



Análise do desempenho de algoritmos de classificação aplicados a manutenção preditiva

Performance analysis of classification algorithms applied to predictive maintenance

Daniel Martins¹, Diogo Marujo²

RESUMO

A manutenção preditiva envolve a previsão de falhas em equipamentos e sistemas com base em dados históricos e sensores, permitindo intervenções preditivas para evitar paradas não programadas e reduzir custos de manutenção. O presente artigo tem como objetivo abordar a aplicação de algoritmos de classificação na área de manutenção preditiva, um campo crucial para a eficiência operacional em diversas indústrias. Nesse sentido, são comparados diversos algoritmos de classificação apresentados no software WEKA, considerando uma base de dados sintética. O desempenho de diferentes algoritmos de classificação, é comparado considerando métricas como acurácia, precisão, recall e F-Measure. Os resultados da análise ajudam a orientar a escolha do algoritmo mais adequado para cenários específicos de manutenção preditiva, levando em conta as necessidades de cada indústria, o tipo de equipamento e os recursos disponíveis. O algoritmo SimpleLogistic se destacou como o mais adequado para o cenário de manutenção preditiva estudado, apresentando desempenho superior em todas as métricas avaliadas. Esse estudo é fundamental para a implementação eficaz da manutenção preditiva, contribuindo para a redução de falhas não planejadas, resultando em benefícios significativos para as operações e a rentabilidade das empresas.

PALAVRAS-CHAVE: algoritmos de classificação, machine learning, manutenção preditiva.

ABSTRACT

Predictive maintenance involves predicting failures in equipment and systems based on historical data and sensors, enabling predictive interventions to avoid unscheduled downtime and reduce maintenance costs. This article addresses the application of classification algorithms in predictive maintenance, a crucial field for operational efficiency in several industries. In this sense, several classification algorithms presented in the WEKA software are compared, considering a synthetic database. The performance of different classification algorithms is compared by considering metrics such as accuracy, precision, recall, and F-Measure. The results of the analysis help guide the choice of the most appropriate algorithm for specific predictive maintenance scenarios, taking into account the needs of each industry, the type of equipment, and available resources. The SimpleLogistic algorithm was the most suitable for the predictive maintenance scenario studied, presenting superior performance in all evaluated metrics. This study is essential for effectively implementing predictive maintenance, reducing unplanned failures, and significantly benefiting companies' operations and profitability.

KEYWORDS: classification algorithms, machine learning, predictive maintenance.

INTRODUÇÃO

A análise de dados (AD) vem se tornando uma ferramenta muito poderosa no que tange o mundo corporativo e acadêmico, visto que transforma dados em informações úteis, auxiliando na tomada de decisão. Nesse sentido, a AD é uma excelente alternativa sua aplicação em diversas áreas que precisam de soluções mais precisas. Segundo Amaral (2019), aprendizagem de máquina é importante pois tem a capacidade de detectar padrões que seriam extremamente difíceis de identificar a olho nu ou mesmo utilizando métodos convencionais de análise de dados

¹ Aluno no Curso de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil. E-mail: martinsd@alunos.utfpr.edu.br. ID Lattes: 4785464325688572

² Docente no Curso de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil. E-mail: diogomarujo@utfpr.edu.br. ID Lattes: 0507143597634871.



Em relação ao aprendizado de máquina, um modelo de classificação estabelece em qual classe uma nova informação pertence, e tem como objetivo medir o quão distante a informação testada está do modelo perfeito. No contexto da manutenção preditiva, a partir do treinamento de um algoritmo de classificação, o objetivo é determinar, com base em condições e características de um equipamento, se ele irá falhar, assim como detectar o tipo de falha. Entretanto, a escolha do algoritmo adequado não é uma tarefa trivial, já que requer uma avaliação cuidadosa do desempenho em relação a uma série de métricas, como a acurácia, precisão, recall, F-Measure (Sammur e Webb, 2011).

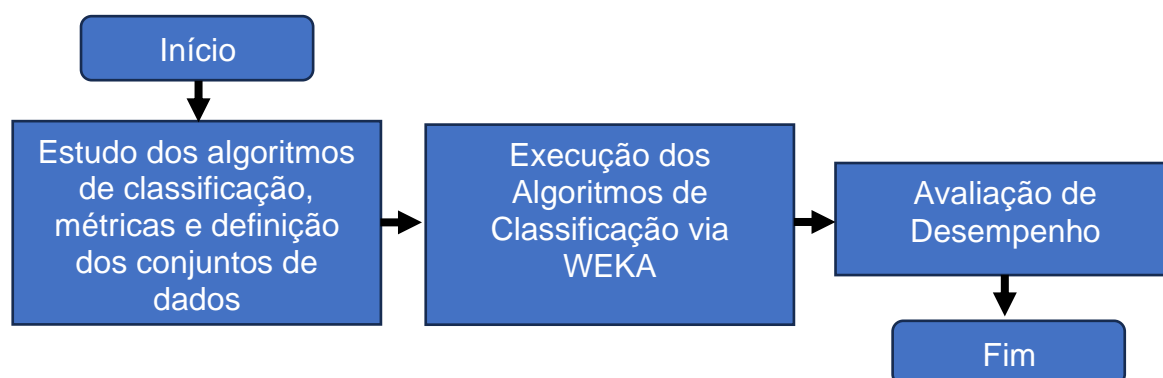
Matka (2020) apresenta e fornece um conjunto de dados de manutenção preditiva realista, porém sintético, para uso pela comunidade científica. Ademais, o artigo explora três algoritmos de classificação. Em Paolanti et. al. (2018) é apresentada uma arquitetura de Machine Learning para Manutenção Preditiva, baseada na abordagem Random Forest. O sistema foi testado em um exemplo real da indústria. Os resultados preliminares mostraram um comportamento adequado da abordagem utilizada. Kanawaday e Sane (2017) exploram o uso da previsão de média móvel integrada autoregressiva (ARIMA) nos dados de séries temporais coletados de vários sensores de uma máquina de corte, para prever possíveis falhas e defeitos de qualidade, melhorando assim o processo geral de fabricação. Carvalho et. Al. (2019) apresentam uma revisão sistemática da literatura sobre métodos de análise de dados aplicados a manutenção preditiva, mostrando quais estão sendo explorados nesta área e o desempenho das técnicas.

Este artigo tem como objetivo comparar algoritmos de classificação aplicados a manutenção preditiva. Para isso serão consideradas as métricas mais comumente utilizadas para avaliar o desempenho dos algoritmos, buscando garantir resultados adequados no momento da escolha. Por meio desta análise apresentada no artigo, espera-se fornecer uma visão abrangente e prática da análise de desempenho de algoritmos de classificação e que, quando aplicados a manutenção preditiva, auxiliem profissionais a tomar decisões embasadas na análise dados.

MATERIAIS E METODOS

O presente estudo foi desenvolvido considerando os passos apresentados no fluxograma da Figura 1.

Figura 1 – Fluxograma do processo



Fonte: Autoria própria (2023)



Na primeira etapa do processo foram estudados os algoritmos de classificação disponíveis no software WEKA (Weka, 2023). Foram selecionadas 12 opções, sendo eles o *BayesNet*, *NaiveBayes*, *BFTree*, *J48*, *RandomTree*, *RandomForest*, *ClassificationViaClustering*, *ClassificationViaRegressin*, *SMO*, *SimpleLogistic*, *LibLINEAR* e *wiSARD*.

Em seguida, foi preciso entender as métricas utilizadas para avaliar o desempenho dos algoritmos. Serão utilizadas as seguintes métricas: avaliação de verdadeiro positivo (TP), falso positivo (FP), acuraria, precisão, *recall* e *F-Measure*.

Para a análise dos algoritmos selecionados foi escolhido um conjunto de dados que simulam dados de manutenção preditiva. Como conjuntos de dados reais de manutenção preditiva são geralmente difíceis de obter, seja por falta de monitoramento ou por questões de segurança da empresa, foi utilizado um conjunto de dados sintético que reflete a manutenção preditiva real encontrada na indústria. O *dataset* utilizado pode ser encontrado em UCI MACHINE LEARNING REPOSITORY (2023), utilizado por Matzka (2020).

A Figura 2, mostra um trecho do conjunto de dados utilizado, que são divididos nos seguintes atributos: ordem do conjunto de dados, número de identificação da instância, código de produto, qualidade (baixa L, médio M e alta H), temperatura do ar, temperatura do processo, velocidade de rotação, torque e desgaste da ferramenta. A coluna *Target* indica se houve falha ou não no equipamento. O tipo de falha (*Failure Type*) indica o que ocorreu com a máquina, resultando em seis possibilidades, sendo: Sem Falha (*No Failure*), Falha de Energia (*Power Failure*), Falha no Desgaste da Ferramenta (*Tool Wear Failure*), Falha de Sobrecarga (*Overstrain Failure*), Falhas Aleatórias (*Random Failures*), Falha de Discipação de Calor (*Heat Dissipation Failure*). Para mais informações, acessar UCI MACHINE LEARNING REPOSITORY (Matzka, 2020).

Figura 2 – Exemplo dos dados

No.	1: λ UDI Numeric	2: Product ID Nominal	3: Type Nominal	4: Air temperature [K] Numeric	5: Process temperature [K] Numeric	6: Rotational speed [rpm] Numeric	7: Torque [Nm] Numeric	8: Tool wear [min] Numeric	9: Target Numeric	10: Failure Type Nominal
1	1.0	M14860	M	298.1	308.6	1551.0	42.8	0.0	0.0	No Failure
2	9975.0	L57154	L	298.6	308.2	1361.0	68.2	172.0	1.0	Power Failure
3	1335.0	L48514	L	299.0	310.4	1365.0	49.1	226.0	1.0	Random Failures

Fonte: Aatoria própria (2023)

A próxima etapa consiste em realizar o pré-processamento dos dados, verificando quais instâncias são úteis para análise em questão, assim como a verificação se todos os dados estão completos ou sem falhas. Os atributos UID e product ID foram removidos do conjunto de dados, uma vez que estão relacionados ao número da instância e a identificação do produto, respectivamente, não sendo estes focos do trabalho. As instâncias que tiveram como tipo de falha (*failure type*), falhas aleatórias (*random failures*), também foram removidas, pois são *outliers* nos dados. Foram encontradas 18 instâncias classificadas dessa forma, logo o conjunto de dados após o pré-processamento possui 9982 instâncias.

O próximo passo consiste no processamento dos dados utilizando o WEKA (Waikato Environment for Knowledge Analysis), software open source desenvolvido em java, criado e mantido pela Universidade de Waikato, na Nova Zelândia (Weka, 2023). Seu diferencial é possuir uma interface gráfica acessível e intuitiva, que permite a realização de análises com grande fluidez e facilidade, resultando nas informações reunidas na figura 2.



Na última etapa foi avaliado o desempenho de cada algoritmo através das métricas de avaliação de verdadeiro positivo (TP), falso positivo (FP), acuraria, precisão, recall e F-Measure. Por meio da matriz confusão é possível analisar o desempenho de um modelo de classificação. Ademais, ela permite a visualização simples de dos dados que foram classificados adequadamente em cada classe. Por fim, a matriz de confusão fornece as informações referentes aos verdadeiros positivos (TP rate) e falsos positivos (FP rate) (Castro, 2016). A acuraria informa, independente da classe, quantos dados foram realmente classificados corretamente, uma vez que está métrica consiste na razão entre as informações que o modelo acertou e todas as informações. A precisão consiste na razão dos dados classificados de forma correta como positivos e todos os dados classificados como positivos. Essa métrica destaca a análise dos erros dados como falsos positivos, ou seja, permite um estudo sobre dados previstos positivamente. O *Recall*, de maneira oposta a precisão, destaca a análise dos erros dados como falsos negativos, desta forma, é composta pela razão das informações classificados de maneira correta como positivos e a quantidade de dados que são de fato positivos. Score F1 também, chamado de *F-Measure* tende a ser a mais adequada para descrever o cenário global como satisfatório ou não, retornando o modelo mais adequado. Ela leva em consideração tanto a precisão, quanto o *recall*, obtendo uma média (Sammur e Webb, 2011).

RESULTADOS E DISCUSSÕES

Nesta seção é apresentada a comparação de 12 diferentes tipos de algoritmos de classificação de dados: *NaiveBayes*, *BayesNet*, *BFTree*, *J48*, *RandomTree*, *RandomForest*, *ClassificationViaClustering*, *ClassificationViaRegressin*, *SMO*, *SimpleLogistic*, *LibLINEAR*, *wiSARD*. Para saber mais sobre cada algoritmo de classificação, acessar a documentação disponível no WEKA.

Todos os algoritmos foram executados com a mesma distribuição de dados, utilizando um percentual de 70% dos dados para treino e 30% para teste. Após executar os 12 algoritmos, as métricas obtidas para cada método são sumarizadas no quadro 1.

Quadro 1 – Resultado da reprodução dos algoritmos

Algoritmo	Acurácia	TP Rate	FP Rate	Precisão	Recall	F-Measure
BayesNet	99,165%	0,992	0,010	0,992	0,992	0,992
NaiveBayes	99,165%	0,992	0,000	0,993	0,992	0,992
BFTree	99,332%	0,993	0,000	0,994	0,993	0,993
J48	99,566%	0,996	0,000	0,996	0,996	0,996
RandomTree	99,432%	0,994	0,010	0,995	0,994	0,995
RandomForest	99,666%	0,997	0,000	0,997	0,997	0,997
ClassificationViaClustering	50,417%	0,504	0,240	-	0,504	-
ClassificationViaRegressin	99,432%	0,994	0,049	0,995	0,994	0,994
SMO	99,132%	0,991	0,000	0,993	0,991	0,991
SimpleLogistic	99,733%	0,997	0,000	0,998	0,997	0,997
LibLINEAR	97,162%	0,972	0,819	-	0,972	-
wiSARD	99,566%	0,996	0	0,996	0,996	0,996

Fonte: Autoria própria (2023)



É possível observar no quadro 1 que o algoritmo ClassificationViaClustering foi o que teve o pior desempenho, com uma acurácia de 50,42% e um TP Rate de 0,50. Portanto, o algoritmo em questão não foi eficiente na classificação dos dados utilizando, informando com um FP Rate de 0,24 que produtos com falhas estavam sem nenhum problema.

O algoritmo LibLINEAR também teve um desempenho insatisfatório, apesar de ter tido acurácia de 97,16% e TP Rate de 0,972. Essa conclusão é fundamentada pela pelo FP Rate de 0,819, ou seja, o algoritmo indicou que muitos equipamentos que possuíam problemas estavam sem falha. Logo, é preciso analisar todas as métricas, já que, nem sempre, uma acurácia elevada garante boa eficiência do algoritmo.

O restante dos algoritmos teve um desempenho satisfatório, com índices de acurácia superiores a 99%, um FP Rate baixo, próximo a 0, acurácia, precisão, recall e F-Mesure superiores a 0,99. Portanto, todos poderiam ser utilizados na classificação do conjunto de dados utilizados. Contudo, o algoritmo que se sobressaiu foi o SimpleLogistic, com valores superiores para todas métricas avaliadas.

CONCLUSÃO

Os resultados revelaram que a escolha do algoritmo adequado desempenha um papel crucial na eficácia da manutenção preditiva. Alguns algoritmos demonstraram um desempenho excepcional, alcançando métricas de classificação superiores a 99%, enquanto outros tiveram um desempenho insatisfatório, com altas taxas de falsos positivos. É importante ressaltar que a acurácia isolada não é uma medida suficiente para avaliar a eficiência do modelo, como evidenciado pelos casos em que algoritmos com alta acurácia ainda apresentaram problemas significativos de classificação. Portanto, a consideração de métricas como precisão e recall é fundamental para compreender o comportamento do modelo em relação a erros do tipo falso positivo e falso negativo.

A alta precisão alcançada pelos algoritmos levanta a necessidade de aprofundar o seu desempenho na classificação de cada uma das classes. Devido a possíveis desequilíbrios nas classes, pode comprometer a análise tornando tendenciosa, em razão disso, é válido uma investigação mais detalhada em trabalhos futuros.

Com base nessa análise, o algoritmo SimpleLogistic se destacou como o mais adequado para o cenário de manutenção preditiva estudado, apresentando desempenho superior em todas as métricas avaliadas. No entanto, a escolha final do algoritmo deve ser guiada pelas necessidades específicas do problema e pelas consequências dos erros de classificação. Em última análise, este estudo fornece insights valiosos para profissionais que buscam aperfeiçoar o processo de manutenção bem como melhorar a eficiência operacional em suas respectivas indústrias.

AGRADECIMENTOS

Agradeço a UTFPR pela oportunidade de desenvolver a iniciação científica.

CONFLITO DE INTERESSE

Não há conflito de interesse.



REFERÊNCIAS

AMARAL, Fernando. **Aprenda mineração de dados: teoria e prática** – Rio de Janeiro, RJ: Alta Books, 2016.

CARVALHO, Thyago P. et al. **A systematic literature review of machine learning methods applied to predictive maintenance**. Computers & Industrial Engineering, v. 137, 2019.

CASTRO, Leandro Nunes de; FERRARI, Daniel Games. **Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações** – São Paulo: Saraiva, 2016.

KANAWADAY, Ameeth; SANE, Aditya. **Machine learning for predictive maintenance of industrial machines using IoT sensor data**. In: 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS), Beijing, China, p. 87-90, 2017.

MATZKA, Stephan. **Explainable artificial intelligence for predictive maintenance applications**. In: 2020 Third International Conference on Artificial Intelligence for Industries (AI4I). IEEE, 2020. p. 69-74.

PAOLANTI, Marina. et al. **Machine Learning approach for Predictive Maintenance in Industry 4.0**. In: 2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA), Oulu, Finland, p. 1-6, 2018.

SAMMUT, C., WEBB, G.I. **Encyclopedia of Machine Learning**. Boston, Springer, 2011

UCI MACHINE LEARNING REPOSITORY. **AI4I 2020 Predictive Maintenance Dataset**. Disponível em:
<https://archive.ics.uci.edu/dataset/601/ai4i+2020+predictive+maintenance+dataset>.
Acesso em: 03 set. 2023.

WEKA. **WEKA**. Disponível em: <https://www.cs.waikato.ac.nz/ml/weka/>. Acesso em: 04 set. 2023.