

ESTUDO COMPARATIVO DA PREDIÇÃO DA VIBRAÇÃO GLOBAL DE UM EQUIPAMENTO ROTATIVO UTILIZANDO SUAUIZACÃO EXPONENCIAL SIMPLES E REDE NEURAL RECORRENTE

Tássio Carvalho¹; Alex Alisson²; Ubatan Miranda³; Erick Sperandio⁴

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

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

³Mestre em Engenharia Mecânica; Centro Universitário SENAI CIMATEC; Salvador-BA;
ubatan.miranda@fieb.org.br

⁴Doutor em Engenharia Ambiental; Centro Universitário SENAI CIMATEC; Salvador-BA;
erick.sperandio@fieb.org.br

RESUMO

Eventualmente equipamentos mecânicos apresentam defeitos que evoluem gradativamente durante a sua vida útil. Em alguns casos essas falhas podem apresentar rápida progressão, não dando tempo para a equipe de manutenção executar um bom planejamento, consequentemente elevando o custo da manutenção corretiva. Com o objetivo de prever o instante em que irá ocorrer essas falhas a presente pesquisa busca estimar a vibração global para o dia seguinte de um equipamento rotativo, auxiliando aos gestores da manutenção em tomadas de decisões quanto ao melhor momento de intervenção. Por meio dos valores globais de vibração extraídos do banco de dados de análises espectrais foi possível montar uma série temporal que relaciona a vibração global para cada dia de operação. Com o suporte de algoritmos computacionais, aplicam-se duas técnicas, sendo elas: a suavização exponencial e a rede neural recorrente. Ao término da execução foi possível concluir que a RNN apresentou as melhores estimativas.

PALAVRAS-CHAVE: Rede Neural Recorrente, Vibração Global, Suavização Exponencial Simples, Predição.

1. INTRODUÇÃO

Ao longo do tempo a demanda por bens industriais vem apresentando ritmo crescente. Segundo o Instituto de Pesquisas Econômicas Aplicadas – IPEA a demanda por bens industriais apresentou uma taxa de variação de crescimento acumulada de 5,1%. Frente a esse aumento as empresas precisam extrair o máximo dos seus equipamentos, consequentemente necessitando de uma operação prolongada, automatizada e confiável.

Tendo a finalidade de tornar essas necessidades citadas realidade, a manutenção preditiva oferece ferramentas para o gerenciamento da condição do equipamento. Em outras palavras a manutenção preditiva, através de um monitoramento sistemático e contínuo, sempre estará buscando formas de estimar a vida útil.

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. "A manutenção preditiva consiste, então, na coleta de dados com relação às variáveis de interesse, comparar tais dados em função do tempo de funcionamento e interpretar tais variações e informações visando interferir no momento adequado, [...]" (NEPOMUCENO, 2013, p. 153).

Existem diversas metodologias que são utilizadas na manutenção preditiva para a verificação da condição do equipamento, sendo uma das mais empregadas a análise de vibração mecânica. Através desta apuração é possível fazer um diagnóstico de falha por meio das assinaturas espectrais ou até mesmo a previsão de falhas pela composição da curva de tendência da vibração global. Esse último apresenta a evolução dos níveis de vibração ao longo do tempo caracterizando uma série temporal. A curva de tendência não indica qual o modelo de falha irá ocorrer, em contrapartida, ela pode auxiliar na previsão da severidade da falha.

Para alcançar o objetivo proposto, em um primeiro momento, a pesquisa limitou-se a estimar a vibração global um dia a frente dos dados observados através de duas técnicas como: Rede Neural Recorrente e a Suavização Exponencial Simples como a primeira etapa da pesquisa.

A primeira etapa culmina na comparação dos ajustes e dos resultados obtidos com o intuito de verificar qual das técnicas apresentaram o menor erro, ou seja, qual das técnicas foram mais adequadas para representar o comportamento um dia a frente dos dados observados.

2. METODOLOGIA

As predições desenvolvidas neste estudo tomam como base o acompanhamento feito em um equipamento rotativo que conta com 28 sensores distribuídos em 8 partes do sistema. Os dados foram coletados no domínio do tempo, mas após a aplicação da Fast Fourier Transform – FFT os dados são discretizados em um conjunto de senoides passando para o domínio da frequência.

Grande parte das informações deste equipamento é sigilosa, uma vez que faz parte de uma doação de uma empresa anônima. Todos os dados utilizados neste estudo e outras informações estão sob o domínio da empresa KNIME.

O banco de dados escolhido A-1__1012 EA1,5kHz0,5-12kHz é oriundo do sinal do sensor presente no eixo de entrada vertical e abrange um intervalo de tempo que vai de janeiro de 2007 até abril de 2009. São cerca de 9,3 milhões de linhas de dados contendo a data e hora da coleta, a frequência em Hertz e por último a amplitude, do qual não foi indicado a unidade. Deste modo será considerado neste estudo uma unidade fictícia denominada Unidade de Vibração e será aplicada para todas as avaliações e cálculos.

Serão extraídos somente os dados de vibração em RMS do período que vai de janeiro até junho de 2007, de modo a reduzir o tempo de processamento das redes neurais. Dentro deste intervalo de tempo são considerados até a data de 17 de abril como os dados de treinamento para a rede executar o seu aprendizado. Entre o período de 18 de abril e 12 de maio, os dados são utilizados para testes, verificando a capacidade de previsão após o treinamento.

Como foi citado anteriormente o maior interesse deste primeiro momento de pesquisa é predizer os valores da vibração global do equipamento em questão. Portanto alguns algoritmos foram gerados na seguinte ordem:

- Desenvolvimento de algoritmo em Python com a adição da biblioteca Pandas para leitura e extração dos valores em RMS dos espectros presentes no banco de dados;
- Elaboração do Algoritmo em R com a utilização do pacote imputeTS⁵ e Forecast;
- A rede neural foi desenvolvida em linguagem Python com a utilização das bibliotecas Keras, Pandas e Numpy.

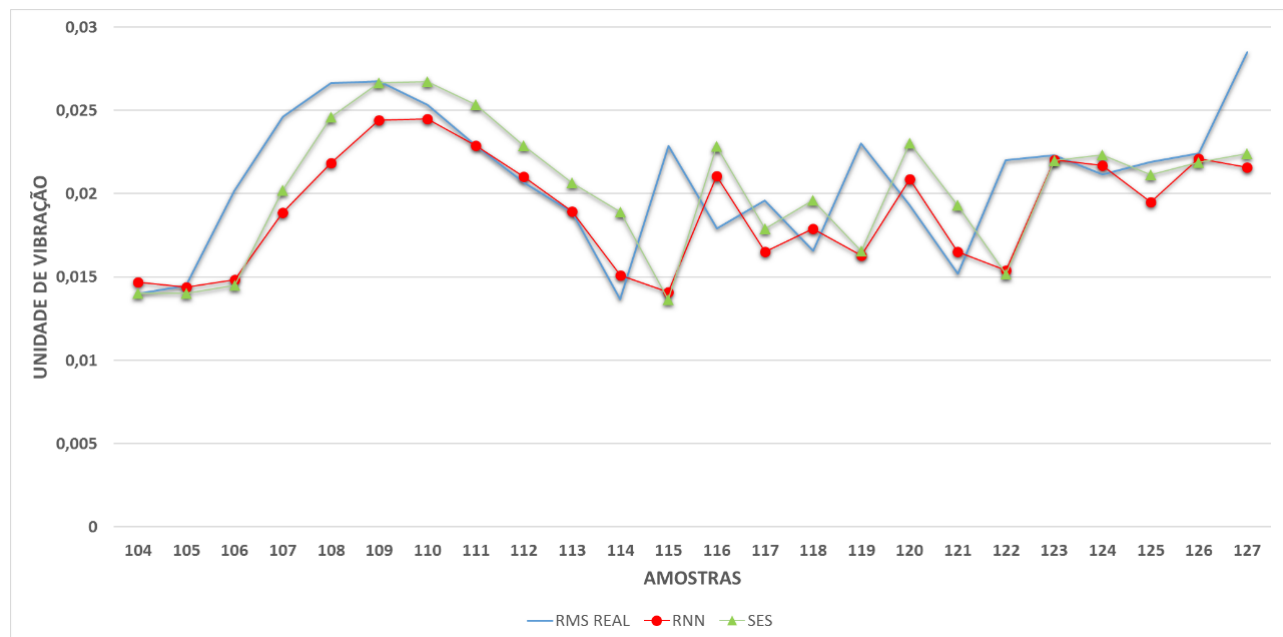
3. RESULTADOS E DISCUSSÃO

Com a elaboração dos modelos preditivos concluídos, verifica-se qual dos métodos obteve a melhor capacidade de predição para cada nova observação recebida. A comparação do ajuste de cada modelo é feita através da verificação da raiz quadrada do erro médio quadrático das previsões. Esse procedimento matemático também é conhecido como *root mean square error* - RMSE.

Verificando somente os dados das observações que foram consideradas para o teste, a suavização exponencial teve como resultado um RMSE de 0,00390. Por outro lado, a rede neural recorrente apresentou um RMSE de 0,00375 desta forma a rede neural recorrente apresentou uma discreta superioridade em suas previsões, justamente por apresentar um RMSE menor que a proporcionada pela suavização exponencial.

As duas metodologias de predição da vibração global de um dia à frente dos dados observados apresentaram gráficos semelhantes. Em compensação, nas predições compreendidas pelos intervalos das amostras 111 até o 114 e do 118 até o 121 a RNN apresentou um ajuste superior. Com o gráfico de dispersão fica mais fácil de perceber a capacidade de predição de cada método. Quanto mais próximo os pontos estiverem do RMS real, melhor.

Gráfico 1 - Comparativo da capacidade dos modelos preditivos



4. CONSIDERAÇÕES FINAIS

As respostas dos modelos de predição citadas anteriormente foram capazes de prever com acurácia semelhante o comportamento vibracional do equipamento. Esse comportamento preditivo é resultado do não crescimento da série, ou seja, a vibração não apresentou uma tendência em seus dados. Tanto a rede neural como a suavização exponencial foram desenvolvidas em um conjunto de dados estacionários. Caso a evolução da vibração apresentasse uma tendência, seja ela ascendente ou descendente, os modelos apresentariam previsões cada vez mais distantes das observações reais. Desta forma, se torna necessário o monitoramento contínuo, verificando o crescimento nos erros das previsões. Uma vez constatada discrepâncias nas estimativas um novo modelo de suavização ou de rede neural deve ser desenvolvido e avaliado.

Do ponto de vista da manutenção preditiva, não é possível indicar a condição do equipamento, já que a unidade que representa a amplitude de vibração é fictícia. Caso houvesse uma unidade real, a comparação poderia ser feita através da avaliação dos valores preditos com a tabela B.1 da norma ISO – 10816.

Vale lembrar que a capacidade de previsão de um dia a frente dos dados observados ainda não apresenta uma contribuição significativa para o planejamento da manutenção, mas esse tipo de estimativa são os primeiros passos de uma pesquisa que visa a previsão de um horizonte mais amplo. Em outras palavras, a pesquisa tem o intuito da predição da vida residual de um equipamento rotativo com acurácia relevante.

5. REFERÊNCIAS

- ¹ COSTA, P. G. et al. **Análise de Séries Temporais em R: Curso Introdutório**. 1. ed. Rio de Janeiro: ELSEVIER, 2018. (195).
- ² HAYKIN, S. **Redes Neurais Princípios e Práticas**. 2. ed. Hamilton: Bookman, 1999. 894 p
- ³ LUGER, G. F. **Inteligência Artificial**. 6. ed. [S.l.]: Pearson, 2014. 614 p.
- ⁴ MANTOVANI, W. A. **Utilização de Redes Neurais Recorrentes na Caracterização de Cargas Não Lineares em Sistemas Elétricos**. 2011. 73 p. Dissertação (Mestrado em Engenharia Elétrica) — UNESP.
- ⁵ MORITZ, S.; BEIELSTEIN, T. B. **imputeTS: Time Series Missing Value Imputation in R**. The R Journal, v. 9, p. 207 – 218, junho 2017. ISSN 2073-4859
- ⁶ TOLOI, C. M. C.; MORETIN, P. A. **Análise de Séries Temporais**. 2. ed. São Paulo: Blücher, 2006.
- ⁷ INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO - 10816: Mechanical Vibration - Evaluation of machine Vibration by measurements on non-rotating Parts - Part 1**. 1 ed. Genebra, 1995. 23 p.