arnaldo Ferreira Ribeiro Júnior Bruna Lane Malkut Fábio Gramani Saliba Júnior Maria Perpétua Oliveira Ramos DOI 10.22533/at.ed.56910290511	
CAPÍTULO 12	128
REÚSO DE EFLUENTE DE ESGOTO TRATADO NO CULTIVO DO PIMENTÃO AMARELO EM SOLO DO CERRADO Delvio Sandri Waltoíres Reis da Silva Júnior Cícero Célio de Figueiredo Rodrigo Moura Pereira DOI 10.22533/at.ed.56910290512	

CAPÍTULO 13	140
SISTEMA DE IRRIGAÇÃO AUTOMÁTICO	
Camila Dias de Jesus	
Márcio da Silva Vilela	
Leonardo Nazário Silva dos Santos	
Clarissa Vitória Borges dos Santos	
DOI 10.22533/at.ed.56910290513	
CAPÍTULO 14	144
SISTEMA RADICULAR DA CULTIVAR 'GOLD JEWEL' DE KALANCHOE BLOSSFELDIANA POELLN CULTIVADA EM SUBSTRATO COMERCIAL E EM DIFERENTES DOSAGENS DE IRRIGAÇÃO	
Fátima Cibele Soares	
Jumar Luís Russi	
Andressa Fernandes Leal	
Carine Brum Duran	
Francieli Ribeiro Corrêa	
Giordana Trindade de Abreu	
DOI 10.22533/at.ed.56910290514	
CAPÍTULO 15	151
UMA ABORDAGEM DE APRENDIZADO DE MÁQUINAS PARA AUXÍLIO NO PLANEJAMENTO E CONTROLE DE MANUTENÇÃO	
Jéfter Mateus de Oliveira Rezende	
Gustavo de Assis Costa	
Camila Dias de Jesus	
DOI 10.22533/at.ed.56910290515	
CAPÍTULO 16	164
UTILIZAÇÃO DA TÉCNICA DE VELOCIMETRIA POR IMAGENS DE PARTÍCULAS (PIV) PARA OBTENÇÃO DO MAPA DE DEFORMAÇÕES EM PAINÉIS DE MADEIRA DE <i>PINUS OOCARPA</i>	
Eduardo Hélio de Novais Miranda	
Rodrigo Allan Pereira	
DOI 10.22533/at.ed.56910290516	
CAPÍTULO 17	170
UTILIZAÇÃO DE AGENTE DE SECAGEM NA PRODUÇÃO DE PAPEL CARTÃO	
Crivian Pelisser	
Márcio Antônio Fiori	
Josiane Maria Muneron de Mello	
Jaqueline Scapinello	
DOI 10.22533/at.ed.56910290517	
SOBRE O ORGANIZADOR	184

UMA ABORDAGEM DE APRENDIZADO DE MÁQUINAS PARA AUXÍLIO NO PLANEJAMENTO E CONTROLE DE MANUTENÇÃO

Jéfter Mateus de Oliveira Rezende

Instituto Federal de Goiás, Faculdade de Engenharia
Jataí – Goiás

Gustavo de Assis Costa

Instituto Federal de Goiás, Faculdade de Engenharia
Jataí – Goiás

Camila Dias de Jesus

Instituto Federal de Goiás, Faculdade de Engenharia
Jataí – Goiás

RESUMO: Falhas e defeitos em equipamentos são corriqueiros em qualquer ambiente industrial, gerando perdas e prejuízos materiais e financeiros. Para sanar problemas como estes, diferentes técnicas de manutenção corretiva e preventiva são empregadas. Dentre estas, podemos citar algumas técnicas baseadas em Inteligência Artificial, as quais permitem que seja utilizado o poder computacional para alcançar alto nível de capacidade analítica baseada em busca de padrões gerados a partir de dados previamente obtidos. Desta forma, é possível que sejam realizadas análises como predição de valores e/ou estados futuros ou mesmo a classificação de dados. A aplicação destas técnicas tem sido uma alternativa eficaz que permite a geração de soluções que irão

amenizar este problema. Neste trabalho foi desenvolvido um subsistema de apoio a um sistema automatizado responsável por integrar e monitorar uma parte de um processo industrial, com o intuito de oferecer auxílio ao planejamento e controle de manutenção em um ambiente que simula uma produção industrial, de forma que o programa informe dados que irão influenciar nas ações que deverão ser realizadas pela equipe de manutenção para evitar possíveis falhas no andamento do processo industrial. Para este subsistema, foram utilizados algoritmo de Regressão e algoritmo de Classificação. Para testar a viabilidade do mesmo, propõe-se um ambiente que simula uma produção industrial através do uso de uma base de dados pública que foi desenvolvida por meio da análise e monitoramento de um sistema de rolamento de motores. O subsistema foi testado em uma base de dados com medições feitas em um motor do IFG, e conseguiu encontrar um defeito. Este projeto tem por objetivo o desenvolvimento de uma solução baseada em aprendizado de máquina para auxiliar no planejamento e controle de manutenção em um ambiente simulado de produção industrial.

PALAVRAS-CHAVE: Inteligência Artificial; Planejamento e Controle de Manutenção; Aprendizado de Máquinas.

ABSTRACT: Failures and defects in equipment

and machines are commonplace in any industrial environment, taunting material and financial losses. To solve these problems, different techniques of corrective and preventive maintenance can be used. Among these techniques, we can mention some based on Artificial Intelligence, which allows computational power to be used to achieve high level of analytical capacity based on the search for patterns generated from previously obtained data. In this way, it's possible to carry out analyzes as prediction of values and/or future states or even the classification of data. The application of these techniques it has been a powerful alternative that allows find solutions that will decrease these problems. In this work, a subsystem to support an automated system that will monitor a part of an industrial process was developed, whit the purpose of offering assistance to planning and maintenance control in an environment that simulates an industrial production, so that the program informs data that will influence the actions that must be performed by maintenance team to avoid possible failures in the progress of the industrial process. For this subsystem, it's used Regression algorithm and Classification algorithm .To test this subsystem a public database was used, this database was originally developed through a monitoring the motor bearing system. The subsystem was tested in a database made on an IFG engine, and was able to find a defect. This project aims to develop and implement a solution based on machine learning to assist in planning and maintenance control in a simulated industrial production environment.

KEYWORDS: Artificial Intelligence; Planning and Control of Maintenance; Machine Learning.

1 | INTRODUÇÃO

Falhas e defeitos em equipamentos são comuns em processos industriais. De acordo com Lessmeier *et. al.* (2016), 40% a 70% das falhas em motores e sistemas de acionamentos eletromecânicos são causadas por danos no rolamento. Essas falhas podem interromper a produção, gerando prejuízos para o empresário e para o consumidor. Na tentativa de minimizar este problema, as indústrias começaram a criar equipes que realizam atividades de inspeção e monitoramento. Essas equipes, ao encontrarem alguma anormalidade, empregam o tipo de manutenção adequada, onde é considerado o grau de criticidade, prioridade das máquinas e os equipamentos da planta industrial.

Para auxílio neste tipo de análise, é possível utilizar métodos computacionais para garantir um resultado mais preciso e confiável. O uso de banco de dados pode ser de grande ajuda, pois será possível avaliar o histórico de equipamentos, quais danos ele já sofreu, se a vida útil de um equipamento já se esgotou, ou se alguma mudança na estrutura da máquina foi feita. Porém, em um banco de dados que contém muitas informações, a análise humana pode não ser indicada, pois algum fato ou dado importante pode passar despercebido pelo analisador, sendo necessário o uso de um

software ou um subsistema que irá verificar e informar os dados necessários para uma análise correta.

Uma ferramenta computacional que pode contribuir de modo extremamente relevante neste caso é a inteligência artificial. Se utilizarmos as técnicas de aprendizado de máquinas como colaboradoras na análise humana, teremos uma previsão mais precisa e confiável. Há diversas abordagens diferentes de inteligência artificial para solucionar uma grande variedade de problemas. Uma delas é o aprendizado de máquina, uma das áreas mais importantes dentro da inteligência artificial. Estas técnicas de aprendizado são utilizadas para encontrar padrões ou tendências em um conjunto de dados, e podem ser de grande auxílio para o planejamento e controle de manutenção, já que as equipes de inspeção e manutenção lidam com um grande número de dados. Dentre os algoritmos de aprendizado de máquinas, foi utilizado o algoritmo de aprendizado supervisionado. O subsistema criado neste trabalho utiliza algoritmo de Regressão e algoritmo de Classificação.

O presente artigo propõe utilizar algoritmos de aprendizado de máquinas para auxiliar em um planejamento e controle de manutenção.

2 | MATERIAIS E MÉTODOS

Para a criação do subsistema baseado em Inteligência Artificial apresentado neste artigo era necessária uma grande quantidade de dados, que deveriam ser colhidos em um ambiente industrial simulado, com diferentes aspectos de funcionamento de motores, para subsidiar a análise proposta. Esta foi encontrada no trabalho de Lessmeier *et. al.* (2016), no qual os autores descrevem detalhadamente uma base de dados bastante completa e heterogênea que foi disponibilizada publicamente para experimentos. A base de dados inclui diferentes tipos de danos relacionados ao rolamento do motor.

O trabalho de Lessmeier *et. al.* (2016) gerou dados de sinais de medição através do monitoramento do rolamento do motor. Foram feitas medições com motores sem nenhum tipo de dano em seu rolamento, medições em motores com danos artificiais em seu rolamento e danos através da aceleração do tempo de vida do motor.

Os tipos de danos existem no anel interno e no anel externo do rolamento, e foram classificados em danos singulares, danos repetitivos e danos múltiplos. Foram atribuídos 5 níveis relacionados à extensão do dano, sendo o nível 1 o dano mínimo e o nível 5 o dano com dimensões maiores.

Foram realizados 32 experimentos com rolamentos diferentes. Os arquivos estão disponíveis para download e podem ser encontrada na página da Universidade Paderborn. As bases de dados possuem medições de 10 variáveis. As variáveis medidas foram:

- Força;

- Corrente de fase 1;
- Corrente de fase 2;
- Velocidade;
- Torque;
- Vibração;
- Temperatura;
- HostService;
- Temp_1Hz;
- Mech_4Khz.

Na página de download, cada arquivo possui um código baseado na classificação dos danos. Neste trabalho, foram utilizados os dados relativos a:

- Perfuração no anel interno no rolamento do motor, sendo o seu código para download KA07;
- Motor sem nenhum tipo de dano, sendo o seu código para download K006;
- Deformação plástica, sendo seu código para download KA30;

Também foram feitas medições em um motor do Instituto Federal de Goiás – Câmpus Jataí. Para medição e armazenamento dos dados, foi utilizado um motor de indução trifásico de 0,5 c.v de potência, 3410 r.p.m, 60 Hz, fabricado pela empresa WEG. As variáveis mensuradas foram: Corrente de fase e velocidade.

Para aferição da velocidade, foi utilizado um tacômetro óptico digital portátil, modelo TD-704 com mira a laser. O tacômetro mediu uma velocidade constante para todo o tempo de operação do motor. A velocidade medida foi de 3592 r.p.m. A medição da corrente de fase foi feita utilizando o equipamento *PowerPad* modelo 8335.

Os dados foram gravados e armazenados em uma planilha no Microsoft Excel. O motor foi acionado com ligação Triângulo, um multímetro foi utilizado para verificar a tensão da rede que chegava ao motor. Após uma primeira ligação do motor, para verificar se estava funcionando corretamente, foram colocados os bornes do *PowerPad* em conjunto com alicate amperímetro em cada fase que saía da alimentação para o motor. A forma de onda foi observada no visor do *PowerPad* e transferida do equipamento para um notebook através de uma conexão USB.

Para este subsistema foi aplicada a linguagem de programação *Python*. Esta linguagem de programação foi escolhida porque é muito versátil, possui comandos simples e fáceis de desenvolver e é também considerada uma das principais linguagens para o desenvolvimento de soluções de aprendizado de máquinas. O interpretador utilizado foi o *Jupyter Notebook*.

3 | RESULTADOS E DISCUSSÃO

Neste tópico apresentaremos os resultados dos algoritmos que fazem parte do subsistema. Estes resultados foram obtidos a partir de duas bases de dados: de Lessmeier *et. al.* (2016); das medições feitas em um motor do IFG.

Na base de dados, algumas variáveis não foram utilizadas no algoritmo, pois tinham poucas amostras e estavam prejudicando os algoritmos de regressão e de classificação. As variáveis não utilizadas foram: Temperatura, Temp_1Hz. Algumas variáveis continham mais amostras do que outras, portanto, foi necessário normalizar a quantidade de amostras das variáveis, de forma que elas tivessem a mesma quantidade. Sem essa normalização, o algoritmo de regressão não funcionaria. As variáveis que continham mais amostras do que outras e precisaram ser normalizadas foram: Corrente de fase 1, Corrente de fase 2 e Vibração.

Foi utilizado uma função de normalização de dados, pois algumas variáveis continham dados na escala decimal, outras variáveis continham dados na escala de milhar. Essa função de normalização utiliza fatores de divisão e multiplicação para diminuir a diferença entre os valores das variáveis. Se não houvesse essa normalização, o algoritmo não funcionaria adequadamente. Neste experimento, as bases de dados obtidas em Lessmeier *et. al.* (2016), foram concatenadas em uma só.

Foi necessário extrair os dados no formato .mat e copiá-los para uma planilha no programa Libre Office. Para isso, foi criado um algoritmo, utilizando a linguagem de programação *Python*, que realiza essa extração automaticamente de todas as variáveis e também faz a conversão para uma planilha em Libre Office. Esta conversão foi necessária, pois o *Jupyter Notebook* não reconhece arquivos no formato .mat, mas aceita arquivos com extensão .csv, que é uma das extensões que podem ser utilizada pelo Libre Office.

Todos esses dados foram coletados em motores sem danos e defeitos, com danos artificiais e danos acelerando o tempo de vida. Cada variável apresenta um comportamento diferente para cada tipo de dano e defeito, com apenas a temperatura se mantendo mais ou menos constante para toda a base de dados.

3.1 Resultados do algoritmo de regressão

As Figuras 1, 2, 3 e 4 apresentam a previsão realizada pelo algoritmo para 4 variáveis da base de dados concatenada, que são: Corrente de fase 1, Corrente de fase 2, Velocidade, Força. Essas 4 variáveis são dependentes, as variáveis restantes foram utilizadas como independentes para cada uma das previsões. Nos gráficos, a cor azul representa os valores reais, verde representa os valores previstos.

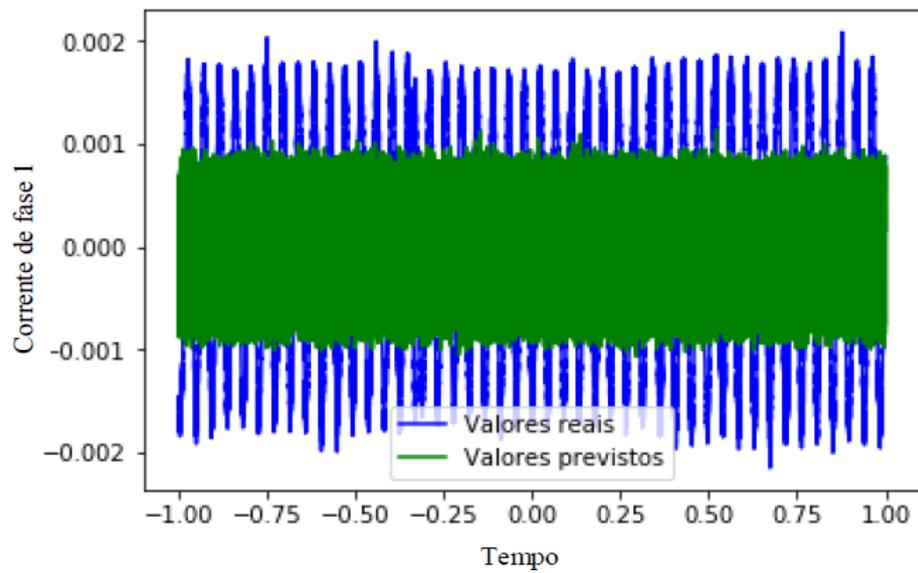


Figura 1: Previsão para Corrente de Fase 1.

Fonte: Autoria própria.

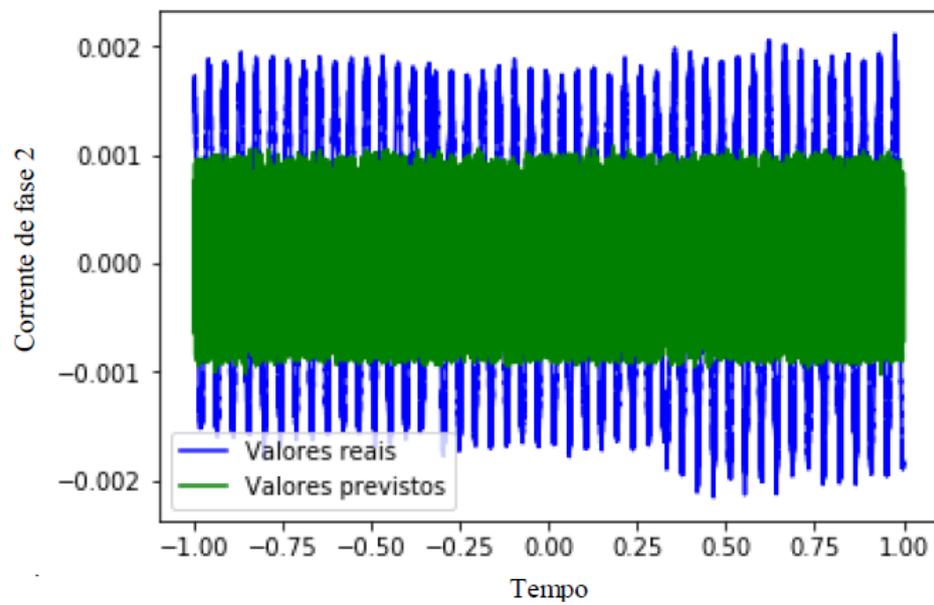


Figura 2: Previsão para Corrente de Fase 2.

Fonte: Autoria própria.

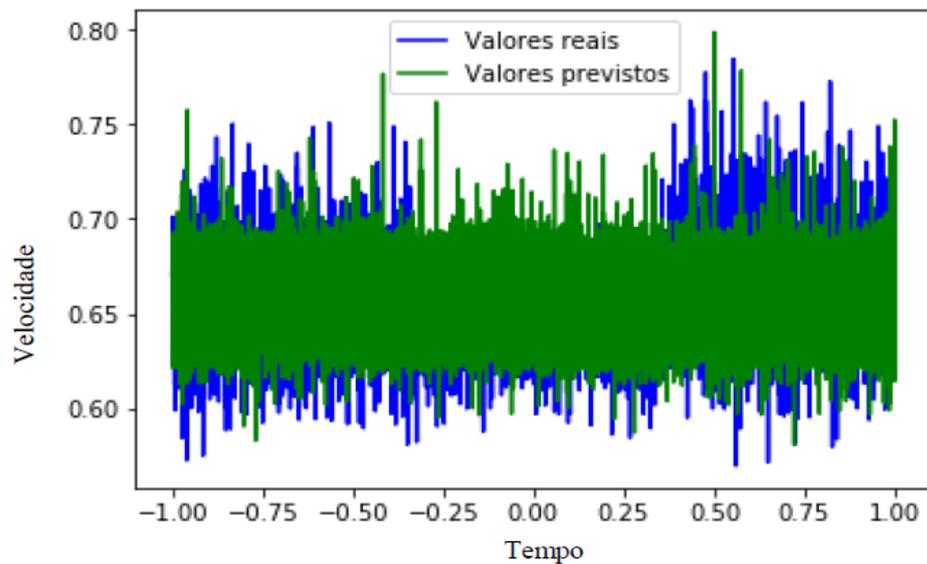


Figura 3: Previsão para Velocidade.

Fonte : Autoria própria.

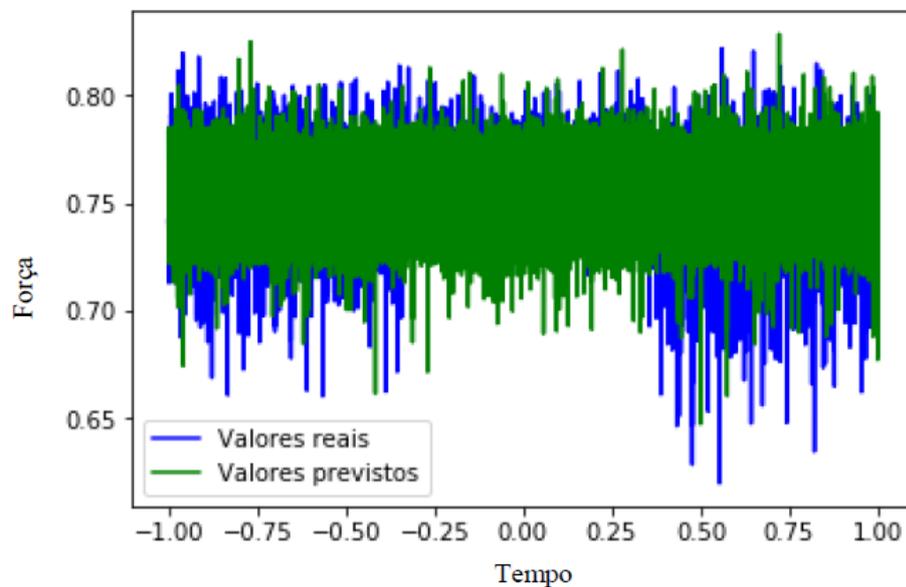


Figura 4: Previsão para Força.

Fonte: Autoria própria.

A previsão mostrada acima foi para uma base de dados concatenada, contendo os dados das três bases de dados: K006 (Motor Saudável), KA07 (Perfuração), KA30 (Deformação Plástica).

Para as variáveis cujos valores eram muito próximos de zero, como Corrente de fase 1 e Corrente de fase 2, a previsão foi menor, pois o algoritmo de regressão faz suas previsões com base nos métodos dos mínimos quadrados, como os valores são próximos de zero, logo, a precisão do algoritmo será menor. Para as variáveis onde os valores eram maiores, como Força e Velocidade, o algoritmo teve uma precisão de quase 99%.

3.2 Resultados do algoritmo de Classificação

No algoritmo de classificação, a base de dados concatenada dos motores foi utilizada como referência. No algoritmo, para classificar os dados, foi empregada a seguinte estratégia:

- Motores saudáveis recebem o valor de: Zero;
- Motores defeituosos recebem valores maiores que Zero.

Os motores defeituosos não poderiam conter os mesmos valores, pois o algoritmo não poderia diferenciar um defeito do outro. Para solucionar este problema, a estratégia adotada foi:

- KA07 recebe o valor de: Um (1);
- KA30 recebe o valor de: Dois (2).

O algoritmo de classificação escolhido foi o KNN (K - *Nearest - Neighbour*). Primeiramente foi criado um modelo de treinamento do algoritmo de classificação. Foram utilizados da base concatenada 70% dos dados, valor geralmente adotado para testes e treinamentos de algoritmos. A Figura 5 mostra o resultado do treinamento do algoritmo de classificação para esta base de dados concatenada.

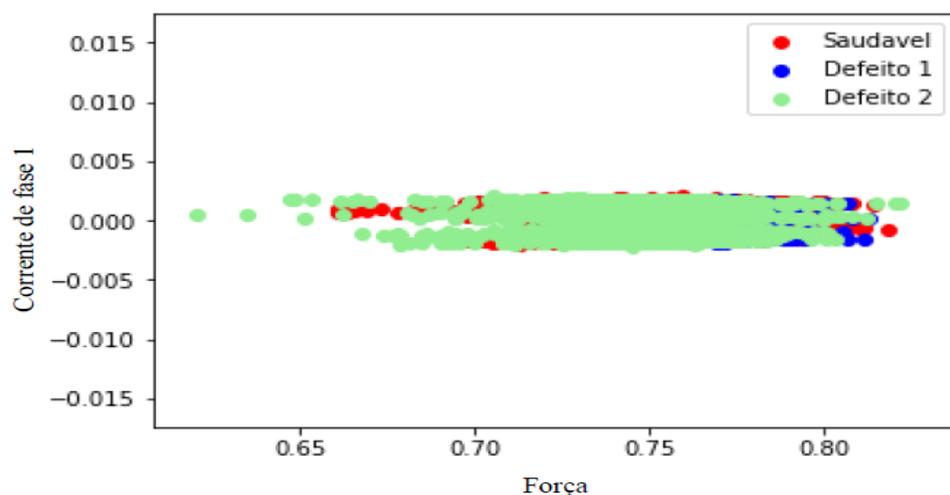


Figura 5: Comportamento do algoritmo de classificação (Treinamento).

Fonte: Autoria própria.

Na figura 5, no eixo Y estão os valores de Corrente de fase 1 e no eixo X os valores de Força. Essas duas variáveis foram correlacionadas porque nos mostram um gráfico mais fácil de ser interpretado, mas quaisquer das variáveis que existam na base de dados poderiam ser correlacionadas.

A partir dos valores existentes na base concatenada, foi plotada a correlação entre

as duas variáveis para visualmente entendermos a distribuição da condição do motor. Em vermelho, estão classificados os valores saudáveis, em azul estão classificados os valores com o defeito de perfuração, em verde os valores classificados como deformação plástica.

Como foi informado anteriormente, somente 70% dos valores da base foram utilizados. Após o teste do modelo de treinamento, foram testados no algoritmo de classificação somente os valores que não foram utilizados antes, ou seja, os 30% restantes dos valores das medições. A Figura 6 apresenta o resultado do algoritmo de classificação para essa base de dados.

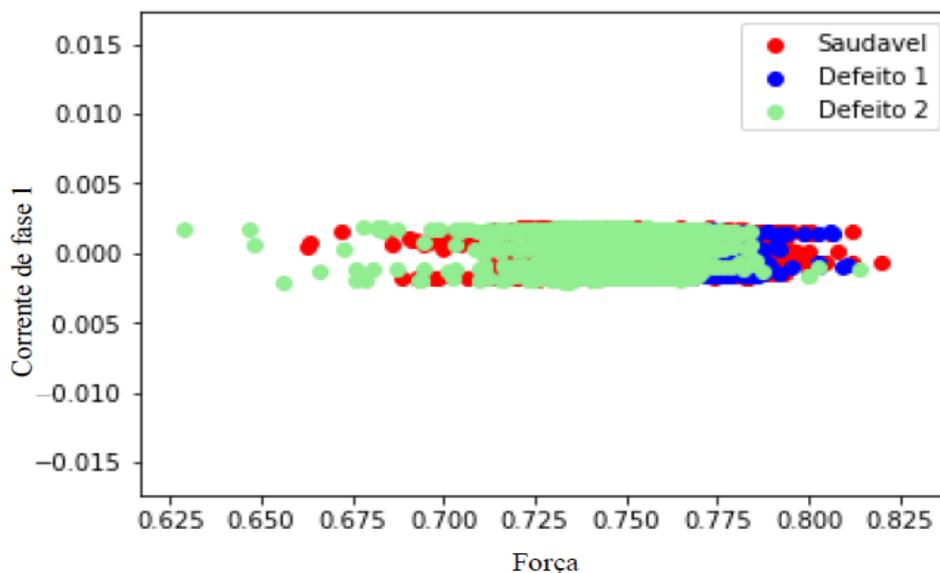


Figura 6: Comportamento do algoritmo de classificação (Teste).

Fonte: Autoria própria.

A figura 6 mostra o resultado da classificação dos dados rotulados. No eixo Y estão os valores de Corrente de fase 1 e no eixo X os valores de Força. A partir dos valores existentes na base concatenada, foi plotada a correlação entre as duas variáveis. Após isso, o algoritmo foi testado novamente, para verificar o que ele consegue classificar dos 30% dos valores da base de dados concatenada, porém sem os dados serem rotulados. A Figura 7 mostra a classificação obtida.

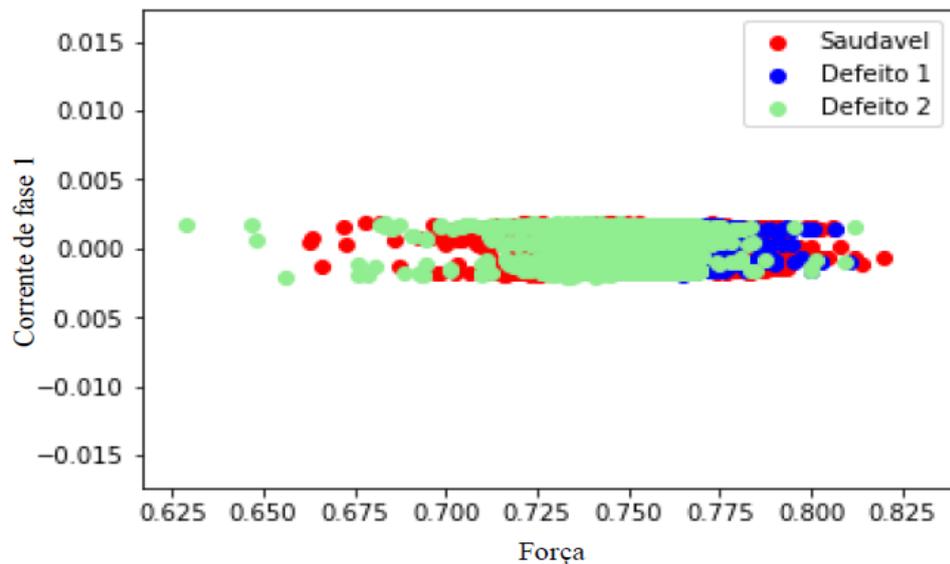


Figura 7: Comportamento do algoritmo de classificação (Predição).

Fonte: Autoria própria.

A Figura 7 representa a classificação dos dados sem serem rotulados. A precisão da classificação foi de aproximadamente 86%. Na Figura 7, no eixo Y estão os valores de Corrente de fase 1 e no eixo X os valores de Força. Os valores da relação entre as duas variáveis estão mostrados no gráfico.

3.3 Resultados em medições no laboratório do campus jataí

Neste tópico será mostrado o comportamento do algoritmo para medições feitas em um motor no laboratório de Eletrônica de Potência do IFG – Campus Jataí. As Figura 8, 9 e 10 mostram os resultados do algoritmo de regressão para a corrente nas três fases do motor:

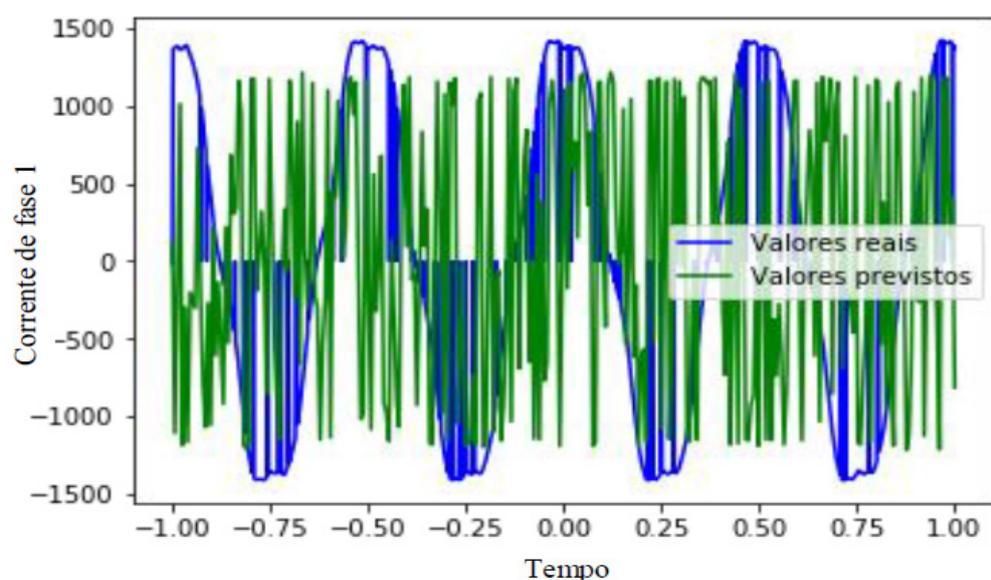


Figura 8: Comportamento do algoritmo de Regressão para a Corrente na Fase 1.

Fonte: Autoria própria.

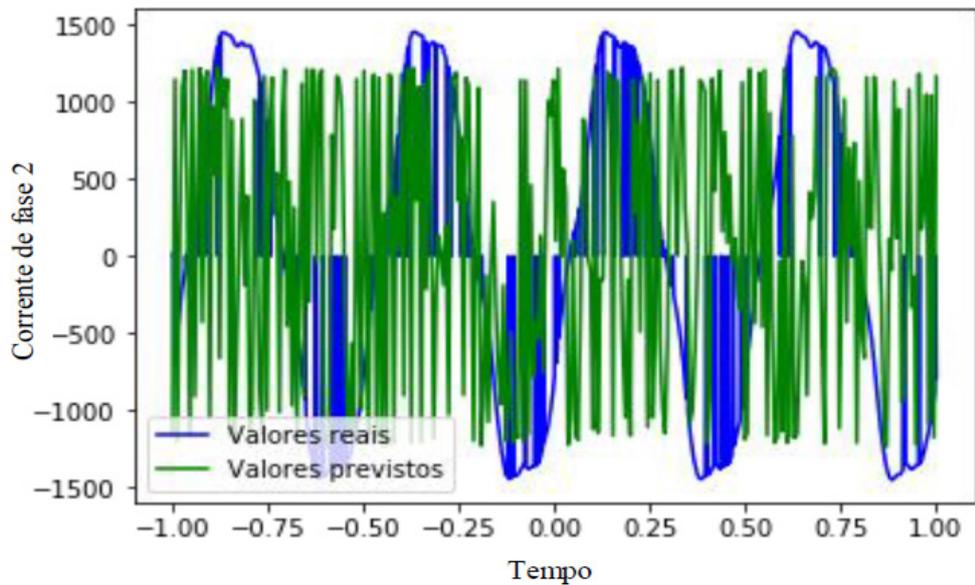


Figura 9: Comportamento do algoritmo de Regressão para a Corrente na Fase 2.

Fonte: Autoria própria.

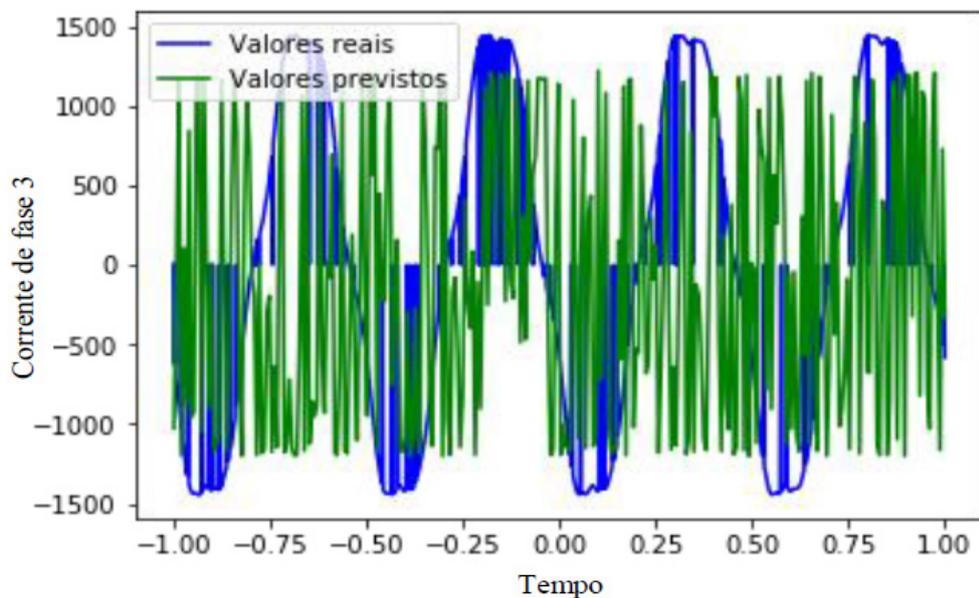


Figura 10: Comportamento do algoritmo de Regressão para a Corrente na Fase 3.

Fonte: Autoria própria.

O algoritmo de classificação teve uma precisão de aproximadamente 61% para essa base de dados. Se fossem colhidas mais amostras de medições de outras variáveis, tais como torque, força e vibração, essa precisão poderia ser maior.

Antes de testar o algoritmo de classificação na base de dados, foi necessário criar um modelo de classificação e testar uma base de dados diferente. A base utilizada para teste foi a base de dados concatenada contendo os valores das medições das três bases de dados: K006, KA07, KA30. Porém, as únicas variáveis aproveitadas foram velocidade e corrente de fase, pois foram as variáveis que foram medidas no motor.

O algoritmo conseguiu identificar um defeito no motor onde foram realizadas tais

medições. O comportamento do algoritmo de classificação é mostrado na Figura 11.

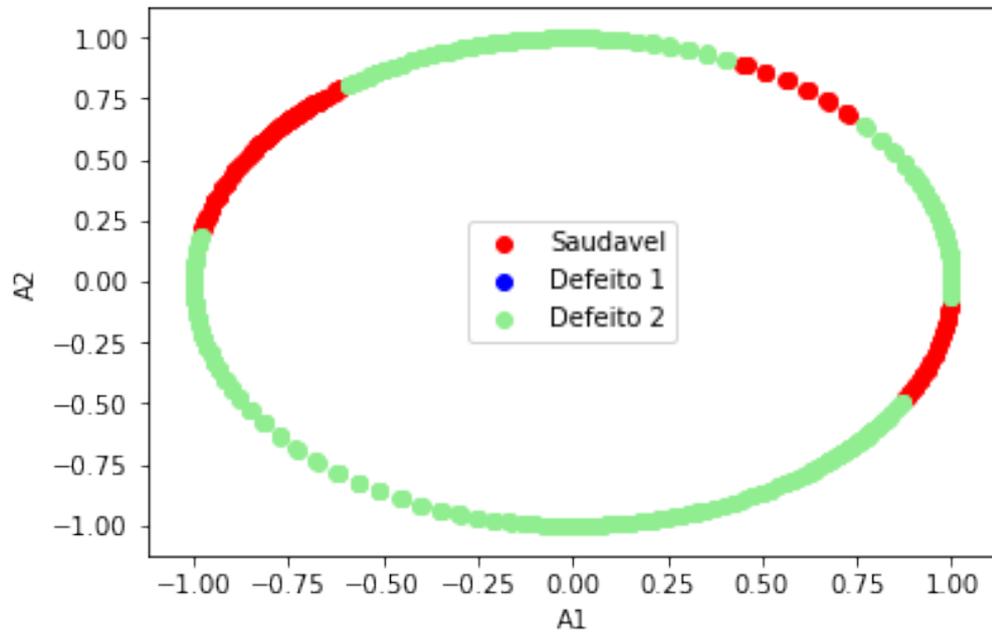


Figura 11: Comportamento do algoritmo de Classificação para a base de dados.

Fonte: Autoria própria.

Na figura 11 foram correlacionadas a Corrente de fase 1, representada pela variável A1, e a Corrente de fase 2, representada pela variável A2. O algoritmo classificou a base de dados obtida com medições no motor do IFG com o defeito 2, o defeito 1 não foi encontrado. O defeito encontrado é detalhado na Tabela 1:

Código do rolamento	Modo principal e sintomas	Elemento do rolamento	Combinação	Arranjos	Extensão do dano	Característica do dano
KA30	Deformação Plástica: Identação	OR	R	Aleatório	1	Distribuído
OR : Anel Externo; IR : Anel Interno ; R : Dano Repetitivo; S : Dano Singular; M : Danos Múltiplos.						

Tabela 1: Comportamento do algoritmo de Classificação para a base de dados.

Fonte: Lessmeier *et. al.* 2016 (Adaptado).

Quando foram colhidas as amostras das variáveis do motor do IFG, os sinais de corrente de fase estavam um pouco distorcidos. Essa distorção pode ocorrer por diversos fatores, neste caso, acredita-se que foi devido às harmônicas. Essa distorção pode influenciar no algoritmo de regressão, talvez classificando as amostras obtidas com um defeito que não exista no motor. No próximo tópico iremos trazer as considerações finais para este trabalho.

4 | CONCLUSÃO

Após o desenvolvimento deste trabalho, concluímos que o algoritmo de regressão, para variáveis com valores próximos de 1, possui uma eficácia de previsão de 99%. Já para variáveis com valores mais próximos de 0, o algoritmo apresentou uma eficácia menor.

O algoritmo de classificação obteve uma precisão de aproximadamente 86% para a base de dados concatenada. Na base dos dados obtidos através de medições feitas no motor no IFG, a precisão do algoritmo foi de aproximadamente 61%.

A quantidade de amostras também interferiu no resultado, pois a base de dados do motor do IFG continha 1024 amostras, o que, comparado à base de dados de treinamento com variáveis que continham mais de 200000 amostras, é muito pouco.

O subsistema desenvolvido demonstrou ser capaz de auxiliar as decisões de uma equipe de manutenção, informando o dano ou defeito encontrado em uma base de dados feita através de medições de variáveis de um motor elétrico, tais como: Velocidade, Corrente de fase, Torque, Vibração e Força.

Este trabalho foi aplicado especificamente na área de Engenharia Elétrica, porém o uso da Inteligência Artificial pode abrir caminhos para solucionar problemas em outras áreas da engenharia e em outras áreas do conhecimento humano, como por exemplo: Biologia, Medicina, Geografia, Matemática, entre outros.

REFERÊNCIAS

LESSMEIER, Christian; ZIMMER, Detmar; SEXTRO, Walter; KIMOTHO, James.

Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification.

Paderborn University, julho 2016.

SOBRE O ORGANIZADOR

João Dallamuta: Professor assistente da Universidade Tecnológica Federal do Paraná (UTFPR). Graduação em Engenharia de Telecomunicações pela UFPR. MBA em Gestão pela FAE Business School, Mestre pela UEL. Trabalha com Gestão da Inovação, Empreendedorismo e Inteligência de Mercado.

Agência Brasileira do ISBN
ISBN 978-85-7247-356-9

