

NOVAS TECNOLOGIAS DE MANUTENÇÃO PREDITIVA UTILIZANDO CIÊNCIA DE DADOS

*Marcelo Koiti Fugihara*¹

*Fábio Heiji Yamada*²

*Jéssica Moura Alves*³

Resumo

Desde o surgimento da revolução industrial, a engenharia de manutenção tem como objetivo reduzir o tempo de inatividade e maximizar a eficiência de equipamentos. A ciência de dados está preparada para desempenhar um papel importante na evolução da manutenção na era da Indústria 4.0 e IoT. As primeiras empresas a descobrir como converter automaticamente seus vastos dados em insights acionáveis ganharam uma enorme vantagem competitiva. Discute-se neste trabalho como gerir dados operacionais ou de fabricação para maximizar a produtividade operacional, criar serviços de manutenção altamente eficientes e reduzir os custos de paralisações e reparos através do aprendizado de máquina e de ciência de dados.

Palavras-chave: Ciência de dados; Manutenção preditiva e Aprendizado de máquina

NEW PREDICTIVE MAINTENANCE TECHNOLOGIES USING DATA SCIENCE

Abstract

Since the dawn of the industrial revolution, maintenance engineering has aimed to reduce downtime and maximize efficiency. Data science is poised to play a major role in the evolution of maintenance as we enter the age of Industry 4.0 and IoT. The first companies to figure out how to automatically convert their vast data into actionable insights will gain a huge competitive advantage. This paper discusses how to manage operational or manufacturing data to maximize operational productivity, build highly efficient maintenance services, and reduce the costs of downtime & repairs through machine learning and data science.

Keywords: Data science; Predictive maintenance and Machine learning

¹ *Sócio Diretor da Belge Engenharia, São Paulo - SP.*

² *Gerente de Projetos da Belge Engenharia, São Paulo - SP.*

³ *Consultor da Belge Engenharia, São Paulo - SP.*

1. INTRODUÇÃO

Os engenheiros costumavam se concentrar na **manutenção corretiva**: conserto dos equipamentos quando eles apresentavam falhas. Essa abordagem leva a tempos de inatividade inesperados - um problema real para equipamentos altamente críticos. Uma alternativa utilizada pelas equipes de reparos é a **manutenção preventiva** ou **programada**, que aplica reformas preventivas com base em uma data de calendário fixa, independentemente da condição do equipamento no momento. Enquanto isso minimiza o tempo de inatividade do equipamento, também pode levar a custos desnecessários e tempo de engenharia.

Avançando para os dias de hoje, muitos analistas estão começando a adotar a **manutenção preditiva** - uma forma de manutenção que utiliza a ciência de dados para prever o tempo ideal para realizar reparos e substituições, equilibrando a necessidade de reparos com a minimização de custos.

Um comparativo dos custos para cada tipo de manutenção está ilustrado no gráfico da Figura 1a.




Figura 1a: Comparação abordando os custos de manutenção (Fonte: SSpredictiva, 2019)

Máquinas e equipamentos estão cada vez mais conectados com métodos cada vez mais sofisticados de coleta de dados, gerando bilhões de pontos de dados a cada ano. Alguns exemplos são: tomografia infravermelha, sonora e ultrassônica, análise de corrente de motor, análise de vibração, óleo, etc.

No entanto, apesar de todos esses argumentos, de acordo com a Gartner, 72% dos dados da indústria de manufatura não são utilizados devido às complexidades envolvidas nos sistemas e processos atuais. Como a quantidade de dados coletados hoje continua a crescer, torna-se cada vez mais difícil extrair percepções significativas com as ferramentas usuais. A saída é a utilização de ciência de dados.

A ciência de dados usa algoritmos de aprendizado de máquina para vasculhar automaticamente grandes quantidades de dados e apontar o que é relevante, o que é interessante e o que é valioso. Prever quando os reparos serão necessários gera eficiência em seu processo de manutenção e abre novas possibilidades para sua empresa.

2. METODOLOGIA

Para processar essa grande quantidade de informações, a companhia adquiriu uma plataforma de processamento de big data com extensão para análise preditiva, o RapidMiner. As etapas implementadas para alcançar o modelo de previsão de reparos segue o caminho da Figura 2a. Isto é, a primeira fase consiste no **tratamento dos dados**, em que se faz a limpeza e a concatenação das diversas fontes de informação chegando numa base confiável e consistente. A partir desta base, utiliza-se grupos de operadores estatísticos a fim de estudar o comportamento da série temporal e definir um modelo que preveja seu desenvolvimento no futuro. Esta etapa é conhecida como **modelagem e validação**. Ao finalizar e validar o protótipo, segue-se para etapa de **operacionalização**, em que o modelo é processado e fornece os resultados analíticos para sua implementação. Além disso, por meio da aplicação das técnicas de machine learning, a cada replicação aprimora-se os resultados ofertados e aumenta-se a assertividade.



Figura 2a: Etapas para análise de dados

2.1. MANUTENÇÃO PREDITIVA E SEU NEGÓCIO

Na economia global, mesmo pequenas diferenças de eficiência e produtividade podem determinar quais empresas prosperam e quais fracassam. A engenharia de manutenção é uma área que pode fazer uma enorme diferença tanto na produtividade da linha superior quanto na eficiência final.

A ciência de dados pode encontrar os sinais críticos escondidos no "ruído" dos dados operacionais de manutenção e inspeção. Ela pode identificar automaticamente os desvios que identificam a probabilidade de danos ou desgaste que levarão à falha parcial ou total da máquina. É possível prever quando, onde e por que as falhas provavelmente ocorrerão. Isso significa minimizar a adivinhação na engenharia.

2.1.1. ESTUDO DE CASO

A manutenção preditiva é essencial para diversos setores do mercado em que a qualidade da vida útil dos equipamentos é imprescindível para o sucesso da empresa. Neste ramo, destaca-se o setor de aeronaves, em que prever falhas de componentes ou equipamentos reduz o tempo de inatividade dispendioso, evita tempos de parada não planejados e otimiza os cronogramas da equipe de manutenção.

Este estudo de caso descreve a metodologia utilizada por uma das maiores prestadora de serviços de aviação, logística e transporte da Alemanha, focada na manutenção e reparos de aviões. Com mais de mil aviões a serem mantidos, a empresa alemã tinha centenas de milhares de registros, dados de sensores, mensagens de erro e relatórios de manutenção que precisavam ser avaliados para prever com precisão e evitar falhas.

2.1.2. SOLUÇÃO

A análise de uma grande quantidade de dados, coletados de uma rede de sensores conectados instalados em estabelecimentos de produção ou operação de equipamentos, permite que as empresas façam previsões confiáveis sobre em que condições uma máquina ou um estabelecimento se desenvolverão ao longo do tempo e quando a manutenção preditiva será necessária. Para o estudo de caso apresentado no presente artigo será utilizado a plataforma de ciência de dados RapidMiner, ferramenta líder em 2019 no Quadrante Mágico de Gartner por Ciência de Dados e Plataformas de Machine Learning pelos últimos seis anos consecutivos.

Os dados coletados para importação na ferramenta podem ser gerados de diversas formas como do controle de qualidade pós-produção, diretamente de sensores nas máquinas ou de informações do uso e condições das máquinas. Além disso, junto dos dados deve haver informações sobre a necessidade ou não de manutenção pouco tempo após a coleta dos dados.

Row No.	Machine_ID	Failure	Sensor_1	Sensor_2	Sensor_3	Sensor_4	Sensor_5	Sensor_6
1	M_0001	no	2.633	0.918	4.229	13.792	23.403	13.764
2	M_0002	yes	9.244	22.732	15.307	8.553	5.707	2.999
3	M_0003	no	3.183	28.526	8.735	4.898	3.685	2.960
4	M_0004	yes	2.785	2.642	5.857	7.417	24.343	16.183
5	M_0005	yes	4.889	14.415	23.903	12.985	5.865	3.780
6	M_0006	no	0.784	5.498	15.232	23.477	12.107	4.825
7	M_0007	no	6.214	26.377	13.063	6.312	4.130	2.937
8	M_0008	yes	2.590	16.258	18.281	3.524	7.293	9.881
9	M_0009	no	10.395	24.494	15.682	3.451	3.702	2.387
10	M_0010	yes	0.348	1.800	6.922	30.658	6.965	2.001
11	M_0011	yes	1.105	1.283	3.774	7.045	29.733	6.332
12	M_0012	yes	1.541	3.556	15.497	18.723	7.875	10.489
13	M_0013	no	1.043	1.607	0.497	32.322	0.600	1.201
14	M_0014	yes	3.204	3.925	4.659	7.155	27.698	11.166
15	M_0015	no	1.266	0.916	0.815	2.032	7.928	19.691

Figura 2b: Dados obtidos da plataforma RapidMiner.

Técnicas de análise preditiva treinam modelos que encontram a dependência entre os estados dos equipamentos e as necessidades de manutenções. Após serem treinados, esses modelos conseguem prever com grande precisão se uma máquina apresentará falhas em um futuro próximo.

Assim, com influência nos dados coletados é calculado o peso de cada fator utilizando diferentes métodos como a correlação, Gini (variação interna de um atributo), ganho de informação e proporção de ganho de informação (inserção e exclusão de atributos).

A Figura 2c ilustra o framework da preparação dos dados na ferramenta RapidMiner, calculando-se o peso de cada atributo por diferentes métodos, transformando-os em colunas e somando os pesos dos diferentes métodos para cada atributo e normalizando os valores, para gerar a tabela da Figura 2d com os dados organizados pelo grau de importância para cada sensor.

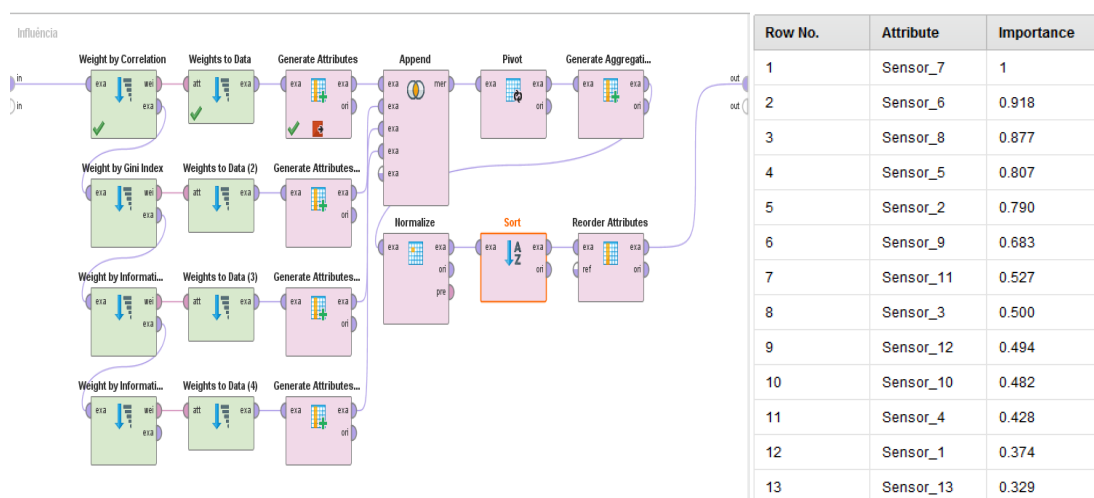


Figura 2c (esquerda) e 2d (direita): Preparação de dados obtidos da plataforma RapidMiner.

O modelo para manutenção preditiva pode envolver a escolha de um método, sua validação e otimização e a aplicação em novos dados. Pode-se utilizar diversos métodos de modelo, um deles é o método kNN, que determina o rótulo de classificação de uma amostra baseado nas amostras vizinhas advindas de um conjunto de treinamento. A variável k representa a quantidade de vizinhos mais próximos que serão utilizados para averiguar de qual classe a nova amostra pertence.

Para validar um modelo, um dos métodos mais utilizados é o Cross-Validation, que resumidamente, avalia a aderência de um modelo, a partir da iteração de subconjuntos da mesma base de dados. O procedimento ocorre da seguinte maneira: uma amostra é dividida em n partes, sendo que uma das partes será o conjunto de teste e as demais são chamadas de conjuntos de treinamentos (vide Figura 2e). Cada iteração se baseia na comparação do conjunto de teste com o conjunto de treinamento (formado pelas n-1 partes restantes), alternando o grupo a ser testado a cada iteração. Ao final das n testes, calcula-se o erro individual de aderência do modelo por iteração e sua média o erro estimado do modelo de predição. A Figura 2f mostra a tabela de performance do modelo, cuja a precisão é estimada por meio da porcentagem de acertos dentro da amostra.



Figura 2e: Esquema de iterações do Cross-Validation

accuracy: 70.71% +/- 8.77% (mikro: 70.59%)

	true no	true yes	class precision
pred. no	34	14	70.83%
pred. yes	26	62	70.45%
class recall	56.67%	81.58%	

Figura 2f: Tabela de acuracidade do modelo

Um método para melhorar a assertividade do modelo é otimizar os parâmetros envolvidos na predição. Para o método apresentado, o ideal é otimizar o parâmetro k (número de vizinhos a serem considerados no estudo) e/ou número de divisões da amostra no cross-validation.

Definido o modelo de predição, basta aplicá-lo a uma nova base de dados, como ilustrado nas imagens da Figura 2g.

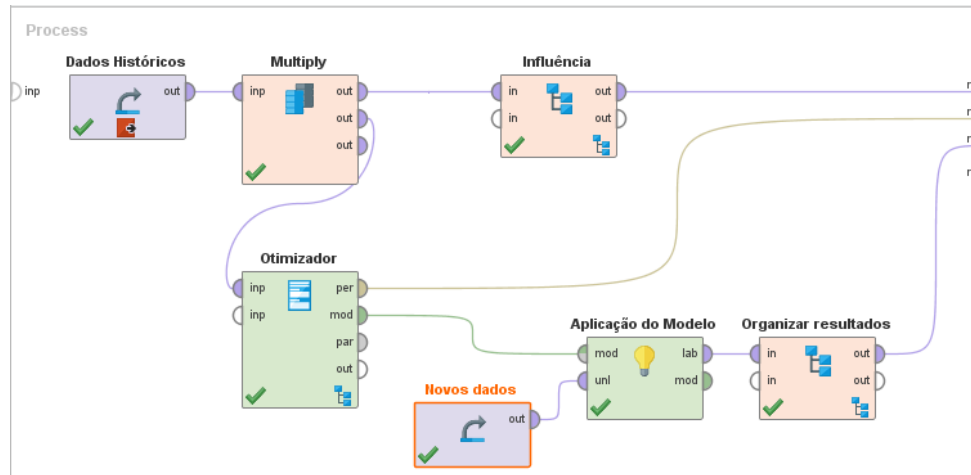


Figura 2g: Modelo exemplo obtido da plataforma RapidMiner.

Nos resultados obtidos, Figura 2h, o analista de dados pode visualizar a classe da máquina (yes: manutenção necessária; no: manutenção dispensável) e o grau de confiabilidade das estimativas realizadas pelo modelo.

Machine... ↑	prediction(F...	confidence[...	confidence[...
M_0137	yes	0.205	0.795
M_0138	no	0.667	0.333
M_0139	no	0.667	0.333
M_0140	yes	0.205	0.795
M_0141	no	0.641	0.359
M_0142	yes	0.333	0.667
M_0143	no	0.641	0.359
M_0144	no	0.667	0.333
M_0145	no	0.692	0.308
M_0146	yes	0.359	0.641
M_0147	yes	0.231	0.769
M_0148	yes	0.282	0.718
M_0149	yes	0.359	0.641
M_0150	yes	0.231	0.769
M_0151	yes	0.179	0.821
M_0152	yes	0.359	0.641

Figura 2h: Resultados obtidos da plataforma RapidMiner

2.1.3. O RESULTADO

Usando a análise em tempo real de dados de séries temporais, extração de recursos, aprendizado de máquina, classificação e mineração de dados, a empresa conseguiu desenvolver modelos precisos para prever quando um componente ou dispositivo falharia. Desta forma, a companhia conseguiu as informações necessárias para realizar uma manutenção mais precisa e eficiente, além de melhor aproveitar o serviço das equipes de manutenção.

Os modelos preditivos criados não apenas revelaram onde os problemas eram prováveis de ocorrer, mas também identificaram a causa raiz. Como resultado, nos primeiros dois meses de testes, o tempo total de inatividade foi reduzido em mais de 20% e as falhas de dispositivos e seus custos subsequentes também foram reduzidos.

3. CONCLUSÃO

A metodologia abordada neste artigo mostra a eficiência e as vantagens conquistadas com o uso da ciência de dados e aprendizado de máquina na manutenção de equipamentos, seja qual for o setor em que ele estiver inserido.

A prática da manutenção preditiva, de forma geral, proporciona maior controle da empresa em suas atividades, minimizando os inconvenientes causados por mal funcionamento ou paradas inesperadas. Desta forma, reduz-se o custo com equipe de manutenção, com peças sobressalentes e aumenta-se a produtividade. Indiretamente, o negócio ganha em segurança no trabalho e tempo disponível para outras atividades, desenvolvendo a empresa.

Portanto, este trabalho apresentou resultados reais e melhorias quantitativas e qualitativas que a ciência de dados vem trazendo na previsão de séries temporais, em particular para manutenção preditiva.

REFERÊNCIAS

- [1] A. NORTH, Matthew. Data Mining for the Masses, A Global Text Project Book, 2012
- [2] BALLOU, R. H. Gerenciamento Da Cadeia de Suprimentos Logística Empresarial, 5ª Edição. Bookman, 2006
- [3] MOBLEY, R. K. An Introduction to Predictive Maintenance, 2nd ed. Plant Engineering, 2002
- [4] HOFMANN, M. and KLINKENBERG, R. RapidMiner: Data Mining Use Cases and Business Analytics Applications, CRC Press, 2013