

第 I 部門

機械学習による複数損傷を有する模型鋼アーチ橋の損傷部材・損傷位置の推定

大阪公立大学大学院 学生員 ○赤星 花奈

大阪公立大学大学院 正会員 林 厳

大阪公立大学大学院 正会員 山口 隆司

1. 研究背景および目的

複数損傷を有する橋梁の損傷検知では、振動モードなどが用いられているが、この場合、多数のセンサを用いてモード同定する必要がある¹⁾。そこで、著者らは、少数のセンサで複数損傷の分類を試みるため、各部材損傷と独立して変化する固有振動数の変化を定量的に評価した²⁾。本研究では、損傷部材の判別や損傷程度を自動で同定するために、文献²⁾で得た結果を学習データとした、ニューラルネットワーク（以下 NN）を利用し、模型鋼アーチ橋の複数損傷の検知手法の有効性を検討した。

2. FEM によるデータの抽出

学習データの作成のために、汎用有限要素解析コード Abaqus/Standard2022 を用いて、対象橋梁に損傷を導入した固有振動解析を行い、データ抽出を行った。対象橋梁は、**図-1**に示す全長 5000mm、幅 567mm、高さ 893mm の鋼製アーチ橋（SS400）であり、アーチリブ、補剛桁、横桁、吊材で構成されている。

対象とする損傷は、**図-1**に示す補剛桁、吊材、横桁の格点部の腐食とし、板厚の減肉と腐食範囲を変化させることでそれを模擬した。**表-1**に、部材に与えた 3 段階の損傷程度を例として示す。各部材の損傷位置は、**図-1**に示す桁の a 側と b 側のそれぞれ位置番号 1~7（横桁のみ 0~8）とし、計 60 カ所である。損傷名は「部材名+a/b 桁+位置番号」である。これらの損傷を単数、複数箇所に与える場合について検討した。単数損傷は計 60 ケ所の損傷とし、複数損傷は、2 部材に損傷を与え、対称性を考慮し、**図-1**に示す赤枠内の損傷を組み合わせた 78 組とした。

3. 損傷検知のフロー

損傷検知フローは、**図-2**に示すとおりで、計 12 個の NN を組み合わせる単数損傷と複数損傷の分類、損傷部材の分類、損傷位置の分類を行った。上層の NN では損傷数や部材の分類、下層の NN では損傷位置を判別する。

表-2に NN の構成と学習データ、認識データを示す。NN の構成は、各 NN でそれぞれ、中間層数とその活性化




図-1 対象橋梁の全体図

表-1 腐食程度と断面寸法

Damage member	degree	(A × B × t × l) (mm)	Cross section
Stiffening girder	25%	40×40×1.2×80	
	50%	40×40×0.8×80	
	75%	40×40×0.4×80	
Cross girder	25%	30×30×1.2×80	
	50%	30×30×0.8×80	
	75%	30×30×0.4×80	
Hanger	25%	12(A)×3.75(t)×40	
	50%	8(A)×2.25(t)×40	
	75%	4(A)×1.125(t)×40	




図-2 検知フロー

関数をベイズ最適化している。また、出力層の活性化関数は softmax 関数とし、学習回数は 1000 回で一定としている。また、学習データは**表-2**に示す損傷程度のデータ

とし、それぞれの分類ごとにラベルを付与した。認識データは学習データと異なる 2 つの損傷程度とした。学習データは、水平 1~2 次、曲げ 1~4 次モードの特徴量は固有振動数とし、-1~+1 の範囲で正規化を行っている。

4. 認識結果と考察

表-3 は、NN1 の認識データに対する予測結果を示す。単数損傷が正しく認識された割合は 83.3%であったが、複数損傷が認識された割合は92.9%という精度であった。また、表-4 に NN2 と NN3 の認識結果を示す。補一補、補一吊の認識率は 90%で以下であったが、他の組み合わせでは、90%以上を確保しており、ほとんどの損傷を分類可能であることがわかった。また、誤認識された複数損傷のケースのうち、損傷程度が大きい方の損傷は、正しく認識されていることが多く、2 つの損傷がともに誤認識されたケースは 4 ケースのみであった。誤認識された損傷には、Ga1~Ga4, Hda1, Hda2, Ca4, Ca5 が含まれることが多く、これらの損傷時は、固有振動数の変化が小さいことや、損傷導入時の振動モードが類似した結果となる損傷ケースであることが原因だと考えられる。

図-3(a)は、正しく認識されたケースの一例として、Ga2 が 12.5%損傷した認識データの特徴量（4 つの振動モードの固有振動数）と、Ga2 を 5 段階で損傷させた学習データであり、図-3 (b) は、誤認識されたケースの一例として、Ga2 が 25%, Ca3 が 50%損傷したケースの固有振動数と、その認識結果である Ga1 の学習データである。

図-3 (a) より、認識データは、4 つの振動モードで、学習データの損傷程度が 6.25%, 25%の間にプロットされ、認識データと学習データの関係が一定である。一方、図-3 (b) より認識データは、4 つの振動モードで異なる損傷程度の位置にプロットされている。誤認識されたすべてのケースでこの傾向が確認された。このことから、固有振動数とその損傷程度の両方を学習させ、すべてのモードで同じ損傷程度になるようにすることで、検知精度が向上すると考えられる。

5. 結論

本研究では模型鋼アーチ橋を対象として、損傷時の固有振動数のみを特徴量とした NN を用いて複数損傷検知を行った。その結果、NN を用いることで複数/単数損傷の分類、損傷部材・損傷位置の分類を 80%以上の認識率で行うことができ、固有振動数のみでも特徴量として有効であった。一方、誤認識された損傷に対しては、

表-2 NN の構成・学習データ・認識データ

	ニューラルネットワークの構成			学習データ	認識データ
	中間層数	活性化関数		損傷程度 (%)	損傷程度 (%)
		中間層	出力層		
N1	60, 106	tanh	softmax	全データ	全データ
N2	5, 7	tanh		6.25, 25, 37.5, 67.5, 75	12.5, 50
N2-1	123	恒等関数			
N2-2	217	ジグモイド			
N2-3	3	ジグモイド			
N3	7, 178	tanh		25-25, 50-25, 75-25, 75-50, 25-75, 50-75, 75-75	25-50, 50-50
N3-1	132, 110, 204	ジグモイド			
N3-2	4	恒等関数			
N3-3	22	恒等関数			
N3-4	126	恒等関数			
N3-5	78	tanh			
N3-6	85	ReLU			

表-3 NN1 の結果


	予測ラベル	
	単数	複数
正解ラベル	100 (83.3%)	20 (16.7%)
単数	11 (7.1%)	145 (92.9%)

※正解：背景紫、不正解：背景黄


表-4 NN2, 3 の結果

		認識率 (正解数/総数)			
N2		1.00			
N2-1~3		1.00			
N3	補-補	0.86	吊-横	0.92	
	補-吊	0.90	横-横	1.00	
	補-横	0.97	吊-吊	1.00	
N3-1~6		1.00			

●: 認識 ●: 学習 (○%は損傷程度)



(a) Ga2(12.5%)が Ga2 に正しく認識されたケース



(b) Ga2(12.5%)–Ca3(50%)が Ga1 に誤認識されたケース

図-3 認識データと学習データの比較

出力された損傷の学習データと認識データの関係性をすべてのモードで一定とすることに、精度向上の余地があると考えられる。

<参考文献>

- 1) Paral, A., Singha Roy, D.K. & Samanta, A.K.: Application of a mode shape derivative-based damage index in artificial neural network for structural damage identification in shear frame building, J Civil Struct Health Monit 9, 411–423, 2019.
- 2) Akahoshi, K., Hayashi, G., Chen, Y. and Yamaguchi, T.: Damage identification of corroded arch bridge using vibration characteristics and rotational angle, Life-Cycle of Structures and Infrastructure Systems (IALCCE 2023), pp.562-569, 2023.7