

# Uso de Mineração de Dados para Priorização no Planejamento de Manutenção Preventiva

Thalita Monteiro Obal<sup>1</sup>, Marjorie Bellinello<sup>2</sup>

UTFPR, Campus Guarapuava, PR

Sanja Petrovic<sup>3</sup>

Nottingham University, Nottingham, UK

**Resumo.** O planejamento de manutenção visa garantir o alto desempenho operacional dos ativos industriais por meio do uso eficaz de recursos financeiros, humanos e peças sobressalentes. Em última análise, as atividades de manutenção devem garantir a disponibilidade operacional e confiabilidade das máquinas. A contribuição da presente pesquisa é uma nova metodologia para o planejamento de manutenção preventiva, que se baseia em registros históricos de falhas na máquina e nos custos de manutenção incorridos. Um algoritmo de mineração de dados é utilizado para agrupar falhas históricas que tenham semelhança entre si. Os clusters criados são classificados por um método de tomada de decisão multicritério híbrido CM-TOPSIS, utilizando critérios que expressam a disponibilidade e confiabilidade e o custo incorrido pelas atividades de manutenção realizadas para corrigir as falhas. Isso permite que o engenheiro priorize as atividades e elabore um plano de manutenção preventiva começando com o cluster de maior criticidade e fazendo um *trade-off* entre a disponibilidade e confiabilidade da máquina e o custo da manutenção. Um estudo de caso de uma empresa de alimentos no sul do Brasil foi utilizado, que forneceu registros de falhas coletados em um período de 5 anos para ilustrar a metodologia proposta.

**Palavras-chave.** Manutenção Preventiva, Mineração de Dados, Agrupamento K-means, Confiabilidade, CM-TOPSIS.

## 1 Introdução

A gestão da manutenção de máquinas e equipamentos na manufatura tem recebido considerável atenção nas últimas décadas devido à natureza dinâmica do ambiente industrial em constante mudança e ao aumento do custo dos bens de capital. Uma quebra inesperada de uma máquina muitas vezes resulta em perdas financeiras devido à interrupção na produção ou devido a penalidades impostas pelos clientes por atrasos ou não entrega de produtos. Também pode resultar em riscos à segurança ou à saúde dos operadores [14]. Uma manutenção adequada torna-se uma vantagem competitiva, pois tem um impacto considerável na segurança, qualidade do produto, preço, lucratividade e entrega do produto acabado no prazo. Conseqüentemente, a confiabilidade e a disponibilidade das máquinas envolvidas no processo de produção tornam-se imperativas. Gerenciar a eficácia das atividades de manutenção enquanto se reduz o custo para atender aos objetivos da organização tornou-se cada vez mais importante. Embora os métodos de gestão da manutenção industrial tenham avançado nas últimas décadas, a complexidade técnica das ações humanas envolvidas nas atividades de manutenção e o custo da manutenção ainda representam desafios.

---

<sup>1</sup>thalitaobal@utfpr.edu.br

<sup>2</sup>belinelli@utfpr.edu.br

<sup>3</sup>sanja.Petrovic@nottingham.ac.uk

As atividades de manutenção podem ser agrupadas em três categorias principais: manutenção corretiva, manutenção preventiva e manutenção preditiva. A manutenção corretiva denota a tomada de medidas quando a máquina apresenta falhas. A manutenção preventiva refere-se à manutenção regular periódica planejada e à substituição de peças sobressalentes. A manutenção preditiva (também conhecida como manutenção baseada em condições ou CBM, da sigla em inglês) busca diagnosticar falhas nos componentes antes que resultem em falhas das máquinas, monitorando continuamente sinais de sensores localizados em partes críticas de uma máquina.

A instalação de sensores e a manutenção preditiva são custosas e exigem monitoramento contínuo [11]. As ações de manutenção corretiva realizadas após uma quebra da máquina podem ser muito caras, pois podem envolver serviços de reparo caros ou aquisição de peças sobressalentes na tentativa de manter o tempo de inatividade da máquina o mais baixo possível [17]. Portanto, a manutenção preventiva é uma política de manutenção importante em muitas plantas de fabricação.

A literatura reporta um grande volume de pesquisas no desenvolvimento de modelos matemáticos de manutenção para estimar a confiabilidade das máquinas e determinar as políticas de manutenção otimizadas ([4], [3], [6], [13]). No entanto, a aplicação desses modelos tem sido muito limitada [12], devido a suposições irrealistas, a falta de informações sobre a estratégia de reparo e manutenção, as políticas de gestão de engenharia, os métodos de detecção de falhas, os mecanismos de falha, entre outros [7].

Por outro lado, os métodos de mineração de dados têm sido cada vez mais vistos como uma ferramenta valiosa que pode ser usada para representar uma fonte integrada de informações que melhora a tomada de decisões, sendo amplamente utilizado em setores que incluem a indústria de manufatura.

Algumas pesquisas têm utilizado a mineração de dados para detecção de falhas na manutenção preditiva em uma variedade de indústrias de manufatura, algumas das mais recentes incluindo [1], [2], [15], [9], [16].

A busca minuciosa na literatura revelou apenas um artigo dedicado à aplicação de análise de dados na gestão de manutenção por [10]. Os autores desenvolvem uma arquitetura para um sistema inteligente de gestão de manutenção para a indústria de petróleo e gás no contexto da Indústria 4.0, que requer um nível avançado de computação e análise cognitiva.

Neste cenário, a principal contribuição da presente pesquisa é o desenvolvimento de uma nova metodologia para o planejamento de manutenção, que se baseia na análise de registros históricos de falhas. A literatura apresentada confirma que as técnicas de mineração de dados podem servir como uma ferramenta eficiente a ser aplicada na gestão de manutenção e possibilitar a utilização de dados históricos relevantes para a manutenção. No entanto, nenhuma pesquisa se baseia na sinergia entre a tomada de decisão multicritério e a clusterização.

Os principais elementos da metodologia incluem a clusterização de registros de falhas, que agrupa falhas com criticidade semelhante e a classificação multicritério de clusters com base em sua criticidade. A metodologia permite ao engenheiro priorizar atividades no plano de manutenção preventiva começando pelo cluster com a maior criticidade e fazendo um trade-off entre a disponibilidade da máquina e a confiabilidade das operações, e o custo da manutenção.

Além disso, uma das indústrias em que a quebra de máquinas é particularmente prejudicial no processo de produção é a indústria alimentícia, pois as consequências das falhas das máquinas provavelmente impactam a qualidade do produto através de contaminação química, física e/ou biológica. Assim, a metodologia desenvolvida é aplicada a um estudo de caso em uma empresa de alimentos no sul do Brasil, com base nos registros de falhas coletados em um período de 5 anos.

## 2 Metodologia para o Planejamento de Manutenção Preventiva Baseado em Data Mining

O planejamento de manutenção envolve a priorização das atividades de manutenção. O cerne da metodologia é a clusterização de falhas, que agrupa falhas de criticidade semelhante. Os clusters criados são classificados por sua criticidade usando um método de tomada de decisão multicritério. Posteriormente o engenheiro de manutenção inclui atividades apropriadas no plano de manutenção considerando a classificação dos clusters.

A descrição dos passos da metodologia é apresentada a seguir.

### Passo 1. Conhecimento do sistema.

Mapear o sistema da fábrica, identificar os componentes das máquinas e as características e peculiaridades de cada linha de produção. Além disso, compreender o impacto que cada parte tem sobre as outras partes na linha de produção quando ocorre uma falha.

### Passo 2. Análise dos modos de falha.

Analisar os dados históricos de falhas e a criticidade das falhas usando FMEA.

Identificar os indicadores a serem utilizados como critérios de decisão na priorização das falhas por sua criticidade. Calcular a disponibilidade e confiabilidade operacional da máquina, utilizando dados de falhas críticas e repetitivas históricas. Geralmente, os indicadores incluem: tempo de reparo (TTR), tempo entre falhas (TBF), tempo médio de reparo (MTTR), tempo médio entre falhas (MTBF), disponibilidade da máquina (%), confiabilidade da máquina/operações (%), taxa de falha, custo das peças, custo dos reparos terceirizados (unidades monetárias), custo da mão de obra (unidades monetárias), perda de lucro (unidades monetárias), etc.

### Passo 4. Agrupamento de falhas

Aplicar o algoritmo de clusterização k-means para agrupar falhas que tenham criticidades similares.

A clusterização é um processo de aprendizado não supervisionado no qual a adesão das observações (falhas) a um cluster precisa ser aprendida. O objetivo é maximizar a similaridade entre falhas dentro de um cluster, e ao mesmo tempo maximizar a dissimilaridade entre falhas em diferentes clusters.

### Passo 5. Priorização dos grupos

Os clusters são classificados por sua criticidade usando o método de tomada de decisão multicritério CM-TOPSIS [8]. O cluster mais crítico é classificado em primeiro lugar. Os indicadores escolhidos para serem utilizados na clusterização no Passo 3 também são usados como critérios na classificação. A classificação considera simultaneamente as medidas de desempenho de interesse na planta de manufatura e o custo incorrido pelas atividades de manutenção.

### Passo 6. Criação do plano de manutenção

A metodologia proposta fornece uma ferramenta que orienta os engenheiros a criar um plano de manutenção preventiva eficaz a partir do cluster com a maior criticidade. Para cada falha no cluster, há uma atividade de manutenção associada realizada no passado. Com base na classificação do cluster, tal atividade pode ou não ser incluída no plano de manutenção preventiva. Dessa

forma, com base em falhas históricas, o engenheiro prioriza atividades de manutenção preventiva considerando um equilíbrio entre a disponibilidade e confiabilidade da máquina e o custo da manutenção.

### 3 Um Estudo de Caso de uma Indústria Alimentícia

Uma empresa de alimentos do sul do Brasil serviu como caso de estudo para a metodologia proposta. Sua linha de produção é composta por máquinas organizadas em série, sem redundância. Portanto, a interrupção de qualquer uma dessas máquinas resulta na paralisação de todo o processo. A máquina de revestimento, localizada no meio da linha, é a que mais frequentemente apresenta falhas.

As atividades de manutenção na indústria de alimentos abrangem aspectos elétricos, eletrônicos e mecânicos. São cruciais para prevenir falhas, como desgaste, contaminação, interrupções completas, superaquecimento e vazamentos. Essas falhas representam riscos tanto para a qualidade dos alimentos quanto para a segurança dos trabalhadores e o meio ambiente. Além de diminuir a produtividade, as falhas acarretam custos desnecessários de manutenção, incluindo peças sobressalentes, e aumentam os riscos associados à lubrificação, afetando diretamente a qualidade e a segurança dos alimentos. Cada tipo de falha requer medidas de reparo específicas, variando em frequência de aplicação.

Ao longo de cinco anos, a empresa registrou 140 incidentes de falhas, cada um documentado com as ações corretivas realizadas para sua resolução. Os passos da metodologia proposta para a manutenção da máquina de revestimento são delineados a seguir. Para a clusterização, utiliza-se o pacote de software R, que oferece o algoritmo k-means, enquanto o CM-TOPSIS é implementado através do Excel.

#### Passo 1. Conhecimento do sistema.

Esta pesquisa foi baseada apenas na análise de confiabilidade da máquina de revestimento, que é a máquina com maior frequência de falhas e é um gargalo da linha de produção. Esta linha de produção não possui backup para nenhuma das máquinas e, como as máquinas estão conectadas em série, se a máquina parar de funcionar, todo o processo também para. A máquina de revestimento está na parte intermediária da linha de produção.

#### Passo 2. Análise dos modos de falha.

Um extrato dos registros de falhas é apresentado na Tabela 1.

#### Passo 3. Indicadores de operações e manutenção.

Os indicadores de operação e manutenção são obtidos a partir de dados históricos de manutenção da máquina de revestimento, manual técnico, parâmetros operacionais obtidos no campo (sistema supervisorio) e FMEA. Os indicadores de operação e manutenção incluem tempo para reparo (TTR) (horas), disponibilidade ( $A(t)$ ) (%), que inclui Tempo entre falhas, tempo médio para reparo e tempo médio entre falhas, custo de mão de obra e perda de lucros (U\$) e custo de peças e reparos terceirizados (U\$). Como o custo de mão de obra e a perda de lucros estão ambos relacionados ao tempo, eles são considerados juntos como um atributo e estão apresentados na Tabela 1.

Tabela 1: Extrato do registro de falhas.

Numeração da falha ( $F_i$ )	Modo de Falha	Tempo para reparo (TTR) (h)	A(t)	Custo de mão de obra + Perda de lucros (US\$)	Custo de peças/ reparos terceirizados (US\$)
F1	Fratura	5,5	0,95	34661,19	124,14
F2	Elétrica / Eletrônico	2,15	0,97	13526,21	188,36
F3	Ajuste elétrica/eletrônico	2,15	0,97	13526,21	-
F4	Lubrificação / Sistema de Transmissão	6,8	0,96	42780,58	68,49
F5	Processo de Limpeza e Sanitização	2,5	0,97	15728,15	222,6
F6	Lubrificação / Fratura	9	0,96	56621,36	244,01
F7	Processo de Limpeza e Sanitização	2,5	0,97	15737,13	-
F8	Eletrônico	4	0,97	25165,05	-

#### Passo 4. Agrupamento de falhas

Em colaboração com o engenheiro de manutenção da empresa, realizou-se a clusterização dos registros de falhas utilizando diversas combinações pertinentes dos indicadores identificados no Passo 3, juntamente com um número apropriado de clusters.

Utilizou-se a função NbClust [5] do software estatístico R, para definição do número de clusters. Esta função emprega 30 índices para avaliar o número ideal de clusters e faz uma lista dos números mais escolhidos. Além disso, seguindo a avaliação do especialista decisor, o número de clusters deve estar entre 3 e 8, levando em conta a natureza das falhas. A função NbClust sugeriu inicialmente 2 clusters, porém o especialista considerou esse número insuficiente. A segunda sugestão do NbClust foi de 4 clusters, o que foi aceito.

Posteriormente utilizou-se a função k-means também do software R para definição dos cluster e agrupamento das falhas. Os clusters foram denominados como A, B, C e D, e continham, respectivamente 11, 20, 34 e 75 falhas.

#### Passo 5. Priorização dos clusters

O método CM-TOPSIS é aplicado para classificar os clusters por sua criticidade. Cada cluster é representado pelo seu centróide e a classificação de múltiplos critérios dos clusters pelo CM-TOPSIS é mostrada na Tabela 2.

Tabela 2: Ranking multicritério dos clusters.

Objetivo	MAX	MIN	MAX	MAX		
Critério	C1: TTR (h)	C2: A(t) (%)	C3: Custo do trabalho (US\$) + perda de lucro (US\$)	C4: Custo das peças (US\$)		
Pesos	0.1591	0.2831	0.1590	0.3988		Rank
A	0.0157	0.0203	0.0158	0.0391	0.5000	2
B	0.0136	0.0203	0.0136	0.0147	0.2235	3
C	0.0119	0.0204	0.0119	0.0806	0.9204	1
D	0.0060	0.0204	0.0060	0.0015	0.0000	4

O indicador O&M C4 possui o maior peso entre os critérios para a priorização dos clusters. A classificação mostra que o cluster C possui as falhas mais críticas em relação aos valores dos indicadores operacionais e de manutenção escolhidos.

A priorização dos clusters reforça que o cluster C combina os modos de falha mais críticos, que impactam principalmente a confiabilidade e os custos do sistema de produção.

## Passo 6. Criação do plano de manutenção

O Cluster C compreende os modos de falha mais críticos que impactam a maquinaria em relação à disponibilidade, confiabilidade e custos de manutenção. Portanto, foram propostas pelo engenheiro atividades preventivas para compor um plano preventivo robusto com o objetivo de mitigar e/ou resolver esses modos de falha e evitar sua recorrência.

## 4 Considerações Finais

Este artigo propõe uma ferramenta inovadora para garantir assertividade na tomada de decisões em manutenção preventiva, visando determinar componentes críticos de um sistema e escolher a política de manutenção mais adequada. A novidade do método híbrido proposto reside na análise de falhas históricas e seu impacto na linha de produção. Essa análise é utilizada para auxiliar o engenheiro na determinação das atividades de manutenção preventiva mais adequadas, que atendam aos requisitos da engenharia de qualidade e da engenharia de manutenção, proporcionando disponibilidade e confiabilidade ao sistema industrial e garantindo a qualidade do produto.

A metodologia é ilustrada através de um estudo de caso na indústria alimentícia. Destacam-se a inconsistência na valoração da criticidade do modo de falha pelo FMEA. Por outro lado, a metodologia híbrida proposta, baseada na análise de registros históricos de falhas, agrupamento de falhas com criticidade similar e classificação de clusters usando um método de tomada de decisão multicritério, mostra-se uma ferramenta eficaz para a priorização de atividades no planejamento de manutenção preventiva. Clusters com maior criticidade são considerados primeiro, proporcionando um equilíbrio entre a disponibilidade da máquina e a confiabilidade das operações, e o custo da manutenção.

Embora a metodologia proposta seja avaliada na fabricação de alimentos, ela é geral e fornece suporte na tomada de decisões de manutenção em qualquer tipo de indústria que tenha registros históricos de falhas disponíveis.

Como trabalho futuro sugere-se a investigação da aplicabilidade da metodologia proposta em outros contextos além da gestão de manutenção. Acredita-se que ela possa ser aplicada a uma variedade de processos de tomada de decisão que requerem a seleção de atividades, onde é difícil desenvolver um modelo matemático, mas mineração de dados históricos guia a tomada de decisões.

## Referências

- [1] G. Aydemir e K. Paynabar. “Image-based Prognostics Using Deep Learning Approach”. Em: **IEEE Transactions on Industrial Informatics** (2019). DOI: 10.1109/tii.2019.2956220.
- [2] G. H. Bazan, P. R. Scalassara, W. Endo e A. Goedel. “Information Theoretical Measurements from Induction Motors Under Several Load and Voltage Conditions for Bearing Faults Classification”. Em: **IEEE Transactions on Industrial Informatics** (2019). DOI: 10.1109/tii.2019.2939678.

- [3] J. H. Cha, M. Finkelstein e G. Levitin. “Age-replacement policy for items described by stochastic degradation with dependent increments”. Em: **IMA Journal of Management Mathematics** 33 (2021). DOI: 10.1093/imaman/dpab014.
- [4] J. H. Cha, M. Finkelstein e G. Levitin. “On the delayed worse-than-minimal repair model and its application to preventive replacement”. Em: **IMA Journal of Management Mathematics** 34 (2023). DOI: 10.1093/imaman/dpab036.
- [5] M. Charrad, N. Ghazzali, V. Boiteau e A. Niknafs. “NbClust: An R Package for Determining the Relevant Number of Clusters in a Data Set”. Em: **Journal of Statistical Software** 61.6 (2014), pp. 1–36. DOI: doi.org/10.18637/jss.v061.i06.
- [6] H. Dui, X. Dong e M. Liu. “A data-driven construction method of aggregated value chain in three phases for manufacturing enterprises.” Em: **Computers Industrial Engineering** 189 (2024). DOI: 10.1016/j.cie.2024.109964.
- [7] A. Garg e S. Deshmukh. “Maintenance management: literature review and directions”. Em: **Journal of Quality in Maintenance Engineering** 12 (2006), pp. 205–238. DOI: 10.1108/13552510610685075.
- [8] C. L. Hwang e K. Yoon. **Multiple Attribute Decision Making: Methods and Applications**. New York: Springer-Verlag, 1981. DOI: 10.1007/978-3-642-48318-9.
- [9] N. Kolokas, T. Vafeiadis, D. Ioannidis e D. Tzovaras. “A generic fault prognostics algorithm for manufacturing industries using unsupervised machine learning classifiers”. Em: **Simulation Modelling Practice and Theory** 103 (2020). DOI: 10.1016/j.simpat.2020.102109.
- [10] H. Nordal e I. El-Thalji. “Modeling a predictive maintenance management architecture to meet industry 4.0 requirements: A case study”. Em: **Systems Engineering** 24.1 (2020), pp. 34–50. DOI: doi:10.1002/sys.21565.
- [11] H. B. Razente, M. Belinelli, M. Souza G. F, M. Rodrigues, M. Matsuzaki e A. Savoldi. “Application of the AHP multi criteria analysis method for the decision-making in industrial maintenance activities: Case study in a food company”. Em: **Proceedings of the joint ICVRAM ISUMA UNCERTAINTIES conference**. 2018.
- [12] A. Sharma, G. S. Yadava e S. G. Deshmukh. “A literature review and future perspectives on maintenance optimization”. Em: **Journal of Quality in Maintenance Engineering** 17 (2011), pp. 5–25. DOI: 10.1108/13552511111116222.
- [13] J. Shen, Y. Zhang, Y. Ma e C. Lin. “A novel opportunistic maintenance strategy for systems with dependent main and auxiliary components”. Em: **IMA Journal of Management Mathematics** 32 (2021). DOI: 10.1093/imaman/dpaa016.
- [14] A. H. C. Tsang. “Condition-based maintenance: tools and decision making”. Em: **Journal of Quality in Maintenance Engineering** 1 (1995), pp. 3–17. DOI: 10.1108/13552519510096350.
- [15] N. Bouhmala V. J. Jimenez e A. H. Gausdal. “Developing a predictive maintenance model for vessel machinery”. Em: **Journal of Ocean Engineering and Science** 5.4 (2020), pp. 358–386. DOI: 10.1016/j.joes.2020.03.003.
- [16] N. Wang, S. Ren, Y. Liu, M. Yang, J. Wang e D. Huisingh. “An active preventive maintenance approach of complex equipment based on a novel product-service system operation mode”. Em: **Journal of Cleaner Production** (2020). DOI: 10.1016/j.jclepro.2020.123365.
- [17] R. Yam, P. Tse, L. Li e P. Tu. “Intelligent Predictive Decision Support System for Condition-Based Maintenance”. Em: **The International Journal of Advanced Manufacturing Technology** 17 (2001), pp. 383–391. DOI: 10.1007/s001700170173.