



Simulação e Previsões nas Tomadas de Decisões da Manutenção Condicional em Equipamentos da Indústria de Mineração

Jadson da Cruz Passos
Jefferson Felipe Azevedo de Amorim
Franco Jefferds dos Santos Silva

Agência financiadora: FAPESPA

Resumo: O presente projeto de pesquisa abordou a previsão de disponibilidade física através de métodos de análises de manutenção aplicados a simulação, previsão e otimização, utilizando técnicas computacionais modernas de inteligência artificial. Foi utilizado como fonte de dados o histórico da rotina de manutenções corretivas e não-corretivas de mais de 90 caminhões fora de estrada e seus respectivos horímetros. O projeto expôs uma análise auxiliar para manutenções preditivas que toma como base o comportamento das máquinas, em cada fase da sua vida útil, através da detecção de diferentes padrões nas ocorrências de manutenção em cada uma dessas fases. Como resultado da pesquisa, a inteligência artificial é exposta como uma excelente ferramenta analítica para realizar cálculos massivos e de altíssima precisão, e a manutenção condicional é nitidamente fundamental para o auxílio na implementação de políticas de manutenção, a fim de reduzir custos.

Palavras chave: Manutenção Condicional, Inteligência Artificial, Previsão.

1. INTRODUÇÃO

A indústria de mineração emprega uma grande quantidade de equipamentos de grande porte, como a mina de Carajás, que, segundo dados de 2015, possui uma frota com cerca de 140 caminhões fora de estrada com capacidades de 240 a 400 toneladas (Silva *et al.*, 2016). E para manter esses caminhões em funcionamento são necessários programas de manutenção. A NBR-5462 (ABNT, 1994) define manutenção como a combinação de todas as ações técnicas e administrativas, incluindo as de supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida.

Os intervalos de manutenção podem ser definidos em termos de horas decorridas (dias, meses ou anos) ou operação (horímetro), e KPI's (Key Performance Indicators) de manutenção tais como DF (disponibilidade física), MTBF (Mean Time Between Failures) e MTTR (Mean Time To Recovery) serão fortemente influenciados pelos intervalos determinados.

Uma gama de dados pode ser obtida dos caminhões para uma análise estatística. Segundo Montgomery *et al.* (2000) o campo da estatística lida com a coleta, apresentação, análise e uso dos dados para tomar decisões, resolver problemas e planejar produtos e processos.

Silveira (2015) define disponibilidade física (DF) como a capacidade de um item estar em condições de executar uma certa função em um dado instante ou durante um intervalo de tempo determinado.

Devido a quantidade de dados para análise, entende-se como mais eficiente utilizar métodos computacionais para a realização das análises. Dessa forma, torna-se necessária a aplicação de aprendizado de máquina, que segundo Monard & Baranauskas (2003) tem como objetivo construir sistemas capazes de adquirir conhecimento de forma automática. Lee (2000) cita que o objetivo fundamental de um Sistema de Aprendizado de Máquina está na extração de

conhecimento na forma de regras de decisão a partir de um conjunto de dados, sendo que essas regras possam ser aplicadas a novos dados.

A previsão é uma tarefa comum de ciências de dados que ajuda as organizações com capacidade de planejamento, definição de metas e detecção de anomalias (TAYLOR & LETHAM, 2017). Dentre modelos computacionais que fazem previsões de séries temporais, há um que foi lançado pela equipe do Facebook Core Data Science, denominado Prophet, que possui parâmetros facilmente interpretáveis.

O projeto de pesquisa teve como objetivo principal propor procedimentos de utilização de técnicas de inteligência artificial implementadas em ferramenta computacional para simulação, análise, previsão e tomadas de decisão na gestão de manutenção baseada em condição de equipamentos da indústria de mineração.

Além desse, pode-se citar os seguintes objetivos específicos: caracterizar manutenção condicional aplicada a equipamentos de mineração; identificar e implementar computacionalmente técnica de tratamento de dados para aplicação em modelos de simulação e previsão de falhas em grupos de equipamentos; propor e implementar caso de aplicação da manutenção condicional a frota de ativos de mineração auxiliada por programa de computador utilizando técnicas inovadoras de inteligência artificial.

2. MATERIAL E MÉTODOS

Fora utilizada a linguagem de programação *Python 3.6*, a qual Borges (2014) definiu como uma linguagem de altíssimo nível orientada a objeto, de tipagem dinâmica e forte, interpretada e interativa. Para o tratamento dos dados, foram utilizadas as bibliotecas *Pandas* e *Matplotlib.pylab*, sendo possível analisar e visualizar graficamente os dados, de modo a eliminar possíveis erros de armazenamento de dados.

Já na parte mais avançada do projeto, diante dos dados anteriormente tratados, foram implementados cálculos e previsões utilizando métodos de aprendizado de máquina presentes na biblioteca *Prophet*, que foi divulgada por Taylor e Letham no ano de 2017, com o intuito de facilitar a tarefa de previsão de dados.

3. RESULTADOS E DISCUSSÃO

A fig. (1) mostra a série temporal de um dos ativos após o tratamento dos dados, a imagem foi plotada através da biblioteca *Matplotlib.pylab*:

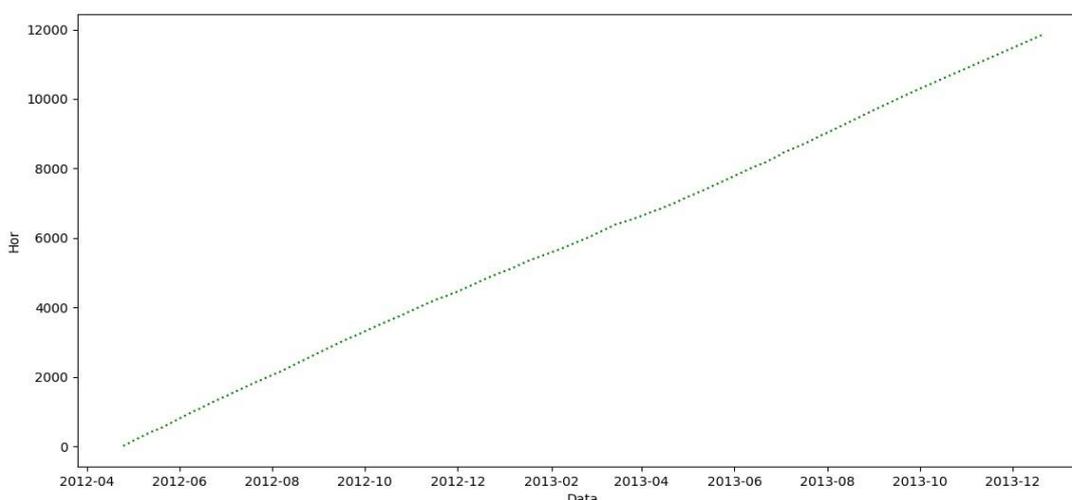


Figura 1: Horímetro do ativo CM4097

A fig. (2) mostra o histórico de manutenções corretivas no mesmo ativo:

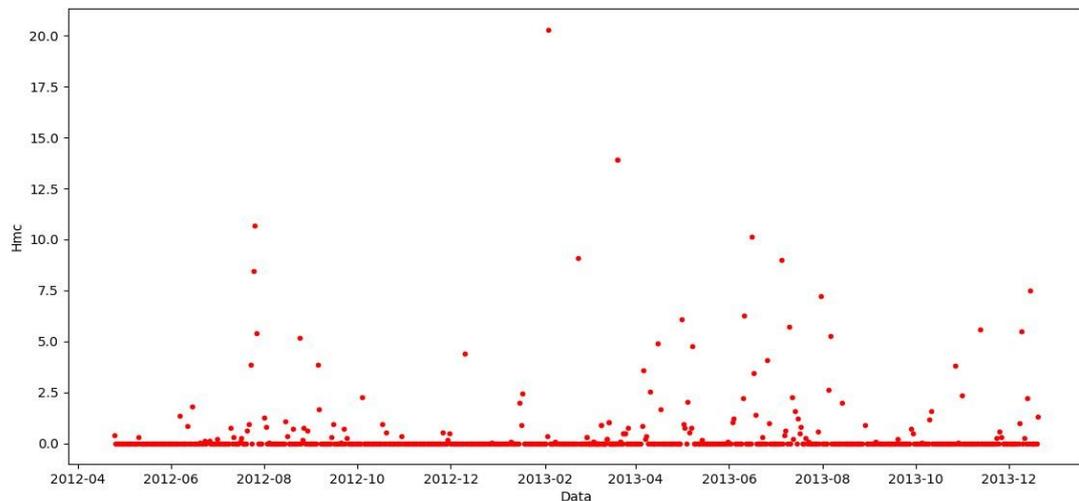


Figura 2: Histórico de manutenções corretivas no ativo CM4097

A fig. (3) foi obtida através da biblioteca *Prophet*, e mostra a disponibilidade física operacional tanto do período histórico, 2010 a 2014, quanto a previsão da disponibilidade segundo a tendência observada nos anos anteriores. Além disso, o intervalo de incerteza é plotado.

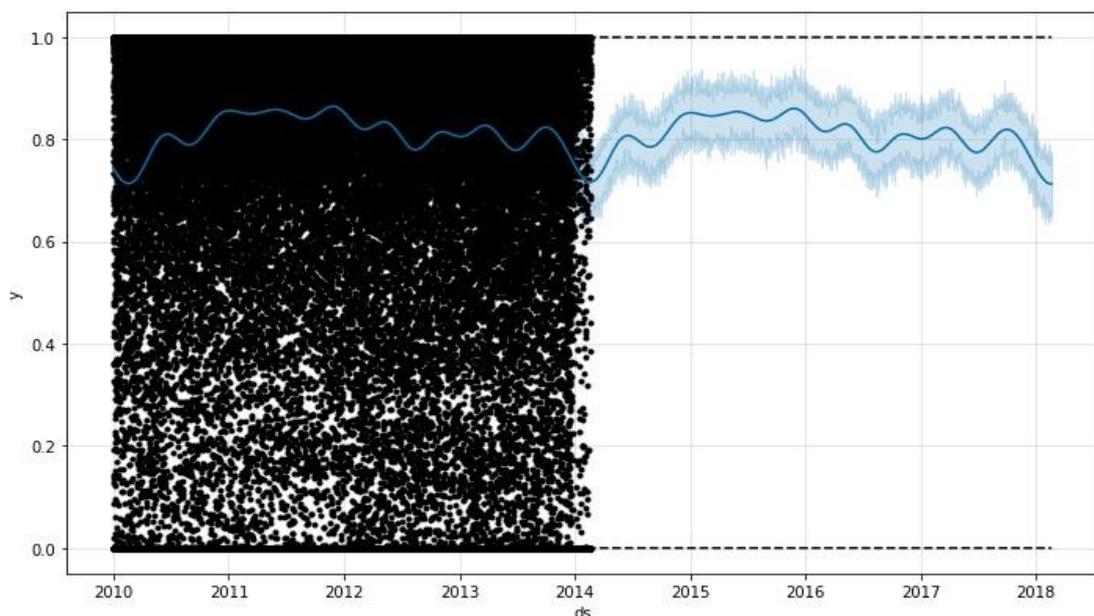


Figura 3: Previsão de disponibilidade física através da leitura de dados históricos

Através do gráfico fica notável uma queda brusca na disponibilidade a cada 4 (quatro) anos, culminando nos pontos mínimos no mês de fevereiro dos anos de 2010 e de 2014, assim como, segundo a previsão, outra crise ocorreria no mesmo mês de 2018. Numericamente, os picos superior e inferior foram de 86,5% e 71,4%. Alguns fatores influenciam os resultados observados, dentre eles pode-se citar: substituição de ativos com horímetro avançado, realização de muitas manutenções corretivas, planejamento de manutenções não-corretivas sem uso de método computacional, entre outros.

Uma forma de se evitar o declínio observado seria um melhor planejamento das manutenções não-corretivas, planejamento este que pode ser feito utilizando, também, aprendizado de máquina, visto que há um banco de dados com datas de realização de manutenções e duração desses eventos de acordo com o horímetro do ativo em questão.

4. CONCLUSÃO

A previsão da disponibilidade física deve, obrigatoriamente, ser feita de forma criteriosa e veementemente ligada aos parâmetros que podem ser utilizados para a sua determinação. É uma atividade bastante complexa realizar previsões quando há uma variabilidade histórica de dados bastante elevada. Sendo assim, uma alternativa é considerar a variabilidade como um fator de grande importância no momento de análise da previsão, visto que o seu principal objetivo é utilizá-la para tomar decisões, como troca de equipamentos, mais precisas.

A análise baseada no aprendizado de máquina permite englobar todas as fases da vida útil de um equipamento e incorporá-las a um modelo capaz de identificar as características de cada uma dessas fases. Sobretudo, a aplicação de cálculos personalizáveis torna a previsão mais útil. Dessa forma, o atual projeto é de grande relevância, pois permite uma análise rica e coerente no campo de manutenções condicionais, indicando vantagens financeiras para a empresa e um conhecimento enriquecedor para quem o aplica.

5. REFERÊNCIAS E CITAÇÕES

BORGES, L. E. *Python para Desenvolvedores: Aborda Python 3.3*. [S.I]: Novatec Editora, 2. ed, 2014.

LEE, Hwei Diana. *Seleção e construção de features relevantes para o aprendizado de máquina*. 2000. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) – Instituto de Ciências e de Computação Universidade de São Paulo, São Carlos, 2000.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. *Sistemas Inteligentes-Fundamentos e Aplicações*, v. 1, n. 1, p. 32, 2003.

MONTGOMERY, Douglas C.; RUNGER, George C.; CALADO, Verônica. *Estatística Aplicada E Probabilidade Para Engenheiros*. Grupo Gen-LTC, 2000.

SILVA, Franco Jefferds dos Santos; VIANA, Herbert Ricardo Garcia; QUEIROZ, André Nasser Aquino. Availability forecast of mining equipment. *Journal of Quality in Maintenance Engineering*, v. 22, n. 4, p. 418432, 2016.

SILVEIRA, C. B., 2015, *Indicadores de Performance da Manutenção Industrial*. [S.I.]: Cistisystems, 2015.

TAYLOR, S. J., LETHAM, B., 2017, *Forecasting at Scale*. PeerJ Preprints, 2017.