

Proceeding Series of the Brazilian Society of Computational and Applied Mathematics

Caracterização de Padrões de Falha através de uma Rede Neural Artificial *Fuzzy ARTMAP*

Lucas Perroni Chaim¹
Fábio Roberto Chavarette²
Mara Lúcia Martins Lopes³
Faculdade de Engenharia, UNESP, Ilha Solteira, SP

1 Introdução

O cenário contemporâneo é repleto de estruturas cuja falha pode resultar em prejuízos significativos tanto financeiros quanto à saúde humana das mais variadas formas. O campo de Monitoramento de Saúde Estrutural, ou *SHM* do termo em inglês, almeja fornecer ferramentas integradas para fins de monitoração e manutenção de estruturas [1].

Em algumas situações, entretanto, pode ser desafiador obter dados significativos, como em pontos de difícil acesso físico ou em construções legadas cujo projeto não acomoda facilmente componentes de monitoramento. Com isto em mente, apresenta-se neste trabalho uma metodologia que faz uso de uma Rede Neural Artificial para a detecção e categorização de falhas, modeladas como desbalanços de massa, em um modelo estrutural a partir apenas de dados de deslocamento e/ou velocidade no tempo coletadas em seus componentes de massa. A aplicação de tal método possibilitaria a monitoração da saúde estrutural de estruturas de grande porte com aparato relativamente simples.

2 Modelagem e pré-processamento de dados

O modelo usado neste trabalho representa um edifício de dois andares, com duas massas M_1 e M_2 representando o primeiro e segundo andar respectivamente, além de uma base fixa abaixo de ambos. Existe um par composto por uma mola de constante elástica k_1 e um amortecedor com coeficiente de amortecimento c_1 entre a base e o andar 1 e um par análogo entre os dois andares superiores. S é um esforço senoidal de amplitude reduzida, da ordem de $10^{-4}m$, simulando um padrão de vibração e aplicado ao primeiro andar.

As equações representativas do sistema, obtidas através da modelagem Lagrangiana do mesmo e apresentadas na equação (2), foram integradas através do *software GNU Octave*, obtendo-se assim dados de deslocamento e velocidade no tempo das coordenadas

¹lpchaim@gmail.com

²fabioch@mat.feis.unesp.br

³mara@mat.feis.unesp.br

generalizadas referentes às massas M_1 e M_2 . Foram gerados vetores para várias situações de massa, sendo desbalanços fora de certa faixa considerados como falhas. Cada uma era arquivada juntamente com um identificador binário respectivo ao andar em que a mesma ocorreu na respectiva configuração. No mesmo *software* processou-se os vetores por meio de uma Transformada Rápida de *Fourier*, ou *FFT*.

$$\begin{bmatrix} m_1 & 0 \\ 0 & m_2 \end{bmatrix} \begin{Bmatrix} \ddot{q}_1 \\ \ddot{q}_2 \end{Bmatrix} + \begin{bmatrix} c_1 + c_2 & -c_2 \\ -c_2 & c_2 \end{bmatrix} \begin{Bmatrix} \dot{q}_1 \\ \dot{q}_2 \end{Bmatrix} + \begin{bmatrix} k_1 + k_2 & -k_2 \\ -k_2 & k_2 \end{bmatrix} \begin{Bmatrix} q_1 \\ q_2 \end{Bmatrix} = \begin{Bmatrix} S \\ 0 \end{Bmatrix} \quad (1)$$

3 Reconhecimento e Categorização de Falhas

Como mecanismo de caracterização foi utilizada uma rede neural artificial do tipo *Fuzzy ARTMAP*, que apresenta aprendizado supervisionado. Isto significa que a rede é treinada para agrupar vetores de entrada em categorias predeterminadas no processo treinamento. A rede apresenta também aprendizado rápido e estável [2].

Foi concebido um processo para a validação do método, realizado com 1000 iterações. Em cada uma delas, 70% dos pares de entrada e respectiva categoria eram alimentados à rede em ordem aleatória no processo de treinamento. Realizava-se então o diagnóstico da rede com 30% dos vetores restantes. Nesta fase a rede fornecia o código de categoria que julgava adequada para cada vetor que recebia como entrada através do conhecimento adquirido no treinamento, retornando se o mesmo correspondia a uma situação de saúde, de falha no primeiro andar ou de falha no segundo andar. As respostas da rede eram comparadas com as situações de cada vetor, já conhecidas pelas condições de simulação, e a porcentagem de acertos era armazenada como a eficácia da iteração atual.

O processo de validação descrito foi aplicado então a dois conjuntos de dados extraídos do mesmo processo de simulação, um composto pelo deslocamento das coordenadas generalizadas das massas e outro composto pela velocidade das mesmas. Uma análise estatística descritiva revelou que os dados se comportavam de maneira extremamente semelhante, mas que os dados relacionados ao deslocamento apresentavam valores médios mais altos e com maior frequência de eficácia do que os relacionados ao conjunto restante. Com valor médio de 93,88%, o primeiro conjunto apresentava 83% dos valores de eficácia acima de 90%, em contraste com apenas 77% no segundo.

Referências

- [1] D. Balageas, C. P. Fritzen, and A. Güemes. *Structural Health Monitoring*. Wiley-ISTE, 2006.
- [2] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rozen, *IEEE Transactions on neural networks*, 3(5):698-713, 1992.
- [3] F. R. Chavarette and A. L. Toniati, Dinâmica e controle de um sistema estrutural sob excitação sísmica, *CONEN - Congresso Nacional de Engenharia Mecânica*, 7:1-11, 2012.