

Revisão Sistemática do Uso de Algoritmo de Predição de Desgaste de Rolo Escova

João Gabriel dos Santos Dias Moura Matos¹; 0009-0000-2270-6010

Bruno Lima dos Santos¹; 0009-0002-1808-2369

Ualison Silva Florêncio¹; 0009-0002-0700-6811

Italo Pinto Rodrigues¹; 0000-0002-6832-8358

1 – UniFOA, Centro Universitário de Volta Redonda, Volta Redonda, RJ.

joao.matos@unifoa.edu.br (contato principal)

Resumo: A operação de satélites depende da disponibilidade de modelos confiáveis implementados em simuladores operacionais, capazes de reproduzir o comportamento do sistema em solo. Um desafio relevante consiste em incorporar o envelhecimento dos equipamentos nesses modelos, especialmente no caso da bateria, componente essencial para o fornecimento de energia durante eclipses. Este trabalho avalia a influência da função de treinamento na obtenção de redes neurais artificiais aplicadas à modelagem do envelhecimento da bateria do satélite CBERS-4. A arquitetura 6x9x2x1 foi mantida constante, sendo testadas três funções de treinamento: Levenberg-Marquardt, Regressão Bayesiana e Descida do Gradiente. O desempenho foi avaliado por meio do erro médio relativo quadrático (MRSE), calculado a partir de 56.081 amostras de telemetria real. Os resultados indicaram que Levenberg-Marquardt apresentou o menor erro (0,4919%), seguido pela Regressão Bayesiana (0,6058%), enquanto a Descida do Gradiente obteve desempenho inferior (1,4680%). Os achados confirmam que a escolha da função de treinamento influencia diretamente a acurácia do modelo, sendo determinante para sua aplicação em simuladores operacionais que exigem tanto fidelidade quanto execução em tempo real.

Palavras-chave: Satélites. Simuladores operacionais. Redes neurais artificiais. Envelhecimento de baterias. Funções de treinamento.

INTRODUÇÃO

O desgaste é definido como a remoção gradual de material do contato de superfícies devido ao movimento relativo entre eles, sendo um dos principais problemas da indústria, que influencia significativamente a qualidade do produto e os custos de fabricação (Williams, 2005).

Os rolos escovas são componentes, projetados com materiais resistentes, utilizados no meio industrial para transporte e limpeza de determinadas superfícies de materiais como placas de aços e laminadores. Nesse sentido, em função do constante contato e atrito com materiais abrasivos, ocorre um desgaste gradual dos rolos, gerando custos operacionais e impacto direto no processo produtivo.

Medir e compreender este fenômeno de desgaste é uma tarefa complexa, focada em experimentos e modelagens anteriormente realizadas para estimar tal comportamento (Bressan *et al.*, 2008). Modelar o desgaste apresenta um grande desafio devido à interação de múltiplos fatores como: propriedade do material, condições de operação e o ambiente. A modelagem orientada a dados surge como uma possível solução, uma vez que coleta e utiliza um grande volume de dados operacionais para criar modelos matemáticos ou computacionais capazes de prever tal comportamento. Nesse sentido, a técnica de modelagem orientada a dados se mostra eficaz em relação aos métodos tradicionais, podendo analisar sistemas complexos com maior precisão.

Sendo assim uso de um algoritmo de previsão de desgaste de rolos escovas pode ser um dos principais fatores para garantir a gestão eficiente do processo industrial como otimização operacional, além de também prever gastos desnecessários contribuindo para uma redução de custos e, paradas não programadas e falhas inesperadas.

O objetivo deste artigo é utilizar a prática da revisão sistemática de literatura (RSL) (Brereton *et al.*, 2007), para identificação de estudos que permitam consolidar o estado da prática e o estado da arte, no que diz respeito às técnicas de modelagem orientada a dados do desgaste de um rolo escova aplicado no processo de transporte de placas de aço.

MÉTODOS

Este estudo foi realizado com base em uma abordagem descrita por Brereton *et al.* (2007) e adaptada por Mumali (2022), para o uso de Inteligência Artificial (IA) na engenharia. A pesquisa foi organizada em três etapas principais:

1. Fase de Planejamento da RSL: Envolve a definição das questões de pesquisa, o desenvolvimento de um protocolo de revisão e a validação desse protocolo.
2. Fase de Execução da RSL: Inclui a identificação de pesquisas relevantes, a seleção de estudos primários, a avaliação da qualidade dos estudos, a extração de dados e a análise dos dados extraídos.
3. Fase de Relato dos Resultados: Compreende a documentação e validação do relatório da revisão sistemática da literatura.

Etapas 1 - Questões de Pesquisa (QP)

Esta revisão sistemática busca responder às seguintes perguntas:

- QP1: Quais algoritmos de IA são utilizados na análise de previsão de desgaste?

- QP2: Quais parâmetros dos componentes em contato foram avaliados?
- QP3: Qual a configuração típica dos algoritmos utilizados?
- QP4: Qual foi o benefício observado após o uso do algoritmo?
- QP5: O algoritmo de IA foi implementado em um processo real?

Etapa 2 – Protocolo de Revisão

Para que as perguntas possam ser respondidas, é necessário estabelecer um protocolo de revisão (Brereton *et al.*, 2007). Na elaboração de uma revisão sistemática, recomenda-se iniciar com a definição de um título provisório e a introdução do objeto de estudo, ressaltando sua relevância. Em seguida, devem ser apresentadas as questões de pesquisa que nortearão a investigação, bem como os objetivos centrais da revisão. Os critérios de elegibilidade precisam ser estabelecidos, indicando tanto as condições de inclusão quanto aquelas que acarretarão a exclusão dos estudos. É fundamental identificar as bases de dados e demais fontes de informação a serem consultadas, delimitando, quando pertinente, o período de publicação. A estratégia de pesquisa deve ser descrita de forma detalhada, incluindo palavras-chave e operadores booleanos utilizados. O processo de seleção dos estudos costuma ocorrer em duas etapas: triagem por título e resumo, seguida da leitura integral para confirmação da pertinência. A extração de dados deve ser conduzida de maneira padronizada, assegurando que informações equivalentes sejam coletadas em todos os estudos. Além disso, a avaliação da qualidade metodológica ou do risco de viés deve ser explicitada, indicando as ferramentas ou escalas adotadas. Por fim, é necessário detalhar a forma de análise dos dados, incluindo eventuais métodos estatísticos e, se aplicável, os procedimentos de meta-análise.

Etapa 3 – Revisão de Protocolo

Foi realizada uma apuração dos artigos pertinentes para definição dos estudos relevantes no desenvolvimento de algoritmos associados a predição de desgaste de materiais. A princípio a estratégia de estudos foi definida por: base de pesquisa: *Web of Science*; Período de busca: 2016 a 2024; Critérios de exclusão: artigos de pesquisa e acesso aberto e, por fim, similaridade no processo industrial. Finalmente, depois de aplicados os filtros de buscas, foram encontradas pesquisas com maior compatibilidade com o tema proposto.

Os outros artigos discutem tópicos variados que não estão especificamente centrados em equipamentos rotativos, se concentram em tópicos industriais gerais, manutenções preventivas em diferentes contextos.

Etapa 4 – Estratégia da Pesquisa

A identificação de pesquisas relevantes exigiu a formulação de termos de busca baseados nas questões de pesquisa, seguindo o protocolo de revisão estabelecido. As palavras-chave determinadas foram: artificial intelligence, machine learning, prediction, rolling process. A string de busca foi ajustada de forma específica para cada base de dados:

“Roll AND rolling process AND (machine learning OR artificial intelligence) AND (prediction OR estimation OR forecasting) AND “Remaining Useful Life”

Etapa 5 – Seleção dos Estudos

Os critérios de seleção são apresentados na Tabela 1. O propósito de usar os critérios de seleção é garantir que apenas pesquisas primárias envolvendo RNA e IA em laminadores de encruamento sejam consideradas, limitando o escopo da pesquisa. A coluna Web of Science da Tabela 2 indica a quantidade de artigos encontrados após a aplicação do critério.

Embora poucas pesquisas tenham apresentado correlação direta com o tema discutido, outros estudos já realizados para análises semelhantes propuseram soluções capazes de serem adaptadas a mesma finalidade devido a qualidade de seus resultados.

Etapa 6 – Análise de Dados

No estudo de Mumali (2022), houve uma tentativa de focar em publicações de revistas conceituadas para garantir dados mais relevantes. No entanto, devido ao número reduzido de amostras disponíveis para essa pesquisa, essa abordagem acabou sendo deixada de lado.

Etapa 7 – Documentação dos Resultados

Foram coletados diferentes tipos de informações, incluindo a data de publicação, o grau de similaridade com o processo industrial, além de dados referentes às análises realizadas (variáveis de entrada e de saída). Também foram consideradas as respostas fornecidas às QPs.



Tabela 1 – Seleção dos Estudos

Critério	Descrição	Web of Science
1	Definiu-se que, somente pesquisas publicadas em inglês seriam utilizadas. O propósito desta etapa era garantir que apenas publicações rigorosamente avaliadas e revisadas por pares de revistas e conferências fossem selecionadas.	65
2	Os resultados foram filtrados para excluir editoriais, livros, capítulos de livros e revisões	18
3	Os estudos resultantes da etapa 2 foram filtrados com base na data de publicação. Foram considerados estudos publicados entre 2016 e 2024 e com acesso aberto.	18
4	Com os resultados do critério anterior, foram selecionados os artigos com similaridades no processo industrial.	9
5	O resultado da etapa 3 foi verificado quanto à correção dos detalhes da publicação e relevância para o propósito da atual revisão sistemática. Os resultados de publicação que faltavam detalhes, como resumos, títulos de fontes e informações sobre dados analisados, foram excluídos. Os artigos incluídos foram analisados e apenas aqueles envolvendo o uso IA e/ou análise da vida útil de equipamentos rotativos seguiram para o próximo critério.	3
6	As publicações resultantes foram selecionadas e as demais excluídas da revisão.	3

Fonte: Elaborada pelos autores.

Etapa 8 – Análise

Os dados levantados foram sistematizados em tabelas, nas quais se destacaram o número de artigos dentro do período delimitado, os periódicos de publicação, o tipo de algoritmo utilizado.

Etapa 9 – Relatório da revisão

Segundo Brereton *et al.* (2007), a etapa final de uma revisão sistemática exige a documentação completa do processo, contemplando as respostas às questões de pesquisa (QPs).

Etapa 10 – Validação da Revisão

Conforme apontado por Brereton *et al.* (2007), a etapa de validação do relatório — que neste estudo corresponde ao próprio artigo. Para atender a essa recomendação, decidiu-se pela submissão do trabalho a um congresso científico, no qual a avaliação é realizada por meio do sistema de revisão duplo-cego.

RESULTADOS E DISCUSSÃO

A Revisão Sistemática identificou os artigos: [1] On Making Factories Smarter through Actionable Predictions based on Time-Series data (Karagiorgou *et al.*, 2020); [2] Data modelling and Remaining Useful Life estimation of rolls in a steel making cold rolling process



(Lakshmanan et al., 2022); [3] A Hybrid Approach for Predicting the Remaining Useful Life of Bearings Based on the RReliefF Algorithm and Extreme Learning Machine (Wang et al., 2024). O intervalo temporal observado permite inferir que: i) trata-se de uma área de investigação ainda em consolidação; ii) a aplicação de técnicas de IA mostra-se relevante para previsões em processos industriais que envolvem o rolo escova; iii) há escassez de algoritmos desenvolvidos especificamente para esse propósito. Quanto às questões de pesquisa definidas no início do trabalho (QPs), as respostas correspondentes encontram-se organizadas na Tabela 2.

Tabela 2 – Respostas às QP.

Artigo	QP1: Quais algoritmos de IA são utilizados na análise de previsão de desgaste?
[1]	Emprega Deep Learning aplicado a dados de sensores IoT em fluxo contínuo, em especial modelos de análise de séries temporais para previsão de falhas.
[2]	Utiliza modelos híbridos de Deep Learning, combinando CNN, LSTM e BiLSTM para previsão da Remaining Useful Life (RUL).
[3]	Propõe um modelo híbrido que combina RReliefF (seleção de atributos) com Extreme Learning Machine (ELM) para previsão da RUL de rolamentos.
Artigo	QP2: Quais parâmetros dos componentes em contato foram avaliados?[IP1]
[1]	Variáveis de condição da máquina, como temperatura, aceleração, vibração, níveis de graxa/óleo lubrificante e condições operacionais diárias.
[2]	Dados de processo do laminador, composição química das bobinas, histórico de desgaste dos rolos e condições operacionais (carga, velocidade de laminação, lubrificação).
[3]	Reconstrução de 60 características no domínio do tempo a partir de sinais de vibração (aceleração horizontal e vertical).
Artigo	QP3: Qual a configuração típica dos algoritmos utilizados?
[1]	Estrutura baseada em redes neurais profundas treinadas em dados de sensores em tempo real, alinhada com atributos de falha registrados em atividades de manutenção.
[2]	Estrutura CNN-LSTM híbrida para extração de características e regressão temporal, ajustada com dados de sensores e históricos industriais.
[3]	Rede ELM de camada única oculta, otimizada por grid search e validação cruzada, utilizando o conjunto de características selecionadas pelo RReliefF.
Artigo	QP4: Qual foi o benefício observado após o uso do algoritmo?
[1]	O sistema possibilitou identificação precoce de eventos raros e detecção de mudanças de comportamento dinâmico, aumentando a confiabilidade e reduzindo custos de manutenção.
[2]	Obteve alta acurácia de previsão da RUL, permitindo melhor planejamento da manutenção e redução de falhas inesperadas.
[3]	O método apresentou maior precisão e robustez em comparação com ANN e SVR tradicionais, com menor custo computacional.
Artigo	QP5: O algoritmo de IA foi implementado em um processo real?
[1] – [2]	Sim.
[3]	Não

Fonte: Elaborada pelos autores.

Modelos híbridos de aprendizado profundo, como *Convolutional Neural Network* (CNN), *Long Short-Term Memory* (LSTM) e *Bidirectional Long Short-Term Memory* (BiLSTM), aplicados em dados de uma planta siderúrgica real, permitiram alcançar previsões precisas

sobre o desgaste de rolos de laminação e a definição do momento adequado para sua substituição (Lakshmanan *et al.*, 2022). A validação em ambiente industrial confere relevância prática, mas a elevada complexidade computacional dificulta a escalabilidade, além de exigir infraestrutura robusta para coleta e integração de dados de processo, composição química e histórico de desgaste.

Integrações entre a Internet Industrial das Coisas (*Industrial Internet of Things – IIoT*) e algoritmos de aprendizado profundo possibilitam a criação de frameworks de manutenção preditiva capazes de monitorar processos em tempo real e identificar eventos raros, o que amplia a confiabilidade em ambientes industriais de alto risco (Karagiorgou *et al.*, 2020).

Combinações entre o algoritmo de seleção de atributos RReliefF (*Regression ReliefF*) e a Máquina de Aprendizado Extremo (*Extreme Learning Machine – ELM*) resultaram em um modelo mais eficiente em termos de custo computacional, superando técnicas tradicionais como Redes Neurais Artificiais e Regressão por Vetores de Suporte (Wang *et al.*, 2024). Apesar da precisão alcançada, a validação restrita a dados experimentais da base XJTU-SY impede a comprovação de robustez em cenários industriais reais, reduzindo a aplicabilidade imediata.

De forma comparativa, os modelos baseados em aprendizado profundo demonstram maturidade prática, ainda que dependentes de alto poder computacional (Lakshmanan *et al.*, 2022), enquanto as arquiteturas de integração digital se destacam pelo potencial de aplicação em fábricas inteligentes, mas carecem de profundidade técnica (Karagiorgou *et al.*, 2020). Já os modelos híbridos mais leves avançam em eficiência e simplicidade, embora permaneçam limitados a condições laboratoriais (Wang *et al.*, 2024). A análise conjunta indica que a convergência entre robustez técnica, integração digital e eficiência algorítmica é o caminho para soluções mais completas em previsão de desgaste e manutenção preditiva.

CONCLUSÕES

A presente revisão sistemática explorou o uso de algoritmos de previsão para desgaste de rolo escova, com estudos que abordam a predição de vida útil restante (RUL) e o aprendizado de máquinas em componentes críticos do processo industrial, fornecendo uma

visão de como diferentes tipos de análise trazem resultados significativos para otimizar a manutenção e reduzir custos operacionais. Estes estudos enfatizam a importância de técnicas avançadas para a eficiência da manutenção preventiva, oferecendo uma melhor abordagem na gestão de ativos industriais. A adoção dessas tecnologias pode transformar a rotina de manutenção industrial, promovendo um aumento na confiabilidade de equipamentos e uma redução significativa de gastos operacionais.

AGRADECIMENTOS

Os autores agradecem ao Centro Universitário de Volta Redonda (UniFOA) pelo apoio institucional e financeiro, por meio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC) (92812/17/RPE).

REFERÊNCIAS

- BRERETON, Pearl; KITCHENHAM, Barbara A.; BUDGEN, David; TURNER, Mark; KHALIL, Mohamed. Lessons from applying the systematic literature review process within the software engineering domain. **Journal of Systems and Software**, [s. l.], v. 80, n. 4, p. 571–583, abr. 2007. <https://doi.org/10.1016/j.jss.2006.07.009>.
- BRESSAN, J.D.; DAROS, D.P.; SOKOLOWSKI, A.; MESQUITA, R.A.; BARBOSA, C.A. Influence of hardness on the wear resistance of 17-4 PH stainless steel evaluated by the pin-on-disc testing. **Journal of Materials Processing Technology**, [s. l.], v. 205, n. 1–3, p. 353–359, ago. 2008. <https://doi.org/10.1016/j.jmatprotec.2007.11.251>.
- KARAGIORGOU, Sophia; ROUNTOS, Christos; CHATZIMARKAKI, Georgia; VAFEIADIS, Georgios; NTALAPERAS, Dimitrios; VERGETI, Danae; ALEXANDROU, Dimitrios. On Making Factories Smarter through Actionable Predictions based on Time-Series Data. **Procedia Manufacturing**, [s. l.], v. 51, p. 1207–1214, 2020. <https://doi.org/10.1016/j.promfg.2020.10.169>.
- LAKSHMANAN, Kayal; BORGHINI, Eugenio; BECKMANN, Arnold; PLEYDELL-PEARCE, Cameron; GIANNETTI, Cinzia. Data modelling and Remaining Useful Life estimation of rolls in a steel making cold rolling process. **Procedia Computer Science**, [s. l.], v. 207, p. 1057–1066, 2022. <https://doi.org/10.1016/j.procs.2022.09.161>.
- MUMALI, Fredrick. Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. **Computers & Industrial Engineering**, [s. l.], v. 165, p. 107964, mar. 2022. <https://doi.org/10.1016/j.cie.2022.107964>.
- WANG, Sen-Hui; KANG, Xi; WANG, Cheng; MA, Tian-Bing; HE, Xiang; YANG, Ke. A Hybrid Approach for Predicting the Remaining Useful Life of Bearings Based on the RRelief Algorithm and Extreme Learning Machine. **Computer Modeling in Engineering & Sciences**, [s. l.], v. 140, n. 2, p. 1405–1427, 2024. <https://doi.org/10.32604/cmescs.2024.049281>.
- WILLIAMS, John A. Wear and wear particles—some fundamentals. **Tribology International**, [s. l.], v. 38, n. 10, p. 863–870, out. 2005. <https://doi.org/10.1016/j.triboint.2005.03.007>.