

Aplicação De Redes Neurais Em Sinais Dinâmicos Transformados Em Imagens Digitais

Pedro Henrique Martinez¹, Júlia Maria de França Moura², Ricardo Carrazedo³

^{1,2,3}USP / SET-Departamento de Engenharia de Estruturas

pedro.h.martinez@usp.br/ juliafmoura@usp.br/ carrazedo@usp.br

Resumo

O monitoramento de estruturas é essencial para avaliar seu desempenho e detectar danos, garantindo segurança e possibilitando intervenções preventivas. Métodos tradicionais enfrentam dificuldades na análise de grandes volumes de dados e interpretação de sinais temporais complexos. Este trabalho propõe o uso de redes neurais artificiais (RNAs) combinadas com métodos inovadores de transformação de sinais em imagens digitais, como Gramian Angular Summation Field (GASF) e Gramian Angular Difference Field (GADF), aplicados a um modelo analítico de estrutura. O objetivo é identificar características dinâmicas fundamentais, como frequência natural, amortecimento e rigidez. Utilizou-se um modelo analítico de uma viga bi-apoiada de concreto armado com características geométricas compatíveis com uma ponte de 25m de vão. A resposta dinâmica foi simulada considerando vibração livre subamortecida, e os sinais foram transformados em imagens no intervalo de $0 < t < 1$ segundo. Entre os métodos avaliados, destacou-se o Gramian Angular Summation Field (GADF), empregado para treinar uma rede neural convolucional de regressão. O modelo foi desenvolvido para prever parâmetros estruturais, como dimensões geométricas, rigidez, inércia e frequência natural, além de identificar reduções de até 10% na rigidez e na inércia da viga. Foram geradas 20.000 amostras de sinais, incorporando variabilidade nas propriedades da viga com base em conceitos de confiabilidade estrutural. Parâmetros como altura, espessura, comprimento, resistência característica do concreto (f_{ck}) e peso específico foram modelados como variáveis aleatórias, com médias e desvios padrão baseados na literatura técnica. A arquitetura da RNA incluiu camadas convolucionais, de pooling e densamente conectadas, culminando em uma camada de saída com 13 neurônios. As métricas de desempenho (*loss*, *val_loss*, *mae*, *val_mae*) demonstraram excelente generalização, sem indícios de *overfitting*. Os resultados indicam que a metodologia proposta prevê parâmetros estruturais com boa precisão, evidenciando seu potencial para novos estudos em aplicações e otimizações futuras utilizando cenários mais complexos e realistas.

Palavras-chave

Monitoramento estrutural; Redes Neurais Artificiais; Gramian Angular Field; Confiabilidade Estrutural.

Introdução

O monitoramento da saúde estrutural (SHM - Structural Health Monitoring) refere-se ao processo de implementação de estratégias de medição para detecção, localização e avaliação da integridade de estruturas (FARRAR et al., 2013).

Na engenharia civil, essa avaliação é crucial, especialmente para obras de arte especiais (OAEs), como pontes, túneis, arranha-céus e barragens, que apresentam arranjos estruturais complexos e alta relevância econômica, social e política (CHEN, 2018).

Atualmente, métodos tradicionais de monitoramento enfrentam desafios significativos, como a dificuldade de processar grandes volumes de dados e interpretar sinais temporais de forma eficiente. Para avaliar danos em pontes, por exemplo, é comum coletar dados de aceleração dos elementos estruturais, utilizando carregamentos de utilização em tempo real (output-only methods) ou carregamentos conhecidos aplicados por osciladores mecânicos (input-output methods) (AVCI et al., 2021).

Esses métodos podem ser classificados em dois grupos: paramétricos, que investigam parâmetros dinâmicos como rigidez, amortecimento e frequências modais; e não paramétricos, que analisam diretamente os sinais com base em séries temporais e estatística (CHEN, 2018).

Dada a extensão dos conjuntos de dados gerados, torna-se necessário empregar técnicas avançadas de tratamento de dados. Uma abordagem promissora é o uso de redes neurais artificiais (RNAs), inspiradas no funcionamento dos neurônios biológicos, que possuem capacidade de processar grandes volumes de informações e lidar com imagens digitais (CHA, 2024; AVCI et al., 2021). Entre as técnicas emergentes, destaca-se o Gramian Angular Field (GAF), que transforma sinais temporais em imagens digitais (WANG et al., 2015; MANTAWY et al., 2021).

Apesar do potencial dessa técnica, sua aplicação no monitoramento de pontes ainda é pouco explorada na literatura. Um exemplo recente é o estudo de Deng et al. (2023), que utilizou GAF e redes neurais artificiais (RNAs) para avaliar a qualidade dos dados coletados na ponte estaiada Hong Kong-Zhuhai Macau. Os dados foram classificados em três categorias: normais, anormais e pseudo normais — estes últimos são dados que parecem normais no domínio do tempo, mas apresentam comportamento caótico no domínio da frequência. A abordagem consistiu em aplicar a transformada rápida de Fourier (FFT) para converter os dados do domínio do tempo em informações no domínio da frequência, que foram então transformadas em imagens digitais usando o método GAF. Essas imagens foram utilizadas para treinar uma rede neural convolucional (CNN), alcançando uma precisão de classificação de 95,5%.

Inspirado por essa abordagem, este trabalho realizou uma investigação inicial sobre o uso combinado das variações do método GAF e RNAs para a recuperação de dados referentes às características geométricas, físicas e dinâmicas de uma viga de concreto armado, compatível com uma ponte cujo vão é de 25 metros.

Gramian Angular Field

A decodificação de uma série temporal em uma imagem pode ser realizada pelo método GAF (Gramian Angular Field). Os passos indicados abaixo podem ser encontrados nos trabalhos de Wang et al. (2015) e Mantawy et al. (2021).

Dada uma série temporal $X=\{x_1, x_2, x_3, \dots, x_n\}$, para n pontos reais observados, utiliza-se a Equação (1) para normalizar o problema no intervalo $[-1, 1]$.

$$\bar{x}_i = \frac{(x_1 - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

Após a normalização, é necessário transformar os valores obtidos pela Equação (1) em coordenadas polares. Para o valor x_i , utiliza-se o arco cosseno, e o tempo será convertido para o raio da coordenada conforme a Equação (2).

$$\begin{cases} \phi_i = \arccos(\bar{x}_i) \\ r = \frac{t_i}{N} \end{cases} \quad (2)$$

A partir deste ponto, a primeira possibilidade de formulação é chamada de GASF (Gramian Angular Summation Field), que é constituída pela aplicação da Equação (3). Nesta equação, é aplicado o cosseno da soma dos arcos ϕ_i , na seguinte ordem:

$$GASF = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

A outra opção possível é chamada de GADF (Gramian Angular Difference Field), que consiste na aplicação da Equação (4). Na Figura 1, pode-se observar a diferença entre as imagens formadas pelos dois modelos.

$$GADF = \begin{bmatrix} \sin(\phi_1 + \phi_1) & \sin(\phi_1 + \phi_2) & \cdots & \sin(\phi_1 + \phi_n) \\ \sin(\phi_2 + \phi_1) & \sin(\phi_2 + \phi_2) & \cdots & \sin(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \sin(\phi_n + \phi_1) & \sin(\phi_n + \phi_2) & \cdots & \sin(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$




Figura 1 – Sinal de aceleração, imagem formada pelo GASF e GADF respectivamente.

Fonte: Mantawy et al., 2021

Deep Learning e Rede Neural Convolucional (CNN)

As técnicas de inteligência artificial estão sendo cada vez mais aplicadas às mais diversas áreas do conhecimento. Elas consistem em modelos computacionais inspirados no neurônio biológico. Isso quer dizer que o neurônio computacional, de forma simplificada, possui entradas de sinais, capacidade de processamento dessas entradas por meio de uma função de ativação e uma saída para o sinal. Treinar um modelo de rede neural significa, portanto, encontrar todos os coeficientes necessários dos diversos neurônios em uma determinada arquitetura de rede neural artificial.

Neste contexto, o Deep Learning pode ser definido como uma subárea do aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas para aprender representações hierárquicas de dados. Essas camadas permitem que o modelo extraia automaticamente características relevantes dos dados brutos (LECUN et al., 2015).

Uma arquitetura possível para ser utilizada no processo de Deep Learning é a Rede Neural Convolucional (CNN). Ela pode ser definida como uma arquitetura projetada para processar dados com uma estrutura de grade, como imagens (LECUN et al., 1998).

Essa arquitetura é composta por camadas convolucionais que aplicam filtros espaciais aos dados de entrada para capturar padrões locais, como bordas e texturas. Esses filtros são compartilhados entre diferentes regiões da entrada, permitindo que a rede seja invariante a translações e eficiente em termos computacionais (GOODFELLOW et al., 2016).

A convolução utiliza um filtro (kernel) que desliza sobre a imagem, multiplicando e somando os valores dos pixels para extrair características como bordas e texturas, gerando um mapa de características (feature map). Já o pooling reduz o tamanho desse mapa, mantendo as informações essenciais, diminuindo a complexidade computacional e evitando overfitting. Os métodos mais utilizados são o max pooling, que seleciona o valor máximo em uma janela, e o average pooling, que calcula a média dos valores. Na Figura 2, os filtros variam entre tamanhos 4 e 3.




Figura 2 – Modelo de Rede Convolucional.

Fonte: Avci et al., 2021

Aplicação Dos Métodos

Para aplicação dos métodos de transformação, foram adaptadas as dimensões de uma viga de ponte de concreto armado dimensionada por Marchetti (2008), com fck de 30 MPa e dimensões de 25 cm (largura), 165 cm (altura) e 25 m (comprimento).

O modelo didático escolhido para representar a resposta dinâmica foi de um grau de liberdade, considerando uma viga bi-apoiada sob hipóteses elástico-lineares, com vibração livre e subamortecida. A resposta original do sistema está ilustrada na Figura 3.




Figura 3 – Resposta original do sistema.

Fonte: Próprio autor

Para simplificar as transformações, optou-se por analisar o sinal no intervalo de tempo $0 < t < 1$ segundo cujas respostas são apresentadas na Figura 4.




Figura 4 – Transformação a partir do GAF.

Fonte: Próprio autor

Neste exemplo, o Gramian Angular Summation Field e o Gramian Angular Difference Field (GADF) foram utilizados para treinar duas redes convolucionais de regressão, com o objetivo de prever os parâmetros iniciais do problema a partir de imagens digitais. Os parâmetros selecionados para predição foram: dimensões da viga (largura, altura, comprimento), fck, peso específico, módulo de elasticidade, rigidez equivalente, inércia equivalente, frequência natural, massa e coeficiente de amortecimento.

Para a criação do banco de dados de treinamento, aplicaram-se os conceitos de confiabilidade estrutural apresentados por Beck (2019). A abordagem por confiabilidade foi escolhida para simular a captação do sinal de aceleração do centro do vão e a partir desse sinal reconhecer as características da viga. Foram geradas 20.000 amostras de sinais, considerando como variáveis aleatórias a altura (h), largura (b),

comprimento (L), f_{ck} do concreto (f_{ck}) e peso específico do concreto (γ), com distribuição normal conforme a Tabela 1. O procedimento de usar variáveis aleatórias é baseado na própria variação estatística no momento da execução de uma viga de concreto armado. Por mais que o projeto seja feito com valores fixos, existirá uma variabilidade nas características geométricas e no valor de características no material concreto.

Variável	Média	Desvio Padrão	Fonte
$X_1 = h$	h^*	$4 + 0,006h^*$	SANTIAGO (2019)
$X_2 = b$	b^*	$4 + 0,006b^*$	SANTIAGO (2019)
$X_3 = L$	L^*	$4 + 0,006L^*$	SANTIAGO (2019)
$X_4 = f_{ck}$	$1,22f_{ck}$	$0,183f_{ck}$	SANTIAGO (2019)
$X_5 = \gamma$	γ	$0,03\gamma$	JCSS

*Unidade em milímetros

Tabela 1 – Variáveis aleatórias selecionadas, com médias, desvios padrão e fontes baseadas em aspectos construtivos.

Além disso, foram incluídos dois parâmetros adicionais no treinamento: a rede deve identificar se a imagem processada apresenta uma perda de 10% de rigidez e/ou 10% de inércia em relação às medidas iniciais do projeto. A resposta da rede será um valor próximo de 0 para indicar que não houve perda superior a 10%, e próximo de 1 para indicar perdas significativas em relação aos dados de projeto. A Figura 5 apresenta uma amostra de 5 das 20.000 imagens geradas por cada método, com as características descritas na Tabela 1 e com resolução de 28x28 pixels.




Figura 5 – Cinco amostras aleatórias utilizando GADF e GASF, respectivamente

Fonte: Próprio autor

O modelo de rede neural desenvolvido para os dois métodos neste problema consiste em uma sequência de camadas que integram operações de convolução, pooling e processamento densamente conectado. A primeira camada aplica uma convolução com 32 filtros de 3x3 pixels, seguida por uma camada de pooling de 2x2 pixels para reduzir a dimensionalidade espacial. A terceira e quarta camadas repetem essa estrutura, mas com 64 filtros. A quinta camada realiza uma nova convolução com 64 filtros para extrair características mais complexas. A sexta camada utiliza a operação Flatten, que transforma a matriz resultante em um vetor unidimensional, preparando os dados para as camadas densamente conectadas.

Por fim, as duas últimas camadas possuem 64 e 13 neurônios, respectivamente, onde os 13 neurônios da última camada correspondem aos onze parâmetros a serem estimados e às duas condições adicionais relacionadas à rigidez e à inércia do sistema. Após o treinamento das duas redes, os parâmetros que indicam a qualidade dos modelos são apresentados na Tabela 2 e 3.

	Métrica	Loss	Descrição
GADF	Loss	0.0089	Função de perda do conjunto de treinamento
	Mae	0.0628	Erro absoluto médio do treinamento
	Val_Loss	0.009	Função de perda do conjunto de validação
	Val_Mae	0.0638	Erro absoluto médio da validação

Tabela 2 – Métricas de desempenho do modelo após o treinamento do modelo GADF

	Métrica	Loss	Descrição
GASF	Loss	0.0090	Função de perda do conjunto de treinamento
	Mae	0.0627	Erro absoluto médio do treinamento
	Val_Loss	0.0088	Função de perda do conjunto de validação
	Val_Mae	0.00611	Erro absoluto médio da validação

Tabela 3 – Métricas de desempenho do modelo após o treinamento do modelo GADF

O desempenho dos modelos GADF e GASF foi comparado usando quatro métricas: *Loss*, *Mae*, *Val_Loss* e *Val_Mae*. No treinamento, ambos os modelos apresentaram resultados muito próximos, com o GADF tendo *Loss* de 0.0089 e *Mae* de 0.0628, enquanto o GASF obteve *Loss* de 0.009 e *Mae* de 0.0627. Essas pequenas diferenças indicam desempenhos similares durante o ajuste aos dados de treino.

Na validação, o GASF superou o GADF em todas as métricas. O GASF alcançou *Val_Loss* de 0.0088, menor que o 0.009 do GADF, mostrando melhor generalização. Além disso, o *Val_Mae* do GASF foi excepcionalmente baixo (0.00611), contrastando com o 0.0638 do GADF. Esse resultado sugere que o GASF é mais preciso ao prever o conjunto de validação.

A diferença entre treino e validação também foi analisada. Para o GADF, as variações foram mínimas, com aumento de apenas 0.0001 no *Loss* e 0.001 no *Mae*, indicando estabilidade. Já o GASF apresentou uma queda anômala no *Mae* de validação (-0.05659), sugerindo que o modelo performou melhor na validação do que no treino, possivelmente devido a características específicas do conjunto de validação.

O GASF demonstrou superioridade clara sobre o GADF, especialmente na validação, com métricas significativamente melhores. No entanto, a discrepância extrema no *Val_Mae* do GASF levanta questões sobre a consistência do conjunto de validação ou possíveis erros de medição. Uma investigação adicional é recomendada para confirmar a robustez dos resultados.

Para exemplificar os resultados, foi gerado um exemplo aleatório e comparado com as previsões da rede treinada. A Figura 6 exibe um dado gerado aleatoriamente, enquanto as Tabelas 3 e 4 apresentam, respectivamente, os valores analíticos e os valores preditos pela rede.




Figura 6 – Amostra aleatória (GASF)

Fonte: Próprio autor

Nas Tabelas 3 e 4, podem ser observados de forma explícita os valores preditos pela rede: a altura da viga (*h*), a espessura (*b*), o comprimento (*L*), a resistência à compressão característica do concreto (*Fck*), o peso específico do concreto (*P.e*), o módulo de elasticidade do concreto (*E*), a rigidez (*K*), o momento de inércia da viga (*I*), a frequência natural (*Wn*), a massa (*M*), o amortecimento (*C*) e as indicações de perda de 10% tanto no momento de inércia quanto na rigidez.

	<i>h</i> (m)	<i>b</i> (m)	<i>L</i> (m)	<i>Fck</i> (Mpa)	<i>P.e</i> (kN/m ³)	<i>E</i> (N/m ²)	<i>K</i> (N/m)
Valores Reais	1.6258	0.23	25.02	36.81	24.46	30307764614	790288.2
Valores Gerados	1.6492	0.24	25.01	36.20	25.11	30149577000	856323.6
Erro Relativo	1.44%	4.92%	0.04%	1.64%	2.64%	0.52%	8.35%

Tabela 3 – Valores reais e valores obtidos pela rede (Parte 1)

	I(m ⁴)	Wn(rad/s)	M(kg)	C (N.s/m)	Falha I	Falha K
Valores Reais	0.08517	25.837	23676.59	23676.59	0	0
Valores Gerados	0.093475707	25.82876	25785.316	25785.316	-0.0007	0.013
Erro Relativo	9.75%	0.03%	8.90%	8.90%	-	-

Tabela 4 – Valores reais e valores obtidos pela rede (Parte 2)

O maior erro percentual relativo entre os dados foi 9,75% na Inercia da viga. Em relação a todos os dados deste exemplo o erro médio relativo foi de 3,86%. A técnica se mostra muito promissora para maiores investigações tanto em modelos mais complexos como para a otimização e melhorias no treinamento visto que as redes neurais podem ser passíveis de melhoramento.

Outro aspecto importante é que as arquiteturas salvas foram capazes de prever múltiplos valores em ordens de grandeza diferentes, evidenciando seu potencial para diversas outras aplicações.

Conclusões

O estudo comparou o desempenho de dois métodos de transformação, GADF e GASF, aplicados à predição de parâmetros estruturais de uma viga de concreto armado usando redes neurais convolucionais. Ambos os modelos apresentaram desempenhos semelhantes no treinamento, mas o GASF superou o GADF na validação, com métricas significativamente melhores, como *Val_Loss* de 0.0088 e *Val_Mae* excepcionalmente baixo de 0.00611. Esses resultados indicam que o GASF é mais preciso e generalizável para prever características do sistema estudado a partir de imagens digitais.

O modelo desenvolvido também foi capaz de identificar condições de falha relacionadas à rigidez e inércia, com erros mínimos nessa classificação. Isso reforça o potencial da abordagem para novos estudos em outras aplicações, onde pequenas variações nos parâmetros podem indicar problemas críticos. A combinação de confiabilidade estrutural e aprendizado de máquina mostrou-se eficaz para lidar com a variabilidade inerente aos materiais e às dimensões das estruturas.

As arquiteturas das redes foram salvas em um formato de arquivo específico (.Keras), permitindo a avaliação e modificação dos modelos, uma vez que o processo de desenvolvimento de redes neurais artificiais é passível de otimização.

Em suma, o GASF emergiu como a melhor escolha para este problema, com desempenho superior e alta precisão na predição dos parâmetros. Contudo, há espaço para refinamentos, como otimização do treinamento e uso de modelos mais complexos. O trabalho contribui para futuras investigações com modelos mais robustos utilizando os métodos de decodificação dos sinais temporais em imagens digitais para auxiliar no monitoramento estrutural.

Referências

- AVCI, O.; ABDELJABER, O.; KIRANYAZ, S.; HUSSEIN, M.; GABBOUJ, M.; INMAN, D. J. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical Systems and Signal Processing*, v. 147, 2021.
- BECK, A. T. *Confiabilidade e Segurança das Estruturas*. 1. ed. Rio de Janeiro: Elsevier, 2019.
- CHA, Y. J.; ALI, R.; LEWIS, J.; BÜYÜKÖZTÜRK, O. Deep learning-based structural health monitoring. *Automation in Construction*, v. 161, 2024.
- CHEN, H. P.; QING, Y. N. *Structural Health Monitoring of Large Civil Engineering Structures*. Wiley-Blackwell, 2018.
- DENG, Yang; JU, Hanwen; ZHONG, Guoqiang; LI, Aiqun. Data quality evaluation for bridge structural health monitoring based on deep learning and frequency-domain information. *Structural Health Monitoring*, [S. l.], v. 22, n. 5, p. 2925-2947, 2023.
- FARRAR, C. R.; WORDEN, K. *Structural Health Monitoring: A Machine Learning Perspective*. John Wiley & Sons Ltd., Hoboken, 2013.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. Cambridge: MIT Press, 2016. 800 p. ISBN: 9780262035613.

- JCSS. Probabilistic Model Code. Joint Committee on Structural Safety, 2001. Disponível em: http://www.jcss.byg.dtu.dk/Publications/Probabilistic_Model_Code.aspx
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, [S.l.], v. 86, n. 11, p. 2278–2324, nov. 1998.
- MANTAWY, I. M.; MANTAWY, M. O. Convolutional neural network based structural health monitoring for rocking bridge system by encoding time-series into images. *Structural Control & Health Monitoring*, v. 29, 2021.
- MARCHETTI, O. Pontes de Concreto Armado. São Paulo: Editora Edgard Blücher, 2008.
- SANTIAGO, W. C. Calibração baseada em confiabilidade dos coeficientes parciais de segurança das principais normas brasileiras de projeto estrutural. 2019. 181 f. Tese (Doutorado em Engenharia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2019.
- WANG, Z.; OATES, T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks. In: *Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence*, 2015.