

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO  
CURSO DE ESPECIALIZAÇÃO EM INDÚSTRIA 4.0**

**PEDRO HENRIQUE CANTELLI GONÇALVES**

**APLICAÇÃO DE FERRAMENTA DE MACHINE LEARNING PARA  
PREDIÇÃO DE FALHAS EM EQUIPAMENTOS EM INDUSTRIA DE  
PAPEL**

**TRABALHO DE CONCLUSÃO DE CURSO DE ESPECIALIZAÇÃO**

**PONTA GROSSA**

**2020**

**PEDRO HENRIQUE CANTELLI GONÇALVES**

**APLICAÇÃO DE FERRAMENTA DE MACHINE LEARNING PARA  
PREDIÇÃO DE FALHAS EM EQUIPAMENTOS EM INDÚSTRIA DE  
PAPEL**

Trabalho de Conclusão de Curso de Especialização apresentada como requisito parcial à obtenção do título de Especialista em Indústria 4.0, da Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa.

Orientador: Prof. Dr. Rui Tadashi Yoshino  
Coorientador: Prof. Dr. Marcelo Vasconcelos de Carvalho

**PONTA GROSSA**

**2020**



Ministério da Educação  
**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
**CÂMPUS PONTA GROSSA**  
Diretoria de Pesquisa e Pós-Graduação



## **TERMO DE APROVAÇÃO DE TCCE**

Aplicação de ferramenta de machine learning para predição de falhas em equipamentos em indústria de papel

*Pedro Henrique Cantelli Gonçalves*

Este Trabalho de Conclusão de Curso de Especialização (TCCE) foi apresentado em oito de fevereiro de 2020 como requisito parcial para a obtenção do título de Especialista em Indústria 4.0. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

---

**Prof. Dr. Rui Tadashi Yoshino**

Prof. Orientador

---

**Prof. Dr. Marcelo Vasconcelos de Carvalho**

Membro titular

---

**Prof. Max Mauro Dias Santos**

Membro titular

A FOLHA DE APROVAÇÃO ENCONTRA-SE ASSINADA NA SECRETARIA DO  
CURSO

## RESUMO

GONÇALVES, Pedro Henrique Cantelli. **APLICAÇÃO DE FERRAMENTA DE MACHINE LEARNING PARA PREDIÇÃO DE FALHAS EM EQUIPAMENTOS EM INDÚSTRIA DE PAPEL**. 2020. Monografia (Especialização em Engenharia de Indústria 4.0) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2020.

A evolução das tecnologias nos últimos anos tem sido cada vez mais rápida e, impulsionadas pela 4ª revolução industrial, as inovações tem se tornado também mais acessíveis e aplicáveis. Este trabalho vem de encontro a necessidade de busca de novas ferramentas para garantir e elevar a disponibilidade de equipamentos e máquinas em uma indústria do setor de papel e celulose. Tendo o objetivo de garantir a disponibilidade dos ativos é necessário conhecer o correto modo de operação dos equipamentos, seus modos de falha e variáveis vitais para acompanhamento, buscando assim prever quando os ativos têm os primeiros indicadores de defeito e evitar que cheguem a uma falha funcional (parada total). Em busca desta predição antecipada de falhas nos equipamentos, encontramos no aprendizado de máquina (Machine Learning) uma oportunidade de potencializar a análise e identificação de defeitos, correlacionando diversas variáveis vitais dos ativos simultaneamente (análise multi-variável) e repetidas vezes em curtos intervalos de tempo (a cada 5 min). Desenvolvemos então um projeto piloto para avaliar as ferramentas de machine learning existentes no mercado, abrangendo 10 grupos de ativos de uma indústria papeleira. Os ativos selecionados para o projeto piloto foram criteriosamente selecionados. O modelo de operação padrão é o resultado do treinamento da ferramenta de inteligência artificial, para que a máquina identifique os desvios mais sutis nas variáveis vitais dos ativos e sinalize com alertas antecipados de potenciais falhas. O projeto piloto foi implementado em 4 meses, com a participação do time de projetos de uma empresa de tecnologia digital juntamente com o time da engenharia de manutenção da indústria papeleira. Como resultado da aplicação da ferramenta de predição de falhas, foi possível identificar e tratar 2 potenciais de falha logo nos primeiros meses de uso. Esta previsibilidade permite que os times de manutenção de campo planejem com mais tempo a atividade de forma a maximizar a operação das máquinas, com segurança e produtividade garantida. Consideramos o projeto piloto extremamente bem-sucedido, pela facilidade de aplicação da ferramenta e também pelo acerto nas falhas previstas e antecipadas.

**Palavras-chave:** Predição de Falhas. Machine Learning. Ativos. Inteligência Artificial. Manutenção. Disponibilidade. Indústria Papel e Celulose.

## ABSTRACT

GONCALVES, Pedro Henrique Cantelli. **Application of a machine learning tool for failure prediction in paper industry of the working.** 2020. Monograph (Specialization in Industry 4.0) - Federal Technology University - Paraná. Ponta Grossa, 2020.

The evolution of technologies in recent years has been increasingly fast and, driven by the 4th industrial revolution, innovations have also become more accessible and applicable. This work meets the need to search for new tools to guarantee and increase the availability of equipment and machinery in a paper and pulp mill. In order to ensure the availability of assets, it is necessary to know the correct mode of operation of the equipment, its failure modes and vital variables for monitoring, thus seeking to predict when the assets have the first defect indicators and prevent them from reaching a functional failure (total stop). In search of this early prediction of equipment failures, we find in Machine Learning an opportunity to enhance the analysis and identification of defects, correlating several vital variables of the assets simultaneously (multi-variable analysis) and repeatedly in short intervals of time (every 5 min). Then we developed a pilot project to evaluate the machine learning tools on the market, covering 10 groups of assets in a paper industry. The assets selected for the pilot were carefully selected. The standard operational model is the result of training the artificial intelligence tool, so that the machine identifies the most subtle deviations in the vital variables of the assets and signals it with early warnings of potential failures. The pilot was implemented in 4 months, with the participation of the project team of a digital technology company together with the maintenance engineering team of the paper industry. As a result of the application of the failure prediction tool, it was possible to identify and treat 2 potentials of failure in the first months of use. This predictability allows the field maintenance teams to plan the activity with more time in order to maximize the operation of the machines, with safety and guaranteed productivity. We consider the pilot project extremely successful, due to the ease of application of the tool and also due to the accuracy of predicted and anticipated failures.

**Keywords:** Failure Prediction. Machine Learning. Assets. Artificial intelligence. Maintenance. Availability. Pulp and Paper Industry.

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>7</b>
<b>2 OBJETIVOS GERAIS.....</b>	<b>7</b>
<b>3 JUSTIFICATIVA.....</b>	<b>8</b>
<b>4 METODOLOGIA.....</b>	<b>8</b>
<b>5 RESULTADOS ESPERADOS.....</b>	<b>11</b>
<b>6 CONSIDERAÇÕES FINAIS .....</b>	<b>12</b>
<b>REFERÊNCIAS.....</b>	<b>13</b>

## 1 INTRODUÇÃO

A evolução das tecnologias nos últimos anos tem sido cada vez mais rápida e, impulsionadas pela 4ª revolução industrial, as inovações tem se tornado também mais acessíveis e aplicáveis. Neste processo de transformação digital das empresas, indústrias e modelos de negócio, a ciência de dados e utilização de big data combinada à técnicas de estatística, inteligência artificial e aprendizagem de máquina são alavancas fundamentais para os avanços em direção ao mundo digitalizado.

## 2 OBJETIVOS GERAIS

Este trabalho vem de encontro a necessidade de busca de novas ferramentas para garantir e elevar a disponibilidade de equipamentos e máquinas em uma indústria do setor de papel e celulose.

Tendo o objetivo de garantir a disponibilidade dos ativos é necessário conhecer o correto modo de operação dos equipamentos, seus modos de falha e variáveis vitais para acompanhamento (Ex.: temperatura, vibração, pressão e etc.), buscando assim prever quando os ativos têm os primeiros indicadores de defeito e evitar que cheguem a uma falha funcional (parada total).

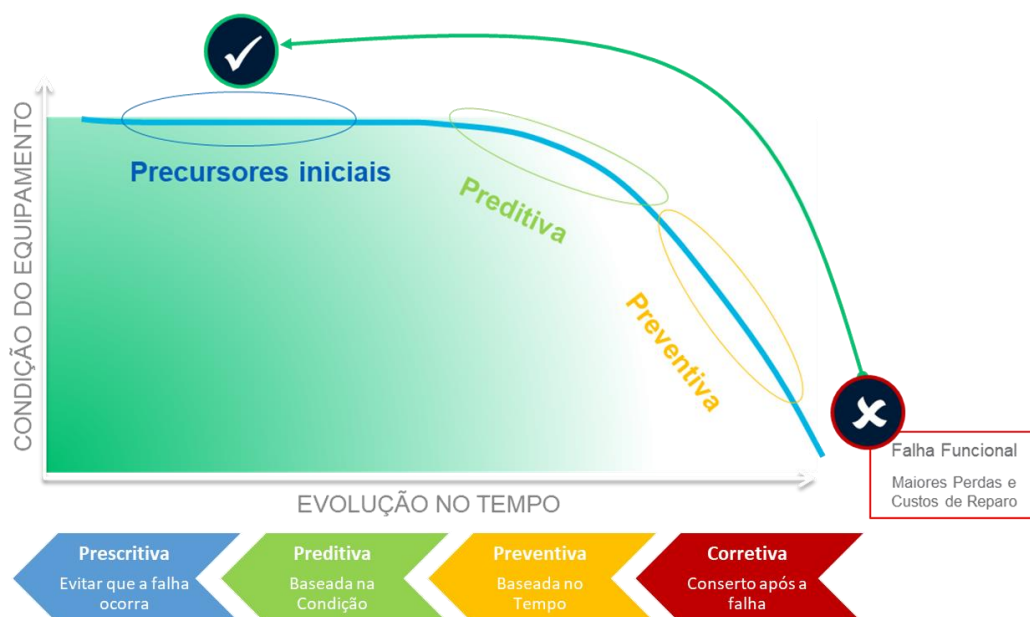


Figura 1 – Curva p-f e evolução da manutenção  
**Fonte:** Autor

Em busca desta predição antecipada de falhas nos equipamentos, encontramos no aprendizado de máquina (Machine Learning) uma oportunidade de potencializar a análise e identificação de defeitos, correlacionando diversas variáveis vitais dos ativos simultaneamente (análise multi-variável) e repetidas vezes em curtos intervalos de tempo.

### **3 JUSTIFICATIVA**

Implantar uma ferramenta de monitoramento de ativos, onde seja possível cruzar informações de variados bancos de dados correlacionando-as para, a partir destas informações, auxiliar na tomada de decisão e de ação, de forma a evitar paradas não programadas, reduzir custos de manutenção, reduzir perdas de produção, minimizar o risco de incidentes de SSO & Meio Ambiente e etc.

### **4 METODOLOGIA**

Desenvolveu-se então um projeto piloto para avaliar as ferramentas de machine learning existentes no mercado, abrangendo 10 grupos de ativos de uma indústria papeleira. Os ativos selecionados para o projeto piloto foram criteriosamente selecionados, pois os mesmos deveriam ser extremamente críticos para a planta (SSO; Produção; Qualidade do Produto), possuírem um bom nível de sensoriamento e histórico de dados suficiente para se criar um modelo de operação padrão.



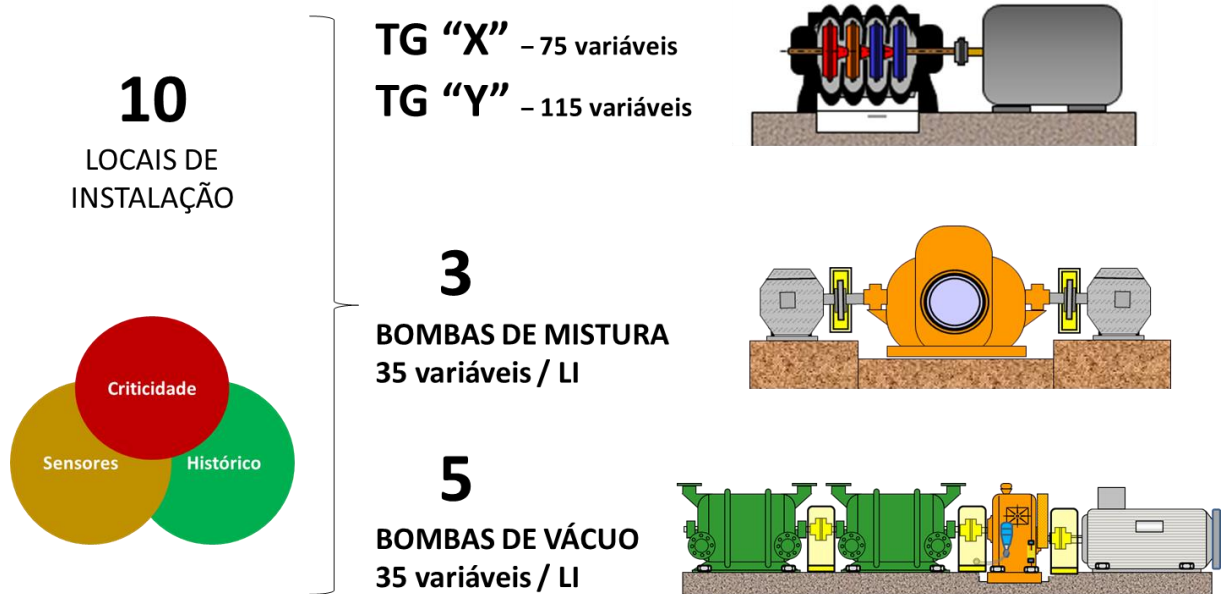


Figura 2 – Ativos selecionados para projeto piloto

Fonte: Autor

O modelo de operação padrão é o resultado do treinamento da ferramenta de inteligência artificial com base em todo o histórico dos sensores e variáveis disponíveis. Este treinamento é realizado já dentro da ferramenta selecionada, realizando uma pré-análise, filtragem, limpeza e ajuste dos dados obtidos. Nos bastidores da ferramenta de predição são criados diversos clusters de operação das variáveis, correlacionadas.

Podemos ver na figura 3 abaixo um exemplo gráfico da formação de clusters com base nos dados correlacionados. No exemplo da figura podemos ver que se a temperatura de um rolamento está em entre 139°F e 142°F (linha tracejada azul na figura 3) em um regime de operação normal, a temperatura do óleo no dreno deve estar entre 131°F e 145°F (linha tracejada verde na figura 3).

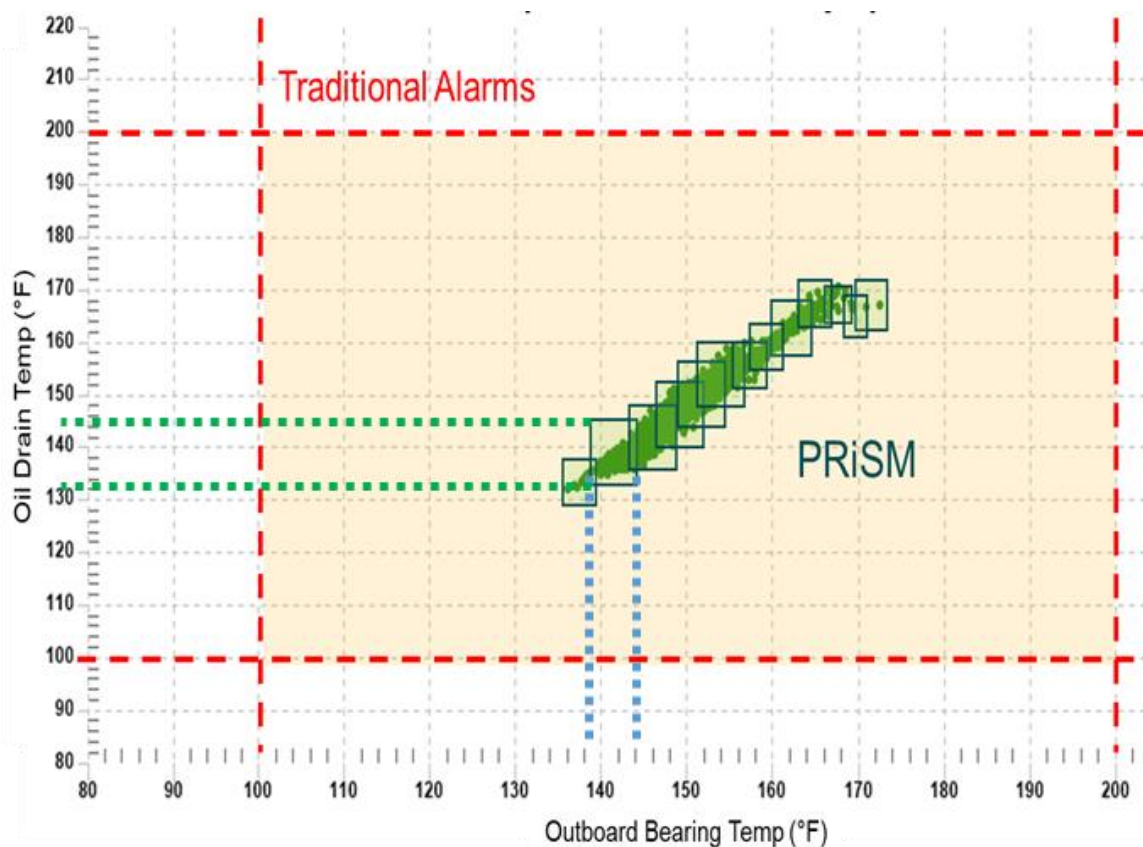


Figura 3 – exemplo da clusterização de valores entre variáveis  
**Fonte:** AVEVA PRISM PREDICTIVE ANALYTICS

Estas correlações são executadas pelos algoritmos presentes na ferramenta de machine learning para absolutamente todas as variáveis imputadas no modelo operacional padrão. Deste modo quando iniciado o monitoramento contínuo e multi-variável em tempo real, a ferramenta é capaz de identificar os desvios mais sutis nas variáveis vitais dos ativos.

Na figura 4 abaixo podemos visualizar a camada de acompanhamento do usuário, onde a linha azul indica o valor esperado para uma determinada variável com base nos clusters e valores atuais das demais variáveis modeladas. A linha vermelha indica o valor medido. Quando as duas linhas começam a se descolar, a ferramenta sinaliza com alertas antecipados de potenciais falhas.

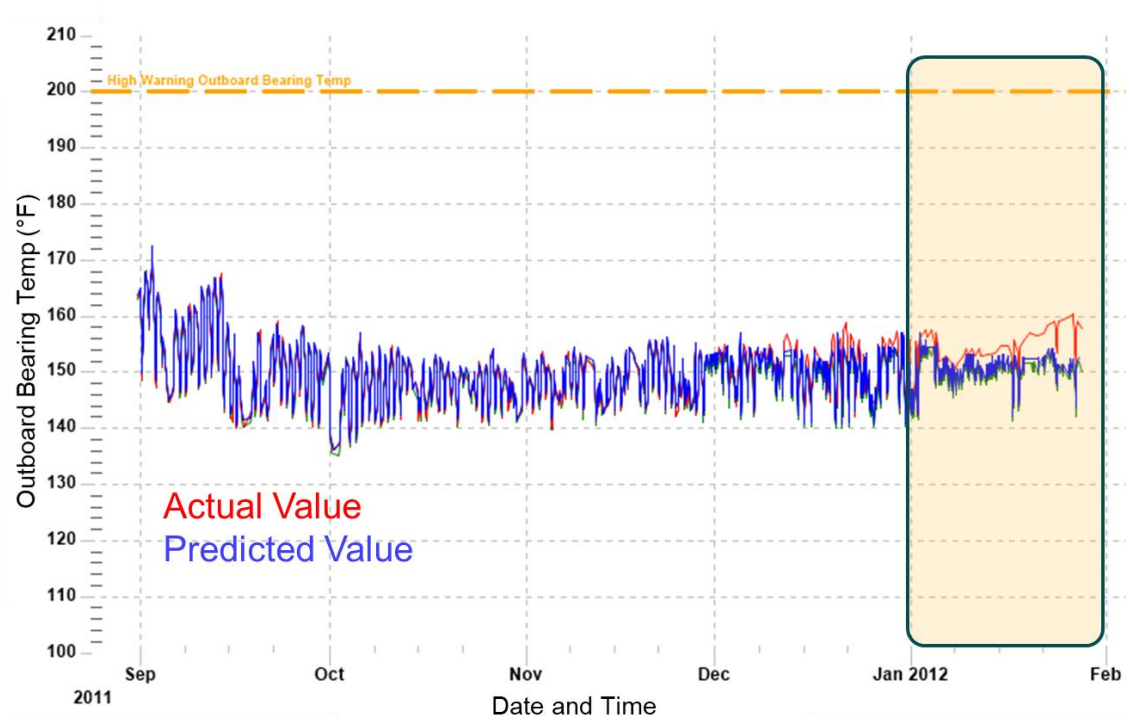


Figura 4 – Visualização do monitoramento contínuo com base no modelo operacional padrão na ferramenta

**Fonte:** AVEVA PRISM PREDICTIVE ANALYTICS

O projeto piloto foi implementado em 4 meses, com a participação do time de projetos da empresa de tecnologia digital detentora da ferramenta aplicada, juntamente com o time da engenharia de manutenção, tecnologia de informação, engenharia de processos e operação da indústria papelreira.

## 5 RESULTADOS ESPERADOS

Como resultado da aplicação da ferramenta de predição de falhas, foi possível identificar e tratar potenciais de falha logo nos primeiros meses de uso.

O caso evidenciado na figura 5, trata-se de um redutor onde foi observado o início de um desvio de comportamento quando relacionado aos modelos operacionais padrão pré-determinados.



Figura 5 – Exemplo de estudo de caso de quebra evitada com uso na ferramenta de predição

**Fonte: AVEVA PRISM PREDICTIVE ANALYTICS**

Este desvio gerou um alerta antecipado de falha e a partir de então iniciou-se uma investigação detalhada pelo time da engenharia de manutenção da indústria papelreira para confirmar se o alerta se tratava de uma anomalia ou defeito. A partir de análises com uso de outras ferramentas, tais como análise espectral de assinatura de vibração e análises de óleo, foi constatado que o desvio evidenciado pela ferramenta realmente tratava-se de um início de defeito no rolamento do eixo de entrada do redutor.

## 6 CONSIDERAÇÕES FINAIS

A previsibilidade com alto nível de precisão proporcionada por este tipo de ferramenta, permite que os times de manutenção de campo planejem com mais tempo a atividade de reparo e/ou substituição.

Também é possível observar que, em um futuro próximo, as análises demandadas pelos alertas antecipados de falha não sejam mais apenas com o foco de identificar antecipadamente um defeito e repará-lo, mas entender profundamente sobre a operação e uso dos equipamentos e máquinas, sinalizando formas mais eficientes de extrair o máximo rendimento e vida útil dos ativos, com segurança e produtividade garantida.

O projeto piloto foi considerado extremamente bem-sucedido, pela facilidade de aplicação da ferramenta e também pelo acerto nas falhas previstas e antecipadas, tanto que já foi iniciada a expansão do uso da ferramenta para demais ativos críticos da fábrica.

## REFERÊNCIAS

AMARAL, Fernando. **Introdução à ciência de dados: mineração de dados e big data**. Rio de Janeiro: Alta books, 2016.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462: Confiabilidade e manutenibilidade**. Rio de Janeiro: Abnt, 1994.

AVEVA PRISM PREDICTIVE ANALYTICS<sup>©</sup>

CARAZAS, F. J. **Decisões baseadas em risco** – método aplicado na indústria de geração de energia elétrica para a seleção de equipamentos críticos e políticas de manutenção. 2011. 218p. Tese (Doutorado), Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

GRILLETTI, LAÍS. Indústria 4.0: as oportunidades de negócio de uma revolução que está em curso. **Endeavor Brasil, 2017** - Disponível em: <https://endeavor.org.br/tecnologia/industria-4-0-oportunidades-de-negocio-de-uma-revolucao-que-esta-em-curso/>. Acesso em 10 jan. 2020.

JUNQUEIRA, FERNANDO CARLOS. **O impacto da Indústria 4.0 no emprego, nas empresas e na vida!** Rio de Janeiro: Instituto 4.0, 2018.

LAFRAIA, J. R. **Manual de Confiabilidade, Manutenibilidade e Disponibilidade**. Rio de Janeiro: Qualitymark. 2001.

MOUBRAY, John; 1997. **RCMII: Reliability-Centered Maintenance**. 2nd ed. New York: Industrial Press.

SHI, Zhongzhi., **Principles of Machine Learning**. International Academic Publishers, 1992.

SIMON, H. Simon, **“Why should machines learn?”**. Morgan Kaufmann, 1983.