

第VI部門

AI および路面性状測定車を用いた伸縮装置の損傷診断手法に関する有効性の検証

阪神高速技術株式会社	正会員	○太田 美由貴
阪神高速技術株式会社		皆川 勝人
株式会社建設技術研究所		法橋 広歩
株式会社建設技術研究所		中田 隆史
株式会社建設技術研究所		櫻井 圭輔

1. はじめに

阪神高速道路は総延長 258.1km のうち橋梁部が約 8 割であり、約 2 万レーンを超える伸縮装置を維持管理している。定期点検では、路面性状測定車で撮影した膨大な数の路面画像を元に点検技術者が目視で確認して損傷を診断しているが、路面画像の診断には多大な時間と労力を要する。構造物の老朽化による損傷の増加や将来的な技術者の不足が懸念される中、点検においても効率化・省力化が求められている。そこで AI の画像認識技術を一次スクリーニングに用いるための診断手法を試行し、その有効性を検証した。

2. 検証方法

阪神高速道路に設置されている伸縮装置は、鋼製、簡易鋼製、ゴム製、ノージョイント等のタイプがあるが、本検証では比較的損傷に特徴のあるゴム製伸縮装置を対象とした。従来の損傷診断でも使用している路面性状測定車で撮影した路面画像は、照度や影による画像のバラツキがなく、鮮明で安定した画質の路面画像であることから、本検証においてもモデル構築および性能評価に用いることとした。路面性状測定車で撮影した路面画像及び検知対象となるゴム製伸縮装置の損傷種別を図-1 に示す。

ベースとなる AI モデルとして、画像認識分野の中でも物体検出に使用されており、高い検知精度で短時間での検出が可能なモデルである YOLOv5 を選定し、教師有り学習により学習した深層学習モデルを構築した。深層学習は大量の画像を用いて学習を進めることが必要なため、深層学習に必要な枚数を 1 枚の画像に対して回転・反転・ズームなどの加工を行い、擬似的に学習データを増加させる拡張処理を行った。また、物体検出を行うモデルでは、学習にあたり検知対象に座標情報を情報付けする必要があるため、labeling を使用したアノテーション基準を設定した。設定した基準を表-1 に示す。損傷の判定における共通事項として、人間の目でも判断に迷う損傷についてはアノテーションの対象外とした。

3. 評価と考察

誤検知に関する指標である適合率と未検知に関する指標である再現率を用いて検知精度を評価した。




図-1 路面画像および損傷種別

検知対象	アノテーションの基準
ゴム製伸縮装置の抽出	画角内のゴムジョイントを一括で囲う（斜めに映っている場合も同様）
ゴム破れの判定	ゴムジョイント表面がはがれ、内部の鋼板が見える部分
ゴム浮きの判定	盛り上がりが顕著に確認される部分にアノテーションを実施
ゴムき裂の判定	溝付近に発生する横方向の線をゴム亀裂と設定

表-1 アノテーション基準

Miyuki OTA, Masato MINAGAWA, Hiromu HOKKYO, Takashi NAKATA and Keisuke SAKURAI
miyuki-ota@hex-eng.co.jp

ゴム製伸縮装置抽出モデルの評価結果を表-2 に示す。誤検知に関する指標である適合率と未検知に関する指標である再現率を用いて検知精度を評価した。ゴム製伸縮装置抽出モデルの評価結果を表-2 に示す。ゴム製伸縮装置とそれ以外の種類の伸縮装置を含む点検画像 777 枚に対して、ゴム製伸縮装置の検知を行ったところ適合率 99.1%，再現率 94.9% と非常に高い精度が得られた。特定の種類のジョイントの誤検知，画像サイズの異なる事例で未検知が見られたが，学習データの追加により改善の余地があると考えられる。

次に 3 種類の損傷診断モデルについての評価結果の一部を表-3 に示す。点検画像 558 枚に対して，トレードオフの関係にある適合率と再現率のバランスの良い値を探索するため，閾値を段階的に調整し，精度比較を行った。損傷診断の一次スクリーニングとしては損傷を見逃さないことが重要であることから，再現率に着目した。

ゴム破れにおいては，閾値 0.10 の場合に再現率 93.8% と非常に高い結果が得られたが，テストデータ数が少なく精度評価が十分ではないため，データ数を増やして再評価を行う必要がある。ゴムき裂の検知においては，閾値を上げる効果が薄く，最も有効な閾値 0.05 において再現率 73.4% であった。伸縮装置が斜めに映っている事例やはっきりとき裂が確認できる事例の未検知があるが，学習事例の追加やアノテーションの見直しにより精度が改善されることが考えられる。ゴム浮きの検知においては，閾値 0.05 の場合に再現率は 94.5% と非常に高かったが，比較的是っきりとした損傷の未検知事例も見られた。ゴム浮きは多様な形状で発生するため，学習事例を増やすことで汎用性が向上すると考えられる。なお，いずれの損傷も適合率が低い理由は汚れや小さな傷を損傷と判定していることが理由として挙げられる。

AI を用いた場合，診断に要する時間は 1 枚当たり 0.27 秒であった。従来の点検技術者による診断の場合，損傷状況にもよるが画像 1 枚当たり 30 秒程の時間を要するため，AI の活用は時間短縮および労力削減につながる。

検知対象	正解数	検知数			閾値	適合率	再現率	検知事例		
		正	誤	未				正検知	誤検知	未検知
ゴム製伸縮装置	367	545	5	29	0.10	99.1%	94.9%			

表-2 ゴム製伸縮装置抽出モデルの評価




検知対象	損傷箇所数	検知数			閾値	適合率	再現率	検知事例		
		正	誤	未				正検知	誤検知	未検知
ゴム破れ	16	15	23	1	0.10	39.5%	93.8%			
		14	6	2	0.30	70.0%	87.5%			
		14	6	2	0.35	70.0%	87.5%			
ゴムき裂	167	122	248	45	0.05	33.0%	73.4%			
		78	89	89	0.20	46.7%	46.7%			
		52	50	115	0.35	51.0%	31.1%			
ゴム浮き	367	347	369	20	0.05	48.4%	94.5%			
		303	150	64	0.20	66.9%	82.8%			
		265	87	102	0.35	75.3%	72.4%			

表-3 損傷診断モデルの評価

4. まとめ

本検証ではゴム製伸縮装置の損傷診断における AI の画像認識技術の活用について検証した。その結果，損傷抽出の一次スクリーニングとして有効な手法であることが明らかとなった。実運用に向けて更なる改善を行うことで，損傷診断に要する時間と労力を大幅に削減できると考えられる。ゴム製伸縮装置以外の種類の伸縮装置においても，同様に自動診断の手法を検証し，伸縮装置の損傷診断を一元化することが今後の課題である。