

# PREDIÇÃO DA VIDA ÚTIL RESIDUAL DE UM EQUIPAMENTO ROTATIVO COM A UTILIZAÇÃO DE MACHINE LEARNING

Tássio Carvalho<sup>1</sup>; Alex Alisson<sup>2</sup>; Erick Sperandio<sup>3</sup>

<sup>1</sup>Bolsista no Centro Universitário SENAI CIMATEC SENAI / CIMATEC programa GETEC; tassio.mec@gmail.com

<sup>2</sup>Doutor em Energia e Ambiente; Centro Universitário SENAI CIMATEC; Salvador-BA; alex.santos@fieb.org.br

<sup>3</sup>Doutor em Engenharia Ambiental; Centro Universitário SENAI CIMATEC; Salvador-BA; erick.sperandio@fieb.org.br

## RESUMO

A predição da vida útil residual de equipamentos rotativos compõe um dos principais desafios da manutenção inteligente. O prognóstico deste indicador proporciona tomadas de decisões mais assertivas por parte dos gestores, sobretudo quanto ao melhor momento de intervenção, contribuindo para uma manutenção mais otimizada e de baixo custo. Diante do desenvolvimento dos dispositivos computacionais, as técnicas de aprendizagem de máquina têm emergido como promissoras para o desenvolvimento de predições da vida útil residual com um desempenho superior em relação a técnicas tradicionais de predição. Nesse sentido, este trabalho apresenta uma implementação baseada em conceitos de redes neurais artificiais e de algoritmos genéticos para a criação de um modelo capaz de prever a vida útil residual de um equipamento. Ainda que as estimativas para os períodos de degradação necessitem ser aprimorados, os resultados preliminares mostram que o método proposto fornece previsões mais assertivas para os momentos de comportamento normal de operação.

**PALAVRAS-CHAVE:** Predição, Vida Útil Residual, Dados Sintéticos, Machine Learning.

## 1. INTRODUÇÃO

A manutenção baseada na condição (MBC) proporciona uma operação mais confiável e segura de sistemas, portanto, tornou-se uma ferramenta indispensável na indústria moderna (BERMEJO et al., 2019). A estratégia da MBC baseia-se na averiguação contínua das condições do equipamento, buscando indícios de degradação que poderão acarretar falhas. Dessa forma, o modelo MBC pode contribuir em decisões no que tange ao momento ótimo de intervenção. Portanto, esse método avançado costuma ser chamado de manutenção preditiva, que pode ser vista como um aprimoramento da manutenção preventiva.

Em outras palavras a manutenção preditiva, através de um monitoramento sistemático e contínuo, sempre estará buscando formas de estimar a vida útil. A manutenção preditiva apresenta uma série de benefícios, como por exemplo: uso otimizado de peças, custos reduzidos, aumento da vida útil do equipamento, segurança da planta, impactos positivos na qualidade do produto (fabricação de falha quase zero) e número reduzido de acidentes (LEE et al., 2013). Entretanto, ainda há limitações inerentes as tecnologias da manutenção preditiva como: desafios na implementação do sistema da empresa devido aos requisitos de integração das diversas tecnologias da Indústria 4.0 (LEE; KAO; YANG, 2014), em que os principais desafios são: (i) processamento de grandes repositórios de dados de séries temporais (provenientes de sensores instalados nos equipamentos) e (ii) design de um modelo preditivo que, a partir de um grande volume de dados processados, possa estimar e executar uma tomada de decisão eficaz em um curto espaço de tempo, conforme a condição do equipamento. Além disso, o modelo preditivo deve ser capaz de desenvolver novos aprendizados perante a novas informações que podem ser recém adquiridos, desta forma, os modelos poderão generalizar as soluções para as adversidades futuras.

Entre os indicadores da manutenção preditiva, a previsão da vida útil remanescente (VUR) desempenha um papel importante no prognóstico e gestão da condição dos equipamentos. Com base nas previsões os gerentes de manutenção conseguem avaliar o momento ótimo de intervenção, garantindo uma boa produtividade a um baixo custo da manutenção, uma vez que as paradas de emergência são reduzidas.

Para alcançar o objetivo proposto, em um primeiro momento, a pesquisa foca em uma abordagem baseada em dados, especialmente para dispositivos com baixo histórico de dados rotulados, onde normalmente são dispostos como: comportamento normal, pré-falha e falha. Na ausência de dados, é necessário construir um mecanismo que permita sintetizar séries temporais para simular o comportamento operacional do dispositivo em diferentes estágios para diferentes situações que possam ocorrer.

## 2. METODOLOGIA

Toda a pesquisa desenvolvida neste trabalho teve sua origem na análise dos históricos de vibração de um equipamento de testes localizado na Universidade de Cincinnati. O equipamento em questão opera com uma rotação constante de 2000 RPM. O acionamento do sistema é dado por um motor de corrente alternada, onde a

transmissão da força motriz é proporcionada por uma correia. O eixo rotativo do equipamento está suportado por 4 rolamentos do tipo Rexnord ZA-2115. Uma carga de 6000 lb é aplicada nos dois rolamentos centrais, através de um sistema de pressão promovido por um conjunto de molas. As coletas dos dados de vibração foram executadas até o rolamento apresentar uma quantidade de detrito correspondente a uma situação de falha. Porém, todos os rolamentos conseguiram exceder o tempo projetado de vida útil, dado que, todos os rolamentos superaram a marca de 100 milhões e revoluções.

Para a presente pesquisa, o conjunto de dados utilizado corresponde ao período de 4 de março até 4 de abril. Todos os 6234 arquivos que estão presente no pacote do experimento 3 apresenta dados discretizados no domínio do tempo. Cada arquivo contém 20.480 pontos que correspondem ao valor pontual de vibração no tempo. Os dados foram coletados através da plataforma da National NI DAQ Card 6062E com uma taxa de amostragem definida em 20 kHz e com o uso do acelerômetro PCB 353B33do.

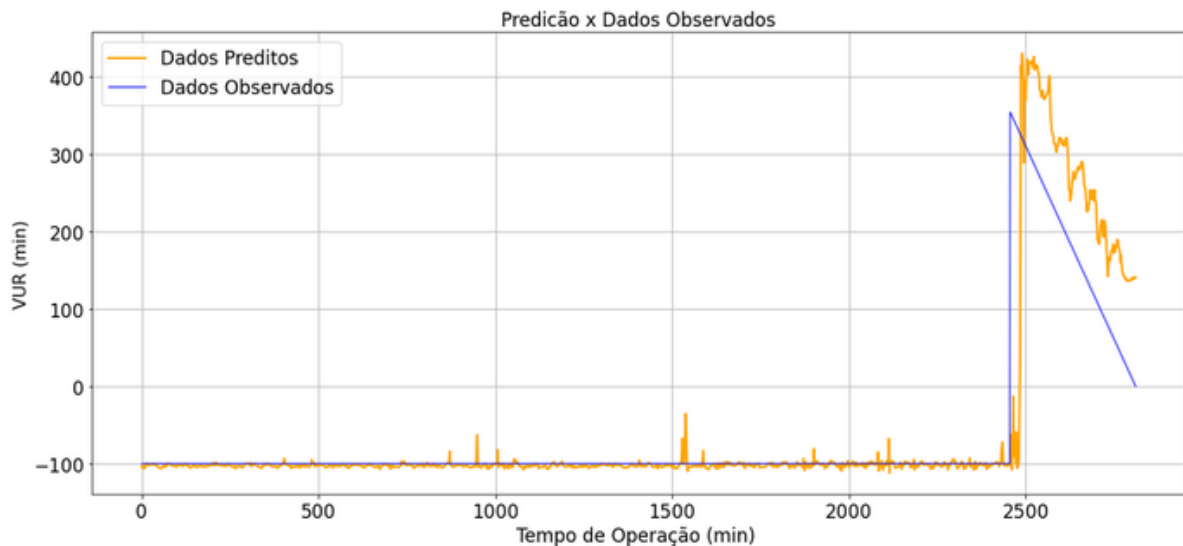
A construção dos dados sintéticos é baseada na combinação das características extraídas pela decomposição das séries. A generalização se dá pelas combinações aleatórias da variação do grau do polinômio que fora ajustado na tendência e com dados provenientes da distribuição do ruído encontrado.

A rede neural utilizada para alcançar o objetivo desta pesquisa é totalmente baseada no modelo de recorrência de sinais. Dentro desta família existem diversas arquiteturas, mas para a execução dos testes preliminares, a arquitetura *Long Short Term Memory* (LSTM) foi a selecionada.

### 3. RESULTADOS E DISCUSSÃO

Com a conclusão da elaboração do modelo preditivo, verifica-se o resultado preliminar através de método qualitativo (inspeção visual do gráfico) e quantitativos (verificação das métricas de qualidade). Visualmente as previsões foram capazes de se adequar aos momentos de operação normal, tal como o momento de transição do comportamento normal para o degradante. Por outro lado, o modelo não foi capaz de apresentar uma boa aderência para o período de degradação pura como mostra a Figura 01. O valor de -100 é a representação digital para o comportamento normal do rolamento, ou seja, para esses momentos, o valor da vida útil residual tende ao infinito.

Figura 1 - Predição do VUR



As verificações da qualidade da predição foram feitas através do uso de métricas de qualidade, bem como: *Mean Squared Error* (MSE), *Root Mean Square Error* (RMSE), *Mean Absolut Error* (MAE), Coeficiente de Determinação ( $r^2$ ) e Fator de 2 (Fac2), como mostra o Quadro 1.

Quadro 2 - Métricas de Avaliação do Modelo

Mean Squared Error	Root Mean Squared Error	Mean Absolut Error	$r^2$	Fator de 2
3291.5885037	57.3723671	19.7763168	0.6658911	0.9491465

#### 4. CONSIDERAÇÕES FINAIS

O modelo preliminar proposto nesta pesquisa apresenta características promissoras, porém existem pontos que precisam ser aprimorados, principalmente no que tange a Rede Neural Artificial.

A rede recorrente foi capaz de apresentar uma boa capacidade de predição para o período em que o rolamento apresentava comportamento normal. Essa capacidade é atribuída ao grande volume de informações com essa característica, já que, inevitavelmente, todos os rolamentos apresentam essa condição de forma idêntica. Em contrapartida, a baixa variedade de comportamentos degradantes apresenta-se como o maior causador da baixa aderência para os momentos de degradação, conseqüentemente reduzindo as métricas de avaliação. De todo modo, a medida corretiva que será testada nos próximos desenvolvimentos é o aumento no número de séries nos dados sintéticos, por outro lado, o custo de processamento pode aumentar consideravelmente, sendo necessário recorrer ao Supercomputador presente no SENAI / CIMATEC para o desenvolvimento dessa atividade.

Outro ponto importante é a necessidade de testes preditivos com redes neurais convolucionais, já que esses foram bem citados na revisão sistemática de literatura. Essas redes aprestaram resultados significativos na predição da VUR bem como a LSTM.

Atendendo as hipóteses aqui expostas, espera-se que o modelo final atenda, com maior rigor e exatidão os objetivos propostos inicialmente para essa pesquisa.

#### 5. REFERÊNCIAS

<sup>1</sup> BERMEJO, Jesús Ferrero et al. Review And Comparison Of Intelligent Optimization Modelling Techniques For Energy Forecasting And Condition-Based Maintenance In PV Plants. **Energies**, v. 12, n. 21, 2019.

<sup>2</sup> LEE, Jay et al. Predictive Manufacturing System: Trends of Next-Generation Production Systems. **IFAC Proceedings Volumes**, v. 46, n. 7, p. 150-156, 2013.

<sup>3</sup> LEE, Jay; KAO, Hung-An; YANG, Shanhu. Service innovation and smart analytics for Industry 4.0 and big data environment. **Procedia CIRP**, v. 16, p. 3-8, 2014.