

卒業論文概要書

Summary of Bachelor's Thesis

Date of submission: 02/01/2022

学科名 Department	情報通信	氏名 Name	中里 海斗	指導 教員 Advisor	渡辺 裕 ㊞
研究指導名 Research guidance	オーディオビジュアル 情報処理研究	学籍番号 Student ID number	1W182233-8		
研究題目 Title	混合教師あり学習による構造物表面の欠陥検出手法の検討 A Study on Defect Detection of Structured Surface by Mixed Supervised Learning				

1. まえがき

近年老朽化が進むインフラ設備が急増し、またそれらを点検・修繕する建設業従事者の高齢化も進行している。このような状況を踏まえ、ドローンを用いたセンシング技術やビッグデータ解析技術等の先端技術をメンテナンス業務に活用する試みが盛んに行われている。

本研究では、機械学習を用いてメンテナンス業務を効率化することを目的とする。構造物の画像を入力として、画像中にひび割れが含まれるか否かを判断する混合教師あり学習モデルについて検討する。

2. 関連研究

2.1 異常検知

異常検知(Anomaly Detection)とは機械学習タスクの一つであり、正常とは振る舞いの異なるデータを見つけることが主目的となる。医用画像を用いた疾患部位の特定や迷惑メール検知、製造物の不良品検査等に活用される。

2.2 混合教師あり学習

混合教師あり学習とは、完全教師あり学習(タスクに適した教師データを用いた学習)と弱教師あり学習(あるタスクに使用するモデルに対し、別のタスクに使用するために作成されたデータを用いた学習)を併用してモデルを最適化する手法である。Jakob Bozicらは、セグメンテーションサブネットワークと分類サブネットワークを組み合わせる異常検知するモデルを構築した。必要とする精度に合わせてアノ

テーションコストを調整できるため、人材不足のインフラ業界に適していると考え、本研究でもこのモデルを採用した。

3. 提案手法

まず、ひび割れに特化したデータセットを用いた場合の混合教師ありモデルの振る舞いを確認するため、予備実験として CRACK500 を用いて学習と評価を行った。算出した AP (Average Precision)と、誤検出および見逃した画像例を表 1 と図 1 に示す。なお、AP とは分類タスクの評価指標の一種である。不均衡データを使用してモデルを学習・評価する際によく用いられる。

表 1 予備実験結果

rate[%]	0	5	10	100
AP	0.9137	0.9176	0.8894	0.9559



図 1 予備実験による誤検出および見逃し画像例

図 1 から、ひび割れの勾配が緩やかで黒ずんで見える画像、および黒斑点を含む画像を誤判定していると考えられる。

これらの課題を解決するために、メディアンフィルタによる前処理の追加を提案する。提案の全体像を図 2 に示す。生画像に対してメディアンフィルタを適用し、大局的な輝度変化をもつ画像を生成する。その後生画像と生成画像を用いて平均化処理を行い、学習用データセットを作成する。




図 2 提案手法の全体像

4. 実験

本研究では、ひび割れあり画像 500 枚およびひび割れなし画像 1846 枚をグレースケールに変換して学習に用いた。前処理を施して学習したモデルと、施さずに学習を行ったモデルの AP の比較を表 2 に示す。

また、前処理前後で新たに正しく判定できた画像例を図 3 に、誤判定した画像例を図 4 に示す。

表 2 従来手法と提案手法の AP

rate[%]	0	5	10	100
従来手法	0.9137	0.9176	0.8894	0.9559
提案手法	0.8995	0.9003	0.9005	0.9482




図 3 改善画像例(左: 生画像, 右: 処理画像)




図 4 悪化画像例(左: 生画像, 右: 処理画像)

結果から、精度の向上には至らなかったが対象とした課題を解決することはできた。精度未向上の原因として、ひびの深度が低い画像はフィルタ処理に際して更に輝度差の低下が生じた点、影により局所的に輝度差が大きく変化する画像は処理により更に境界が際立ってしまった点が考えられる。ひび割れの深度が高いデータや照度の変化が緩やかな環境下で撮影された画像に対して本手法を適用すれば、従来手法と比較して有意な精度向上がみられると考える。

5. まとめ

本研究では、ひび割れ画像に特化した CRACK500 を用いて混合教師ありモデルの学習を行い、ひび割れの検出手法について検討した。その際、データセットの前処理としてメディアンフィルタを用いた処理を施すと、勾配の緩やかなひび割れの見逃しと斑点による誤検出を軽減することができた。

今後の課題としては、フィルタサイズの調整や他の前処理の追加を検討して想定外の影響による精度低下の改善案を模索しつつ、腐食や破断等他の点検項目を検出・分類していきたい。

参考文献

- [1] Bozic, J., Tabernik, D., & Skočaj, D. (2021). Mixed supervision for surface-defect detection: from weakly to fully supervised learning. *Comput. Ind.*, 129, 103459.

2021年度 卒業論文

混合教師あり学習による
構造物表面の欠陥検出手法の検討

A Study on Defect Detection of Structured Surface
by Mixed Supervised Learning

指導教員 渡辺 裕 教授

提出日：2022年2月1日

早稲田大学 基幹理工学部 情報通信学科

1W182233-8

中里 海斗

目次

第1章 序論.....	1
1.1 研究の背景.....	1
1.2 本研究の目的.....	1
1.3 関連研究.....	2
1.4 関連研究の解決すべき課題.....	2
1.5 本論文の構成.....	2
第2章 関連技術.....	3
2.1 まえがき.....	3
2.2 畳み込みニューラルネットワーク (CNN).....	3
2.3 異常検出.....	4
2.4 種々の学習.....	4
2.4.1 教師なし学習.....	4
2.4.2 弱教師あり学習.....	4
2.4.3 混合教師あり学習.....	5
2.5 メディアンフィルタ.....	5
2.6 むすび.....	6
第3章 提案手法.....	7
3.1 まえがき.....	7
3.2 データセット.....	7
3.3 予備実験.....	8
3.3.1 実験の概要.....	8
3.3.2 予備実験の結果.....	8
3.3.3 予備実験の考察.....	8
3.4 提案手法.....	10
3.5 むすび.....	11
第4章 提案手法の検証実験.....	12
4.1 まえがき.....	12
4.2 実験の概要.....	12
4.3 データセット.....	12
4.4 評価指標.....	13
4.5 実験結果.....	13
4.6 考察.....	16
4.7 むすび.....	16
第5章 結論と今後の課題.....	17
5.1 結論.....	17
5.2 今後の課題.....	17
謝辞.....	18
参考文献.....	19
図一覧.....	20
表一覧.....	21

第1章 序論

1.1 研究の背景

近年老朽化が進むインフラ設備が急増し、またそれらを点検・修繕する建設業従事者の高齢化も進行しており、より効率的なメンテナンス技術が求められている。1945年に太平洋戦争が終結後、1964年の東京オリンピック大会の開催決定を機に大規模なインフラ整備が行われた。道路整備五箇年計画をもとに主要道路の整備が進められ、1964年に東海道新幹線および地下鉄丸ノ内線が開通した。上下水道も整備され、生活の基盤が整ったとともに経済成長を促す結果となった[1]。一方で、昨今道路橋やトンネルといった社会資本の老朽化が問題視されている。例えば建設後50年以上経過する道路橋の割合について、2018年3月には約25%であったものが、2033年3月には約63%にまで増加することが予想される[2]。加えて、建設業の担い手不足も顕在化している。現在建設業技能者の約3分の1は55歳以上となっており、他産業と比較して高齢化が進行している[3]。

このような状況を踏まえ、官民の双方でインフラの老朽化および人手不足対策が打ち出されている。国土交通省は、維持管理と更新に係るトータルコストの縮減およびインフラメンテナンスの高度化・効率化等が必要であるとした。特に、インフラの機能に不具合が生じてから対策を行う「事後保全」ではなく、インフラの劣化状況や利用状況を踏まえて、不具合が生じる前に計画的に修繕等の対策を行う「予防保全」への転換が始まっている。一方高速道路の維持管理を行うNEXCO東日本では、ICTや機械化を積極的に導入し、新たなメンテナンス体制を構築する「SMH(スマートメンテナンスハイウェイ)構想」を公表した[4]。JR東日本でも、人工知能を用いて自動で良否判定を行う架線設備モニタリングシステム等のスマートメンテナンスの取り組みを推進している[5]。先に挙げた省庁や公共機関以外の企業においても、ドローンを用いたセンシング技術やビッグデータ解析技術等の先端技術をメンテナンス業務に活用する試みが盛んに行われている。

1.2 本研究の目的

本研究では、機械学習を用いてメンテナンス業務を効率化することを目的とする。一般的なメンテナンス業務は、「計画」、「措置」、「点検」、そして「診断」というサイクルで行われる[6]。さて、国土交通省道路局が作成する道路橋の定期点検要領[7]にある部材の代表的な変状を表1-1に示す。本研究では、目視点検による作業員の手間と労働災害のリスクが大きい「点検」のフェーズに焦点をあてる。また数ある変状のうち、最も代表的なコンクリート部材のひび割れ検出を試みる。具体的には、構造物の画像を入力として画像中にひび割れが含まれるか否かを判断する機械学習モデルについて検討する。本研究により、老朽化や高齢化が問題視されるインフラ業の点検業務に関し、更なる業務効率化に繋がるだろう。

表 1-1 変状の種類

鋼部材	コンクリート部材	その他
腐食	ひび割れ	支承の機能障害
亀裂	底版ひび割れ	その他
破断	その他	
その他		

1.3 関連研究

対象物の表面にあるサビや亀裂等の欠陥を検出する研究に，Jakob Bozicらの手法がある[8]．必要とする精度に応じてアノテーションコストや計算時間を調整できる，工業生産品の表面欠陥検出手法である．Papers With CodeのDefect Detectionタスクにおいて，令和4年1月現在State-of-the-Artを達成している．四つの工業生産品データセットでモデルを実行し，完全教師データを少量利用することで完全教師モデルに匹敵する精度を得ている．詳細は2.4.3項にて述べる．

1.4 関連研究の解決すべき課題

Jakob Bozicらの手法は，人員が不足しているインフラ構造物のメンテナンス業務において，求める精度に応じてアノテーションコストを削減可能な点で非常に有用である．一方，研究では産業生産品のデータセットのみでモデルの検証がなされていた．構造物中には汚れや撮影時の影等があり，特有の影響を考慮する必要がある．本研究では，ひび割れの検出に適したデータセット(CRACK500)を用いてモデルを学習し，本課題に対処する．

1.5 本論文の構成

本論文の構成を以下に示す．

第1章は本章であり，本研究の背景，目的，関連研究について述べる．

第2章では，本研究に関連する技術について述べる．

第3章では，予備実験およびその結果を踏まえて本研究で提案する手法について述べる．

第4章では，提案手法を検証する実験，結果および考察について述べる．

第5章では，本論文の結論と今後の課題について述べる．

第2章 関連技術

2.1 まえがき

本章では、本研究で用いる技術について述べる。まず、畳み込みニューラルネットワーク (CNN) とそのタスクの一種である異常検出について言及する。次いで、機械学習の様々な学習法を示し、最後にメディアンフィルタについて述べる。

2.2 畳み込みニューラルネットワーク (CNN)

畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) は機械学習の一種であり、特に画像処理の分野で広く活用されている。図2-1に示すように、まずは入力画像に対して多層の畳み込みフィルタを適用し、エッジの鋭さや色など、画像の特徴を抽出する。そして得られた特徴量をもとに全結合層を経てクラスに分類し、入力画像のその識別結果を出力する。さて、何層にもわたる畳み込みフィルタはそれぞれ固有のパラメータを保有しており、入力画像中の異なる特徴を取り出すこととなる。他方、全結合層内には多数のノードが含まれており、こちらも重みパラメータを保有する。モデルの学習では大量の画像を用いて幾度も入出力を繰り返しながら、それぞれ最適なパラメータの探索が行われる。ゆえに一般的には、学習の教師ともいえる画像の集まり (データセット) の規模が大きくなるほど、高性能なモデルを構築できる。

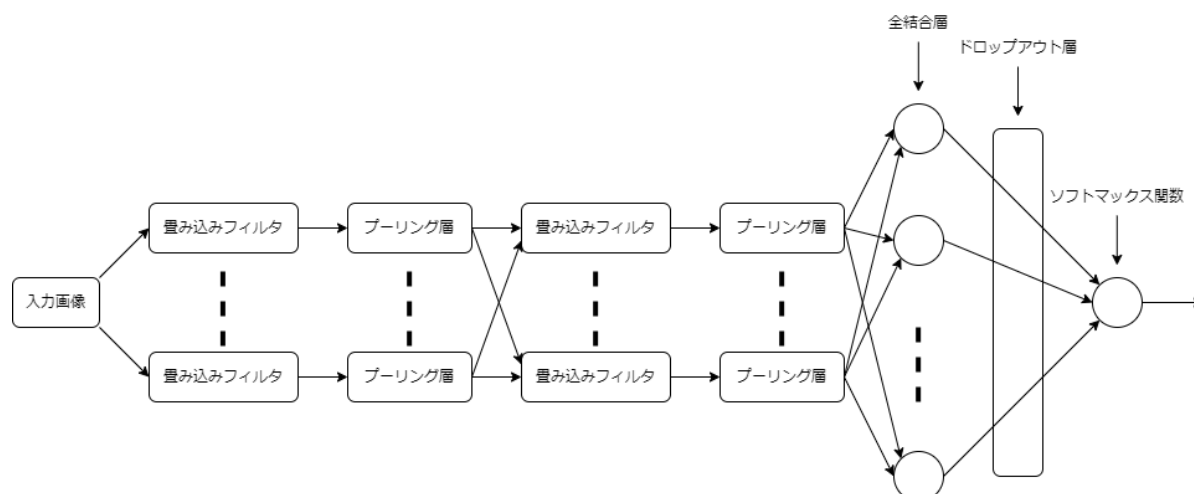


図 2-1 畳み込みニューラルネットワークの基本構成

2.3 異常検出

異常検出とは異常検知(Anomaly Detection)とも呼ばれる機械学習のタスクの一つである。正常とは異なる振る舞いをするデータを見つけることが主目的となる。医用画像を用いた疾患部位の特定や迷惑メール検知、製造物の不良品検査等に活用される。

2.4 種々の学習

機械学習は、正解(教師)データ(異常検出においては異常を含むデータ)の有無によって大別される。加えて、特殊な教師データを用いた学習方法も存在する。本節では代表的な手法を挙げ、適宜種々の学習による異常検出の手法について述べる。

2.4.1 教師なし学習

教師なし学習とは、異常を含むデータを使用せず、正常データのみでモデルを学習する手法である。異常検出手法の大多数が教師なし学習である。無論、正常データに対して異常データのサンプル数が圧倒的に少ないためだ。教師なし学習による異常検出では、正常データは一定の分布内に凝縮するという原理に基づき、外れ値を検出することで入力データを分類する。例えば、Ano-GAN[9]は生成器と識別器という2種類のネットワークから構成される。生成器はランダムノイズを入力として、正常データに可能な限り類似するデータの生成を学習する一方、識別器は与えられたデータが事前に与えられた正常データか、生成器からの出力かを判断しながら学習を進める。異常データが入力されると生成器はうまくデータを生成できず、結果入力データが異常であると識別できる。

2.4.2 弱教師あり学習

弱教師あり学習とは、あるタスクに使用するモデルに対し、別のタスクに使用するために作成されたデータを用いて学習することを指す。モデルのパフォーマンス低下は避けられないが、アノテーションコストを大幅に削減できる。例えば、Amy Bearmanら[10]はセマンティックセグメンテーションのタスクに対し、図2-2のように画像内の全てのピクセルにクラスラベルを割り当てる代わりに画像の一部のみにクラスラベルを付与した教師データを作成した。小さな教師データ作成コストで一定以上の精度を達成している。




図 2-2 弱教師あり学習の例

2.4.3 混合教師あり学習

混合教師あり学習とは、完全教師あり学習(タスクに適した教師データを用いた学習)と弱教師あり学習を併用してモデルを最適化する手法である。1.3節で述べたJakob Bozicらの手法は混合教師あり学習に該当する。Jakob Bozicらは画像分類のタスクに対し、画像毎に正常異常のラベルを付与した教師データ(弱教師データ)を用いてモデルを学習した。その後異常画像に対し、異常箇所についてピクセルごとにセグメンテーションを行い完全教師データの作成を行った。そして一部の弱教師データを完全教師データに置き換え、その割合と分類精度の関係を検証した。結果としておよそ5-10%の完全教師データを混合して学習を行うと、実用に足る精度を得られると主張した。学習に際して使用したモデルの構造を表2-1に示す。大きくセグメンテーションサブネットワークと、分類サブネットワークで構成される。前者で完全教師データの情報を利用し、後者で弱教師データを用いる。

表 2-1 モデルの構造

セグメンテーションサブネットワーク			分類サブネットワーク		
Layer	Kernel size	Features	Layer	Kernel size	Features
2x Conv2D	5x5	32	Max-pool	2x2	1025
Max-pool	2x2	32	Conv2D	5x5	8
3x Conv2D	5x5	64	Max-pool	2x2	8
Max-pool	2x2	64	Conv2D	5x5	16
4x Conv2D	5x5	64	Max-pool	2x2	16
Max-pool	2x2	64	Conv2D	5x5	32
Conv2D	5x5	1024			
Conv2D	1x1	1			

2.5 メディアンフィルタ

メディアンフィルタとは、ノイズを除去する前処理手法の一つである。近傍の画素値を取得し、注目画素(中央の画素)を近傍画素の中央値で置き換える処理を行う。周辺の飛び抜けた値に左右されることがないため、図2-3のようにゴマ塩ノイズの除去に活用されることが多い。図2-3において、左が元画像、中央がランダムにゴマ塩ノイズを付与した画像、右がメディアンフィルタのフィルタサイズを3として適用した画像である。エッジを残しつつノイズ処理できることも特徴である。




図 2-3 ゴマ塩ノイズの除去

2.6 むすび

本章では、本研究で用いる技術を紹介した。2.2節では畳み込みニューラルネットワークを、2.3節では機械学習タスクの一つである異常検出について述べた。また、2.4節でモデルの学習手法を述べ、2.5節にて前処理の手法について述べた。

第3章 提案手法

3.1 まえがき

本章では、まず予備実験としてひび割れ画像を集めたデータセット (CRACK500) を用いて関連研究のモデルを学習, テストした結果を示す. 次いで, その結果から得られた課題を解決する手法を提案する.

3.2 データセット

多数のひび割れ画像を含むデータセットに, CRACK500 [11] [12] がある. 本データセットには, Fan YangがアメリカのTemple Universityキャンパス内で撮影した舗装のひび割れ画像が500枚含まれ, 各画像は1000ピクセル以上のひび割れを含む640×360ピクセルの16枚に分割されている. ひび割れを含まない画像を用意するため, 本研究では分割前の画像を用いてひび割れを含まない画像を作成した. 図3-1に, positive画像(ひび割れを含む画像)とpositive画像のひび割れ箇所をセグメンテーションした画像(GT: グラウンドトゥルース), およびnegative画像(ひび割れを含まない画像)をいくつか示す.




図 3-1 CRACK500の画像例

3.3 予備実験

3.3.1 実験の概要

ひび割れに特化したデータセットを用いた場合の2.4.3項で示したモデルの精度を検証するため、予備実験としてCRACK500を用いて学習とテストを行う。その際、異常箇所をセグメンテーションした教師データ(完全教師データ)の割合と検出精度の確認をするため、完全教師データをpositive画像に対し0, 5, 10, 100%の4通りの割合で含むよう学習・テストデータを調整して精度を算出した。

3.3.2 予備実験の結果

各完全教師データの割合に対するAP (Average Precision)とAUROC (Area Under Receiver Operating Characteristic Curve)を表3-1に示す。なお、評価指標であるAPとAUROCについては4.4節で詳しく説明する。表3-1より、ひび割れに特化したデータセットを用いた場合でも高精度にひび割れを検出できることが確認できた。

表 3-1 完全教師データの割合に対するAPとAUROC

rate [%]	0	5	10	100
AUROC	0.9178	0.9580	0.9184	0.9840
AP	0.8501	0.9083	0.8683	0.9457

3.3.3 予備実験の考察

予備実験の結果から、第1章に述べた関連研究における課題は概ね解決できたと考えられる。しかしながら同時に、精度の低下を引き起こしうる要素をいくつか確認した。

そこで、テスト結果のうちひび割れの見逃し画像(positive画像をnegativeと出力)と、誤検出した画像を抜粋して図3-2, 図3-3に示す。図3-2から、(1)ひび割れが画像中の端に分布しているもの、(2)ひび割れの勾配が緩やかで黒ずんで見えるもの、および図3-3から(3)局所的に存在する黒い模様、の3点がモデルの精度低下をまねいた主な原因と考えられる。



図 3-2 予備実験による見逃し画像例



図 3-3 予備実験による誤検出画像例

3.4 提案手法

3.3.3項で得られた分析結果に対し、(2)(3)を解決する手法を提案する。学習データの前処理として、2.5節で述べたメディアンフィルタを用いて、画像中の緩やかな輝度変化と斑点模様の軽減を行う。まず、生データをそのまま使用した精度と、グレースケール画像に変化させて算出した精度を表3-2に示す。

表 3-2 生画像とグレースケール画像のAPおよびAUROC

rate[%]		0	5	10	100
生画像	AUROC	0.9178	0.9580	0.9184	0.9840
	AP	0.8501	0.9083	0.8683	0.9457
グレースケール画像	AUROC	0.9591	0.9637	0.9494	0.9840
	AP	0.9137	0.9176	0.8894	0.9559

図3-2から、ひび割れ検知のタスクにおいてはRGB成分の検出精度に対する寄与は小さいと考えられる。そこで、図3-3のように生データに対しグレースケール変換を行う。その後、図3-4のようにフィルタサイズ91×91にてメディアンフィルタによる処理を施す。この処理により、エッジの特徴をある程度残したうえで大局的な色の変化のみをもつ画像を得ることができる[13]。




図 3-4 グレースケール画像例



図 3-5 メディアンフィルタにより処理した画像例

その後、式(3.1)のように正規化することで、図3-6のような緩やかな輝度変化や暗い斑点模様の輝度を小さくした画像を得ることができる。

$$I_c(x, y) = 128I_a(x, y)/I_b(x, y) \quad (3.1)$$




図 3-6 提案手法による処理の例

3.5 むすび

本章では、3.2節で本研究にて使用するひび割れに特化したデータセットについて詳細を述べた。その後3.3節にて予備実験の概要と結果を述べ、精度低下を招く原因を分析した。最後に、3.4節で得られた課題に対する提案手法を述べた。

第4章 提案手法の検証実験

4.1 まえがき

本章では，提案手法にて前処理を施したデータセット (CRACK500_unshadow) を用いて行った検証実験の概要，評価指標，実験結果および考察について述べる．

4.2 実験の概要

CRACK500_unshadowを用いて混合教師あり学習を行い，完全教師データの割合を0, 5, 10, 100%に変化させて精度を評価する．実験に際して設定したハイパーパラメータを表4-1に示す．

表 4-1 ハイパーパラメータ

バッチサイズ	学習率	エポック数
10	0.01	80

4.3 データセット

学習およびテストに使用したデータセットの各クラスのデータ数を表4-2に示す．なお，画像サイズはすべて640×360である．

表 4-2 CRACK500_unshadowのデータ数

クラス	データ数
train_positive	500
train_negative	1846
test_positive	150
test_negative	1102

4.4 評価指標

実験で使用した評価指標であるAUROCとAPについて述べる。AUROCとAPはそれぞれROC曲線とPR曲線の曲線下の面積である。さて、ROC曲線とPR曲線について詳しく述べるために、2値分類における混同行列を表4-3に示す。

表 4-3 2値分類の混同行列

		モデルの予測	
		Positive	Negative
真値	Positive	TP(True Positive)	FN(False Negative)
	Negative	FP(False Positive)	TN(True Negative)

ここで、偽陽性率(FPR: False Positive Rate)と真陽性率(TPR: True PositiveRate)はそれぞれ

$$FPR = \frac{FP}{FP + TN} \quad (4.1)$$

$$TPR = \frac{TP}{TP + FN} \quad (4.2)$$

のように算出される。ROC曲線は横軸にFPR、縦軸にTPRをプロットして描く曲線である。モデルの評価に際しては、ROC曲線のAUC(曲線下の面積)が1に近づくほど、真偽を正確に判定できているといえる。しかしながら、例えばpositiveデータ数が5、negativeデータ数が9995のテストセットで評価する際、すべてをnegativeと判定してもTPRは高い一方、FPRの分母が大きくなり(=FPRが0に近づく)、AUROCが高くなってしまう。ゆえに、positiveデータとnegativeデータ数が大きく異なる(=不均衡データ)際、AUROCによるモデル性能の比較は適切でないことが多い。

一方PR曲線は、横軸に再現率(Recall)、縦軸に適合率(Precision)を取って描く。RecallとPrecisionは次のように算出される。

$$Recall = \frac{TP}{TP + FN} \quad (4.3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4.4)$$

よってPR曲線の曲線下の面積であるAPは、positiveデータを正しく判定した数により大きく変動するため、不均衡データを使用するモデルの評価に適していると考えられる。

4.5 実験結果

完全教師データの割合を0, 5, 10, 100%と変化させ、CRACK500_unshadowを用いて学習したモデルを用いてAPおよびAUROCを算出した結果を表4-4に示す。なおグレースケール画像とは、表3-2でも示した通り前処理を適用せずCRACK500のグレースケール化のみ行ったデータを使用して、モデルを学習し算出したAPおよびAUROCである。

表 4-4 CRACK500_unshadowを用いて算出したAPとAUROC

rate[%]		0	5	10	100
グレースケール画像	AUROC	0.9591	0.9637	0.9494	0.9840
	AP	0.9137	0.9176	0.8894	0.9559
提案手法	AUROC	0.9499	0.9520	0.9528	0.9750
	AP	0.8995	0.9003	0.9005	0.9482

また，提案手法によるテスト結果で見逃しを改善できた画像例を図4-1に，誤検出を改善できた画像例を図4-2に示す．




図 4-1 見逃し改善の画像例(左: グレースケール画像, 右: 提案手法処理)




図 4-2 誤検出改善の画像例(左: グレースケール画像, 右: 提案手法処理)

他方, 提案手法により見逃しを引き起こしてしまった画像例を図4-3, 誤検出を引き起こした画像例を図4-4に示す.




図 4-3 見逃した画像例(左: グレースケール画像, 右: 提案手法処理)




Fig. 4.1 誤検出した画像例(左: グレースケール画像, 右: 提案手法処理)

予備実験の結果に基づき、メディアンフィルタによる前処理を活用して精度改善を試みたが、向上してほしいAPはもとよりAUROCの増加も見られなかった。

4.6 考察

数値的な精度の向上は見られなかったが、予備実験の結果からターゲットとした原因の解消をすることはできた。提案手法により新たに見逃されたデータから、ひびが浅く近傍ピクセルとの輝度差が小さいひび割れに関して、フィルタの処理により更に輝度差が小さくなり、判定の閾値を下回ってしまったと考えられる。また新たに誤検出されたデータから、局所的に輝度差が大きく変化するほど濃い場合の影に関し、影とその他の境界を更に際立たせて、閾値を上回ってしまったと考えられる。ひび割れの深さが大きいデータや照度の変化が大きい環境下で撮影された画像に対して本手法を適用すれば、従来手法と比較して有意な精度向上がみられるだろうと考える。

4.7 むすび

本章では、4.2節および4.3節にて予備実験の結果に対する提案の手法を検証した実験の概要と使用したデータセットについて述べた。そして4.4節で結果を評価する指標について説明をした。その後4.5節および4.6節にて実験結果とそこから考えられる事柄について述べた。精度向上にはいたらなかったが、設定する環境下によっては有用であることが示唆された。

第5章 結論と今後の課題

5.1 結論

本研究は、構造物の画像からひび割れの有無を検出し、構造物の点検業務を効率化することを目的とした。まず予備実験として、Jakob Bazicらの手法をベースにCRACK500を用いて混合教師あり学習を行い、完全教師ありデータの割合に対する精度の変化を検証した。その後、予備実験の結果からメディアンフィルタによる前処理の追加を提案し、見逃したデータや誤検出したデータに関して分析を行った。

提案手法は出力の改善画像から、ひび割れの深さが大きいデータや照度の変化が大きい環境下で撮影された画像に対して、従来手法と比較して有意な精度向上がみられることが示された。

5.2 今後の課題

本研究では、メディアンフィルタによる前処理にて影の除去を試みた。しかしながら浅いひび割れの情報を失ったり、濃い影の境界を強調したりと想定外の影響が生じた。様々な環境が存在することを考慮し、フィルタサイズの更なる吟味や他の前処理の追加を試みる必要がある。加えて、今回検出の対象としたのは数ある変状のうちひび割れのみであった。今後は別途学習用データセットを用意し、腐食や破断等の他の変状を検出・分類するモデルの構築を目指したい。

また、本研究ではメンテナンスサイクルのうち「点検」に焦点をあてた。点検業務の効率化には、例えば得られた膨大な点検データを元に、定期メンテナンスのような「時間基準」でなく、設備の状態を常に監視して、異常の兆候を確認してから対処する「状態基準」で修繕を行うCBMを導入したり、ドローンを用いて構造物のデータを収集したりなどがある。旧態依然を脱却し、高くアンテナを張り巡らせながら、予防保全につながるアプローチを模索したい。

謝辞

本研究の実験環境を整え，研究テーマに対し丁寧かつ熱心なご指導くださった渡辺裕教授，および研究に対する提案や研究者としての振る舞いをご教示くださった早稲田大学情報通信研究センターの原潤一博士に厚く御礼申し上げます。

加えて，日頃の研究内容に対するフィードバックのみならず，学生生活全般の相談に乗ってくださった研究室の皆様に、深く感謝申し上げます。

最後に，いついかなるときも私を気にかけて，精神面でも金銭面でも支えてくださった家族に心より感謝いたします。

参考文献

- [1]” 第 I 部 第 1 章 第 2 節 1 経済成長とインフラ整備の歴史”. 国土交通白書平成 27 年度版. 国土交通省, 2015, p.15-44. <https://www.mlit.go.jp/hakusyo/mlit/h27/hakusho/h28/pdf/np101200.pdf> (参照 2021-01-14).
- [2]” 第 II 部 第 2 章 第 2 節 社会資本の老朽化対策等”. 国土交通白書令和 3 年度版. 国土交通省, 2021, p. 91. <https://www.mlit.go.jp/hakusyo/mlit/r02/hakusho/r03/pdf/kokudo.pdf> (参照 2021-01-14)
- [3]国土交通省不動産・建設経済局建設市場整備課.” 報道・広報”. 国土交通省. <https://www.mlit.go.jp/report/press/content/001380300.pdf>, (参照 2021-01-14)
- [4]東日本高速道路株式会社.” スマートメンテナンスハイウェイ (SMH)”. <https://www.enxco.co.jp/activity/safety/smh/>, (参照 2021-01-14)
- [5]東日本旅客鉄道株式会社.” 鉄道設備におけるスマートメンテナンスの取り組みについて”. https://www.jreast.co.jp/press/2019/20191106_ho01.pdf, (参照 2021-01-14)
- [6]国土交通省総合政策局公共事業企画調整課.” 報道・広報”. 別紙 1. 国土交通省. <https://www.mlit.go.jp/common/001248162.pdf>, (参照 2021-01-14)
- [7] Bozic, J., Tabernik, D., & Skočaj, D. (2021). Mixed supervision for surface-defect detection: from weakly to fully supervised learning. *Comput. Ind.*, 129, 103459.
- [8]国土交通省道路局. 道路橋定期点検要領, 2019, p.106. https://www.mlit.go.jp/road/sisaku/yobohozen/tenken/yobo4_1.pdf, (参照 2021-01-14)
- [9] Schlegl T., Seeböck P., Waldstein S.M., Schmidt-Erfurth U., Langs G. (2017) Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery. In: Niethammer M. et al. (eds) *Information Processing in Medical Imaging*. IPMI 2017. *Lecture Notes in Computer Science*, vol 10265. Springer, Cham.
- [10] Bearman A., Russakovsky O., Ferrari V., Fei-Fei L. (2016) What’s the Point: Semantic Segmentation with Point Supervision. In: Leibe B., Matas J., Sebe N., Welling M. (eds) *Computer Vision - ECCV 2016*. ECCV 2016. *Lecture Notes in Computer Science*, vol 9911. Springer, Cham.
- [11] L. Zhang, F. Yang, Y. Daniel Zhang and Y. J. Zhu, “Road crack detection using deep convolutional neural network,” 2016 IEEE International Conference on Image Processing (ICIP), 2016, pp. 3708-3712, doi: 10.1109/ICIP.2016.7533052.
- [12] Yang, Fan et al. “Feature Pyramid and Hierarchical Boosting Network for Pavement Crack Detection.” *IEEE Transactions on Intelligent Transportation Systems* 21 (2020): 1525-1535.
- [13]全邦釘, 井後敦史, 橋本和明, : “画像解析によるひび割れ検出とハフ変換による型枠跡および P コン跡の同定”, コンクリート工学年次論文集, Vol. 37, No. 1, 2015

図一覧

図 2-1 畳み込みニューラルネットワークの基本構成	3
図 2-2 弱教師あり学習の例	4
図 2-3 ゴマ塩ノイズの除去	5
図 3-1 CRACK500の画像例	7
図 3-2 予備実験による見逃し画像例	9
図 3-3 予備実験による誤検出画像例	9
図 3-4 グレースケール画像例	10
図 3-5 メディアンフィルタにより処理した画像例	10
図 3-6 提案手法による処理の例	11
図 4-1 見逃し改善の画像例(左: グレースケール画像, 右: 提案手法処理) ...	14
図 4-2 誤検出改善の画像例(左: グレースケール画像, 右: 提案手法処理) ...	15
図 4-3 見逃した画像例(左: グレースケール画像, 右: 提案手法処理)	15

表一覧

表 1-1 変状の種類	2
表 2-1 モデルの構造	5
表 3-1 完全教師データの割合に対するAPとAUROC	8
表 3-2 生画像とグレースケール画像のAPおよびAUROC	10
表 4-1 ハイパーパラメータ	12
表 4-2 CRACK500_unshadowのデータ数	12
表 4-3 2値分類の混同行列	13
表 4-4 CRACK500_unshadowを用いて算出したAPとAUROC	14