

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

JADER AUGUSTO DIETER

REDES NEURAS ARTIFICIAIS PARA MANUTENÇÃO PREDITIVA EM
MÁQUINAS INJETORAS

São Leopoldo
2022

Jader Augusto Dieter

**REDES NEURAIS ARTIFICIAIS PARA MANUTENÇÃO PREDITIVA EM
MÁQUINAS INJETORAS**

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica, pelo Curso de Engenharia Elétrica da Universidade do Vale do Rio dos Sinos (UNISINOS).

Orientador(a): Prof. Dr. Gabriel de Oliveira Ramos

São Leopoldo

2022

RESUMO

Atualmente vivemos em um mundo globalizado, tal realidade tem interferido diretamente em nossas vidas e os processos industriais também fazem parte dessa revolução, com o rápido acesso às informações e a possibilidade da cadeia produtiva fornecer qualquer produto para qualquer país no mundo, cria cada vez mais a necessidade de uma produção mais ágil, menos onerosa e mais automatizada, que resulta em disponibilidade rápida de produtos e que agregam valor e confiança ao fornecedor.

Paralelo a esses fatores temos a evolução da Indústria 4.0 e o emprego da chamada Manutenção 4.0, que justamente atua nos processos para prever possíveis erros, paradas para manutenção, quebra de equipamentos, ou seja, ações que prejudicam o bom andamento do processo e o torna menos competitivo.

Considerando esses fatores, o presente trabalho tem como objetivo analisar a viabilidade do desenvolvimento de um modelo redes neurais artificiais com intuito de viabilizar manutenções preditivas para reduzir possíveis paradas de máquinas injetoras. Neste estudo foi realizada uma pesquisa bibliográfica sobre os conceitos de Manutenção Preditiva 4.0 e Indústria 4.0 e apresentando as ferramentas que ambas compartilham, como: Internet das Coisas, Big Data, Computação em nuvem e Inteligência Artificial.

Para comprovação da possibilidade da implementação de um sistema de Inteligência Artificial que traga benefícios a partir do emprego dessa tecnologia foi realizado uma coleta de dados de 3 máquinas injetoras, num período de 6 meses, e diversas análises de dados empregando a técnica Análise de Séries Temporais via Redes Neurais Recorrentes do tipo Long Short-Term Memory, onde se observou a viabilidade da predição de eventos futuros de sobreaquecimento do óleo hidráulico dos equipamentos, possibilitando a predição de temperaturas com 30 minutos de antecedência com um bom índice de desempenho.

Palavras-chave: Indústria 4.0; Manutenção Preditiva; Redes Neurais Artificiais; Análise de Séries Temporais.

LISTA DE FIGURAS

Figura 1 – Resumo da Cadeia Produtiva do Plástico	13
Figura 2 – Linha do tempo Revolução Industrial	16
Figura 3 - Estrutura de uma célula LSTM	24
Figura 4 - Diagrama de projeto proposto	32
Figura 5 - Estrutura de máquina injetora	33
Figura 6 - Overview da proposta de solução	35
Figura 7 – Estrutura de janelamento	48
Figura 8 – Exemplo de janelamento de cada turno da manhã	49

LISTA DE FOTOGRAFIAS

Fotografia 1 - Sensor de temperatura NTC	36
Fotografia 2 - Reservatório de óleo da máquina injetora	37
Fotografia 3 - Máquina de injeção utilizada no estudo	38

LISTA DE GRÁFICOS

Gráfico 1 - Curva P-F	20
Gráfico 2 - Histórico completo de leituras da máquina 1	41
Gráfico 3 - Histórico completo de leituras da máquina 2	42
Gráfico 4 - Histórico completo de leituras da máquina 3	42
Gráfico 5 - Comportamento de um turno contínuo de operação da máquina 1	43
Gráfico 6 - Comportamento da máquina 1 com início de operação com atraso	43
Gráfico 7 - Comportamento da máquina 1 em um turno com parada	43
Gráfico 8 - Histograma das leituras das máquinas	45
Gráfico 9 - Distribuição das leituras das máquinas	46
Gráfico 10 - Variação de MAE em relação às épocas de treinamentos	56
Gráfico 11 - Predições de qualidade da máquina 1	57
Gráfico 12 - Predições de baixa qualidade da máquina 1	58
Gráfico 13 - Predições de turno com uma parada da máquina 1	59
Gráfico 14 - Comparação cruzada das 3 máquinas	60
Gráfico 15 - Predições para máquina 2 com modelo da máquina 1	60

LISTA DE TABELAS

Tabela 1 - Resultados de pesquisa referencial inicial	27
Tabela 2 - Pesquisas encontradas em bancos de dados	28
Tabela 3 - Lista de máquinas utilizadas no estudo	37
Tabela 4 - Lista de temperaturas operacionais de óleo máximas	38
Tabela 5 - Extrato de banco de dados da máquina 3	39
Tabela 6 - Lista de turnos de cada máquina	40
Tabela 7 - Descrição dos recursos computacionais utilizados	41
Tabela 8 - Dados transpostos de amostras das máquinas	44
Tabela 9 - Quantidade de turnos em cada conjunto	47
Tabela 10 - Quantidade de amostras para cada conjunto	49
Tabela 11 - Parâmetros da rede neural	51
Tabela 12 - Resultados de treinamento da rede para máquina 1	53
Tabela 13 - Resultados de treinamento da rede para máquina 2	54
Tabela 14 - Resultados de treinamento da rede para máquina 3	54
Tabela 15 - Melhores resultados de treinamento da rede para as máquinas	55
Tabela 16 - Comparação cruzada de conjunto de validação entre modelos	55

LISTA DE SIGLAS

AI	Artificial Intelligence (Inteligência Artificial)
CBM	Condition-based Predictive Maintenance (Manutenção Preditiva de Condição)
CPS	Cyber-Physical System (Sistemas Físico-Digitais)
FP	Failure Prediction (Predição de Falha)
IoT	Internet of Things (Internet das Coisas)
IIoT	Industrial Internet of Things (Internet das Coisas Industrial)
LSTM	Long Short-Term Memory (Memória de Curto-Longo Prazo)
MAE	Mean Absolute Error (Erro Médio Absoluto)
ML	Machine Learning (Aprendizagem de Máquina)
MSE	Mean Squared Error (Erro Quadrático Médio)
MTBF	Mean-Time-Between-Failure (Média de Tempo entre Falhas)
MTTF	Mean-Time-to-Failure (Média de Tempo para Falha)
M2M	Machine-to-Machine (Máquina para Máquina)
NN	Neural Network (Redes Neurais)
PdM	Predictive Maintenance (Manutenção Preditiva)
RFID	Radio-Frequency Identification (Identificação por Rádio Frequência)
RNN	Recurrent Neural Network (Redes Neurais Recorrentes)
SBM	Statistical-based Predictive Maintenance (Manutenção Preditiva Estatística)
SGD	Stochastic Gradient Descent (Gradiente Estocástico Descendente)

SUMÁRIO

1 INTRODUÇÃO	10
1.1 Tema	11
1.2 Delimitação do tema	11
1.3 Problema	11
1.4 Objetivos	12
1.4.1 Objetivo geral	12
1.4.2 Objetivos específicos	12
1.5 Justificativa	12
2 FUNDAMENTAÇÃO TEÓRICA	15
2.1 Indústria 4.0	15
2.2 Manutenção industrial	17
2.2.1 Manutenção corretiva	18
2.2.2 Manutenção preventiva	18
2.2.3 Manutenção preditiva	19
2.2.3.1 Manutenção Preditiva Estatística (SBM)	20
2.2.3.2 Manutenção Preditiva de Condição (CBM)	20
2.3 Inteligência Artificial	21
2.3.1 Machine Learning	22
2.3.2 Redes Neurais	22
2.3.3 Redes Neurais Recorrentes	23
2.3.4 Long Short-Term Memory	23
2.4 Discussão	24
3 ESTADO DA ARTE	26
3.1 Metodologia	26
3.1.1 Questões de pesquisa	26
3.1.2 Busca	27
3.1.3 Seleção de estudos	27
3.1.4 Classificação	28
3.2 Resultados	28
3.3 Discussão	30
3.3.1 Diferencial	31
3.3.2 Lacunas	31
4 MÉTODO PROPOSTO	32
4.1 Objetivo	32
4.2 Coleta de dados	35
4.2.1 Sensores de temperatura	36
4.2.2 Instalação	36
4.3 Máquinas injetoras	37

	9
4.3.1 Limites operacionais	38
4.4 Dataset	39
4.4.1 Intervalos de tempo	40
4.5 Data engineering	40
4.5.1 Exibição	41
4.5.2 Inspeção e limpeza	44
4.5.3 Média, desvio padrão e limites	44
4.5.4 Histograma	45
4.5.5 Distribuição	46
4.6 Modelo de dados	47
4.6.1 Separação em conjuntos	47
4.6.2 Janelamento de dados	48
4.6.3 Normalização	49
4.7 Modelo de rede	50
4.7.1 Critério de parada	52
5 ANÁLISE DOS RESULTADOS	53
5.1 Treinamento da rede	53
5.2 Discussão dos resultados	55
5.2.1 Melhores resultados	55
5.2.2 Relação entre MAE e épocas	56
5.2.3 Qualidade de predições	57
5.2.4 Comparação cruzada	59
6 CONCLUSÃO	62
6.1 Sugestões para trabalhos futuros	63
REFERÊNCIAS	65

1 INTRODUÇÃO

O interesse humano pela constante evolução nos processos industriais é um elemento permanente na história da manufatura, presente desde a primeira revolução industrial, ocorrida na metade do século XVIII. Como resultado de todo este percurso, estamos presentes na quarta revolução industrial, também chamada de Indústria 4.0, que de acordo com Wang et al. (2016), pode ser determinada como um conjunto da internet das coisas *Internet of Things* (IoT) e de manufatura inteligente, onde há a possibilidade de coletas de dados em tempo real pelos equipamentos, promovendo à mudança de um modelo de fábrica centralizada para um processo de inteligência descentralizada. Ela permite que o processo industrial, a partir da implementação de seus sistemas, se adaptem com maior velocidade às mudanças, realizando as alterações nas ordens de acordo com os dados tratados e condições de operação através de um processo auto adaptativo e de reconfiguração. Além do IoT também temos outros conceitos que se destacam como principais, são: *Cyber-Physical System* (CPS), *Industrial Internet of Things* (IIoT), *Big Data*, dentre outros.

Essa combinação entre dispositivos eletrônicos inteligentes, comunicação sem-fio e computação em nuvem, de acordo com a análise de Wang et al. (2015), tem como resultado infinitas possibilidades que agregam valor aos sistemas de produção. Pode-se destacar, dentre outras, a área de *Predictive Maintenance* (PdM), formada através de um conjunto de ferramentas que visam a detecção de anomalias nas condições físicas dos equipamentos, buscando assim a realização de manutenção antecipada, permitindo um aumento na vida útil do equipamento e no aumento do tempo útil de produção.

Esta metodologia permite uma maior assertividade na implementação de manutenção preditiva como ferramenta de melhoria industrial. A chamada manutenção preditiva possui a melhor relação custo versus benefício, se comparada às manutenções preventiva e corretiva, pois ela permite um incremento considerável do período de produção e redução no tempo de inatividade dos equipamentos, uma vez que tende a necessitar de intervenções mais simples do que em casos de falhas completas do maquinário, além de reduzir custos de mão de obra e prolongar a vida útil dos equipamentos (DILMEGANI, 2018). Se conclui que essa antecipação de

anomalias e, em consequência, de falhas, possibilita uma redução dos custos de operação pois viabiliza também, além das questões já mencionadas, a otimização do uso e estoque de peças e componentes anteriormente não explorados.

1.1 Tema

Este trabalho tem por objetivo a previsão de falhas em máquinas - Failure Prediction (FP), dentro do escopo de *Predictive Maintenance* (PnM) do tipo *Condition-based* (CBM), através do monitoramento contínuo do maquinário e antecipação de sinais de futuras falhas.

O método de análise escolhido para o processamento dos dados oriundos das máquinas é a aplicação de Inteligência Artificial (AI), através do uso de Redes Neurais Recorrentes (RNN) do tipo *Long Short-Term Memory* (LSTM).

1.2 Delimitação do tema

O presente projeto busca avaliar a efetividade da implementação de RNN do tipo LSTM para a criação de um sistema de PnM através da análise dos dados de temperatura do óleo do sistema hidráulico de máquinas de injeção de termoplásticos.

Todavia, apesar de utilizar, este trabalho não trata diretamente da eficácia e da análise dos métodos de coleta dos dados das máquinas utilizadas no estudo (IoT), nem de sua transmissão e posterior armazenagem (*Big Data*).

1.3 Problema

Busca-se nesta pesquisa analisar a viabilidade do uso de Inteligência Artificial do tipo LSTM para a previsão de falhas relacionadas à temperatura do óleo do sistema hidráulico em máquinas injetoras de termoplásticos.

1.4 Objetivos

1.4.1 Objetivo geral

O objetivo central deste trabalho é analisar o uso de rede neural LSTM para análise de padrão da série temporal da temperatura de óleo do sistema hidráulico de máquinas de injeção de termoplásticos e contribuir, com certa antecedência, para a previsão de determinados padrões relevantes, como a tendência de crescimento da temperatura de óleo além dos níveis operacionais desejados.

1.4.2 Objetivos específicos

No intuito de obter a resposta ao problema deste projeto, alguns são os objetivos intermediários que deverão ser implementados:

- a) Análise e definição da natureza dos dados necessários;
- b) Criação de um dataset de informações reais;
- c) Preparação dos dados, através de Data Featuring e outras metodologias;
- d) Implementação de Redes Neurais Recorrentes do tipo LSTM, em algumas de suas possibilidades;
- e) Comparação de resultados entre os modelos aplicados;
- f) Ajustes finos na manipulação inicial de dados, nos hiperparâmetros e na aplicação do treinamento das Redes Neurais.

1.5 Justificativa

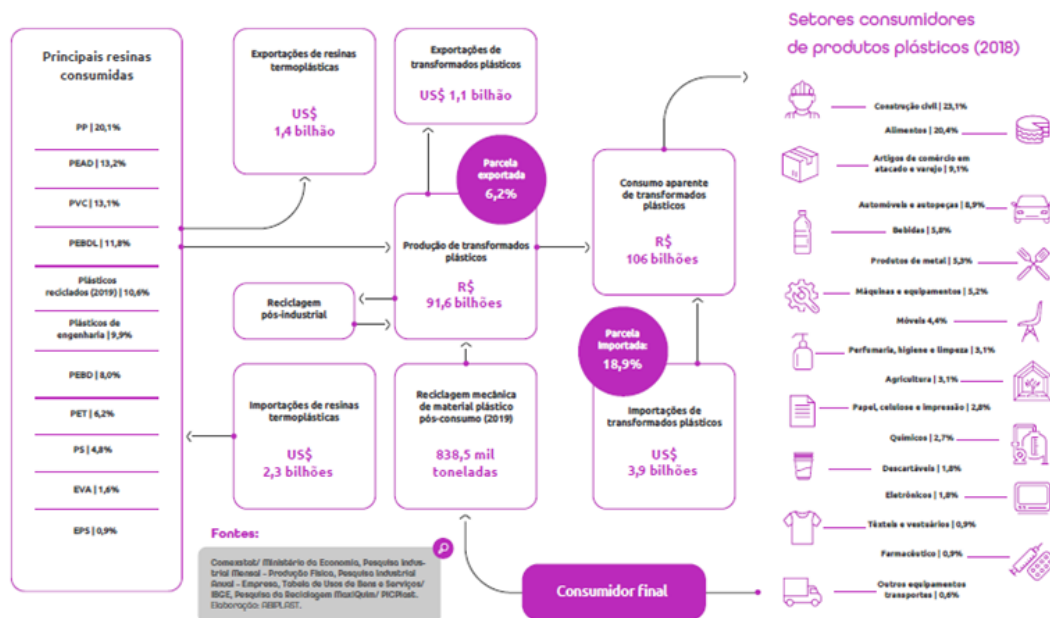
O setor de transformação de termoplásticos é um dos grandes atores da indústria brasileira, responsável por um faturamento de 90,8 bilhões de Reais (2020) e empregando cerca de 320 mil pessoas espalhadas em aproximadamente 10800 empresas presentes no Brasil, de acordo com dados até o ano de 2020 da Abiplast (Associação Brasileira da Indústria de Plásticos). Esse relatório também aponta que a indústria do plástico é a quarta maior empregadora das indústrias de transformação brasileiras.

Na Figura 1, verifica-se um espelho cadeia produtiva do plástico e é possível ter uma visão da importância desta indústria, que é responsável pela produção de

todos os gêneros de produtos ou componentes, como palmilhas, solas de calçado, caixas para eletrônicos, insumos para veículos automotores, entre outros produtos.

Figura 1 – Resumo da Cadeia Produtiva do Plástico

Resumo da cadeia produtiva do plástico



Fonte: ABIPLAST (2020).

O elemento mais importante a ser observado é o tempo útil de produção, ou seja, o período em que a máquina está efetivamente operando. Desta forma, paradas de operação é uma das principais dores do setor e um dos pontos a serem evitados e são o principal elemento de busca de melhoria por parte deste setor industrial, conforme apontado por Kardec e Nascif (2009).

Neste cenário, as empresas possuem o interesse e a necessidade de utilizar a metodologia de manutenção preditiva, evitando paradas desnecessárias e gastos superiores por danos mais graves, presentes em manutenções corretivas (XAVIER; PINTO, 1999) bem como gastos desnecessários com trocas de componentes em manutenção preventiva. Assim, como objeto de delimitação da pesquisa, verifica-se uma carência no auxílio das empresas de injeção termoplástica na implementação de métodos de manutenção preditiva, principalmente no momento pós pandemia, com recursos escassos e com a expansão e redução de custos de dispositivos IoT e recursos computacionais para Big Data.

Levando isso em consideração, busca-se aqui o estudo de viabilidade da criação de um método efetivo de antecipação de falhas relacionadas à temperatura do óleo de máquinas de injeção termoplásticas, evitando assim danos graves e paradas por períodos prolongados, permitindo assim o uso de técnicas de PdM por parte deste setor industrial. Estes objetivos possuem o potencial de permitir uma significativa redução nos custos de produção, resultando assim também em uma redução importante nos preços de produtos oriundos de cadeias produtivas que utilizam este tipo de maquinário, tendo assim um grande potencial para a sociedade em geral, possibilitando a oferta de produtos de qualidade e mais acessíveis.

Em termos acadêmicos, estudos de revisão sistemática demonstram o grande interesse nos últimos anos pelos temas tratados neste projeto (Souza et al. 2020), voltados para PdM e FP. Entretanto, pouco é o material disponível de pesquisas para sistemas deste gênero, voltados especificamente para máquinas de injeção termoplástica. Desta forma, verifica-se que este projeto pode contribuir para a abertura de discussões com relação ao uso de Machine Learning como ferramenta da Indústria 4.0 no importante setor de termoplásticos, ou para maquinários semelhantes como prensas hidráulicas.

2 FUNDAMENTAÇÃO TEÓRICA

Para o planejamento e execução do objetivo central proposto por este trabalho, se faz necessário o conhecimento de alguns fundamentos importantes com relação aos principais tópicos abordados na metodologia proposta e, em consequência, na análise dos resultados encontrados no decorrer do projeto. Para tal compreensão, este capítulo apresenta um resumo com relação aos conceitos de Indústria 4.0, de manutenção preditiva e das técnicas de Machine Learning, fundamentando entendimentos consolidados e amplamente utilizados sobre cada um dos temas.

2.1 Indústria 4.0

A chamada revolução industrial, ocorrida no final do século XVIII, é onde houve o início da implementação de processos industriais, com a utilização de máquinas mecânicas (BARBOSA; AROCA, 2017). Desde então até os tempos atuais, só ocorreram evoluções sendo denominadas, respectivamente:

- Segunda revolução industrial, ocorrida na virada do século XX, onde o marco foi a utilização de energia elétrica, produção em escala de bens e na divisão de tarefas;
- Terceira revolução industrial, iniciada nos anos 70, onde ocorreu a melhoria dos processos com emprego de equipamentos de controle e automação, tecnologia de informação, análise computacional, entre outros. A terceira revolução é presente até os dias atuais e ela proporcionou que as máquinas tivessem papel de destaque frente ao trabalho manual, diminuindo erros causados por falhas humanas (BARBOSA; AROCA, 2017).
- A quarta revolução industrial, chamada de Indústria 4.0, foi mencionada pela primeira vez em 2013, através da apresentação de um projeto estratégico do governo alemão e ela vem modificando totalmente os processos industriais e permitindo uma evolução nunca vista. Ela trata da integração e cooperação entre diversos elementos distintos, como dispositivos eletrônicos autônomos (IoT), sistemas físico-digitais (CPS), permite uma melhor análise e compreensão dos

dados oriundos das fábricas, possibilitando uma maior assertividade do controle industrial e uma tomada de decisão apoiada por dados concretos, frutos da coleta, transmissão e processamento de informações de máquinas, prédios, pessoas, etc (MAURA, 2019).

No esquema da Figura 2, pode-se verificar os marcos das revoluções industriais e suas principais características.

Figura 2 – Linha do tempo Revolução Industrial



Fonte: Citisystems (2022)

Nas fábricas que atuam com o conceito de Indústria 4.0, as máquinas estão inseridas numa comunidade colaborativa, onde se faz uso de ferramentas de análises como IoT, Big Data, computação em nuvem e AI (MAURA, 2019).

A fábrica inteligente (*Smart Factories*), conceito esse que foi introduzido em 2011 na feira de Hannover, na Alemanha, e visa definir a tendência sobre o futuro dos processos industriais, tendo relação com outros conceitos já existentes, como *Machine-to-Machine* (M2M), identificação por radiofrequência (RFID), dentre outros, bem como com novidades dos últimos anos (WANG, 2016).

A adoção da metodologia 4.0 exige a aplicação de um grau elevado de automação industrial, com aplicação de diversos níveis de controle para medição de variáveis físicas que impactam diretamente na eficiência do processo. Estes dados são enviados para sistema de processamento, que podem ser locais ou online, onde

é feita a análise, permitindo assim um planejamento das operações a serem executadas. Esse método é promotor da disruptura das operações das empresas, nos mais diversos setores como compras, planejamento e produção, entre outros (MAURA, 2019).

2.2 Manutenção industrial

A manutenção é praticamente definida por boa parte dos autores como um instrumento que as empresas utilizam para evitar ou diminuir a incidência de falhas, melhorar processos, tornar os equipamentos capazes de retornar a condição inicial de operação, evitar o sucateamento e desgaste natural pelo uso contínuo, ou seja, percebe-se que trata-se de uma atividade complexa já que envolve diversas variáveis e tem como objetivo final manter a confiabilidade do equipamento no processo produtivo, não diminuindo resultados de rendimento e nem gerando gastos desnecessários (MONCHY, 1987).

Como não poderia ser diferente o conceito de manutenção foi evoluindo entre décadas e de acordo com os diferentes conceitos de revolução industrial (KARDEC; NASCIF, 2009). Na primeira revolução, o conserto era realizado após a falha e estas eram vistas como oriundas dos desgastes dos equipamentos ao longo dos anos, portanto, as ações aplicadas eram apenas voltadas para reparo.

Já na segunda revolução, ocorria maior número de manutenções, que por consequência promoviam maior vida útil aos equipamentos. Não havia distinção de comportamento de falha dos equipamentos, todos eram tratados da mesma forma. As manutenções passaram a serem planejadas e com aplicação de procedimentos padrões, pois já havia computadores auxiliando no processo de reparo, apesar de serem limitados. Também é nesse período que se identifica o início da manutenção preventiva, com paradas programadas.

Na terceira revolução, há maior confiabilidade no processo de manutenção assim como maior disponibilidade de recursos, há uma melhoria no custo x benefício e uma preocupação adicional com o meio ambiente. As falhas foram padronizadas e listadas. Já as manutenções passaram a ser passíveis das condições dos dados de monitoramento, a manutenção preditiva começou a ser aplicada, incluindo a análise de riscos. Os computadores já são menores, mais ágeis assim como os softwares. A manutenção é definida por equipes multidisciplinares e um dos objetivos principais é

restaurar a confiabilidade total dos equipamentos no processo, por isso, há contratação de mão de obra especializada.

Na quarta as manutenções assim como na terceira tem o objetivo de maior confiabilidade no processo de manutenção, bem como maior disponibilidade de recursos, mas se acrescenta a variável de segurança e o foco nos resultados do negócio. As falhas devem ser previstas prematuramente e devem ocorrer em menor número possível. A manutenção preditiva passou a ser a principal aliada, assim como o monitoramento constante das condições de processo, pois isso minimiza as preventivas e corretivas não planejadas. As técnicas são mais confiáveis e surge a aplicação da Engenharia de Manutenção. Os projetos que surgem com o tema de manutenção são voltados para confiabilidade, manutenção e custo de ciclo de vida.

Desta forma, percebe-se que, dentro do ambiente industrial, é constante a busca por manter o funcionamento correto de máquinas e equipamentos utilizados no processo produtivo, visando obter o maior resultado financeiro possível com relação ao montante investido. Existem três principais métodos de manutenção, conforme descrição presente neste capítulo (MOBLEY, 2002).

2.2.1 Manutenção corretiva

Nesta abordagem, realiza-se a manutenção do equipamento apenas quando ocorre uma falha. Este é o método que resulta em maior custo de operação, pois apresenta grandes períodos de parada para os equipamentos, exigindo também uma maior equipe de manutenção, além de um grande custo com partes e peças.

A postura reativa desta opção tem como consequência direta um baixo índice de disponibilidade para produção. Quando uma falha é consumada, tende a apresentar defeitos mais graves e complexos, exigindo novas peças, maior tempo de interação dos técnicos em manutenção, bem como a exigência imediata de insumos, como peças e materiais, criando a necessidade do pagamento de valores de ocasião mais altos ou da criação de um estoque próprio.

2.2.2 Manutenção preventiva

No caso da manutenção preventiva, utiliza-se o tempo como elemento principal para o planejamento da manutenção industrial. Ou seja, as manutenções

são programadas com base em períodos de tempo, como horas, dias, meses ou anos, normalmente definidos através da análise estatística da vida útil das máquinas e suas partes, com referência em informações do fabricante ou a partir da utilização de um histórico previamente conhecido.

Estima-se que este método apresenta uma redução de três vezes no custo de uma manutenção, quando comparada à manutenção corretiva. Por isso, ele é fruto de grande interesse e de estudos há várias décadas, possuindo metodologias bastante sólidas para orientar as empresas e seus gestores em sua implementação.

Dois são os conceitos que norteiam a manutenção preventiva:

- *Mean-Time-to-Failure* (MTTF): intervalo de tempo para ocorrer uma falha
- *Mean-Time-Between* (MTBF): intervalo de tempo entre falhas

O trabalho de manutenção em um ambiente industrial deste gênero é orientado por essas duas estatísticas, buscando realizar a manutenção e pequenas intervenções, como troca de óleo e calibrações, dentro do período conhecido. Entretanto, este comportamento resulta em custos desnecessários de manutenção, como a troca de peças com possibilidade de maior vida útil, ou de falhas completas mesmo antes do intervalo estatístico.

2.2.3 Manutenção preditiva

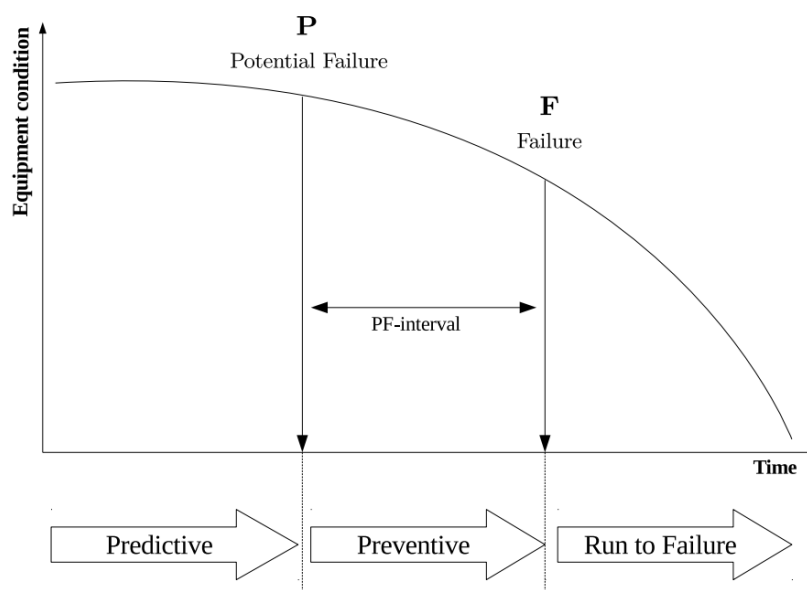
A manutenção preditiva possui algumas definições, dependendo da metodologia utilizada. Em geral, a premissa principal envolve o monitoramento das condições mecânicas, eficiência de operação e diversos outros indicadores, permitindo assim a detecção antecipada de problemas no maquinário industrial.

Pode-se dizer, entretanto, que a manutenção preditiva tem como resultado diversas melhorias, oriundas deste monitoramento constante. Verifica-se um aumento da produtividade, do tempo em operação, da qualidade geral e da redução dos custos atrelados à manutenção da planta industrial.

Diversos são os métodos utilizados no monitoramento do estado geral das máquinas envolvidas no processo produtivo, como: análise de vibração, parâmetros de processo, termografia, tribologia e inspeção visual. Através delas, é possível aumentar a vida útil dos componentes mecânicos, evitando trocas desnecessárias e prevenindo paradas totais em caso de falhas completas.

Para permitir a detecção prévia de uma falha, um método bastante utilizado é a curva P-F, onde estabelece-se uma relação entre o início de uma falha em potencial e o ponto de falha completa, distribuído no tempo. A análise desta curva demonstra a diferença entre cada abordagem de manutenção, uma vez que pode-se estabelecer o período em que cada método é aplicado.

Gráfico 1 - Curva P-F



Fonte: Davari (2021).

Pode-se separar a manutenção preditiva em dois métodos: baseado em estatística e baseado em condição.

2.2.3.1 Manutenção Preditiva Estatística (SBM)

Nesta abordagem, chamada de *Statistical-based Predictive Maintenance* (SBM), utiliza-se dados estatísticos do passado, com situações de problemas e falhas registradas, criando assim modelos estatísticos visando a previsão de potenciais problemas futuros (WANG, 2016).

2.2.3.2 Manutenção Preditiva de Condição (CBM)

Nesta metodologia, referida como *Condition-based Predictive Maintenance* (CBM), utiliza-se o monitoramento constante das máquinas e equipamentos, bem

como seus componentes, para detectar comportamentos anômalos e prever a ocorrência de uma falha em alguma parte do sistema produtivo (WANG, 2016).

Neste caso, aplica-se metodologias de Internet das Coisas (IoT) para monitorar em tempo real diversos parâmetros físicos, com posterior transmissão para uma base de dados, sendo esta base o elemento principal de processamento e detecção antecipada de futuros acontecimentos.

Pode-se definir esta forma de manutenção como a base para implementações de Predictive Maintenance (PdM), através da análise dos dados por intermédio de algoritmos que podem utilizar métodos estatísticos e inteligência artificial. Em resumo, pode-se dizer que PdM permite a criação de sistemas de manutenção preditiva mais inteligentes, através da análise contínua de dados e a criação de grandes bancos de dados com históricos de diversas situações e falhas, permitindo uma melhoria contínua na exatidão dos resultados, podendo garantir o funcionamento dos diversos componentes presentes na linha de produção até o limite dentro das condições ideais de segurança.

É possível descrever os sistemas PdM inteligentes em seis módulos principais, conforme Wang (2016, p. 264), “[...] (1) sensores e aquisição de dados, (2) pré-processamento de sinais e extração de características, (3) tomada de decisão da manutenção, (4) indicadores-chave de performance, (5) otimização da programação de manutenção, e (6) análise de feedback e compensação”.

2.3 Inteligência Artificial

A inteligência artificial (AI) é um campo da computação que busca utilizar algoritmos para a solução de problemas complexos. Segundo Akerkar (2014), pode-se definir a inteligência artificial como a área da ciência que visa desenvolver sistemas computacionais inteligentes a partir de características do comportamento humano associadas à inteligência. Segundo suas palavras, “AI é uma mentalidade, uma forma de enxergar e resolver problemas a partir de uma perspectiva particular”.

O seu uso já está incorporado no cotidiano humano, podendo destacar o seu uso para controle por voz, atendimento ao cliente automatizado, carros autônomos, etc. Isso é possível através de diversos gêneros de AI que, cada um com suas características, permitem a execução de tarefas como: detecção de voz, reconhecimento de padrões, análise de imagens, etc.

2.3.1 Machine Learning

Machine Learning (ML), ou Aprendizagem de Máquina, são técnicas utilizadas para permitir que computadores resolvam problemas complexos através de um conjunto de dados que envolvem características e respostas esperadas. Esse conjunto de informações podem ser textos, imagens, valores de sensores, etc.

Segundo a IBM (2018), o que diferencia ML das técnicas tradicionais de software, é que o primeiro utiliza um conjunto de regras para a definição da resposta esperada, enquanto o segundo gera as suas próprias regras através do aprendizado de dados históricos fornecidos para o treinamento do algoritmo. Desta forma, é possível que o sistema de ML melhore constantemente sua taxa de sucesso, através de análise constante dos próprios resultados.

De acordo com Norvig (2010), são três as técnicas de feedback possíveis para o aprendizado em ML:

- Aprendizado supervisionado: fornecimento de um conjunto de entradas e saídas para a criação de uma regra geral, utilizando um professor
- Aprendizado não-supervisionado: fornecimento de um conjunto de entradas sem a saída correspondente correta
- Aprendizado por reforço: fornecimento de recompensas, na interação com o ambiente, para determinar a correta saída para uma entrada, criando assim uma metodologia de ajuste e melhora contínua no resultado do sistema

2.3.2 Redes Neurais

Para Norvig (2010), Redes Neurais (NN) são o correspondente modelo matemático do funcionamento do cérebro, mais especificamente, dos neurônios, que são as células responsáveis por processar todo o tipo de informação. As redes neurais são como um conjunto de neurônios, ligados entre si através de sinapses, propagando os sinais entre eles, com o potencial plástico de mudança da ligação das sinapses, de acordo com o padrão de estímulos.

É exatamente através desta capacidade de formação de novas conexões que se dá o processo de aprendizagem no cérebro humano, e em consequência, é o mesmo método aplicado para as redes neurais. A técnica utilizada para a aprendizagem das NN é o aprendizado supervisionado, onde é possível treinar a

rede através de um conjunto de entradas e saídas, permitindo uma melhora constante dos resultados a cada novo treino.

As redes neurais são divididas em camadas, sendo estas compostas por neurônios artificiais, chamados de nodes ou units, ligados entre si e entre camadas através de chamados links. Cada ligação possui um peso numérico associado, e o processo de aprendizado pode alterar este valor, sempre em busca da melhor configuração que permita estabelecer a relação entre entradas e saídas (NOVIG, 2010).

2.3.3 Redes Neurais Recorrentes

As Redes Neurais Recorrentes (RNN) são uma classe das Redes Neurais voltadas para o processamento sequencial de dados. De acordo com Goodfellow, Bengio & Courville (2016), as RNN possibilitam o processamento de grandes conjuntos de dados, inclusive de comprimento variável. Este tipo de rede apresenta a característica de compartilhamento de parâmetros em diferentes pontos do modelo utilizado.

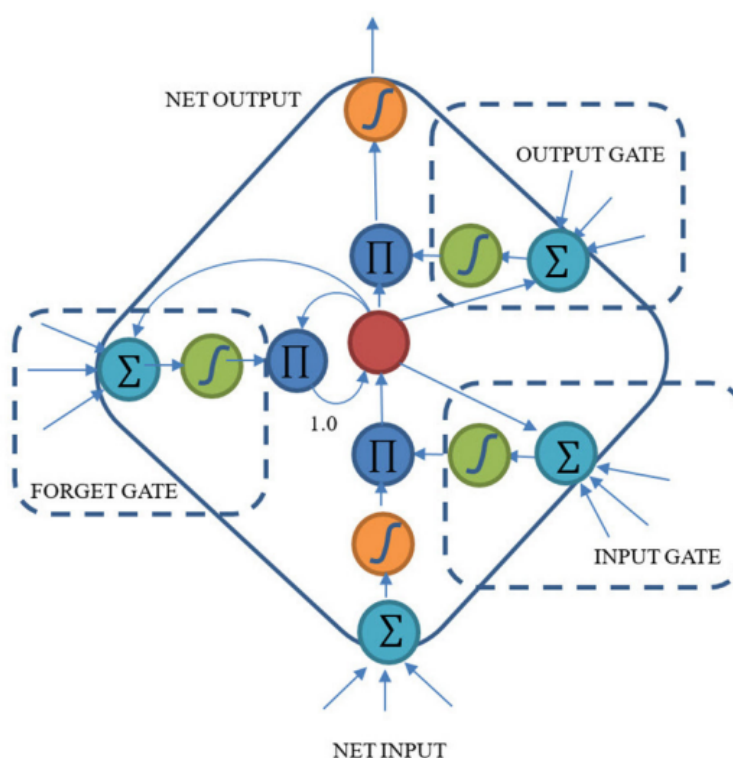
Pode-se dizer que as redes RNN utilizam a ferramenta de memória em todas as decisões, uma vez que as entradas de dados são somadas aos resultados anteriores, influenciando também na saída. Ou seja, a nova saída depende tanto da nova entrada quanto da memória dos resultados das entradas passadas. Esta poderosa técnica agrega grande capacidade de resolução de problemas com dependência temporal, como reconhecimento de voz, predição de séries temporais, análise de áudio e vídeo, etc.

2.3.4 Long Short-Term Memory

Diversas variações das redes RNN tem por objetivo melhorar a sua performance, entretanto, enfrentam o problema com relação ao processamento de longas sequências de dados, chamado de “vanishing gradient problem” (HOCHREITER et al., 2001). Este problema está ligado ao fato de que a evolução temporal do índice do erro de predição, utilizado no algoritmo de *Backpropagation* para treinamento da rede, que tende a se tornar irrelevante de acordo com a passagem do tempo, através da perda de peso para o cálculo do gradiente.

Proposta inicialmente por Hochreiter and Schmidhuber (1997), as redes Long Short-Term Memory (LSTM) buscavam a solução do problema de “vanishing gradient”. Através do uso de diferentes controles nas três portas do modelo, de entrada, de saída e de esquecimento, é possível reter as informações relevantes nos neurônios artificiais e armazenar informações por longos períodos. Com esta característica, uma rede LSTM possui melhores resultados no processamento, classificação e predição em sequências dinâmicas de longas séries temporais (YU et al., 2017).

Figura 3 - Estrutura de uma célula LSTM



Fonte: Yu et al. (2017).

2.4 Discussão

Uma vez apresentada a revisão da bibliografia apresentada neste capítulo, é possível definir quais são os elementos apresentados que fazem parte do escopo do trabalho. O projeto utiliza-se dos conceitos de manutenção preditiva do tipo Condition-based Predictive Maintenance, conceito este presente na área de estudos de Predictive Maintenance da Indústria 4.0.

Para resolver o problema proposto neste trabalho, utiliza-se de Inteligência Artificial, através do uso de Redes Neurais Recorrentes, com aprendizado

supervisionado, mais especificamente em redes do tipo Long-Short Time Series, para a predição de séries temporais de dados de temperatura de óleo do sistema hidráulico de máquinas injetoras de termoplásticos.

3 ESTADO DA ARTE

A pesquisa inicial do Estado da Arte da área do trabalho proposto tem por objetivo conhecer as metodologias anteriormente propostas por outros autores, mesmo em objetivos de pesquisa não diretamente relacionados, bem como os seus resultados, visando assim a evolução constante das pesquisas a partir do compartilhamento de técnicas e informações. Pode-se nomear alguns dos objetivos centrais atrelados à revisão literária aqui proposta:

1. Levantamento de trabalhos e artigos relacionados à técnicas de predição, através de ML, de problemas relacionados à manutenção preditiva em indústrias;
2. Compreensão das técnicas utilizadas;
3. Entendimento das premissas de cada pesquisador, dos métodos utilizados e das soluções encontradas
4. Registro de resultados positivos, bem como as características implementadas para cada solução
5. Classificação de artigos e trabalhos de predição PdM via ML através dos critérios estabelecidos em metodologia.

3.1 Metodologia

A metodologia estabelecida para a pesquisa dos estudos baseia-se nas diretrizes para a realização de mapeamento sistemático de estudos para engenharia de software, propostas por Petersen (2015). Deste estudo, são quatro os passos utilizados para esta revisão literária, considerados o suficiente para as exigências deste trabalho.

3.1.1 Questões de pesquisa

Como primeiro passo, está a elaboração de Questões de Pesquisa, que buscam auxiliar na classificação dos artigos a partir de sua relevância em relação ao tema proposto neste trabalho.

- Questão 1: Qual foi o problema ligado à PdM objeto do trabalho?
- Questão 2: Qual foi o método utilizado como solução do problema?

- Questão 3: Qual o tipo de máquina analisada?
- Questão 4: Qual o tipo de dado utilizado?
- Questão 5: Qual o padrão utilizado para avaliação da solução?

3.1.2 Busca

No segundo passo, realizou-se a busca no banco de dados da Google Scholar, um agregador de conteúdo científico que reúne os maiores databases de artigos internacionalmente reconhecidos. Para tal tarefa, estudou-se os conceitos e palavras mais utilizados para trabalhos nesta área, resultando nas buscas conforme tabela abaixo.

Tabela 1 - Resultados de pesquisa referencial inicial

Mecanismo de busca	Texto de consulta	Resultados
Google Scholar	(Predictive AND Maintenance AND (RNN OR LSTM) AND (TEMPERATURE))	7500

Fonte: Elaborado pelo autor.

3.1.3 Seleção de estudos

Com os resultados das pesquisas nos databases científicos, realizou-se uma seleção mais criteriosa dos artigos encontrados, com base em quatro premissas pré-elaboradas, conforme a lista abaixo:

1. O estudo deve ter sido publicado nos últimos 10 anos
2. O estudo deve pertencer à área de aplicação de RNN à Predictive Maintenance, de preferência com alguma relação à temperatura
3. O título e o resumo devem fornecer informações suficientes para entender se o estudo se encaixa no tema procurado
4. De preferência, apenas um estudo para cada tipo de abordagem

Também estabeleceu-se o critério de revisão das referências bibliográficas e dos artigos selecionados, a fim de encontrar estudos de alto padrão e não presentes nas buscas dos bancos de dados e que possam ser agregados à esta revisão.

3.1.4 Classificação

Aplicados os filtros nos resultados encontrados, conforme as instruções acima, chegou-se ao número final de artigos que merecem destaque na revisão do Estado da Arte, uma vez que cumprem todos os requisitos e podem ser considerados como referência para o presente trabalho. Na lista abaixo eles estão identificados de acordo com o seu banco de dados de origem, bem como a quantidade de artigos selecionados.

Tabela 2 - Pesquisas encontradas em bancos de dados

Banco de dados	Quantidade selecionada
IEEE	123
ScienceDirect	321
Google Scholar	198
Total	345

Fonte: Elaborado pelo autor.

3.2 Resultados

Finalizadas as etapas anteriores, realizou-se a avaliação individual de cada artigo, relacionando-os com as questões coletivas propostas na revisão literária, com o limite de 50 estudos em cada banco de dados. Neste trabalho, foram referenciados apenas os trabalhos que se mostraram relevantes com base nos critérios anteriormente descritos.

No artigo de Yang (et al., 2021), o objetivo é a **predição da temperatura do óleo de transformadores** refrigerados a óleo, utilizando-se um algoritmo de RNN do tipo **PSO-LSTM**. O tipo de equipamento monitorado é a classe de **transformadores de distribuição de energia elétrica** de alta tensão, do tipo refrigerado a óleo, e os dados utilizados são de **temperatura ambiente** e **temperatura do óleo**. Para efeitos de avaliação, realizam-se comparações de RMSE, MAE e MAPE% na avaliação dos resultados encontrados, apresentando um parecer bastante positivo dos resultados encontrados.

No artigo de Chiu (et al., 2019), busca-se a **previsão de falhas e performance de produtividade**, e para isso utiliza-se de uma combinação de

Random Forest (RF) como forma de identificação de fatores-chave, com interior análise de série temporal através de **LSTM**. O estudo de caso envolve uma **serra industrial de fio**, utilizada no processo de produção de wafers de semicondutores, e são vinte os tipos de dados lidos da máquina para posterior processamento: **pressão de fechamento, densidade e gravidade de pasta, velocidade de fio, posição, temperatura de saída da pasta resfriada, temperatura de fio de pasta, fluxo de pasta, tensão de fio esquerdo e fio direito, temperatura de saída de pasta, posição de válvula de pressão d'água, temperatura de entrada d'água e seis diferentes temperaturas de rolamentos de guia de fio**. No processo de avaliação dos resultados, utilizou-se uma comparação de MSE e R^2 entre o método proposto, suporte a regressão vetorial e regressão linear. Esta comparação, de acordo com o resultado apresentado no artigo, demonstra o aumento de exatidão para atingir o objeto do trabalho através da metodologia proposta.

No artigo de Mateus (et al., 2021), a pesquisa visa a **antecipação do comportamento de uma prensa industrial**, e os autores aplicam redes **LSTM** para a predição temporal, com comparações entre diversas manipulações do dataset. Utiliza-se seis diferentes dados para a análise temporal: **corrente elétrica, nível e temperatura de óleo da unidade hidráulica, pressão, velocidade de rotação e torque**. Ao final, os resultados são apresentados como positivos, segundo o autor, a partir de comparações entre MAPE, MAE e RMSE, de acordo com configurações diferentes na preparação dos dados.

No artigo de Essien (et al., 2020), os pesquisadores buscam avaliar a **predição de velocidade de máquina industrial** através de inteligência artificial, e para isso utilizam também análise de séries temporais via redes neurais, porém através de **LSTM autoencoder**. O aparelho objeto de estudos trata-se de uma **máquina de produção de latas de alumínio**, de onde criou-se um dataset munido com as informações da **velocidade de operação da máquina**, em número de batidas para conformação do produto final. Diversas comparações são executadas, utilizando-se os parâmetros de RMSE, MAE, sMAPE e tempo de treino, e são utilizadas como embasamento para demonstrar o superior resultado em relação aos trabalhos da área utilizados como revisão literária.

No artigo de Ramos (et al., 2021), o objetivo central do trabalho é a **descoberta de anomalias no funcionamento da planta industrial**, e é aplicada uma metodologia de previsão através de ML com **CNN autoencoder**. Neste caso,

não trata-se apenas de uma máquina, mas de **vários equipamentos** presentes em uma linha de produção de **indústria química**. Devido à complexidade para avaliação do ambiente em estudo, utiliza-se dados de 27 origens diferentes: **fluxo de carga do alimentador, fluxo do condensado para refrigeração, fluxo de injeção anti polimerização, corrente do compressor, percentual de água, taxa e percentual de nível de tambor, pressão do compressor de recirculação, pressão da barreira de vapor e de descarga de pressão, rotação do motor, temperatura de entrada e de saída do controle e diversos sinais de vibração**. Os pesquisadores apresentaram, ao final do estudo, resultados positivos com base na comparação de R^2 e também na comparação entre o previsto e o ocorrido no dataset.

No artigo de Khorrama (et al., 2019), os autores desejam a realização de **predição de falhas em rolamentos** de maquinário industrial, onde o tipo de inteligência artificial aplicada é uma rede neural do tipo **CRNN**. A solução é avaliada em dados oriundos de uma **máquina elétrica trifásica** padrão, mais especificamente nos seus rolamentos, de onde são colhidos os dados de **posição X e Y de vibração** através de dois acelerômetros instalados na sua carenagem. Os resultados apresentados são baseados em comparações de acurácia entre estudos correlacionados e o método proposto neste trabalho, que, segundo os autores, demonstram que a sua escolha possui superior técnicas às técnicas passadas.

3.3 Discussão

Analisando os artigos acima, pode-se perceber que o tema de manutenção preditiva possui bastante interesse no meio acadêmico. Existe uma demanda real no mercado e na academia com relação à detecção prévia de potenciais problemas presentes na linha de produção e, em especial, às máquinas e seus derivados, e muitos estudos ainda são necessários para a criação de metodologias que apresentem resultados concretos e com viabilidade econômica.

Muitos trabalhos voltados para PdM e PHM utilizam o processamento de séries temporais, como LSTM e seus derivados, para a detecção antecipada de alterações de parâmetros importantes, ou de algoritmos de autoencoders, para detectar anomalias no funcionamento de máquinas ou ambientes. O uso de LSTM permite que se utilize da capacidade das redes RNN nos grandes datasets de dados

de cada artigo, ao mesmo tempo que mantém o histórico com grande importância na análise futura, exatamente pela capacidade que este tipo de rede tem de reter memória.

3.3.1 Diferencial

Não foi possível encontrar trabalhos relacionados a máquinas de injeção de termoplásticos, nem relacionados à detecção de problemas especificamente ligados à temperatura do óleo do sistema hidráulico deste tipo de máquina, nem de máquinas correlacionadas, como prensas hidráulicas. Desta forma, o presente trabalho apresenta o diferencial de trabalhar com um tipo de máquina e de problema ainda escasso no que diz respeito a material acadêmico.

Além disso, o possível uso em conjunto com a leitura de dados presente e em tempo real em um ambiente industrial por um longo período de tempo, permite que, através de muitos testes, simulações e comparações, se chegue a um método viável de manutenção preditiva em um setor importante para a região sul do Brasil e o país.

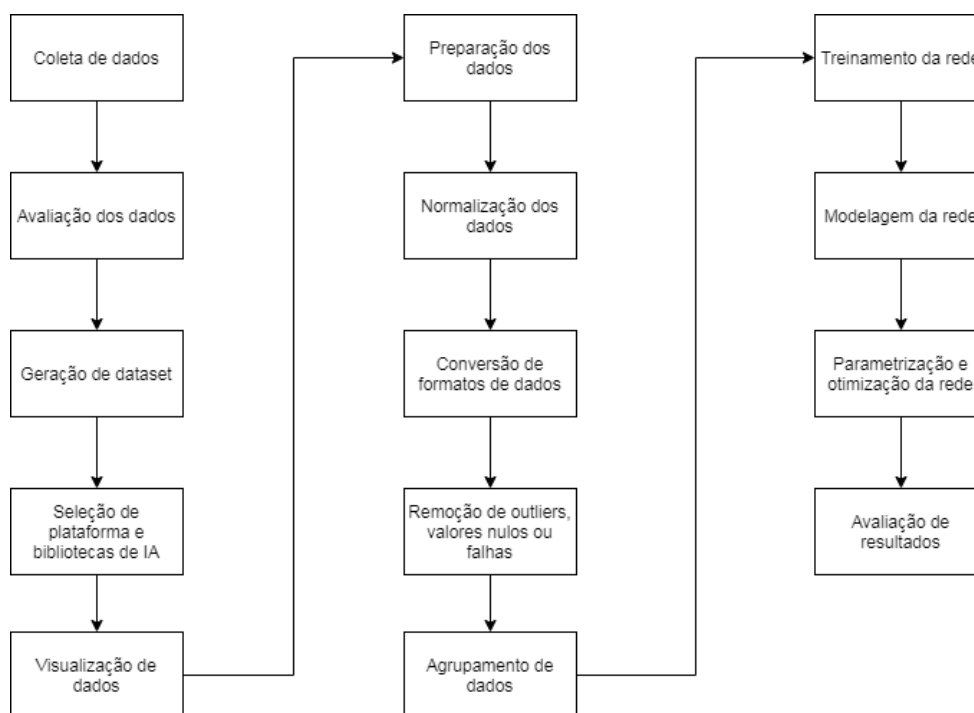
3.3.2 Lacunas

São lacunas presentes a ínfima quantidade de literatura encontrada, além da falta de trabalhos relacionados diretamente a máquinas injetoras, também o fato de que os estudos se relacionam com variáveis de comportamento diferente do esperado para as variáveis do presente trabalho. Isso ocorre pelo fato de que os trabalhos analisam outros elementos relacionados à indústria, buscando a predição de comportamentos, porém a temperatura do óleo do sistema hidráulico das máquinas injetoras apresenta características únicas e que necessitam de avaliação diferenciada dos artigos do Estado da Arte.

4 MÉTODO PROPOSTO

Neste capítulo, apresenta-se a metodologia aplicada para a realização da pesquisa proposta neste trabalho. Em primeiro lugar, definiu-se o objetivo do projeto, baseado nas possibilidades levantadas a partir de uma pesquisa primária. A partir de então, os demais sub capítulos descrevem as características dos dados lidos, a forma de leitura, os modelos de máquinas utilizados neste experimento, bem como a avaliação e modelagem dos dados a serem utilizados na aprendizagem de máquina. Por fim, este capítulo apresenta as etapas de treinamento e parametrização para otimização da rede, a fim de buscar o melhor resultado possível.

Figura 4 - Diagrama de projeto proposto



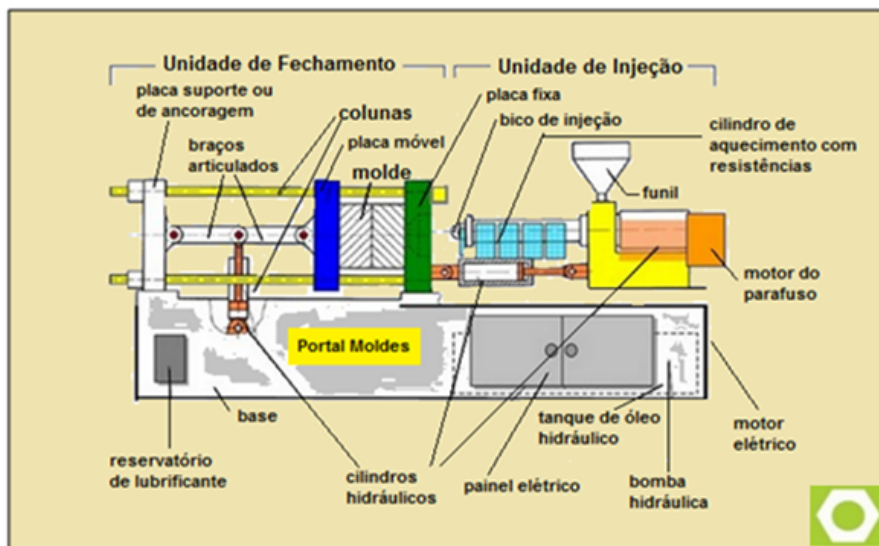
Fonte: Elaborado pelo autor.

4.1 Objetivo

Máquinas de injeção de termoplásticos são equipamentos industriais altamente utilizados na produção de diversas peças plásticas, e são conjuntos bastante complexos de elementos mecânicos e elétricos. Assim como prensas hidráulicas, a injetora possui um sistema hidráulico, uma vez que são cilindros hidráulicos os responsáveis por diversas movimentações deste tipo de máquina, como: abertura e fechamento, avanço e recuo da unidade injetora, avanço e recuo

do extrator, etc. Na Figura 5 é possível verificar a estrutura completa deste tipo de maquinário.

Figura 5 - Estrutura de máquina injetora



Fonte: Moldes Injeção Plásticos (2022)

Todas essas movimentações numa máquina de injeção se dão a partir de aberturas de fechamentos de válvulas que permitem a passagem de óleo que, por sua vez, adentra ao cilindro hidráulico e avança a sua posição, ocasionando a movimentação.

Portanto, o óleo é um elemento essencial para essas máquinas, sendo responsável pela transmissão da força, além de realizar a lubrificação das peças internas, evitando desgaste prematuro. Desta forma, o monitoramento do estado do óleo acaba por resultar em um método eficiente de manutenção preditiva, pois alterações no seu padrão podem sinalizar problemas futuros, como por exemplo:

- Falha no sistema de refrigeração
- Falha no trocador de calor (possível obstrução)
- Queda da pressão hidráulica geral
- Falha na bomba hidráulica
- Óleo fora do padrão aceitável (perda de viscosidade, sujo, etc)
- Falha de vedação do sistema hidráulico (entrada de ar na sucção da bomba hidráulica)
- Falha no alívio de pressão (ajuste abaixo ou igual à pressão de trabalho)

Assim, percebe-se que o óleo com temperatura fora dos padrões normais de trabalho pode ser um sintoma de diversas falhas mecânicas ou elétricas na máquina. Quando o problema ocorre sem controle e a temperatura do óleo chega no limite operacional da máquina, o CLP ou o controlador dela tende a ter um sistema de produção, causando o seu desligamento para proteção. Porém, este método ocasiona uma parada muito mais longa para conserto ou para redução natural da temperatura, além de ser um custo de peças e serviço mais alto do que no caso de uma manutenção preditiva.

Destaca-se também que a permanência do óleo em temperaturas altas pode ocasionar outros problemas, como:

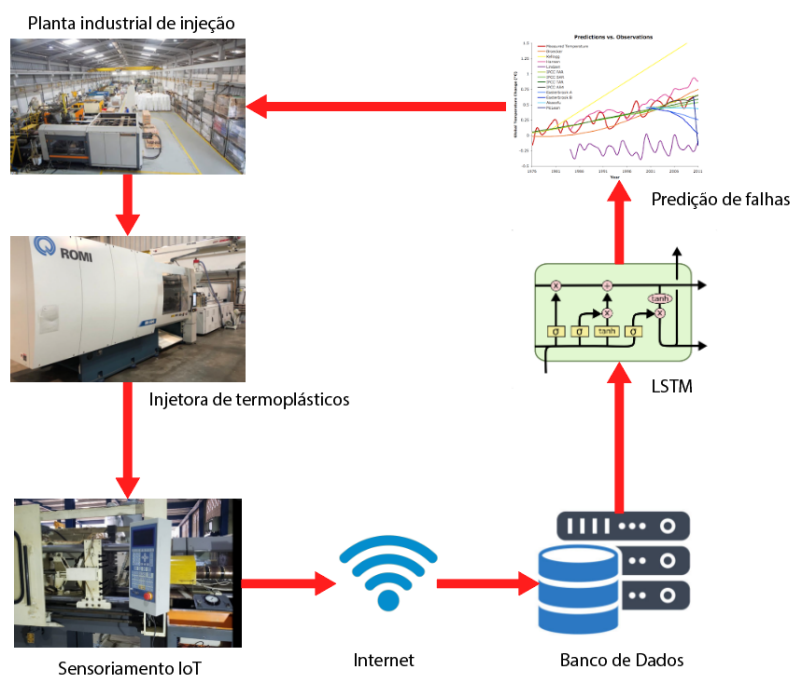
- Dano permanente ao próprio óleo, necessitando de troca
- Alteração da velocidade de operação da máquina
- Tendência de queda na pressão de trabalho
- Desgaste na bomba hidráulica

Importante salientar que todas as informações de falhas e danos relacionados à temperatura do óleo do sistema hidráulico de injetoras de termoplásticos foram levantadas a partir de comunicação com um fabricante deste tipo de maquinário, na cidade de Novo Hamburgo - RS, que colocou seu suporte técnico à disposição. Entretanto, este tipo de informação não foi encontrada em seus manuais ou documentação, a fim de ser referenciada neste trabalho.

É evidente a extrema importância que tem o monitoramento constante da temperatura do óleo do sistema hidráulico de uma máquina injetora, porém, nem sempre sendo o suficiente para conseguir o melhor rendimento possível e melhor relação custo benefício, devido às grandes paradas ocasionadas por sistemas simples de alarme de limite de temperatura operacional, método tradicional nos dias de hoje.

Portanto, o objetivo deste trabalho é o estudo da viabilidade da aplicação de inteligência artificial, através do gênero de Redes Neurais Recorrentes, visando a predição e sinalização antecipada de futuras falhas relacionadas à temperatura do óleo de máquinas injetoras de termoplásticos, conforme representado na Figura 6.

Figura 6 - Overview da proposta de solução



Fonte: Elaborado pelo autor.

4.2 Coleta de dados

Apesar deste projeto envolver apenas a etapa de análise e processamento via AI dos dados capturados de campo, é importante apresentar a estrutura responsável pela coleta de dados. Neste caso, utilizou-se de um sistema de monitoramento de produção, especificamente de injetoras de termoplásticos, já em operação há mais de um ano, de propriedade do autor deste trabalho, em uma fábrica de injeção de solados e outros componentes para calçados, da cidade de Novo Hamburgo - RS.

Este sistema de IoT, ou IIoT, realiza a coleta de diversas informações das máquinas e de seus operadores, e faz o envio, via internet, para uma sistema em nuvem, onde os dados são processados e armazenados em um banco de dados não-relacional. Este sistema já realizava o monitoramento desta temperatura de óleo, além dos outros sinais coletados no ambiente industrial, sendo portanto o fornecedor do dataset apresentado neste desenvolvimento.

Os dados coletados são relacionados ao período de setembro de 2020 até maio de 2022, oriundos de um total de três máquinas, tendo intervalos de leitura de dez, cinco e um minuto, de acordo com a evolução deste trabalho, sendo realizados apenas durante o tempo em que as máquinas estão energizadas. Portanto, não há leituras em turnos sem trabalho, em finais de semana ou feriados sem operação,

bem como em alguns intervalos de alimentação (critério de manter a máquina ligada no almoço, por exemplo, é dependente do operador) ou entre turnos, além de casos onde o aparelho permaneceu desligado para manutenção elétrica ou mecânica.

4.2.1 Sensores de temperatura

Os sensores de temperatura utilizados foram do tipo NTC, com as características 10K e com beta de 3950, com 1% de exatidão. A leitura foi realizada através de entrada analógica no microcontrolador do equipamento de monitoramento de máquinas, com posterior cálculo específico para conversão de valor de resistência elétrica em temperatura. Realizou-se a calibração dos sensores em ambiente controlado, a partir da utilização de um termômetro eletrônico de referência.

Fotografia 1 - Sensor de temperatura NTC




Fonte: Registrado pelo autor.

4.2.2 Instalação

A instalação dos sensores de temperatura se fez através de uma abertura ao local onde existe o reservatório de óleo nos modelos das máquinas injetoras utilizadas neste estudo, permanecendo o sensor colado ao corpo do reservatório. Realizou-se uma comparação entre a temperatura do óleo medida pelo controlador da máquina e a leitura realizada pelo equipamento próprio, mostrando uma diferença máxima de 1 °C, considerando-se assim satisfatório para este projeto.

Fotografia 2 - Reservatório de óleo da máquina injetora



Fonte: Registrado pelo autor.

4.3 Máquinas injetoras

As três máquinas escolhidas para participar do levantamento de dados estão disponibilizadas na Tabela 3. Todas elas operam, normalmente, em regimes de três turnos contínuos, permanecendo sem funcionamento apenas entre às 17h de sábado até às 06h de segunda-feira, geralmente. O tipo de insumo plástico injetado neste maquinário em específico é sempre poliuretano (PU) ou PVC, uma vez que elas produzem exclusivamente solados de calçados.

Tabela 3 - Lista de máquinas utilizadas no estudo

Máquina	Fabricante	Modelo	Ano
1	Himaco	Apta 140	2019
2	Himaco	Apta 140	2020
3	Himaco	Apta 140	2020

Fonte: Elaborado pelo autor.

Fotografia 3 - Máquina de injeção utilizada no estudo



Fonte: Registrado pelo autor.

4.3.1 Limites operacionais

Cada máquina injetora possui um limite operacional de temperatura do óleo hidráulico, possuindo diferentes valores, mesmo entre os mesmos modelos. Isso deve-se ao fato de cada máquina possuir características próprias, como diâmetro de tubulação, dimensão do trocador de calor, dentre outros, que alteram o limite máximo configurado em cada equipamento. Este limite é calibrado em fábrica, podendo ser alterado através da Interface Homem-Máquina da injetora, algo não recomendado pelo fabricante.

Ao atingir o limite operacional, o sistema entra em modo de proteção e o equipamento desativa totalmente a sua operação, aguardando que a temperatura seja reduzida até um valor seguro. As máquinas utilizadas neste projeto possuem diferentes limites, conforme a Tabela 4.

Tabela 4 - Lista de temperaturas operacionais de óleo máximas

Máquina	Limite (°C)
1	54
2	57
3	61

Fonte: Elaborado pelo autor.

4.4 Dataset

Como resultado da coleta extensiva de dados das máquinas descritas nos capítulos anteriores, chegou-se a um dataset composto de 189567 leituras individuais, com registro das informações de identificador único do registro (informação descartada para este trabalho), data, horário e temperatura do óleo.

A extração dos dados do banco de dados não-relacional principal se deu através de de arquivo no formato XLS, onde as informações de cada leitura compõem uma linha, com cada dado separado por vírgula à direita. Devido às características do sistema de coleta de dados, o formato recebido da temperatura é em variável int de 16 bits, com valor de base em dez.

A tabela 5, composta de um algumas leituras extraídas do banco de dados levantado junto à máquina 3, permite uma compreensão maior de como os dados são disponibilizados originalmente, a partir da abertura no software Microsoft Excel.

Tabela 5 - Extrato de banco de dados da máquina 3

24230	62617a38b7641a8c1fc0e4af,426,2022-04-21T13:10:13.000Z
24231	62617a7ab7641a8c1fc0e4ce,430,2022-04-21T13:11:13.000Z
24232	62617ab9b7641a8c1fc0e4eb,432,2022-04-21T13:12:13.000Z
24233	62617afcb7641a8c1fc0e50a,438,2022-04-21T13:13:13.000Z
24234	62617b43b7641a8c1fc0e52b,443,2022-04-21T13:14:13.000Z
24235	62617b89b7641a8c1fc0e54c,444,2022-04-21T13:15:13.000Z
24236	62617bcbb7641a8c1fc0e56b,448,2022-04-21T13:16:13.000Z
24237	62617c0eb7641a8c1fc0e58a,449,2022-04-21T13:17:13.000Z
24238	62617c51b7641a8c1fc0e5a9,455,2022-04-21T13:18:13.000Z
24239	62617c94b7641a8c1fc0e5c8,464,2022-04-21T13:19:13.000Z
24240	62617cdab7641a8c1fc0e5fb,466,2022-04-21T13:20:13.000Z
24241	62617d19b7641a8c1fc0e618,473,2022-04-21T13:21:13.000Z
24242	62617d5cb7641a8c1fc0e637,474,2022-04-21T13:22:13.000Z
24243	62617d9eb7641a8c1fc0e656,479,2022-04-21T13:23:13.000Z
24244	62617de9b7641a8c1fc0e67a,486,2022-04-21T13:24:13.000Z
24245	62617e2bb7641a8c1fc0e699,492,2022-04-21T13:25:13.000Z
24246	62617e71b7641a8c1fc0e6ba,505,2022-04-21T13:26:13.000Z
24247	62617ebbb7641a8c1fc0e6dd,519,2022-04-21T13:27:13.000Z
24248	62617f01b7641a8c1fc0e6fe,518,2022-04-21T13:28:13.000Z
24249	62617f4ab7641a8c1fc0e723,520,2022-04-21T13:29:13.000Z

Fonte: Elaborado pelo autor.

4.4.1 Intervalos de tempo

Inicialmente, o dataset foi preenchido com leituras a cada dez minutos. Conforme o decorrer do trabalho, optou-se pela redução do intervalo de tempo para cinco minutos e, por último, para um minuto. Estas alterações do intervalo de tempo foram devido ao entendimento de que mais dados e janelas amostrais se faziam necessárias para construir um resultado positivo. Uma vez que os resultados se mostraram mais detalhados com o intervalo de um minuto, optou-se por utilizar e representar neste trabalho apenas esta etapa, sendo o restante dos dados descartados.

Com isso, os dados utilizados neste estudo estão no intervalo entre as datas de 30/03/2022 e 27/05/2022. Como a leitura de temperatura depende do estado da máquina, de sua efetiva operação, e como as mesmas podem permanecer desligadas por períodos contínuos, ou por intervalos de tempo dentro de cada turno, optou-se pela filtragem de leituras dentro dos períodos de turnos diurnos, verificando a real existência de dados completos em cada série temporal.

Os turnos considerados foram entre as 7 horas e 11:30 horas da manhã, bem como entre 13h e 17:15h da tarde. Portanto, são excluídos do dataset turnos onde não há 270 leituras no turno da manhã ou 255 leituras no turno da tarde, sendo considerado um turno incompleto, resultando nos valores da Tabela 6.

Tabela 6 - Lista de turnos de cada máquina

Máquina	Total de leituras	Turnos completos	Turnos excluídos
1	53614	64	18
2	52725	58	19
3	43146	50	26

Fonte: Elaborado pelo autor.

4.5 Data engineering

Para a realização da análise dos dados, seu tratamento e modelagem, além da posterior implementação da rede neural de processamento, utilizou-se um notebook jupyter executado no ambiente de desenvolvimento da Google, chamado de Colab. Esta ferramenta permite a importação de datasets externos e a execução de diversas bibliotecas importantes ao projeto, conforme descrito na tabela 7.

Tabela 7 - Descrição dos recursos computacionais utilizados


Identificação	Versão	Descrição
Python	3.7.13	Linguagem de programação
Numpy	1.21.6	Manipulação de arrays e operações matemáticas
Pandas	1.3.5	Leitura de arquivos de banco de dados
TensorFlow	2.8.0	Modelamento e treinamento de rede neural
Keras	2.8.0	Recursos para rede neural

Fonte: Elaborado pelo autor.

4.5.1 Exibição

Em primeiro lugar, realizou-se a visualização completa dos dados do dataset, separados por cada máquina objeto de estudo. Cabe ressaltar que os períodos sem dados, onde as máquinas estavam fora de operação, representam as linhas retas dentro dos gráficos que relacionam data, horário e temperatura do óleo.


Gráfico 2 – Histórico completo de leituras da máquina 1



Fonte: Elaborado pelo autor.


É possível perceber, através da análise do gráfico completo de leituras das três máquinas, que ocorrem diversas variações de temperatura ao longo da operação dos equipamentos, tendo essas variações diversas diferenças entre os dias, entre turnos e mesmo entre as máquinas.

Gráfico 3 – Histórico completo de leituras da máquina 2



Fonte: Elaborado pelo autor.

Gráfico 4 – Histórico completo de leituras da máquina 3




Fonte: Elaborado pelo autor.

A partir da separação dos gráficos por turnos individuais, pode-se realizar a análise do comportamento típico dos dados de temperatura dos turnos filtrados de acordo com os critérios anteriormente descritos. Neste caso, percebe-se um comportamento padrão de aumento da temperatura no decorrer do tempo, conforme a operação da máquina é realizada, com o início de cada turno, e o consequente aquecimento do óleo, até uma temperatura de equilíbrio, como nos Gráficos 5 e 6.


Pode-se perceber também, como no Gráfico 7, alguns períodos de redução da temperatura, que são intervalos de tempo onde a máquina permaneceu sem operação, por algum motivo específico, como manutenção, alteração de molde de injeção, alteração de material ou cor de material, etc. Durante a parada, a temperatura do óleo apresenta uma significativa redução, uma vez que o sistema hidráulico está em repouso.

Gráfico 5 – Comportamento da temperatura de um turno contínuo de operação da máquina 1




Fonte: Elaborado pelo autor.

Gráfico 6 – Comportamento da temperatura da máquina 1 em um turno com início de operação com atraso



Fonte: Elaborado pelo autor.

Gráfico 7 – Comportamento da temperatura da máquina 1 em um turno com parada no decorrer da operação



Fonte: Elaborado pelo autor.

4.5.2 Inspeção e limpeza

O segundo ponto importante de tratamento de dados envolve a inspeção dos dados, para verificação de elementos que devem ser excluídos da análise, como outliers, falhas de leitura, períodos de funcionamento fora do padrão, etc. Este tipo de análise é feita através da avaliação dos dados, tanto em forma gráfica quanto em forma de tabelas, utilizando bibliotecas como Matplotlib e Pandas.

Não foi necessária a exclusão ou ajuste de leituras, uma vez que não houve valores outliers discrepantes, bem como não houve falha em leituras com valores inválidos.

4.5.3 Média, desvio padrão e limites

Com base nos dados do dataset de cada máquina, utilizou-se a transposição de dados para cálculo sistemático de referências importantes para a análise dos dados, como a média de temperatura de cada máquina, bem como seu desvio padrão e limites, tanto superior quanto inferior, além da separação percentual de cada faixa de temperatura.

Tabela 8 – Dados transpostos de amostras das máquinas

Máquina	Leituras	Média (°C)	Desvio padrão (°C)	Mínimo (°C)	Máximo (°C)	Distribuição (°C)		
						25 %	50 %	75 %
1	53614	41,9	5,3	17,6	55,7	38,8	42,9	45,6
2	52725	38,5	4,9	17,8	52,9	35,8	39,1	41,5
3	43146	38,5	5,9	16,2	56,4	35,0	39,1	43,0

Fonte: Elaborado pelo autor.


Uma percepção sumária da verificação da Tabela 8 é de que, muito provavelmente, cada máquina deverá ter o seu modelo de redes neurais individualmente treinado, sem cruzamento de histórico. Chega-se a esse conceito através da percepção, junto às análises dos Gráficos 2, 3 e 4, que os valores

padrões de temperatura, bem como as taxas de variação em operação e parada, possuem uma diferença significativa.

4.5.4 Histograma

Como forma de análise geral dos dados de histórico, criou-se o histograma de todos os valores filtrados do dataset estudado, separados para cada máquina sob estudo. Neste histograma, representado no Gráfico 8, pode-se verificar o agrupamento das medidas de temperatura coletadas, o que auxilia na determinação dos parâmetros de treinamento da rede neural.

Gráfico 8 – Histograma das leituras das máquinas




Fonte: Elaborado pelo autor.

4.5.5 Distribuição

Outra forma de análise geral dos dados é através do gráfico de distribuição dos valores de temperatura, representado no Gráfico 9, ainda não normalizados, assim como os dados utilizados no histograma.

Gráfico 9 – Distribuição das leituras das máquinas



Fonte: Elaborado pelo autor.

4.6 Modelo de dados

A partir da análise dos dados obtidos nos datasets de cada máquina, pode-se realizar a construção da estrutura a ser aplicada na rede neural, para então ser possível realizar o seu treinamento e posterior análise de resultados.

4.6.1 Separação em conjuntos

Decidiu-se pela separação do dataset objeto de treinamento em três grupos separados, chamados de treinamento, validação e testes. O grupo de treinamento é utilizado diretamente no treino da rede neural, enquanto o grupo de validação é utilizado para a análise das métricas de desempenho do sistema. O último grupo de teste, que não é inserido nos métodos das bibliotecas de treinamento de ML, pode também ser utilizado como avaliação de desempenho da rede e suas previsões.

Optou-se pelo critério utilizado por Melchiades et al. (2021), em um trabalho que envolve previsão de índices de equipamentos com base em sensoriamento, de dividir os datasets da seguinte forma: 80 % dos turnos para treinamento, 10 % dos turnos para validação e 10 % dos turnos para testes, resultando na quantidade descrita na Tabela 9.

Tabela 9 - Quantidade de turnos em cada conjunto

Máquina	Treinamento	Validação	Teste
1	51	6	7
2	46	6	6
3	40	5	5

Fonte: Elaborado pelo autor


A seleção é feita em ordem cronológica, evitando assim a introdução de viés, bem como observa-se que os conjuntos de turnos são selecionados de forma disjuntiva e exaustiva, ou seja, cada amostra de dados pertence a exatamente e apenas um conjunto.

4.6.2 Janelamento de dados

Uma forma bastante efetiva de modelo dos dados a serem aplicados no treino de redes neurais é através do janelamento das leituras, criando assim uma quantidade de dados bastante superior de séries temporais possíveis de serem utilizadas.

Após a análise dos dados presentes nos datasets, levando-se em consideração também da necessidade de uma sinalização de potencial de falha futura em tempo hábil para a solução do problema, optou-se pelo janelamento com 30 dados de entrada e 30 dados de saída, com um intervalo também de 30 minutos. Considerando que o sistema é alimentado com dados a cada minuto, pode-se estimar que o aviso de futura ultrapassagem do limite da temperatura do óleo poderá ser realizado com até 30 minutos de antecedência.

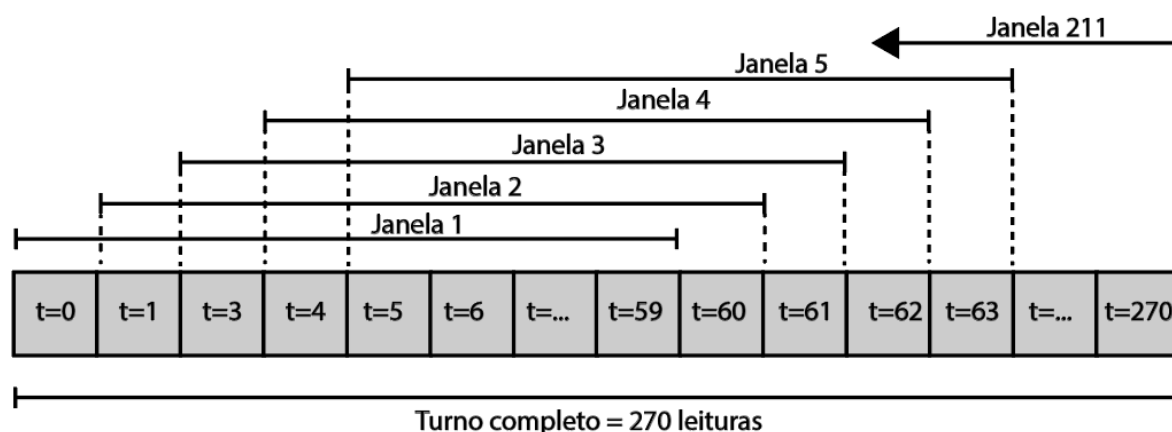
Figura 7 – Estrutura de janelamento



Fonte: Elaborado pelo autor.

Uma vez que a dimensão total da janela desta abordagem é de 60 unidades, e que o janelamento cria diversos recortes dos dados a partir da série temporal original, sabe-se então que cada turno da manhã é capaz de gerar 211 diferentes janelas de 60 medidas, enquanto um turno da tarde tem capacidade de gerar 196 janelas, chegando-se aos valores descritos na Tabela 9.

Figura 8 – Exemplo de janelamento de cada turno da manhã



Fonte: Elaborado pelo autor.

Também aplica-se neste projeto o uso da opção de embaralhamento das amostras durante o treinamento da rede, visando assim uma maior capacidade de generalização e menor possibilidade de existência de viés.

Tabela 10 - Quantidade de amostras para cada conjunto

Máquina	Treinamento	Validação	Teste
1	10401	1221	1417
2	9361	1221	1221
3	8125	1025	1010

Fonte: Elaborado pelo autor.

4.6.3 Normalização

Visando aumentar a performance e obter melhor resultados, utilizou-se do método de normalização de dados *Rolling Z-Score*, utilizado com sucesso por Melchiades et al. (2021), método esse que calcula o valor normalizado de cada leitura a partir do seu conjunto amostral dentro da sua janela de dados.

Para tanto, calcula-se tanto a média quanto o desvio padrão dos elementos de entrada e dos elementos de saída, para então realizar a operação final de transcrição total da janela, de elementos originalmente representados em graus centígrados, para uma escala comum e reduzida.

$$z = \frac{x - \text{mean}(x)}{\text{std}(x)} \quad (1)$$

Onde,

$z \rightarrow$ valor normalizado

$x \rightarrow$ valor original a ser normalizado

$\text{mean}(x) \rightarrow$ média da série

$$\bar{x} = \frac{\sum x_i}{n} \quad (2)$$

$\text{stdev}(x) \rightarrow$ desvio padrão da série

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1} \quad (3)$$

4.7 Modelo de rede

Através da biblioteca TensorFlow e da biblioteca Keras, criou-se o modelo de rede neural recorrente a ser utilizado no treinamento dos datasets oriundos das três máquinas injetoras objeto de estudo. A base do modelo consiste em uma adaptação da estrutura por Melchiades et al. (2021), resultando em uma camada LSTM, duas camadas *Dense* e uma camada de *Dropout*, totalizando quatro camadas.

A camada LSTM foi inserida com quantidades variáveis de neurônios, a partir do critério adotado de um, quatro e oito neurônios para cada elemento de entrada de cada janela de dados, que neste caso é de 30 medidas. Já as duas camadas *Dense* possuem configuração fixa de 30 unidades cada, enquanto a camada de *Dropout* também foi aplicada com valores variáveis, de taxa de 0,5 e 0,9.

A estrutura da rede LSTM foi construída de acordo com o padrão *Multi-step Single-shot*, modelo que visa a predição de múltiplos valores futuros, em um único processamento, com base no aprendizado do histórico do dataset. As alterações de quantidade de neurônios e da taxa da camada de *Dropout* serviram como referência

para a análise dos resultados, buscando o melhor resultado possível, tanto em acurácia quanto em eficiência.

A função de perda *Loss* foi definida a partir do uso do erro quadrático médio (MSE), que consiste na média do somatório do valor quadrático dos erros entre o valor da predição e o valor real.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (4)$$

Também encontrava-se ativada a análise do erro médio absoluto (MAE), que realiza o cálculo da média dos erros entre o valor da predição e o valor real em cada época de treinamento (QI et al., 2020). Este método é amplamente utilizado e indicado para redes do tipo LSTM RNN, portanto, mostra-se um bom parâmetro de desempenho para o sistema proposto neste trabalho.

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (5)$$

O otimizador utilizado trata-se da versão *Adaptive Moment Estimation* (ADAM) do gradiente estocástico descendente (SGD), com sua configuração padrão. ADAM mostra-se uma boa escolha uma vez que é um algoritmo de primeira ordem de SGD bastante utilizado na área e que possui alta eficiência computacional, baixo requerimento de memória e bastante otimizado para tratamento de largos datasets (KINGMA; BA, 2017). A Tabela 11 resume toda a estrutura e os hiperparâmetros utilizados na proposta de solução.

Tabela 11 - Parâmetros da rede neural

Parâmetro	Configuração
Padrão	LSTM RNN
Modelo	Multi-step Single-shot
Camada LSTM	1x 30, 120 e 240 neurônios
Camada Densa	2x 30 unidades
Camada Dropout	0,5 e 0,9

Otimizador	ADAM
Função de perda	Mean Absolute Error
Batch	32 amostras

Fonte: Elaborado pelo autor.

4.7.1 Critério de parada

Ao realizar o treinamento das redes neurais, são comuns dois tipos de problemas. O primeiro deles consiste na realização de quantidade insuficiente de épocas, resultando em resultados inferiores aos possíveis com a configuração escolhida do modelo. O segundo problema normalmente encontrado ocorre quando há excesso de treinamento da rede, ou seja, a rede pode apresentar a característica chamada de *overfitting*, quando a mesma é demasiadamente ajustada especificamente para o conjunto de treino, apresentando resultados inferiores em outros conjuntos de dados.

De acordo com Valença (2007), um bom método para analisar a quantidade ideal de épocas de treinamento consiste no uso da técnica de validação cruzada. Através desta técnica, avalia-se a capacidade de generalização da rede a partir da comparação entre as melhores de desempenho de MAE dos conjuntos de teste e validação.

Considerando que o ajuste de pesos da rede neural não utiliza o conjunto de validação, a análise de performance do mesmo é um ótimo critério para avaliar o desempenho da rede. Portanto, o treinamento monitora constantemente o MAE relativo ao conjunto de validação e, ao detectar a parada de melhora de seu índice, ele interrompe o processo, respeitando o critério de quantidade de treinamentos sem melhora configurado pelo usuário, neste caso fixado em 5.

-

5 ANÁLISE DOS RESULTADOS

Nesta etapa, são exibidos os resultados encontrados na experimentação prática do modelo de dados e da rede neural proposta na seção 4. Estes resultados estão baseados nos índices encontrados no histórico final de cada treinamento e na posterior aplicação do conjunto de dados de testes.

Inicialmente, são detalhados os treinamentos propostos, para então a apresentação dos resultados finais. Através destes resultados, é possível a realização de comparação e diagnóstico completo, visando a indicação da melhor configuração para a estrutura de dados proposta, bem como a análise de eficácia de uma rede LSTM para o problema central deste trabalho.

5.1 Treinamento da rede

No total, foram realizados 6 treinamentos diferentes para cada máquina, com a variação entre eles de hiperparâmetros de quantidade de neurônios na camada LSTM ou no índice de taxa de *Dropout*, resultando no total de 18 treinamentos para os três datasets.

Após cada treinamento, registrou-se diversas informações pertinentes para uma análise completa da rede neural. Conforme a Tabela 12, foram registrados a quantidade de épocas de treinamento até que o processo fosse interrompido pelo critério de parada descrito no Capítulo 4.7.1, o intervalo de tempo de processamento de cada época, em segundos, e os índices de função de perda e de MAE.

Tabela 12 - Resultados de treinamento da rede para máquina 1

Treinamento		1	2	3	4	5	6
Parâmetro	Neurônios	30	120	240	30	120	240
	Dropout	0,5	0,5	0,5	0,9	0,9	0,9
Epochs	Quantidade	28	32	32	16	25	35
	Intervalo (s)	5	10	28	5	10	29
Loss	Treino	0,420	0,302	0,283	0,903	0,559	0,434
	Validação	0,304	0,261	0,246	0,498	0,326	0,283
	Teste	0,285	0,274	0,303	0,500	0,309	0,305

MAE	Treino	0,451	0,376	0,363	0,689	0,531	0,462
	Validação	0,367	0,334	0,326	0,498	0,385	0,350
	Teste	0,351	0,314	0,327	0,499	0,372	0,351

Fonte: Elaborado pelo autor.

Tabela 13 - Resultados de treinamento da rede para máquina 2

Treinamento		1	2	3	4	5	6
Parâmetro	Neurônios	30	120	240	30	120	240
	Dropout	0,5	0,5	0,5	0,9	0,9	0,9
Epochs	Quantidade	19	18	17	10	26	29
	Intervalo (s)	5	9	27	5	9	27
Loss	Treino	0,565	0,433	0,414	1,122	0,690	0,574
	Validação	0,433	0,371	0,389	0,727	0,451	0,386
	Teste	0,429	0,392	0,408	0,712	0,445	0,391
MAE	Treino	0,548	0,472	0,457	0,804	0,616	0,556
	Validação	0,484	0,433	0,444	0,668	0,499	0,439
	Teste	0,456	0,407	0,420	0,635	0,470	0,408

Fonte: Elaborado pelo autor.

Tabela 14 - Resultados de treinamento da rede para máquina 3

Treinamento		1	2	3	4	5	6
Parâmetro	Neurônios	30	120	240	30	120	240
	Dropout	0,5	0,5	0,5	0,9	0,9	0,9
Epochs	Quantidade	41	17	11	13	14	13
	Intervalo (s)	4	8	23	4	8	22
Loss	Treino	0,559	0,493	0,476	1,114	0,738	0,631
	Validação	0,416	0,440	0,433	0,673	0,519	0,430
	Teste	0,449	0,451	0,458	0,680	0,497	0,476
MAE	Treino	0,560	0,520	0,510	0,814	0,656	0,603
	Validação	0,469	0,475	0,459	0,639	0,534	0,477

	Teste	0,477	0,471	0,471	0,641	0,517	0,509
--	-------	-------	-------	-------	-------	-------	-------

Fonte: Elaborado pelo autor.

5.2 Discussão dos resultados

A partir da compilação dos resultados encontrados em cada treinamento, pode-se realizar a análise de qual configuração da rede proporcionou os melhores resultados. De acordo com o critério adotado, de melhores resultados de MAE para o conjunto de validação, chega-se à conclusão de que a performance com melhor relação de custo x benefício é através do uso de 240 neurônios na camada LSTM para as máquinas 1 e 3, e do uso de 120 neurônios para a máquina 2, além de taxa de 0,5 na camada de *Dropout*, conforme detalhado na Tabela 15.

5.2.1 Melhores resultados

Tabela 15 - Melhores resultados de treinamento da rede para as máquinas

Rede LSTM		Máquina 1	Máquina 2	Máquina 3
Parâmetro	Neurônios	240	120	240
	Dropout	0,5	0,5	0,5
Epochs	Quantidade	32	18	11
	Intervalo (s)	28	9	23
Loss	Treino	0,283	0,433	0,476
	Validação	0,246	0,371	0,433
	Teste	0,303	0,392	0,458
MAE	Treino	0,363	0,472	0,510
	<u>Validação</u>	<u>0,326</u>	<u>0,433</u>	<u>0,459</u>
	Teste	0,327	0,407	0,471

Fonte: Elaborado pelo autor.

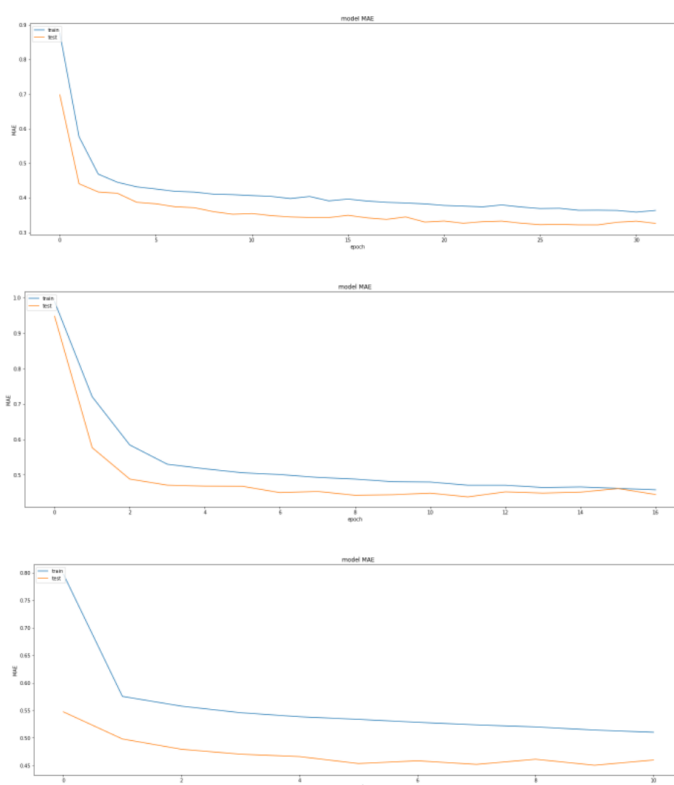
É possível concluir que existe uma melhora nos resultados de MAE do conjunto de validação no incremento de 120 para 240 neurônios, enquanto também ocorre um aumento considerável no intervalo de tempo necessário para o processamento de cada época, na ordem de três vezes.

Outra conclusão possível, também de acordo com a Tabela 14, é de que existe uma considerável melhora no resultado final das avaliações de performance do conjunto de validação de acordo com a quantidade total de amostras a serem aplicadas nas bateladas de dados utilizadas no treino da rede. Isso torna-se claro, uma vez que o melhor desempenho foi do dataset da máquina 1, que possui em torno de 10 % a mais de janelas de dados em relação à máquina 2 e 28 % a mais em relação a máquina 3.

5.2.2 Relação entre MAE e épocas

Levando em consideração que o intervalo de tempo de treinamento de cada época pode ser considerado importante para um sistema que faça o contínuo aprendizado, de acordo com a entrada de novos dados, pode-se realizar também um estudo com relação à melhora do índice de MAE em relação ao número de épocas.

Gráfico 10 - Variação de MAE em relação às épocas de treinamentos



Fonte: Elaborado pelo autor.


Os gráficos de MAE apresentam uma certa estabilidade a partir de uma determinada quantidade de épocas realizadas, portanto, mostrando correta a

escolha pelo critério de parada. Em caso de uso de quantidade superiores de épocas, corre-se o risco de *overfitting*, trazendo assim melhores resultados para o conjunto de treino, mas degradando consideravelmente a capacidade de generalização da rede para novos dados.

5.2.3 Qualidade de predições

A partir do uso do método de prediction disponível nos modelos das rede neurais após os treinamentos, é possível a visualização de gráficos que relacionam predições reais, baseadas nos conjuntos de validação ou teste, conjuntos esses que não fizeram parte do histórico de leituras utilizados na compilação da rede.

Gráfico 11 - Predições de qualidade da máquina 1




Fonte: Elaborado pelo autor.

O Gráfico 11 exibe o cenário mais comum das predições do modelo da máquina 1, onde verifica-se uma boa qualidade de valores, quando compara-se os valores reais e os valores calculados. Neste exemplo de períodos aleatórios, apesar da baixa capacidade de acurácia no que diz respeito ao detalhamento da curva de temperatura, pode-se perceber que a rede consegue modelar corretamente a

tendência de incremento da temperatura do óleo, o que se mostra condizente com a capacidade de detecção antecipada de aumentos expressivos deste índice.

Gráfico 12 - Predições de baixa qualidade da máquina 1




Fonte: Elaborado pelo autor.

Já o Gráfico 12 apresenta com mais detalhes a teórica baixa capacidade de acurácia e de pequenas variações temporárias da temperatura, mesmo para o modelo da máquina 1, que apresentou o melhor resultado em relação ao critério adotado de MAE do conjunto de validação. Mesmo assim, mais uma vez a rede foi capaz de prever a curva de tendência da temperatura, tanto na subida quanto na descida.

Uma análise primária deste comportamento, a partir da investigação de mais gráficos de previsões das máquinas 2 e 3, parece sugerir que a forma ideal de atingir maior detalhamento na curva de temperatura e melhor resposta em curtas variações de temperatura, é através de maior quantidade de dados a serem utilizados no treinamento. Essa conclusão está baseada no maior detalhamento e desempenho da rede da máquina 1, que possui uma quantidade consideravelmente maior de amostras em suas bateladas de treino.

Outro ponto importante que foi observado no ensaio de qualidade das previsões, possível de ser visualizado no Gráfico 13, é a baixa qualidade de previsões em casos de paradas de máquinas. Neste caso, considera-se que o uso de apenas um feature, a temperatura do óleo da máquina, é um fator limitante na busca pelo incremento de acurácia. A variação de temperatura, como no caso do Gráfico 13, pode se dar ao fato de que a máquina não está em operação, mas também ao incremento da temperatura interna para derretimento do plástico, à temperatura ambiente, ao nível de pressão utilizado na injeção, ao índice de dissipação individual de cada máquina, entre outros.

Gráfico 13 - Predições de turno com uma parada da máquina 1



Fonte: Elaborado pelo autor.

5.2.4 Comparação cruzada

Optou-se por realizar uma comparação cruzada da performance dos modelos de redes. Isso foi feito a partir do uso do método de evaluate do modelo, a partir da inserção dos conjuntos de dados das outras máquinas, sempre observando-se o uso do modelo com melhor desempenho em cada máquina.

Tabela 16 - Comparação cruzada de conjunto de validação entre modelos


Modelo	Performance					
	Máquina 1		Máquina 2		Máquina 3	
	Loss	MAE	Loss	MAE	Loss	MAE
Máquina 1	0,246	0,326	0,480	0,464	0,487	0,470
Máquina 2	0,356	0,395	0,389	0,444	0,449	0,477
Máquina 3	0,297	0,357	0,455	0,471	0,433	0,459

Fonte: Elaborado pelo autor.

A Tabela 16 apresenta a comparação dos resultados de performance cruzada, estando em negrito os valores originais para as máquinas de cada rede. É possível perceber que ocorre uma considerável degradação na capacidade de generalização das redes, mesmo no modelo de melhor desempenho da máquina 1, quanto dados de outras máquinas são aplicados.

Para maior clareza e visualização da comparação cruzada dos conjuntos, o Gráfico 14 apresenta as informações em forma de barras.


Gráfico 14 - Comparação cruzada das 3 máquinas



Fonte: Elaborado pelo autor.

Esse cenário, onde cada máquina necessita de seu próprio treinamento, já era previsto na Metodologia deste projeto. Este experimento apenas confirmou a extrema dificuldade de criação de uma rede única para máquinas diversas, mesmo quando postos à prova os dados de mesmo fabricante e modelo.

Gráfico 15 - Predições para máquina 2 com modelo da máquina 1



Fonte: Elaborado pelo autor.

Por último, o Gráfico 15 apresenta uma simulação de predição realizada pela rede da máquina 1, com a entrada de dados reais da máquina 2. Percebe-se uma

redução significativa na capacidade de previsão da curva de temperatura, mesmo em termos de tendência, o que torna o resultado inferior ao encontrado no capítulo 5.2.3.

6 CONCLUSÃO

Este trabalho teve por objetivo o estudo da viabilidade da criação de uma solução de Manutenção Preditiva de Condição a partir da predição do aumento anormal da temperatura do óleo do sistema hidráulico em máquinas injetoras de termoplásticos. A implementação deste tipo de sistema é bastante desafiadora, uma vez que exige o estudo e a aplicação de diversos conceitos e técnicas, principalmente das áreas de Internet das Coisas e *Machine Learning*.

Para atingir este objetivo, foi proposta a implementação de Redes Neurais, especificamente do tipo Redes Neurais Recorrentes, através da arquitetura *Long Short-Term Memory*, amplamente utilizada em sistemas de Inteligência Artificial para previsão de grandezas físicas, uma vez que é adequada para classificar e prever séries temporais com intervalos de tempo arbitrários.

A construção do dataset de dados a serem utilizados no treinamento da rede se deu a partir da coleta em tempo real da temperatura do óleo do sistema hidráulico em máquinas injetoras em uma planta fabril durante vários meses. Com este banco de dados, foi possível o estudo e a construção da estrutura de amostras e da construção do modelo da Rede Neural.

Com os resultados apresentados nas simulações com as redes treinadas com os datasets das máquinas, a partir dos critérios de índice de MAE de conjuntos de dados de validação e teste, bem como da avaliação da qualidade da curva de predições de depurações em períodos aleatórios, chega-se à conclusão de que é possível o uso de redes RNN do tipo LSTM para a predição do comportamento anormal da temperatura do óleo do sistema hidráulico de máquinas injetoras.

A partir do recebimento da informação antecipada do problema em questão, a administração de uma fábrica poderia, ao utilizar uma solução como esta, tomar medidas preventivas para evitar a parada completa da máquina, ou mesmo a operação com temperatura elevada. As ações a serem tomadas em uma situação de aviso prévio de sobreaquecimento, como por exemplo o aumento da refrigeração durante um intervalo específico, ou a alteração do produto sendo produzido e, em consequência, da intensidade de pressão, dentre outras, necessitam de uma melhor avaliação específica para os modelos de máquinas e de estrutura de cada empresa. Além disso, pode-se dizer que seria muito importante a realização de um estudo

específico para apresentar as possibilidades e avaliar o desempenho de cada solução para a tomada de decisão e ação a partir desta detecção preditiva.

Desta forma, observou-se a grande capacidade das áreas de IoT, *Big Data* e ML, quando atuando de forma integrada, em oferecer soluções efetivas e tecnicamente viáveis, que podem ser a porta de entrada de muitas empresas para a entrada na revolução da Indústria 4.0.

6.1 Sugestões para trabalhos futuros

Ao mesmo tempo em que este trabalho confirmou a viabilidade do objetivo inicial, ele também permitiu a reflexão sobre alguns pontos importantes e que merecem maior atenção e devem ser considerados em estudos futuros, pois permitiriam uma melhora significativa nos resultados do projeto.

Em primeiro lugar, conforme descrito no Capítulo 5.2.3, a adição de novas features se mostra um modo bastante promissor de aprimorar o desempenho da NR. Informações extras, como de estado de operação, de pressão hidráulica utilizada, de temperatura ambiente, bem como o estado das resistências elétricas das máquinas, poderiam ser adicionadas aos dados de entrada das séries temporais, proporcionando à rede um melhor desempenho, maior qualidade das predições e maior taxa de acerto de tendência de ultrapassagem futuro do limite operacional.

Em segundo lugar, o estudo do desempenho da rede através de alterações no formato do modelo se faz necessário. Sugere-se o estudo relativo à alteração da quantidade e posição de camadas LSTM, com variações também do número de neurônios, bem como da quantidade e posição de camadas *Dense* e de *Dropout*. Saliencia-se que o aumento da quantidade de camadas no modelo em caso de aumento no número de features é bastante provável, dada à maior complexidade desta estrutura de dados, e também merece atenção e análise. Outra possível comparação seria entre a própria rede LSTM e outros métodos de predição de séries temporais, como ARIMA.

Por último, com base nos resultados também presentes no Capítulo 5.2.3, pode-se definir que é de suma importância uma grande quantidade de leituras, visando também a melhora do treinamento e, em consequência, do desempenho das predições da Rede Neural. Os resultados deste trabalho sugerem que melhores

performances dependem diretamente da oferta de grandes quantidades de amostras para o treinamento, algo a ser observado em futuros projetos da área.

REFERÊNCIAS

ABIPLAST. Perfil 2020. **A indústria de transformação e reciclagem de plástico no Brasil**. Disponível: <<http://www.abiplast.org.br/publicacoes>>. Acesso em: 30 de abril de 2022.

ABREU, A. M.; SOARES, I. M; SOUZA, O. **Termografia em manutenção preditiva: conceitos e aplicabilidades em máquinas e equipamentos industriais**. Bolsista de Valor: Revista de divulgação do Projeto Universidade Petrobras e IF Fluminense, vol. 2, n. 1, 2012.

BARBOSA, G. F.; AROCA, R. V. **An IoT-Based Solution for Control and Monitoring of Additive Manufacturing Processes**. J. POWDER METALL MIN, v.6, n.158, p. 2, 2017. Disponível em: <http://www.omicsonline.org/open-access/an-iotbased-solution-for-control-and-monitoring-of-additivemanufacturing-processes-2168-9806-1000158.php>. Acesso em: 20 de abril de 2022.

BENGIO, Y.; COURVILLE, A.; VINCENT, P. **Representation learning: a review and new perspectives**. IEEE transactions on pattern analysis and machine intelligence, v. 35, n. 8, 2016.

CitiSystems. **Indústria 4.0: O que é, e como ela vai impactar o mundo**. Disponível em: <<https://www.citisystems.com.br/industria-4-0/>>. Acesso em 26 de maio de 2022.

CHIU, M., TSAI, C., Li, T. **An Integrative Machine Learning Method to Improve Fault Detection and Productivity Performance in a Cyber-Physical System**. ASME. *J. Comput. Inf. Sci. Eng.* April 2020.

DAVARI, Narjes; VELOSO, Bruno; COSTA, Gustavo; PEREIRA, Pedro; RIBEIRO, Rita; GAMA, João. **A Survey on Data-Driven Predictive Maintenance for the Railway Industry**. Sensors 2021, 21, 5739.

DILMEGANI, C. **Predictive Maintenance: In-depth Guide**. In: **AI Multiple**. 27 mar. 2018. Disponível em: <<https://blog.aimultiple.com/predictive-maintenance/>>. Acesso em: 4 de abril de 2022.

GIANETTI, C.; ESSIEN, A. **Towards scalable and reusable predictive models for cyber twins in manufacturing systems**. *J Intell Manuf* 33, p. 441–455, 2022.

HOCHREITER, S.; SCHMIDHUBER, J. **Bridging long time lags by weight guessing and Long Short-Term Memory**. *Spatio temporal models in biological and artificial systems*, 2001.

IBM. **Machine Learning e Ciência de dados com IBM Watson**. Disponível em: <<https://www.ibm.com/br-pt/analytics/machine-learning>>. Acesso em: 30 de novembro de 2021.

KAGERMANN, H; WAHLSTER, W; HELBIG, J; **Recommendations for implementing the strategic initiative INDUSTRIE 4.0**. Final report of the Industrie 4.0, p. 82, 2013.

KARDEC, Alan; NASCIF, Júlio. **Manutenção: função estratégica**. 3.ed. Rio de Janeiro: Ed. Qualitymark, p. 384, 2009.

KINGMA, Diederik; BA, Jimmy Lei. **ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION**. 3rd International Conference on Learning Representations - ICLR 2015.

KHORRAM, A.; KHALOOEI, M.; REZGHI, M. **End-to-end CNN+LSTM deep learning approach for bearing fault diagnosis**. *ApplIntell* 51, p. 736–751, 2021.

SOUZA, Marcos; COSTA, Cristiano; RAMOS, Gabriel; RIGHI, Rodrigo. **A feature identification method to explain anomalies in condition monitoring**. *Computers in Industry*, Volume 133,103528, ISSN 0166-3615, 2021.

MATEUS, B.; MENDES, M.; FARINHA, J.; CARDOSO, A.M. **Anticipating Future Behavior of an Industrial Press Using LSTM Networks**. *Appl. Sci*, 11, 6101, 2021.

MAURA, Sandra. **Os caminhos para a transformação das empresas no futuro**. **In: Indústria 4.0.** , 12 out. 2019. Disponível em: <[https://www.industria40.ind.br/artigo/18906-industria-40-os-caminhos-para-a-transfo](https://www.industria40.ind.br/artigo/18906-industria-40-os-caminhos-para-a-transformacao-das-empresas-para-o-futuro)
[rmacao-das-empresas-para-o-futuro](https://www.industria40.ind.br/artigo/18906-industria-40-os-caminhos-para-a-transfo)>. Acesso em: 29 de maio de 2022.

MELCHIEADES, Mateus; SCHREIBER, Lincoln; RAMOS, Gabriel; CROVATO, Cesar; MEJIA, Rodrigo; RIGHI, Rodrigo. **Anticipating faults by predicting non-linearity of environment variables with neural networks: a case study in semiconductor manufacturing**. 2021.

MÊUSER, JS. **Fundamentos das redes neurais: exemplos em java**. Recife, 2010.

MOBLEY, R. Keith. **AN INTRODUCTION TO PREDICTIVE MAINTENANCE**. Second edition. Butterworth Heinemann, 2002.

MOLDES INJEÇÃO PLÁSTICOS. **Moldagem, ciclos e etapas de moldagem**. Disponível em: <<http://moldesinjecaoplasticos.com.br/moldagem-ciclo-e-etapas-de-moldagem/>>. Acesso em: 26 de maio de 2022.

MONCHY, François. **A Função Manutenção: Formação para a gerência da Manutenção Industrial**. 1.ed. São Paulo: Editora Durban, p. 424, 1987.

MOYA, M. **The control of the setting up of a predictive maintenance programme using a system of indicators**. Omega: The International Journal of Management Science, Volume 32, Issue 1, 2004, p. 57–75.

NORVIG, Peter; RUSSEL, Stuart. **Artificial Intelligence: A Modern Approach**. Englewood, 1995.

PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. **Guidelines for conducting systematic mapping studies in software engineering: An update**. Information and Software Technology. v. 64, p. 1–18, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950584915000646>>. Acesso em: 5 de maio de 2022.

QI, Jun; DU, Jun; SINISCALCHI, Marco. **On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression**. IEEE Signal Processing Letters, pg. 1485 - 1489, 2020.

SOUZA, Valdir Cardoso de. **Organização e Gerenciamento da Manutenção: Programa e Controle de Manutenção**. 4. ed. All Printe Editora, São Paulo, 2011.

WANG, K. **Intelligent predictive maintenance (IPdM) system – Industry 4.0 scenario**. Advanced Manufacturing and Automation V, WIT transaction on Engineering Science Vol. 113, pp. 259-268, 2016.

WANG, Shiyong et al. **Implementing Smart Factory of Industrie 4.0: An Outlook**. International Journal of Distributed Sensor Networks, 2016.

XAVIER, J.; PINTO, A. **Manutenção Função Estratégica**. 2 ed. Qualitymark. Rio de Janeiro, 1999.

YANG, J; LU, W; LIU, X, **Prediction of Top Oil Temperature for Oil-immersed Transformers Based on PSO-LSTM**. 4th International Conference on Energy, Electrical and Power Engineering, pp. 278-283, 2021.

YU, Zhibin; MOIRANGTHEM, Dennis; LEE, Minho. **Continuous Timescale Long-Short Term Memory Neural Network for Human Intent Understanding**. Front. Neurorobot. 11:42, 2017.