

Diagnóstico Estrutural Usando Aprendizagem de Máquina e Filtragem Adaptativa

Henrique Corrêa Van Der Haegen Baptista e Eduardo Luiz Ortiz Batista

Resumo—Este trabalho é dedicado ao monitoramento de saúde de estruturas usando técnicas de aprendizagem de máquina. A principal contribuição está no uso de modelagem de sistemas por filtragem adaptativa para obtenção de atributos (*features*) a partir de sinais de vibração. Os atributos obtidos são a resposta ao impulso da estrutura sob análise e a resposta em frequência correspondente. Usando esses atributos no contexto de um processo de classificação por aprendizagem de máquina, é possível obter uma ferramenta bastante interessante para o diagnóstico de saúde de estruturas. Resultados experimentais obtidos usando um dispositivo experimental próprio são apresentados visando demonstrar a efetividade da abordagem proposta.

Palavras-Chave—Aprendizagem de máquina, filtragem adaptativa, monitoramento de saúde de estruturas, processamento de sinais.

Abstract—This work is dedicated to structural health monitoring using machine learning techniques. The main contribution is the use of system modeling via adaptive filtering to obtain attributes from vibration signals. The obtained attributes are the impulse response of the structure under analysis and the corresponding frequency response. By using these attributes in the context of a machine learning classification process, a very interesting tool for structural health diagnosis can be obtained. Experimental results obtained using a real-world experimental device are presented to demonstrate the effectiveness of the proposed approach.

Keywords—Adaptive filtering, machine learning, signal processing, structural health monitoring.

I. INTRODUÇÃO

A avaliação da integridade estrutural é um aspecto fundamental para a manutenção tanto de grandes estruturas (como edifícios, pontes e torres de transmissão) quanto de estruturas relativamente menores (como vigas, plataformas e máquinas em geral) [1], [2]. O monitoramento contínuo de tal integridade permite a detecção precoce de problemas e a implementação de medidas preventivas visando não apenas evitar que alguma falha importante ocorra, mas também manter o sistema funcionando com alto desempenho [3]. Nesse contexto, diversas técnicas de monitoramento de integridade ou saúde estrutural têm sido propostas nos últimos anos, sendo muitas delas baseadas em aprendizagem de máquina (*machine learning*) [2].

Uma das principais vantagens do uso de técnicas de aprendizagem de máquina para o monitoramento de saúde de estruturas está na capacidade de analisar grandes quantidades de dados de forma rápida, visando identificar padrões complexos que seriam difíceis de serem detectados por seres humanos

Henrique C. V. D. H. Baptista e Eduardo L. O. Batista estão vinculados ao LINSE-Laboratório de Circuitos e Processamento de Sinais do Departamento de Engenharia Elétrica e Eletrônica da Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil (e-mails: henrique.vanderhaegen@gmail.com e eduardo.batista@ufsc.br). Henrique Baptista é bolsista PIBIC na UFSC.

[2]. Essa capacidade é particularmente interessante se considerarmos o frequente uso do espectro em frequência de sinais de vibrações para o diagnóstico de saúde de estruturas [1]. Nesse caso, tem-se uma quantidade significativa de dados para cada amostra e padrões de defeitos muitas vezes ofuscados por ruído.

O presente artigo é focado no diagnóstico de saúde ou integridade estrutural usando aprendizagem de máquina e dados de sinais de vibração, tópico esse já explorado na literatura aberta [1], [2]. A novidade proposta aqui diz respeito à aplicação de filtragem adaptativa [3], [4] para auxiliar em tal diagnóstico. Mais especificamente, um processo de modelagem adaptativa de sistemas [4] é realizado visando obter um modelo representativo do funcionamento da estrutura ou sistema a ser diagnosticado. Então, esse modelo é usado para obter os atributos necessários para o treinamento de modelos de aprendizagem de máquina. Resultados experimentais obtidos a partir de um sistema experimental próprio são apresentados, visando demonstrar o potencial e as principais características da abordagem proposta.

O restante deste artigo está organizado conforme descrito a seguir. A Seção II é dedicada a uma breve discussão acerca da fundamentação teórica necessária para realização deste trabalho. Na Seção III, a abordagem proposta para o diagnóstico de saúde de estruturas é detalhada. A Seção IV é dedicada à apresentação de resultados experimentais que demonstram a qualidade da abordagem proposta e também as suas características principais. Finalmente, na Seção V, as conclusões finais são apresentadas.

II. FUNDAMENTAÇÃO TEÓRICA

Esta seção visa descrever os conceitos e técnicas utilizados como base para este trabalho. Assim, primeiramente discute-se o monitoramento de saúde de estruturas e a utilização de técnicas de aprendizagem de máquinas nesse contexto. Em seguida, a modelagem de sistemas utilizando filtragem adaptativa é brevemente discutida.

A. Monitoramento da Saúde de Estruturas Usando Aprendizagem de Máquinas

O monitoramento da saúde de estruturas (*structural health monitoring* - SHM), ou monitoramento de integridade estrutural (*structural integrity monitoring* - SIM), é uma área de pesquisa e desenvolvimento que tem emergido como provedora de soluções que permitem a transição de uma realidade de identificação de defeitos estruturais de maneira *offline* para uma realidade de monitoramento contínuo e *online* [2]. As técnicas de SHM baseiam-se no uso de sensores para aquisição contínua de diferentes tipos de dados (vibração, temperatura,

deformação, entre outros). Posteriormente, esses dados são processados e analisados visando a identificação de problemas ou anomalias. Tal análise pode ser feita usando tanto abordagens baseadas em modelos físicos realistas do sistema (análises do tipo *model-driven*) quanto abordagens baseadas puramente nos dados medidos (*data-driven*) [2]. As abordagens baseadas em modelos físicos requerem um conhecimento detalhado e uma modelagem precisa (e.g, usando modelagem por elementos finitos) de um sistema que é normalmente complexo. Consequentemente, tais abordagens apresentam maior dificuldade de implementação. Por outro lado, as abordagens baseadas em dados são mais simples de serem implementadas, requerendo porém grandes volumes de dados (e.g., históricos vastos de medidas de sensores) para obtenção de resultados satisfatórios. É no contexto das abordagens de SHM baseadas em dados que se dá a aplicação de aprendizagem de máquina [2].

As abordagens de SHM baseadas em dados envolvem normalmente um procedimento de reconhecimento de padrões, procedimento esse tipicamente realizado usando algoritmos de aprendizagem de máquina [5]. Mais especificamente, um modelo de aprendizagem de máquina, como uma rede neural artificial ou uma árvore de decisão aleatória (*random forest*), é submetido a um processo de treinamento a partir do qual tal modelo aprende a identificar padrões de defeitos para o sistema em questão. Esse processo de treinamento depende fortemente da disponibilidade de um volume de dados de treinamento suficientemente grande e representativo do funcionamento do sistema. Quando poucos dados estão disponíveis, é comum o uso de alguma forma de geração de dados sintéticos (*data augmentation*), o que pode ser feito a partir dos dados já disponíveis ou mesmo a partir de modelos físicos do sistema (abordagem híbrida baseada em dados e em modelos físicos). Por outro lado, quando há um grande volume disponível de dados rotulados de boa qualidade, as técnicas supervisionadas de aprendizagem de máquina são a opção mais direta e efetiva.

B. Modelagem de Sistemas com Filtragem Adaptativa

A modelagem de sistemas é uma das principais tarefas em filtragem adaptativa [4]. Nessa tarefa, um sistema desconhecido é estimulado com um sinal de entrada (tipicamente, um ruído branco) e o sinal obtido em sua saída é medido. A partir desses sinais de entrada e saída, um processo de otimização é realizado, resultando em um modelo matemático representativo do sistema. Tal processo de otimização é, em geral, robusto a ruídos de medição [4].

O modelo matemático mais utilizado no contexto de modelagem de sistemas usando filtragem adaptativa é o de um filtro de resposta ao impulso finita (FIR) linear. Tal modelo resulta em um conjunto de coeficientes que representa a resposta ao impulso do sistema.

III. ABORDAGEM PROPOSTA

A abordagem de SHM proposta no presente trabalho é focada no uso de sinais de vibração para realização do diagnóstico estrutural. Mais especificamente, a ideia é realizar uma modelagem adaptativa da estrutura ou sistema sob análise a

partir de sinais de vibração e de um filtro FIR adaptativo. Esse procedimento resulta em um modelo FIR cujos coeficientes correspondem à resposta ao impulso do sistema. Uma vez obtido tal modelo, a resposta em frequência também pode ser obtida aplicando-se a transformada de Fourier (mais especificamente, a FFT) à resposta ao impulso. A motivação para o uso da resposta em frequência está no fato que vibrações estruturais são fortemente dependentes da frequência de excitação e, assim, tal característica é bastante utilizada para análises estruturais a partir de sinais de vibração. Finalmente, usando a resposta ao impulso ou a resposta em frequência do sistema sob análise como atributo, esquemas de aprendizagem de máquina são utilizados visando realizar o diagnóstico do sistema. Para realizar esse diagnóstico, é necessário treinar os modelos de aprendizagem de máquina e, portanto, a construção de um conjunto de dados (*dataset*) adequado contendo dados para as diferentes situações do sistema é também necessária. Assim, observa-se que a abordagem proposta é na verdade uma abordagem baseada em dados, apesar de depender também de um certo tipo de modelagem de sistemas na sua concepção.

A. Vantagens da Abordagem Proposta

Uma vantagem importante da abordagem proposta está na possibilidade de obtenção de respostas ao impulso e em frequência menos ruidosas em comparação com outros métodos como, por exemplo, a aplicação direta da transformada de Fourier sobre sinais de vibração obtidos após a estimulação da estrutura com um esforço qualquer em banda larga. Essa é uma vantagem proporcionada diretamente pelo processo de modelagem adaptativa de sistemas, o qual pode ser ajustado de forma a obter robustez a ruídos de medição e também robustez ao ruído do gradiente observado predominantemente ao final do processo de convergência [4].

Outra vantagem diz respeito à possibilidade de redução da quantidade de dados que precisa ser transferida do sistema de aquisição de dados para o sistema de processamento e análise de dados, aspecto esse bastante importante no contexto de SHM [2]. Os principais algoritmos de filtragem adaptativa são voltados para o processamento em tempo real [4]. Assim, é possível implementar tais algoritmos diretamente no sistema de aquisição e fazer a leitura diretamente do modelo FIR obtido, ao invés das muitas amostras de sinais de vibração para um posterior processamento.

Uma terceira vantagem da abordagem proposta está na facilidade da geração de amostras sintéticas visando *data augmentation* [5]. Tal geração pode ser feita simplesmente alterando-se os parâmetros do processo de modelagem adaptativa de sistemas. Em outras palavras, para um mesmo conjunto de sinais de vibração, é possível executar diferentes processos de modelagem com parâmetros distintos, gerando múltiplas amostras para o *dataset*.

B. Desvantagens da Abordagem Proposta

Uma importante dificuldade para aplicação da abordagem proposta está na necessidade de aplicar um estímulo (um esforço) na estrutura a ser analisada ou mesmo medir um estímulo que é aplicado naturalmente na estrutura (e.g., o

vento que gera vibrações em uma ponte). No entanto, essa é uma dificuldade comum também a muitos outros métodos de SHM baseados em dados [2]. De fato, sem uma estimulação da estrutura em uma certa frequência, não é possível observar a sua resposta estrutural correspondente, o que inviabiliza a detecção de problemas cujos efeitos são manifestados nessa frequência específica.

Outra desvantagem da abordagem proposta está no custo computacional envolvido no processo de modelagem adaptativa de sistemas. No entanto, esse custo, apesar de ser maior do que a aplicação direta da FFT, está longe de ser proibitivo [4]. Além disso, ele pode ser transferido para o sistema de aquisição de dados como mencionado anteriormente.

IV. EXPERIMENTOS E RESULTADOS

Nesta seção, resultados experimentais envolvendo a aplicação da abordagem proposta a uma situação prática são apresentados visando avaliar a sua efetividade em comparação com a aplicação direta da transformada de Fourier aos sinais de vibração para obtenção de atributos (*features*). Nesse contexto, as abordagens aqui consideradas são as seguintes:

- **FFT**: a viga é excitada por uma força com distribuição uniforme de probabilidade e os atributos são as magnitudes do espectro em frequência obtido aplicando a FFT ao sinal de vibração medido na viga;
- **FFT2**: similar à abordagem FFT, mas agora a FFT é aplicada a uma janela com o dobro do tamanho desejado e o espectro obtido é em seguida dizimado para ficar com o tamanho desejado;
- **AdaptRI** (proposta): os atributos são as amostras da resposta ao impulso obtida a partir da modelagem adaptativa do sistema em questão;
- **AdaptFFT** (também proposta): atributos são as magnitudes da resposta em frequência obtida aplicando a FFT sobre a resposta ao impulso usada na abordagem AdaptRI.

Nas abordagens envolvendo modelagem adaptativa, filtros FIR adaptados pelo algoritmo LMS normalizado (NLMS - *normalized least mean squares*) [4] foram utilizados. No caso da abordagem AdaptRI, o tamanho de memória (ordem) de tais filtros foi variado entre 250, 500, 1000, 1500, e 2000 coeficientes, valor esse determinado pelo número de atributos desejado. Para a abordagem AdaptFFT, o tamanho de memória foi de 500, 2000, 2500, 3000, e 4000, igual ao dobro do número de atributos. O passo de adaptação usado foi $\mu = 0.25$ e o fator de penalização $\psi = 10^{-3}$.

Os classificadores utilizados nos experimentos são redes neurais artificiais (*multilayer perceptrons*), com seus hiperparâmetros ajustados buscando o melhor desempenho possível. As arquiteturas das redes foram mantidas fixas em cada experimento da seguinte forma: i) para o Experimento 1, a rede possui duas camadas ocultas com 200 e 100 neurônios, respectivamente; e ii) para os Experimentos 2 e 3, a rede possui duas camadas ocultas com 500 e 200 neurônios, respectivamente. Além disso, a separação dos *datasets* em conjunto de treino e de teste é feita na proporção de 70% e 30%, respectivamente. As diferentes abordagens são avaliadas em




Fig. 1. Ilustração do sistema experimental utilizado: a) bloco de engaste; b) viga engastada livre (esquerda) ou bi-engastada (direita); c) atuadores magnéticos; d) suporte; e) base de sustentação; e f) acelerômetro em destaque.

termos do *score* médio obtido para o conjunto de teste em 10 rodadas de treinamento, cada rodada usando um sorteio aleatório diferente para a separação entre conjunto de treino e conjunto de teste.

A aquisição dos dados usados nos experimentos foi realizada usando o sistema experimental descrito em [6]. Tal sistema é capaz de trabalhar com vigas engastadas livres ou bi-engastadas, possuindo dois atuadores magnéticos para aplicação de forças nas vigas, além de dois acelerômetros tridimensionais para medição da aceleração em dois pontos distintos. A taxa de amostragem utilizada foi de 250 Hz, taxa essa considerada suficiente para o diagnóstico nos experimentos realizados. A Fig. 1 traz uma ilustração da estrutura experimental utilizada, a qual é completada por uma placa de aquisição e um software de aquisição personalizados [6], [7].

O objetivo central nos experimentos realizados é diagnosticar problemas de engastamento (nível de aperto dos parafusos do engaste) em uma viga engastada livre. A viga engastada livre é a ilustrada à esquerda na Fig. 1, possuindo um comprimento (fora do engaste) de 620 mm, largura de 41 mm e espessura de 3 mm. Conforme ilustrado em tal figura, o bloco de engaste possui 6 parafusos. A partir de diferentes ajustes nesses parafusos, obtém-se as 5 diferentes classes consideradas, sendo elas:

- **Classe A**: viga presa adequadamente com todos os parafusos bem apertados;
- **Classe B**: viga levemente frouxa, obtida aplicando um giro de 360° em cada um dos dois parafusos inferiores do engaste;
- **Classe C**: viga um pouco mais frouxa, obtida aplicando um giro adicional de 360° em cada um dos dois parafusos do meio do engaste;
- **Classe D**: viga ainda mais frouxa, obtida aplicando um giro adicional de 360° em cada um dos dois parafusos

inferiores do engaste;

- **Classe E:** viga no pior nível de engastamento, obtida aplicando um giro adicional de 360° em cada um dos dois parafusos do meio do engaste.

Cabe destacar que o par de parafusos superior do engaste não foi afrouxado em nenhum momento.

Foram realizados um total de 40 experimentos, cada um obtido a partir de uma combinação diferente de i) nível de aperto do engaste, ii) atuador utilizado (Atuador 1 é o superior na Fig. 1 e Atuador 2 é o inferior), e iii) amplitude normalizada (0,1; 0,2; 0,5 e 1,0) de um sinal de excitação (força) branco e com distribuição uniforme de probabilidade aplicado à viga. Cada experimento envolve 3 repetições de medidas de vibração por 2 acelerômetros com a excitação aplicada por 60 segundos sobre a viga. Com isso, tem-se um total de 240 amostras disponíveis para análise, sendo 48 delas para cada classe.

A. Experimento 1: Classificação One vs All

Neste primeiro experimento, o *dataset* é reorganizado de forma a obter um problema de classificação envolvendo apenas duas classes: viga engastada adequadamente e viga com engaste inadequado. Nesse contexto, as classes B, C, D e E são consideradas inadequadas, enquanto a Classe A é a única considerada adequada. Trata-se de um problema mais simples do que o originalmente proposto, mas que, por outro lado, apresenta um grande desbalanço de quantidade de amostras entre as suas duas classes.

Os resultados obtidos para o Experimento 1 estão apresentados na Fig. 2. Nessa figura, observa-se que as abordagens propostas (AdaptRI e AdaptFFT) superaram as abordagens tradicionais (FFT e FFT2) com boa margem. Além disso, observa-se que a abordagem AdaptRI proposta obteve taxa de acerto de 100% ($score = 1$) com apenas 250 atributos (e também para 500, 1000 e 1500 atributos), enquanto a AdaptFFT obteve taxas de acerto próximas a 100% para 250, 500 e 1000 atributos. O desempenho das abordagens propostas acabou caindo para números de atributos maiores. Isso se deve ao fato que o processo de modelagem com filtros FIR adaptativos com maiores números de coeficientes (respostas ao impulso mais longas) é naturalmente mais lento e o tempo de treinamento usado foi fixo para todos os casos. Assim, acredita-se que, com um maior tempo de treinamento, o desempenho das abordagens propostas seria melhor para os casos com maior número de atributos. Vale ressaltar ainda que a queda de desempenho mais rápida da AdaptFFT está relacionada com o fato que, para um número de atributos igual a 500 por exemplo, a modelagem adaptativa é feita com um FIR com 1000 coeficientes, para que a FFT aplicada sobre a resposta ao impulso resulte em 500 atributos, já que a metade das amostras de magnitude da FFT é desprezada por questões de simetria. Isso não ocorre no caso da AdaptRI, para a qual o número de atributos é igual ao número de coeficientes do filtro FIR adaptativo.

B. Experimento 2: Multiclassificação

O segundo experimento envolve a classificação considerando as 5 classes originais descritas anteriormente. Trata-se

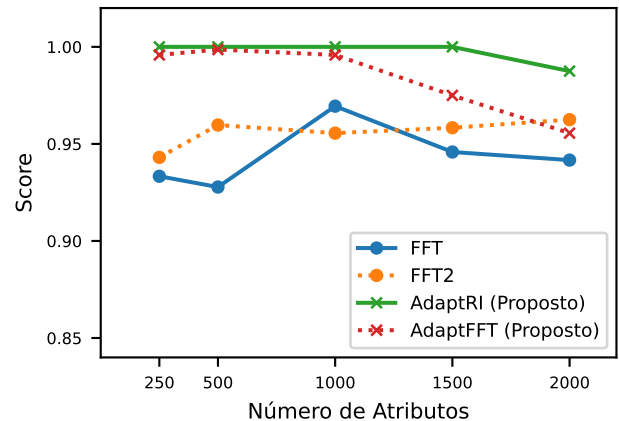


Fig. 2. Experimento 1: *score* médio obtido para o conjunto de teste em 10 rodadas de treinamento considerando diferentes números de atributos.

de um problema mais complexo do que o considerado no Experimento 1 e com bom equilíbrio entre as classes. Os resultados obtidos estão apresentados na Fig. 3. Novamente observa-se que o melhor desempenho foi obtido usando a abordagem AdaptRI proposta (com 1000 e 1500 atributos), enquanto as abordagens clássicas (FFT e FFT2) apresentaram desempenho intermediário. A abordagem AdaptFFT proposta, por sua vez, foi a que apresentou o desempenho mais fraco. Esses resultados são bastante ilustrativos das características das abordagens propostas, conforme descrito a seguir. Nota-se que agora, para um problema mais complexo, um número maior de atributos é requerido para obtenção de bom desempenho. No entanto, conforme mencionado para o Experimento 1, a modelagem adaptativa foi feita com um tempo fixo em todos os experimentos e, assim, as abordagens AdaptRI e AdaptFFT apresentaram queda de desempenho para valores maiores de número de atributos devido à convergência mais lenta da modelagem adaptativa nesses casos. A abordagem AdaptFFT sofre mais nesse contexto já que, conforme mencionado anteriormente, a modelagem é feita com um número de coeficientes duas vezes maior do que no caso da AdaptRI. Assim, a combinação entre necessidade de um número maior de atributos com a convergência mais lenta da modelagem para um número maior de coeficientes produziu o fraco desempenho da AdaptFFT. A AdaptRI, por sua vez, apesar das dificuldades mencionadas, conseguiu o melhor desempenho dentre todas as abordagens consideradas. Considerando o que foi discutido, acredita-se que a AdaptFFT também poderia ter apresentado um desempenho competitivo em outras condições de sua modelagem adaptativa.

C. Experimento 3: Multiclassificação com Data Augmentation

Neste terceiro experimento, a ideia é avaliar o impacto do uso de *data augmentation* nas diferentes abordagens consideradas. No caso das abordagens FFT e FFT2, o *data augmentation* é realizado capturando dois trechos diferentes dos dados de um mesmo experimento, para assim dobrar ou triplicar o número de amostras. Para as abordagens AdaptRI e AdaptFFT, usa-se dois ou três valores diferentes de passo

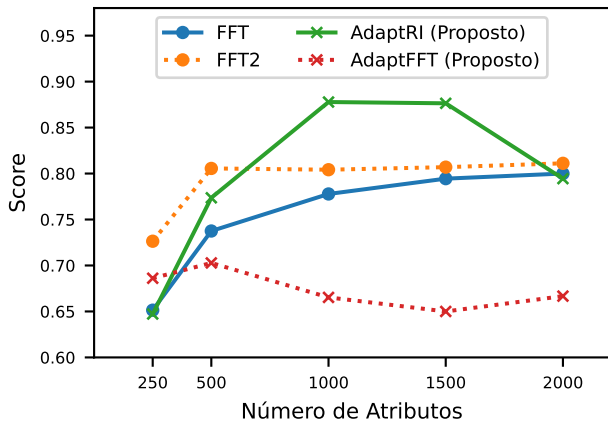


Fig. 3. Experimento 2: *score* médio obtido para o conjunto de teste em 10 rodadas de treinamento considerando diferentes números de atributos.

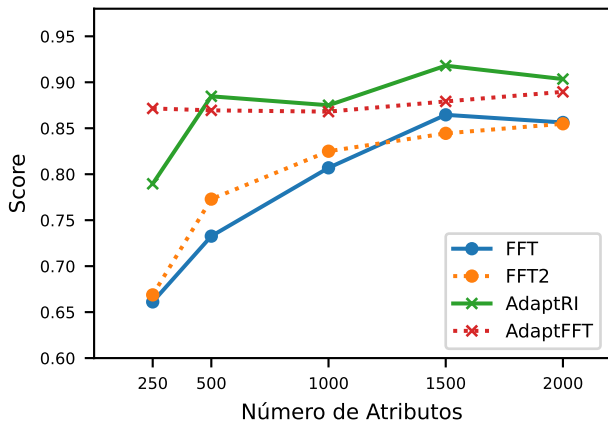


Fig. 4. Experimento 3: *score* médio obtido para o conjunto de teste em 10 rodadas de treinamento considerando diferentes números de atributos e usando *data augmentation* para duplicar o número de amostras.

de adaptação na modelagem adaptativa, resultando em duas ou três respostas ao impulso e em frequência distintas para um mesmo experimento. Os resultados obtidos para o caso em que o número de amostras é dobrado estão apresentados na Fig. 4. A partir dessa figura, observa-se que o uso de *data augmentation* melhorou o desempenho de todas as abordagens consideradas, com destaque particular para a abordagem AdaptFFT proposta, que agora apresentou um resultado bastante competitivo (contrastando com os seus resultados no Experimento 2). Novamente, a abordagem AdaptRI proposta foi a que apresentou o melhor desempenho. Ainda, na Fig. 5, estão apresentados os resultados para o caso em que o número de amostras é triplicado (exceto para FFT2, para a qual o resultado com duplicação de amostras é repetido, já que não foi possível triplicar as amostras para essa abordagem em função da duração das gravações no *dataset*). Nesse caso, o desempenho das abordagens AdaptRI e AdaptFFT propostas melhorou ainda mais, enquanto o desempenho da abordagem FFT sofreu uma leve piora em relação ao caso com duplicação de número de amostras.




Fig. 5. Experimento 3: *score* médio obtido para o conjunto de teste em 10 rodadas de treinamento considerando diferentes números de atributos e usando *data augmentation* para triplicar o número de amostras.

V. CONCLUSÕES

No presente trabalho, uma nova abordagem para monitoramento de saúde de estruturas foi apresentada. Tal abordagem baseia-se no uso de filtragem adaptativa para extração de atributos a serem usados em um processo de diagnóstico usando aprendizagem de máquina. Os resultados experimentais obtidos mostraram que a abordagem proposta apresenta elevado potencial de aplicação, com desempenho superior ao de abordagens tradicionais, além de apresentar outras vantagens importantes como a possibilidade de redução da quantidade de dados a serem transferidos do sistema de aquisição de dados para o sistema de processamento e análise de dados.

AGRADECIMENTOS

Os autores gostariam de agradecer ao CNPq e ao PIICT-UFSC pelo apoio ao presente trabalho.

REFERÊNCIAS

- [1] W. Fan and P. Qiao, "Vibration-based damage identification methods: A review and comparative study," *Structural Health Monitoring*, vol. 10, no. 1, pp. 83–111, Jan 2011.
- [2] A. Malekloo, E. Ozer, M. A. Hamaydeh, and M. Girolami, "Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights," *Structural Health Monitoring*, vol. 21, no. 4, pp. 1906–1955, July 2022.
- [3] C. Hansen, S. Snyder, X. Qiu, L. Brooks, and D. Moreau, *Active Control of Noise and Vibration*, 2nd ed. Boca Raton, FL: CRC Press, 2012.
- [4] P. S. R. Diniz, *Adaptive Filtering: Algorithms and Practical Implementation*, 4th ed. New York, NY: Springer, 2008.
- [5] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. MIT Press, 2012.
- [6] E. L. O. Batista, N. Citadin, M. Marin, M. Barghouti, and E. Lopes, "Um sistema experimental de código aberto para pesquisa em controle ativo de vibrações," in *Anais do XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2022)*, Santa Rita do Sapucaí, Brasil, Sept. 2022, pp. 1–5.
- [7] E. L. O. Batista. (2022) ActVib GitHub repository. [Online]. Available: <https://github.com/eduardobatista/ActVib>