



Inteligência Artificial Aplicada ao Monitoramento da Integridade Estrutural de Pontes

João Pedro Santos Cordeiro;
Adam Dreyton Ferreira dos Santos

Agência financiadora: CNPq

Resumo: O assunto abordado neste trabalho, visa uma melhor visualização em torno da utilização de algoritmos de aprendizado de máquina em conjunto com o monitoramento de integridade estrutural (SHM), utilizando a base de dados da ponte Z-24.

Palavras chave: Monitoramento, Inteligência, Clusterização.

1. INTRODUÇÃO

A implementação de sistemas Monitoramento de Integridade Estrutural (SHM) para monitoramento estrutural tem se destacado nas últimas décadas como um método promissor para gerenciamento de estruturas, de forma a mantê-las seguras e consequentemente duráveis. A utilização de SHM permite identificar danos presentes na estrutura de forma autônoma (FIGUEIREDO et al, 2013 apud ARAUJO, 2017, p. 12), o que representa uma vantagem em relação a sistemas baseados em inspeções visuais, por substituir manutenções programadas por manutenções necessárias, diminuindo a necessidade de interrupções das atividades inerentes a estrutura, ocasionando gargalos na produção em grandes indústrias e em companhias prestadoras de serviços (MAIO, 2010 apud ARAUJO, 2017, p. 12), por exemplo.

Segundo Farrar, Worden 2013 (apud ARAUJO, 2017, p. 12) e Santos et al, 2015 (apud ARAUJO, 2017, p. 12) a SHM é referido na literatura como um processo de implementação de uma estratégia de detecção de danos em estruturas capazes de medir em tempo real, por meio de sensores acoplados a estas, as repostas estruturais, com intuito de identificar danos ainda em estágio inicial. As informações obtidas a partir do monitoramento realizado pelos sensores são geralmente usadas para planejar e projetar atividades de manutenção, aumentar a segurança, verificar hipóteses, reduzir incertezas e ampliar o conhecimento sobre a estrutura que está sendo monitorada (GLISIC; INAUDI, 2007 apud RODRIGUES, 2016, p. 13).

Um problema bastante pertinente na SHM é a variabilidades ambientais e operacionais que podem afetar a coleta dos dados que podem afetar significativamente as indicações de dano na estrutura. Segundo Araujo (2017), se não forem levadas em conta no processo de detecção de danos, tais mudanças nas características de resposta dinâmica podem resultar em falsas indicações de dano.

Uma abordagem bastante consistente para lidar com o problema de variabilidades ambientais e operacionais é a aplicação de algoritmos de aprendizado de máquina, que segundo Araujo (2017), tem o intuito de desenvolver modelos capazes de representar o estado normal da estrutura, mesmo sob efeitos ambientais e operacionais extremos.

Levando em consideração algoritmos de aprendizado de máquina utilizaremos três algoritmos de clusterização:

- **K-Means:** Que segundo Alsabti et al., 1998 (apud ARAUJO, 2017, p. 27), um algoritmo de clusterização, que agrupa um conjunto de dados em K partições, representadas cada uma por um centróide, que é a média dos pontos pertencentes a partição.
- **MeanShift:** O Mean Shift é um método não supervisionado e não paramétrico para estimar o gradiente de uma função de probabilidade, tendo dados amostrados (CHENG, 1995). Esse algoritmo tem como característica o fato de não haver necessidade de ter conhecimento antecipado dos números de clusters.
- **DBSCAN:** O DBSCAN segundo Ester et al., 1996 (apud ARAUJO, 2017, p. 15), tem sua abordagem baseada na densidade espacial dos dados. O agrupamento baseado em densidade localiza regiões de alta densidade que são separadas umas das outras por regiões de baixa densidade.

Os algoritmos de clusterização possuem uma característica bastante importante que consiste na descoberta automática de condições de estado normal ou não de uma determinada estrutura. E é nessa característica que o trabalharemos no artigo, visando a comparação entre esses três algoritmos através da base de dados da ponte Z-24 obtida em um ambiente não controlado.

O principal objetivo do artigo é avaliar o desempenho dos algoritmos abordados, através da comparação com enfoque na menor quantidade de erros tipo I e tipo II além do menor número total de erros.

2. MATERIAL E MÉTODOS

A linguagem de programação Python em conjunto com a Scikit-learn que por sua vez fornece a implementação de muitos algoritmos de aprendizado de máquina perfeitamente integrada à linguagem Python, formam a metodologia usada no projeto.

A ponte Z-24, antes de sua demolição foi submetida a uma série de testes com objetivo de fornecer uma base de dados retirada de um ambiente real que hoje é amplamente utilizada para testes de algoritmos de aprendizado de máquina. Essa base de dados foi obtida em um período de cerca de um ano. Os dados de treino com dimensão (198 X 2) e os dados testes de dimensão (235 X 2) formam a base de dados da ponte Z-24. Dados de treino são dados na condição normal da estrutura, já os de teste englobam tanto os dados de condição normal, quanto dados de condição anormal da estrutura.

E para a avaliação dos resultados os erros tipo I e II formam a base para o julgamento desses algoritmos afim de informar qual o melhor resultado obtido. Os erros tipo I são ditos quando os pontos no gráfico estão acima do threshold e pertencem aos dados de treino e. Já os erros tipo II são ditos quando os pontos no gráfico estão abaixo do threshold e pertencem aos dados de teste e de condição anormal da estrutura.

3. RESULTADOS E DISCUSSÃO

As figuras a seguir mostram os resultados obtidos durante a execução dos algoritmos de aprendizado de máquina. A Figura 1 mostra a execução dos três algoritmos usados, KMeans (A), MeanShift (B) e DBSCAN (C).

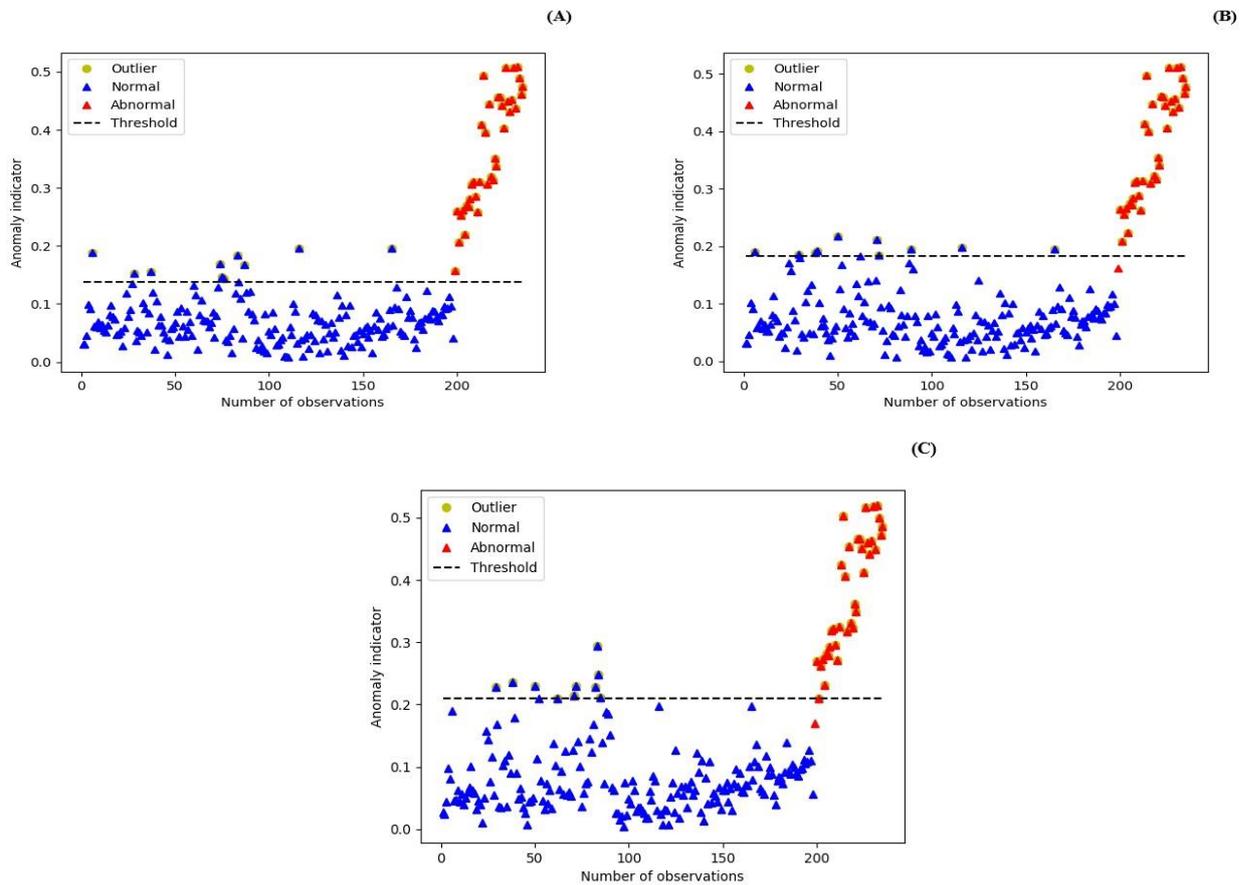


Figura 1- K-Means (A), MeanShift (B) e DBSCAN (C)

Em termos de erros tipo I, todos os algoritmos apresentaram a mesma quantidade, ou seja, 10 (5.05%) de erros. Já em termos de erro II o K-Means (A) conseguiu se sair melhor entre os demais algoritmos, pois conseguiu 0% de erros tipo II, enquanto o MeanShift (B) e o DBSCAN (C), ambos identificaram 1 (2.70%) de erros tipo II e no total de erros também obtiveram as mesmas quantidades. Portanto, podemos dizer que ambos os algoritmos trabalharam de forma eficiente de acordo com os resultados obtidos, com baixos números de erros, com o K-Means (A) se saindo um pouco melhor dentre os outros dois algoritmos pois identificou 0% de erros tipo II e um erro a menos no número total de erros.

4. CONCLUSÃO

A SHM como método de auxílio no processo de monitoramento de pontes ou de qualquer outra estrutura sujeita a anomalias na sua integridade estrutural, vem se tornando amplamente utilizada pois proporciona rapidez, eficiência e segurança na detecção de danos de estruturas que precisam estar em constante monitoramento.

Dentre os algoritmos de clusterização que permitem a criação de modelos capazes de lidar com o problema de variabilidades ambientais e operacionais, os algoritmos de clusterização K-Means, MeanShift e DBSCAN mostraram desempenho satisfatórios com base nos resultados obtidos. Porém o KMeans manteve resultados melhores em relação aos outros dois algoritmos.

Portanto, devemos destacar a importância dessa abordagem baseada na utilização de algoritmos de aprendizado de máquina, pois sua utilização é bastante simples e acessível para a detecção de danos em estruturas além de fornecer uma ampla variedade de algoritmos de clusterização para a utilização e realização de pesquisas com enfoque na SHM.

5. REFERÊNCIAS E CITAÇÕES

ARAÚJO, Alessandra P. **Aplicação de algoritmo de clusterização na detecção de danos estruturais**. Monografia (Bacharel em Ciências da Computação). 59p. Belém. UFPA, 2017.

CHENG, Yizong. Mean shift, mode seeking, and clustering. **IEEE transactions on pattern analysis and machine intelligence**, v. 17, n. 8, p. 790-799, 1995.

RODRIGUES, Caio Marcos Flexa. **Aplicação de Algoritmos Baseados em Análise de Componentes Principais para Normalização de Dados em Monitoramento de Integridade Estrutural**. Monografia (Bacharel em Ciências da Computação). 68p. Belém. UFPA, 2016.