

CNNによる画像認識・分類を用いたコンクリート橋点検画像の分析および活用法の提案

市民工学専攻：笹脇 壮太
指導教員：三木 朋広

1. 序論

現在、日本において道路橋を含めた社会インフラの老朽化が問題となっており、新技術を用いた維持管理の効率化が急務となっている。そこで本研究は、損傷程度や健全度評価の最終的な判断は技術者が行うという前提のもと、診断したい点検画像と類似の画像を検出するという目的のため、CNN（畳み込みニューラルネットワーク）を用いてコンクリート橋梁の点検画像から基本部材、損傷種類などを検出するモデルの作成・評価を行った。またクラスごとの検出結果の比較などを行い、適切なモデルにするための検討、考察を行った。そして最後に作成したモデルをどのように活用できるか検討を行った。

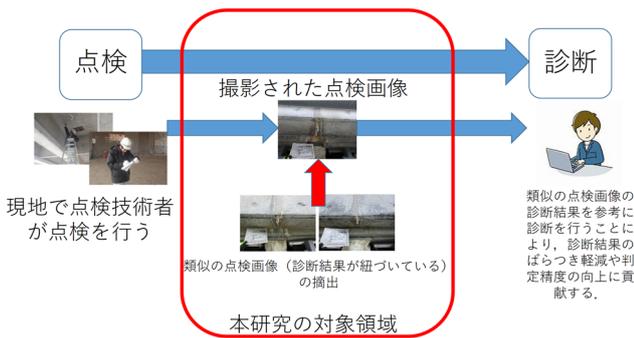


図-1 本研究の位置づけ

2. 解析概要

本研究の物体検出は、解析手法としてCNNのネットワークを使用しているYOLOv5を用いる。学習に必要な工程である、画像に対して物体がある位置とクラスの注釈をつけるアノテーションという作業をlabeling上で行い、学習・推論をGoogle Colaboratory上で行った。ハイパラメーターによる比較を行うため、Batch sizeを5, 10, 30とし、Epoch数は250とした。

(Batch size5だけ200とする)。以下の図-2のような解析フローとなる。学習・検証データは橋梁数を16、橋種をPC, RC, 混合、橋梁形式を中空床板橋、画像データ枚数を500、画像サイズを1024×768と設定した。検出クラスは基本部材、損傷種類、点検板・損傷種類、その他の4種類より21項目を設定した。検出クラス

は表-1に示す。

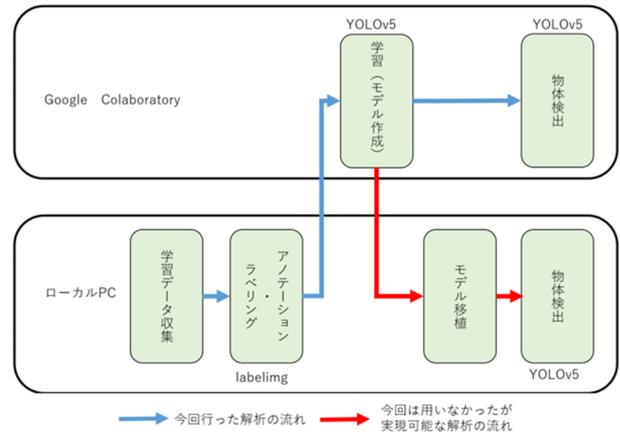


図-2 解析フロー

表-1 本研究における検出クラス

	クラス番号	クラス名	日本語表記
基本部材	0	balustrade	高欄・地覆
	1	road	舗装
	2	drainage basin	排水枿
	3	distributing pipe	配水管
	4	joint	伸縮装置（ジョイント）
	5	beam	桁・床版
	6	pier	橋脚
損傷種類	7	support	支承
	8	chalking line	チョーキング（線）
	9	chalking character	チョーキング（文字）
	10	crack	損傷（ひびわれ）
	11	eflo	損傷（漏水・遊離石灰・エフロ）
	12	corrosion	損傷（腐食）
点検板・損傷番号	13	check board	点検板
	14	5	損傷番号⑤（防食機能の劣化）
	15	6	損傷番号⑥（ひびわれ）
	16	7	損傷番号⑦（剥離・鉄筋露出）
	17	8	損傷番号⑧（漏水・遊離石灰）
	18	17	損傷番号⑰（その他）
その他	19	people	人・手
	20	ruler	定規類

キーワード 維持管理, 深層学習, コンクリート橋, 物体検出

3. 検出モデルの評価

2章で行った学習の評価指標として、適合率、再現率、mAP0.5, mAP0.5:0.95, 学習時間を用いた。図-3, 図-4より mAP0.5 は Epoch 数が増すごとに数値のばらつきが減り、130Epoch 付近で値は収束した。200Epoch 時点での値として差はほとんど見られなかった。Batch size 30 がほかの Batch size に比べて数値おおよびばらつきが収束するまでに時間がかかり、1Epoch ごとの学習進捗が遅いという結果になった。mAP 0.5:0.95 も mAP 0.5 と傾向は同じだが、全体的に値が微量ながら上昇し続ける結果となった。

Batch size を小さくするたびに学習の精度は上がるが、Epoch 数が一定値を超えると精度にほとんど差が見られなかった。Batch size を小さくしすぎると学習時間が大幅に長くなった。モデルを作成するにあたっては精度と学習時間を考慮して、最適な Batch size を見つけ出すことが重要である。



図-3 各 Batch size における mAP0.5



図-3 各 Batch size における mAP0.5:0.95

4. 学習モデルを用いた推論および考察

3章で行った Batch size 10 の学習モデルを使って学習データ以外の画像 100 枚に対して物体検出を行った。推論結果より以下のことがモデルの精度向上、改良のために必要と考えられる。

- 学習データを増やす。(今回学習した重みを再利用し、追加で学習を行う.)
- 基本部材においては、様々なパターンを学習させ

る必要がある。(距離, 撮影角度, 日中 or 夜間,) 特に高欄や排水柵など, 部材ごとにも多数の種類が存在するものは注意が必要。

- 損傷種類においては, 損傷箇所うまくアノテーションできない場合が多く, 良質な学習データの準備(誰がみても損傷箇所が分かる画像のみを使用)やクラスの再検討が必要であると考える。
- 点検板・損傷番号においては, 比較的検出できていた傾向があるので, 転移学習・ファインチューニングにより, 損傷番号のクラスの拡張も可能であると考える。
- 転移学習・ファインチューニングを用いて, クラスの拡張も可能であると考える。その際, クラスにおいて考えうるパターンをできるだけ網羅しながら学習させることが重要である。

5. 活用法の提案

現在国土交通省を中心に行われている点検 DB (データベース) の整備が完成すると, 全国の膨大な点検データを活用して精度の高い検出モデルの開発につながる。今回の基本部材, 損傷種類などを検出できるモデルが完成すれば, 点検画像の入力を行うと, 自動的に点検画像から設定されたクラスを検出し, 同様のクラスが含まれる画像を抽出できるというようなシステムが可能となる。また出力された画像から, 点検 DB を使って点検調書や補修履歴を逆引きすることにより, 過去の類似事例を参考にすることができ, 損傷種類や健全度の判定の補助ツールとなりえる。

このようなシステムが完成すれば, 診断の精度が上がる, 診断のばらつきを抑える, 点検から診断にかかる時間を短縮できる, 少ない人数で診断できる, 診断の知識が少ない人でも診断が可能になるなどのメリットが生まれる。

6. まとめ

本研究では, 人手不足やコストが懸念されているコンクリート橋梁の点検において, YOLOv5 を用いて画像の物体検出を行い, 精度を検証した。

解析では 21 項目のクラスを設定して, Batch size を変えて精度や学習時間を比較した。また推論では各クラスに対して精度向上のための考察を行った。

解析結果をもとに, 実用的な検出モデルの活用法を提案した。