

ÍTALO RODRIGO SOARES SILVA

**MODELO DE PREVISÃO DO KPI CONFIABILIDADE EM UM GRUPO DE
MÁQUINAS DE COMBUSTÃO INTERNA UTILIZANDO TÉCNICAS DE REDES
NEURAS ARTIFICIAIS EM USINAS TERMOELÉTRICAS**

ÍTALO RODRIGO SOARES SILVA

MODELO DE PREVISÃO DO KPI CONFIABILIDADE EM UM GRUPO DE MÁQUINAS DE COMBUSTÃO INTERNA UTILIZANDO TÉCNICAS DE REDES NEURAS ARTIFICIAIS EM USINAS TERMOELÉTRICAS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental - PPG.EGPSA, do Instituto de Tecnologia e Educação Galileo da Amazônia– ITEGAM, como parte dos requisitos necessários à obtenção do título de Mestre.

Orientador: Dr. Manoel Henrique Reis Nascimento

Coorientador: Dr. Milton Fonseca Júnior

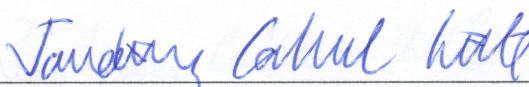
**MANAUS – AM
2021**

ÍTALO RODRIGO SOARES SILVA

**MODELO DE PREVISÃO DO KPI CONFIABILIDADE EM UM GRUPO DE
MÁQUINAS DE COMBUSTÃO INTERNA UTILIZANDO TÉCNICAS DE REDES
NEURAS ARTIFICIAIS EM USINAS TERMOELÉTRICAS**

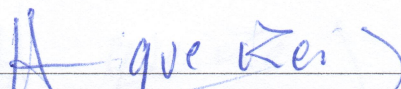
Esta dissertação foi julgada e aprovada para a obtenção do título de Mestre do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental do Instituto de Tecnologia e Educação Galileo da Amazônia – ITEGAM.

Manaus-AM, 27 de julho de 2021.

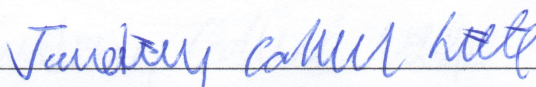


Prof. Dr. Jandecy Cabral Leite
Coordenador do PPG.EGPSA - ITEGAM

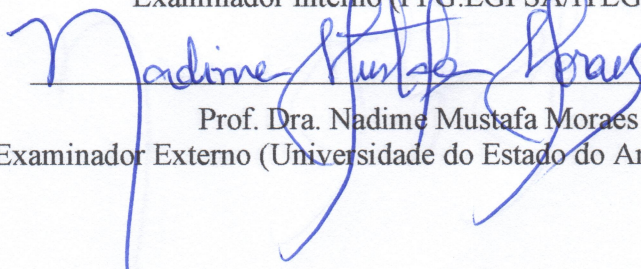
BANCA EXAMINADORA



Prof. Dr. Manoel Henrique Reis Nascimento
Orientador (PPG.EGPSA/ITEGAM)



Prof. Dr. Jandecy Cabral Leite
Examinador Interno (PPG.EGPSA/ITEGAM)



Prof. Dra. Nadime Mustafa Moraes
Examinador Externo (Universidade do Estado do Amazonas - UEA)

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Biblioteca do ITEGAM

Silva, Ítalo Rodrigo Soares, 2021 - Modelo de previsão do KPI confiabilidade em um grupo de máquinas de combustão interna utilizando técnicas de redes neurais artificiais em usinas termoelétricas / Ítalo Rodrigo Soares Silva - 2021. 114 f., il: Colorido

Orientador: Dr. Manoel Henrique Reis Nascimento

Co-orientador: Dr. Milton Fonseca Junior

Dissertação: Instituto de Tecnologia e Educação Galileo da Amazônia, Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA), Manaus - AM, 2021.

1. Usinas Termoelétricas 2. Redes Neurais Artificiais 3. Confiabilidade 4. Manutenção Preditiva

CDD - 1001. ed.2021.2

AGRADECIMENTOS

Primeiramente à Deus, pois a fé foi o meu combustível e força motriz para o aprendizado, experiência e vontade de realizar esta pesquisa.

Ao meu finado pai Fabrício Souza Silva e meu avô Fábio Paulo da Silva que Deus os tenham para glorificar este momento.

À minha avó e mãe que sempre me apoiaram em diversos momentos para que eu pudesse seguir adiante e por nunca medirem esforços principalmente pela minha educação.

À minha família que sempre me apoiou e incentivou.

Ao meu mentor Doutor Jandecy Cabral Leite pelos ensinamentos, experiências e incentivo à pesquisa.

Ao meu orientador Doutor Manoel Henrique Reis Nascimento e Coorientador Doutor Milton Fonseca Júnior que contribuíram ativamente para este trabalho com ensinamentos, orientações e experiências na qual sem isso este trabalho não seria possível.

Ao corpo docente do **Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental** do **ITEGAM** na qual foi solícito e atendeu as expectativas de aprendizado em aulas.

Ao **ITEGAM** e a coordenação acadêmica por disponibilizar toda a infraestrutura e equipamentos para estudo e análises laboratoriais em aulas.

Aos colaboradores do **ITEGAM** que sempre apoiaram e incentivaram esta pesquisa, em especial aos colegas Ricardo Silva Parente e Paulo Oliveira Siqueira Júnior.

E todas as pessoas que acompanharam a minha vida acadêmica e que permitiram o meu amadurecimento enquanto aluno.

Epígrafe

“Viva sem deixar nenhum arrependimento.”

Portgas D. Ace

Dedicatória

Dedico esta pesquisa a todos aqueles que contribuíram para a sua realização: ao Altíssimo, à minha família, aos colegas de trabalho e todos da comunidade científica.

RESUMO

SILVA, Ítalo Rodrigo Soares. **Modelo de previsão do KPI Confiabilidade em um grupo de Máquinas de Combustão Interna utilizando Técnicas de Redes Neurais Artificiais em Usinas Termoeletricas**. 2021. p. 114. Dissertação do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (EGPSA), Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM), Manaus, 2021.

A indisponibilidade de equipamentos em Termoeletricas por quaisquer motivos se torna um risco do empreendedor, este que como consequência arca com prejuízos ainda maiores com um custo elevado de máquinas paradas, além das penalidades sancionadas e previstas por lei, partindo desse pressuposto os programas de manutenção são metodologias que visam contribuir com técnicas e ferramentas de mitigação dessa problemática, contudo, somente o uso dos programas de manutenção não são suficientes, dessa forma, esta pesquisa tem como objetivo desenvolver um Algoritmo de Previsão da Confiabilidade de Motores, capaz de prever o Indicador Chave de Performance Confiabilidade, tendo como finalidade indicar a probabilidade do equipamento operar em um espaço de tempo pré-definido, como objeto de estudo se tem um grupo de máquinas de combustão interna de Usinas Termoeletricas. Em virtude disso, a pesquisa cumpre com os objetivos de catalogar as variáveis significativas para o modelo de previsão; analisar doze algoritmos de treinamento da RNA, considerando a abordagem de aprendizado supervisionado, onde a quantidade de neurônios, camadas escondidas e funções de ativação são requisitos de performance da rede; desenvolver o modelo de previsão da Confiabilidade do grupo de motores, onde os algoritmos de treinamento são validados por meio do critério de parada do melhor modelo; encontrar a melhor performance da rede com base no Erro Médio Quadrático (MSE), Raiz do Erro Médio Quadrático (RMSE), Regressão Linear e Avaliação de parada pelo melhor modelo; por fim, simular os dados de falhas catalogados afim de analisar o estado técnico do grupo de motores com o melhor modelo. A inovação da pesquisa é caracterizada pelos métodos computacionais de processamento de dados ao utilizar: métodos de otimização, iterativos e heurísticos, caracterizando o uso de técnicas de inteligência artificial para prever a Confiabilidade em dias e meses, além disso, é utilizado os indicadores da manutenção preditiva como: Tempo Médio entre Falhas (MTBF), Tempo Médio para Reparo (MTTR), Disponibilidade e Confiabilidade. Para analisar os resultados dessa pesquisa, utilizou-

se de um conjunto de vinte unidades de geração de carga como parâmetros de investigação da frequência de falhas, foram aplicados os doze algoritmos de treinamento, com uma combinação entre as funções de ativação: Sigmoide, Linear e Tangente Hiperbólica, os resultados da pesquisa mostram que as técnicas de *Levenberg-Marquardt* e *Bayesian Regularization* apresentaram 100% de correlação entre as variáveis de saída e simulada, caracterizando a eficiência na previsão em dias e meses.

Palavras-chave: Usinas Termoelétricas, Redes Neurais Artificiais, Confiabilidade, Manutenção Preditiva.

ABSTRACT

SILVA, Ítalo Rodrigo Soares. **Modelo de previsão do KPI Confiabilidade em um grupo de Máquinas de Combustão Interna utilizando Técnicas de Redes Neurais Artificiais em Usinas Termoeletricas**. 2021. p. 114. Dissertação do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (EGPSA), Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM), Manaus, 2021.

The unavailability of equipment in thermoelectric plants for any reason becomes a risk of the entrepreneur, who as a consequence bears even greater losses with a high cost of machines stopped, in addition to the penalties sanctioned and provided by law, based on this assumption the maintenance programs are methodologies that aim to contribute with techniques and tools to mitigate this problem, however, However, only the use of maintenance programs are not enough, thus, this research aims to develop an Engine Reliability Prediction Algorithm, capable of predicting the Reliability Key Performance Indicator, with the purpose of indicating the probability of the equipment to operate in a pre-defined space of time, as the object of study has a group of internal combustion machines of Thermoelectric Power Plants. In view of this, the research meets the objectives of cataloging the significant variables for the prediction model; analyze twelve ANN training algorithms, considering the supervised learning approach, where the number of neurons, hidden layers, and activation functions are performance requirements of the network; To develop the prediction model for the reliability of the motor group, where the training algorithms are validated using the best model stopping criterion; to find the best network performance based on Mean Squared Error (MSE), Root Mean Square Error (RMSE), Linear Regression, and Best Model stopping criterion; and finally, to simulate the cataloged failure data in order to analyze the technical state of the motor group with the best model. The innovation of the research is characterized by the computational methods of data processing by using: optimization methods, iterative and heuristic, characterizing the use of artificial intelligence techniques to predict the reliability in days and months, in addition, it is used predictive maintenance indicators as: Mean Time Between Failures (MTBF), Mean Time To Repair (MTTR), Availability and Reliability. To analyze the results of this research, a set of twenty load generation units was used as parameters for investigating the frequency of failures, the twelve training algorithms were applied, with a combination between the activation

functions: Sigmoid, Linear and Hyperbolic Tangent, the research results show that the techniques of Levenberg-Marquardt and Bayesian Regularization showed 100% correlation between the output and simulated variables, characterizing the efficiency in predicting in days and months.

Keywords: Thermal Power Plants, Artificial Neural Networks, Reliability, Predictive Maintenance.

LISTA DE FIGURAS

Figura 2.1 - Modelo de movimento harmônico.....	33
Figura 2.2 - Assinatura Espectral.	35
Figura 2.3 - Espectro de frequência.....	36
Figura 2.4 - Arquitetura de uma RNA.....	41
Figura 2.5 - Gráfico da função Sigmoide.	42
Figura 2.6 - Gráfico da função Tangente hiperbólica.....	43
Figura 2.7 - Gráfico da função ReLU.....	44
Figura 3.1 - Fluxo de etapas.	55
Figura 4.1 - Algoritmo APCM.	62
Figura 4.2 - Comparativo de erros do grupo de máquinas previsão dias.	68
Figura 4.3 - Arquitetura da RNA vencedora na previsão em dias.....	69
Figura 4.4 - Regressão linear do Algoritmo Levenberg-Marquardt.....	70
Figura 4.5 - Comparativo de erros do grupo de máquinas previsão meses.....	86
Figura 4.6 - Arquitetura da RNA vencedora na previsão de meses.	87
Figura 4.7 - Regressão Linear do Algoritmo Bayesian Regularization.....	88
Figura 4.8 - Relação TP e TF janeiro e maio de 2019 - MO6.....	95

LISTA DE GRÁFICOS

Gráfico 4.1 - Análise de dados dos anos: 2018 e 2019.....	60
Gráfico 4.2 - Análise das Horas de Operação dos anos: 2018 e 2019.....	61
Gráfico 4.3 - Análise da performance previsão dias.....	71
Gráfico 4.4 - Histograma de Erro do Motor 7 previsão dias.	72
Gráfico 4.5 - Análise da Confiabilidade 2018 – MO7.....	72
Gráfico 4.6 - Análise da Disponibilidade 2018 – MO7.....	73
Gráfico 4.7 - Análise da Confiabilidade 2019 – MO7.....	73
Gráfico 4.8 - Análise da Disponibilidade 2019 – MO7.....	74
Gráfico 4.9 - Taxa de parada ano 2018 – MO7.	74
Gráfico 4.10 - Taxa de parada ano 2019 – MO7.	75
Gráfico 4.11 - Análise comparativa do TP e TF em 2018 – MO7.	75
Gráfico 4.12 - Relação do TP e TF do mês de junho de 2018 – MO7.	76
Gráfico 4.13 - Análise comparativa do TP e TF em 2019 – MO7.	76
Gráfico 4.14 - Relação do TP e TF em janeiro de 2019 – MO7.....	77
Gráfico 4.15 - Comparativo do modelo simulado e calculado para 1 dia.	77
Gráfico 4.16 - Confiabilidade prevista para 1 dia.....	78
Gráfico 4.17 - Confiabilidade prevista para 5 dias.	79
Gráfico 4.18 - Confiabilidade prevista para 10 dias.	80
Gráfico 4.19 - Confiabilidade prevista para 15 dias.	81
Gráfico 4.20 - Confiabilidade prevista para 20 dias.	82
Gráfico 4.21 - Comparativo de previsões – MO7.....	83
Gráfico 4.22 - Análise da performance previsão meses.	89
Gráfico 4.23 - Histograma de erro Motor 6 previsão meses.....	90
Gráfico 4.24 - Análise da Confiabilidade - MO6.	90
Gráfico 4.25 - Análise da Disponibilidade - MO6.	91
Gráfico 4.26 - Análise da Confiabilidade 2019 - MO6.	91
Gráfico 4.27 - Análise da disponibilidade 2019 - MO6.	92
Gráfico 4.28 - Taxa de parada ano 2018 – MO6.	92
Gráfico 4.29 - Taxa de parada ano 2019 – MO6.	93
Gráfico 4.30 - Análise comparativa do TP e TF em 2018 – MO6.	93
Gráfico 4.31 - Relação do TP e TF do mês de março de 2018 – MO6.	94

Gráfico 4.32 - Análise comparativa do TP e TF em 2019 – MO6.	94
Gráfico 4.33 - Comparativo entre o modelo simulado e calculado para 1 mês.	95
Gráfico 4.34 - Confiabilidade prevista para 1 mês.	96
Gráfico 4.35 - Confiabilidade prevista para 3 meses.	97
Gráfico 4.36 - Confiabilidade prevista para 5 meses.	98
Gráfico 4.37 - Comparativo de previsões.	99

LISTA DE TABELAS

Tabela 4.1 - Algoritmos vencedores (previsão dias).....	67
Tabela 4.2 - Taxa de Confiabilidade prevista para 1 dia.....	78
Tabela 4.3 - Taxa de Confiabilidade prevista para 5 dias.....	79
Tabela 4.4 - Taxa de Confiabilidade prevista para 10 dias.....	80
Tabela 4.5 - Taxa de Confiabilidade prevista para 15 dias.....	81
Tabela 4.6 - Taxa de Confiabilidade prevista para 20 dias.....	82
Tabela 4.7 - Comparativo de Mínimos e Máximos.....	84
Tabela 4.8 - Algoritmos vencedores (previsão meses).....	84
Tabela 4.9 - Taxa de Confiabilidade prevista para 1 mês.....	96
Tabela 4.10 - Taxa de Confiabilidade prevista para 3 meses.....	97
Tabela 4.11 - Taxa de Confiabilidade prevista para 5 meses.....	98
Tabela 4.12 - Comparativo de Mínimos e Máximos.....	100

LISTA DE QUADROS

Quadro 3.1 - Exemplos de falhas.	51
Quadro 3.2 - Características do grupo de máquinas.....	52
Quadro 3.3 - Variáveis de entrada e saída da RNA.	52
Quadro 3.4 - Recursos computacionais da máquina simuladora.	53
Quadro 3.5 - Algoritmos de treinamento.	54

LISTA DE SIGLAS E ABREVIATURAS

AHP	Processo de Hierarquia Analítica
AM	Manutenção Autônoma
FAHP	<i>Fuzzy AHP</i>
FMEA	<i>Failure Mode and Effect Analysis</i>
GPMP	Gestão do Plano de Manutenção Preventiva
HFAHP	Hesitant FAHP
IA	<i>Artificial Intelligence</i>
IAMP	Plataformas de Gestão de Ativos Inteligentes
IFAHP	Intuitionistic FAHP
IoT	<i>Internet Of Things</i>
ISO	<i>International Organization for Standardization</i>
KPI	<i>Key Performance Indicator</i>
MCI	Máquinas de Combustão Interna
MDT	Tempo médio de indisponibilidade
MMS	Sistema de Gestão de Manutenção
MP	Manutenção Preventiva
MTBF	<i>Mean Time Between Failures</i>
MTTR	<i>Mean Time To Repair</i>
MUT	Tempo médio de disponibilidade
NARX	<i>Nonlinear Autoregressive Exogenous</i>
NBR	Norma Técnica Brasileira
PDM	Modelo de Manutenção Preditiva
RNA	Redes Neurais Artificiais
SOM	<i>Self-Organizing Maps</i>
TD	Total de Dias
TF	Taxa de Falhas
TO	Total de Ocorrências
TP	Total de Parada
MO	Motor
TPM	Manutenção Produtiva Total
UTE	Usinas Termoelétricas
RAM	<i>Random Access Memory</i>
GB	<i>Gigabyte</i>
SNF	<i>Sistema Neuro-Fuzzy</i>
ANFIS	<i>Adaptive neuro fuzzy inference system</i>
NEFCLASS	<i>Neuro-Fuzzy Classification</i>
FSOM	<i>Fuzzy Self-Organized Map</i>

SUMÁRIO

1	INTRODUÇÃO	20
1.1	JUSTIFICATIVA DA DISSERTAÇÃO.....	21
1.2	OBJETIVOS.....	23
1.2.1	Geral	23
1.2.2	Específicos	23
1.3	ESCOPO DO TRABALHO	23
2	REVISÃO BIBLIOGRÁFICA	25
2.1	ESTADO DA ARTE	25
2.1.1	Gestão da Manutenção.....	25
2.1.2	Modelos de Inteligência Computacional.....	28
2.2	GESTÃO DA MANUTENÇÃO	31
2.2.1	Manutenção Preditiva	31
2.2.2	Análise de vibração.....	32
2.2.3	Termografia	35
2.2.4	Análise de óleo.....	36
2.2.5	Ultrassom.....	37
2.2.6	Indicador Chave de Performance Confiabilidade	37
2.3	REDES NEURAIS ARTIFICIAIS (RNA).....	39
2.3.1	Arquiteturas de RNA	39
2.3.2	Aprendizado de uma RNA.....	41
2.3.3	Algoritmos de treinamento	44
3	MATERIAIS E MÉTODOS	51
3.1	MATERIAIS	51
3.1.1	Documentos de manutenção	51
3.1.2	Características do grupo de máquinas	52
3.1.3	Indicadores da Gestão da Manutenção	52
3.1.4	Ambiente de desenvolvimento	53

3.1.5	Recursos da máquina de teste.....	53
3.1.6	Algoritmos de treinamento	53
3.1.7	Funções de ativação	54
3.2	MÉTODOS	54
3.2.1	Análise dos registros documentais de falhas	55
3.2.2	Seleção de variáveis fundamentais para o modelo computacional	55
3.2.3	Implementação do modelo de previsão com RNA e Indicadores da Gestão da Manutenção.....	57
3.2.4	Análise e comparação dos resultados com o modelo de previsão.....	58
4	RESULTADOS E DISCUSSÕES.....	60
4.1	ANÁLISE DE REGISTROS DOCUMENTAIS DE FALHAS	60
4.2	DESENVOLVIMENTO DO ALGORITMO DE PREVISÃO DA CONFIABILIDADE DE MOTORES (APCM).....	61
4.3	APLICAÇÃO DOS ALGORITMOS DE TREINAMENTO PARA PREVISÃO DE DIAS	66
4.3.1	Modelo de RNA vencedora	69
4.3.2	Indicadores da Gestão da Manutenção	72
4.3.3	Simulações para 1, 5, 10, 15 e 20 dias	77
4.4	APLICAÇÃO DOS ALGORITMOS DE TREINAMENTO PARA PREVISÃO DE MESES	84
4.4.1	Modelo de RNA vencedora	87
4.4.2	Indicadores da Gestão da Manutenção	90
4.4.3	Simulações para 1, 3 e 5 meses	95
5	CONCLUSÕES E SUGESTÕES	101
5.1	CONCLUSÕES	101
5.2	SUGESTÕES PARA TRABALHOS FUTUROS.....	102

CAPÍTULO 1

1 INTRODUÇÃO

Um dos fatores que contribuem para os impactos ambientais, sociais e econômicos nos setores do comércio e da indústria é a falha de máquinas e/ou geradores elétricos, estes que proporcionam a geração de energia para diversos consumidores por meio do despacho de carga (CORRÊA, 2020; SALLES *et. al.*, 2020; RUIZ-HERNÁNDEZ *et. al.*, 2020).

Neste setor há um destaque preocupante com a interrupção do fornecimento de energia, ocasionado por falhas ou paradas de máquinas, estes que impactam diretamente nos setores de serviços essenciais como: hospitais, clínicas e supermercados, ocasionando eventuais danos irreversíveis como a perda de vidas (CHINI *et. al.*, 2020).

Os programas de manutenção são metodologias que usufruem de ferramentas para manter ou aumentar a expectativa de vida útil de um determinado equipamento, na qual métodos de prevenção, predição e correção são executados por profissionais qualificados, estes que adaptam ou adotam metodologias de diferentes procedimentos para executar no ambiente (AGNESE, 2020).

Dessa maneira ao se tratar de máquinas, algumas técnicas são levadas em consideração, como: análise de vibração, análise termográfica, análise de óleo, ultrassom e outras, são medidas eficazes para identificar falhas, contudo, demanda tempo, controle rigoroso dos pontos de medição e treinamento de pessoal para executar os procedimentos de avaliação (ROCHA, *et. al.*, 2020; ZINGONI, 2020).

Para se obter um controle apurado e gerência nos programas de manutenção é utilizado os Indicadores Chave de Performance que são regulamentados pela Norma Brasileira 5462, trazendo a temática desses indicadores, há a Confiabilidade que se refere a probabilidade do funcionamento adequado de um equipamento dentro de um determinado período de tempo dos elementos envolvidos na cadeia produtiva.

Em virtude da evolução de demandas no setor, considerando soluções que consigam mitigar a problemática de falhas em máquinas, a ciência avança com tecnologias e ferramentas cada vez mais eficientes, objetivando resultados satisfatórios com o uso adequado de técnicas de inteligência artificial (SOUZA, 2020; ABDULRAHMAN *et. al.*, 2020; BAROROH *et. al.*,

2020), estes que em muitos casos apresentam e são fundamentados por meio de modelos matemáticos.

Trazendo à tona a realidade desta pesquisa, tem-se o destaque da sua inovação em implementar, testar e analisar técnicas de Redes Neurais Artificiais (RNA) com o uso de Algoritmos de Treinamento, estes que são cientificamente fundamentados por modelos matemáticos ou métodos heurísticos, que executam processos estocásticos para encontrar a região ótima de convergência dentro de um espaço de busca (SOUZA, 2020; ABDULRAHMAN *et. al.*, 2020; BAROROH *et. al.*, 2020).

A sua contribuição vem de encontro com a problemática de falhas e a investigação do método de Confiabilidade, para avaliar a probabilidade de funcionamento do equipamento em um período de tempo, além disso, é válido ressaltar o uso de Aprendizado de Máquina, Reconhecimento de Padrões, Classificação de Padrões, Métodos Determinísticos, Heurísticas sistemáticas e Algoritmos de Otimização (RIGHETTO, 2020; ABDULRAHMAN *et. al.*, 2020; BAROROH *et. al.*, 2020) para analisar e avaliar o registro de falhas e mensurar indicadores da Gestão da Manutenção (CARDOSO, 2020; ARUNTHAVANATHAN *et. al.*, 2020).

Logo, a pesquisa apresenta um enfoque no cenário da manutenção de máquinas de combustão interna em Usinas Termoelétricas, onde será investigado e desenvolvido um modelo de previsão que usufrua das técnicas de RNA para prever o grau de Confiabilidade desses equipamentos em um período de dias e meses.

1.1 JUSTIFICATIVA DA DISSERTAÇÃO

A indisponibilidade de equipamentos em Termoelétricas por quaisquer motivos se torna um risco do empreendedor, este que como consequência arca com prejuízos ainda maiores com um custo elevado de máquinas paradas, além das penalidades sancionadas e previstas por lei, estas que chegam até a perda da garantia física que implicam na redução de energia vendida.

Em virtude disso, a pesquisa se justifica pela oportunidade de melhorar os métodos de predição na manutenção de Máquinas de Combustão Interna em Usinas Termoelétricas, provendo um modelo computacional capaz de estimar a probabilidade de funcionamento do equipamento em um determinado espaço de tempo, que sirva como ferramenta de apoio a tomada de decisão, dentre as contribuições se destacam:

- Previsão a curto e médio prazo da frequência de falhas, além do grau de confiabilidade por motor.

- Modelo Supervisionado de aprendizado de máquina capaz de prever o Indicador Chave de Performance Confiabilidade utilizado na gestão da manutenção em um grupo de máquinas de combustão interna;
- Indicadores de avaliação do estado técnico da máquina como MTBF, MTTR, Disponibilidade e Confiabilidade.

O estudo é delimitado na investigação dos elementos passíveis de falha no grupo de máquinas, através dos relatórios de manutenção, onde serão utilizados alguns indicadores como variáveis de entrada para o modelo de RNA:

- Total de Ocorrências - TO;
- Total de Parada - TP;
- Tempo Total de Operação da Máquina;
- Tempo Médio entre Falhas - MTBF;
- Tempo Médio de Reparo – MTTR;
- Disponibilidade;
- Taxa de Falhas – TF;
- Total de Dias Analisados - TD.
- Ano;
- Dias de Previsão

Para a avaliação do melhor modelo de RNA será comparado o Erro Médio Quadrático (MSE) e a Raiz Quadrática do Erro Médio (RMSE), usufruindo da abordagem de aprendizado supervisionado e os seguintes algoritmos de treinamento:

- *Levenberg-Marquardt,*
- *Bayesian Regularization,*
- *Broyden–Fletcher–Goldfarb–Shanno Quasi-Newton,*
- *Resilient Backpropagation,*
- *Scaled Conjugate Gradient,*
- *Conjugate Gradient with Powell/Beale Restarts,*
- *Fletcher-Powell Conjugate Gradient,*
- *Polak-Ribière Conjugate Gradient,*
- *One Step Secant,*
- *Variable Learning Rate Gradient Descent,*
- *Gradient Descent with Momentum;*
- *Gradient Descent.*

Concluindo as etapas de treinamento, teste, validação e seleção da melhor RNA, será realizado simulações em dois horizontes de tempo:

- Curto prazo considerando: 1, 5, 10, 15 e 20 dias;
- Médio prazo considerando: 1,3 e 5 meses;

Dessa forma, será possível realizar análises comparativas acerca dos indicadores e estimar a Confiabilidade nesses períodos de tempo.

1.2 OBJETIVOS

1.2.1 Geral

Desenvolver um Algoritmo de Previsão da Confiabilidade de Motores que contemple o uso do aprendizado de máquina com Redes Neurais Artificiais (RNA) para estimar o Indicador Chave de Performance (KPI) Confiabilidade em um grupo de Máquinas de Combustão Interna (MCI) em Usinas Termoelétricas.

1.2.2 Específicos

- Catalogar as variáveis significativas dos registros documentais de falhas para o modelo de RNA;
- Analisar os diversos algoritmos de aprendizado para o treinamento da RNA considerando a formulação do aprendizado supervisionado;
- Desenvolver o modelo computacional para a previsão da Confiabilidade de Motores utilizando as técnicas de RNA;
- Encontrar o modelo de RNA com menor RMSE para cada motor;
- Simular os dados de falhas catalogados do histórico de falhas com o melhor modelo de RNA provido do Algoritmo de Previsão da Confiabilidade de Motores;

1.3 ESCOPO DO TRABALHO

A dissertação possui cinco capítulos, sendo estruturada da seguinte forma:

- **Capítulo 1:** Introdução sobre o tema, identificação e justificativa do problema, os objetivos, contribuição e relevância do estudo e delimitação da pesquisa;
- **Capítulo 2:** Neste capítulo é apresentado um estado da arte considerando os trabalhos relacionados à Gestão da Manutenção e Modelos de Inteligência Artificial, os

conceitos e características da Gestão da Manutenção considerando os Indicadores Chave de Performance, por fim é explanado sobre as Técnicas de Redes Neurais Artificiais, as arquiteturas, funções de ativação e algoritmos de treinamento;

- **Capítulo 3:** São apresentados os procedimentos metodológicos da pesquisa, os materiais utilizados e métodos realizados para chegar nos resultados e conclusões;
- **Capítulo 4:** Neste capítulo são apresentados os principais resultados pertinentes aos testes e comparações dos modelos de RNA, configurações de arquitetura da RNA, erros, arquiteturas, e os resultados de simulações nos períodos de tempo em dias e meses com as comparações por motor;
- **Capítulo 5:** No último capítulo é apresentado as conclusões da pesquisa e as sugestões para trabalhos futuros;

CAPÍTULO 2

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta os principais elementos para o embasamento científico da pesquisa, onde é considerado uma forte revisão bibliográfica referente à Gestão da Manutenção, Modelos de Inteligência Computacional, Redes Neurais Artificiais e aplicação desses elementos no contexto deste trabalho.

2.1 ESTADO DA ARTE

Nos tópicos de Gestão da Manutenção e Modelos de Inteligência Computacional são apresentadas algumas inovações como parte integrante do contexto abordado na presente pesquisa, contribuindo com elementos que estão sendo trabalhados por outros autores.

2.1.1 Gestão da Manutenção

A gestão da manutenção se torna importante e parte do processo decisório de uma empresa a partir do momento em que existe o comprometimento da entrega do produto ou serviço ao cliente/consumidor, tornando isso uma vertente de custos extras (OHTA, SALOMON e SILVA, 2020).

Contudo, a realização dos procedimentos exige capacidade técnica e métodos empregados de forma abrangente nos demais setores de uma empresa, dessa maneira, o cenário atual das empresas representa uma adaptação gradual na globalização da economia ao alcançar a qualidade total em produtos, serviços e gerenciamento ambiental (SINGH *et. al.*, 2020).

Um dos problemas na gestão da manutenção é o controle de previsão dos *KPIS*, além da minimização e maximização dos mesmos, ou seja, encontrar o equilíbrio adequado para cada máquina e setor de operação sem agredir a margem de lucro e capacidade de produção de uma empresa (MARTINS *et. al.*, 2020).

Pesquisas acerca do assunto são desenvolvidas afim de alcançar novos modelos de controle e gerenciamento dos demais *KPIS* que se desdobram desde a previsão quanto aos procedimentos de análise do equipamento (SOBRAL, 2020).

Garantir a qualidade, disponibilidade e confiabilidade se torna uma importante tarefa, que requer o auxílio de ferramentas e modelos matemáticos, que sejam capazes de expressar os valores da empresa e gerar a informação necessária para a tomada de decisão (SELVIK, STANLEY, ABRAHAMSEN, 2020).

Um conjunto de nove grupos de indicadores é desenvolvido, para representar o desempenho em edifícios inteligentes (AL DAKHEEL, 2020), onde o estudo se consolida em duas etapas:

A primeira se baseia no estudo e implementação do conceito *smartness* do ambiente da construção, ele destaca as características, funções e tecnologias de diversos modelos de construção civil inteligentes.

A segunda parte é concentrada em um documento onde é destacado as análises de indicadores chave de desempenho existentes que impactam diretamente na qualidade da construção de edifícios inteligentes.

Mediante os fatos, foi constatado que a necessidade do desenvolvimento de uma diretriz quantificada para melhorar a inovação energética e tecnológica é base para o aumento da inteligência em edifícios (AL DAKHEEL, 2020).

Em sua pesquisa, Martins *et. al.* (2020) define e aplica um conjunto de métodos e filosofias, para melhorar o processo de Gestão da Manutenção Preventiva em uma empresa, dedicada na produção e manutenção de transformadores de potência e distribuição.

O autor utiliza do método de pesquisa-ação, estratégia de manutenção mista baseada em Manutenção Centrada em Confiabilidade (RCM) e Manutenção Produtiva Total (TPM). Com o desenvolvimento desse trabalho foi possível destacar as seguintes realizações:

- Método de classificação crítica do equipamento baseado em sua importância para o processo de produção;
- Desenvolvimento de um fluxograma de decisões e ações para o GPMP (Gestão do Plano de Manutenção Preventiva);
- Redução do tempo perdido em Manutenção Preventiva (MP);
- Implantação da Manutenção Autônoma (AM) que resultou em 66% nas falhas de equipamentos;
- Introdução de um conjunto de novos Indicadores Chave de Desempenho (KPI's);
- Aumento nas taxas de cumprimento dos planos de manutenção em 12%.

No final da obra poderá alcançar uma redução de 120.060 euros.

Já na pesquisa de Mutlag e DaWood (2020) é descrito a implementação de um modelo de Processo de Hierarquia Analítica (AHP) com a finalidade de melhorar o Sistema de Gestão de Manutenção (MMS), através de um estudo de caso em usinas geradoras de energia elétrica (*South Baghdad Power Plant*) ele seleciona o melhor modelo MMS, tendo como premissas de seleção:

- Sucesso ou Falha – M1;
- Falha não planejada – M2;
- Manutenção Preventiva – M3;
- Manutenção Proativa – M4;
- Manutenção Preditiva – M5;

Contudo, outros parâmetros de análise são utilizados como: KPI's, Segurança, Operação de Manutenção, Treinamento, Combustível, Custo de Manutenção, Qualidade e Tamanho da Tripulação. Como resultado avaliado pelo Sistema AHP a melhor classificação foi a M3.

Na pesquisa desenvolvida pelos autores Roth, Brown IV e Jain (2020) é realizado uma integração de métodos de ciências sociais, e dados para entender as limitações dos sistemas de informação de gerenciamento de energia (EMIS), com o intuito de informar o projeto de uma nova estrutura de indicadores de desempenho de Gestão de Energia Multicamadas (MEMPI), para caracterizar o desempenho de energia de edifícios.

É aplicado a estrutura MEMPI a dados reais de 569 edifícios de escolas públicas da Califórnia e realizado a medição do desempenho energético em diferentes e variadas escalas de tempo, por fim, a pesquisa é conduzida a uma série de comparações das percepções da estrutura MEMPI, em relação a percepção dos gerentes que supervisionam as escolas.

O uso de indicadores chave de desempenho é fundamental na indústria para formalizar e representar os objetivos de operação, atualmente definidos pelos padrões ISO 22400, para melhorias contínuas nos processos de manufatura e vistos como uma ferramenta de suporte para medir melhorias (BHADANI *et. al.*, 2020).

O autor utiliza o método do cálculo de *KPI's* relevantes para uma planta de produção de agregados usando simulações dinâmicas. Sendo a implementação dos *KPI's* em três estágios, conforme mencionado em sua pesquisa esses indicadores são essenciais para os operadores e gerentes da fábrica tomarem decisões. De acordo com os resultados são apresentadas

características de relacionamento com as dependências de vários equipamentos e *KPI's* de processo.

Um estudo contribuindo com o reconhecimento dos *KPI's* de excelência operacional em direção à sustentabilidade é realizado, examinando os artigos científicos revisados por meio de sugestões de especialistas, os *KPI's* identificados são agrupados em seis categorias dominantes e 27 sub-categorias no campo da indústria de produtos de couro que é o enfoque da pesquisa, de acordo com a pesquisa as descobertas indicam que os *KPI's* da categoria de Gerenciamento têm a prioridade mais alta (MOKTADIR *et. al.*, 2020).

2.1.2 Modelos de Inteligência Computacional

Com a introdução de procedimentos e modelos computacionais no cenário empresarial e industrial com o intuito de realizar processos de forma inteligente, ágil e confiável muitos pesquisadores dedicam tempo e esforço com contribuições aprimoradas em modelos matemáticos e técnicas de inteligência computacional capazes de atuar na parte decisória de uma organização (KUMAR; JAIN, SINGH, 2020).

No trabalho desenvolvido por Shamayleh, Awad e Farhat (2020) por meio de um estudo de caso realizado em um hospital nos Emirados Árabes Unidos (EAU) é apresentado um modelo de manutenção preditiva (PDM) como diagnóstico de falhas em equipamentos críticos com vários e frequentes modos de falhas.

A pesquisa se baseia no estudo do comportamento e compreensão física da falha, coleta em tempo real dos parâmetros corretos usando os recursos e benefícios da Internet das Coisas (IoT), além das técnicas de Aprendizado de Máquina para prever e classificar o status dos equipamentos com possíveis falhas ou totalmente defeituosos.

Já na pesquisa de Ohta, Salomon, Silva (2020) é apresentada uma aplicação do Processo de Hierarquia Analítica (AHP) na gestão da manutenção de uma planta industrial, para isso foi aplicado o Fuzzy AHP (FAHP) evitando a situação de incertezas quanto as variáveis analisadas no contexto do AHP Clássico, além disso é apresentado outros modelos baseados no FAHP, sendo: conjuntos fuzzy hesitantes e conjuntos fuzzy intuicionistas, as aplicações do Hesitant FAHP (HFAHP) e do Intuitionistic FAHP (IFAHP) são a inovação do seu trabalho.

De acordo com Marquez *et. al.* (2020) as IAMP ou Plataformas de Gestão de Ativos Inteligentes são definidas como plataformas de software para gerenciamento dos dados de

ativos industriais que são baseados na integração com tecnologias industriais (MARQUEZ *et. al.*, 2020). Por ser uma área em constante desenvolvimento e crescimento o autor afirma que que os IAMPs também devem apoiar sistemas de gerenciamento inteligentes de forma equilibrada no ponto de vista estratégico da empresa para os ativos da empresa na gestão da manutenção.

Com isso a primeira etapa da pesquisa se baseia na discussão dos fatores que implicam e justificam o crescimento dos IAMP, no segundo momento é evidenciado e explicado a importância desses aspectos gerenciais para investimentos e transformações digitais por meio do uso de tecnologias.

Para isso, um estudo de caso foi realizado no setor de energia com o intuito de mapear ou identificar os módulos de plataforma e aplicativos que fornecem recursos de valor agregado importante, além do desenvolvimento de uma metodologia para o processo de análise da criticidade dos ativos.

Conforme Zonta *et. al.* (2020) aborda em sua pesquisa a capacidade de prever a necessidade de manutenção de ativos em diferentes momentos do uso de equipamentos é um dos principais desafios no âmbito da indústria 4.0 e na gestão da manutenção. Dessa forma a sua pesquisa apresenta uma revisão sistemática da literatura de iniciativas de manutenção preditiva na Indústria 4.0, identificação e classificação de métodos, padrões e aplicações, abordando os principais desafios e limitações da manutenção preditiva.

O autor conclui enfatizando que a Ciência da Computação em conjunto com as áreas da Inteligência Artificial/Computacional e os demais campos da engenharia e ciência de dados se torna mais presente nas indústrias e destaca a importância de uma abordagem multidisciplinar para atender as necessidades de implantação de um modelo de fabricação inteligente.

Já no trabalho de Izquierdo *et. al.* (2020) a demanda por energia proveniente de fontes renováveis aumenta e tende a um mercado maior para o desenvolvimento de tecnologias que inferem no aumento e rentabilidade de projetos da natureza, fato que potencializa a busca por investidores. A pesquisa visa reduzir custos e diminuir o Custo Nivelado de Energia através de uma política de manutenção oportunista baseada em estimativas de confiabilidade de aerogeradores.

A confiabilidade que é o indicador principal da pesquisa é alcançada por meio do uso da técnica de predição e classificação Redes Neurais Artificiais para calcular dinamicamente o

impacto das condições operacionais nas falhas de aero geradores, a abordagem foi validada por meio de um estudo de caso.

De acordo com Ramirez e Marquez (2020) a gestão da manutenção fotovoltaica exige o aumento da confiabilidade e redução de custos operacionais, mas o uso de métodos e técnicas trazem eficientes resultados principalmente quando analisados em grandes áreas, porém em casos em que a primeira análise consiste no processamento de imagens se torna necessário o uso de algoritmos eficientes para identificação de falhas e a importância da falha. Para isso, o autor apresenta um sistema robusto para decisão e gerenciamento de manutenção fotovoltaica que se baseia no processamento de imagens e detecção de falhas de forma inteligente, logo foi realizado um estudo de caso em uma usina solar.

Para Goksu e Erginer (2020) as práticas de manutenção são consideradas como meio de proporcionar segurança e proteção ao meio ambiente e serviço de qualidade. Em sua pesquisa é fornecido um recurso para um software de manutenção preditiva que realiza análises das condições futuras dos principais sistemas de motores, sendo este modelo desenvolvido com a técnica de Redes Neurais Artificiais com base na condição e conseqüentemente a identificação de falhas potenciais registrados pelo histórico de falhas.

Outro ótimo exemplo é explanado por Jiménez *et. al.* (2020) ao desenvolver um modelo de gerenciamento de manutenção baseado em aprendizado de máquina e recursos não lineares em turbinas eólicas, um dos problemas comuns relacionados a temática é a delaminação o que leva a conseqüências parciais ou totais na estrutura do material como a ruptura em áreas de concentração de tensão.

O modelo visa classificar a delaminação caracterizando um sistema de monitoramento de confiabilidade em pás de turbinas eólicas, além disso é utilizado um modelo autoregressivo não linear com entrada exógena (NARX) este que é encarregado de realizar a extração de recursos para o processo de classificação e normalização dos dados.

Além disso, a pesquisa é caracterizada como estudo de caso considerando diferentes níveis de delaminação, os sinais obtidos são filtrados e transformados pela técnica de *Wavelet* em seguida passado ao NARX para caracterizar os sinais filtrados, outro detalhe importante a ser ressaltado é uso de métodos de aprendizado de máquina supervisionado como: árvores de decisão, análise discriminante, máquinas de vetor de suporte quadrático, vizinhos mais próximos e classificação de conjunto como fator de inovação ao realizar análises comparativas de resultados.

2.2 GESTÃO DA MANUTENÇÃO

As práticas de manutenção para realizar reparos em máquinas e/ou sistemas são frequentemente utilizadas em diversas áreas do setor industrial, comercial e empresas que usufruem de máquinas como elemento de trabalho. Essas práticas são classificadas de acordo com o tipo de manutenção, sendo elas: Corretiva, Preventiva, Preditiva, Controlada ou Preditiva, Programada, Não-Programada, Campo, Fora do Local de Utilização, Remota, Automática e Deferida (ABNT, 1994).

Contudo, para se conseguir um equilíbrio de desempenho nos determinados tipos de manutenção é necessário trabalhar com os indicadores de Desempenho que fornecem valores resultantes de modelos matemáticos que visam minimizar ou maximizar processos ou falhas. Segundo Garcia *et. al.* (2020) dentre esses indicadores se tem: MTTR, MTBF, MTTF, Disponibilidade, Confiabilidade, Custo de Manutenção, Backlog, Fator de Produtividade e HH (Homem Hora) empregado por tipo de manutenção.

Para Loyarte-lópez *et. al.* (2020) com a existência ou implantação de um sistema de indicadores em uma organização a efetividade da gestão e de seus resultados se tornam maiores e controlados, além disso, um balanceamento de seus resultados por meio de uma medição estruturada e planejada levam as organizações a realizarem intervenções calculadas e confiáveis, almejando redução de custos nos processos ao elevar a disponibilidade de seus ativos e agregar valor do produto, trazendo o conceito da Gestão da Manutenção 4.0.

Dessa forma a implantação de Programas de Gestão da Manutenção se tornam uma oportunidade chave de melhoria nos processos e principalmente na qualidade do serviço, os requisitos essenciais para um monitoramento de sucesso incluem modelos e métodos dos diferentes tipos de manutenção que contemplem o uso de indicadores que permitem de forma analítica mensurar o grau de desempenho ou performance pertinente ao equipamento que está sendo analisado, além disso o uso de implementações ou sistemas computacionais inteligentes são outras opções para garantir uma acuracidade maior nas análises.

2.2.1 Manutenção Preditiva

Também conhecida como manutenção sob condição ou manutenção com base no estado do equipamento, é baseada em métodos de prospecção ou previsão de um futuro estado do equipamento ou sistema por meio de um histórico de dados e técnicas para analisar a tendência de variáveis (KRISHNAVENI *et. al.*, 2020; SELWYN e HEMALATHA, 2020).

Dentre os objetivos da manutenção preditiva se destacam:

- Determinar antecipadamente a necessidade de serviços de manutenção em um equipamento;
- Eliminar desmontagens desnecessárias para inspeção;
- Aumentar o tempo de disponibilidade das máquinas;
- Reduzir as intervenções de corretiva;
- Impedir o aumento de danos;
- Aproveitar a vida útil total dos componentes;
- Aumentar o grau de confiabilidade das máquinas;

Para isso, alguns métodos são necessários, técnicas e procedimentos de verificação e análise de variáveis no que tange o estado técnico da máquina levando em consideração a condição real do equipamento por meio da coleta de dados (LUO *et. al.*, 2020; AYVAZ e ALPAY, 2021; TIAN, LIU e SHU, 2021), dentre os métodos utilizados se destacam:

- Análise de vibração;
- Termografia;
- Análise de óleo;
- Ultrasson

Estes são processos que visam o tempo de vida útil dos componentes das máquinas, assim como as condições operacionais para se obter o melhor aproveitamento.

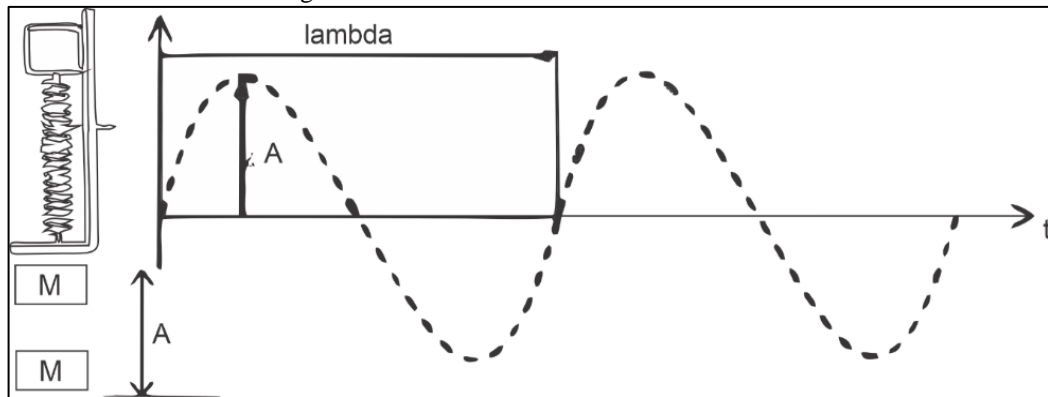
2.2.2 Análise de vibração

Para entender os procedimentos de análise da vibração em máquinas de combustão interna é necessário que se tenha uma prévia sobre vibração e os tipos de vibração, mesmo com a possibilidade de se realizar a análise do fenômeno diretamente na simulação computacional (MARTINS, 2017; TIAN, LIU e SHU, 2021).

Entende-se como vibração o movimento de uma partícula de um corpo ou sistema de corpos conectados, qualquer movimento que se repete de forma regular ou irregular em um dado intervalo de tempo (TEOH *et. al.*, 2020). O movimento pode se repetir regularmente, como por exemplo um pêndulo que tem diferentes valores de energia cinética e energia potencial ao longo de sua trajetória, dessa forma o mais conhecido dos tipos de movimento

periódico é chamado de harmônico (MARTINS, 2017). A Figura 2.1 ilustra um exemplo de movimento harmônico.

Figura 2.1 - Modelo de movimento harmônico.



Fonte: Adaptado de MASRI, CAFFREY (2021); MARTINS (2017).

A massa M relacionada ao pêndulo em sua extremidade superior por uma mola com determinada força k, mediante a uma determinada distância X_0 exerce uma relação de equilíbrio observando o movimento de subir e descer, esse movimento resulta em um gráfico senoidal de Amplitude que é um valor medido do nível zero até o pico do sinal e tempo que é o tempo de execução de um ciclo completo do sinal em segundos (MASRI, CAFFREY, 2021; MARTINS, 2017). Para tal movimento que pode ser expresso pela Eq. (2.1):

$$x(t) = A \cdot \cos \omega t = A \cdot \cos 2\pi \frac{t}{\lambda} \quad (2.1)$$

Onde:

$x(t)$ = deslocamento da massa no sistema vibratório;

A = amplitude de oscilação;

M = massa observada no sistema;

λ = período;

ω = frequência angular

Para qualquer movimento periódico não amortecido relacionado à harmônica satisfaz a Eq. (2.2):

$$x(t) = x(t + \lambda) \quad (2.2)$$

O período pode ser calculado por meio da Eq. (2.3):

$$\lambda = \frac{2\pi}{\omega} \left[\frac{s}{\text{ciclo}} \right] \quad (2.3)$$

Já a frequência pode ser expressa pela Eq. (2.4):

$$f = \frac{1}{\lambda} = \frac{\omega}{2\pi} \left[\frac{\text{ciclos}}{s} \right], \text{ ou } [Hz] \quad (2.4)$$

A caracterização do movimento harmônico se dá pelo fato de que a aceleração x da partícula com movimento linear é sempre proporcional ao deslocamento em relação a um ponto fixo na trajetória sendo direcionada ao ponto fixo (MARTINS, 2017; TEOH *et. al.*, 2020).

Se $x(t)$ é uma função periódica com período λ , sua representação em séries de Fourier é dada pela Eq. (2.5):

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cos n\omega t + b_n \sen n\omega t) \quad (2.5)$$

Onde:

$\omega = 2\pi/\lambda$ é a frequência natural;

$a_0, a_1, \dots, a_n, b_1, \dots, b_n$ são coeficientes constantes;

Os coeficientes constantes $a_0, a_1, \dots, a_n, b_1, \dots, b_n$ podem ser expressos pelas Eq. (2.6), (2.7) e (2.8):

$$a_0 = \frac{2}{\lambda} \int_0^{\lambda} x(t) dt \quad (2.6)$$

$$a_n = \frac{2}{\lambda} \int_0^{\lambda} x(t) \cos n\omega t dt \quad (2.7)$$

$$b_n = \frac{2}{\lambda} \int_0^{\lambda} x(t) \sen n\omega t dt \quad (2.8)$$

A forma exponencial de $x(t)$ é dada pela Eq. (2.9):


$$x(t) = \sum_{n=-\infty}^{\infty} c_n e^{in\omega t} dt \quad (2.9)$$

O coeficiente determinado como c_n pode ser expresso pela Eq. (2.10):

$$c_n = \frac{1}{\lambda} \int_0^{\lambda} x(t) e^{-in\omega t} dt \quad (2.10)$$

Por meio desse modelo e com os resultados é possível desenvolver um espectro de frequências que auxilia na representação e comportamento do sistema que estará sujeito à oscilações. Através de análises de máquinas excitadas pelos esforços dinâmicos, captadores de vibrações em pontos definidos na máquina ocorre a captação dos registros de vibração (FONSECA-JUNIOR *et. al.*, 2015). A Figura 2.2 ilustra um exemplo de assinatura espectral

Figura 2.2 - Assinatura Espectral.



Fonte: Adaptado de MORO (2020).

Os pontos de pico das elevações da Figura 2 representam as ordens harmônicas, onde a primeira é caracterizada como natural, e as demais como segunda ordem, as menores são identificadas como ruídos espalhados no espectro, como pode ser visto no intervalo de 0 a 100 como frequência em Hz e uma amplitude de 0 a 8 para a média quadrática.

A simulação computacional se torna uma opção viável para analisar vibrações, tendo em vista que se o analisador possuir conhecimento necessário para entendimento dos resultados, estes obtidos por meio de um software, é possível adquirir uma solução que possa ser implantada no sistema sem desperdício de mão de obra e matéria prima para a simulação de um equipamento sujeito a falhas, que poderiam ser evitadas caso houvesse as alterações necessárias (MORO, 2020; HELLER, SEVER e SCHWINGSHACKL, 2020).

2.2.3 Termografia


Esse método tem como base a detecção da radiação infravermelho emitida naturalmente por corpos com proporcionalidade de temperatura à intensidade emitida do equipamento, com isso, é possível identificar regiões ou pontos onde a temperatura está alterada e obter informações acerca do estado da máquina (MEIßNER *et. al.*, 2021; LUGHOFER e SAYED-MOUCHAWEH, 2019; FONSECA-JUNIOR *et. al.*, 2015).

A termografia integra um método preditivo no qual é possível detectar o surgimento de defeitos desde suas etapas iniciais agregando qualidade ao processo de manutenção, dessa forma torna-se uma oportunidade de diferenciação da concorrência e aumento da competitividade.

Uma análise bem-sucedida no ensaio termográfico deve ser feita em condições atmosféricas ambientais mais próximas do ideal possível, deve ser tomado as devidas precauções em relação aos equipamentos que serão estudados, por exemplo transformadores, compressores, grupos geradores, sendo feito a termografia durante os ciclos de trabalho (DINARDI, DA COSTA e TORNÉ, 2020; DA SILVA, 2020).

A termografia de infravermelho é considerada um método de análise não destrutiva, pelo fato de não induzir alterações nas propriedades físicas, químicas, mecânicas ou dimensionais do objeto analisado.

Sendo assim fruto do calor liberado como radiação eletromagnética que podem ser detectados por dispositivos ou seres que reagem a ele. A Figura 2.3 ilustra um exemplo de espectro com todas as frequências.



Fonte: GONÇALVES *et. al.* (2011).

2.2.4 Análise de óleo

É uma técnica que monitora as condições do óleo e do equipamento, através de métodos laboratoriais para identificar falhas, contaminação e degradação do óleo. A lubrificação é responsável por acrescentar maior confiabilidade no equipamento quando realizada corretamente, portanto são necessárias medidas para prevenir e controlar os contaminantes presentes no óleo (PIRES e OKADA, 2020).

Segundo o autor através desse estudo é possível tomar medidas como filtrar ou substituir o óleo em casos de contaminações severas, nem sempre a contaminação é causada por fenômenos naturais, quando há o desgaste do equipamento geram-se partículas provenientes

dos materiais utilizados na sua produção, dessa forma pela análise de óleo é possível identificar essas partículas (DALL AGNESE, 2020). O método de constatação do teor de água no óleo lubrificante é uma das análises mais importantes, principalmente em se tratando de motores de combustão interna.

2.2.5 Ultrassom

É uma técnica aplicada para detecção de anomalias em subestações, linhas de transmissão, descarga parcial, arco elétrico e muitas outras aplicações, seu funcionamento se dá através dos ruídos gerados pelas máquinas e equipamentos em funcionamento (AWANG *et. al.*, 2020). Com a alta frequência da máquina em funcionamento ocorre esse processo, tal ruído é imperceptível ao ouvido humano, ou seja, o ultrassom manutenção preditiva é capaz de detectar a descontinuidade em sua fase inicial, possibilitando a correção antes que se torne um problema real (GONÇALVEZ *et. al.*, 2020).

As ondas acústicas ou o som propriamente dito são classificados de acordo com suas frequências e medidos em ciclos por segundo, ou seja, o número de ondas que passam por segundo pelo sistema auditivo. A unidade ciclos por segundos, é normalmente conhecida por Hertz de abreviatura Hz (AWANG *et. al.*, 2020).

A detecção de ruído ultrassônico é uma boa técnica preditiva a ser utilizada na manutenção de equipamentos, fato que, os ruídos normais provenientes dos seus principais componentes, tais como motores elétricos, bombas, compressores e turbinas emitem ruído ultrassônico, tais como efeito corona, pontos de vazamento e rolamento mal lubrificadas (GIRIT, ATAKOK e ERSOY, 2020).

2.2.6 Indicador Chave de Performance Confiabilidade

De acordo com a NBR 5462, confiabilidade é a possibilidade de um item, equipamento, máquina ou sistema desempenhar sua função em determinado período de tempo dentro de um projeto, o que se espera com o método é analisar o grau de confiança dos equipamentos e com isso determinar métricas de uso ou técnicas de manutenção que atuem na melhoria contínua do equipamento (LU *et. al.*, 2021).

Essa medição é comumente feita com base em um histórico de desempenho dos equipamentos e sua estimativa de funcionamento futuro, com isso se pode mensurar: Aumento

de vida útil das máquinas, redução de custos de manutenção, melhoria no desempenho operacional, agilidade e consistência das equipes técnicas (ZOU *et. al.*, 2021; LUGHOFER e SAYED-MOUCHAWEH, 2019). O parâmetro de confiabilidade a ser calculado a partir dessa observação de históricos pode ser expressa pela Eq. (2.11):

$$\lambda_i^x = \frac{N_{fi}}{t_i^x \cdot n} \quad (2.11)$$

Onde N_{fi} é o número de falhas antes do i -ésimo ponto de falha, t_i^x é o tempo de falha do i th ponto de falha para o subsistema x , e n é o número de falhas do subsistema (BAI *et. al.*, 2020). A taxa de falha de cada ponto de falha do subsistema x pode ser expressa pela Eq. (2.12):

$$\lambda^x = [\lambda_1^x, \lambda_2^x, \lambda_3^x \dots \lambda_i^x, \dots \lambda_{n-1}^x, \lambda_n^x]^t \quad (2.12)$$

Para Bai *et. al.* (2020) em relação as técnicas de investigação de falhas uma das mais utilizadas é a curva da banheira, na qual é possível analisar o tempo de vida útil de um equipamento, uma série de funções de base radial combinatória para RBF são usados para aproximar funções de cálculo complexas ou difíceis, sendo expressa pela Eq. (2.13).

$$\hat{y}(x) = \sum_{i=1}^n \beta_i f(\|x - x_i\|) = f(x)^T \beta \quad (2.13)$$

Onde $\hat{y}(x)$ é o vetor de resposta de previsão, x, β é o vetor de coeficientes de base radial β_i é o i -ésimo componente β , $f(x)$ é o vetor RBF $f(\|x - x_i\|)$ é o i -ésimo componente de $f(x)$, $r = \|x - x_i\|$ é a distância euclidiana entre dois vetores (LUGHOFER e SAYED-MOUCHAWEH, 2019; BAI *et. al.*, 2020). A mesma equação pode ser reescrita para a equação de taxa de falhas sendo expressa pela Eq. (2.14):

$$\hat{\lambda}^x(t) = \sum_{i=1}^n \beta_i f(\|x - x_i\|) = f(x)^T \beta \quad (2.14)$$

Onde $\hat{\lambda}^x(t)$ é a taxa de falhas do subsistema x no tempo t . A confiabilidade da unidade é definida como a sua probabilidade acumulada de sucesso, sendo assim a função de confiabilidade $R(t)$ é dado pela Eq. (2.15):

$$R(t) = \frac{n_s(t)}{n_s(t) + n_f(t)} = \frac{n_s(t)}{n_0} \quad (2.15)$$

A função de distribuição $F(t)$ é o complemento de $R(t)$, sendo expressa pela Eq. (2.16):

$$R(t) = 1 - F(t) = 1 - \int_0^t f(u)du = \int_t^{+\infty} f(u)du \quad (2.16)$$

Dessa forma a função de confiabilidade indica a probabilidade de um item/equipamento apresentar sucesso em seu funcionamento caracterizado pela ausência de falhas em um intervalo de tempo (LUGHOFER e SAYED-MOUCHAWEH, 2019; BAI *et. al.*, 2020). Para mensurar a confiabilidade por meio de cálculos probabilísticos é necessário projetar um cenário futuro., contudo se deve ter o levantamento de tempo médio entre falhas dos equipamentos, taxa de falhas dos equipamentos e saber previamente o que será projetado para o cálculo da confiabilidade, nesse caso a quantidade de dias de projeção (SOLTANALI *et. al.*, 2021).

2.3 REDES NEURAIAS ARTIFICIAIS (RNA)

A seguir são apresentados os tópicos fundamentais para o conhecimento das Técnicas de Redes Neurais Artificiais, explanando elementos como: arquiteturas, topologias, aplicabilidade, modos de aprendizado, funções de ativação e algoritmos de treinamento.

2.3.1 Arquiteturas de RNA

As Redes Neurais Artificiais são técnicas computacionais que objetivam prever eventos, reconhecer ou classificar padrões, possuem arquiteturas e topologias, além disso são inspirados na estrutura neural de organismos inteligentes e com os ajustes necessários em seus pesos é possível adquirir conhecimento (ZHANG, MA e XU, 2021).

Seu funcionamento é simples cada unidade é conectada por canais de comunicação, a unidade é responsável por realizar operações sobre dados passados como entrada (SUGANTHAN e KATUWAL, 2021). Como resultado, as redes neurais podem melhorar processos de decisão em diversas áreas como:

- Detecção de fraudes em cartões de crédito e assistência médica;
- Otimização de logística para redes de transporte;
- Reconhecimento de padrões de voz e caracteres;
- Marketing direcionado;
- Predições financeiras;
- Classificação de dados;
- Visão computacional para identificação de fotos.

Cada modelo de RNA possui características e finalidades conforme comentado, é válido ressaltar que a utilização desses modelos depende da arquitetura e o processo de aprendizado que deve ser balanceado com um algoritmo de treinamento, Canário *et. al.* (2020) comenta sobre algumas arquiteturas:

- **Redes Neurais Convolucionais:** comumente utilizada em situações de classificação, predição de imagens e detecção de objetos, é válido ressaltar que cada camada é conectada por meio de conexões e ativação;
- **Redes Neurais Recorrentes:** comumente utilizadas em situações de previsão e aplicação de séries temporais, tendo como principal característica informações sequenciais com dados de registro de data e hora;
- **Redes Neurais Feedforward:** modelo simples de RNA onde a informação é passada entre as camadas de forma linear, composto por perceptrons que se conectam e trocam informação;
- **Redes Neurais Autoencoder:** Apesar de similares às redes neurais mais tradicionais, autoencoders procuram modelar as entradas por si só, é um método considerado não supervisionado.
- **Redes Neurais de Hopfield:** Os neurônios são conectados entre si, possuem todas as funções das camadas de uma rede neural, funcionando como entrada no início, camada escondida durante o treinamento, e saída ao final. A rede é treinada para que haja uma conversão para um estado estável de interesse.

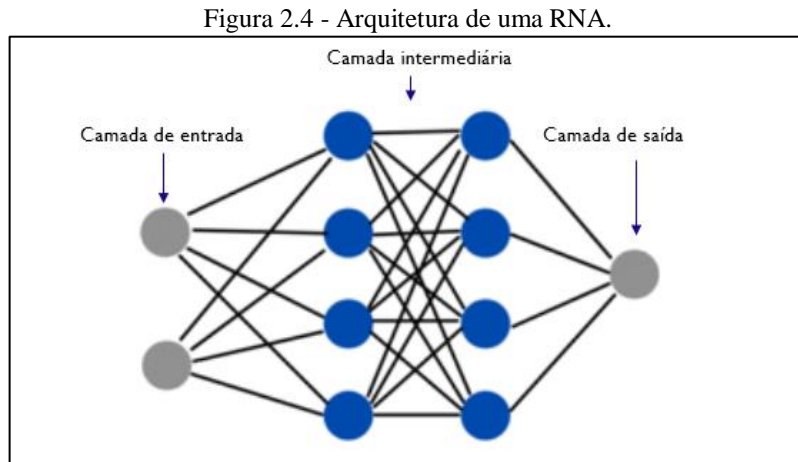
Tendo em vista algumas das arquiteturas de RNA, deve-se conhecer um modelo de neurônio artificial, uma rede neural utiliza camadas onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados (RAMANUJAN *et. al.*, 2020), sendo classificadas da seguinte forma:

- **Camada de entrada:** onde os padrões são apresentados à rede;
- **Camada intermediária:** onde os pesos são ajustados e ocorre a maior parte do processamento considerando o algoritmo de treinamento e modelo matemático utilizado;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

As funções de ativação são artifícios importantíssimos para um modelo de rede neural, tendo em vista que elas são responsáveis por decidir se um neurônio é ativado ou não, ou seja, se a informação que o neurônio está recebendo é relevante para a informação fornecida ou deve ser ignorada. Tais procedimentos manifestação ações de propagação dos dados para camadas

posteriores, desde que os gradientes sejam fornecidos juntamente com o erro para atualizar os pesos e bias.

A Figura 2.4 ilustra um exemplo de uma arquitetura de rede neural com camadas de entrada, ocultas e de saída, onde cada camada se comunica com as próximas camadas por meio de seus neurônios, que levam valores de entrada para as camadas ocultas que possuem a missão de realizar processamento desses dados e enviar para a camada de saída.



Fonte: Adaptado de RAMANUJAN *et. al.* (2020).

De acordo com Suganthan e Katuwal (2021) basicamente o sinal de um neurônio x da camada de entrada, de uma célula (y), em um dado tempo (t), recebido por um neurônio (n) da camada intermediária, pode ser expresso conforme a Eq. (2.17).

$$net_n(y, t) = \sum_n W_{x.n} S'_x(y, t) \quad (2.17)$$

Onde:

$S'_x(y, t)$ = atributos da célula dados pela variável (neurônio) (x);

$W_{x.n}$ = pesos das entradas do neurônio (x) ao neurônio (n);

A relação entre as redes neurais artificiais e as biológicas é diretamente ligada pela forma como se comunicam através de sinapses que podem ser representados matematicamente (BAU *et. al.*, 2020).

2.3.2 Aprendizado de uma RNA

Um fator importantíssimo a ser ressaltado para uma rede neural é o processo de aprendizado que depende da forma como se relaciona ao ambiente, pensando nessa perspectiva alguns paradigmas de aprendizado são levados em consideração:

- **Aprendizado supervisionado:** com a ajuda de um agente externo a rede aprende o padrão desejado;
- **Aprendizado não-supervisionado:** é uma forma de auto-organização, quando não há um agente externo para inferir no processo de aprendizado;
- **Reforço:** quando um avaliador externo analisa ou define a resposta fornecida pela rede.

O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Dentre as formas de uma rede neural aprender há aqueles que consistem em: correção de erros, competição, modelos hebbiano e máquinas de aprendizado (BULAGHI *et. al.*, 2020).


Contudo, apenas isso não é o suficiente para se ter um o melhor modelo de rede neural, isso se dá pelas diversas aplicações não-lineares, as funções de ativação fazem isso intuitivamente criando modelos de aprendizado que relacionam variáveis dependentes e independentes. Alguns exemplos de função de ativação são apresentados na Tabela 2.1:

Sigmoide: caracterizada com uma curva em S na representação gráfica, é utilizada no processo de mapeamento de valores previstos para probabilidades, capaz de mapear qualquer valor real entre 0 e 1 (RIZZO e CANATO, 2020; KOÇAK E ÜSTÜNDAĞ ŞIRAY, 2021). Expressa pela Eq. (2.18).

$$\sigma = \frac{1}{1 + e^x} \quad (2.18)$$

Onde a derivada da função é dada por $f'(x) = \sigma * (1 - \sigma)$. A Figura 2.5 ilustra um exemplo gráfico da função Sigmoide considerando um intervalo entre 0 e 1.

Figura 2.5 - Gráfico da função Sigmoide.




Fonte: Adaptado de RIZZO e CANATO (2020).

Tangente hiperbólica (TanH): com um formato gráfico similar à Sigmoide por possuir também um formato em S, é uma alternativa para ativar as camadas ocultas de uma rede neural, obtido pela razão entre o seno hiperbólico e o cosseno hiperbólico (RIZZO e CANATO, 2020), sendo expresso pela Eq. (2.19).

$$\tan H(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.19)$$

Onde a derivada da função é dada por $1 - a^2$ em um intervalo de -1 a 1. A Figura 2.6 ilustra um exemplo gráfico da função Tangente hiperbólica considerando o intervalo citado anteriormente.

Figura 2.6 - Gráfico da função Tangente hiperbólica.




Fonte: Adaptado de RIZZO e CANATO (2020).

Unidade Linear Retificada (ReLU): É uma função inspirada no modelo biológico de neurônio, o mesmo tem a possibilidade de retornar um valor positivo ou negativo, em redes neurais convolucionais ou recorrentes essa função obtém resultados satisfatórios na ativação dos neurônios artificiais. A Eq. (2.20) expressa o modelo da função ReLU.

$$ReLU(x) = \max\{0, x\}, \text{ sendo } \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{c. c} \end{cases} \quad (2.20)$$

De forma geral, a derivada não é definida em 0, mas é possível implementá-la com valor 0 ou 1, normalmente assumem comportamentos estáveis, sendo 1 quando $x > 0$ e 0 quando $x < 0$. Este modelo de função de transferência se torna mais eficiente em relação a outros, sendo esta uma das descobertas recentes que contribuem ativamente para o conceito de *Deep Learning*.

Uma das desvantagens da ReLU é que as unidades tendem a morrer no decorrer das épocas de um processo de treinamento da rede neural, caracterizado pela instabilidade dos neurônios em produzir apenas zeros, fato consequente da soma negativa antes da aplicação da ReLU. A Figura 2.7 ilustra um exemplo gráfico da função ReLU.



Fonte: Adaptado de RIZZO e CANATO (2020).

Para saber se uma rede neural está apta no treinamento existem quatro métodos conhecidos na literatura como critérios de parada, são eles: número de ciclos, erro, combinação dos métodos anteriores ou validação do melhor modelo (Koçak e Üstündağ Şiray, 2021; ARABI BULAGHI *et. al.*, 2020).

Dependendo da quantidade de iterações que foi definida para uma rede neural a combinação desses métodos pode reduzir o tempo de predição ou aumentar se não utilizado da maneira correta.

2.3.3 Algoritmos de treinamento

O problema da etapa de treinamento de redes neurais é solucionado por meio de um método de controle, dentre o maior fator de impacto para se alcançar o erro mínimo é a explosão do gradiente (SOUZA *et. al.*, 2021; Koçak e Üstündağ Şiray, 2021) pela necessidade de números exaustivos de iterações para o modelo encontrar o melhor padrão da região do conjunto avaliado, a sua complexidade ainda torna necessário o uso de métodos heurísticos na determinação do melhor desempenho da rede para um determinado treinamento.

Em suma uma rede neural possui pesos que são inicializados, recebendo valores aleatório, muitas vezes multiplicados pelos pesos de outras camadas até atingir um valor desejado para o

estado do treinamento (SOUZA *et. al.*, 2021; BULAGHI *et. al.*, 2020), partindo desse princípio os algoritmos de aprendizado na etapa de treinamento se tornam importantes no sentido de aplicar métodos iterativos, heurísticos ou matemáticos para diminuir o custo computacional e a capacidade de regular a função alvo a um estado real aproximado.

Levenberg-Marquardt: também conhecido como método dos mínimos quadrados amortecidos (DLS) é fundamental da solução de problemas de quadrados mínimos não lineares, ou seja, trabalha diretamente no ajuste de curva pelo método dos mínimos quadrados, contudo, este algoritmo não encontra um mínimo global (DE RUBIO, 2020).

O LMA interpola entre o algoritmo de *Gauss-Newton* (GNA) e o método do Gradiente Descendente, sendo mais robusto que os citados, outro detalhe é o tempo de convergência do LMA que é melhor em relação ao de um Algoritmo Genético (AG) (BILSKI *et. al.*, 2020).

O método consiste no ajuste de curva, onde dado um conjunto m de pares empíricos (x_i, y_i) de variáveis independentes e dependentes, encontra os parâmetros β da curva do modelo $f(x, \beta)$ de modo que a soma dos quadrados dos desvios $S(\beta)$ seja minimizado (KUMAR e JAYANTHY, 2020), sendo expresso pela Eq. (2.21).

$$\beta \in \operatorname{argmin}_{\beta} S(\beta) \equiv \operatorname{argmin}_{\beta} \sum_{i=1}^m [y_i - f(x_i, \beta)]^2 \quad (2.21)$$

Assim como outros algoritmos o LMA se caracteriza por procedimentos iterativos, em cada etapa de iteração, o vetor de parâmetro β é substituído por uma nova estimativa $\beta + \delta$, para determinar δ , a função $f(x_i, \beta + \delta)$ é aproximada por uma linearização (KUMAR e JAYANTHY, 2020), expressa pela Eq. (2.22).

$$f(x_i, \beta + \delta) \approx f(x_i, \beta) + J_i \delta \quad (2.22)$$

Onde:

$J_i = \frac{\partial f(x_i, \beta)}{\partial \beta}$, sendo este o gradiente do vetor linha de f em relação à β .

Bayesian Regularization: A regularização desempenha um papel no aprimoramento do processo de generalização, limitando uma medida do peso de uma rede. Se o valor do peso da rede for menor, a rede responderá de forma sutil. Com a regularização, uma grande rede que fica simplificada deve ser capaz de representar a função real (RAHMAN, DARMAWIDJADJA e ALAMSAH, 2017).

Um algoritmo de retro propagação clássica com métodos de regularização bayesiana (PEPRAH e LARBI, 2020) visa minimizar a função expressa pela Eq. (2.23).

$$F = E_d \quad (2.23)$$

Onde E_d pode ser expresso pela Equação 2.24:

$$E_d = \frac{1}{n} \sum_{i=1}^n (t_i - a_i)^2 \quad (2.24)$$

Onde, n é o número de entradas para o conjunto de treinamento, t_i é o valor alvo para os dados, e um a_i é a saída para os i -ésimo elemento do conjunto obtido como resposta da rede neural (RAHMAN, DARMAWIDJADJA e ALAMSAH, 2017). O método de regularização altera o desempenho de erro da função adicionando um desvio padrão de pesos e vieses, sendo expresso pela Eq. (2.25).

$$F = \beta E_d + \alpha E_w \quad (2.25)$$

Onde α e β são parâmetros de regularização, enquanto E_w pode ser expresso pela Eq. (2.26).

$$E_w = \frac{1}{n} \sum_{i=1}^n (W_i)^2 \quad (2.26)$$

Onde W_i é um peso ou limite, usado para alterar a função de desempenho de erro, dessa forma a rede obtém pesos e limites menores, contudo, o método não define o melhor peso e limite (RAHMAN, DARMAWIDJADJA e ALAMSAH, 2017).

Broyden–Fletcher–Goldfarb–Shanno Quasi - Newton: é um método iterativo para resolver sem restrições problemas não lineares, através do método da matriz Hessiana da função de perda é possível determinar a direção de descida pelo pré-condicionamento do gradiente com informações de curvatura (EGIDIO, HANSSON e WAHLBERG, 2020).

O problema da otimização é minimizar $f(x)$, onde x é um vetor em \mathbb{R}^n , e f é uma função escalar diferenciável, o algoritmo começa com uma estimativa inicial para o valor ideal x_0 e prossegue iterativamente para obter uma estimativa melhor em cada estágio (EGIDIO, HANSSON e WAHLBERG, 2020; UPAKA, 2020). A Solução é dada pela Eq. (2.27).

$$B_k P_k = -\nabla f(x_k) \quad (2.27)$$

Algumas implementações notáveis com *BFGS Quasi-Newton* são: algumas funções do software *Artelys Knitro* para otimização não linear em grande escala (SHI *et. al.*, 2021); Caixa

de ferramentas do MatLab® especificamente a função *fminunc* implementa o BFGS quando o tamanho do problema é definido como escala média (OU *et. al.*, 2020); Função *base optim()* da linguagem R e A função *scipy.optimize.fmin_bfgs* do SciPy (BORHANI, 2020).

Resilient Backpropagation: É um algoritmo de otimização de primeira ordem, leva em consideração o sinal da derivada parcial e atua de forma independente em cada peso, o *Rprop* é um dos mecanismos de atualização de pesos mais rápidos (ERKAYMAZ, 2020; UPAKA, 2020). O viés total entre a produção de uma ANN e os valores observados são definidos como a função de erro, para reduzir essa função de erro em cada iteração, os pesos são modificados automaticamente (LIN, *et. al.*, 2020; MELLAH, HEMSAS e TALEB, 2021), isso é expresso pelas Eq. (2.28) e (2.29).

$$\frac{\partial L}{\partial w_{ij}} = \frac{\partial L}{\partial O_i} \cdot \frac{\partial O_i}{\partial net_i} \cdot \frac{\partial net_i}{\partial w_{ij}} \quad (2.28)$$

$$w_{ij}(t + 1) = w_{ij}(t) - \epsilon \cdot \frac{\partial L}{\partial w_{ij}}(t) \quad (2.29)$$

Onde:

L = função de erro do modelo;

w_{ij} = peso do i -ésimo neurônio ao j -ésimo neurônio;

O_i = saída do modelo;

net_i = é a soma ponderada das entradas do neurônio i

ϵ = taxa de aprendizado;

Para acelerar a convergência da Equação 2.29 o algoritmo trata a atualização de pesos de forma diferente, dependendo da derivada da função de erro, a aprendizagem alternativa maior η^+ pode ser definido para acelerar as iterações se o erro gradiente permanece na mesma direção em intervalos de tempo vizinhos e menor taxa de aprendizagem alternativa η^- ao se aproximar de pesos ideais (MELLAH, HEMSAS e TALEB, 2021).

Scaled Conjugate Gradient: é um algoritmo que utiliza procedimentos iterativos de solução numérica, comumente aplicados em sistemas esparsos com de atas densidades como a decomposição de *Cholesky*, tais procedimentos resolvem problemas de equações diferenciais parciais ou de otimização (FARIZAWANI *et. al.*, 2020).

Para isso o algoritmo denota um palpite inicial para x^* para x_0 , considerando um sistema linear $Az = b - Ax_0$, começa com x_0 , busca-se a solução em cada iteração, neste ponto o algoritmo precisa de uma métrica para identificar se está próximo da solução x^* , esta métrica é

caracterizada como um minimizador exclusivo da função quadrática (UPAKA, 2020; LOH, 2020), expressa pela Eq. (2.30).

$$f(x) = \frac{1}{2}x^T Ax - x^T b \quad (2.30)$$

Onde $x \in \mathbb{R}^n$

A existência de um minimizador único é aparente à medida que a segunda derivada é dada por uma matriz simétrica positiva-definida (AHMED, HAMED e SAEED CHILMERAN, 2020) e expressa pela Eq. (2.31).

$$\nabla^2 f(x) = A \quad (2.31)$$

E que o minimizador ao usar $Df(x)=0$ resolva o problema inicial pela derivada da primeira ordem, expressa pela Eq. (2.32).

$$\nabla f(x) = Ax - b \quad (2.32)$$

Dessa forma, a primeira base vetorial P_0 para ser negativo do gradiente de f em $X = X_0$, começando com o palpite inicial X_0 isso significa que se toma $P_0 = b - Ax_0$, os outros vetores na base serão conjugados ao gradiente (TIWARI e AGRAWAL, 2020), daí o nome de Gradiente Conjugado.

Conjugate Gradient with Powell/Beale Restarts: O CG básico aumenta consideravelmente a complexidade do cálculo por iteração de aprendizagem, uma vez que tem que ser efetuado uma pesquisa de linha em ordem para determinar um tamanho de passo apropriado (UPAKA, 2020). Uma pesquisa de linhas envolve vários cálculos da função de erro global ou sua derivada, o que aumenta a complexidade. O algoritmo *Conjugate Gradient with Powell/Beale Restarts* (SCGBP) evita a pesquisa de linha por iteração de aprendizagem, este que é um procedimento que envolve vários cálculos da função de erro global ou a sua derivada, ao utilizar a abordagem do *Levenberg- Marquardt* com o intuito de dimensionar o tamanho do passo e não conter nenhum parâmetro crítico definido pelo utilizador (SULAIMAN, *et. al.*, 2020).

Tendo em conta a precisão da máquina, o valor de σ deve ser tão pequeno quanto possível ($\leq 10^{-4}$). Então o seu valor não é crítico para o desempenho do algoritmo, ou seja, a cada iteração, há uma chamada de $F(x)$ e duas chamadas de $F(x')$, o que dá a complexidade calculada em $O(7N^2)$, esta complexidade pode ser reduzida para $O(6N^2)$ porque o cálculo de $F(x)$ pode ser incorporado num dos cálculos de $F(x')$. SDBP tem uma complexidade de cálculo $O(3N^2)$ por iteração. Portanto, em comparação com o *Steepest Descent Back-Propagation* (SDBP),

SCGBP envolve o dobro de trabalho de cálculo por iteração. Quando λ_k é zero, SCGBP é igual ao CG básico (SINGLA, DUHAN e SAROHA, 2021). No SCGBP, o erro diminui monotonicamente para zero, que é a característica do SCGBP porque não é permitido um aumento do erro. Em várias iterações, o erro é constante para uma ou duas iterações, nestes casos, a matriz *Hessian* não é definida como positiva e λ_k não aumenta (ANDREI, 2020).

Fletcher-Powell Conjugate Gradient: *Fletcher-Reeves* e *Polak-Ribiere* introduziram duas equações para calcular β_k um escalar positivo, para encontrar o P_0 , vetor de pesquisa neste algoritmo (UPAKA, 2020; YUAN, LU e WANG, 2020; SULAIMAN, *et. al.*, 2020). A Eq. (2.33) apresenta o método β_k de *Fletcher-Reeves* enquanto a Eq. (2.34) o apresenta para o método de *Polak-Ribiere*.

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad (2.33)$$

$$\beta_k = \frac{g_k^T g_k}{\Delta g_{k-1}^T g_{k-1}} \quad (2.34)$$

Onde:

β_k é a razão entre a Norma quadrática do gradiente atual e a Norma quadrática do gradiente anterior e como resultante se tem um escalar positivo.

Polak-Ribière Conjugate Gradient: Este algoritmo procura o valor negativo do gradiente da rede desde a primeira iteração com base na direção de conjugação (YUAN, LU e WANG, 2020). Com uma função quadrática pura, o mínimo é alcançado dentro das iterações N (exceto erro de arredondamento), a redefinição de cada iteração transforma o método em descida mais íngreme, o algoritmo para quando encontra o mínimo determinado, quando nenhum progresso é feito após um reset de direção ou quando algum critério de tolerância é alcançado (SULAIMAN, *et. al.*, 2020).

Quatro das fórmulas mais conhecidas para β_k são nomeadas em homenagem a seus desenvolvedores (YUAN, LU e WANG, 2020), respectivamente *Fletcher-Reeves*, *Polak-Ribière*, *Hestenes-Stiefel* e *Dai-Yuan* expressas pelas Eq. (2.35), (2.36), (2.37) e (2.38).

$$\beta_k = \frac{\Delta g_k^T \Delta g_k}{\Delta g_{k-1}^T \Delta g_{k-1}} \quad (2.35)$$

$$\beta_k^{PR} = \frac{\Delta g_k^T (\Delta g_k - \Delta g_{k-1})}{\Delta g_{k-1}^T \Delta g_{k-1}} \quad (2.36)$$

$$\beta_k^{HS} = \frac{\Delta g_k^T (\Delta g_k - \Delta g_{k-1})}{-g_{k-1}^T (\Delta g_k - \Delta g_{k-1})} \quad (2.37)$$

$$\beta_k^{DY} = \frac{\Delta g_k^T \Delta g_k}{-g_{k-1}^T (\Delta g_k - \Delta g_{k-1})} \quad (2.38)$$

One Step Secant: é um algoritmo que se baseia no método de Newton, ou seja, utiliza a expansão da série de *Taylor* de segunda ordem (SINGLA, DUHAN e SAROHA, 2021). É considerado como um algoritmo alternativo ao método do gradiente conjugado, frequentemente utilizado para otimização rápida da convergência do estado da rede. Para uma função $f(x)$, a série de $f(x)$ de *Taylor* em torno de x_k pode ser expressa pela Eq. (2.36).

$$f(x_k + \Delta x) \approx f(x_k) + \nabla f(x_k)^T \Delta x + \frac{1}{2} \Delta x^T A \Delta x \quad (2.36)$$

Onde:

A = é uma aproximação da matriz *Hessiana*.

O gradiente desta aproximação é expresso pela Eq. (2.37).

$$\nabla f(x_k + \Delta x) \approx \nabla f(x_k) + A \Delta x \quad (2.37)$$

O algoritmo de Newton é observado para alcançar uma convergência mais rápida em relação aos métodos de gradiente de conjugação (SINGLA, DUHAN e SAROHA, 2021). No entanto, é complexo, e o custo do cálculo da matriz *Hessiana* por iteração é cara, especialmente no caso de uma rede neural *feedforward*.

CAPÍTULO 3

3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais que foram utilizados para a realização da pesquisa considerando a contextualização do que se pretende alcançar para resolver a problemática, e os métodos para se chegar no objetivo geral que é desenvolver um modelo computacional para previsão do KPI Confiabilidade focado em Máquinas de Combustão Interna.

3.1 MATERIAIS

3.1.1 Documentos de manutenção

Por meio de documentos de registros de manutenção e falhas ocorridos nos anos de 2018 e 2019 foi possível realizar uma análise apurada acerca das informações e adaptá-los em estruturas de dados úteis para processamento, estes que foram adquiridos por especialistas de manutenção de Usinas Termoelétricas. Alguns exemplos de falhas são elencados no Quadro 3.1.

Quadro 3.1 - Exemplos de falhas.

Motor	Tipo de falha
1	Mangueira flexível
1	Tampa do suporte do eixo de manivela
2	Tubulação de retorno da turbina
4	Rede de desaeração
5	Mangote flexível
6	Transmissor de pressão
2	Rubinete
7	Válvula reguladora de pressão
8	Válvula de equalização de pressão
5	Abraçadeira da rede de retorno da turbina
10	Rede de saída do filtro lama
13	Rede de desaeração
14	Detector de névoa
16	O'ring da tampa de visita
18	Parafuso de fixação
20	Dreno da bomba injetora
8	Junta de expansão
9	Abraçadeira de água da turbina
11	Válvula de segurança
12	Suporte de fixação

Motor	Tipo de falha
19	Tubo de alta pressão
15	Válvula de controle de pressão
12	Disjuntor de 69kv
1	Cabeçote
3	Turbina
4	Bomba injetora
7	Injetor

Fonte: AUTOR (2021).

3.1.2 Características do grupo de máquinas

As características dos motores da Wartisila foram necessárias a fim de fundamentar melhor a pesquisa, além de permitir um conhecimento maior acerca da eficiência de cada máquina, a contribuição se refere a outros elementos que incorporam a estrutura de dados para futuras pesquisas com outras técnicas, as suas características são apresentadas no Quadro 3.2.

Quadro 3.2 - Características do grupo de máquinas.

Fabricante	Wartisila NSD Corporation
Modelo	18V46
Tipo do Motor	Ciclo Diesel de 4 tempos
Potência Nominal	15,75 MW
Eficiência	42,3%;
Configuração de cilindros	V;
Número de cilindros	18
Diâmetro interno dos cilindros	460 mm
Velocidade	514 rpm
Comprimento	13,58 m
Largura	5,347 m
Altura	5,488 m
Peso	237 Toneladas

Fonte: AUTOR (2021).

3.1.3 Indicadores da Gestão da Manutenção

Para o conjunto de dados de entrada e saída da RNA foi preciso trabalhar com alguns indicadores da Gestão da Manutenção que são regulamentados pela Norma Brasileira 5462. Estes que são apresentados no Quadro 3.3:

Quadro 3.3 - Variáveis de entrada e saída da RNA.

Variável	Indicador
Entrada	Total de Ocorrências - TO;
Entrada	Total de Parada - TP;
Entrada	Tempo Total de Operação da Máquina - TTOM;
Entrada	Tempo Médio entre Falhas - MTBF;

Variável	Indicador
Entrada	Tempo Médio de Reparo – MTTR;
Entrada	Disponibilidade -D;
Entrada	Taxa de Falhas – TF;
Entrada	Total de Dias Analisados - TD.
Entrada	Dias de Previsão - DA
Saída	Confiabilidade - CO

Fonte: AUTOR (2021).

3.1.4 Ambiente de desenvolvimento

Para a implementação do Algoritmo da Previsão da Confiabilidade de Motores foi utilizado o *software MatLab 2016a* usufruindo de alguns recursos como geração de gráficos, criação de funções, implementação de modelos matemáticos e recursos de linguagem de programação para aplicação dos procedimentos do algoritmo e modelos de RNA.

3.1.5 Recursos da máquina de teste

As configurações da máquina utilizada para as simulações foram importantes, principalmente na relação de uso dos recursos computacionais como: Paralelismo e Processamento de dados com alocação de memória em Unidades de Processamento Gráfica (GPU). O Quadro X apresenta as configurações da máquina utilizada.

Quadro 3.4 - Recursos computacionais da máquina simuladora.

Recurso	Valor
Memória RAM	6GB
Processador	I5 terceira geração
Clock de processamento	2.90 GHz
Memória Cache L3	6MB
Tecnologia de armazenamento	HD
Memória Secundária	500GB

Fonte: AUTOR (2021).

3.1.6 Algoritmos de treinamento

Os algoritmos de treinamento da RNA foram de suma importância para encontrar o melhor estado de convergência com base na quantidade de neurônios, camadas, funções de ativação e erros como o MSE e RMSE. O Quadro X apresenta os algoritmos utilizados caracterizando os seus métodos de convergência.

Quadro 3.5 - Algoritmos de treinamento.

Algoritmo	Método
<i>Levenberg-Marquardt</i>	Otimização
<i>Bayesian Regularization</i>	Otimização
<i>Broyden–Fletcher–Goldfarb–Shanno Quasi-Newton</i>	Iterativo
<i>Resilient Backpropagation</i>	Heurístico
<i>Scaled Conjugate Gradient</i>	Iterativo
<i>Conjugate Gradient with Powell/Beale Restarts</i>	Iterativo
<i>Fletcher-Powell Conjugate Gradient</i>	Quase-Newton
<i>Polak-Ribière Conjugate Gradient</i>	Otimização
<i>One Step Secant</i>	Newton
<i>Variable Learning Rate Gradient Descent</i>	Numérico
<i>Gradient Descent with Momentum</i>	Iterativo
<i>Gradient Descent</i>	Iterativo

Fonte: AUTOR (2021).

3.1.7 Funções de ativação

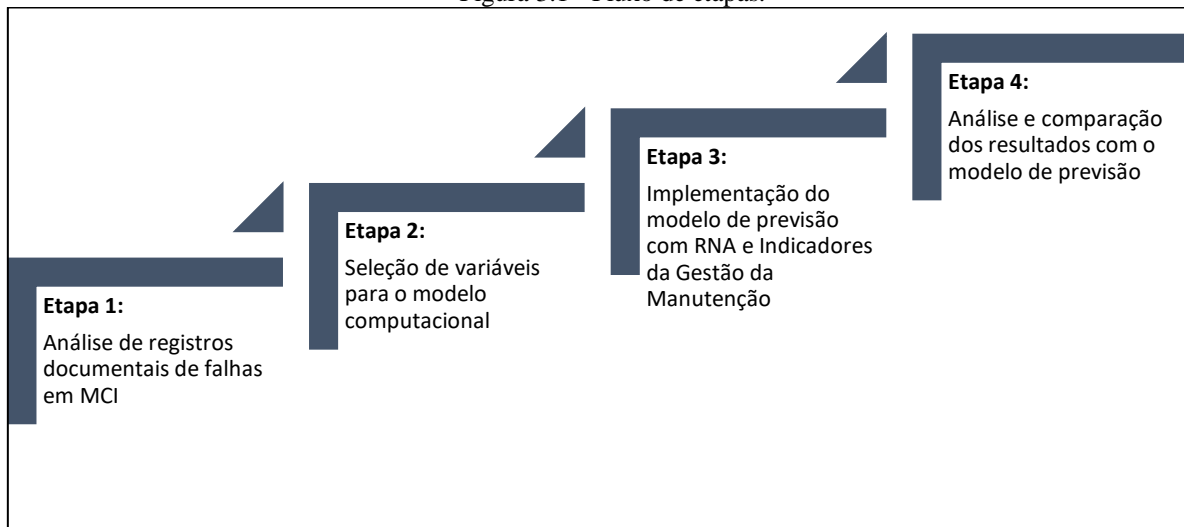
As funções de transferência são de suma importância para avaliar e reduzir a explosão do gradiente nas camadas de transferência entre os neurônios, no qual o controle de iteração, menor erro e melhor modelo são critérios de parada do algoritmo utilizado. As funções utilizadas são apresentadas a seguir:

- Linear;
- Sigmoid;
- Tangente hiperbólica

3.2 MÉTODOS

A pesquisa é caracterizada pela investigação de métodos computacionais que evidenciem eficiência no processamento de dados e eficácia na simulação dos resultados, para aplicar os conceitos de previsão do KPI Confiabilidade, por meio de dados pré-processados de documentos de manutenção referentes ao grupo de máquinas de Usinas Termoeletricas, foi realizado uma análise acerca do conteúdo, por fim algumas etapas foram consideradas para consolidar a pesquisa, sendo elas ilustradas pela Figura 3.1.

Figura 3.1 - Fluxo de etapas.



Fonte: AUTOR (2021).

3.2.1 Análise dos registros documentais de falhas

Conforme ilustrado na Figura 3.1, são realizadas quatro etapas, a primeira etapa é uma análise dos registros documentais de falhas do grupo de máquinas de Usinas Termoeletricas, esses documentos compreendem registros de um período de janeiro a dezembro dos anos de 2018 e 2019, contendo informações como: data, hora, tempo de parada, sistema que falhou, subsistema que foi afetado e a descrição da falha.

3.2.2 Seleção de variáveis fundamentais para o modelo computacional

A segunda etapa definida pela seleção de variáveis fundamentais para o modelo computacional, é feito um levantamento dos principais indicadores da gestão da manutenção e com base nos dados pré-processados de 2018 e 2019, são selecionadas as variáveis que caracterizam o uso ou requisito para o cálculo da Confiabilidade de cada motor.

Estes que compõe o conjunto de dados de entrada do modelo de RNA, e definidas pela Norma Brasileira 5462 que regulamenta os termos relacionados à confiabilidade e manutenibilidade, sendo eles:

Total de Parada: Obtido através da Eq. (3.1):

$$TTP = \sum_{i=1}^n tpf - tpi \quad (3.1)$$

Onde:

TTP = tempo total de parada;

tpf = tempo final de parada;

t_{pi} = tempo inicial de parada;

n = quantidade de paradas

Total de Frequência: Obtido pelo somatório das frequências de falhas conforme a Eq. (3.2):

$$TF = \sum_{i=1}^n f_i \quad (3.2)$$

Onde:

TF = Total de Frequência;

f_i = unidade de falha;

n = quantidade de falhas

Dias analisados: Obtido pela diferença entre a data final e a data inicial do mês analisado conforme Eq. (3.3):

$$DA = DF - DI \quad (3.3)$$

Onde:

DA = Dias analisados;

DF = data final;

DI = data inicial

Horas de operação: Obtido pelo produto da quantidade de dias analisados por 24 conforme Eq. (3.4):

$$HO = DA * 24 \quad (3.4)$$

Onde:

HO = Horas de operação;

DA = dias analisados;

24 = horas do dia

MTBF: Obtido pela diferença entre o Total de parada e Total de Frequência dividido pelas Horas de Operação, conforme expresso na Eq. (3.5):

$$MTBF = \frac{TTP - TF}{HO} \quad (3.5)$$

Onde:

$MTBF$ = Tempo médio entre falhas;

TTP = Tempo Total de Parada;

TF = Total de Frequência;

HO = Horas de Operação

MTTR: Obtido pela divisão entre o Tempo Total de Parada e Tempo Total de Frequência, conforme expresso na Eq. (3.6):

$$MTTR = \frac{TTP}{TTF} \quad (3.6)$$

Onde:

$MTTR$ = Tempo médio de reparo;

TTP = Tempo Total de Parada;

TF = Tempo Total de Frequência;

Taxa de falha: Obtido pelo inverso de MTBF, conforme expresso na Eq. (3.7):

$$\lambda(t) = \frac{1}{MTBF} \quad (3.7)$$

Onde:

$\lambda(t)$ = Taxa de falhas;

$MTBF$ = Tempo médio entre falhas;

T = tempo de projeção

Confiabilidade: Obtido pela função de tempo não definida, conforme expresso na Eq. (3.8):

$$R(t) = e^{-\lambda * t} \quad (3.8)$$

Onde:

$R(t)$ = Confiabilidade;

e = logaritmo neperiano;

λ = taxa de falhas;

t = tempo de projeção

3.2.3 Implementação do modelo de previsão com RNA e Indicadores da Gestão da Manutenção

A terceira etapa definida como Implementação do modelo de previsão com RNA e Indicadores da Gestão da Manutenção, é realizado o desenvolvimento do modelo de previsão considerando o aprendizado supervisionado, os algoritmos de treinamento para o estado de

convergência da RNA, as funções de ativação e quantidade de neurônios como critérios de disputa do melhor modelo.

O algoritmo implementado, tem como finalidade:

- Ler o conjunto de dados de falhas;
- Realizar o processamento desses dados, para encontrar e calcular os indicadores citados na etapa 2,
- Separar o conjunto processado com base na quantidade de motores, ou seja, cada motor terá um conjunto de entrada e saída observada para treinamento da RNA;
- O algoritmo determina qual o melhor modelo com base no MSE e RMSE para depois realizar simulações nos períodos de dias e meses.

3.2.4 Análise e comparação dos resultados com o modelo de previsão

A última etapa definida como Análise e comparação dos resultados com o modelo de previsão, é realizado um comparativo entre os diferentes tipos de redes com os algoritmos de otimização já citados.

Essa etapa consiste em dividir o conjunto de dados para as etapas de treinamento, teste e validação da RNA, tendo em vista esse método foi utilizado a seguinte divisão:

- 70% dos dados para treinamento
- 15% dos dados para validação
- 15% dos dados para teste

Para as simulações do modelo, estes baseado nos dados processados, a arquitetura ANN comumente conhecida como Múltiplas Camadas foi a que melhor se enquadrou no contexto, tendo em vista o propósito de aproximação de funções.

Para essa arquitetura foi proposto a abordagem de treinamento supervisionado dispondo de amostras de entrada e saídas desejadas, dessa forma, os pesos e limiares serão ajustados continuamente por diferentes técnicas de convergência ou algoritmos de otimização.

O fator de escolha do melhor algoritmo é feito com base no menor Erro Médio Quadrático (MSE) e a Raiz do Erro Médio Quadrático (RMSE), onde cada modelo de rede é treinado, uma filtragem é realizada, para identificar a que possui o menor índice de MSE e RMSE (PANG, NIU e O'NEILL, 2020; BANDYOPADHYAY e DUTTA, 2020).

Para cada iteração realizada é feito uma validação de performance da rede, onde é chamada uma função responsável por simular o resultado de saída da rede com o vetor de saída, conforme a Eq. (3.9) e (3.10):

$$MSE = \frac{\sum_{i=1}^n (ra_i - rs_i)^2}{n} \quad (3.9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (ra_i - rs_i)^2}{n}} \quad (3.10)$$

Onde:

MSE = Erro Médio Quadrático;

$RMSE$ = Raíz do Erro Médio Quadrático;

n = número de elementos do vetor de saída;

ra = resultado alvo;

rs = resultado simulado

Para a execução dos testes foram avaliados os 12 algoritmos, cada um foi submetido a uma série de 3 treinamentos para avaliar as melhores condições de topologia de rede considerando a quantidade de neurônios e função de transferência nas camadas de entrada e intermediária.

No final o modelo de previsão tem a finalidade de indicar a melhor configuração de RNA para os dados processados e prever a porcentagem de confiabilidade do equipamento a ser previsto, considerando a probabilidade de funcionamento correto do equipamento em um período de tempo em dias e meses.

CAPÍTULO 4


4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados de treinamento, teste e validação entre os doze algoritmos de treinamento, os comparativos dos melhores resultados por máquina, os indicadores de gestão da manutenção como tempo de parada, tempo gasto, frequência, disponibilidade e confiabilidade, e por fim os comparativos entre as simulações com 1, 5, 10, 15 e 20 dias e 1, 3 e 5 meses.

4.1 ANÁLISE DE REGISTROS DOCUMENTAIS DE FALHAS

O Gráfico 4.1 apresenta um comparativo de dias analisados (DA) para os anos de 2018 e 2019 em um período de janeiro a dezembro, nele é possível identificar uma variação entre 26 e 30 dias, a linha de tendência azul demarca as variações de 2018, a linha de tendência laranja demarca as variações de 2019 que é determinado pela quantidade de dados coletados em cada mês.


Gráfico 4.1 - Análise de dados dos anos: 2018 e 2019.



Fonte: AUTOR (2021).

O Gráfico 4.2 apresenta o comparativo da quantidade de horas de operação (HO) do grupo de máquinas para os anos de 2018 e 2019 em um período de janeiro a dezembro, nele também é possível identificar uma variância de horas analisadas entre 600 e 720 caracterizando o período em que as máquinas operam em cada mês.

Gráfico 4.2 - Análise das Horas de Operação dos anos: 2018 e 2019.



Fonte: AUTOR (2021).

Em virtude das análises documentais dos registros de falhas fornecidos pelos especialistas, foi possível desenvolver uma base de dados para trabalhar os principais indicadores da gestão da manutenção que foram utilizados no modelo de previsão utilizando RNA's, os tópicos seguintes abordam os resultados acerca do algoritmo para previsão em dias e meses e seus resultados em função dos indicadores de manutenção e simulações.

4.2 DESENVOLVIMENTO DO ALGORITMO DE PREVISÃO DA CONFIABILIDADE DE MOTORES (APCM)

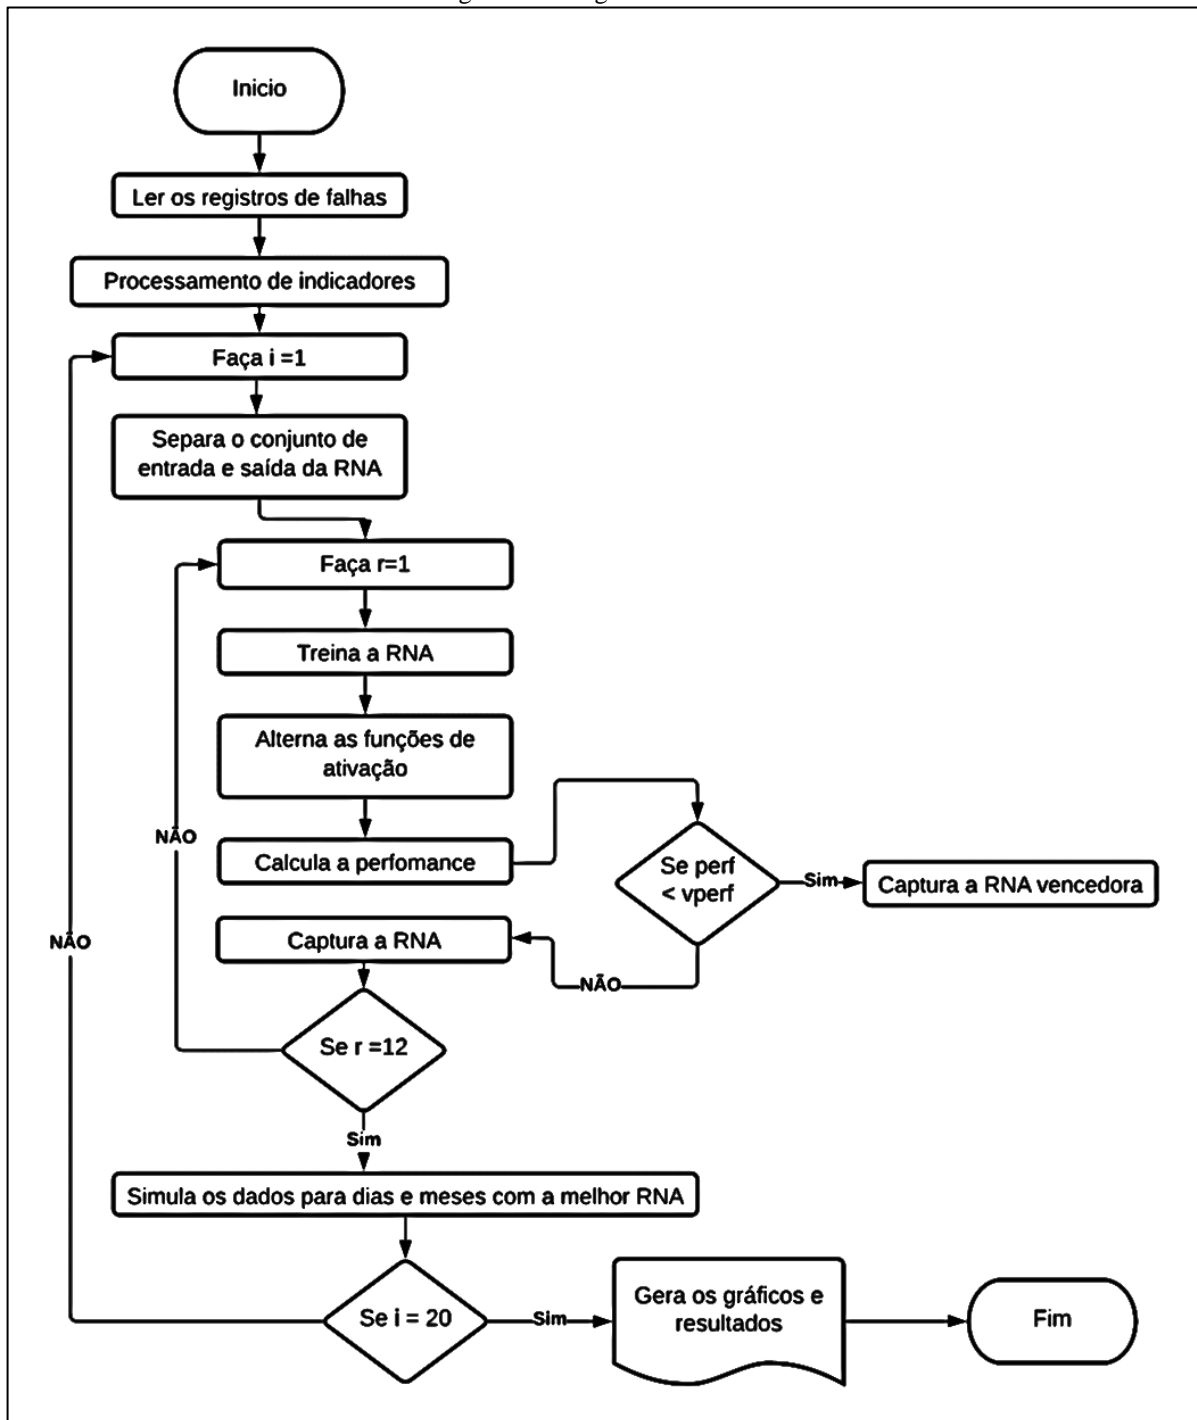
O modelo de previsão é uma forma de avaliar processos estocásticos e organizar dados com determinada tendência, contudo, as Redes Neurais Artificiais são utilizadas como processos de identificação, classificação e predição que auxiliam esses procedimentos.

Um processo de identificação ocorre quando dados empíricos ou com nenhuma similaridade são introduzidos nas camadas de entrada de uma RNA, é possível utilizar outras técnicas para normalização de dados, quando não há formalidades em uma RNA, alguns exemplos como Suavização Exponencial ou *Holt Winters* são formulados e aplicados em diversas áreas e principalmente em estudos de análise experimental na literatura.

O APCM tem como objetivo analisar a performance de 12 algoritmos de treinamento e apontar resultados de simulação com o uso de uma RNA, isso serve para buscar as melhores configurações (quantidade de neurônios, camadas ocultas, funções de ativação e algoritmo de treinamento utilizado) para um modelo de RNA, durante o processo de análise, os treinamentos são realizados, por meio de uma avaliação de erros foi possível classificar os algoritmos vencedores para cada motor.

A Figura 4.1 ilustra os passos do APCM para se obter o melhor modelo de RNA com base no menor MSE e RMSE, o algoritmo consiste em 17 etapas, cada etapa possui uma importância relevante onde é levado em consideração os requisitos mínimos de máquina de teste, a quantidade de iterações, taxa de aprendizado, erro e quantidade de camadas para fugir da explosão do gradiente.

Figura 4.1 - Algoritmo APCM.



Fonte: AUTOR (2021).

Embora, sua eficiência seja avaliada por métodos estatísticos como: MSE e RMSE, os algoritmos de treinamento são catalisadores de performance computacional ao realizar procedimentos iterativos, daí surge a ideia de complexidade computacional, onde o custo temporal ou computacional é levado em consideração, de tal forma que a notação matemática que melhor expressa a utilização de recursos em função do tamanho de dados é dada pela quantidade de operações elementares, de forma superficial é analisado a quantidade de iterações que o APCM realiza, cada iteração leva em consideração $O(n)$, contudo as operações matemáticas também fazem parte deste cálculo, diferindo apenas no uso de funções que realizam pequenas tarefas.

Por isso, a presente dissertação retrata um cenário de análise comparativa entre algoritmos de aprendizado de máquina para evidenciar o melhor caso para o treinamento de uma RNA sem mensurar a utilização de recursos de memória e processamento de computador para demonstrar quão eficiente é o APCM.

O APCM é constituído pelos seguintes passos:

Passo 1: Leitura dos registros de falhas do grupo de motores, nesta etapa um conjunto de dados contemplando algumas variáveis já citadas são lidas e guardados em uma estrutura de dados, estes dados são:

- Sistema que falhou;
- Subsistema que falhou;
- Equipamento afetado;
- Descrição da falha;
- Data de ocorrência;
- Hora inicial da ocorrência;
- Hora final da ocorrência;
- Motor afetado;

Passo 2: Consiste no processamento dos dados adquiridos no passo 1, onde por meio de modelos matemáticos citados na seção materiais são formulados os indicadores da gestão da manutenção, estes que desempenham papel importante na manutenção e principalmente em equipamentos como as máquinas da Wartisila.

Os indicadores gerados vão de encontro com a formulação do problema de estimar a Confiabilidade das máquinas, para isso o MTBF, MTTR, Disponibilidade e Taxa de Falha foram elementos importantíssimos para aquisição deste indicador alvo. Dessa forma, a base de dados é reestruturada de tal forma que seja possível utilizá-la como modelo de entrada da RNA;

Passo 3: Neste passo que é considerado o início do processo de análise estatística entre os algoritmos de treinamento, é inicializado um loop para avaliar o conjunto de 20 unidades geradoras de carga;

Passo 4: Este passo considera uma separação na base dados, uma estrutura de dados é gerada considerando as características relativas ao motor corrente, onde as variáveis de entrada e saída observada são introduzidas na rede neural;

Passo 5: Neste passo, o algoritmo considera a avaliação do conjunto de 20 motores por meio de 12 algoritmos de treinamento já citados, por isso, é inicializado um loop que começa com o primeiro algoritmo até o décimo segundo;

Passo 6: Após inicializar o loop com 12 iterações, o APCM inicializa o processo de configuração ou setup da rede neural, para isso, algumas etapas são evidenciadas:

- **Primeiro:** é avaliado uma quantidade satisfatória de neurônios para as camadas ocultas, neste caso é considerado um intervalo de 1 a 20, de tal forma que a eficiência do aprendizado da rede não seja prejudicada ao aumentar a taxa;
- **Segundo:** são definidas duas camadas ocultas para a rede neural, esta quantidade vai de encontro com o impacto da perda de aprendizado que pode ser representada pela explosão do gradiente, onde o ajuste da curva de deslizamento para encontrar a melhor região de convergência da rede leva um tempo maior;
- **Terceiro:** é realizado a parametrização das funções de ativação que serão utilizadas na iteração corrente do motor e algoritmo de treinamento;

Passo 7: Esta etapa consiste em realizar a avaliação de um conjunto de 3 iterações que são possibilidades de alternância entre as funções de ativação: Sigmoide, Tangente Hiperbólica e Linear, a primeira camada recebe a função corrente e a segunda recebe uma função sorteada pela máquina, de tal forma que no final as três sejam avaliadas.

Ainda nesta etapa é definida a utilização do algoritmo corrente, via argumento de função prototipada, dessa forma, foi possível reaproveitar código e melhorar a manutenção em pontos estratégicos como a avaliação do algoritmo, a definição dos parâmetros da RNA e as funções de plotagem de gráficos;

Passo 8: o APCM inicializa o processo de treinamento da RNA com os parâmetros especificados, é válido ressaltar o uso de computação paralela que permite dividir as tarefas ou Threads para aliviar a o custo computacional e balancear o uso dos recursos do computador;

Passo 9: Nesta etapa o APCM realiza a avaliação de performance estatística do vetor de RNA salvo nas 3 iterações realizadas com as alternâncias entre funções de ativação, o cálculo da performance é realizado da seguinte forma:

- **Primeiro:** é instanciado uma variável chamada *vperf* com valor igual a 0;
- **Segundo:** é realizado a chamada da função responsável por calcular o MSE e RMSE para retornar o valor resultante para a variável *perf* referente à estrutura salva da RNA corrente;
- **Terceiro:** durante o processo de iteração uma estrutura de seleção avalia se o valor de *vperf* é menor que o valor de *perf*, se a sentença for verdadeira o APCM captura o índice da RNA atual possivelmente vencedora em relação as outras;
- **Quarto:** caso a sentença seja falsa o processo continua e o APCM captura a estrutura da RNA corrente e guarda em outro array.
- **Quinto:** após o processo de iteração das RNAs com a menor taxa de erro, o APCM guarda a estrutura, finaliza este processo iterativo e repassa para a próxima etapa.

Passo 10: Este passo consiste em avaliar novamente a performance da RNA, porém, desta vez é considerado a RNA com melhor função de ativação e o algoritmo de treinamento corrente, decorrente ao processo iterativo de 12 iterações.

Ainda nesta etapa o APCM realiza o mesmo processo descrito no passo 8, de tal forma que seja definido o critério do melhor algoritmo de treinamento para o motor corrente;

Passo 11: após a avaliação do melhor algoritmo, o APCM guarda as configurações de todos os testes realizados em uma estrutura de dados aninhada de acordo com as etapas descritas acima, de tal forma que seja evidenciado o modelo vencedor e finaliza o loop de 12 iterações;

Passo 12: o APCM inicializa o processo de simulação de cenários com os dados de entrada da rede, este processo é realizado da seguinte forma:

- **Primeiro:** é capturado os dados da RNA vencedora já treinada;
- **Segundo:** é capturado os dados de saída observados relativos ao motor corrente do processo de iteração do conjunto de 20 motores, considerando o modelo de previsão para 1, 3,5 10, 15 dias e 1 ,3 e 5 meses;
- **Terceiro:** é realizado a chamada da função responsável por simular a saída observada e retornar a saída prevista;
- **Quarto:** é realizado a chamada da função responsável por calcular o MSE e RMSE.

Passo 13: o APCM finaliza o loop relativo à avaliação de performance do melhor algoritmo para o conjunto de 20 motores;

Passo 14: nesta etapa o APCM inicializa o processo de plotagem dos gráficos ou precisamente os resultados acerca do processo de treinamento e simulações, este processo é dado pelos seguintes passos:

Primeiro: é inicializado um loop para capturar os dados de treinamento e falhas do conjunto de 20 motores;

Segundo: é realizado a chamada da função responsável por plotar os gráficos de treinamento relativos ao melhor modelo do motor corrente, onde são gerados os gráficos de histograma de erros, performance de erros, estado de treinamento e regressão das etapas de treinamento, validação e teste;

Terceiro: é realizado a chamada da função responsável por plotar os gráficos relativos aos indicadores de gestão da manutenção, como: taxa de falhas em função do mês, taxa de falhas em função do ano, taxa de disponibilidade, taxa de confiabilidade em função do ano e do motor e análise comparativa entre os modelos de previsão considerando o motor corrente;

Passo 15: Finaliza o loop com 20 iterações;

Passo 16: realiza a chamada da função responsável por plotar gráficos em 3 dimensões considerando uma análise da taxa de confiabilidade em função das unidades de falha e o conjunto de 20 motores;

Passo 17: o APCM finaliza.

4.3 APLICAÇÃO DOS ALGORITMOS DE TREINAMENTO PARA PREVISÃO DE DIAS

Esta seção apresenta os resultados da aplicação dos algoritmos de aprendizado para o melhor modelo da RNA, aplicado à previsão de 1, 5, 10, 15 e 20 dias, onde o conjunto de dados para treinamento da rede neural contempla: 66.000 registros de falha considerando os anos de 2018 e 2019.

O conjunto de entrada da RNA possui onze variáveis, discriminadas a seguir: *Total de Frequência; Tempo de parada; Horas de Operação; MTBF; MTTR; Disponibilidade; Taxa da Falha; Dias analisados; Mês corrente; Ano corrente; Tempo de previsão*, ambas validadas por modelos matemáticos, que são calculadas dinamicamente durante o processo de execução do algoritmo, este que é feito na etapa de processamento de dados.

O conjunto de saída da RNA possui uma variável, discriminada como: Confiabilidade, esta que é a resultante da Equação 45, a mesma é calculada dinamicamente na etapa de processamento de dados. A Tabela 4.1 apresenta um resumo dos resultados de treinamento para cada motor, onde as colunas representam: *Motor* é o número sequencial do motor; *Algoritmo* é o algoritmo de treinamento vencedor; *NC1* é o número de neurônios da camada escondida 1; *NC2* é o número de neurônios da camada escondida 2; *FC1* é a função de transferência da camada escondida 1; *FC2* é a função de transferência da camada escondida 2; *MSE* é o Erro

Médio Quadrático; **RMSE** é a Raíz do Erro Médio Quadrático e **R** é a Correlação entre as variáveis de saída e observada.

Tabela 4.1 - Algoritmos vencedores (previsão dias).

Motor	Algoritmo	NC1	NC2	FC1	FC2	MSE	RMSE	R
1	Levenberg-Marquardt	17	19	Linear	Linear	1,90504418124 532e-13	4,3646811810 7762e-07	100
2	Bayesian Regularization	7	18	Tangente Hiperbólica	Linear	1,33108878940 683e-11	3,6484089537 8634e-06	100
3	Bayesian Regularization	20	6	Sigmoide	Linear	4,71277808832 307e-13	6,8649676534 7301e-07	100
4	Bayesian Regularization	13	2	Sigmoide	Sigmoide	7,81565213538 123e-12	2,7956487861 2841e-06	100
5	Bayesian Regularization	16	20	Sigmoide	Tangente Hiperbólica	1,15298014392 188e-13	3,3955561310 6584e-07	100
6	Bayesian Regularization	19	16	Sigmoide	Tangente Hiperbólica	8,86606572120 808e-13	9,4159788238 9721e-07	100
7	Levenberg-Marquardt	13	11	Tangente Hiperbólica	Sigmoide	1,31552126872 483e-14	1,1469617555 6329e-07	100
8	Bayesian Regularization	13	14	Tangente Hiperbólica	Sigmoide	5,52289598506 254e-13	7,4316189252 8307e-07	100
9	Bayesian Regularization	6	15	Sigmoide	Linear	6,81640075897 218e-13	8,2561496830 9816e-07	100
10	Bayesian Regularization	10	12	Linear	Tangente Hiperbólica	2,67745708584 111e-13	5,1744150257 2137e-07	100
11	Levenberg-Marquardt	19	20	Tangente Hiperbólica	Linear	4,71248685706 242e-14	2,1708263074 3743e-07	100
12	Bayesian Regularization	7	11	Sigmoide	Linear	1,45649010554 774e-13	3,8163989644 0052e-07	100
13	Bayesian Regularization	5	10	Tangente Hiperbólica	Tangente Hiperbólica	1,54638046163 622e-12	1,2435354685 8794e-06	100
14	Bayesian Regularization	9	19	Tangente Hiperbólica	Tangente Hiperbólica	1,16479705759 205e-13	3,4129123305 3539e-07	100
15	Levenberg-Marquardt	18	6	Sigmoide	Linear	1,43562045513 182e-13	3,7889582409 0451e-07	100
16	Bayesian Regularization	6	19	Sigmoide	Tangente Hiperbólica	1,13442553269 753e-12	1,0650941426 4540e-06	100
17	Bayesian Regularization	3	9	Linear	Sigmoide	6,43944150963 287e-12	2,5376054676 8659e-06	100
18	Bayesian Regularization	14	17	Sigmoide	Linear	3,01990353617 133e-13	5,4953648979 5840e-07	100
19	Levenberg-Marquardt	17	15	Tangente Hiperbólica	Linear	2,25939045929 022e-12	1,5031268939 4150e-06	100
20	Bayesian Regularization	15	19	Tangente Hiperbólica	Linear	1,25494578236 631e-13	3,5425213935 3640e-07	100


Fonte: AUTOR (2021).

A Tabela 4.1 apresenta os resultados dos 20 melhores algoritmos classificados de acordo com o melhor treinamento para cada motor, nela é possível identificar que o motor 7 obteve 1,31552126872483e-14 de MSE, 1,14696175556329e-07 de RMSE e 100% de correlação entre as variáveis de saída e observada, caracterizando total proximidade com a função real projetada.

O gráfico da Figura 4.2 ilustra o comparativo de RMSE do grupo de máquinas, onde o menor valor aproximado indica a proximidade da função real, tendo em vista que é caracterizado pelo menor erro, o motor 7 se aproxima da função conforme demonstrado. Outros motores como o 2 e 4 obtiveram respectivamente 1,33108878940683e-11 e

7,81565213538123e-12 para MSE e 3,64840895378634e-06 e 2,79564878612841e-06 para RMSE. As elevações apresentadas na figura justificam esses valores.

Figura 4.2 - Comparativo de erros do grupo de máquinas previsão dias.



Fonte: AUTOR (2021).

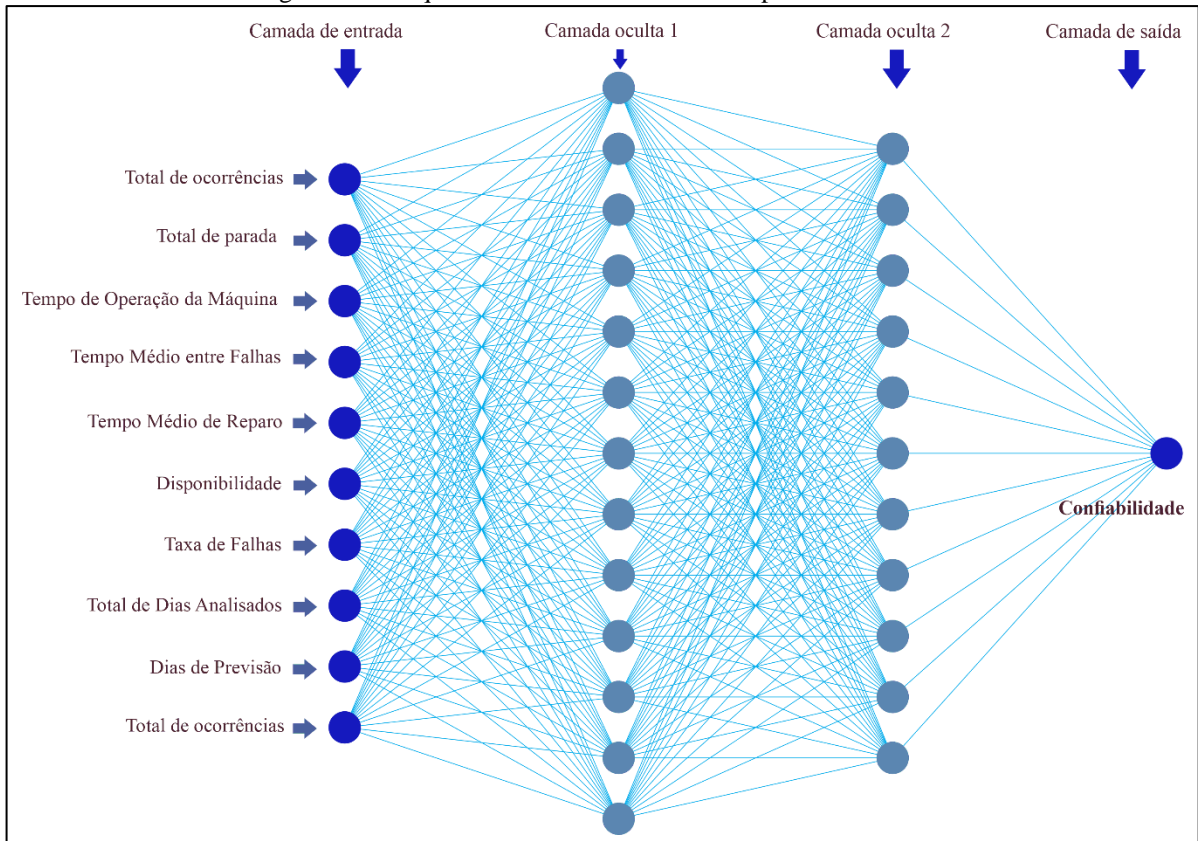
A configuração de RNA vencedora foi a do motor 7 com o algoritmo *Levenberg-Marquardt*, 13 neurônios na primeira camada escondida e 11 na segunda camada escondida, ambas utilizando a função de transferência Sigmoide que permitem uma taxa de erro de aproximadamente 1,15 e-07 para o RMSE.

A Figura 4.3 ilustra o modelo de arquitetura da rede neural evidenciada pela RNA vencedora considerando os dados de treinamento do motor 7 ao utilizar as configurações citadas. Nesta figura possível identificar 4 fileiras que são denominadas respectivamente: camada de entrada, camada oculta 1, camada oculta 2 e camada de saída.

Em cada camada existe uma quantidade de neurônios que possuem atividades distintas, por exemplo as entradas servem para prover valores de suas respectivas variáveis, as ocultas servem para realizar processos e cálculos que permitam ativar outros neurônios mediante as possibilidades até se chegar na camada de saída com um determinado resultado.

O processo de convergência da rede depende dos parâmetros utilizados na modelagem da rede neural, do algoritmo de treinamento e na aplicação das funções de ativação nas camadas ocultas ou de saída.

Figura 4.3 - Arquitetura da RNA vencedora na previsão em dias.



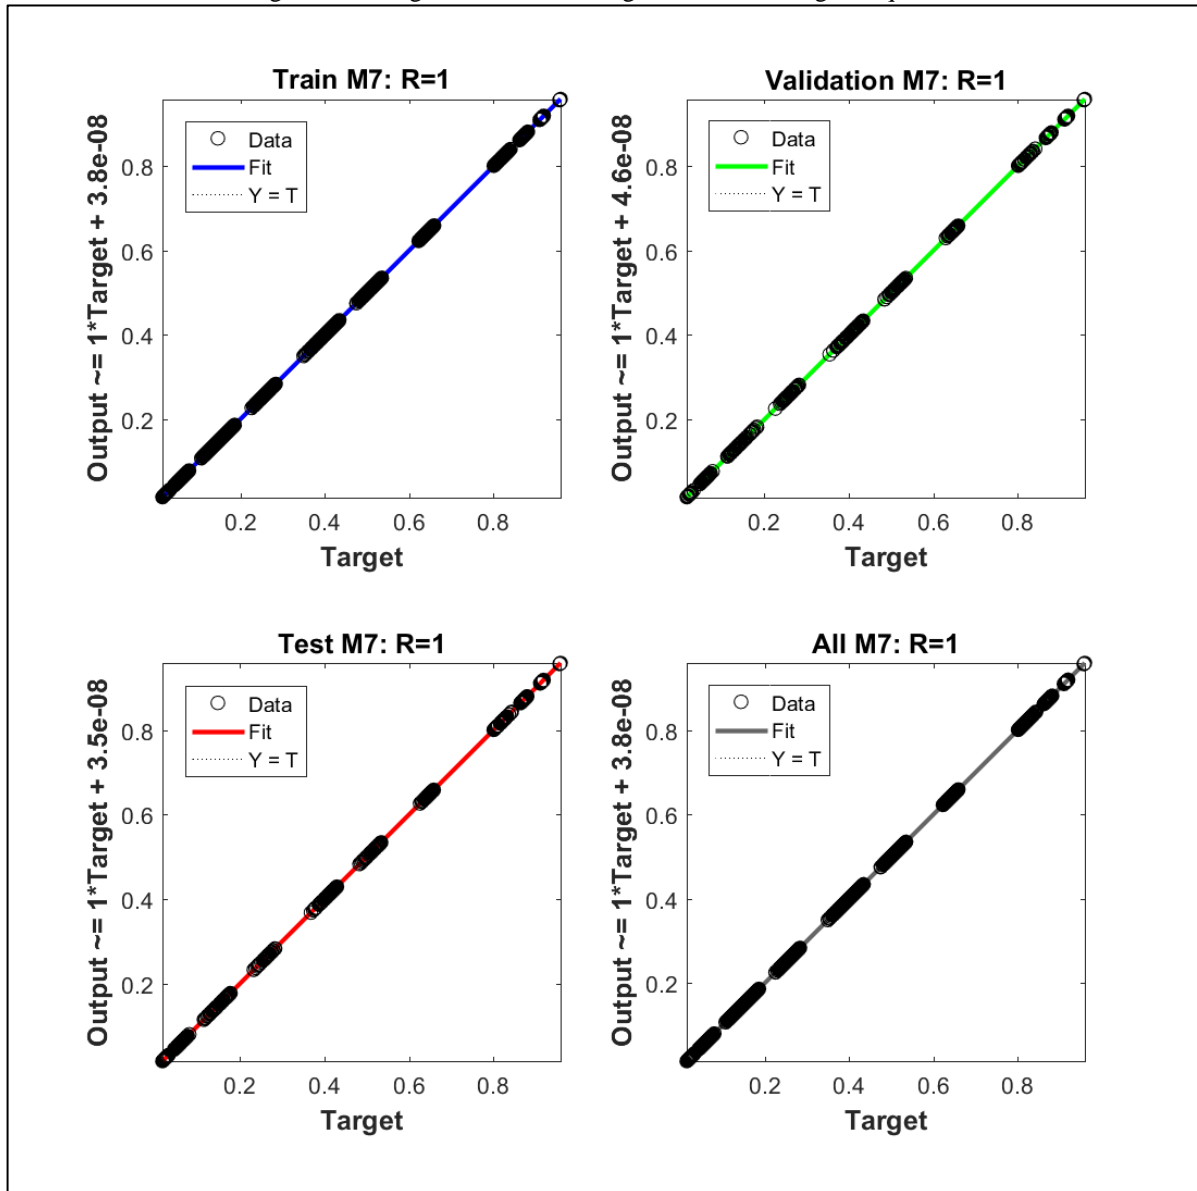
Fonte: AUTOR (2021).

Tendo em vista que a melhor configuração de RNA é a do motor 7 onde foi possível alcançar um RMSE de $1,15 \times 10^{-7}$, serão apresentados os resultados detalhados referentes a esse motor.

4.3.1 Modelo de RNA vencedora

A Figura 4.4 ilustra 4 gráficos que representam respectivamente os resultados de treino, validação, teste e a média entre ambos, onde cada um obteve 100% de correlação entre as variáveis de saída e simulada. Esses valores são provenientes de uma análise de regressão linear, como já citado antes, o conjunto de dados de saída é correlacionado com o conjunto de dados simulado, provido da rede neural, dessa forma, os pontos pretos indicados em cada reta de tendência estão bem próximos caracterizando a correlação entre ambos, onde os pontos de cada variável são os mesmos.

Figura 4.4 - Regressão linear do Algoritmo Levenberg-Marquardt.



Fonte: AUTOR (2021).

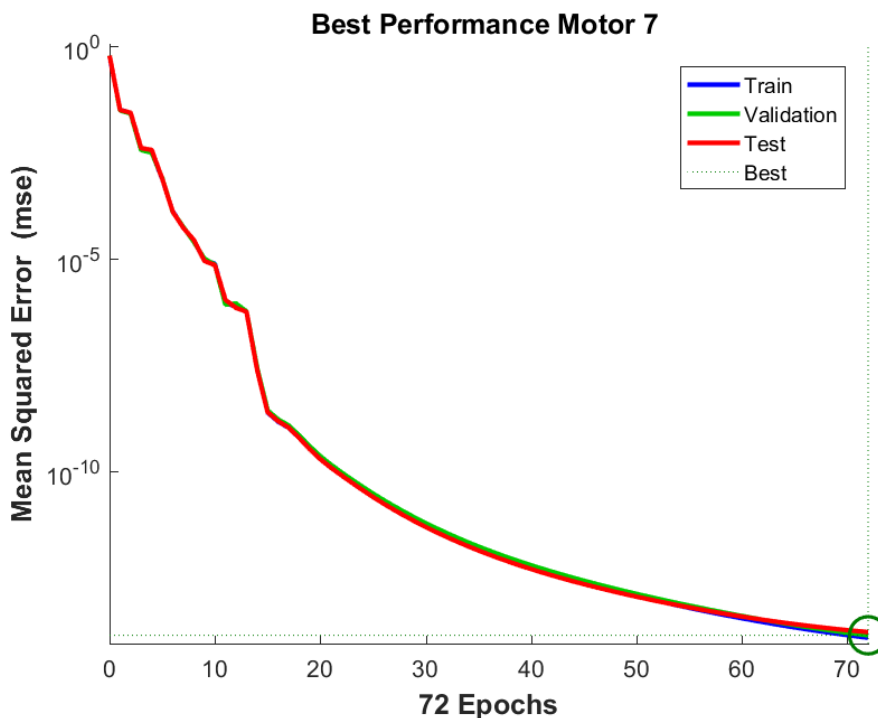
O primeiro gráfico representado pelo “Train” treinamento do motor 7 alcança 100% de correlação entre a variável observada e prevista, ou seja, os valores coordenados pelos eixos das abscissas e ordenadas são iguais em função das entradas inferidas na rede neural.

O segundo, terceiro e quarto gráfico também evidenciam 100% de confiabilidade na correlação entre as variáveis observada e preditora, de tal forma que a divisão de dados para executar esta etapa é realizada com o intuito de comprovar a eficiência do modelo mediante suas configurações e validar a previsão por meio de uma técnica matemática que é a Regressão Linear. O último gráfico caracterizado como “All” ou “Todos” tem como finalidade demonstrar uma média entre as etapas anteriores, onde é evidenciado 100% de correlação ou confiabilidade.

O algoritmo *Levenberg-Marquardt* tem como característica a minimização por métodos de amortecimento dos mínimos que é fundamental para solução de problemas não lineares, ou seja, trabalha diretamente no ajuste do deslizamento de curva, contudo, este algoritmo não encontra um mínimo global.

O Gráfico 4.3 apresenta o resultado de melhor performance do motor 7, onde o tempo de convergência do algoritmo é levado em consideração, isso se dá pela descida ou ajuste da curva de deslizamento, a cada época realizada o tempo de convergência aumenta, de acordo com o gráfico o algoritmo levou 72 épocas para encontrar o melhor estado de convergência, ou seja, é o momento em que os pesos chegam a um limiar correlacionado para simular com precisão os valores de entrada inferidos como elementos de previsão.

Gráfico 4.3 - Análise da performance previsão dias.

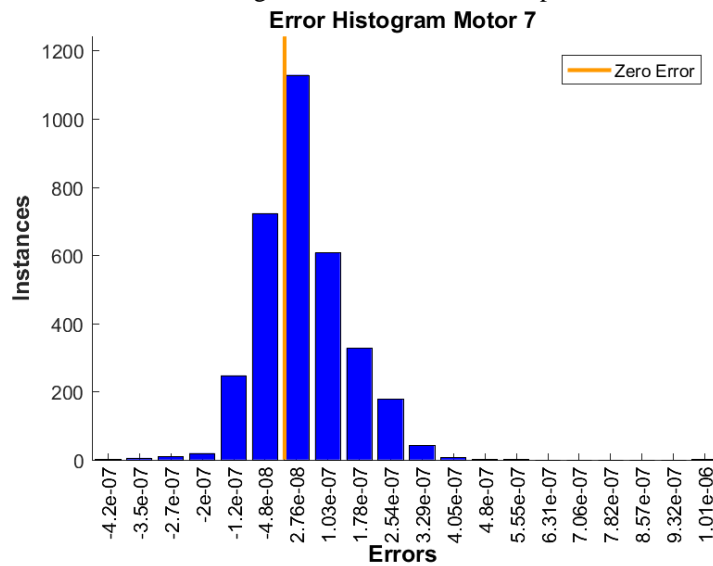


Fonte: AUTOR (2021).

O Gráfico 4.4 apresenta uma análise comparativa do motor 7 entre os erros capturados em cada época do modelo de previsão, onde a menor taxa de erro é localizada na linha vertical de cor laranja entre as barras de valores $-4.8e-08$ e $2.76e-08$.

Os erros são ajustados ao longo das épocas, como é demonstrado no Gráfico 4.4, é possível afirmar que desde o primeiro erro o ajuste é realizado e centralizado, de tal forma que a linha em destaque vertical evidencia a menor taxa ao variar em um intervalo de $-4.2e-07$ a $1.01e-06$ e uma quantidade instâncias que tende a variar em um intervalo de 0 a 1200.

Gráfico 4.4 - Histograma de Erro do Motor 7 previsão dias.

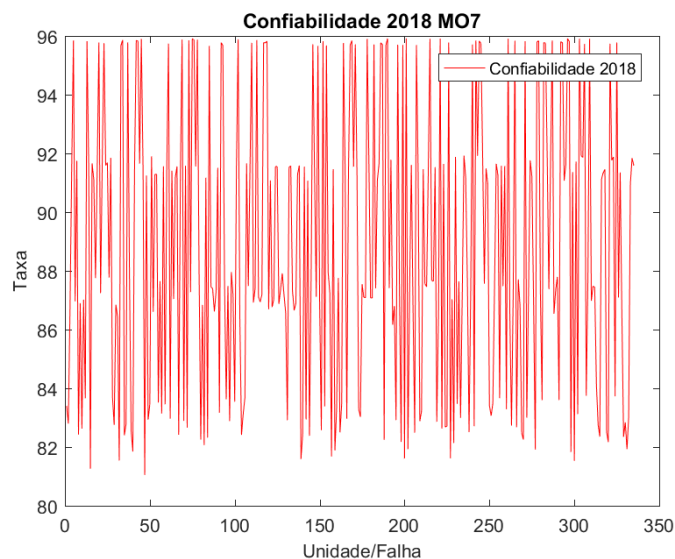


Fonte: AUTOR (2021).

4.3.2 Indicadores da Gestão da Manutenção

O Gráfico 4.5 apresenta uma análise da Confiabilidade do Motor 7 no ano de 2018, onde é considerado um conjunto de 350 falhas, variando em uma porcentagem de 80 a 96%. Neste gráfico é possível identificar as variações consistentes para cada falha analisada, contudo, entre as unidades 100 e 150 ocorre uma estabilidade variando entre 87 e 91%, fato consequente da frequência de falhas.

Gráfico 4.5 - Análise da Confiabilidade 2018 – MO7.

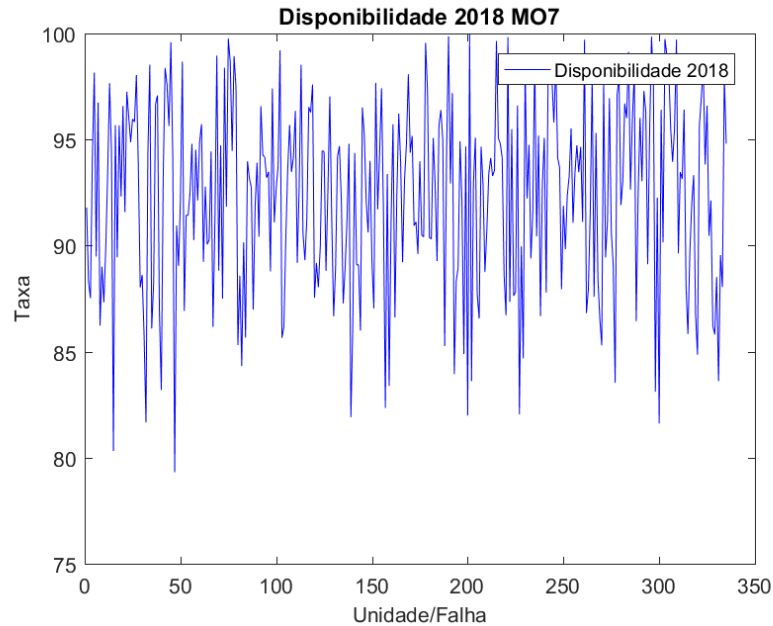


Fonte: AUTOR (2021).

O Gráfico 4.6 apresenta uma análise da Disponibilidade do Motor 7 no ano de 2018, onde é considerado um conjunto de 350 falhas, variando em uma porcentagem de 80 a 100 %. Em

comparação ao gráfico de Confiabilidade, este apresenta uma estabilidade em seus valores, havendo poucas variações, fato característico de uma tendência em relação à Confiabilidade.


Gráfico 4.6 - Análise da Disponibilidade 2018 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.7 apresenta uma análise da Confiabilidade do Motor 7 no ano de 2019, onde é considerado um conjunto de 350 falhas, variando em uma porcentagem de 81 a 90 %. Neste gráfico é possível identificar uma frequência de variações, fato decorrente do número de falhas e da Disponibilidade.

Gráfico 4.7 - Análise da Confiabilidade 2019 – MO7.

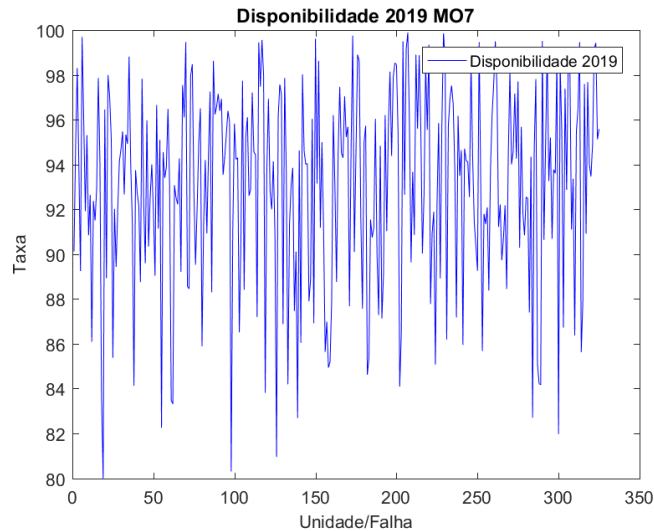


Fonte: AUTOR (2021).

O Gráfico 4.8 apresenta uma análise da Disponibilidade do Motor 7 no ano de 2019, onde é considerado um conjunto de 350 falhas, variando em uma porcentagem de 80 a 100 %. Tendo

em vista o gráfico de Confiabilidade, este valida as altas taxas de variações, onde a frequência de falhas se torna maior, ocasionando em uma não linearidade nas taxas de disponibilidade.


Gráfico 4.8 - Análise da Disponibilidade 2019 – MO7.



Fonte: AUTOR (2021).

Considerando os eventos da análise de Disponibilidade e Confiabilidade nos anos de 2018 e 2019, torna-se válido abordar sobre as taxas de falhas em função dos respectivos anos. O Gráfico 4.9 apresenta uma análise comparativa da taxa de parada adquirida em função do MTBF, ou seja, do tempo em horas, o gráfico apresenta os resultados referentes ao ano de 2018, nele é possível identificar que o mês de junho obteve uma taxa de 63% de indisponibilidade e o de mês de novembro obteve uma taxa de 60% de disponibilidade.


Gráfico 4.9 - Taxa de parada ano 2018 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.10 apresenta uma análise comparativa da disponibilidade e indisponibilidade em relação ao ano de 2019, onde nele é possível identificar que o mês de janeiro obteve uma taxa de 53% de indisponibilidade e o mês de agosto obteve uma taxa de 33% de disponibilidade.

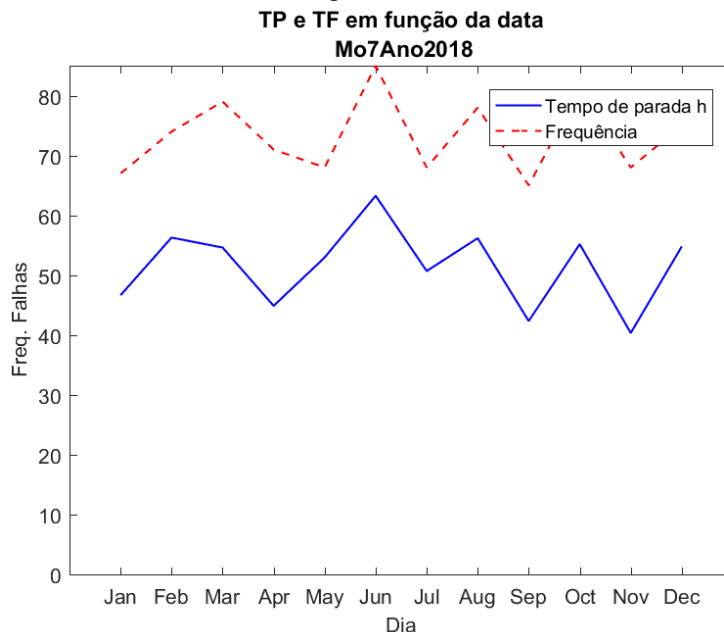
Gráfico 4.10 - Taxa de parada ano 2019 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.11 apresenta uma análise comparativa do ano de 2018 em função do tempo de parada e total de frequência, onde nele é possível identificar a diferença entre os indicadores, como já citado o mês de junho possui a maior taxa, contudo, a frequência é maior que o tempo de parada com uma relação de 63,27 h para 85 ocorrências, caracterizando uma consistência na quantidade de ocorrências das falhas.

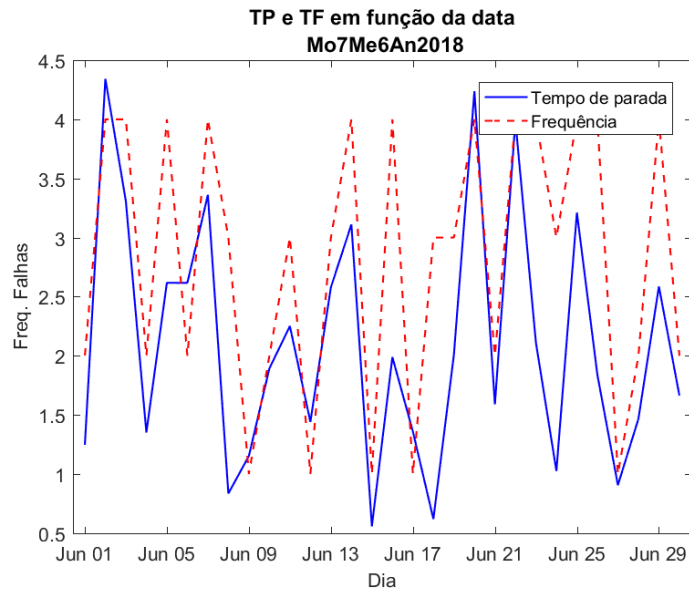
Gráfico 4.11 - Análise comparativa do TP e TF em 2018 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.12 apresenta a relação do tempo de parada e total de frequência do mês de junho de 2018, considerando o mês de forma isolada, percebe-se que a frequência é consistente em relação ao tempo de parada da falha.


Gráfico 4.12 - Relação do TP e TF do mês de junho de 2018 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.13 apresenta uma análise comparativa do ano de 2019 em função do tempo de parada e total de frequência, onde nele é possível identificar a diferença entre os indicadores, como já citado o mês de janeiro possui a maior taxa, contudo, a frequência é maior que o tempo de parada com uma relação de 51,43 h para 73 ocorrências, caracterizando uma consistência na quantidade de ocorrências das falhas.


Gráfico 4.13 - Análise comparativa do TP e TF em 2019 – MO7.



Fonte: AUTOR (2021).

O Gráfico 4.14 apresenta a relação do tempo de parada e total de frequência do mês de janeiro de 2019, considerando o mês de forma isolada, percebe-se que a frequência é consistente em relação ao tempo de parada da falha.

Gráfico 4.14 - Relação do TP e TF em janeiro de 2019 – MO7.

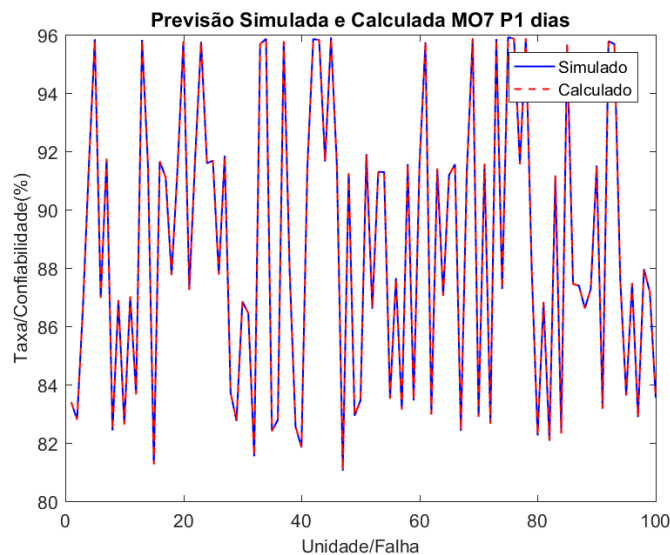


Fonte: AUTOR (2021).

4.3.3 Simulações para 1, 5, 10, 15 e 20 dias

Nesta seção são apresentados os principais resultados referentes às simulações do algoritmo APCM com o melhor modelo de RNA, onde é previsto a taxa de Confiabilidade para 1, 5, 10, 15 e 20 dias, é válido ressaltar que a correlação entre as variáveis de saída é 100% caracterizando a confiança do algoritmo, isso é mostrado no Gráfico 4.15, onde é apresentado uma comparação entre o modelo simulado e calculado.

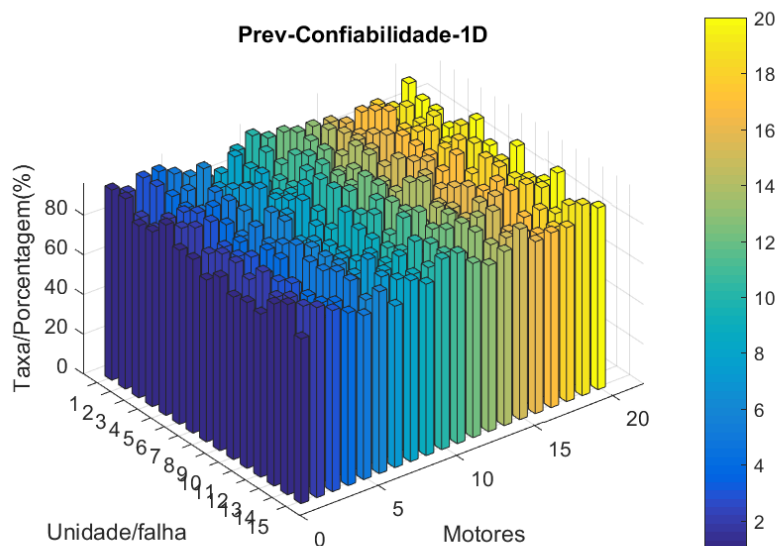
Gráfico 4.15 - Comparativo do modelo simulado e calculado para 1 dia.



Fonte: AUTOR (2021).

O Gráfico 4.16 apresenta uma comparação da Confiabilidade do grupo de 20 motores, onde é relacionado uma amostra de 15 unidades de falhas para representar a taxa em porcentagem, nele é possível identificar uma variação de 82 a 96% de Confiabilidade para o modelo de previsão de 1 dia.

Gráfico 4.16 - Confiabilidade prevista para 1 dia.



Fonte: AUTOR (2021).

Em virtude disso, a Tabela 4.2 apresenta os dados relativos ao Gráfico 4.16 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 1 dia.

Tabela 4.2 - Taxa de Confiabilidade prevista para 1 dia.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	81,51101	81,71595	81,46191	81,92049	81,55561	81,66445	81,26022	81,83137	82,39142	82,04899
MÁX	95,87566	95,78380	95,84275	95,82482	95,80316	95,77544	95,84395	95,90367	95,78977	95,91339
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	82,26604	86,68469	81,44882	81,99013	81,57842	81,88309	81,80735	83,03946	82,27714	82,38606
MÁX	95,91594	95,91158	95,84741	95,86794	95,82308	95,83925	95,91381	95,91251	95,89260	95,76550

Fonte: AUTOR (2021).


Na Tabela 4.2 é possível identificar variações entre 81 e 87 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 1 dia, para a linha MAX é possível observar uma variação entre 81 e 96% de a máquina operar em uma previsão de 1 dia.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 7 com 81,26%. Contudo, o motor que obteve a maior taxa de

Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 11 com 95,92%.

O Gráfico 4.17 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 5 dias, onde nele é possível identificar uma variação de 40 a 81% de Confiabilidade.

Gráfico 4.17 - Confiabilidade prevista para 5 dias.



Fonte: AUTOR (2021).

A Tabela 4.3 apresenta os dados relativos ao Gráfico 4.17 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 5 dias.

Tabela 4.3 - Taxa de Confiabilidade prevista para 5 dias.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	35,9817	36,4363	35,8734	36,8946	36,0802	36,3216	35,4315	36,6943	37,9673	37,1849
MÁX	81,0106	80,6233	80,8717	80,796	80,7048	80,5881	80,8767	81,129	80,6484	81,1701
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	37,6793	48,9454	35,8446	37,0517	36,1307	36,8104	36,6405	39,4841	37,7047	37,955
MÁX	81,1809	81,1625	80,8913	80,978	80,7887	80,8569	81,1719	81,1664	81,0822	80,5463


Fonte: AUTOR (2021).

Na Tabela 4.3 é possível identificar variações entre 35 e 49 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 5 dias, para a linha MAX é possível observar uma variação entre 80 e 82% de a máquina operar em uma previsão de 5 dias.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 7 com 35,4315%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 11 com 81,1809%.

O Gráfico 4.18 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 10 dias, onde nele é possível identificar uma variação de 15 a 66% de Confiabilidade.

Gráfico 4.18 - Confiabilidade prevista para 10 dias.



Fonte: AUTOR (2021).

A Tabela 4.4 apresenta os dados relativos ao Gráfico 4.18 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 10 dias, nela é possível observar varrições nas linhas de máxima e mínima taxa da Confiabilidade, característica consequente da frequência.de falhas.

Tabela 4.4 - Taxa de Confiabilidade prevista para 10 dias.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	12,9468	13,276	12,869	13,6121	13,0178	13,1926	12,5539	13,4648	14,4152	13,8271
MÁX	65,6272	65,0011	65,4023	65,28	65,1326	64,9444	65,4105	65,8192	65,0416	65,8859
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	14,1973	23,9565	12,8484	13,7283	13,0543	13,5501	13,4253	15,59	14,2165	14,4058
MÁX	65,9034	65,8735	65,434	65,5744	65,2681	65,3783	65,8888	65,8798	65,7432	64,877


Fonte: (AUTOR, 2021).

Na Tabela 4.3 é possível identificar variações entre 12 e 24 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 10 dias, para a linha MAX é possível observar uma variação entre 64 e 65% de a máquina operar em uma previsão de 10 dias.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 7 com 12,5539%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 11 com 65,9034%.

O Gráfico 4.19 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 15 dias, onde nele é possível identificar uma variação de 5 a 55% de Confiabilidade.

Gráfico 4.19 - Confiabilidade prevista para 15 dias.



Fonte: AUTOR (2021).

A Tabela 4.5 apresenta os dados relativos ao Gráfico 4.19 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 15 dias.

Tabela 4.5 - Taxa de Confiabilidade prevista para 15 dias.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	4,65848	4,8373	4,61657	5,02214	4,69686	4,79176	4,44805	4,9408	5,47306	5,1416
MÁX	53,165	52,406	52,8919	52,7437	52,5651	52,3374	52,9018	53,3984	52,455	53,4797
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	5,34945	11,7256	4,60545	5,08656	4,71661	4,98785	4,91909	6,15556	5,36028	5,46771
MÁX	53,501	53,4645	52,9304	53,1008	52,7293	52,8629	53,4831	53,4723	53,306	52,256

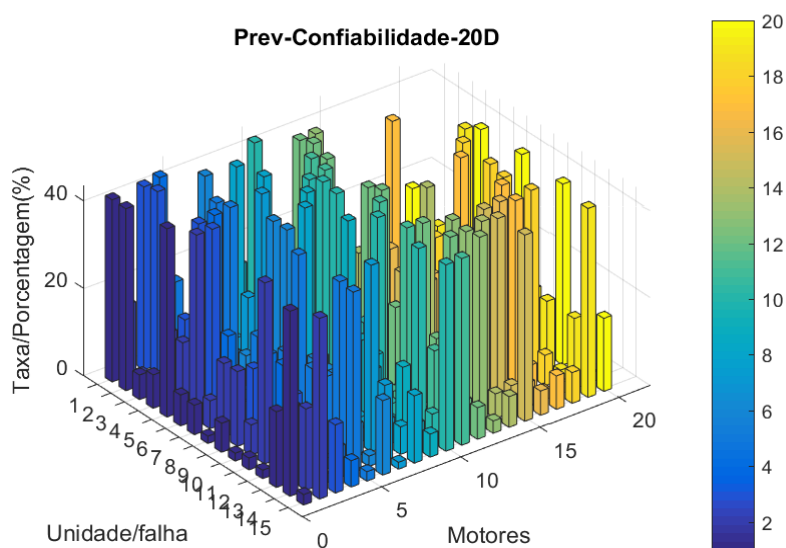
Fonte: AUTOR (2021).

Na Tabela 4.5 é possível identificar variações entre 4 e 12 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 15 dias, para a linha MAX é possível observar uma variação entre 52 e 54% de a máquina operar em uma previsão de 15 dias.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 7 com 4,44805%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 11 com 53,501%.

O Gráfico 4.20 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 20 dias, onde nele é possível identificar uma variação de 1 a 43% de Confiabilidade.

Gráfico 4.20 - Confiabilidade prevista para 20 dias.



Fonte: AUTOR (2021).

A Tabela 4.6 apresenta os dados relativos ao Gráfico 4.20 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 20 dias.

Tabela 4.6 - Taxa de Confiabilidade prevista para 20 dias.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	1,6762	1,76253	1,65612	1,8529	1,69464	1,74045	1,57601	1,813	2,07797	1,9119
MÁX	43,0693	42,2514	42,7746	42,6148	42,4226	42,1777	42,7853	43,3216	42,3041	43,4095
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	2,01564	5,73915	1,65081	1,88466	1,70414	1,83605	1,80238	2,43047	2,02108	2,07527
MÁX	43,4326	43,3931	42,8161	43	42,5993	42,7433	43,4133	43,4015	43,2217	42,0903

Fonte: (AUTOR, 2021).


Na Tabela 4.6 é possível identificar variações entre 1 e 2,45 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 20 dias, para a linha MAX é possível observar uma variação entre 42 e 44% de a máquina operar em uma previsão de 20 dias.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 7 com 1,57601%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 11 com 43,4326%.

Tendo em vista as simulações apresentadas nos Gráficos de 1, 5 10, 15 e 20 dias é notório a evidência da perda de Confiabilidade conforme o aumento da quantidade de passos à frente de previsão, em conformidade das eventuais causas ou consequências que podem ocorrer durante esses intervalos de dias que não são previstas.

Visto isso, o Gráfico 4.21 apresenta uma comparação das previsões simuladas com uma amostra de 40 unidades de falhas, considerando o motor 7, a queda de Confiabilidade se torna maior em decorrência dos passos à frente, visto que a DP20 é menor em relação à DP15 e suas antecessoras.

Gráfico 4.21 - Comparativo de previsões – MO7.



Fonte: AUTOR (2021).

Por fim, a Tabela 4.7 apresenta os valores relativos aos mínimos e máximos de cada previsão, onde o motor de número 7 é o que possui a maior probabilidade de funcionamento em cada horizonte de previsão, contudo, o motor de número 11 é o que possui a menor probabilidade de funcionamento em cada horizonte de previsão.

Tabela 4.7 - Comparativo de Mínimos e Máximos.

#	1d	5d	10d	15d	20d
Mínimo M7	81,26022	35,432	12,554	4,4481	1,576
Máximo M11	95,91594	81,181	65,903	53,501	43,433

Fonte: AUTOR (2021).

4.4 APLICAÇÃO DOS ALGORITMOS DE TREINAMENTO PARA PREVISÃO DE MESES

Esta seção apresenta os resultados da aplicação dos algoritmos de aprendizado para o melhor modelo da RNA, aplicado à previsão de 1, 3 e 5 meses, onde o conjunto de dados para treinamento da rede neural contempla: 1440 registros de falhas condensados em períodos de 12 meses para os anos de 2018 e 2019.

A Tabela 4.8 apresenta um resumo dos resultados de treinamento para cada motor, onde as colunas representam: *Motor* é o número sequencial do motor; *Algoritmo* é o algoritmo de treinamento vencedor; *NC1* é o número de neurônios da camada escondida 1; *NC2* é o número de neurônios da camada escondida 2; *FC1* é a função de transferência da camada escondida 1; *FC2* é a função de transferência da camada escondida 2; *MSE* é o Erro Médio Quadrático; *RMSE* é a Raiz do Erro Médio Quadrático; *R* é a Correlação entre as variáveis de saída e observada.

Tabela 4.8 - Algoritmos vencedores (previsão meses).

Motor	Algoritmo	NC1	NC2	FC1	FC2	MSE	RMSE	R
1	Bayesian Regularization	3	19	Linear	Tangente	1,102108	1,0498134	100
					Hiperbólica	1782069	0161333e-4e-12	
2	Fletcher-Powell Conjugate Gradient	9	4	Tangente Hiperbólica	Linear	2,664298	0,0051616	99
						3932609	84214731	
3	Bayesian Regularization	10	6	Sigmoide	Linear	2,227307	4,7194362	100
						8434280	4115006e-6e-09	
4	Bayesian Regularization	11	17	Sigmoide	Sigmoide	4,991619	7,0651395	100
						7078834	6541797e-4e-09	
5	Bayesian Regularization	4	11	Sigmoide	Tangente	5,859571	2,4206550	100
					Hiperbólica	0108432	7886672e-6e-12	
6	Bayesian Regularization	3	12	Sigmoide	Tangente Hiperbólica	7,818961 4859986 1e-13	8,8424891 7782691e-07	100


Motor	Algoritmo	NC1	NC2	FC1	FC2	MSE	RMSE	R
7	Bayesian Regularization	13	11	Tangente Hiperbólica	Linear	4,918967 3190711 0e-09	7,0135349 9960691e-05	100
8	Polak-Ribière Conjugate Gradient	9	17	Tangente Hiperbólica	Sigmoide	7,473213 1242268 3e-05	0,0086447 74794190 32	99
9	Levenberg-Marquardt	4	1	Sigmoide	Linear	4,925314 1889611 5e-10	2,2193048 8868951e-05	100
10	Levenberg-Marquardt	6	10	Linear	Tangente Hiperbólica	3,784906 3504115 2e-05	0,0061521 59255425 30	99
11	Bayesian Regularization	7	18	Tangente Hiperbólica	Sigmoide	3,622374 3002204 1e-11	6,0186163 6941615e-06	100
12	Levenberg-Marquardt	10	4	Sigmoide	Linear	1,508705 6683186 9e-07	0,0003884 20605570 648	100
13	Conjugate Gradient with Powell/Beale Restarts	1	1	Tangente Hiperbólica	Tangente Hiperbólica	8,664752 6398679 0e-05	0,0093084 65308453 32	99
14	Scaled Conjugate Gradient	4	11	Tangente Hiperbólica	Tangente Hiperbólica	5,263196 0008415 3e-06	0,0022941 65643723 56	99
15	Bayesian Regularization	20	17	Sigmoide	Linear	1,186311 9578549 5e-10	1,0891794 8835578e-05	100
16	Levenberg-Marquardt	2	10	Sigmoide	Tangente Hiperbólica	2,321058 9988622 4e-07	0,0004817 73701945 451	99
17	Levenberg-Marquardt	9	3	Linear	Sigmoide	1,070273 3599910 6e-09	3,2715032 6301390e-05	100
18	Levenberg-Marquardt	9	11	Sigmoide	Linear	1,417373 0302080 1e-05	0,0037648 01495707 33	99
19	Bayesian Regularization	18	5	Tangente Hiperbólica	Sigmoide	1,085471 5250818 7e-10	1,0418596 4749666e-05	100
20	Bayesian Regularization	19	7	Tangente Hiperbólica	Sigmoide	8,622216 7944077 5e-10	2,9363611 4849787e-05	100

Fonte: AUTOR (2021).

A Tabela 4.8 apresenta os resultados dos 20 melhores algoritmos classificados de acordo com o melhor treinamento para cada motor, nela é possível identificar que o motor 6 obteve 7,81896148599861e-13 de MSE, 8,84248917782691e-07 de RMSE e 100% de correlação entre as variáveis de saída e observada, caracterizando total proximidade com a função real projetada.

O gráfico da Figura 4.5 ilustra o comparativo de RMSE do grupo de máquinas, onde o menor valor aproximado indica a proximidade da função real, sendo este caracterizado pelo motor 6.

Figura 4.5 - Comparativo de erros do grupo de máquinas previsão meses.



Fonte: AUTOR (2021).

A configuração de RNA vencedora foi a do motor 6 com o algoritmo *Bayesian Regularization*, 3 neurônios na primeira camada escondida e 12 na segunda camada escondida, utilizando respectivamente as funções Sigmoides e Tangente Hiperbólica como ativação dos neurônios, isso permite o seu uso como melhor modelo avaliado pelo APCM.

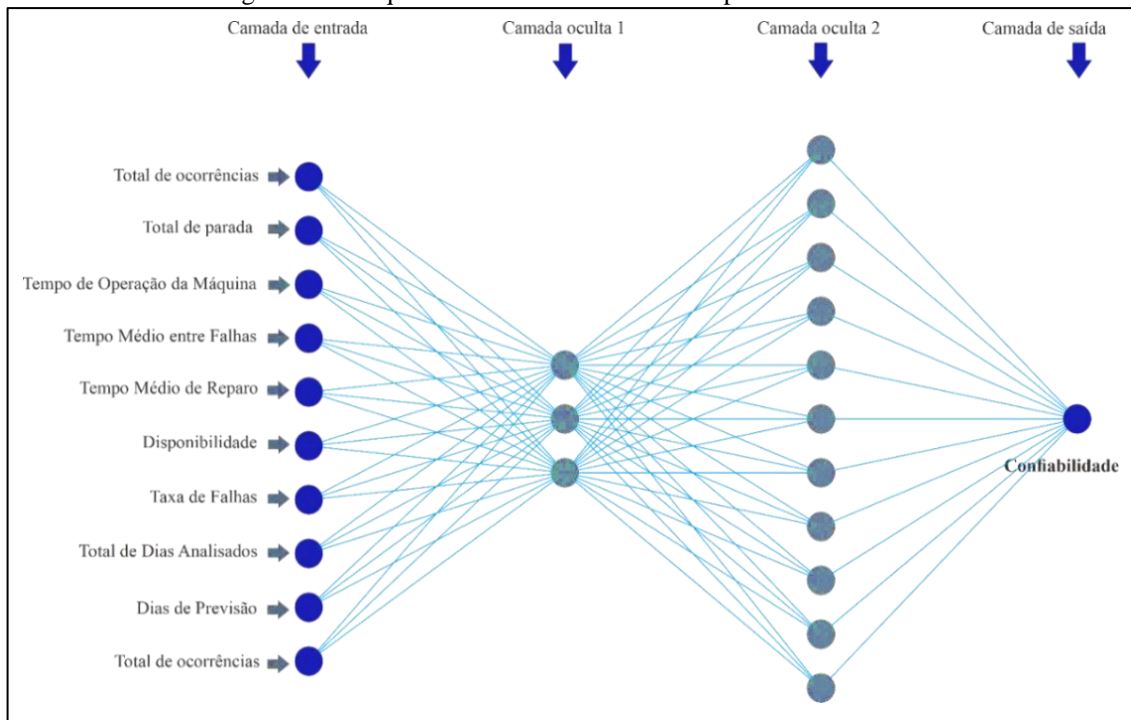
A Figura 4.6 ilustra o modelo de arquitetura da rede neural evidenciada pela RNA vencedora considerando os dados de treinamento do motor 6 ao utilizar as configurações citadas. Nesta figura possível identificar 4 fileiras que são denominadas respectivamente: camada de entrada, camada oculta 1, camada oculta 2 e camada de saída.

Em cada camada existe uma quantidade de neurônios que possuem atividades distintas, por exemplo as entradas que servem para prover valores de suas respectivas variáveis, as ocultas que servem para realizar processos e cálculos que permitam ativar outros neurônios mediante as possibilidades até se chegar na camada de saída com um determinado resultado.

O processo de convergência da rede depende dos parâmetros utilizados na modelagem da rede neural, do algoritmo de treinamento utilizado e na aplicação das funções de ativação nas camadas ocultas ou de saída. Como pode ser visto o número de neurônios demanda na taxa de

aprendizado da rede, caracterizando a eficiência na inicialização dos pesos, que em muitas vezes se dá por processos estocásticos.

Figura 4.6 - Arquitetura da RNA vencedora na previsão de meses.



Fonte: AUTOR (2021).


Tendo em vista que a melhor configuração de RNA é a do motor 6 onde foi possível alcançar um RMSE de $8,9e-07$, serão apresentados os resultados detalhados referentes a esse motor.

4.4.1 Modelo de RNA vencedora

A Figura 4.7 ilustra 4 gráficos que representam respectivamente os resultados de treino, teste e a média entre ambos proveniente do algoritmo de Regularização Bayesiana, como característica robusta, o mesmo não possui a etapa de validação, realizado apenas 2 de 3 etapas, onde cada um obteve 100% de correlação entre as variáveis de saída e simulada.

Esses valores são provenientes de uma análise de regressão linear, como já citado antes, o conjunto de dados de saída é correlacionado com o conjunto de dados simulado, provido da rede neural, dessa forma, os pontos pretos indicados em cada reta de tendência estão bem próximos caracterizando a correlação entre ambos, onde os pontos de cada variável são os mesmos.

Figura 4.7 - Regressão Linear do Algoritmo Bayesian Regularization.



Fonte: AUTOR (2021).


O primeiro gráfico representado pelo “Train” treinamento do motor 6 alcança 100% de correlação entre a variável observada e prevista, ou seja, os valores coordenados pelos eixos das abscissas e ordenadas são iguais em função das entradas inferidas na rede neural.

O segundo e terceiro gráficos também evidenciam 100% de confiabilidade na correlação entre as variáveis observada e preditora, de tal forma que a divisão de dados para executar esta etapa é realizada com o intuito de comprovar a eficiência do modelo mediante suas configurações e validar a previsão por meio de uma técnica matemática que é a Regressão Linear. O último gráfico caracterizado como “All” ou “Todos” tem como finalidade demonstrar uma média entre as etapas anteriores, onde é evidenciado 100% de correlação ou confiabilidade

A Regularização Bayesiana desempenha um papel de aprimoramento no processo de generalização, limitando a medida do peso de uma rede, se o valor do peso da rede for menor, a rede responderá de forma sutil, dessa forma, com a regularização, uma grande rede que fica simplificada deve ser capaz de representar a função real.

O Gráfico 4.22 apresenta o resultado de melhor performance do motor 6, onde o tempo de convergência do algoritmo é levado em consideração, isso se dá pela descida ou ajuste da curva de deslizamento, a cada época realizada o tempo de convergência aumenta, de acordo com o gráfico o algoritmo levou 119 épocas para encontrar o melhor estado de convergência, ou seja, é o estado ótimo de convergência do algoritmo para atingir uma constante na reta de aprendizado.

Gráfico 4.22 - Análise da performance previsão meses.




Fonte: AUTOR (2021).

O Gráfico 4.23 apresenta uma análise comparativa do motor 6 entre os erros capturados em cada época do modelo de previsão, onde a menor taxa de erro é localizada na linha vertical de cor laranja na barra $1,83e-08$.

Os erros são ajustados ao longo das épocas, como é demonstrado no Gráfico 4.23, é possível afirmar que desde o primeiro erro o ajuste é realizado e centralizado, de tal forma que a linha em destaque vertical evidencia a menor taxa ao variar em um intervalo de $-2.8e-06$ a $3.19e-06$ e uma quantidade instâncias que tende a variar em um intervalo de 0 a 18.

Gráfico 4.23 - Histograma de erro Motor 6 previsão meses.




Fonte: AUTOR (2021).

4.4.2 Indicadores da Gestão da Manutenção

O Gráfico 4.24 apresenta uma análise da Confiabilidade do Motor 6 no ano de 2018, onde é considerado um conjunto de 12 falhas referentes aos doze meses, variando em uma porcentagem de 88,5 a 91%.

Neste gráfico é possível identificar as variações em cada mês de forma estabilizada, contudo, entre os meses 6 e 8 há uma queda na ocorrência de falhas, acarretando em uma taxa de confiabilidade maior em relação aos outros meses.


Gráfico 4.24 - Análise da Confiabilidade - MO6.



Fonte: AUTOR (2021).

O Gráfico 4.25 apresenta uma análise da Disponibilidade do Motor 6 no ano de 2018, onde é analisado um conjunto de 12 meses, variando em uma porcentagem de 92 a 94,5 %. Em comparação ao gráfico de Confiabilidade, este apresenta uma tendência no aumento da disponibilidade nos meses 6, 7, 8, 11 e 12 alcançando taxas como 94%.


Gráfico 4.25 - Análise da Disponibilidade - MO6.



Fonte: AUTOR (2021).

O Gráfico 4.26 apresenta uma análise da Confiabilidade do Motor 6 no ano de 2019, onde é considerado um conjunto de 12 meses, variando em uma porcentagem de 88,5 a 92,5 %. Neste gráfico é possível identificar uma queda na confiabilidade ao longo dos meses, onde a maior baixa é alcançada no mês 5 com 88,5 %, isso é explicado pela frequência de falhas que tende a baixar esse indicador conforme as ocorrências aumentam.


Gráfico 4.26 - Análise da Confiabilidade 2019 - MO6.



Fonte: AUTOR (2021).

O Gráfico 4.27 apresenta uma análise da Disponibilidade do Motor 6 no ano de 2019, onde é considerado um conjunto de 12 meses, variando em uma porcentagem de 91 a 94,6 %. Tendo em vista o gráfico de Confiabilidade, este validada as altas taxas de variações, onde a frequência de falhas se torna menor ao longo dos meses, a menor taxa é encontrada no mês 6 com 91 %.


Gráfico 4.27 - Análise da disponibilidade 2019 - MO6.



Fonte: AUTOR (2021).

Considerando os eventos da análise de Disponibilidade e Confiabilidade nos anos de 2018 e 2019, torna-se válido abordar sobre as taxas de falhas em função dos respectivos anos ao longo de 12 meses. O Gráfico 4.28 apresenta uma análise comparativa da taxa de parada adquirida em função do MTBF, ou seja, do tempo em horas, o gráfico apresenta os resultados referentes ao ano de 2018, nele é possível identificar que o mês de junho obteve uma taxa de 57% de indisponibilidade e o de mês de dezembro obteve uma taxa de 63% de disponibilidade.


Gráfico 4.28 - Taxa de parada ano 2018 – MO6.



Fonte: AUTOR (2021).

O Gráfico 4.29 apresenta uma análise comparativa da disponibilidade e indisponibilidade em relação ao ano de 2019, onde nele é possível identificar que o mês de fevereiro obteve uma taxa de 58% de indisponibilidade e o mês de janeiro obteve uma taxa de 62% de disponibilidade.


Gráfico 4.29 - Taxa de parada ano 2019 – MO6.



Fonte: AUTOR (2021).

O Gráfico 4.30 apresenta uma análise comparativa do ano de 2018 em função do tempo de parada e total de frequência, onde nele é possível identificar a diferença entre os indicadores, como já citado o mês de março possui a maior taxa, contudo, a frequência é maior que o tempo de parada com uma relação de 57,3 h para 80 ocorrências, caracterizando uma consistência na quantidade de falhas.


Gráfico 4.30 - Análise comparativa do TP e TF em 2018 – MO6.



Fonte: AUTOR (2021).

O Gráfico 4.31 apresenta a relação do tempo de parada e total de frequência do mês de março de 2018, considerando o mês de forma isolada, percebe-se que a frequência alcança taxas maiores em relação ao tempo de parada, isso explica o fato de se ter uma frequência maior com tempo de parada menor para cada unidade de falha.


Gráfico 4.31 - Relação do TP e TF do mês de março de 2018 – MO6.



Fonte: AUTOR (2021).

O Gráfico 4.32 apresenta uma análise comparativa do ano de 2019 em função do tempo de parada e total de frequência, onde nele é possível identificar a diferença entre os indicadores, como já citado o mês de fevereiro possui a maior taxa de parada, contudo, a frequência é maior que o tempo de parada no mês de maio, com uma relação de 58,1 h para 73 ocorrências.

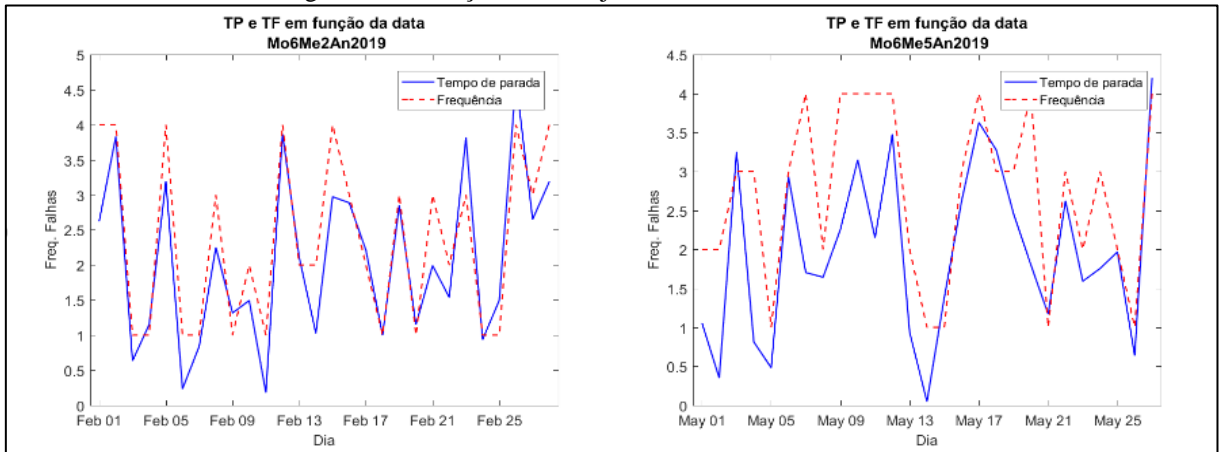
Gráfico 4.32 - Análise comparativa do TP e TF em 2019 – MO6.



Fonte: AUTOR (2021).

A Figura 4.8 apresenta a relação do tempo de parada (lado esquerdo) e total de frequência (lado direito) do mês de fevereiro e maio respectivamente, a fim de analisar o contexto do tempo de parada, onde há uma similaridade no comportamento das duas séries em, ocasionando uma correlação entre ambos. E o contexto da frequência do mês de maio, que tende a ter valores maiores em função do número de ocorrências.

Figura 4.8 - Relação TP e TF janeiro e maio de 2019 - MO6.




Fonte: AUTOR (2021).

4.4.3 Simulações para 1, 3 e 5 meses

Nesta seção são apresentados os principais resultados referentes às simulações do algoritmo APCM com o melhor modelo de RNA, onde é previsto a taxa de Confiabilidade para 1, 3 e 5 meses, é válido ressaltar que a correlação entre as variáveis de saída é 100% caracterizando a confiança do algoritmo, isso é mostrado no Gráfico 4.33, onde é apresentado uma comparação entre o modelo simulado e calculado.


Gráfico 4.33 - Comparativo entre o modelo simulado e calculado para 1 mês.



Fonte: AUTOR (2021).

O Gráfico 4.34 apresenta uma comparação da Confiabilidade do grupo de 20 motores, onde é relacionado uma amostra de 15 unidades de falhas para representar a taxa em porcentagem, nele é possível identificar uma variação de 87 a 92% de Confiabilidade para o modelo de previsão de 1 mês.

Gráfico 4.34 - Confiabilidade prevista para 1 mês.



Fonte: AUTOR (2021).

A Tabela 4.9 apresenta os dados relativos ao Gráfico 4.34 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 1 mês.

Tabela 4.9 - Taxa de Confiabilidade prevista para 1 mês.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	87,90171	88,45322	87,96779	87,43659	87,77889	88,49822	87,65488	87,68537	88,3474	86,90909
MAX	90,47025	90,39174	92,40976	91,48236	91,08229	90,96599	90,47925	91,17645	90,93395	90,47714
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	88,0592	87,47487	88,53408	88,07932	88,70764	88,24632	86,84718	88,62843	88,02934	88,3246
MAX	90,86769	90,20478	90,5151	90,46107	90,69421	90,24283	91,46181	91,29457	90,23228	90,46409

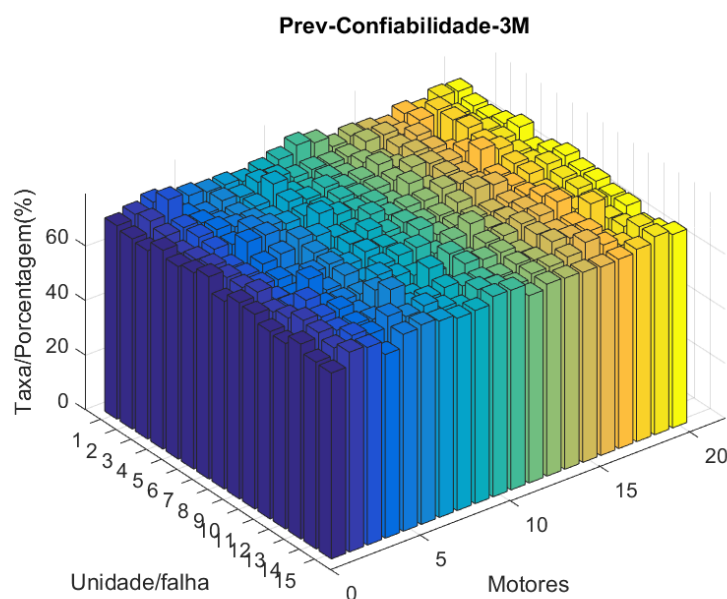
Fonte: AUTOR (2021).

Na Tabela 4.9 é possível identificar variações entre 86 e 88,7 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 1 mês, para a linha MAX é possível observar uma variação entre 90 e 93% de a máquina operar em uma previsão de 1 mês.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 17 com 86,85%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 3 com 92,41%.

O Gráfico 4.35 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 3 meses, onde nele é possível identificar uma variação de 66 a 78% de Confiabilidade.

Gráfico 4.35 - Confiabilidade prevista para 3 meses.



Fonte: AUTOR (2021).

A Tabela 4.10 apresenta os dados relativos ao Gráfico 4.35 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 3 meses.

Tabela 4.10 - Taxa de Confiabilidade prevista para 3 meses.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	67,9191	69,20555	68,07239	66,84665	67,63481	69,31122	67,34855	67,41887	68,95747	65,64408
MAX	74,04868	73,85608	78,91391	76,5618	75,56171	75,27265	74,07078	75,79631	75,19313	74,06561
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	68,28483	66,93449	69,39551	68,33163	69,80446	68,72107	65,50389	69,61763	68,21539	68,90411
MAX	75,02888	73,39875	74,15886	74,02615	74,59998	73,49166	76,51021	76,09128	73,4659	74,03358

Fonte: AUTOR (2021).


Na Tabela 4.10 é possível identificar variações entre 65 e 70 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 3 meses, para a linha MAX é possível observar uma variação entre 73 e 79% de a máquina operar em uma previsão de 3 meses.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 17 com 65,50%. Contudo, o motor que obteve a maior taxa de

Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 3 com 78,91%.

O Gráfico 4.36 apresenta uma análise comparativa da Confiabilidade do grupo de 20 motores considerando o modelo de previsão de 5 meses, onde nele é possível identificar uma variação de 50 a 66% de Confiabilidade.

Gráfico 4.36 - Confiabilidade prevista para 5 meses.



Fonte: AUTOR (2021).

A Tabela 4.11 apresenta os dados relativos ao Gráfico 4.36 da previsão de Confiabilidade do grupo de 20 motores. A tabela apresenta os mínimos e máximos em uma escala de 0 a 100% em conformidade com a proposta de previsão, neste caso 5 meses.

Tabela 4.11 - Taxa de Confiabilidade prevista para 5 meses.

MOTOR	1	2	3	4	5	6	7	8	9	10
MIN	52,47912	54,14623	52,67667	51,10531	52,11352	54,28409	51,74643	51,83651	53,82311	49,58222
MAX	60,60785	60,34534	67,38904	64,07475	62,68586	62,2867	60,638	63,01057	62,17708	60,63095
MOTOR	11	12	13	14	15	16	17	18	19	20
MIN	52,95094	51,21729	54,39417	53,01145	54,92945	53,51594	49,40587	54,68464	52,86123	53,75372
MAX	61,95088	59,72385	60,75823	60,57711	61,36177	59,8499	64,00281	63,41979	59,81495	60,58725

Fonte: AUTOR (2021).

Na Tabela 4.11 é possível identificar variações entre 49 e 55 % para a linha MIN em função da probabilidade de a máquina operar em uma previsão de 5 meses, para a linha MAX é possível observar uma variação entre 59 e 68% de a máquina operar em uma previsão de 5 meses.

O motor que obteve a menor taxa de Confiabilidade dentro considerando o grupo de máquinas foi o de número 17 com 49,41%. Contudo, o motor que obteve a maior taxa de Confiabilidade ao considerar o espaço amostral de 15 unidades de falhas com 20 motores foi o de número 3 com 67,39%.


Tendo em vista as simulações apresentadas nos Gráficos de 1, 3 e 5 meses é possível identificar uma perda na taxa de Confiabilidade, conforme o aumento da quantidade de passos à frente de previsão, em conformidade das eventuais causas ou consequências que podem ocorrer durante esses intervalos de meses que não são previstas.

Visto isso, o Gráfico 4.37 apresenta uma comparação das previsões simuladas com uma amostra de 24 unidades de falhas, onde é considerado os anos de 2018 e 2019, tendo em vista o motor 6, a queda de Confiabilidade se torna maior em decorrência dos passos à frente, visto que a MP5 é menor em relação à MP3 e MP1.

Entre os dois primeiros meses de previsão relativos ao motor 6, é possível identificar taxas menores em relação aos 24 meses, o Gráfico 4.35 demonstra essas variações, além disso, os meses 16,17 e 18 também apresentam tendências de baixa confiabilidade em função da frequência de falhas.

De acordo com o Gráfico 4.35 o mês que apresenta picos, ou seja, valores significativos para confiabilidade em função dos 24 meses, é o mês 13, em virtude disso, é possível afirmar que neste mês o motor 6 tem a maior probabilidade de operar com disponibilidade mediante a taxa de confiabilidade e o horizonte de previsão.

Gráfico 4.37 - Comparativo de previsões.



Fonte: AUTOR (2021).

Por fim, a Tabela 4.12 apresenta os valores relativos aos mínimos e máximos de cada previsão, onde o motor de número 17 é o que possui a maior probabilidade de funcionamento em cada horizonte de previsão, contudo, o motor de número 3 é o que possui a menor probabilidade de funcionamento em cada horizonte de previsão.

Tabela 4.12 - Comparativo de Mínimos e Máximos.

#	1m	3m	5m
Mínimo M17	92,40976	65,50389	49,40587
Máximo M3	86,84718	78,91391	67,38904

Fonte: AUTOR (2021).

CAPÍTULO 5

5 CONCLUSÕES E SUGESTÕES

Este capítulo apresenta as considerações finais em relação à pesquisa e as principais sugestões para trabalhos futuros.

5.1 CONCLUSÕES

Esta dissertação se propôs a apresentar o desenvolvimento de um modelo computacional focado na previsão em dias e meses da Confiabilidade de um grupo de máquinas de combustão interna utilizando aprendizado de máquina por meio das técnicas de Redes Neurais Artificiais (RNA). Neste contexto foram levantadas algumas questões acerca da aplicabilidade do algoritmo para a solução da melhoria nos programas de manutenção com uma ferramenta de apoio à tomada de decisão.

A catalogação das variáveis significativas providas de documentos de falhas permitiu o amadurecimento do modelo computacional por meio de testes e processamento de indicadores da gestão manutenção.

A análise dos doze algoritmos de aprendizado para treinamento das diferentes combinações de modelos de previsão, mostrou-se eficiente, alcançando resultados iguais ou próximos de 100% de correlação entre as variáveis de saída observada e prevista. Além disso, os modelos vencedores obtiveram resultados satisfatórios para previsão da Confiabilidade, uma vez que, as taxas de erros em relação à aproximação da função real são próximas de 0.

Um dos aspectos importantes a serem destacados é o uso de métodos de otimização, iterativos e heurísticos para o treinamento da RNA que torna viável mediante o custo computacional. Outro aspecto é viabilidade de previsão com 100% de confiança no treinamento ao analisar a correlação entre as variáveis de saída e simuladas para o problema de convergência da rede.

O desenvolvimento do modelo computacional trouxe inovações com o uso de modelos de previsão para estimar a Confiabilidade do grupo de máquinas uma vez que métodos de otimização, iterativos e heurísticos foram aplicados, no entanto, os métodos de otimização

como o *Levenberg–Marquardt* que possibilita o ajuste de curvas pela solução dos mínimos quadrados, foi melhor em relação aos outros.

Entretanto, a seleção do melhor modelo e melhor algoritmo é adquirido por meio de análises de erro, o ajuste do erro se dá pelo tempo de convergência da rede, onde os métodos a quantidade de neurônios, camadas escondidas e funções de ativação foram elementos essenciais para a definição de arquiteturas robustas para prever o conjunto de dados inferido na RNA.

Por fim, a simulação dos dados e previsão da confiabilidade permitiu o desenvolvimento de análises apuradas acerca da eficiência do grupo de motores, além disso os indicadores de gestão da manutenção foram elementos essenciais para embasar o fundamento dos resultados alcançados com gráficos e comparações referentes ao tempo de parada, quantidade de ocorrências de falhas, MTBF, MTTR, taxa de falha, disponibilidade e confiabilidade, considerando o grupo e as unidades de despacho de carga.

Em suma, os resultados aqui apresentados são satisfatórios por cumprirem com os objetivos estabelecidos e se mostram benéficos para aplicação na manutenção preditiva com o uso de técnicas de Redes Neurais Artificiais (RNA).

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Considerando o constructo da pesquisa e os resultados alcançados, é possível considerar alguns elementos de sugestões para pesquisas futuras, sendo eles:

- a) Implementação de métodos bio-inspirados e de otimização para o treinamento da RNA como: *Particle Swarm Optimization (PSO)*, *Genetic Algorithm (GA)*, *Simulated annealing (AG)*, *Grey Wolf Optimizer (GWA)*, *Whale Optimization Algorithm (WOA)*, *Ant Lion Optimizer (ALO)* e outros para analisar o estado de convergência da RNA;
- b) Implementação de arquiteturas de Redes Neurais Convolucionais ou Recorrentes para previsão de outros indicadores e realizar análises de performance em relação ao modelo desenvolvido nesta dissertação;
- c) Avaliar novos indicadores da gestão da manutenção como: Custo de manutenção sobre faturamento, Custo de manutenção sobre valor de reposição e *Backlog* para inferir na entrada da RNA;
- d) Desenvolver um sistema híbrido utilizando *Neuro Fuzzy* para avaliar os diferentes níveis de inferências das variáveis levantadas relativas aos motores considerando a eficiência de cada e considerar o uso de modelos como: SNF, ANFIS, NEFCLASS e FSOM;

- e) Readaptar a base de dados com procedimentos de normalização para identificar e apontar futuras falhas em equipamentos do motor por meio de Mapas de *Kohonen* ou Rede Neural de *Hopfield*.

REFERÊNCIAS

AHMED, Huda I.; HAMED, Eman T.; SAEED CHILMERAN, Hamsa Th. A Modified Bat Algorithm with Conjugate Gradient Method for Global Optimization. **International Journal of Mathematics and Mathematical Sciences**, v. 2020, 2020.

AL DAKHEEL, Joud *et al.* Smart buildings features and key performance indicators: A review. **Sustainable Cities and Society**, p. 102328, 2020.

ANDREI, Neculai. Three-Term Conjugate Gradient Methods. In: *Nonlinear Conjugate Gradient Methods for Unconstrained Optimization*. **Springer**, Cham, 2020. p. 311-347.

BULAGHI, Zohre Arabi *et al.* World competitive contest-based artificial neural network: A new class-specific method for classification of clinical and biological datasets. **Genomics**, v. 113, n. 1, p. 541-552, 2021.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 5462: confiabilidade e manutenibilidade - terminologia**. Rio de Janeiro, 1994.

AWANG, Mohd Naim *et al.* Main Propulsion Marine Diesel Engine Condition Based Maintenance Monitoring Using Ultrasound Signal. In: **Advancement in Emerging Technologies and Engineering Applications**. Springer, Singapore, 2020. p. 175-187.

AYVAZ, Serkan; ALPAY, Koray. Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. **Expert Systems with Applications**, v. 173, p. 114598, 2021.

BAI, Bin *et al.* Fault data screening and failure rate prediction framework-based bathtub curve on industrial robots. **Industrial Robot: the international journal of robotics research and application**, 2020.

BANDYOPADHYAY, Samir; DUTTA, Shawni. Early Lung Cancer Prediction Using Neural Network with Cross-Validation. **Preprints**. 2020.

BAU, David *et al.* Understanding the role of individual units in a deep neural network. **Proceedings of the National Academy of Sciences**, v. 117, n. 48, p. 30071-30078, 2020.

BHADANI, Kanishk *et al.* Development and implementation of key performance indicators for aggregate production using dynamic simulation. **Minerals Engineering**, v. 145, p. 106065, 2020.

BILSKI, Jarosław *et al.* Local Levenberg-Marquardt algorithm for learning feedforward neural networks. **Journal of Artificial Intelligence and Soft Computing Research**, v. 10, 2020.

BORHANI, Mostafa. Multi-label Log-Loss function using L-BFGS for document categorization. **Engineering Applications of Artificial Intelligence**, v. 91, p. 103623, 2020.

CANÁRIO, João Paulo *et al.* In-depth comparison of deep artificial neural network architectures on seismic events classification. **Journal of Volcanology and Geothermal Research**, v. 401, p. 106881, 2020.

CARVALHO, Helton Vieira de. **SIMULAÇÃO E ANÁLISE DE UM MOTOR QUATRO TEMPOS A DIESEL**. 2020. 61p. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Universidade Federal do Rio Grande do Norte, Natal-RN, 2020.

CORREA, Rafaela Gomide. **Estudo numérico do escoamento de ar em um motor de combustão interna**. 2020. 56 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Universidade Federal de Uberlândia, Uberlândia, 2020.

DA SILVA, Juliano Coelho. **Termografia aplicada A Manutenção Industrial**. Clube de Autores (managed), 2020.

Dall’Agnese, M. A. **Análise da confiabilidade da manutenção em tratores de uma empresa de produção agrícola**. 2020. 25 páginas. Monografia de Trabalho de Conclusão do Curso em Engenharia Mecânica – Curso de Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.

DE RUBIO, José Jesús. Stability analysis of the modified Levenberg-Marquardt algorithm for the artificial neural network training. **IEEE Transactions on Neural Networks and Learning Systems**, 2020.

DINARDI, Phellipe Tocchetto; DA COSTA, Keven Soares; TORNÉ, Israel Gondres. Termografia em um contexto de manutenção industrial eficiente. **Na era da Automação** Volume, p. 48. 2020.

EGIDIO, Lucas N.; HANSSON, Anders; WAHLBERG, Bo. Learning the Step-size Policy for the Limited-Memory Broyden-Fletcher-Goldfarb-Shanno Algorithm. **arXiv preprint arXiv:2010.01311**, 2020.

ERKAYMAZ, Okan. Resilient back-propagation approach in small-world feed-forward neural network topology based on Newman–Watts algorithm. **Neural Computing and Applications**, v. 32, n. 20, p. 16279-16289, 2020.

FARIZAWANI, A. G. *et al.* A review of artificial neural network learning rule based on multiple variant of conjugate gradient approaches. **In: Journal of Physics: Conference Series**. IOP Publishing, 2020. p. 022040.

FONSECA-JUNIOR, M. *et al.* Programa de gestão de manutenção a través de la implementación de herramientas predictivas y de TPM como contribución a la mejora de la eficiencia energética en plantas termoeléctricas. **Dyna**, v. 82, n. 194, p. 139-149, 2015.

GARCIA, Alioska Jessica Martinez *et al.* **Análise do sistema de indicadores de gestão da manutenção de pavimentos flexíveis em vias urbanas da cidade de Curitiba–PR**. 2020. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

GIRIT, Oguz; ATAKOK, Gurcan; ERSOY, Sezgin. Data Analysis for Predictive Maintenance of Servo Motors. **Shock and Vibration**, v. 2020, 2020.

GOKSU, Burak; ERGINER, Kadir Emrah. Prediction of Ship Main Engine Failures by Artificial Neural Networks. **Journal of ETA Maritime Science**, v. 8, n. 2, p. 98-113, 2020.

GONÇALVES, Daniel Resende *et al.* Monitoramento de integridade estrutural baseado em impedância eletromecânica utilizando o método de krigagem ordinária. **HOLOS**, v. 2, p. 1-16, 2020.

GONÇALVES, Tiago Miguel Alves *et al.* **Análise de sistemas de energia e máquinas eléctricas com recurso a termografia**. 2011.

HELLER, D.; SEVER, I. A.; SCHWINGSHACKL, C. W. A method for multi-harmonic vibration analysis of turbomachinery blades using Blade Tip-Timing and clearance sensor waveforms and optimization techniques. **Mechanical Systems and Signal Processing**, v. 142, p. 106741, 2020.

IZQUIERDO, Juan *et al.* On the importance of assessing the operational context impact on maintenance management for life cycle cost of wind energy projects. **Renewable Energy**, v. 153, p. 1100-1110, 2020.

JIMÉNEZ, Alfredo Arcos *et al.* Maintenance management based on Machine Learning and nonlinear features in wind turbines. **Renewable Energy**, v. 146, p. 316-328, 2020.

KOÇAK, Yılmaz; ŞIRAY, Gülesen Üstündağ. New activation functions for single layer feedforward neural network. **Expert Systems with Applications**, v. 164, p. 113977, 2021.

KRISHNAVENI, S. *et al.* Analysis and control of the motor vibration using arduino and machine learning model. **Materials Today: Proceedings**, v. 45, p. 2551-2555, 2021.

KUMAR, D. Arul; JAYANTHY, T. Application of back propagation artificial neural network in detection and analysis of diabetes mellitus. **Journal of Ambient Intelligence and Humanized Computing**, p. 1-8, 2020.

KUMAR, Gourav; JAIN, Sanjeev; SINGH, Uday Pratap. Stock market forecasting using computational intelligence: A survey. **Archives of Computational Methods in Engineering**, v. 28, n. 3, p. 1069-1101, 2021.

LIN, Qing *et al.* Prediction of Maximum Flood Inundation Extents With Resilient Backpropagation Neural Network: Case Study of Kulmbach. **Smart Approaches to Predict Urban Flooding: Current Advances and Challenges**, 2021.

LOH, Eng Chuen *et al.* Comparison of Feedforward Neural Network with Different Training Algorithms for Bitcoin Price Forecasting. **ASM Science Journal**, 2020.

LOYARTE-LÓPEZ, Edurne *et al.* Enhancing Researchers' Performance by Building Commitment to Organizational Results. **Research-Technology Management**, v. 63, n. 2, p. 46-54, 2020.

LU, Xue-Qin *et al.* Metaheuristics for homogeneous and heterogeneous machine utilization planning under reliability-centered maintenance. **Computers & Industrial Engineering**, v. 151, p. 106934, 2021.

LUGHOFER, Edwin; SAYED-MOUCHAWEH, Moamar. **Predictive maintenance in dynamic systems: advanced methods, decision support tools and real-world applications**. Springer, 2019.

LUO, Weichao *et al.* A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. **Robotics and Computer-Integrated Manufacturing**, v. 65, p. 101974, 2020.

MARQUEZ, Adolfo Crespo *et al.* Maintenance Management through Intelligent Asset Management Platforms (IAMP). Emerging Factors, Key Impact Areas and Data Models. **Energies**, v. 13, n. 15, p. 3762, 2020.

MARTINS, L. *et al.* Improving Preventive Maintenance Management in an Energy Solutions Company. **Procedia Manufacturing**, v. 51, p. 1551-1558, 2020.

MARTINS, Thomas. **Análise modal de vibrações de um motor de combustão interna: enfoque em um sistema monocilíndrico de quatro tempos**. 2017. 49 f. Trabalho de Conclusão de Curso (Graduação) – Universidade Tecnológica Federal do Paraná, Guarapuava, 2017.

MASRI, Sami F.; CAFFREY, John P. Response of a multi-degree-of-freedom system with a pounding vibration neutralizer to harmonic and random excitation. **Journal of Sound and Vibration**, v. 481, p. 115427, 2020.

MEIßNER, Christian *et al.* Investigation on wall and gas temperatures inside a swirled oxy-fuel combustion chamber using thermographic phosphors, O₂ rotational and vibrational CARS. **Fuel**, v. 289, p. 119787, 2021.

MELLAH, Hacene; HEMSAS, Kamel Eddine; TALEB, Rachid. Cascade-Forward Neural Network Based on Resilient Backpropagation for Simultaneous Parameters and State Space Estimations of Brushed DC Machines. **arXiv preprint arXiv:2104.04348**, 2021.

MOKTADIR, Md Abdul *et al.* An investigation of key performance indicators for operational excellence towards sustainability in the leather products industry. **Business Strategy and the Environment**, v. 29, n. 8, p. 3331-3351, 2020.

MORO, Giancarlo Dal. **Efficient Joint Analysis of Surface Waves and Introduction to Vibration Analysis: Beyond the Clichés**. Springer Nature, 2020.

MUTLAG, Sattar A.; DAWOOD, H. K. A Maintenance Management-based Decision Support System for Multicriteria using AHP Methodology for Power Plants. **TEST Engineering & Mangement**, v. 82, p. 10146-10153, 2020.

OHTA, Robison; SALOMON, Valerio AP; SILVA, Messias B. Classical, fuzzy, hesitant fuzzy and intuitionistic fuzzy analytic hierarchy processes applied to industrial maintenance management. **Journal of Intelligent & Fuzzy Systems**, v. 38, n. 1, p. 601-608, 2020.

OU, Yue *et al.* Thermal Analysis of Electron Gun for Terahertz Traveling Wave Tubes Based on L-BFGS Algorithm. **In: 2020 IEEE MTT-S International Conference on Numerical Electromagnetic and Multiphysics Modeling and Optimization (NEMO)**. IEEE, 2020. p. 1-4.

PANG, Zhihong; NIU, Fuxin; O'NEILL, Zheng. Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons. **Renewable Energy**, v. 156, p. 279-289, 2020.

PEPRAH, Michael Stanley; LARBI, Edwin Kojo. Lake Water Level Prediction Model Based on Artificial Intelligence and Classical Techniques—An Empirical Study on Lake Volta Basin, Ghana. **International Journal of Earth Sciences Knowledge and Applications**, v. 3, n. 2, p. 134-150, 2021.

PIRES, Caique Aparecido; OKADA, Roberto Hirochi. MANUTENÇÃO PREDITIVA: estratégia de produção e redução de custos. **Revista Interface Tecnológica**, v. 17, n. 1, p. 635-647, 2020.

RAHMAN, M. Fadly; DARMAWIDJADJA, M. Ilham; ALAMSAH, Dion. Klasifikasi untuk diagnosa diabetes menggunakan metode bayesian regularization neural network (rbnn). **J. Inform**, v. 11, n. 1, p. 36, 2017.

RAMANUJAN, Vivek *et al.* What's Hidden in a Randomly Weighted Neural Network?. **In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. 2020. p. 11893-11902.

RAMIREZ, Isaac Segovia; MARQUEZ, Fausto Pedro Garcia. Fault Detection and Identification for Maintenance Management. **In: International Conference on Management Science and Engineering Management**. Springer, Cham, 2020. p. 460-469.

RIZZO, Igor Vilela; CANATO, Robson Leandro Carvalho. INTELIGÊNCIA ARTIFICIAL: FUNÇÕES DE ATIVAÇÃO. **Prospectus**, v. 2, n. 2, p. 51-65, 2020.

ROTH, Jonathan; BROWN IV, Howard Alexander; JAIN, Rishree K. Harnessing smart meter data for a Multitiered Energy Management Performance Indicators (MEMPI) framework: A facility manager informed approach. **Applied Energy**, v. 276, p. 115435, 2020.

SELVIK, Jon Tommeras; STANLEY, Ian; ABRAHAMSEN, Eirik Bjorheim. Critérios SMART para avaliação da qualidade de indicadores-chave de desempenho usados na indústria de petróleo e gás. **International Journal of Performability Engineering**, v. 16, n. 7, 2020.

SELWYN, T. Sunder; HEMALATHA, S. Experimental analysis of mechanical vibration in 225 kW wind turbine gear box. **Materials Today: Proceedings**, 2020.

SHAMAYLEH, Abdulrahim; AWAD, Mahmoud; FARHAT, Jumana. IoT based predictive maintenance management of medical equipment. **Journal of medical systems**, v. 44, n. 4, p. 1-12, 2020.

SHI, Hao-Jun Michael *et al.* On the Numerical Performance of Derivative-Free Optimization Methods Based on Finite-Difference Approximations. **arXiv preprint arXiv:2102.09762**, 2021.

SILVA, Daisy Paes. **Gap de integralidade das variáveis discretas para a resolução do problema de fluxo de potência ótimo reativo**. 2020.

SINGH, Pardeep *et al.* Sustainability of maintenance management practices in hydropower plant: A conceptual framework. **Materials Today: Proceedings**, v. 28, p. 1569-1574, 2020.

SINGLA, Pardeep; DUHAN, Manoj; SAROHA, Sumit. Solar irradiance forecasting using elman neural network with different training algorithms. **International Conference on Sustainable Development in Technology for 4th industrial Revolution**. 2021.

SOBRAL, Nuno Viriato Reiner. **Implementação de um sistema computadorizado de gestão da manutenção em ambiente industrial**. 2020. Tese de Doutorado.

SOLTANALI, Hamzeh *et al.* A comparative study of statistical and soft computing techniques for reliability prediction of automotive manufacturing. **Applied Soft Computing**, v. 98, p. 106738, 2021.

SOUZA, Calebe Paiva Gomes De *et al.* Performance comparison of non-adaptive and adaptive optimization algorithms for artificial neural network training applied to damage diagnosis in civil structures. **Applied Soft Computing**, p. 107254, 2021.

SUGANTHAN, P. N.; KATUWAL, Rakesh. On the origins of randomization-based feedforward neural networks. **Applied Soft Computing**, p. 107239, 2021.

SULAIMAN, I. M. *et al.* The convergence properties of some descent conjugate gradient algorithms for optimization models. **Journal of Mathematics and Computer Science**, v. 22, n. 3, p. 204-215, 2020.

TEOH, Yew Heng *et al.* Performance, Emissions, Combustion and Vibration Analysis of a CI Engine Fueled with Coconut and Used Palm Cooking Oil Methyl Ester. **Processes**, v. 8, n. 8, p. 990, 2020.

TIAN, Hua; LIU, Peng; SHU, Gequn. Challenges and opportunities of Rankine cycle for waste heat recovery from internal combustion engine. **Progress in Energy and Combustion Science**, v. 84, p. 100906, 2021.

TIWARI, Rajdev; AGRAWAL, Krishna Kant. Normalized Cepstral Coefficients based Isolated Word Recognition for Oral-tradition Tribal Languages using Scaled Conjugate Gradient Method. **J. Crit. Rev.**, v. 7, p. 2097-2107, 2020.

UPAKA, RATHNAYAKE. Comparison of different artificial neural network (ANN) training algorithms to predict the atmospheric temperature in Tabuk, Saudi Arabia. **Mausam**, v. 71, n. 2, p. 233-244, 2020.

YUAN, Gonglin; LU, Junyu; WANG, Zhan. The PRP conjugate gradient algorithm with a modified WWP line search and its application in the image restoration problems. **Applied Numerical Mathematics**, v. 152, p. 1-11, 2020.

ZHANG, Yun; MA, Hui; XU, Jianliang. Neural network-based fuzzy vibration controller for offshore platform with random time delay. **Ocean Engineering**, v. 225, p. 108733, 2021.

ZONTA, Tiago *et al.* Predictive maintenance in the Industry 4.0: A systematic literature review. **Computers & Industrial Engineering**, p. 106889, 2020.

ZOU, Guang *et al.* Fatigue inspection and maintenance optimization: A comparison of information value, life cycle cost and reliability based approaches. **Ocean Engineering**, v. 220, p. 108286, 2021.

APÊNDICES

APÊNDICE A – ARTIGO PUBLICADO

Artigo publicado na revista *International Journal for Innovation Education and Research* (IJIER) – ISSN:2411-2933, com Qualis Capes A2.

“Bayesian Regularizers of Artificial Neural Networks applied to the reliability forecast of internal combustion machines in the short-term”

DOI: <https://doi.org/10.31686/ijier.vol9.iss5.3111>

Ítalo Rodrigo Soares Silva, Manoel Henrique Reis Nascimento, Milton Fonseca Júnior,
Ricardo Silva Parente, Paulo Oliveira Siqueira Júnior e Jandecy Cabral Leite

Recebido em: 14/05/2021, Aceito em: 28/04/2021.