

# MANUTENÇÃO PREDITIVA USANDO MACHINE LEARNING

Pedro Reginaldo Tome Silva<sup>1</sup>, Giuliano Araujo Bertoti<sup>2</sup>

<sup>1</sup> Aluno do curso de Análise e Desenvolvimento de Sistemas da FATEC-SJC

<sup>2</sup> Prof. Me. do curso de Análise e Desenvolvimento de Sistemas da FATEC-SJC  
pedro.silva201@fatec.sp.gov.br, giuliano.bertoti@fatec.sp.gov.br

## Resumo

Atualmente nossa vida depende de diversas máquinas, tanto aquelas usadas na produção de alimentos, vestimentos, construção civil, eletrodomésticos, geração de energia e produtos no geral, como também meios de transportes como aviões, barcos, carros, motos, caminhões, helicópteros e equivalentes. Ambos possuem peças que se desgastam ao longo do tempo e precisam ser substituídas. Porém, esperar que a peça se danifique pode causar transtornos como a interrupção da produção de um alimento ou mesmo um acidente com um avião ou um automóvel. O objetivo deste artigo é apresentar o desenvolvimento de um software de manutenção preditiva, usando Machine Learning, que permite a identificação de desgaste ou defeito de uma peça antes que a máquina em questão quebre ou apresente defeito, podendo assim, ser resolvido de forma segura, cuidadosa e ágil, aumentando a segurança de todos os envolvidos direta e indiretamente, também tornando-se mais viável a economia financeira de peças e, principalmente, de tempo para ser reparados todos os locais de onde há possíveis e eventuais falhas.

## 1. Introdução

Manutenção preditiva pode ser definida da seguinte forma: medidas que detectam o início da degradação do sistema, permitindo assim que os estressores causais sejam eliminados ou controlados antes de qualquer deterioração do estado físico do componente, ocasionando principalmente na condição quantitativa do material ou equipamento [1]. Geralmente se encontra em motores de veículos automotores, veículos elétricos, aviões, locomotivas, automotrizas, equipamentos náuticos, máquinas de obras, equipamentos de uso industrial, geradores de energia elétrica e similares.

Para identificar problemas é necessária a análise contínua do equipamento, podendo ser por meio de vibração, ultrassom, termografia, inspeções técnicas para análise não destrutivas, utilizando os princípios da Internet das Coisas, bem como adiantar determinadas revisões para melhor aperfeiçoamento do dispositivo [2].

Analisar dados coletados por meios computacionais e transformá-los em informações úteis para prever através da Machine Learning as preferências e necessidades dos usuários é equivalente à analisar o histórico de máquinas, equipamentos ou instrumentos para prever eventos como, por exemplo, falhas que podem parar ou atrasar processos, além de gerar grandes

prejuízos das empresas. Logo a quarta revolução industrial depende, em grande parte, dos avanços gerados pela tecnologia [3].

Um dos exemplos é a implementação de um software em nuvem para a realização de manutenções preditivas de forma periódica, aumentando a eficiência dos aviões, principalmente em voos de longa distância, trazendo uma maior objetividade do serviço como um todo [4].

Assim, o objetivo do projeto é desenvolver um sistema que realiza a manutenção preditiva usando Machine Learning, por meio da plataforma Teachable Machine que reconhece ruídos de objetos em estado normal e os compara com sons que estavam apresentando uma determinada falha durante a execução como, por exemplo, a comparação entre um carro em boas condições e outro que apresenta problemas no escapamento do veículo.

## 2. Metodologia e Materiais

O primeiro passo no desenvolvimento foi gravar dois sons de um ventilador, um em condições normais e outro aparentando problemas. O uso do ventilador também serviu para suprir a necessidade de visitar fábricas, oficinas mecânicas, construções, usinas de geração de energia elétrica, além de similares, reduzindo assim custos burocráticos e logísticos.

A plataforma Teachable Machine, utilizada neste projeto, é uma ferramenta que envolve o reconhecimento de imagens e sons, através de inteligência artificial, por meio de uma câmera para a gravação de imagens, áudios e vídeos, com um microfone para a gravação de áudio [5].

Com isso um computador com microfone foi utilizado para gravar os áudios do aparelho em dois cenários, o primeiro deles com as condições normais de uso e o segundo com problemas que o mesmo dispositivo já vem acarretando conforme sua vida útil, assim o software reconheceu os dois áudios gravados e foi gerado um gráfico sobre a intensidade sonora de ambos, conforme o decorrer das gravações. Por fim, gerou-se um código em Javascript e outro em p5.js para execução, no último em específico leva-se ao editor de código para onde é executado, sendo que é o padrão do site, além de um gráfico que mostra as ações e compara ambos os casos de teste.

Assim o software consegue fazer uma análise detalhada e dentro desta leitura é possível perceber os principais problemas de vibrações e suas causas: desbalanceamento, desalinhamento, defeitos em mananciais de rolamentos, defeitos em sistemas de

engrenagens, defeitos em motores elétricos e similares. Diante disso, traça-se um diagnóstico sobre estas situações em que o mesmo é denominado de registro das vibrações, para este caso, usa-se dois cenários distintos, um com o dispositivo que registra o som e o outro analisa o desempenho do motor, gerador ou equipamento. Assim estes dados são transferidos para especialistas de onde são traçados todos os detalhes de uma determinada análise, ou mais de um, dependendo do caso.

### 3. Desenvolvimento

Primeiramente foi realizada uma série de estudos, com diferentes cenários, simulando as ações cotidianas, envolvendo desde a abertura e fechamento de portas e janelas, diferentes modelos de interruptor, abertura e fechamento de torneira, de acordo com os propósitos citados anteriormente.

Além disso, incluiu-se o uso do Teachable Machine para usar a ferramenta online de forma correta e segura, seguindo todas as instruções de uso que oferecia, em especial para a gravação de ruídos, no qual o mesmo se enquadra neste artigo.

Para a construção do problema, foi utilizado um ventilador, em estado avançado de deterioração, causado por quebras na estrutura do produto e também pelo desgaste natural, ocasionado principalmente pelo tempo de vida útil.

A Figura 1 mostra como foi realizada a primeira parte do procedimento prático usando o Teachable Machine de uma forma generalizada.[6]

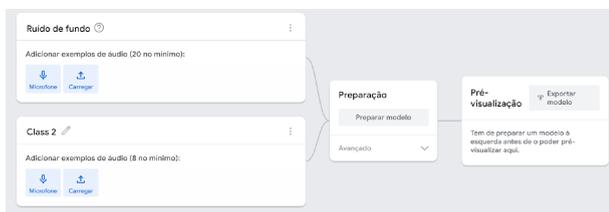


Figura 1 - Página do Teachable Machine com o uso voltado para a gravação de áudios.

Assim, os dois arquivos de áudio, um de cada cenário, inicialmente são gravados de forma separada, com uma maior organização possível e para evitar interferência externa, as audições ocorreram no período entre zero hora e seis da manhã, pois neste horário a incidência sonora é menor, tornando-se mais seguro realizar neste período pois barulhos cotidianos como sons emitidos por pássaros (que não ocorrem dentro de uma fábrica com máquinas, por exemplo) são menores neste horário, além de ser realizado em local totalmente isolado e afastado de áreas por onde a exposição sonora é muito maior, dentro e fora de casa, longe de animais, veículos, espaços de uso coletivo e equivalentes. No uso efetivo do sistema estas condições não são necessárias pois o modelo de machine learning não está sendo treinado. No período de treino, as condições especiais citadas acima são necessárias para que o modelo de machine learning consiga isolar e aprender apenas os

ruídos relacionados com as falhas em uma máquina. Porém, no uso efetivo do sistema tais condições não são mais necessárias, pois o modelo já treinado conseguirá identificar o barulho relacionado com a falha mesmo que outros sons estejam presentes no ambiente.

O procedimento ilustrado na Figura 2 consistiu em duas amostras de áudio: a primeira delas foi a gravação de um objeto em situação normal e a segunda consistiu em captar o som com falhas que já haviam sido agravadas ao longo do tempo, durante todo o tempo de uso até a realização deste experimento, reconhecendo as falhas [7] [8].

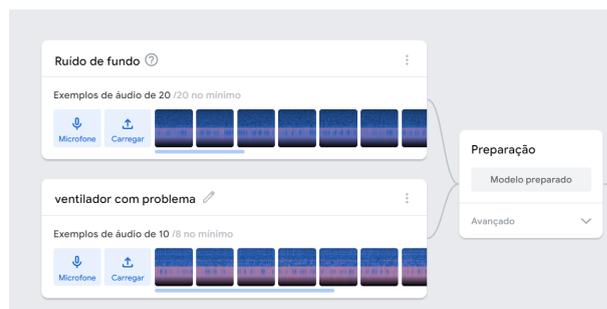


Figura 2 - Página do Teachable Machine com os sons de ambas as situações estipuladas já gravadas e preparadas para a próxima fase.

A Figura 3 mostra o treinamento do sistema de reconhecimento usando todos os sons captados neste experimento, com os áudios separados em fragmentos menores e dentro deles possui blocos com cores frias, representando o nível de intensidade sonora, do azul ao lilás, quanto mais próximo desta última cor citada maior será a intensidade de vibração do mesmo [9].

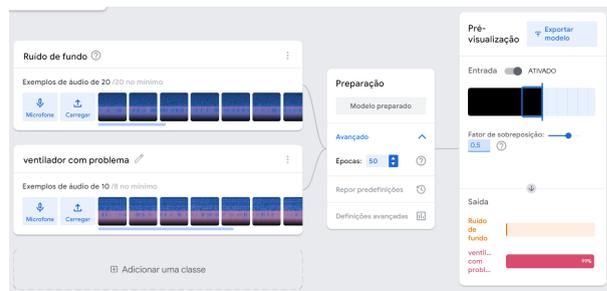


Figura 3 - Execução dos áudios gravados com gráficos comparando as audições entre si e a geração de uma trilha unindo-os.

Após esta fase, os áudios são comparados em dois gráficos de barras: o primeiro, em laranja, representa o som original e o segundo, em rosa, mostra os problemas obtidos por meio da leitura, ambos somados chegam a cem por cento, caso forem três ou mais elementos, apareceram mais cores correspondendo à quantidade proporcional de itens gravados seguindo o propósito estipulado anteriormente, podendo ir até N elementos utilizados neste experimento.

Com a conclusão e a execução dos arquivos de áudio, o mesmo gera dois códigos fontes em Javascript com a biblioteca Tensorflow.js, permitindo assim o

treinamento de redes neurais sem a necessidade de instalar software ou equivalente [10].

Na figura 4 são exibidas a precisão por época e a perda por época. O primeiro citado corresponde ao nível de acerto, numa escala de 0 a 100, isto é, se o modelo acertar por completo o resultado será igual a 1. Já a perda por época designa o nível de perfeição, diferente do item anterior, se o número for exatamente 0 será considerado perfeito, caso contrário, será superior a 0.

A Figura 4 apresenta os dois gráficos sobre precisão por época e a perda por época, respectivamente.

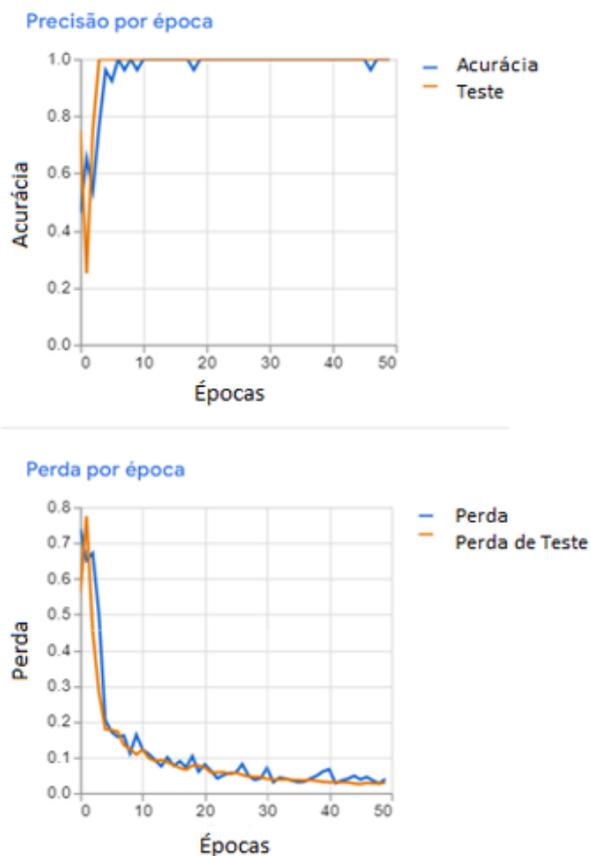


Figura 4 - Em destaque os gráficos referentes a precisão por época e a perda por época sobre os itens avançados do aplicativo

Em acurácia, os resultados comprovaram a objetividade, tendo uma regularidade a partir do décimo período em diante, com duas exceções durante a análise, até a décima época.

Diante destes argumentos, o sistema passa a operar de forma contínua e por mais tempo, dependendo da necessidade, para facilitar e aumentar a organização destes setores, ocasionados pelo desligamento de determinadas máquinas sem planejamento prévio, além de evitar acidentes de trabalho [11].

#### 4. Resultado e discussões

Os resultados na Figura 5 mostraram um cenário que poderá ser variado de acordo com o uso da plataforma. Na parte superior aparece a execução dos dois áudios e também o fator de sobreposição, isto é, o nível de

velocidade da reprodução em relação a trilha da junção de ambos os conteúdos, variados em uma escala de 0 a 0,75, com divisão de até duas casas decimais terminados entre zero e cinco. Quanto maior for o valor, maior também será a rapidez desta linha, caso contrário será mais lento, por exemplo, se o fator de sobreposição for de 0,25 indica que o mesmo será mais lento ao se comparar com o número padrão de 0,5. Se for 0,7 ele será mais rápido do que 0,5 mas não condiz em nada, para realizações de eventos reais deve-se utilizar o valor padrão de 0,5 durante a execução deste fator.

A saída é constituída por uma série de blocos com o percentual de vibrações de acordo com as ações obtidas durante a sessão, no total deve ser de 100%, composta pela soma de ambas as captações.

Outro ponto notado na resolução é a forma de como são gerados os códigos, pois podem ser compatíveis em diferentes projetos sejam websites ou aplicativos, visualizados dentro do Tensorflow, com os códigos em Javascript e em P5.js. Além da versão Tensorflow Lite, voltado para o segmento mobile, por onde poderá ser implementado através do aplicativo Android Studio para diversas finalidades.

Assim o modelo é exportado e transformado em um arquivo JSON com três itens: o metadata, o model e o weights.bin. O primeiro é usado para transcrever as bibliotecas usadas no projeto como também o uso de labels e de imagens utilizadas, o segundo envolve a topologia do modelo que foi utilizado no processo, e o último citado é um programa binário com os pesos do modelo em que terminou de ser realizado [12].

Com isso a aplicação poderá ser implementada na elaboração de futuros programas ou softwares para tratar a respeito de Machine Learning. As Figuras 5 e 6 trazem uma breve explicação da situação do problema estipulado e de seu desenvolvimento como um todo, apresentando os principais elementos do desenvolvimento da apresentação.



Figura 5 - Transformação dos áudios para chegar no resultado final, com a execução do ruído e as comparações entre os cenários mencionados na saída do programa.

Na Figura 6 são exibidos uma amostra dos resultados obtidos acima.

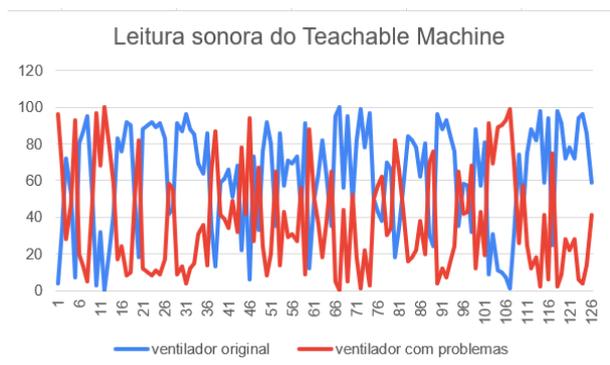


Figura 6 - Interpretação do percentual de saída através de uma planilha para a obtenção do gráfico.

A Machine Learning pode ser usada na indústria em outros casos também: uma fabricante de veículos automotores observou a possibilidade de aperfeiçoar a sua linha de produtos no segmento de caminhões e ônibus, mesmo com as imposições governamentais sobre a redução de emissões poluentes nestes veículos, adotando um sistema de freios inteligentes, por meio de câmeras e da inteligência artificial, evitando uma possível intervenção do condutor no ato da freada, prevenindo acidentes. Exemplo: o assistente de ponto cego, na prática são sensores que ficam no lado direito evitando a possibilidade de atropelamentos e outros eventos similares naquele lado, tornando-se mais vantajoso para os empresários e principalmente aos usuários e funcionários destes automotores [13].

Outro exemplo, semelhante ao descrito acima, também está relacionado ao setor de transportes: uma fabricante de trens em conjunto com empresas voltadas ao setor de tecnologia, criou o sistema de monitoramento de condições pantográficas, em inglês, a sigla é PCMS (Pantograph Condition Monitoring System), ao traduzir a abreviatura condiz em: Sistema de Monitoramento da Condição do Pantógrafo, este dispositivo ajuda a fazer uma radiografia mais detalhada da rede aérea, reduzindo gastos relacionado à troca de componentes além de torná-los mais seguros durante toda a extensão da linha férrea, reduzindo a ocorrência de falhas durante a realização das viagens, também combatendo fios defeituosos que podem acarretar a rede aérea, tornado-se mais seguro [14].

Em outros segmentos, além da mobilidade, a manutenção preditiva também é utilizada no tratamento de água e esgoto, visando a redução de custos com máquinas na filtragem e no tratamento de resíduos líquidos. Há também a integração com o IoT (Internet of Things) e o IIoT (Industrial Internet of Things), na tradução livre e correspondida de internet das coisas e internet industrial das coisas [15], na manutenção de usinas termelétricas [16], na área de tecnologia em soluções de problemas empresariais [17], além de outros projetos idênticos aos citados anteriormente, baseados neste mesmo princípio.

## 5. Conclusões

O artigo mostrou como realizar a manutenção preditiva utilizando Machine Learning. Estes resultados obtidos apresentaram um novo conceito durante a realização da manutenção preditiva, visando a agilidade no uso correto de peças para serem usadas, evitando problemas desnecessários após manutenção, que ocasiona em determinadas vezes a volta de um gerador, máquina ou motor a uma oficina de forma precoce, utilizando o processo de aprendizagem por máquina.

Outros resultados deste experimento também foram importantes, como a percepção dos problemas de acordo com a realidade, causados principalmente pela falta de manutenção ou a realização do serviço de má qualidade. A tecnologia vem mudando a realidade de todos os setores da sociedade e nestas áreas que são fundamentais, como a prestação de serviços, a indústria e os transportes, cada vez se vê soluções inteligentes capazes de ter maior percepção do que o próprio “olho humano”, mas se a metodologia tradicional ainda se mantivesse, teríamos sérios problemas relacionados a produtos de má qualidade entregues ao consumidor, obras da construção civil com instrumentos que podem acarretar a estrutura de edificações, ocasionado tragédias, bem como acidentes automobilísticos e diversos outros acontecimentos.

A tecnologia utilizada neste experimento foi importante para a resolução do problema de forma mais rápida, clara e objetiva, portanto os resultados satisfazem as expectativas criadas inicialmente.

Neste experimento não houve nenhum resultado negativo, por onde ocasionou alguma baixa durante a montagem e execução, visando em prejudicar o projeto como um todo.

Diante disso, este experimento provou que é possível usar um aplicativo de forma prática e segura podendo ser utilizado em qualquer segmento, desde um eletrodoméstico até um motor de alta precisão, tornando-se mais acessível e dinâmico a todos os envolvidos, reduzindo a interferência humana de possíveis falhas visando forçar o fim da vida útil antes do término do prazo estabelecido em garantia. Assim espera-se que a tecnologia passe a trabalhar junto com a mecânica, independentemente da situação em que as estiver, viabilizando melhorias.

## Agradecimentos

Agradeço ao Professor Me. Giuliano Araujo Bertoti pela colaboração e empenho durante a realização deste trabalho.

## Referências Bibliográficas

- [1] U.S DEPARTMENT OF ENERGY, **Operations & Maintenance Best Practices**, p. 52-53, Ago. 2010. Disponível em: <[Operations & Maintenance Best Practices Guide: Release 3.0 \(energy.gov\)](https://www.energy.gov/eere/operational-reliability/operations-maintenance-best-practices-guide-release-3.0)>. Acessado em: Mai. 2022.

- [2] J.R.Fernández, Y.T.Prasetyo, S.F.Persada e A.A.N.Perwira Redi, **Automation of Predictive Maintenance Using Internet of Things (IoT) Technology at University-Based O&M Project**, International Journal of Information and Education Technology, Vol 11, No. 7, July 2021.  
Disponível em: <[1531-AT024.pdf \(ijiet.org\)](#)>. Acessado em: Nov. 2022.
- [3] REVISTA MANUTENÇÃO, entenda como a inteligência artificial pode e deve ser aplicada na manutenção industrial.  
Disponível em: <[Entenda como a inteligência artificial pode e deve ser aplicada na manutenção industrial - Revista](#) [Manutenção \(revistamanutencao.com.br\)](#)>. Acessado em: Jun. 2022.
- [4] BOEING INSIGHT ACCELERATION, Empower predictive maintenance.  
Disponível em: <[Insight Accelerator | Predictive Maintenance | Boeing Services](#)>, Acessado em: Nov. 2022.
- [5] E.C.R.FOGAÇA, **Sistema de detecção de crianças em situação de perigo em piscinas usando deep learning e iot**, p 39, 2022.  
Disponível em: <[Sistema de detecção de crianças em situações de perigo em piscinas usando DEEP LEARNING e IOT.pdf \(uea.edu.br\)](#)>. Acessado em: Nov. 2022.
- [6] Teachhabe Machine  
Disponível em: <<https://teachablemachine.withgoogle.com>>. Acessado em: Nov.2022.
- [7] H.KACORRI, **Teachable Machines for accessibility**, p 11-12, Nov.2017.  
Disponível em: <[2017\\_sigaccess\\_kacorri.pdf](#)>. Acessado em: Nov. 2022.
- [8] J.R.A SOARES JUNIOR **PRÁXIS DOCENTE COM O TEMA GERADOR: Flora Amazônica**, p 55-62, 2021.  
Disponível em: <[https://tede.ufam.edu.br/bitstream/tede/8255/5/Disserta%c3%a7%c3%a3o\\_JoaoSoaresJR\\_PROFCIAMB.pdf](https://tede.ufam.edu.br/bitstream/tede/8255/5/Disserta%c3%a7%c3%a3o_JoaoSoaresJR_PROFCIAMB.pdf)>. Acessado em: Mar. 2023
- [9] J.R.A SOARES JUNIOR & K.V CAVALCANTI, **Tutorial desenvolvimento de aplicativos de apoio a práxis ambiental educativa mediante uso de tecnologias de inteligência artificial**, p. 43, 2021.  
Disponível em: <[Microsoft Word - PRODUTO EDUCACIONAL CORRECAO GRAMATICAL CORRIGIDO \(ufam.edu.br\)](#)>. Acessado em: Ago. 2022.
- [10] R.J.R.Torres, **Método de automatização do processo de redosagem de concreto em central dosadora**, p 26-27, 2021.  
Disponível em: <[Metodoautomatizacaoprocesso\\_Torres\\_2021.pdf \(ufrn.br\)](#)>. Acessado em: Nov. 2022.
- [11] N.A.R MACIEJEWSKI, **Detección e diagnóstico de defeitos no regime transitório de motores de indução baseado em sistemas inteligentes**, p 27, 2021.  
Disponível em: <[TeseMaciejewskiNarcoARavazzoliCorrig.pdf \(usp.br\)](#)>. Acessado em: Ago. 2022.
- [12] F.P. OLIVEIRA, **TMIC - Uma extensão do App Inventor para a Implementação de Modelos de ML voltados a Classificação de Imagens Treinados no Machine Learning**, p 27.  
Disponível em: <[TCC.pdf \(ufsc.br\)](#)>. Acessado em Nov. 2022.
- [13] DIÁRIO DO TRANSPORTE, **VÍDEO: Diário do Transporte acompanha o novo ônibus da Mercedes-Benz que freia sozinho, o detector de ponto cego e o farol alto inteligente**.  
Disponível em: <[VÍDEO: Diário do Transporte acompanha o novo ônibus da Mercedes-Benz que freia sozinho, o detector de ponto cego e o farol alto inteligente » Diário do Transporte \(diariodotransporte.com.br\)](#)>. Acessado em: Ago. 2022.
- [14] ART, Condition Monitoring Solutions, Increasing maintenance efficiency and improving life expectancy of vital assets.  
Disponível em: <[Condition Monitoring - Australian Rail Technology \(ar-tech.com.au\)](#)>. Acessado em: Ago. 2022.
- [15] M.A ESTEVES, N SAMPAIO, J.E DA SILVA & M.T.R RICCI, **Utilização de Machine Learning em uma Estação de Tratamento de Efluentes**, p 7, 2020.  
Disponível em: <<https://tratamentodeagua.com.br/wp-content/uploads/2020/09/26626327.pdf>>. Acessado em: Set.2022.
- [16] A.N.F.GAMA, **O uso de Machine Learning na implementação de manutenção preditiva em usinas termelétricas**. 2017.  
Disponível em: <[Responsabilidade Social \(ufjf.br\)](#)>. Acessado em: Nov. 2022.
- [17] IBM, What is predictive maintenance?  
Disponível em: <[Predictive maintenance | IBM](#)>, Acessado em: Nov. 2022.