



Previsão de falha por fadiga em aços

Sérgio Felipe Damasceno Santos Barbosa

Universidade do Vale do São Francisco

(sergio.felipedamasceno@discente.univasf.edu.br)

Thiago Magalhães Amaral

Universidade do Vale do São Francisco

(thiago.magalhaes@univasf.edu.br)

CONTEXTUALIZAÇÃO: A fadiga no aço é um problema bastante presente na área da engenharia, segundo Shi et al. (2024), 70% a 80% dos acidentes estruturais que envolvem equipamentos mecânicos são causados pela fadiga. Logo, surge uma maior preocupação a respeito desse fenômeno, principalmente no desenvolvimento de projetos mecânicos e em programas de manutenção. Quando um material está submetido a cargas cíclicas pode vir a falhar por fadiga, para materiais como o aço o seu ciclo é definido por volta de 10^7 (Dantas et al., 2022), a fadiga representa um grande desafio para a segurança e a confiabilidade de sistemas industriais, automotivos e em suas infraestruturas. Nesse contexto, a mineração de dados surge como uma ferramenta para a análise de suas propriedades, permitindo identificar relações entre diferentes variáveis que afetam a fadiga. Estudos recentes de Movaffaq e Sahar (2025) avaliaram e mostraram a eficiência da aplicação do machine learning para previsão de propriedades mecânicas dos aços, utilizando o random forest como o seu modelo principal. Já em outro estudo feito por Konda et al. (2022), mostraram o modelo kNN como uma possível forma de prever a fadiga.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

OBJETIVO: Estabelecer uma relação entre a falha por fadiga e outras variáveis, a fim de entender quais fatores interferem mais neste fenômeno e criar um modelo capaz de prever o comportamento com base nas suas características.

MÉTODO: Foi usada a base de dados “Steel Fatigue Strength Prediction” desenvolvida por: Ankit Agrawal et al. (2014), contendo variáveis como composição química, detalhes de processamento upstream, condições de tratamento térmico e propriedades mecânicas. Foi utilizado o software Orange para desenvolver um modelo capaz de auxiliar na tomada de decisão. Foram realizados no pipeline a limpeza de dados, por meio de normalização/padronização colocando todas as variáveis na mesma escala, e por meio do ganho de informação filtrando as características que identificam quais variáveis influenciam mais o target principal (fadiga). Testes dos modelos foram realizados para identificar qual prevê melhor o comportamento da fadiga, foram eles kNN com vizinhanças de 3, 5 e 7, e o outro modelo foi Random Forest que é baseado em árvores de decisões para prever de forma precisa. Já para avaliação das métricas utilizadas foram disponibilizados os seguintes critérios: MSE (erro quadrático médio), RMSE (erro quadrático médio), MAE (erro médio absoluto), MAPE (erro percentual médio absoluto), R^2 (Coeficiente de Determinação), com eles foi possível analisar qual dos modelos é o mais indicado para o projeto. Um gráfico de dispersão (scatter plot) acompanhado de uma linha de regressão, foi utilizado para visualizar o quanto os valores previstos dos modelos se aproximam dos resultados do alvo (target). E como parte final a interpretação dos resultados baseados no que foi obtido nos modelos, os principais fatores que interferem no alvo principal (fadiga) e a viabilidade da aplicação ou não do projeto. A ferramenta correlação foi utilizada para visualizar quais variáveis afetam mais o valor final do target, onde nessa ferramenta os resultados de correlação estão entre um intervalo de -1 até +1, se for negativo a variável afeta de modo a diminuir o valor final do meu target, sendo positivo, contribui a aumentar o valor do mesmo, e se for 0 eles não têm relação.

RESULTADOS E DISCUSSÕES: Após a avaliação dos modelos identificou-se que o modelo mais eficiente foi o kNN(2), atingindo métricas superiores tanto no R^2 , MSE e RMSE, indicando bem o quanto o modelo explica a variação de dados, apresentando alta

precisão e prevendo valores mais próximos do real. Ao utilizar o Scatter Plot, uma ferramenta que utiliza duas variáveis e as relaciona através de pontos em um gráfico, foi adicionada uma linha de regressão nos modelos, indicando assim uma alta precisão nos resultados encontrados para o kNN(2), que obteve com o seu r (linha de regressão) o valor de 0.97. Para uma linha de regressão quanto mais próximo de 1 será o ideal, foi percebido que tanto o Random Forest quanto o kNN(2) atingiram a mesma marca de $r=0.97$, porém avaliando as outras métricas citadas, o kNN(2) seria o indicado para prever uma possível falha por fadiga. Com a pesquisa feita foi possível identificar que os fatores que mais afetam a falha por fadiga dos aços, através da ferramenta correlação, são fatores ligados a processos de tratamentos térmicos como o Tt(Tempo de têmpera), CT(Temperatura de carbonização) e DT (Temperatura de difusão).

CONSIDERAÇÕES FINAIS: O estudo evidenciou que a aplicação de métodos de mineração de dados, se mostrou uma abordagem eficaz para analisar e prever o comportamento da fadiga em aços. Entre os modelos testados, o kNN(2) apresentou o melhor desempenho em comparação aos outros modelos, com os menores valores de MSE, RMSE, além do maior valor de R^2 e da linha de regressão, indicando alta precisão na previsão da vida útil dos aços. A análise permitiu também identificar as variáveis mais influentes no fenômeno da fadiga, contribuindo para uma melhor compreensão dos fatores que afetam a durabilidade dos aços. Esses resultados demonstram que a integração entre a mineração de dados e a engenharia pode antecipar falhas e orientar decisões mais seguras em projetos mecânicos e em etapas de manutenção. Logo, a metodologia apresentada mostra-se promissora na previsão de fadiga, capaz de otimizar processos e aumentar a confiabilidade de estruturas metálicas submetidas a esforços cíclicos. O estudo serve como base para a maior compreensão sobre esse comportamento em aços, concedendo espaço para pesquisas futuras que possam envolver outros tipos de materiais.

PALAVRAS-CHAVE: Fadiga, aços, mineração de dados, tratamentos térmicos, previsão, manutenção, kNN, random forest.

REFERÊNCIAS



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

AGRAWAL, Ankit et al. **Exploration of data science techniques to predict fatigue strength of steel from composition and processing parameters.** v. 3, n. 8, p. 1–19, 2014. DOI: 10.1186/2193-9772-3-8.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees.** Monterey, CA: Wadsworth and Brooks, 1984.

DANTAS, Rita. **Very high cycle fatigue behaviour of S690 structural steel.** *Materials Today: Proceedings*, v. 50, p. 1236–1241, 2022. DOI: 10.1016/j.matpr.2021.06.581. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2452321622007685> Acesso em: 16 out. 2025.

DERR, L.; et al. **Orange: Data Mining Toolbox in Python.** [Software]. Disponível em: <https://orangedatamining.com>. Acesso em: 26 set. 2025.

KATEB, M.; SAFARIAN, S. **Machine learning-driven predictive modeling of mechanical properties in diverse steels.** *Machine Learning with Applications*, p. 100634, fev. 2025.

KONDA, Nithin; VERMA, Raviraj; JAYAGANTHAN, Rengaswamy. **Machine learning based predictions of fatigue crack growth rate of additively manufactured Ti6Al4V.** *Metals*, v. 12, n. 1, p. 50, 2022. DOI: 10.3390/met12010050. Disponível em: <https://www.mdpi.com/2075-4701/12/1/50>. Acesso em: 15 out. 2025.

MOHAMMED, M. M. **Fundamental Drivers of Metal Fatigue Failure and Performance.** *Multidisciplinary Materials Chronicles*, v. 1, n. 1, p. 49–61, 2024. DOI: 10.62184/mmc.jmmc110020245.

SHI, Shengrun; YAO, Dengzun; WU, Guiyi; CHEN, Hui; ZHANG, Shuyan. Characterization of fatigue damage in Hadfield steel using acoustic emission and machine learning-based methods. *Sensors*, v. 24, n. 1, p. 275, 2024. DOI: 10.3390/s24010275. Disponível em: <https://www.mdpi.com/1424-8220/24/1/275>. Acesso em: 16 out. 2025.

UNITED STATES NAVAL ACADEMY. **Chapter 12 – Fatigue: Fatigue failure of materials.** *Course Notes EN380*, [s.l.], 2018. Disponível em: https://www.usna.edu/NAOE/_files/documents/Courses/EN380/Course_Notes/Ch12_Fatigue.pdf. Acesso em: 15 out. 2025.

ZHUANG, Chao. **Steel Fatigue Strength Prediction.** 2023. Disponível em: <https://www.kaggle.com/datasets/chaozhuang/steel-fatigue-strength-prediction/data>. Acesso em: 26 set. 2025.