第I部門　　橋梁点検画像を用いた損傷程度判定に関する画像分類モデルと学習データ分布の影響評価

摂南大学大学院　理工学研究科　学生員　麻田　尚平
摂南大学　正会員　田井　政行

１．研究背景・目的

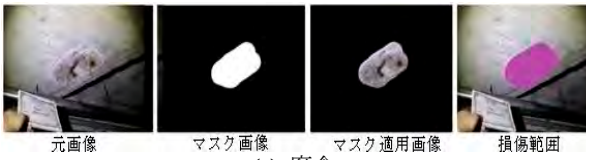
我が国では橋梁の老朽化が進行しており，効率的かつ信頼性の高い維持管理が求められている．近年，深層学習を用いた橋梁点検画像の損傷判定が進められている[1]が，損傷種類ごとのモデル比較や，学習データ分布が判定性能に与える影響は十分に検討されていない．そこで本研究では，xROAD の橋梁点検画像を用い，腐食および剥離・鉄筋露出を対象として，CNN 系 6 モデルと Transformer 系 1 モデルの計 7 モデルを比較した．さらに，不均衡条件と均等化条件を比較し，正解率，平均絶対誤差（MAE），重大誤り率およびクラス別再現率から判定性能を評価した．

２．使用データおよび研究方法

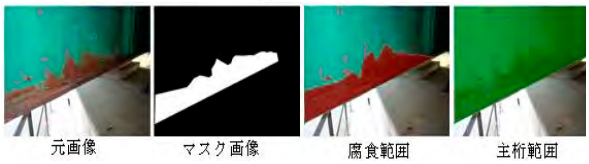
本研究では，xROAD の橋梁点検調書から主桁の損傷画像を抽出し，鋼部材の腐食およびコンクリート部材の剥離・鉄筋露出を対象とした．腐食は b，c，d，e の 4 クラス，剥離・鉄筋露出は c，d，e の 3 クラスに分類した．学習画像には，背景や周辺構造物の影響を低減するためマスク処理を適用した．腐食では，主桁に対する腐食の位置や広がりを考慮するため，腐食領域と主桁領域を強調した画像を用いた．剥離・鉄筋露出では，損傷部周辺の局所的な特徴を捉えるため，背景を除去して損傷領域を抽出した画像を用いた．対象損傷およびマスク処理例を**表-1** および**図-1** に示す．

表-1　対象損傷および使用画像





(a) 腐食



(b) 剥離・鉄筋露出

図-1　マスク処理例

表-2　損傷程度別の画像枚数

対象損傷	b	c	d	e	合計
腐食	1214	189	853	125	2381
剥離・鉄筋露出	-	996	864	243	2103

表-3　画像分類モデルの学習条件

項目	条件
学習画像枚数	500 枚，1000 枚，1500 枚，2000 枚
学習データ：検証データ	8：2
エポック数	30
バッチサイズ	16
学習回数	各条件 4 回

３．画像分類モデルおよび学習・評価方法

学習条件を表-3 に示す．テストデータには学習およびモデル選択に使用しない固定画像を用い，腐食は各クラス 10 枚の計 40 枚，剥離・鉄筋露出は c および d を各 11 枚，e を 5 枚の計 27 枚とした．また，同一原画像に由来する画像が学習・検証・テストデータ間で重複しないよう分割した．評価指標には，正解率，平均絶対誤差（MAE），重大誤り率およびクラス別再現率を用いた．損傷程度を b＝0，c＝1，d＝2，e＝3 として数値化し，MAE を式（1）より算出した．

$$MAE = \frac{1}{N}\sum_{i=1}^{N} | y_i - \hat{y}_i | \qquad (1)$$

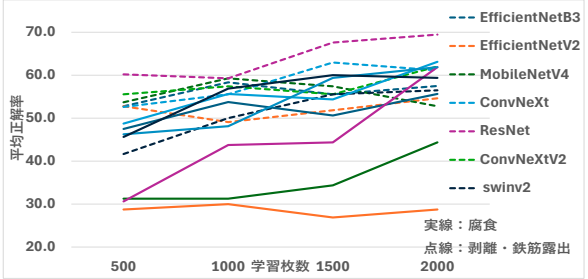


図-2　モデル別の平均正解率

ここで，Nはテスト画像数，y_iおよび$\hat{y}_i$は，それぞれ画像iの正解クラスと予測クラスの数値である．MAE は，予測が正解から平均して何段階ずれているかを表し，値が小さいほど良好である．さらに，正解クラスと予測クラスの差が 2 段階以上となる画像の割合を，式(2)により重大誤り率として算出した．

$$\text{重大誤り率} = \frac{1}{N}\sum_{i=1}^{N} 1(| y_i - \hat{y}_i | \geq 2) \times 100 \qquad (2)$$

また，各損傷程度の判定性能を確認するため，クラス別再現率を式（3）より算出した．

$$R_k = \frac{TP_k}{TP_k + FN_k} \times 100 \qquad (3)$$

ここで，R_kはクラスkの再現率，TP_kおよびFN_kはそれぞれ正解数および他クラスへの誤分類数である．

Shohei Asada, Masayuki Tai
2652m102as@edu.setsunan.ac.jp

4. 画像分類モデルの比較結果

図-2 に平均正解率，図-3 に平均再現率，図-4 に平均 MAE および平均重大誤り率を示す．腐食では，ConvNeXt の平均正解率が 63.1%で最も高かった．ConvNeXtV2 は平均 MAE が 0.538，平均重大誤り率が 13.8%で最小であり，ConvNeXt も 0.550，14.4%と近い値を示した．したがって，正解率を重視する場合は ConvNeXt，誤判定の段階差や重大誤りの少なさを重視する場合は ConvNeXtV2 が良好であった．図-5 の Grad-CAM では，ConvNeXt が腐食部周辺に着目し，腐食範囲や色調変化を捉えた可能性がある．剥離・鉄筋露出では，ResNet の平均正解率が 68.5%，平均 MAE が 0.361 で最良であった．また，d の平均再現率は 88.6%と高かったが，e は 20.0%にとどまった．平均重大誤り率も 4.6%と最小値 3.7%に近かった．図-6 の Grad-CAM では，露出鉄筋や剥離境界への着目が確認され，局所的特徴を捉えた可能性がある．以上より，ResNet は全体として良好であった．

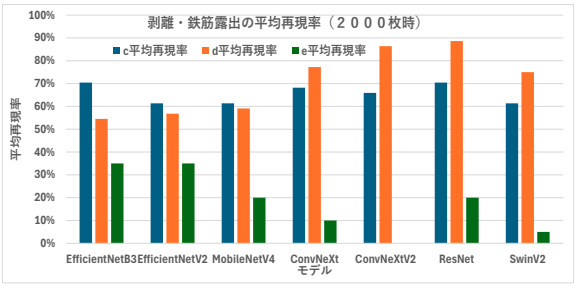


図-3 剥離・鉄筋露出に対するモデル別の平均再現率

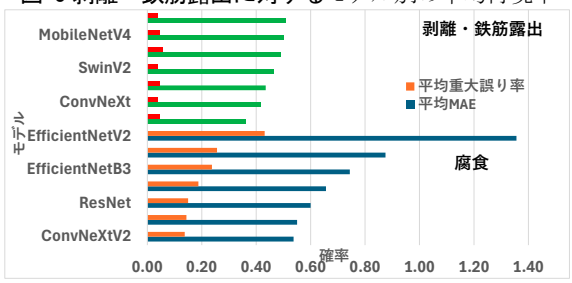


図-4 モデル別の平均 MAE および平均重大誤り率

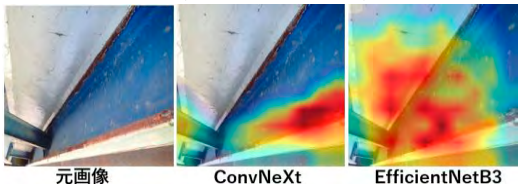


図-5 腐食画像に対する CNN モデルの Grad-CAM 例

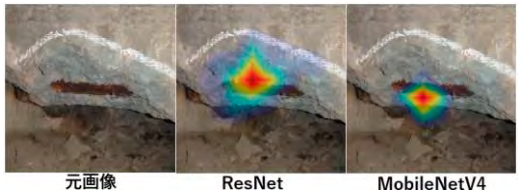


図-6 剥離・鉄筋露出画像に対する CNN モデルの Grad-CAM 例

5. 学習データ分布・データ拡張が判定性能に与える影響

損傷程度ごとの画像枚数に偏りがあるため，腐食では ConvNeXt，剥離・鉄筋露出では ResNet を用い，学習データ分布とデータ拡張の影響を比較した．不均衡条件では元のクラス比率を維持し，均等化条件では最少クラスに合わせて各クラスから同数を抽出した．また，原画像のみを 1 倍条件，反転画像を 1 枚追加したものを 2 倍条件とし，正解率とクラス別再現率を評価した．

腐食では，均等化により正解率が 1 倍条件で 40.0%から 52.5%，2 倍条件で 50.0%から 60.0%に向上し，特に c および e の再現率が改善した．また，均等化と 2 倍拡張を組み合わせた条件で最も高い正解率を示した．

一方，剥離・鉄筋露出では，不均衡・1 倍条件が正解率 77.8%で最も高く，均等化や拡張による改善はみられなかった．c の再現率は全条件で同一であったが，d および e は条件により変動した．以上より，学習データ分布と拡張の効果は損傷種類で異なり，画像特徴やクラス分布に応じた学習条件の設定が必要である．

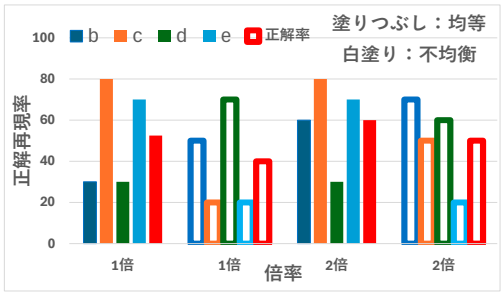


図-7 腐食における均等化条件と不均衡条件の比較

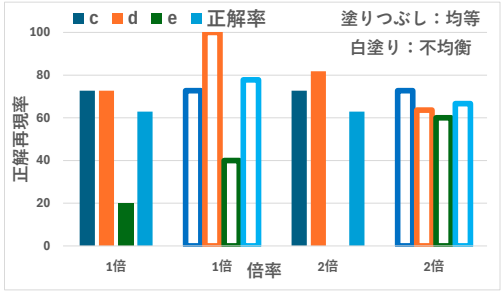


図-8 剥離・鉄筋露出における均等化条件と不均衡条件の比較

6. まとめ

腐食では，正解率を重視する場合は ConvNeXt，重大誤り率を重視する場合は ConvNeXtV2 が良好であった．一方，剥離・鉄筋露出では ResNet が良好な性能を示した．ただし，e はテスト画像枚数が少なく，再現率の解釈には留意が必要である．また，均等化とデータ拡張は腐食では有効であったが，剥離・鉄筋露出では明確な効果がみられなかった．以上より，損傷種類や評価目的，クラス分布に応じたモデルと学習条件の選定が必要である．

参考文献

1）西牟田裕介ら：直轄橋梁定期点検における損傷程度判定 AI に関する研究，AI・データサイエンス論文集，Vol.4，No.3，pp.135-141，2023.