

インフラ維持管理 DX に資する  
AI およびデジタルツイン技術に関する基礎的研究

2022年10月

古賀 掲維

# 目次

<b>第 1 章</b>	<b>序論</b>	<b>3</b>
1.1	本研究の背景 . . . . .	3
1.2	本研究の目的 . . . . .	5
1.3	本研究の概要 . . . . .	5
<b>第 2 章</b>	<b>画像分類 AI を用いた舗装道路のひび割れ率算定</b>	<b>8</b>
2.1	はじめに . . . . .	8
2.2	舗装の維持管理指数 (MCI) . . . . .	9
2.3	深層学習を用いた路面性状分類 AI モデルの構築 . . . . .	12
2.4	深層学習を用いたひび割れ率算定 . . . . .	22
2.5	おわりに . . . . .	26
<b>第 3 章</b>	<b>領域分割 AI を用いたコンクリートのひび割れ検出</b>	<b>28</b>
3.1	はじめに . . . . .	28
3.2	セマンティック・セグメンテーション . . . . .	29
3.3	教師データ . . . . .	30
3.4	AI モデルの構築 . . . . .	32
3.5	領域分割における精度について . . . . .	37
3.6	解析結果 . . . . .	42
3.7	おわりに . . . . .	48
<b>第 4 章</b>	<b>物体検出 AI を用いた橋梁の損傷検出</b>	<b>51</b>
4.1	はじめに . . . . .	51
4.2	物体検出手法について . . . . .	52
4.3	SSD . . . . .	54
4.4	教師データの作成 . . . . .	57

4.5	AI モデルの訓練 . . . . .	60
4.6	解析結果 . . . . .	62
4.7	おわりに . . . . .	65
<b>第 5 章</b>	<b>たわみ影響線およびたわみの時刻歴応答の変化率を用いた橋梁劣化箇所 同定手法</b>	<b>69</b>
5.1	はじめに . . . . .	69
5.2	たわみ影響線の変化率を用いた橋梁劣化箇所同定手法 . . . . .	70
5.3	たわみの時刻歴応答の変化率を用いた橋梁劣化箇所同定手法 . . . . .	78
5.4	おわりに . . . . .	96
<b>第 6 章</b>	<b>3次元 CAD を援用した RC はりの FE 解析手法</b>	<b>98</b>
6.1	はじめに . . . . .	98
6.2	RC はりの実験および 3次元 FE 解析の概要 . . . . .	99
6.3	実験結果および解析結果 . . . . .	112
6.4	おわりに . . . . .	121
<b>第 7 章</b>	<b>結論</b>	<b>124</b>
7.1	はじめに . . . . .	124
7.2	各章の成果の検討内容および成果のまとめ . . . . .	124
7.3	インフラ維持管理における本成果の意義と残された課題 . . . . .	126
	<b>参考文献</b>	<b>128</b>
	<b>謝辞</b>	<b>134</b>

# 第 1 章

## 序論

### 1.1 本研究の背景

我が国の道路網をはじめとした社会インフラ構造物の多くは戦後の復興期から高度経済成長期にかけての短期間に整備され、その大部分が建造から 50 年以上を経て老朽化が進行しており、21 世紀は維持管理の時代として既存の構造物を如何に延命していくかが課題となっている。特に、少子高齢化や都市部への人口流出・過疎化による人口減少が進行しつつある地方自治体においては、社会保障費支出が増加する中で、道路や橋梁などの社会インフラを限られた財源や人材の中で適切に維持管理していくことは、住民生活の利便性確保だけでなく、防災・減災の面からも非常に大きな課題となっている。そのような背景の中、2012 年 12 月に発生した中央自動車道の笹子トンネルの崩落事故を機に、国内において社会インフラ管理に対する意識が高まり、「道路法等の一部を改正する法律」が衆参両議院における審議・全会一致による可決を経て 2013 年 5 月 29 日に成立し、2013 年 6 月 5 日に公布された [1]。改正道路法では、「国土交通省が地方道の大規模かつ構造が複雑な構造物を地方自治体に代わって改築および修繕を行える」、「道路管理者が予防保全の観点で踏まえ道路の点検を行うべきことを明確化する」などが規定された。さらに、国土交通省は、道路法施行令第 35 条の 2 第 2 項の規定に基づき、道路法施行規則において道路の維持・修繕に関する具体的な基準等を定めるため、「道路法施行規則の一部を改正する省令」および「トンネル等の健全性の診断結果の分類に関する告示」を 2014 年 3 月 31 日に公布した [2]。この省令および告示では、各道路管理者の責任による点検→診断→措置→記録というメンテナンスサイクルを確立するために、具体的な点検頻度や方法等を以下のように定めている。

- 橋梁 (約 70 万橋)・トンネル (約 1 万本) 等は, 国が定める統一的な基準により, 5 年に 1 回の頻度で, 近接目視により点検を行うことを基本とすること
- 点検, 診断の結果等について, 記録・保存すること
- 統一的な尺度で健全性の診断結果を分類すること

しかしながらこれらの手法は, 膨大な作業時間と作業量を要する, 検査者の知識および経験に依存する, 地方自治体の技術者不足, 検査者の個人差によるばらつきがある, 高精度かつ客観的な評価が難しい, など多くの問題を抱えている. さらにこれらの問題は今後益々深刻化する方向にあり, 将来にわたって効率的かつ適切に社会インフラを維持管理していくためには, インフラ維持管理のイノベーションが急務となっている.

近年, 様々な分野でデジタルトランスフォーメーション (DX) が推進されている. デジタルトランスフォーメーション (DX) はスウェーデンのウメオ (Umeå) 大学の Erik Stolterman が提唱した用語 [3] で, 当初は, デジタル技術が引き起こす社会における変化一般のことを指していた. 昨今の日本で利用されているデジタルトランスフォーメーション (DX) という用語は, 2018 年 9 月に経済産業省による発表された DX レポート [4] や, 2020 年 7 月に閣議決定された世界最先端デジタル国家創造宣言・官民データ活用推進基本計画 [5] にあるように, 「企業が, 将来の成長, 競争力強化のために, 新たなデジタル技術を活用して新たなビジネスモデルを創出・柔軟に改変すること」といった経営的な文脈で用いられている.

インフラ分野のデジタルトランスフォーメーション (DX) については, 国土交通省が主導する形で, 社会経済状況の激しい変化に対応し, インフラ分野においてもデータとデジタル技術を活用して, 国民のニーズを基に社会資本や公共サービスを変革すると共に, 業務そのものや, 組織, プロセス, 建設業や国土交通省の文化・風土や働き方を変革し, インフラへの国民理解を促進すると共に, 安全・安心で豊かな生活の実現を目指すとされている [6].

以上を鑑みれば, これからのインフラ維持管理においては, ビッグデータ等のデータや, AI, IoT(Internet of Things) に代表されるデジタル技術, 現実の情報をデジタル上で表現し, 分析やシミュレーションなどを行うデジタルツインなどを活用してデジタルトランスフォーメーション (DX) を推進していく必要があると考えられる.

## 1.2 本研究の目的

本研究は、インフラ維持管理におけるデジタルトランスフォーメーション (DX) を推進し、効率的かつ適切に社会インフラを維持管理する手法を開発することを目的として、AI やデジタルツインの活用について検討したものである。

AI については、画像認識を中心に、画像分類 (Image Classification) モデルを用いたアスファルト舗装路面のひび割れ率の算定に関する研究、領域分割 (Semantic Segmentation) モデルを用いたコンクリートのひび割れの抽出に関する研究、物体検出 (Object Detection) モデルを用いた橋梁の損傷検出に関する研究を行っている。これらの研究では、AI による画像認識を用いることで、近接目視で生じる問題点を低減させることを目指している。

デジタルツインについては、実験と FEM によるシミュレーションを組み合わせ、たわみ影響線および移動荷重による応答変位の変化率を用いた橋梁の損傷箇所の同定に関する研究、3次元 CAD を援用した RC はりの FE 解析手法に関する研究を行っている。これらの研究では、実験と FEM シミュレーションを実施することで FEM シミュレーションの妥当性を検討し、コンピュータ上で様々なパラメーターをもつモデルを再現することを目指している。

## 1.3 本研究の概要

本論文は、著者がこれまで行ってきた AI およびデジタルツインに関連した研究のうち、インフラ維持管理分野の DX に資すると思われる一連の研究を取り纏めたものである。

各章の構成と内容は以下の通りである。

第 1 章では、本研究の背景、目的および本論文の構成について述べる。

第 2 章では、舗装の維持管理指数 (MCI) の指標の一つであるひび割れ率を、費用が高額な路面性状専用測定車を使用せず、スマートフォンやドライブレコーダーで撮影した動画から画像処理と画像認識 AI を用いて算定する手法を示すとともに、本手法で算定したひび割れ率の精度検証を行い、路面性状専用測定車の代替手段となりうることを確認する。

第 3 章では、コンクリートのひび割れを、領域分割 AI を用いて自動抽出する手法について詳述するとともに、本手法で算出したひび割れの精度を IoU (Jaccard 係数) という指標を用いて検証した結果を示し、本手法を用いることで高い精度が得られることを示す。

第 4 章では、橋梁の損傷を、物体検出 AI を用いて写真から検出する手法について、教

師データの作成方法, 物体検出処理における精度検証方法とともに示している. 剥離, 鉄筋露出, 漏水, 遊離石灰の 4 つの損傷を対象とした物体検出 AI の学習状況, AP(Average Precision), mAP(mean Average Precision) による精度検証結果について示し, 物体検出 AI を橋梁の損傷検出に適用する場合の留意点や精度向上について考察する.

第 5 章では, たわみ影響線の変化率を用いて, 橋梁の劣化箇所を同定する手法を開発するため, 実験を行った結果を示すとともに, 実験と FEM によるシミュレーション結果を用いたたわみの変化率について言及し, 本手法の妥当性について検討する. さらに, 移動荷重による変位応答の変化率を用いて, 橋梁の劣化箇所を同定する手法を開発するため, 移動荷重を受ける単純支持はりについて, フーリエ級数を用いた解析解による結果と FEM によるシミュレーション結果を比較検討し, FEM シミュレーションにおける解析手法の妥当性を示すとともに, FEM シミュレーション上で損傷を有するモデルを作成し, 損傷を有するはりと損傷の無いはりについて, 移動荷重による変位の時刻歴応答の変化率を求めることで, 損傷の有無だけでなく, 損傷位置を検出できることを示す.

第 6 章では, 3 次元 CAD を援用した鉄筋コンクリートはり (RC はり) の FE 解析手法を開発するため, 3 次元 CAD を活用したモデル作成と汎用 FEM ソフトウェアの接触解析機能を用いることで, 異なる材料およびメッシュ分割から構成されたモデルを効率的に解析できることを示すとともに, 鉄筋定着部に損傷を有するはりの実験および FEM シミュレーションを行い, 手法の妥当性について検討する.

第 7 章では, 各章の成果を総括して結論とする.

## 参考文献

- [1] 国土交通省『道路法等の一部を改正する法律案について』, 2013-03, URL: [https://www.mlit.go.jp/report/press/road02\\_hh\\_000005.html](https://www.mlit.go.jp/report/press/road02_hh_000005.html).
- [2] 国土交通省『道路の維持修繕に関する省令・告示の制定について（道路法施行規則の一部改正等）』, 2014-03, URL: [https://www.mlit.go.jp/report/press/road01\\_hh\\_000412.html](https://www.mlit.go.jp/report/press/road01_hh_000412.html).
- [3] Erik Stolterman and Anna Croon Fors. “Information Technology and the Good Life”. In: *Information Systems Research* 143 (2004), pp. 687–692.
- [4] 経済産業省『DX レポート, ～IT システム「2025 年の崖」克服と DX の本格的な展開～』, 2018-09, URL: [https://www.meti.go.jp/shingikai/mono\\_info\\_service/digital\\_transformation/20180907\\_report.html](https://www.meti.go.jp/shingikai/mono_info_service/digital_transformation/20180907_report.html).
- [5] 内閣官房情報通信技術 (IT) 総合戦略室『世界最先端デジタル国家創造宣言・官民データ活用推進基本計画』, 政府 CIO ポータル, 2020, URL: <https://cio.go.jp/node/2413>.
- [6] 国土交通省 国土技術政策総合研究所インフラ DX 研究推進本部『国土交通省が進める DX』, URL: [http://www.nilim.go.jp/japanese/organization/infradx\\_honbu/indexinfradx.htm](http://www.nilim.go.jp/japanese/organization/infradx_honbu/indexinfradx.htm).

## 第2章

# 画像分類 AI を用いた舗装道路のひび割れ率算定

### 2.1 はじめに

アスファルト舗装は、路面舗装の主流であり、今後も使用されることが想定される。アスファルト舗装の路面性状評価法としては、舗装の維持管理指数 (MCI: Maintenance Control Index, 以降 MCI) [7] を用いる方法がある。MCI は舗装路面の供用性を 3 つの路面性状値 (ひび割れ率, わだち掘れ量, 平たん性) で定量的に評価する手法である。MCI の測定には、一般的に専用の路面性状専用測定車が用いられる。路面性状専用測定車は、MCI で用いられる路面性状値のデータを同時測定する車両であり、近年、効率的に道路舗装の維持管理を行うため、主に一般国道で用いられており、路面性状専用測定車により、長距離区間における路面性状調査を短時間で実施することが可能となった。しかしながら、路面性状専用測定車による計測は、1km 当り数万円と費用が高額であるため、全国の道路の約 95% を占める地方自治体が管理する道路ではコストの面から用いられないことが多い。地方自治体が管理する道路の場合、路面損傷の確認は日常の巡回時の目視やスケッチ、写真撮影が主となっている。しかし、目視点検の場合は、1) 人為的ミスが発生する可能性がある、2) 緊急時の迅速な状況把握が難しい、3) スケッチや写真撮影も検査員が画像データを見て損傷度合を判断するため定量的でない、という問題が生じるため、高コストである MCI や、労働生産性の低い目視点検よりも効率の良い経済的な手法の確立が急務となっている [8]。

MCI の 3 つの路面性状値 (ひび割れ率, わだち掘れ量, 平たん性) の解析において、ひび割れ解析に要する時間が、解析時間全体の約 7 割程度を占めるといわれており、ひび割れ

の解析時間を短縮することで、路面性状調査がより経済的になると考えられる [9]。路面性状専用測定車によるひび割れ率の測定では、路面を垂直に撮影した連続画像に  $0.5 \times 0.5\text{m}$  のマス目を重ね合わせ、マス目内の画像を専門家が目視で解読し、それぞれのマス目の判別結果を記録するという方法が採られている。このマス目内の画像を判別する方法は、近年目覚ましい進歩を遂げている深層学習 (Deep Learning) が得意とする分野であり、簡便に路面の連続画像を取得し、マス目に分割する手法と深層学習による画像分類 AI を組み合わせれば、安価で高精度にひび割れ率を算定する手法を開発できると考えられる。

舗装道路のひび割れ率算出に関する既往の研究として、全らの研究 [10] では、車載カメラにより撮影された舗装画像を分割し、深層学習による画像分類を用いてひび割れの有無を判定することで、ひび割れと判定された画像の総数を分割した画像の総数で除すことでひび割れ率を算出する手法を提案している。この手法では、パッチングは考慮されておらず、また、車載カメラで撮影した画像は、実際の路面における  $0.5 \times 0.5\text{m}$  のマス目を考慮せず分割されており、MCI におけるひび割れ率の算出方法とは異なった手法となっている。

また、浅田らの研究 [11] では、ドライブレコーダー画像と深層学習を用いた道路舗装のひび割れ評価手法を提案している。ドライブレコーダー画像内に設置したマス目に対して、ひび割れの判定には画像分類を用いてひび割れ面積を算出し、パッチングについては、物体検出による結果とマス目の重なり具合からひび割れ面積を算出している。この手法では、ドライブレコーダーの画像に広角レンズの歪みが残っていること、射影変換が行われていないこと、実際の路面における  $0.5 \times 0.5\text{m}$  のマス目を考慮せず分割されており、やはり、MCI におけるひび割れ率の算出方法とは異なった手法となっている。

本章の研究は、MCI の 3 つの路面性状値のうち、ひび割れ率の算定について着目し、スマートフォンやドライブレコーダーといった一般的な機器と画像処理および深層学習を組み合わせることで、MCI に準じた安価かつ高精度にひび割れ率算定手法を提案するとともに、手法の妥当性を検証したものである。

## 2.2 舗装の維持管理指数 (MCI)

MCI は、舗装の供用性を「ひび割れ率」、「わだち掘れ量」および「平たん性」という路面性状値によって定量的に評価するものである。舗装の劣化形態は様々なものがあり、例えばひび割れ卓越型の劣化形態や、わだち掘れ卓越型の劣化形態が存在する。「ひび割れ率」や「わだち掘れ量」といった単独指標では、それら劣化形態の異なる舗装の比較が困難である。そこで、昭和 56 年に建設省土木研究所が、道路局、地方建設局 (いずれも当時) とともに、維持修繕判断を行う総合的な指標として開発したものが MCI である。MCI は、

道路管理者の視点から異なる劣化形態の路面を見比べ、劣化の程度を点数により評価したものに對し、路面性状の主要指標である「ひび割れ率」、「わだち掘れ量」および「平坦性」という路面性状値で重回歸分析することにより求められたものであり、以下の式 (2.1) のうち、最小値をもって MCI とすることとしている。

$$\begin{aligned}
 MCI &= 10 - 1.48C^{0.3} - 0.29D^{0.7} - 0.47\sigma^{0.2} \\
 MCI_0 &= 10 - 1.51C^{0.3} - 0.30D^{0.7} \\
 MCI_1 &= 10 - 2.23C^{0.3} \\
 MCI_2 &= 10 - 0.54D^{0.7}
 \end{aligned}
 \tag{2.1}$$

ここに、 $C$  はひび割れ率 (%),  $D$  はわだち掘れ量 (mm),  $\sigma$  は平坦性 (mm) である。

式 (2.1) からわかるように、MCI の最大値は 10 である。MCI の値が 3 以下の場合には早急な補修が必要であり、4 以下の場合には補修が必要、5 以下の場合には補修が望ましい管理基準となる。

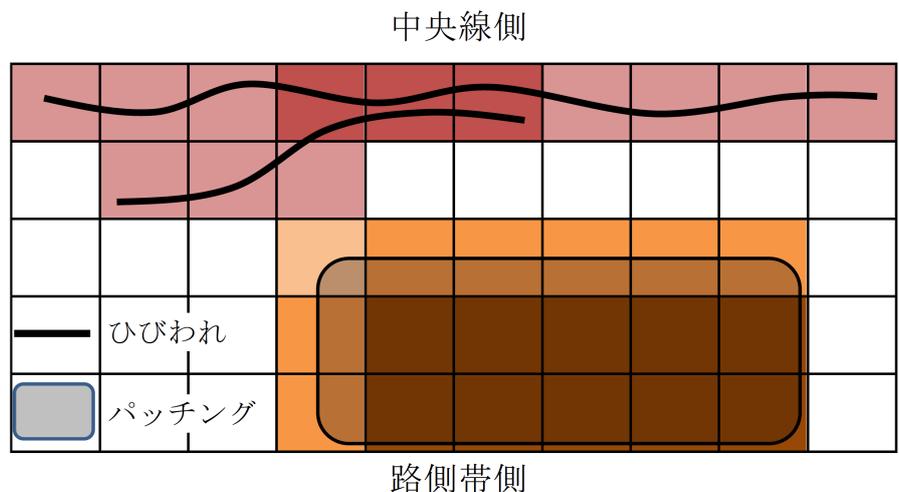
MCI におけるひび割れ率の算定では、各マス目  $0.5\text{m} \times 0.5\text{m}$  (面積  $0.25\text{m}^2$ ) について、表 2.1 のようにひび割れ面積を判断することとなっている。MCI におけるひび割れ率は、算定する区間の総ひび割れ面積を総面積で割り 100 をかけたものとなるので、以下の式 (2.2) のようになる。

表 2.1 MCI におけるひび割れ面積

状態	ひび割れ面積
線状ひび割れが 1 本だけある	$0.15\text{m}^2$
線状ひび割れが 2 本以上ある	$0.25\text{m}^2$
パッチングの占める面積が 0% 以上 25% 未満	$0\text{m}^2$
パッチングの占める面積が 25% 以上 75% 未満	$0.125\text{m}^2$
パッチングの占める面積が 75% 以上	$0.25\text{m}^2$

$$\text{ひび割れ率 (\%)} = \frac{\text{総ひび割れ面積}}{\text{総面積}} \times 100
 \tag{2.2}$$

図 2.1 は舗装面のひび割れ・パッチングの例である。マス目のサイズは  $0.5\text{m} \times 0.5\text{m}$  であり、マス目の面積は  $0.25\text{m}^2$  である。この例について、表 2.1 を用いてひび割れ面積を計算したものが表 2.2 である。



- : ひび割れ 1 本    ■ : ひび割れ 2 本以上  
■ : パッチング 25%未満    ■ : パッチング 25%～75%未満  
■ : パッチング 75%以上

図 2.1 舗装面のひび割れ・パッチングの例

表 2.2 ひび割れ面積の計算式

マス目の種類	マス目数	ひび割れ面積
ひび割れ 1 本	10	1.5m <sup>2</sup>
ひび割れ 2 本以上	3	0.75m <sup>2</sup>
パッチング (25% 未満)	1	0m <sup>2</sup>
パッチング (25% 以上 75% 未満)	7	0.875m <sup>2</sup>
パッチング (75% 以上)	10	2.5m <sup>2</sup>
総ひび割れ面積	-	5.625m <sup>2</sup>

表 2.2 の計算結果に式 (2.2) を用いると、図 2.1 の区間のひび割れ率は以下のように求まる。

$$\text{ひび割れ率 (\%)} = \frac{5.625}{0.25 \times 50} \times 100 = 45(\%) \quad (2.3)$$

本研究では、MCI で用いられている手法で求められたひび割れ率を正解と考え、深層学

習を用いて MCI の手法により近いひび割れ率の算定を目指す。

## 2.3 深層学習を用いた路面性状分類 AI モデルの構築

本節では、舗装面のひび割れ率の算定に使用する路面性状分類 AI モデルの構築方法について説明する。AI モデル構築の基本的な考え方としては、舗装面の画像を MCI と同じようにマス目に分割し、それぞれのマス目について深層学習を用いて画像分類を行うこととした。

### 2.3.1 教師データの作成

AI モデル構築に使用する教師データは、以下の各目に示すような手順で作成した。

#### (1) 路面動画の取得

自動車に設置したスマートフォンを用い路面を撮影した動画を取得した。また、同時にドライブレコーダーを用いて GPS により位置情報を取得した。図 2.2 はスマートフォン、ドライブレコーダーの設置状況、表 2.3 は用いたスマートフォン、ドライブレコーダーの機種および動画の撮影条件である。



図 2.2 舗装面のひび割れ・パッチングの例

表 2.3 動画の撮影条件

スマートフォン	SONY Xperia xz1
ドライブレコーダー	KENWOOD DRV-830
動画解像度 (画素)	1, 920 × 1, 080 (Full HD)
フレームレート (fps)	60

## (2) フレームの抽出

MCI に準じてひび割れ率を算出するためには、できるだけ隙間や重複なく連続したマス目の画像を取得する必要がある。本研究では、GPS の位置情報より自動車の走行速度を算出し、動画から取り出すフレームの間隔を決定している。

ある時刻における走行速度 (m/s) を  $v$  とすると、取り出すフレームの間隔  $f$  は以下の式 (2.4) で表すことができる。

$$f = \frac{\text{フレームレート (fps)} \times \text{切り出す距離 (m)}}{v} \quad (2.4)$$

なお、走行速度  $v$  は 2 点間の距離を算出するヒュベニ (Hubeny) の公式を用いることによって、以下の式で求めることができる。

$$v = l/t \quad (2.5)$$

$$l = \sqrt{(D_y \times M)^2 + (D_x \times N \times \cos P)^2} \quad (2.6)$$

$$M = \frac{R_x(1 - E^2)}{W^2} \quad (2.7)$$

$$N = \frac{R_x}{W} \quad (2.8)$$

$$E = \sqrt{\frac{R_x^2 - R_y^2}{R_x^2}} \quad (2.9)$$

$$W = \sqrt{1 - E^2 \times \sin^2 P} \quad (2.10)$$

ここに、 $t$  は 2 点間の移動にかかった時間 (s)、 $D_x$  は 2 点の経度の差、 $D_y$  は 2 点間の緯度の差、 $P$  は 2 点の緯度の平均、 $M$  は子午線曲率半径、 $N$  は卯酉線曲率半径、 $E$  は離心率、 $R_x$  は長半径 (赤道半径)、 $R_y$  は短半径 (極半径) である。

### (3) レンズ補正

前項において抽出されたフレーム画像はレンズによるゆがみがあるため、チェスボードを用いてレンズ補正を行った。図 2.3 は撮影に用いたチェスボードである。

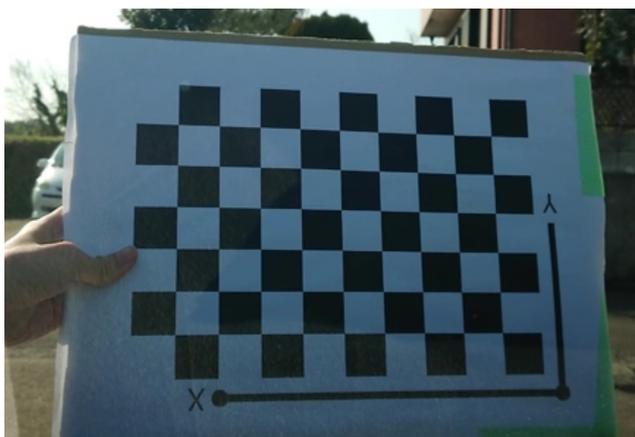


図 2.3 チェスボード

### (4) フレーム画像の射影変換

前項においてレンズ補正したフレーム画像は撮影時に車両前方を向いて撮影しているため、画像上において路面は台形状に記録されている。この画像を MCI に準じて 0.5m 四方角に分割するためにはこれを正対位置 (真上) からの視点に補正する必要がある。補正にあたっては、路面の動画取得時に撮影した 0.5m 四方の矩形板の頂点 (基準点) の座標値を用いて射影変換を行った。

射影変換には以下のような式を用いた。

$$\begin{Bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \end{Bmatrix} = \begin{bmatrix} x_1 & y_1 & 1 & 0 & 0 & 0 & -X_1x_1 & -X_1y_1 \\ x_2 & y_2 & 1 & 0 & 0 & 0 & -X_2x_2 & -X_2y_2 \\ x_3 & y_3 & 1 & 0 & 0 & 0 & -X_3x_3 & -X_3y_3 \\ x_4 & y_4 & 1 & 0 & 0 & 0 & -X_4x_4 & -X_4y_4 \\ 0 & 0 & 0 & x_1 & y_1 & 1 & -Y_1x_1 & -Y_1y_1 \\ 0 & 0 & 0 & x_2 & y_2 & 1 & -Y_2x_2 & -Y_2y_2 \\ 0 & 0 & 0 & x_3 & y_3 & 1 & -Y_3x_3 & -Y_3y_3 \\ 0 & 0 & 0 & x_4 & y_4 & 1 & -Y_4x_4 & -Y_4y_4 \end{bmatrix} \begin{Bmatrix} a \\ b \\ c \\ d \\ e \\ f \\ g \\ h \end{Bmatrix} \quad (2.11)$$

$$X_i = \frac{ax_i + by_i + c}{gx_i + hy_i + 1} \quad (2.12)$$

$$Y_i = \frac{dx_i + ey_i + f}{gx_i + hy_i + 1} \quad (2.13)$$

ここに  $(x_i, y_i)$  は変換前の座標,  $(X_i, Y_i)$  は変換後の座標,  $(x_j, y_j)_{j=1..,4}$  は基準点の変換前の座標,  $(X_j, Y_j)_{j=1..,4}$  は基準点の変換後の座標である. 式 (2.11) を解くことより, パラメーター  $a \sim h$  が求まり, 式 (2.12), (2.13) により射影変換を行うことができる. 図 2.4 は基準点を用いたフレーム画像の射影変換の様子である.



(a) 変換前の基準点



(b) 変換後の基準点



(c) 取得したパラメータで変換したフレーム画像

図 2.4 基準点を用いたフレーム画像の射影変換

### (5) フレーム画像の分割

前項で射影変換したフレーム画像から、0.5m 四方のマスキングの画像 (以降、タイル画像) を切り出す。

前項で取り出したフレーム画像は射影変換を行っているため、機器すなわち車両に近い部分が最も高い画質となる。したがって、タイル画像の切り出しにあたっては、式 (2.4) にフレームレートとして表 2.3 にある 60fps, 切り出す距離として 0.5m を代入して  $f$  を求め、フレーム画像の下端から 0.5m の距離を切り出し、0.5m 四方となるよう横方向にも分割した。画像の分割状況を図 2.5 に示す。赤枠が分割時の境界線である。図 2.5 に示した例では、路線幅が 2.5m となっているため、横方向の分割数は 5 となっている。

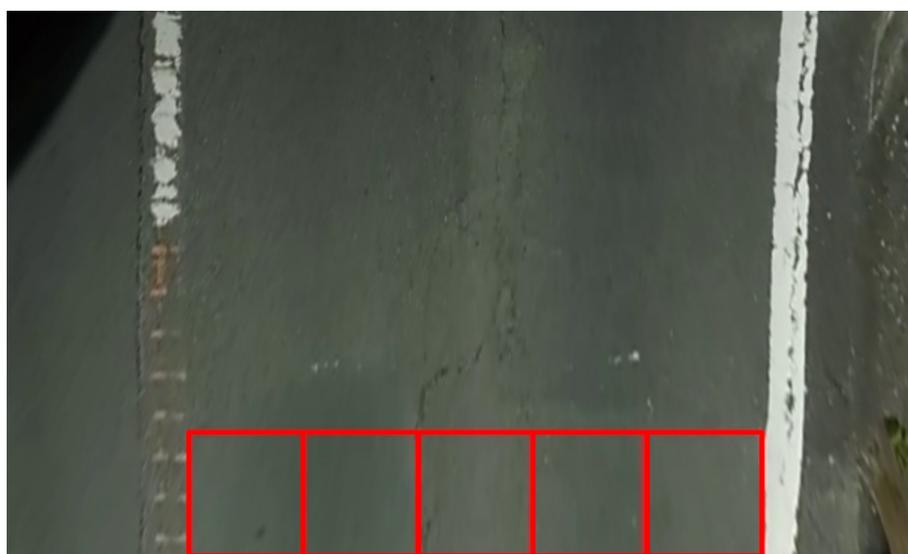


図 2.5 フレーム画像の分割例

### (6) タイル画像の分類

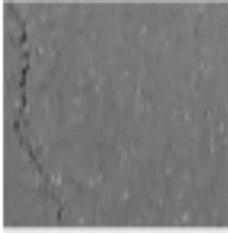
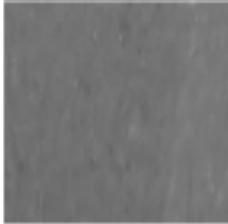
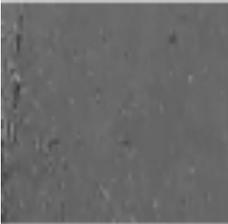
前項で分割したタイル画像約 3,000 枚を目視で表 2.4 に示す 6 つのカテゴリに分類したデータを作成した。ただし、パッチング 100% のタイル画像については、本来なら「パッチング (75% 以上)」に分類されるが、タイル画像では「線状ひび割れなし」と区別がつかないことから、パッチング 100% のタイル画像は「線状ひび割れなし」のカテゴリに分類している。今回用意したデータでは、一部のカテゴリで画像数が集まらず、カテゴリ間の画像数のばらつきが大きくなっている。

表 2.5 はタイル画像の分類例である。

表 2.4 分類カテゴリー

カテゴリー	ラベル名	画像数
線状ひび割れなし	p0	452
線状ひび割れ 1 本のみ	h1	747
線状ひび割れ 2 本以上	h2	1, 012
パッチング (25% 未満)	p2	114
パッチング (25% 以上 75% 未満)	p5	392
パッチング (75% 以上)	p7	309
合計	-	3, 026

表 2.5 タイル画像の分類例

正常	ひび割れ	
		
p0	h1	h2
パッチング		
		
p2	p5	p7

### 2.3.2 AI モデルの構築

本研究では、画像分類の AI モデルとして VGG-16 [12] を用いた。VGG-16 は深さ 16 層の畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) である。本項では、AI モデルの構築手順について説明する。

#### (1) 開発環境

開発環境を表 2.6 に示す。プログラミング言語は Python を用い、機械学習フレームワークは PyTorch を用いた。

表 2.6 AI モデルの開発環境

CPU	AMD Ryzen Threadripper PRO 3955WX
Memory	256GB ECC Registered DDR4
GPU	NVIDIA RTX A6000 48GB DDR6
OS	Windows 11 Pro (21H2)
Python 環境	Python 3.8.13(Miniforge3)
機械学習フレームワーク	PyTorch 1.10.2 + Torchvision 0.11.3

#### (2) AI モデルの準備

今回は、少ないデータ数で効率的な学習を行わせるため、転移学習を行うこととした。AI モデルは、PyTorch の Torchvision パッケージで提供されている ImageNet データセット [13] で訓練済みの VGG-16 モデルを利用した。図 2.6 は VGG-16 モデルの表示結果である。転移学習を行うために、AI モデルの最後の層 (classifier グループの 6 層目) の出力数 (out\_features) を本論文の分類カテゴリ数である 6 に変更し、最後の層 (classifier グループ 6 層目の Linear 層) のみ、重み (weight) とバイアス (bias) が更新されるように設定した。この層以外の重みおよびバイアスは訓練によって更新されない。

#### (3) AI モデルの訓練

前節で作成した教師データを訓練用 (train)、検証用 (valid)、テスト用 (test) に 7:2:1 で分割しデータセットを作成した。それぞれの画像数は訓練用 2,115 枚、検証用 602 枚、

```

VGG(
  (features): Sequential(
    (0): Conv2d(3, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (1): ReLU(inplace=True)
    (2): Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (3): ReLU(inplace=True)
    (4): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (5): Conv2d(64, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (6): ReLU(inplace=True)
    (7): Conv2d(128, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (8): ReLU(inplace=True)
    (9): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (10): Conv2d(128, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (11): ReLU(inplace=True)
    (12): Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (13): ReLU(inplace=True)
    (14): Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (15): ReLU(inplace=True)
    (16): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (17): Conv2d(256, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (18): ReLU(inplace=True)
    (19): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (20): ReLU(inplace=True)
    (21): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (22): ReLU(inplace=True)
    (23): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (24): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (25): ReLU(inplace=True)
    (26): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (27): ReLU(inplace=True)
    (28): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (29): ReLU(inplace=True)
    (30): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  )
  (avgpool): AdaptiveAvgPool2d(output_size=(7, 7))
  (classifier): Sequential(
    (0): Linear(in_features=25088, out_features=4096, bias=True)
    (1): ReLU(inplace=True)
    (2): Dropout(p=0.5, inplace=False)
    (3): Linear(in_features=4096, out_features=4096, bias=True)
    (4): ReLU(inplace=True)
    (5): Dropout(p=0.5, inplace=False)
    (6): Linear(in_features=4096, out_features=1000, bias=True)
  )
)

```

図 2.6 PyTorch の VGG-16 モデル

テスト用 309 枚となっている。作成したデータセットを利用し、表 2.7 に示すパラメータで訓練を行った。訓練時には、画像の各画素の RGB 値を 0~1 に正規化し、さらに、ImageNet データセットの画素の平均値および標準偏差で正規化を行っている。なお、データ拡張 (Data Augmentation) は行っていない。

表 2.7 訓練パラメータ

誤差関数	交差エントロピー誤差
最適化関数	Adam [14]
学習率	1.0e-4
エポック数	500
バッチサイズ	32
正規化 (RGB)	平均値:(0.485, 0.456, 0.406) 標準偏差:(0.229, 0.224, 0.225)

図 2.7 は訓練時の正答率 (accuracy) の収束状況、図 2.8 は損失 (loss) の収束状況である。図中の凡例の train は訓練フェーズ、valid は検証フェーズを示している。図 2.7, 2.8 より学習が進むにしたがって、正答率が高くなり、損失も減少していることがわかる。学習終了時点 (epoch=500) において特に過学習の傾向は見られなかった。学習終了時点での全分類カテゴリーの正答率は、train フェーズが約 80%、valid フェーズで約 81% であった。

表 2.8 は学習した AI モデルを用いてテスト用データについて推論を行い、各分類カテゴリーの正答率を計算したものである。「パッチング (25% 未満):p2」で 53.85%、「線状ひび割れ 1 本のみ:h1」で 68.42% と正答率が低い結果となった。全テストデータの正答率の平均は 71.99% であった。これは、表 2.4 で示したとおり、今回用いているデータがカテゴリー間で画像数のばらつきが大きい点が要因の一つであると考えられる。表 2.9 はテスト用データについて、推論結果の混同行列 (Confusion Matrix) を示したものである。表 2.9 から、それぞれのカテゴリーをどのように推論したかを知ることができる。「パッチング (25% 未満):p2」や「線状ひび割れ 1 本のみ:h1」で誤った推論が多いことがわかる。

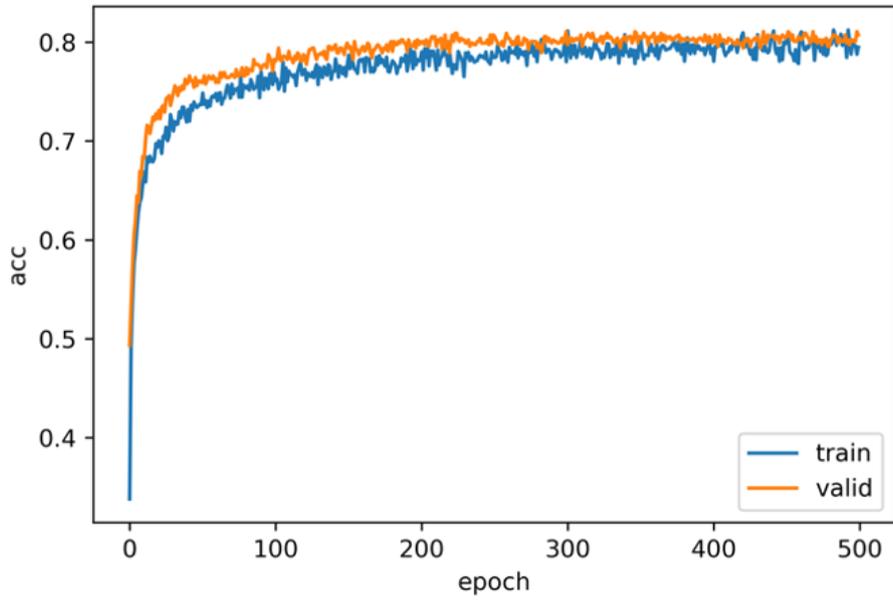


図 2.7 正答率 (accuracy) の収束状況

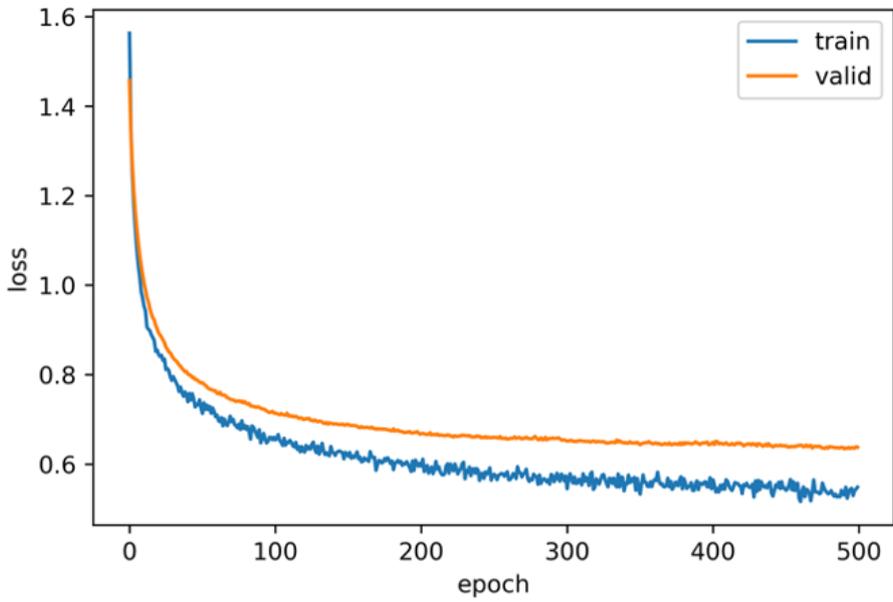


図 2.8 損失 (loss) の収束状況

表 2.8 テスト用データにおける正答率

分類カテゴリー	正答率 (%)
p0: 線状ひび割れなし	80.43
h1: 線状ひび割れ 1 本のみ	68.42
h2: 線状ひび割れ 2 本以上	87.25
p2: パッチング (25% 未満)	53.85
p5: パッチング (25% 以上 75% 未満)	82.50
p7: パッチング (75% 以上)	71.88
全体	77.99

表 2.9 テスト用データの混同行列

		推論したカテゴリー						
		p0	h1	h2	p2	p5	p7	計
正解カテゴリー	p0	37	3	6	0	0	0	46
	h1	5	52	14	0	4	1	76
	h2	1	10	89	0	2	0	102
	p2	2	1	0	7	3	0	13
	p5	2	1	1	3	33	0	40
	p7	3	1	2	0	3	23	32

## 2.4 深層学習を用いたひび割れ率算定

前節で構築した AI モデルを用いて、実際の路面のひび割れ率の判定を行った。対象としたのは路面幅 2.5m × 長さ 10m の路面 10 区間である。図 2.9 に AI モデルによって得られた判定結果を、図 2.10 に目視によって得られた結果を示す。画像中のマス目はひび割れ面積ごとに着色しており、表 2.10 はその配色とひび割れ面積である。また、図 2.10 に示した結果は、タイル画像の作成方法は MCI と異なるが、MCI と同様に目視によってタイル画像を分類しており、MCI で用いられるひび割れ率と同じ結果と見なすことができるため、本研究では図 2.10 に示した結果を正解として扱っている。なお、図 2.9, 2.10 では全 10 区間の内、3 区間のみを示している。

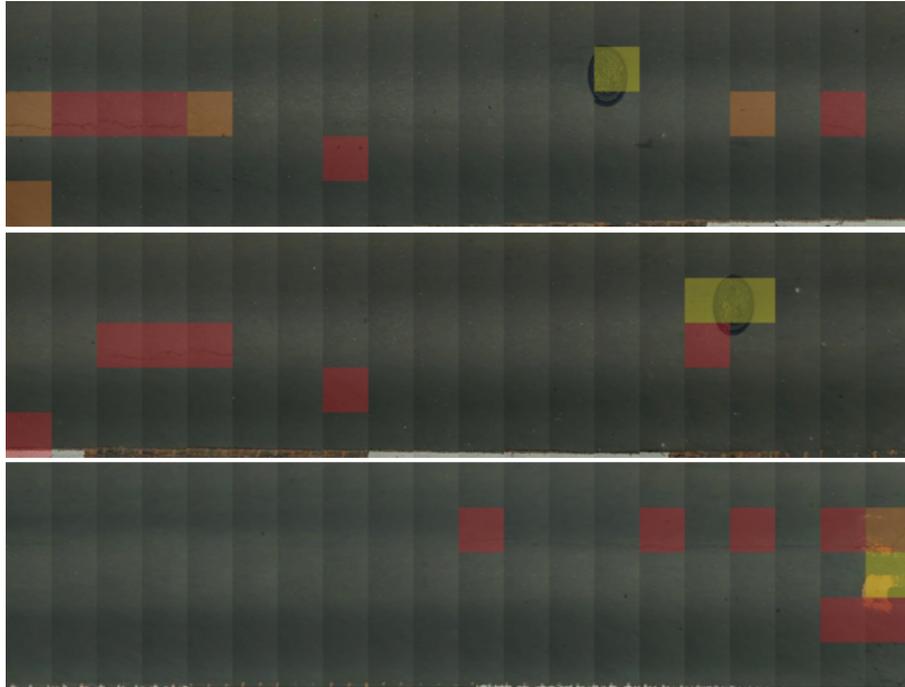


図 2.9 AI モデルによる判定結果

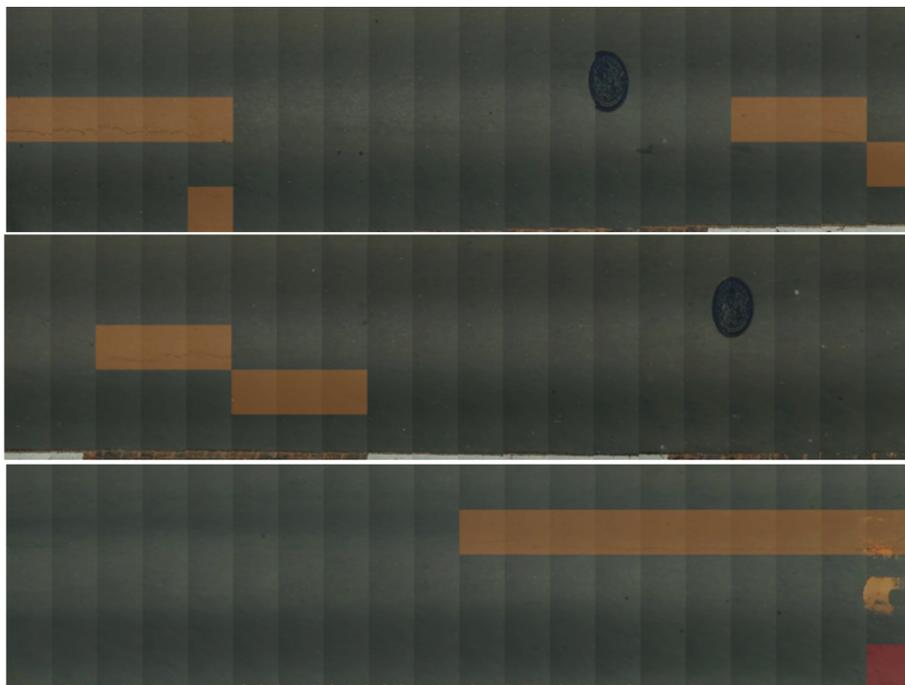


図 2.10 目視による結果 (正解)

表 2.10 損傷度ごとの配色とひび割れ面積

ラベル名	ひび割れ面積 (m <sup>2</sup> )	配色
p0	0	■
h1	0.15	■
h2	0.25	■
p2	0	■
p5	0.125	■
p7	0.25	■

図 2.9 と図 2.10 を比較すると、p0(■) と h1(■), h2(■) の誤判定や、h1(■) と h2(■) の誤判定が多い結果となった。これは表 2.9 に示した混同行列の結果とも概ね一致している。また、マンホールや速度表示など学習させていない物体や、影、路面の汚れによる誤判定が目立った。

表 2.11 は、10 区間におけるひび割れ率の算定結果と正解および算定結果と正解との誤差 (算定結果と正解の差の絶対値)、各マス目における分類判定結果の正解率である。ひび割れ率は、各マス目の判定結果に表 2.10 のひび割れ面積をかけ合計したものを区間の総面積 25m<sup>2</sup> で割ることによって求めることができる。

AI による算出結果では全区間のひび割れ率の平均は 21.7%、目視による正解では全区間のひび割れ率の平均は 17.3%、全区間の平均誤差 (全区間のひび割れ率の平均の差の絶対値) は 4.4% であった。式 (2.1) で示した MCI の計算式では、ひび割れ率  $C$  は、係数  $\times C^{0.3}$  で値に影響してくることになる。AI による算出結果の平均では  $C^{0.3} = 2.53$ 、目視による正解の平均では  $C^{0.3} = 2.35$  となることから、その差 0.18 に係数をかけたものが MCI の値に影響してくることがわかる。表 2.12 は MCI の値への影響をまとめたものである。表 2.12 の影響率 (%) は、MCI の最大値 10 に対する割合を求めている。本研究の手法により求めたひび割れ率の MCI 値への影響率は、どの MCI の計算式においても 4.0% 以下に収まっており、適用する区間の損傷状況にもよるが、MCI で用いられている従来の手法の代替手段としての活用が可能ではないかと考えられる。

一方、表-2.11 における各マス目の分類判定の正解率の平均は 77.3% となっており、まだ十分な精度が得られていないと考えられる。分類判定の正解率には、表 2.8 で示した各カテゴリーの正答率と相関があると考えられるため、さらに精度を向上させるには、各カテゴリーの正答率を高める必要がある。各カテゴリーの正答率を高める方策としては、1)

表 2.11 ひび割れ率算定結果と正解との比較

区間	ひび割れ率算出結果 (%)	ひび割れ率正解 (%)	誤差 (%)	分類判定正解率 (%)
1	15.6	12.0	3.6	75
2	13.2	7.8	5.4	84
3	21.5	6.0	15.5	80
4	26.0	3.6	22.4	86
5	15.8	3.6	12.2	91
6	30.4	24.0	6.4	75
7	23.6	41.0	17.4	65
8	33.8	35.0	1.2	56
9	19.1	32.8	13.7	74
10	17.9	7.0	10.9	87
平均	21.7	17.3	4.4	77.3

表 2.12 ひび割れ率の精度の MCI 値への影響

MCI 計算式	係数	値への影響	影響率 (%)
$MCI$	-1.48	-0.27	-2.7
$MCI_0$	-1.51	-0.28	-2.8
$MCI_1$	-2.23	-0.40	-4.0
$MCI_2$	0	0	0

教師データの個数を増やす, 2) 分類カテゴリーを増やす, 3) 教師データの画質を向上させる, などが有効であると考えられる。

1) については, カテゴリーごとの正答率や混同行列を考慮すれば, 画像数を増やし, 各カテゴリーの画像数を揃える必要があると考えられる。また, 適切なデータ拡張を行うことも有効であると考えられる。

2) については, 誤検知が多かったマンホールや速度表示などの物体の分類カテゴリーを追加することによって, マンホールをひび割れと誤検知する割合を減らすことができると考えられる。

3) については、教師データの各タイル画像を詳細に確認すると、画像がぼやけているものも多く含まれていた。これは、スマートフォンで取得した動画から抽出したフレーム画像に幾つかの変換を行ったためであると考えられる。より高解像度かつ低圧縮な動画で教師データを作成すれば、より質の高い教師データが得られるものと考えられる。

また、本論文の分類カテゴリでは「線状ひび割れなし:p0」に分類している「パッチング 100%」の取り扱いについても検討が必要である。本来であれば、「パッチング (75% 以上:p7)」に分類され、ひび割れ面積  $0.25\text{m}^2$  で計算すべきところが、ひび割れ面積  $0\text{m}^2$  で計算されている。したがって、パッチング 100% のマス目を多く含む区間においては、精度が大きく低下する可能性がある。パッチング 100% のマス目とひび割れなしのマス目を分割した画像で判別するのは困難であるため、実用化に向けては、マス目ではなくより広い範囲でパッチング部分を認識し、その情報に基づきひび割れ率を算定するような手法を開発する必要があると考える。

## 2.5 おわりに

本章では、MCI に準じた舗装面のひび割れ率の算定を安価かつ高精度に行える手法の開発を目的として、スマートフォンおよびドライブレコーダーから取得した路面動画と位置情報から、画像処理と深層学習による画像分類 AI モデルを利用して自動的にひび割れ率を算定する手法を開発した。本手法を実際の路線 (幅  $2.5\text{m}$  × 区間長  $10\text{m}$  × 10 区間) に適用したところ、AI により求めた全区間のひび割れ率の平均は 21.7%、目視により求めた全区間のひび割れ率の平均は 17.3% で、その差は 4.4% であった。本手法のひび割れ率を用いて MCI 値を計算した場合の影響は最大 4.0% となっており、路面の損傷状況にもよるが、MCI で用いられている従来の手法の代替手段としての活用が可能ではないかと考える。一方、各マス目画像の分類判定正答率の平均は 77.3% である、まだ改善の余地がある。しかしながら、MCI で標準的に用いられる手法に準じて舗装面のひび割れ率を算出する一連の流れは構築できており、今後、AI モデルを改善していくことによって、より高精度にひび割れ率を算定する手法として活用できると考える。また、本手法で用いている機器は一般的なスマートフォンやドライブレコーダーであり、最新の機器を揃えても 10 万円程度で準備できることから、路面性状専用測定車を用いるのに比べてはるかに安価にひび割れ率を測定できると考える。

## 参考文献

- [7] 日本道路協会『舗装調査・試験法便覧』，第1分冊，第II章，日本道路協会，2019，pp. 147–176.
- [8] 中村博康，井原務「道路舗装のひび割れ率の簡易評価手法の検討」『舗装』48.11 (2013)，pp. 12–15.
- [9] 佐々木博「スマートフォンを活用した新たな舗装維持管理技術」『舗装』51.6 (2016)，pp. 23–28.
- [10] 全邦釘，井後敦史，南免羅裕治，黒木航汰，大窪和明「車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価」『土木学会論文集 E1 (舗装工学)』73.3 (2017)，I.97–I.105.
- [11] 浅田拓海，亀山修一，川端伸一郎，佐々木克典「走行車両から撮影した路面画像を用いた舗装のひび割れ評価手法の開発」『土木学会論文集 E1 (舗装工学)』70.3 (2015)，I.9–I.16.
- [12] Karen Simonyan and Andrew Zisserman. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2014. DOI: 10.48550/ARXIV.1409.1556. URL: <https://arxiv.org/abs/1409.1556>.
- [13] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. “ImageNet: A large-scale hierarchical image database”. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009, pp. 248–255. DOI: 10.1109/CVPR.2009.5206848.
- [14] Diederik P. Kingma and Jimmy Ba. *Adam: A Method for Stochastic Optimization*. 2014. DOI: 10.48550/ARXIV.1412.6980. URL: <https://arxiv.org/abs/1412.6980>.

## 第3章

# 領域分割 AI を用いたコンクリートのひび割れ検出

### 3.1 はじめに

コンクリート構造物の近接目視点検では、主にひび割れの発生状況を観察することが基本とされている。これは、コンクリート構造物において、ひび割れは耐久性・耐荷力の低下、水密性や防水性の低下など、コンクリート構造物の安全性や機能性に悪影響を及ぼす可能性が高く、また、構造物の美観を損なう原因ともなるためである。現在のコンクリート構造物の点検手法は主に目視点検によるスケッチを検査者が作成するというものである。しかしながらこの手法は、

1. 膨大な作業時間・作業量を要する
2. 検査者の知識および経験に依存する
3. 地方自治体の技術者不足
4. 検査者の個人差によるばらつきがある [15]
5. 高精度かつ客観的な評価が難しい

など多くの問題を抱えている。

地方公共団体において、道路や橋梁などの社会インフラを適切に維持管理していくことは住民生活の利便性確保だけでなく、防災・減災の面から住民が安心・安全な生活を送るためにも非常に重要な取り組みである。一方で公共事業にかけられるコストは限られており、効率良く適切に社会インフラを維持管理していく仕組みがますます重要になってきている。適切な点検による現状の確認とその結果に基づく補修の実施といった結果的な維持

管理手法の確立が急務となっている。

現在、ひび割れ点検などの維持管理に用いられている画像診断は、面的に情報を把握することができることや膨大な対象から評価対象に関する情報を定量化することができるという特長があるが、専用の機材や車両が必要なことやコストなどの問題から、日常点検での活用が難しいとされている。このような現状から、コンクリート構造物の維持管理を行う上で、目視点検の欠点を補いつつ、その精度の助力となる迅速性・客観性を兼ね合わせたひび割れ評価方法が必要である。

コンクリートのひび割れ検出に関する既往の研究として、全らの研究 [16, 17, 18] では、幾何学のおよび統計的パラメータに着目した画像解析によるコンクリート表面のひび割れ検出手法や、Random Forest による教師あり機械学習法と非正方形型フィルタを用いた画像処理を組み合わせたコンクリート表面のひび割れ検出手法、ディープラーニング (CNN) と Random Forest を組み合わせたコンクリート表面のひび割れ検出手法を提案し、精度検証を行っている。検証結果として示されている指標の一つの F 値は、それぞれの手法を用いた場合、0.6162, 0.6450, 0.7046 と報告されている。

また、山根, 全の研究 [19] では、Deep Learning による Semantic Segmentation を用いたコンクリート表面のひび割れ検出手法を提案し、その精度について検証している。しかしながら、検証結果として示されている指標の一つの F 値は、誤検出除去後で 0.4994 と前述の Random Forest を用いた一連の手法より低い値となっている。

本章では、セマンティック・セグメンテーション (Semantic Segmentation) の AI モデルとして高い性能を有する DeepLabv3 [20] を用いて、コンクリート表面のひび割れをピクセル単位で高精度かつ自動的に抽出する手法について検討する。

## 3.2 セマンティック・セグメンテーション

セマンティック・セグメンテーション (Semantic Segmentation) とは、画像処理タスクの 1 つで、1 枚の画像中に含まれる複数の物体について、物体の領域と物体名 (クラス) をピクセル単位で推論する手法である。セマンティック・セグメンテーションは、自動運転における車や人物の検出、製造業における製品の傷等の検出、医療画像診断における病変部位の検出などに利用されている。

深層学習 (Deep Learning) を用いたセマンティック・セグメンテーションの AI モデルとしては、SegNet [21], U-Net [22], PSPNet [23], DeepLab [24] が広く知られている。図 3.1 は、SegNet のネットワーク構造である。

セマンティック・セグメンテーションの AI モデルの多くは、エンコード層 (Encoder)

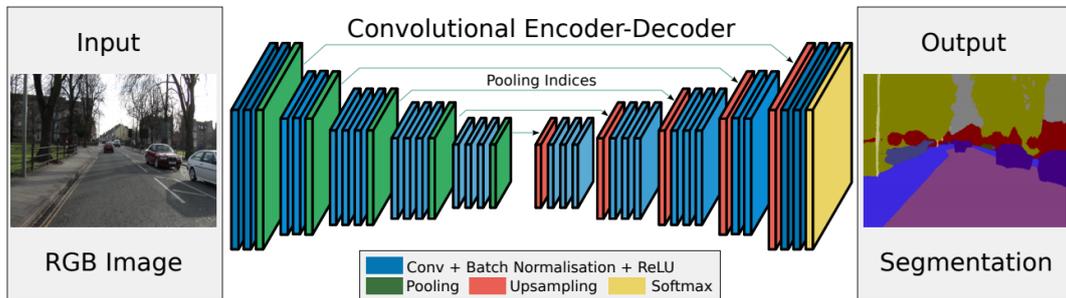


図 3.1 SegNet のネットワーク構造 [21]

とデコード層 (Decoder) を有しており、それぞれ複数階層の畳み込み層 (Convolution) で構成されている。モデルに入力された画像は、エンコード層 (モデル左側) の畳み込み処理でその特徴量が求められ、デコード層 (モデル右側) の逆畳み込み処理でアップサンプリングを行い、最終的に元の画像サイズ×クラス数の確率が出力される。各ピクセル単位で確率が最大のクラスを求めることで、画像をクラス (物体名) 付きで領域分割する仕組みとなっている。

本研究で採用している DeepLab は、2015 年に v1 [24], 2017 年に v2 [25], v3 [20], 2018 年に v3+ [26] が発表されている。v1 では、膨張畳み込み (Dilated Convolution) や CRF (Conditional Random Field) による Refine が導入され、v2 では膨張空間ピラミッドプーリング (Atrous Spatial Pyramid Pooling, ASPP), v3 では、改良版膨張空間ピラミッドプーリングが導入され、精度向上を図っている。v3+ では、バックボーンを ResNet から Xception に変更したり、畳み込み層に深さ単位分離可能畳み込み (Depthwise Separable Convolution) を導入するなどして、計算コストを削減し軽量化している。本研究では、本研究で用いるライブラリ PyTorch [27] で公式のモデルと学習済みの重みが提供されている DeepLabv3 を用いることとした。

### 3.3 教師データ

セマンティック・セグメンテーションでは、元画像 (Original) と目標とする出力を画像に注釈 (Annotation) した画像のペアが教師データとなる。教師データの注釈画像のフォーマットとしては、各クラスの番号をピクセル値としたインデックスカラー (indexed color) 形式の画像が用いられることが多い。本研究では、教師データの注釈作業の効率性

を考慮し、まず、グレースケール (gray scale) 形式で注釈画像を作成し、データセット作成時にインデックスカラー形式に変換した。グレースケール形式の注釈画像では、ひび割れ部をピクセル値 255、それ以外の背景部をピクセル値 0 として注釈画像を作成した。図 3.2 は、教師データの画像の例である。

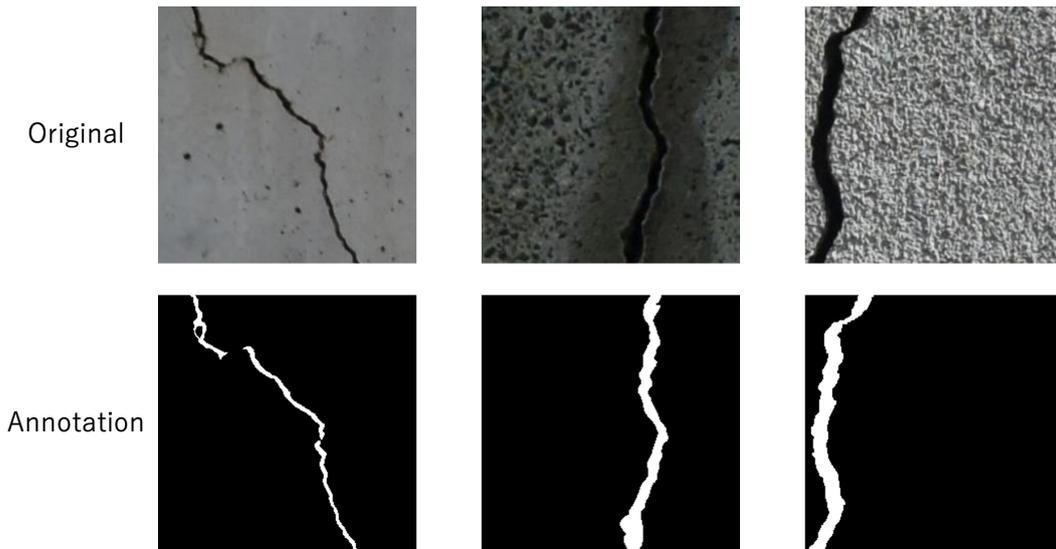


図 3.2 教師データの画像の例

### 3.3.1 教師データの作成の流れ

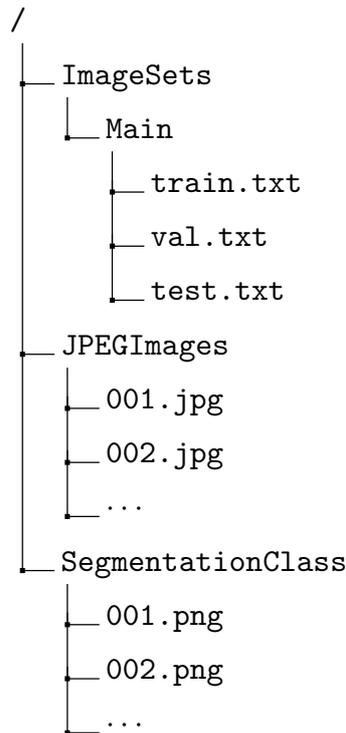
本研究は、画像編集・加工ソフトウェアの 1 つである GIMP [28] を用いて教師データの作成を行った。以下に教師データの作成の流れを示す。

1. 元画像を読み込む
2. 元画像を 2 値化処理し、別ファイルとして保存
3. 元画像と 2 値化した画像を、レイヤー機能で重ね合わせ
4. 元画像のレイヤーを参考にしながら、2 値化したレイヤーをピクセル単位で目視によって修正
5. 2 値化したレイヤーのみをグレースケール形式で保存

教師データの作成は、ピクセル単位での操作となるため、1 枚当たり 3 分程度の時間を要した。本研究では、最終的に 900 ペアの教師画像を作成した。なお、画像のサイズは 256

× 256 ピクセルである。

作成した教師データは, PyTorch のモデルに合わせて VOC データセット 2012[29] に準拠したデータセットを作成した. VOC データセット 2012 のディレクトリ構造は以下のようにになっている.



ImageSets/Main には, 訓練, 検証, テストで利用するデータセット情報を格納する. データセット情報は, テキスト形式のファイルの中に画像ファイル名から拡張子を除いたリストを格納する. JPEGImages には, 画像データを JPEG 形式で格納する. SegmentationClass には, 正解領域をクラス番号の値としたインデックスカラー形式の PNG 形式画像を格納する. 本研究では, 背景 (background) を 0, ひび割れ (crack) を 1 としている.

### 3.4 AI モデルの構築

PyTorch の torchvision パッケージで提供される DeepLabv3 モデルは, 特徴量を計算するバックボーン部 (backbone) と予測結果を求める分類部 (classifier) に分かれている.

本研究では, 転移学習 (transfer learning) やファインチューニング (fine tuning) の影響を考慮するため, 以下に示す 3 種類のモデルを作成した.

- **モデル A:** 学習済み重みを利用しないモデル
- **モデル B:** 学習済み重みを利用し、分類部のみ再学習させるモデル
- **モデル C:** 学習済み重みを利用し、モデル全体を再学習させるモデル

### 3.4.1 開発環境

開発環境を表 3.1 に示す。プログラミング言語は Python を用い、機械学習フレームワークは PyTorch を用いた。

表 3.1 AI モデルの開発環境

CPU	AMD Ryzen Threadripper PRO 3955WX
Memory	256GB ECC Registered DDR4
GPU	NVIDIA RTX A6000 48GB DDR6
OS	Windows 11 Pro (21H2)
Python 環境	Python 3.8.13(Miniforge3)
機械学習フレームワーク	PyTorch 1.10.2 + Torchvision 0.11.3

### 3.4.2 AI モデルの訓練

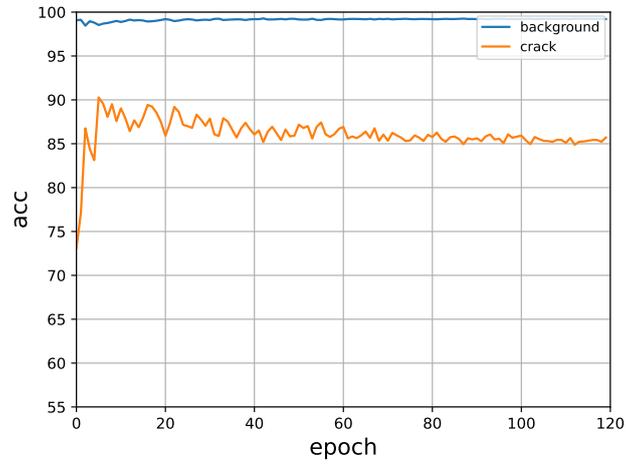
表 3.2 に示すパラメータで訓練を行った。

表 3.2 訓練パラメータ

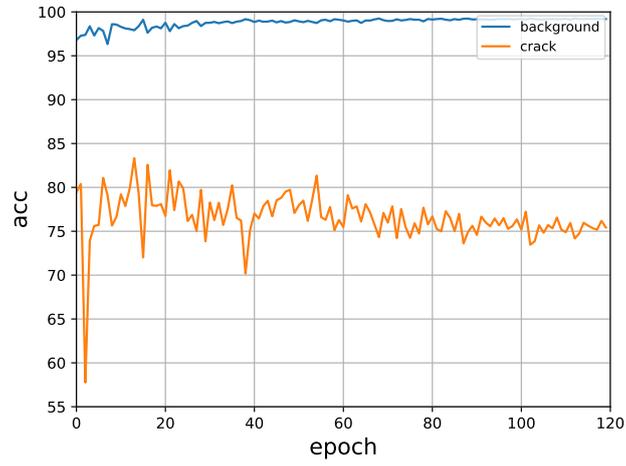
誤差関数	交差エントロピー誤差
最適化関数	SGD
学習率	0.04
エポック数	120
バッチサイズ	8

図 3.3 は、それぞれのモデルの訓練時の正答率 (accuracy) の収束状況、図 3.4 は、損失 (loss) の収束状況である。図中の crack はひび割れ、background はそれ以外の部分のグラフとなっている。

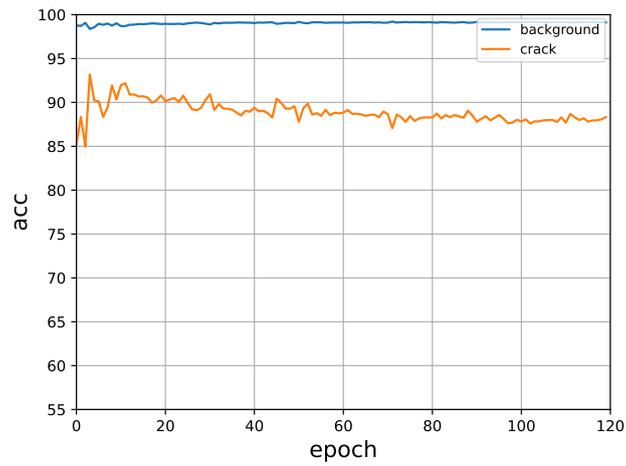
図 3.4 より学習が進むにしたがって、損失も減少していることがわかる。図 3.3 をみると、学習済み重みを利用し、分類器のみ再学習させたモデル B がもっとも精度が低く、続いて、学習済み重みを利用しないモデル A、学習済み重みを利用し、モデル全体を再学習させたモデル C の順となった。学習済みの重みは、Pascal VOC で提供されている COCO train2017 から 20 カテゴリを取り出したデータセットが用いられているが、ひび割れ画像のような特徴のある画像について学習させる場合は、分類器のみではなく、特徴量を抽出するバックボーン部まで学習させたほうが精度が高くなると考えられる。



(a) モデル A

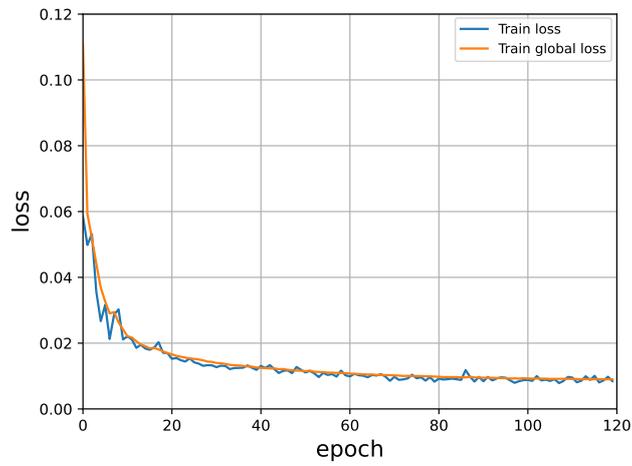


(b) モデル B

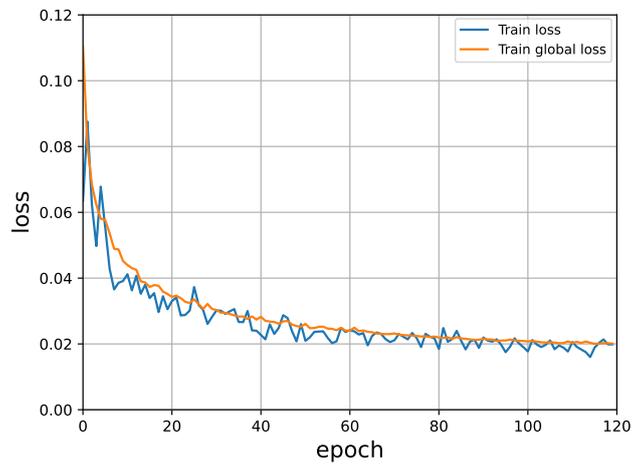


(c) モデル C

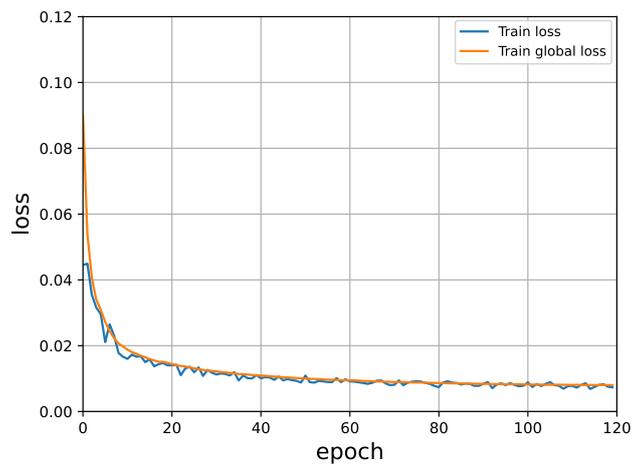
図 3.3 正答率 (accuracy) の収束状況



(a) モデル A



(b) モデル B



(c) モデル C

図 3.4 損失 (loss) の収束状況

### 3.5 領域分割における精度について

前節で、AI モデルの訓練時の正答率を図 3.3 に示したが、この正答率はピクセル単位のクラス毎の正答率を集計したものとなっており、セマンティック・セグメンテーションを用いて領域分割を行った場合の精度として不十分である。領域分割の場合の精度は、推論された領域 (推論領域) と正解の領域 (正解領域) を比較検討することによって求めるのが適切である。領域分割で用いられる評価指標としては、F 値 (DICE 係数) や IoU (Intersection over Union; Jaccard 係数) がよく知られている。F 値よりも IoU のほうがより厳しい指標となっており、IoU は Pascal VOC や ImageNet などの代表的ベンチマークにおいても、物体検出や領域分割の誤差評価を行う場合に用いられている。図 3.5 に推論領域、正解領域および正答領域の概略を示す。

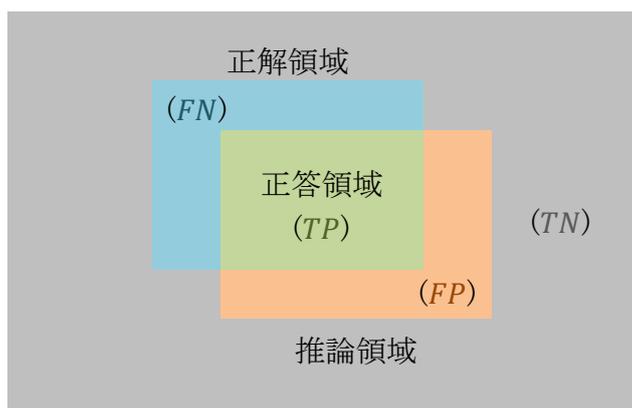


図 3.5 推論領域、正解領域および正答領域の概略

表 3.3 領域分割における混同行列

	Positive	Negative
True	$TP$ ( <span style="color: green;">■</span> ) 物体を 正しく推論できた領域	$TN$ ( <span style="color: gray;">■</span> ) 物体ではない部分を 正しく推論できた領域
False	$FP$ ( <span style="color: orange;">■</span> ) 物体と誤検知した領域	$FN$ ( <span style="color: blue;">■</span> ) 物体を見逃した領域

図中の  $TP$ ,  $TN$ ,  $FP$ ,  $FN$  はそれぞれ表 3.3 に示す混同行列 (Confusion Matrix) の通りである.

式 (3.1)~ 式 (3.5) に代表的な評価指標を示す.

$$\text{Precision(適合率)} = \frac{TP}{TP + FP} \quad (3.1)$$

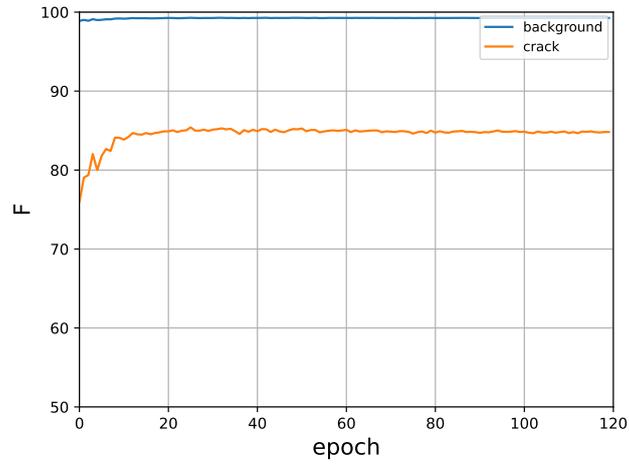
$$\text{Recall(再現率)} = \frac{TP}{TP + FN} \quad (3.2)$$

$$\text{F 値 (DICE 係数)} = \frac{2}{1/\text{Precision} + 1/\text{Recall}} = \frac{2TP}{2TP + FP + FN} \quad (3.3)$$

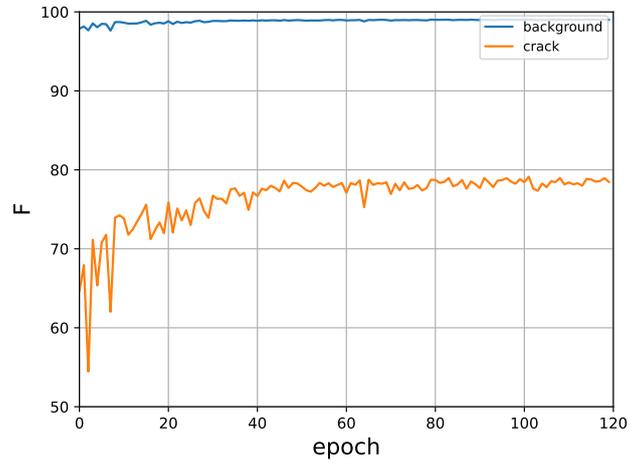
$$\text{IoU(Jaccard 係数)} = \frac{TP}{TP + FP + FN} \quad (3.4)$$

$$\text{Global correct} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.5)$$

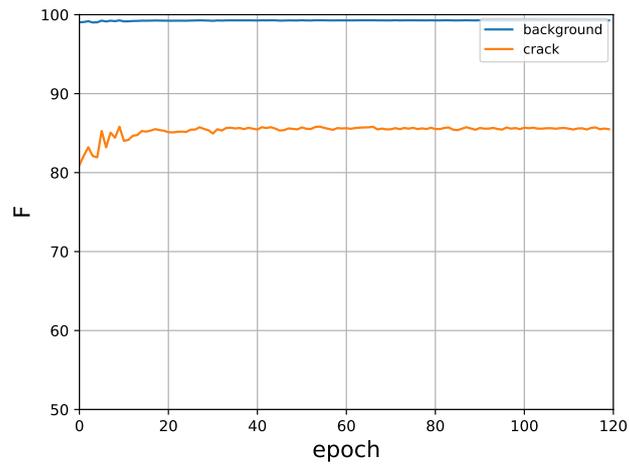
図 3.6, 図 3.7 に F 値, IoU の収束状況, 図 3.8 に, Global correct, mean F, mean IoU の収束状況を示す.



(a) モデル A

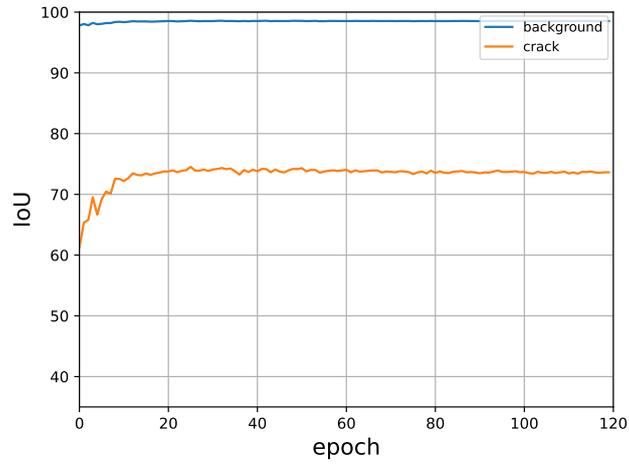


(b) モデル B

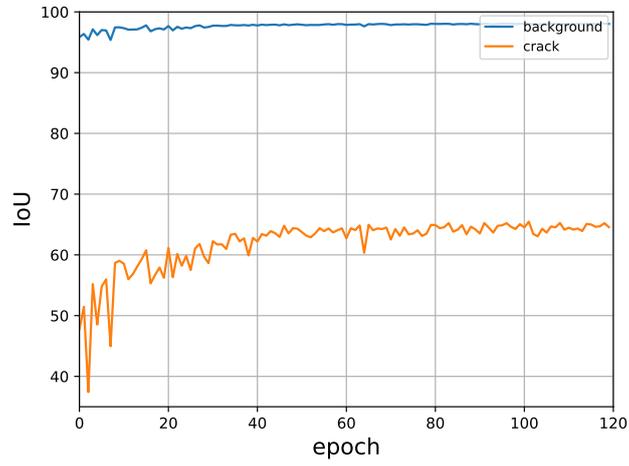


(c) モデル C

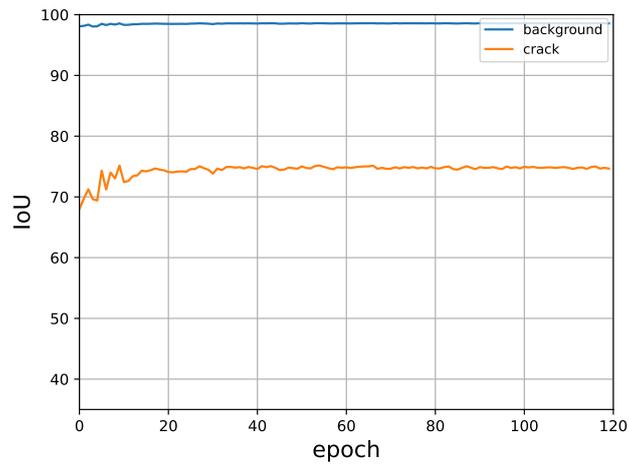
図 3.6 F 値の収束状況



(a) モデル A

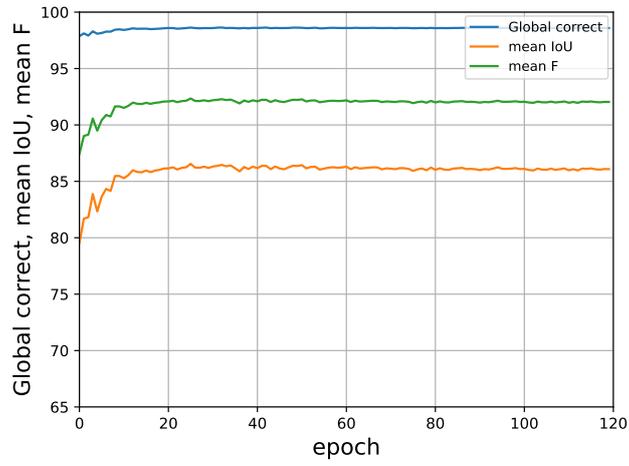


(b) モデル B

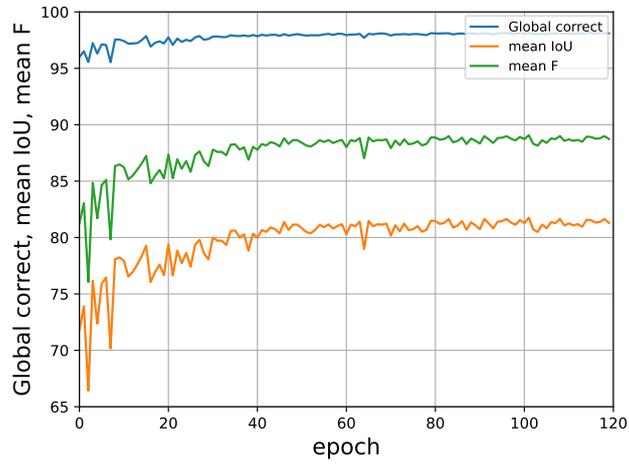


(c) モデル C

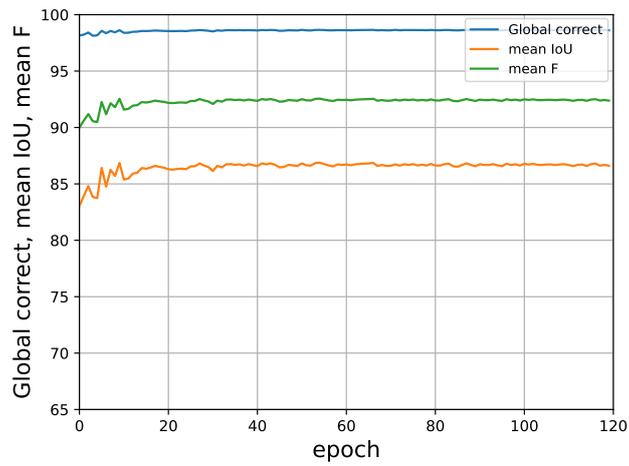
図 3.7 IoU の収束状況



(a) モデル A



(b) モデル B



(c) モデル C

図 3.8 Global correct, mean F, mean IoU の収束状況

表 3.4 は, 各モデルの訓練終了時のひび割れ (crack) の F 値および IoU, ひび割れと背景 (background) の平均 F 値 (mean F) および平均 IoU(mean IoU) をまとめたものである.

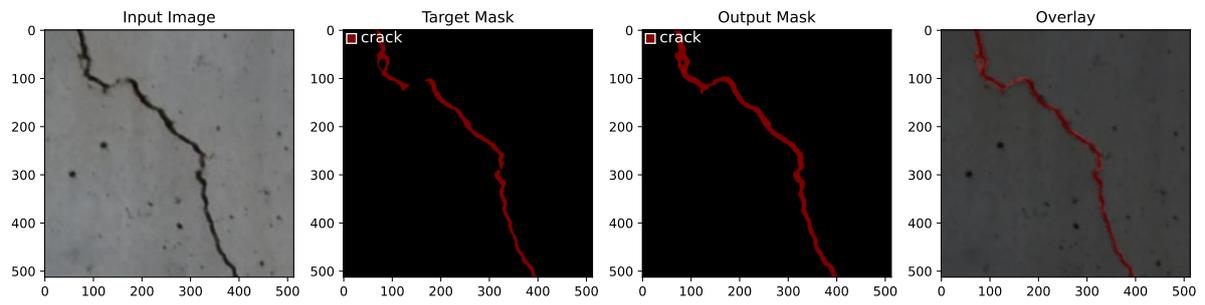
表 3.4 訓練終了時の F 値, IoU, mean F, mean IoU

	モデル A	モデル B	モデル C
F 値	84.8%	78.5%	85.5%
IoU	73.6%	64.6%	74.7%
mean F	92.0%	88.7%	92.4%
mean IoU	86.0%	81.3%	86.6%

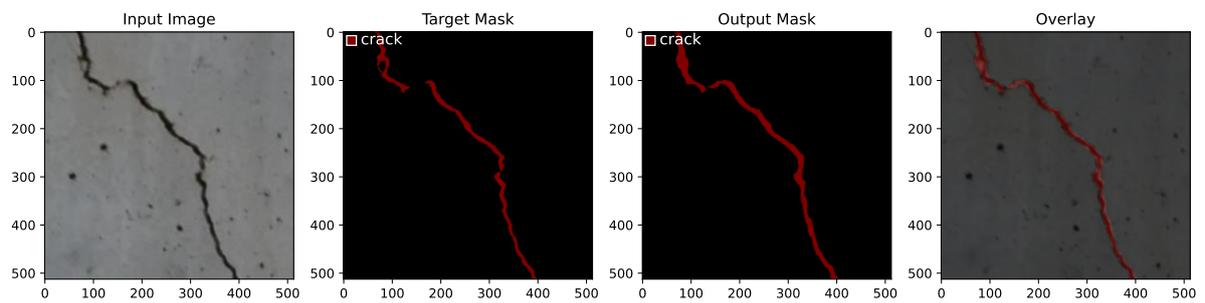
どの指標においても, モデル C が最も精度が高い結果となった.

## 3.6 解析結果

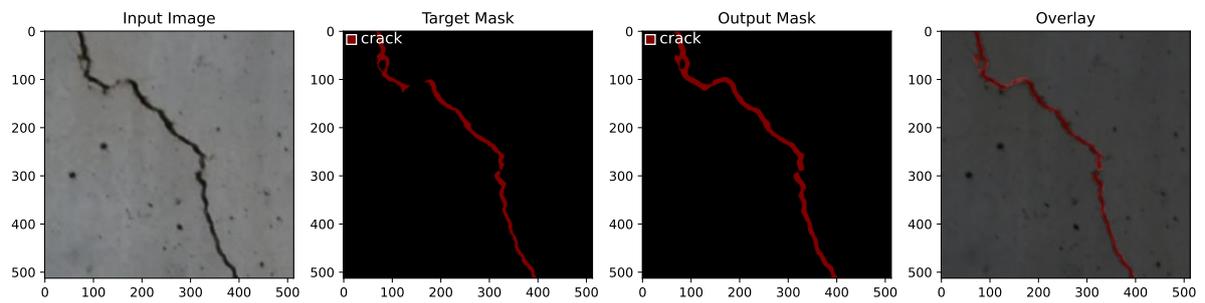
テスト用に準備した教師データに含まれない 30 枚の画像について, 本研究で構築した AI を用いた解析を行った. 5 枚の画像の解析結果を図 3.9~図 3.13 に示す. 図中の Input Image が入力画像, Target Mask が正解画像, Output Mask が推論結果, Overlay は入力画像と推論結果を重ね合わせたものである.



(a) モデル A (F 値:82.5%, IoU:70.3%, mean F:91.0%, mean IoU:84.7%)

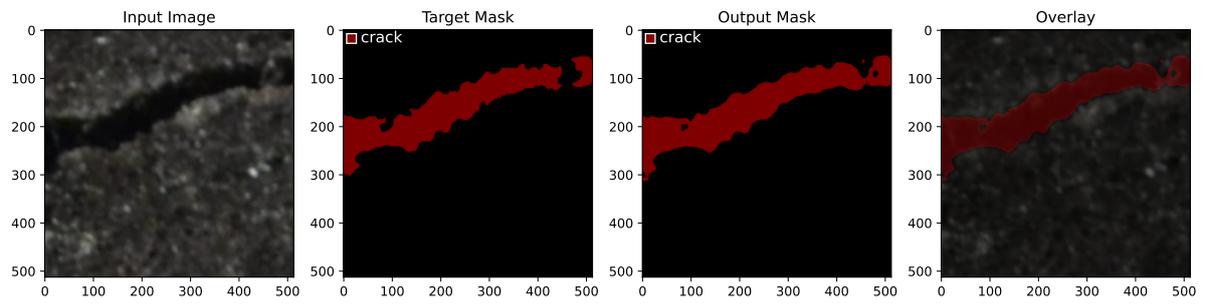


(b) モデル B (F 値:79.6%, IoU:66.1%, mean F:89.5%, mean IoU:82.5%)

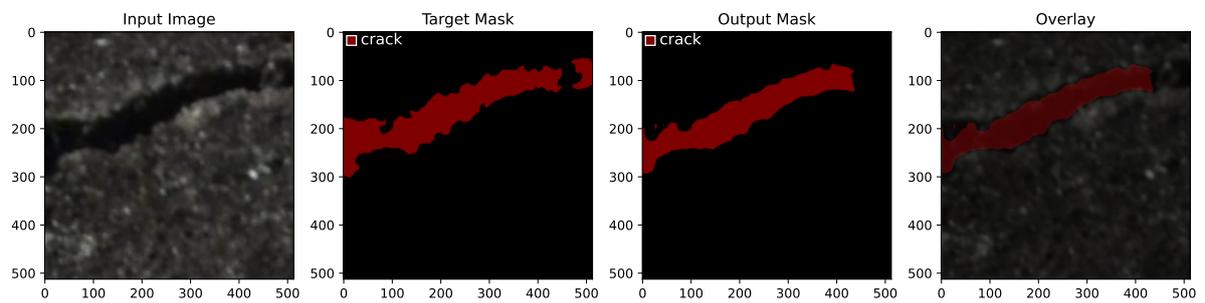


(c) モデル C (F 値:83.6%, IoU:71.9%, mean F:91.6%, mean IoU:85.5%)

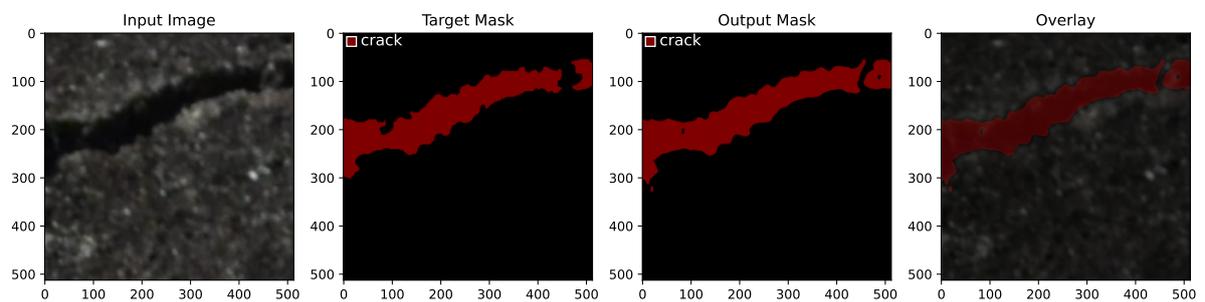
図 3.9 画像 1 の解析結果



(a) モデル A (F 値:94.0%, IoU:88.8%, mean F:96.6%, mean IoU:93.6%)

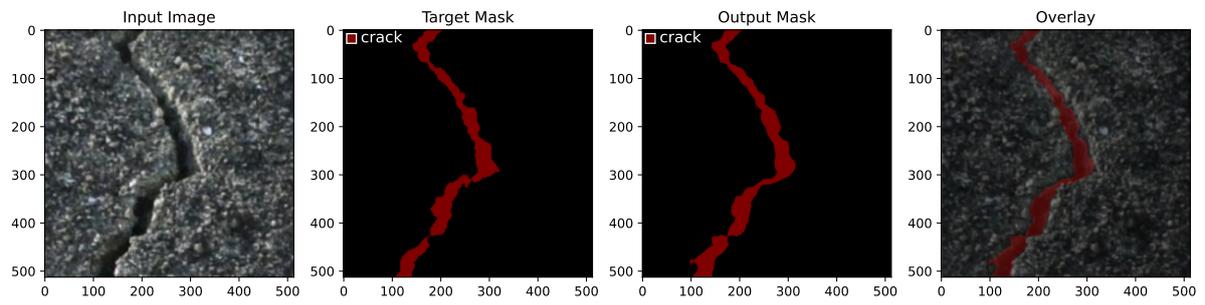


(b) モデル B (F 値:86.1%, IoU:75.6%, mean F:92.2%, mean IoU:86.2%)

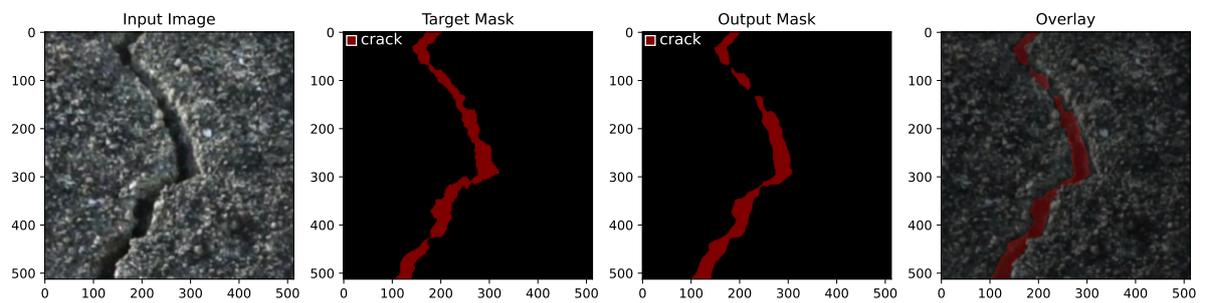


(c) モデル C (F 値:94.1%, IoU:88.8%, mean F:96.6%, mean IoU:93.6%)

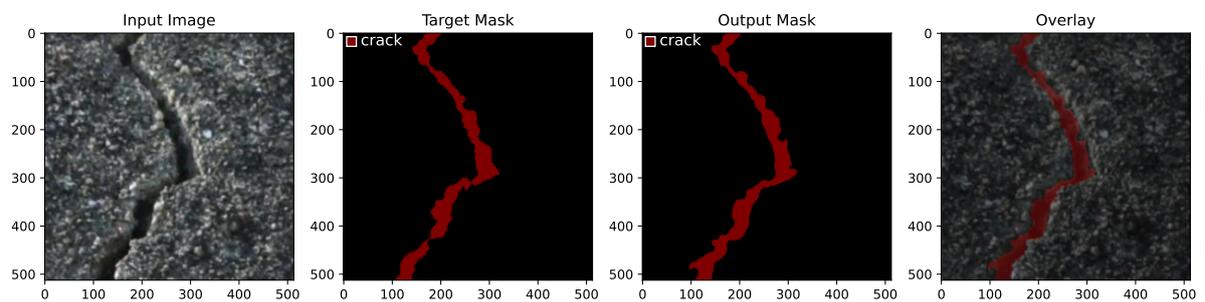
図 3.10 画像 2 の解析結果



(a) モデル A (F 値:89.1%, IoU:80.4%, mean F:94.2%, mean IoU:89.5%)

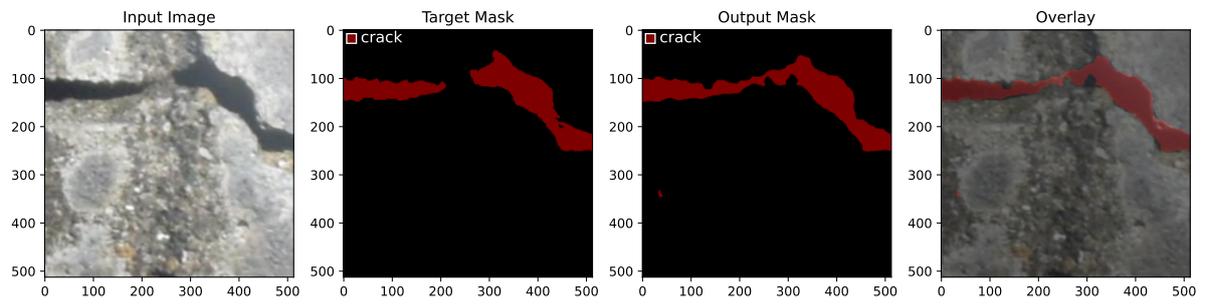


(b) モデル B (F 値:83.6%, IoU:71.9%, mean F:91.3%, mean IoU:85.0%)

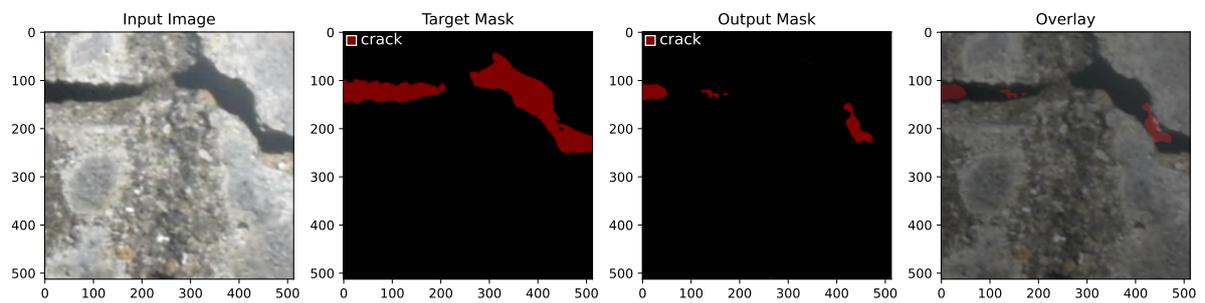


(c) モデル C (F 値:88.3%, IoU:79.0%, mean F:93.8%, mean IoU:88.8%)

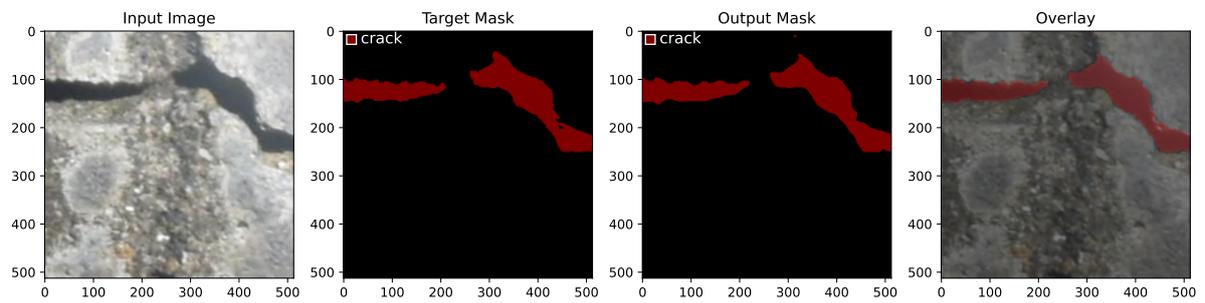
図 3.11 画像 3 の解析結果



(a) モデル A(F 値:91.3%, IoU:84.0%, mean F:95.3%, mean IoU:91.2%)

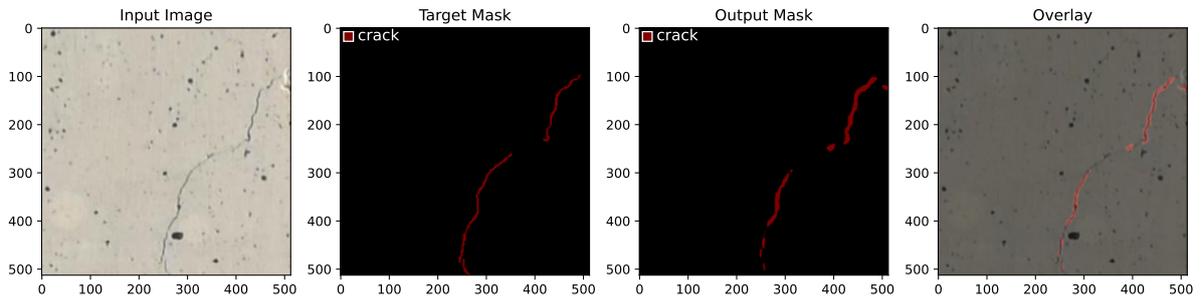


(b) モデル B(F 値:27.8%, IoU:16.1%, mean F:62.0%, mean IoU:54.5%)

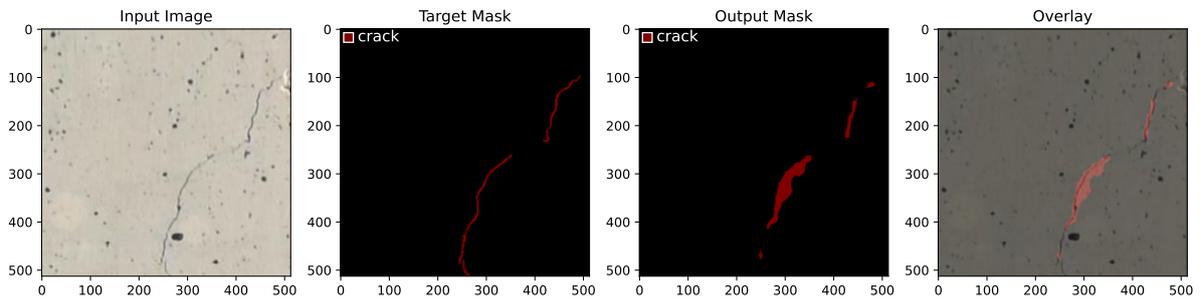


(c) モデル C(F 値:94.8%, IoU:90.1%, mean F:97.2%, mean IoU:94.6%)

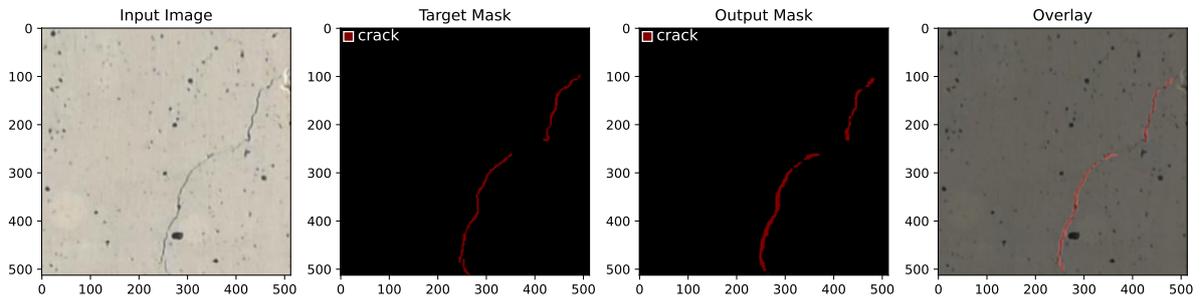
図 3.12 画像 4 の解析結果



(a) モデル A(F 値:56.4%, IoU:39.3%, mean F:78.0%, mean IoU:69.2%)



(b) モデル B(F 値:42.1%, IoU:26.7%, mean F:70.7%, mean IoU:62.7%)



(c) モデル C(F 値:67.9%, IoU:51.4%, mean F:83.8%, mean IoU:75.4%)

図 3.13 画像 5 の解析結果

画像 1(図 3.9)~画像 3(図 3.11) はどのモデルも精度良く検出できているが、画像 4(図 3.12) では、モデル A、モデル C の IoU が、84.0%、90.1% であるのに対し、モデル B の IoU は 16.1% とかなり差がでる結果となった。また、画像 5 のような細かいひび割れに関しては、各モデルとも精度が低くなった。全体を通してみると、学習済みの重みを利用し、モデル全体を再学習させたモデル C が他のモデルより高い精度となっていた。

30 枚の画像について解析結果の集計結果を表 3.5 に示す。

テストデータの解析結果でも、モデル C が最も精度が高い結果となっており、ひび割れ (crack) の F 値 90.4% は全らの既往研究と比較しても非常に高い精度でひび割れを検出

表 3.5 テストデータの解析結果

	モデル A	モデル B	モデル C
F 値	90.1%	82.5%	90.4%
IoU	82.0%	70.2%	82.5%
mean F	94.7%	90.7%	94.9%
mean IoU	90.4%	84.1%	90.7%

できていると言える。また、領域分割のベンチマークで一般的に用いられる mean IoU においても 90.7% と高い精度を有していることから、本研究の手法によるひび割れ検出は十分実用的なレベルに達していると考えられる。

### 3.7 おわりに

本章では、領域分割 AI のインフラ維持分野への適用可能性を検討するため、深層学習 (Deep Learning) を用いたセマンティック・セグメンテーション (Semantic Segmentation) を用いて、ひび割れが生じているコンクリートの画像からひび割れをピクセル単位で自動的に抽出する手法について検討を行った。AI モデルとして、DeepLabv3 を採用し、900 枚の教師データを用いて AI の構築を行い、F 値、IoU、mean F、mean IoU を評価指標として用いて、構築した AI モデルの精度検証を 30 枚の画像に対して行ったところ、最も精度の高いモデル C では、それぞれ 90.4%、82.5%、94.9%、90.7% という高い精度を得ることができた。今回の教師データは、256×256 ピクセルの画像を用いているが、DeepLabv3 の標準的な入力サイズは 513×513 ピクセルであることから、より高解像度の画像を教師データとして用いれば、さらに高精度な AI モデルを構築できると考えられる。また、撮影時の情報から画像のピクセルの実寸法を求めれば、ひび割れ幅やひび割れ長の算出も可能になると考えられる。

本研究の手法をさらに発展させ実構造物に適用することで、目視点検の欠点を補いつつ、その精度の助力となる迅速性・客観性を兼ね合わせたコンクリート構造物のひび割れ評価方法が開発していくことができると考える。

## 参考文献

- [15] 鵜飼正人「画像処理によるトンネル構造物ひび割れ検査精度の向上」『特集: 信号通信技術』24.3 (2010), p. 53.
- [16] 全邦釘, 片岡望, 三輪知寛, 橋本和明, 大賀水田生「統計的特徴および幾何学的特徴に着目したコンクリート表面ひび割れの画像解析による検出」『土木学会論文集 F3 (土木情報学)』70.2 (2014), I.1–I.8.
- [17] 全邦釘, 井後敦史「Random Forest によるコンクリート表面ひび割れの検出」『土木学会論文集 F3 (土木情報学)』71.2 (2015), I.1–I.8.
- [18] 全邦釘, 嶋本ゆり, 大窪和明, 三輪知寛, 大賀水田生「ディープラーニングおよび Random Forest によるコンクリートのひび割れ自動検出手法」『土木学会論文集 F3 (土木情報学)』73.2 (2017), I.297–I.307.
- [19] 山根達郎, 全邦釘「Deep learning による Semantic Segmentation を用いたコンクリート表面ひび割れの検出」『構造工学論文集 A』65A (2019), pp. 130–138.
- [20] Liang-Chieh Chen, George Papandreou, Florian Schroff, and Hartwig Adam. *Rethinking Atrous Convolution for Semantic Image Segmentation*. 2017. DOI: 10.48550/ARXIV.1706.05587. URL: <https://arxiv.org/abs/1706.05587>.
- [21] Vijay Badrinarayanan, Alex Kendall, and Roberto Cipolla. *SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation*. 2015. DOI: 10.48550/ARXIV.1511.00561. URL: <https://arxiv.org/abs/1511.00561>.
- [22] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. 2015. DOI: 10.48550/ARXIV.1505.04597. URL: <https://arxiv.org/abs/1505.04597>.
- [23] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, and Jiaya Jia. *Pyramid Scene Parsing Network*. 2016. DOI: 10.48550/ARXIV.1612.01105. URL: <https://arxiv.org/abs/1612.01105>.
- [24] Liang-Chieh Chen, George Papandreou, Iasonas Kokkinos, Kevin Murphy, and Alan L. Yuille. *Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs*. 2014. DOI: 10.48550/ARXIV.1412.7062. URL: <https://arxiv.org/abs/1412.7062>.
- [25] Liang-Chieh Chen, George Papandreou, Iasonas Kokkinos, Kevin Murphy, and Alan L. Yuille. “DeepLab: Semantic Image Segmentation with Deep Convolu-

- tional Nets, Atrous Convolution, and Fully Connected CRFs”. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 40.4 (2018), pp. 834–848. DOI: 10.1109/TPAMI.2017.2699184.
- [26] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, and Hartwig Adam. *Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation*. 2018. DOI: 10.48550/ARXIV.1802.02611. URL: <https://arxiv.org/abs/1802.02611>.
- [27] The PyTorch Foundation. URL: <https://pytorch.org/>.
- [28] The GIMP Team. URL: <https://www.gimp.org/>.
- [29] The PASCAL VOC project. *The PASCAL Visual Object Classes Homepage*. URL: <http://host.robots.ox.ac.uk/pascal/VOC/index.html>.

## 第4章

# 物体検出 AI を用いた橋梁の損傷 検出

### 4.1 はじめに

我が国では、戦後急速に道路インフラが整備され、交通や経済を支えきた。しかしながら、近年では、老朽化や交通量の増加や過積載車両の増加に伴い、橋梁の変状が顕在化し、また、安全安心のための維持管理不足が深刻に問題視されるようになった。このような現状を踏まえ、国土交通省は、道路法施行令第35条の2第2項の規定に基づき、道路法施行規則において、道路の維持・修繕に関する具体的な基準等を定めるため、「道路法施行規則の一部を改正する省令」および「トンネル等の健全性の診断結果の分類に関する告示」を2014年3月31日に公布した[2]。この省令および告示では、各道路管理者の責任による点検→診断→措置→記録というメンテナンスサイクルを確立するために、具体的な点検頻度や方法等を法令で定めることを目的としており、以下のような内容の行うこととなっている。

- 橋梁(約70万橋)・トンネル(約1万本)等は、国が定める統一的な基準により、5年に1回の頻度で、近接目視により点検を行うことを基本とすること
- 点検、診断の結果等について、記録・保存すること
- 統一的な尺度で健全性の診断結果を分類すること

一方、2013年10月時点までは、橋梁点検要領を作成している自治体の約8割が遠望目視による点検を採用していたことが国土交通省の調べで分かっている。遠望目視と近接目視を比較すると、近接目視による点検の方が橋梁の状態を把握しやすく、遠望目視では発

見できなかった劣化等を発見することができる。しかしながら、近接目視による点検は、効果的・効率的な検査でない。指標となる健全性の診断を適切に行える高度な知識と経験豊富な維持管理技術者の不足、点検が高所にわたるものや大掛かりな作業・足場が必要な場合もあり、莫大な費用と時間がかかるため橋梁の維持管理は全国的に大きな課題になっている。20年後には老朽橋は約4倍、維持費用は約6割増加し、技術者は約2割減少すると予想されており、安全性の確保やコストの抑制のためにインフラ維持管理のイノベーションが不可欠である。

橋梁の損傷検出に関する既往の研究として、田畑ら [30] の研究では、UAV を用いて撮影した画像を分割し、それぞれの画像に対して、深層学習を用いて画像分類を行うことで、損傷を検出する方法について検討している。

青島ら [31] の研究では、コンクリート部材表面の変状8種に対して、深層学習を用いて画像分類を行い、Fine Tuning や Data Augmentation を行うことで高い正答率が得られることを示している。また、画像分類で用いたデータセットに対して物体検出を行い、単一の損傷を有する画像に対する検出精度について検討を行っている。

党, 全ら [32] の研究では、多種類の橋梁損傷を同時検出することを目的として、UAV で撮影した画像を用いてひび割れ、腐食、剥離の3種について深層学習を用いた物体検出を行った結果を報告しているが、画像に対して損傷が小さい場合、損傷を検出できないなどの問題点を指摘している。

本章では、橋梁等のインフラの維持管理技術として活用することを目的として、カメラによる静止画やドローン等による動画から、損傷の発生箇所と損傷の種類と一度に特定できる損傷検知 AI の構築について検討する。

## 4.2 物体検出手法について

画像認識における物体検出 (Object Detection) とは、1枚の画像の中から複数の物体の種類 (クラス) と位置を検出することを指す。

図 4.1 は、物体検出処理の結果例である。図 4.1 では、1枚の画像から人物 (Person) の位置および馬 (Horse) の位置が検出されている。

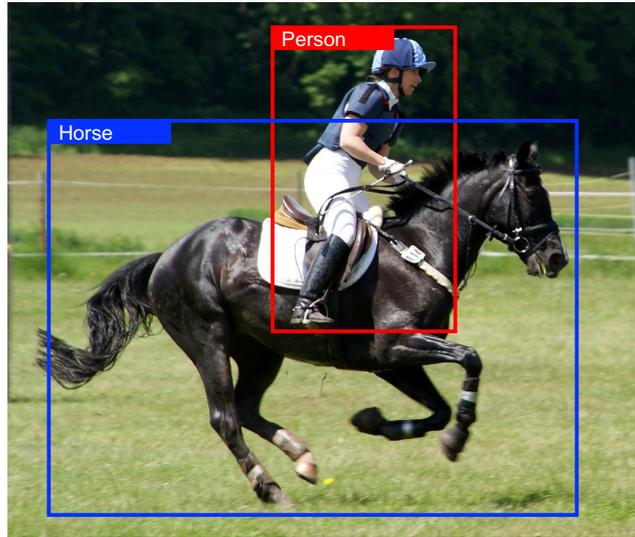


図 4.1 物体検出結果の例

一般的に、物体検出処理では画像を入力データとし、出力データとして以下の3つの情報が得られる。

1. 物体を含む矩形領域 (以後、バウンディングボックス) の位置とサイズ
2. 物体のクラスを示すラベル情報
3. 検出結果の信頼度 (confidence)

バウンディングボックスの情報は、矩形領域の形を規定するものとなっており、長方形の左上の  $x, y$  座標 ( $x_{min}, y_{min}$ ) と右下の  $x, y$  座標 ( $x_{max}, y_{max}$ )、もしくは、中心の  $x, y$  座標 ( $c_x, c_y$ ) とバウンディングボックスの幅 ( $w$ ) と高さ ( $h$ ) で記述される。なお、左上が座標の原点となる。

図 4.2 は、バウンディングボックスの2通りの記述方法を図示したものである。

3の検出の信頼度は各バウンディングボックスとラベルに対する確からしさを示しており、物体検出処理では、この信頼度の高いバウンディングボックスのみが最終的に出力される。

図 4.3 は古典的な物体検出処理の流れ図である。

図 4.3 の5の画像分類処理では畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) が利用されることが多い。CNN を繰り返し利用することから容易に想像されるように、物体検出処理には多くの計算コストが必要となるため、実際に用いられる手法では高速化のための様々な工夫が行われている。

AI を用いた代表的な物体検出手法 (Object Detection) としては、R-CNN[33],

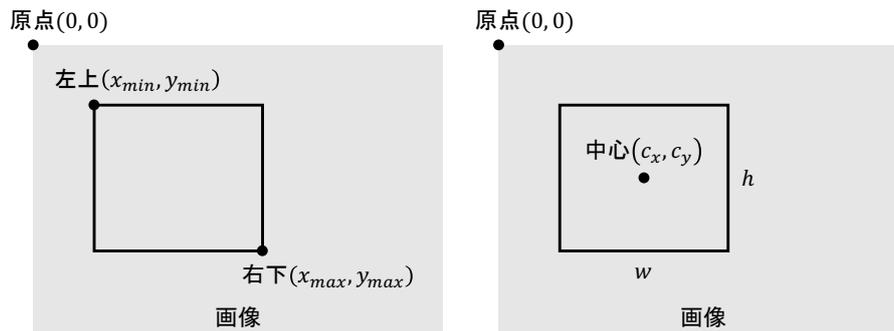


図 4.2 バウンディングボックスの記述方法

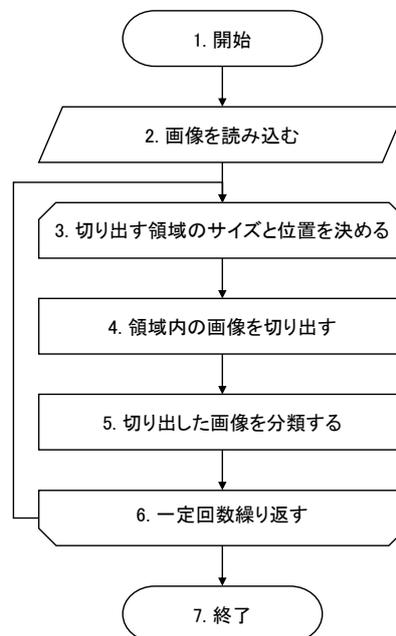


図 4.3 物体検出処理の流れ

YOLO[34], SSD[35] 等をあげることができる。本研究では、高速かつ高精度に物体検出可能なモデルである SSD を用いることとした。

### 4.3 SSD

SSD(Single Shot Multibox Detector) は、物体検出モデルの 1 つで、Single Shot の名前が示す通り、1 度の画像分類処理で物体の領域候補検出と種類の推論を行うため、高速な処理が可能となっている。SSD には、画像を  $300 \times 300$  ピクセルにリサイズして入力する

SSD300 と、512×512 にリサイズして入力する SSD512 がある。

SSD では画像から物体を含むバウンディングボックスを求める際に、直接バウンディングボックスを出力するのではなく、あらかじめ定めた「デフォルトボックス」と呼ぶ矩形領域をどのように変形させればバウンディングボックスになるかという情報を出力する。このデフォルトボックスを変形させる情報をオフセットと呼んでいる。

SSD では、デフォルトボックスの情報が  $(c_{xd}, c_{yd}, w_d, h_d)$ 、オフセットの情報が  $(\Delta c_x, \Delta c_y, \Delta w, \Delta h)$  であった場合、バウンディングボックスは式 (4.1) 以下のように計算される。なお、式 (4.1) は、理論的に導かれるものではなく、SSD の内部処理で行われている計算式である点に注意されたい。

$$\begin{aligned}
 c_x &= c_{xd}(1 + 0.1\Delta c_x) \\
 c_y &= c_{yd}(1 + 0.1\Delta c_y) \\
 w &= w_d \times \exp(0.2\Delta w) \\
 h &= h_d \times \exp(0.2\Delta h)
 \end{aligned}
 \tag{4.1}$$

図 4.4 は、デフォルトボックスからバウンディングボックスへの変換を図示したものである。

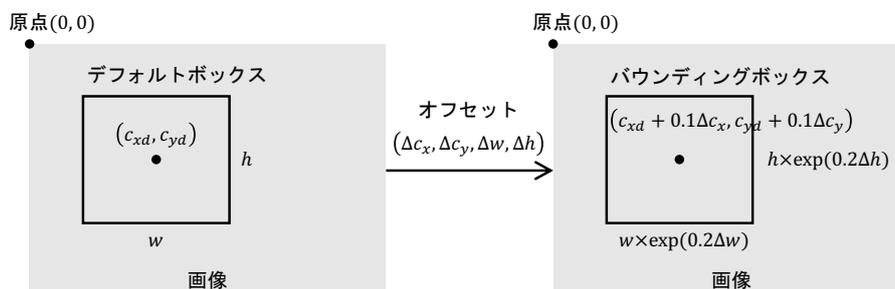


図 4.4 デフォルトボックスからバウンディングボックスへの変換

図 4.5 は、SSD300 の処理の流れである。図中の DBox は Default Box(デフォルトボックス)、BBox は Bounding Box(バウンディングボックス) の略である。

図 4.5 について簡単に説明する。SSD300 では、まず、入力画像サイズが 300×300 にリサイズされる(手順 1)。この処理は、内部で使用している畳み込み層に対応したものとなっている。続いて、手順 2 では、8,732 個のデフォルトボックス (DBox: Default Box) が準備される。手順 3 では、画像が SSD のネットワークに入力され、8,732 個のデフォルトボックスに対するオフセットと信頼度が出力される。手順 4 では、デフォルトボックスの内、信頼度が高いデフォルトボックスを抽出する。このときの信頼度の閾値としては、



図 4.5 SSD の処理の流れ

0.5(50%) や 0.75(75%) が用いられることが多い [36]。手順 5 では、オフセット情報を用いてデフォルトボックスをバウンディングボックスに修正し、バウンディングボックスの重なりが大きいものの内、信頼性が最も高いバウンディングボックスを取り出す。最後に、手順 6 として、一定の信頼度以上の BBox が出力される。

図 4.6 は SSD300 のネットワーク構造である。

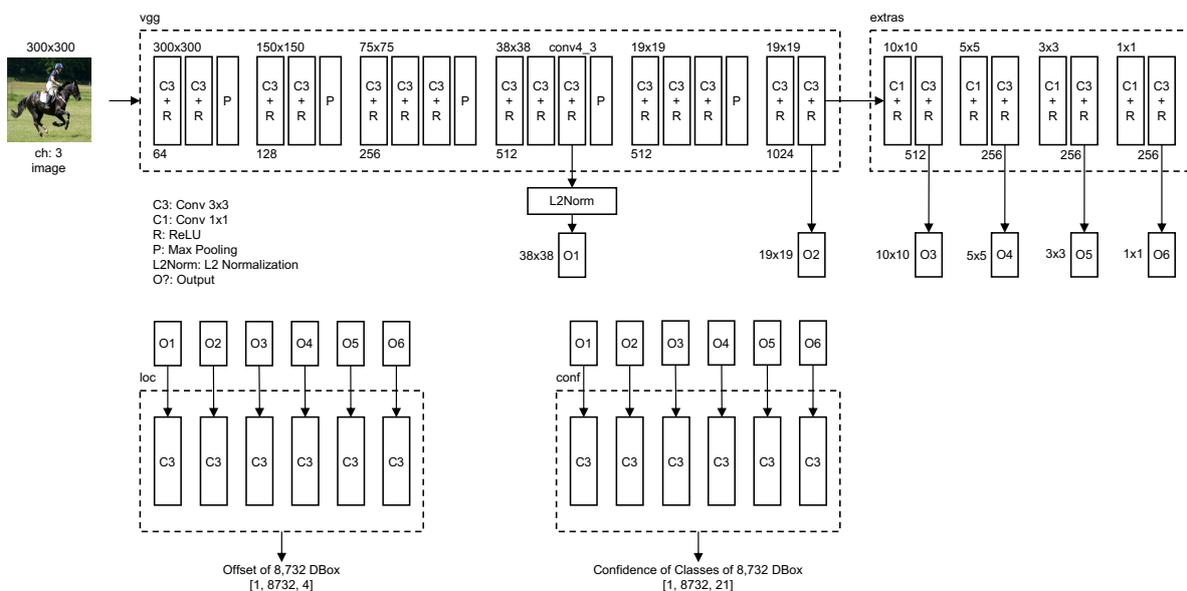


図 4.6 SSD のネットワーク構造

図 4.6 に示す通り, SSD のネットワーク構造は大きく 4 つのモジュール (vgg, extras, loc, conf) から構成される. 図中の C3 はフィルタサイズ  $3 \times 3$  の畳み込み層, C1 はフィルタサイズ  $1 \times 1$  の畳み込み層, P は最大プーリング層, R は活性化関数として ReLU が使用されていることを示している. L2Norm は, L2 正規化層である.

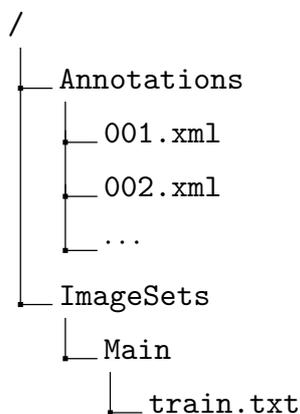
ネットワークに入力されたデータ (画像  $300 \times 300 \times$  色数 3 チャンネル) は, まず vgg モジュールに渡される. vgg モジュールは, 2 章で用いた VGG16 モデル [12] の一部を取り出したものとなっている. vgg モジュールに渡されたデータは, 10 回の畳み込み処理の後, L2 正規化層に渡され, これが出力 1(O1) となる. このとき, O1 の特徴量マップのサイズは,  $38 \times 38$  となっている. データは, さらに 5 回畳み込み処理され, 出力 2(O2) が取り出される. vgg モジュールから出力されたデータは, 次は extras モジュールに渡される. extras モジュールでは, それぞれ 2 回の畳み込み処理された結果が, 出力 3(O3)~ 出力 6(O6) として取り出される.

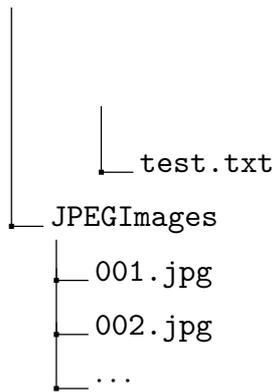
出力 1(O1)~ 出力 6(O6) は, loc モジュールでデフォルトボックスのオフセット情報に, conf モジュールで, 各デフォルトボックスにおける各クラスの信頼度に変換され出力される.

SSD のネットワーク構造では, ある程度畳み込みを行った段階 ( $38 \times 38$ ) で特徴量マップを取り出したため, 画像内の小さな物体の検出精度が低いという弱点がある.

## 4.4 教師データの作成

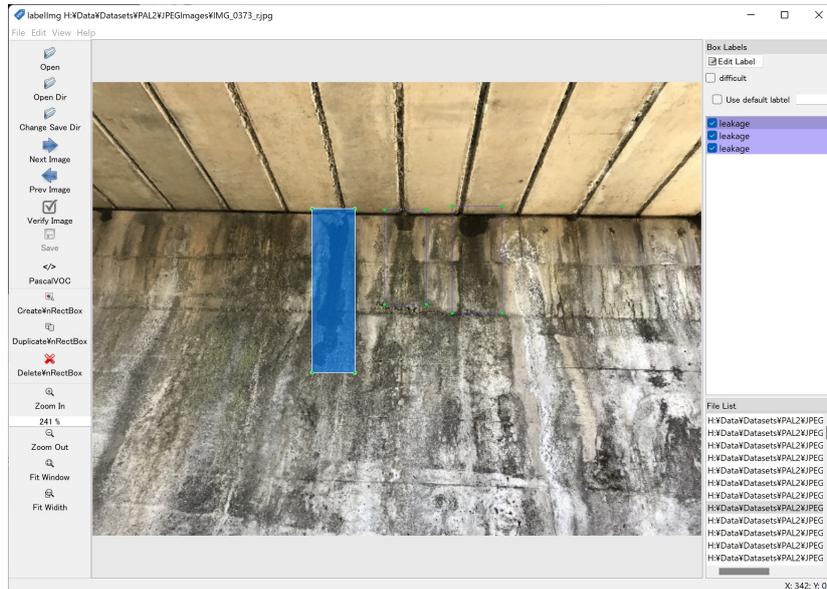
物体検出処理で用いる教師データは, 画像, 正解のバウンディングボックスとラベル情報から構成される. 教師データのフォーマットは幾つかの形式があるが, 本研究では一般的に用いられている VOC データセット 2012[29] に準拠した教師データを作成した. VOC データセット 2012 のディレクトリ構造は以下のようになっている.



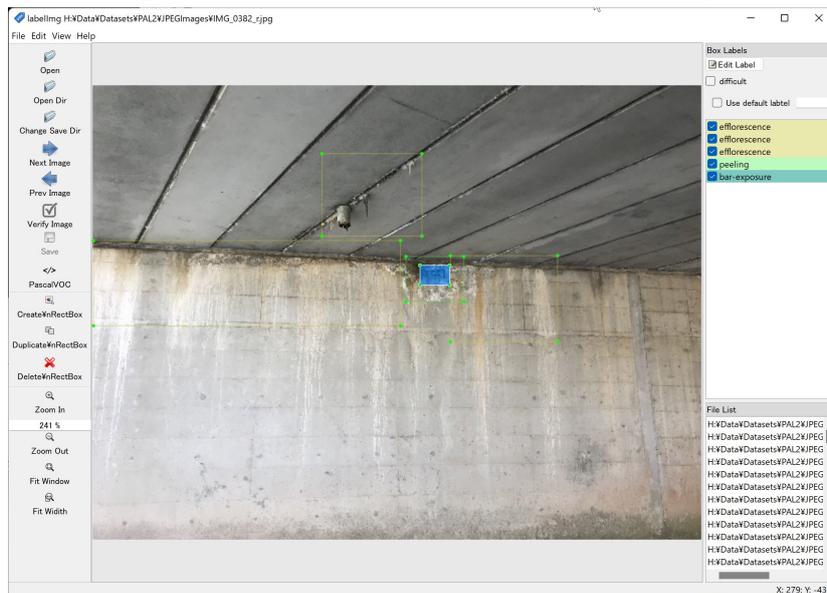


Annotations には, XML 形式で正解のバウンディングボックスとラベル情報を格納する。ImageSets/Main には, 訓練, テストで利用するデータセット情報を格納する。データセット情報は, テキスト形式のファイルの中に画像ファイル名から拡張子を除いたリストを格納する。JPEGImages には, 画像データを JPEG 形式で格納する。

VOC データセット形式の教師データは手動でも作成できるが, バウンディングボックスの座標値を調べてそれを XML で記述するには多くの時間を必要となるため, 通常は専用のツールを利用して作成されることが多い。代表的なツールとしては, LabelImg がある [37]。図 4.7 は, LabelImg を用いた教師データ作成画面である。



(a) 画面例 1



(b) 画面例 2

図 4.7 LabelImg を用いた教師データの作成

LabelImg では、画像を読み込みマウスを用いて矩形領域とラベル名を指定することで、バウンディングボックスの座標値とラベル名を書き出すことができる。

本研究では、教師データとして 129 枚の画像を用意し、各画像について LabelImg を用

いてラベル付けを行った。表 4.1 は、ラベル付けを行った損傷名とラベル名である。

表 4.1 教師データのラベル名

損傷名	ラベル名
剥離	peeling
鉄筋露出	bar-exposure
漏水	leakage
遊離石灰	efflorescence

## 4.5 AI モデルの訓練

前節で作成した教師データを訓練用、テスト用に 9:1 で分けたデータセットを作成した。画像枚数は、訓練用が 116 枚、テスト用が 13 枚である。訓練用データおよびテスト用データ中の各ラベルの正解バウンディングボックス数を表 4.2 に示す。

表 4.2 各ラベルの正解バウンディングボックス数

損傷名	ラベル名	訓練用	テスト用
剥離	peeling	108	18
鉄筋露出	bar-exposure	93	17
漏水	leakage	41	4
遊離石灰	efflorescence	153	20

AI モデルの訓練の訓練は、表 4.3 に示すパラメーターで行った。なお、AI モデルとしては、入力画像サイズ 512×512 の SSD512 を用いた。

表 4.3 中の Jaccard 係数 (IoU) は、ボックスの重なりを程度を表すもので、例えば、図 4.8 のようにボックスが重なっている場合、Jaccard 係数は式 (4.2) のように計算される。

$$\text{Jaccard 係数} = \frac{\text{正解ボックス} \cap \text{予測ボックス}}{\text{正解ボックス} \cup \text{予測ボックス}} \quad (4.2)$$

図 4.9 は訓練時の損失値の収束状況である。図中の confidence loss が信頼度の損失値、localization loss がオフセット情報の損失値、total loss はその合計となっている。

表 4.3 訓練パラメーター

パラメーター名	設定内容
損失関数	確率的勾配降下法 (SGD: Stochastic Gradient Descent)
イテレーション (回)	30, 000
バッチサイズ	32
Jaccard 係数	0.5
学習率 (Learning rate)	5.0e-4

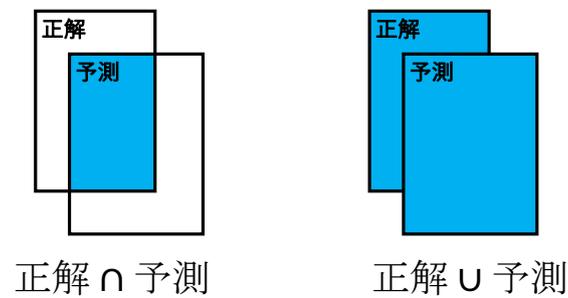


図 4.8 ボックスの重なり状況

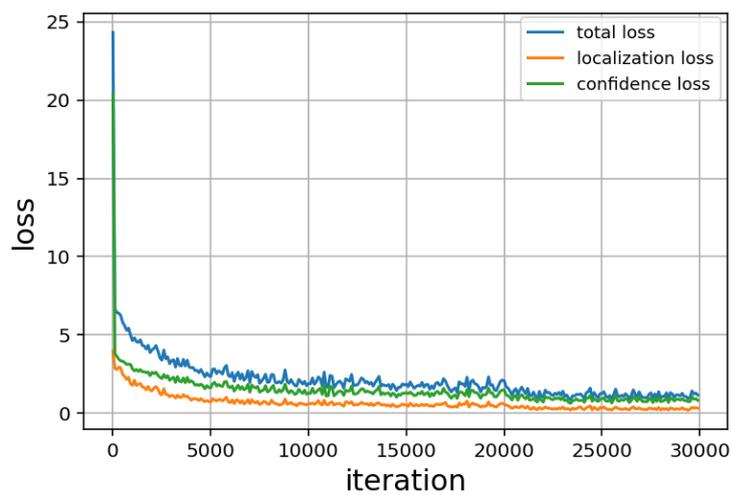


図 4.9 損失値の収束状況

図 4.9 から、訓練が進むにつれ損失値が低下してきていることがわかる。

## 4.6 解析結果

図 4.10~4.13 に前節で訓練した AI モデルとテスト用データを用いて画像中の損傷を推論した結果を示す。

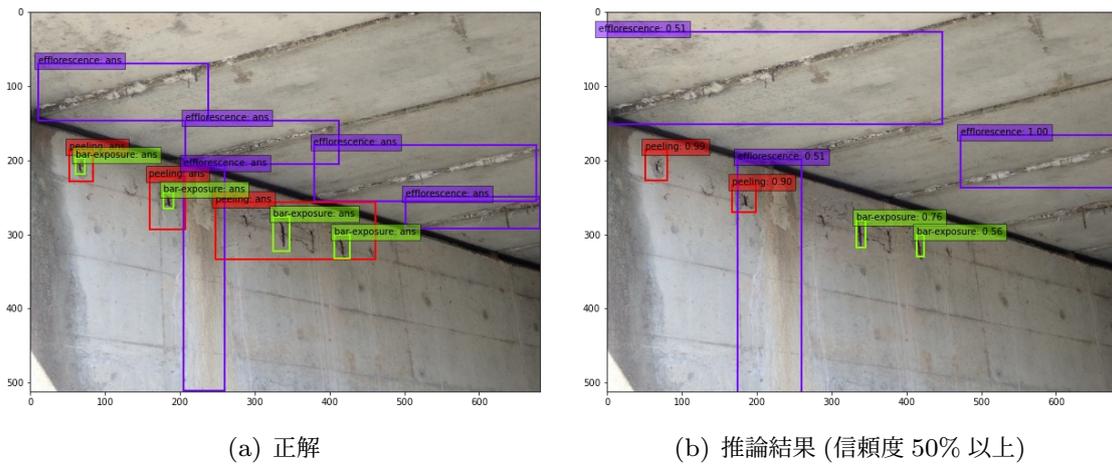


図 4.10 解析結果 (画像 No.2)

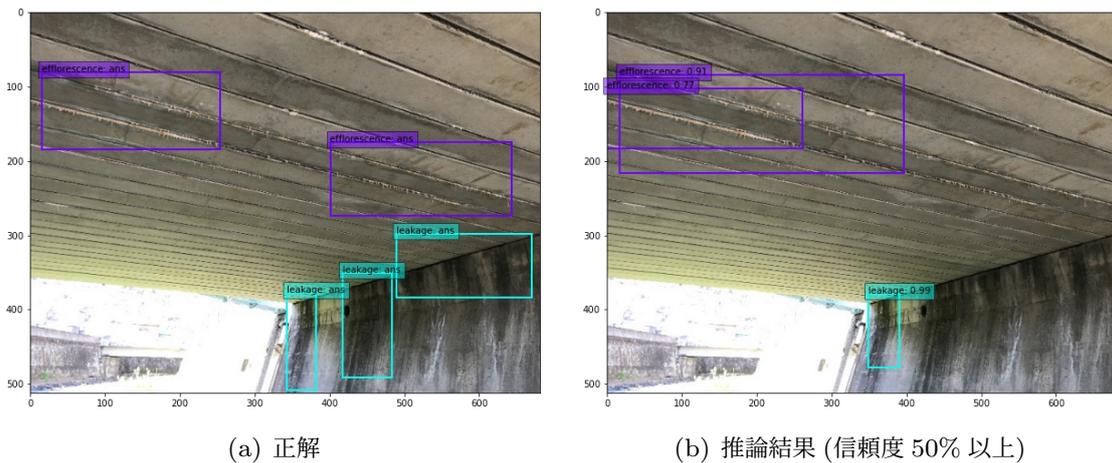


図 4.11 解析結果 (画像 No.7)

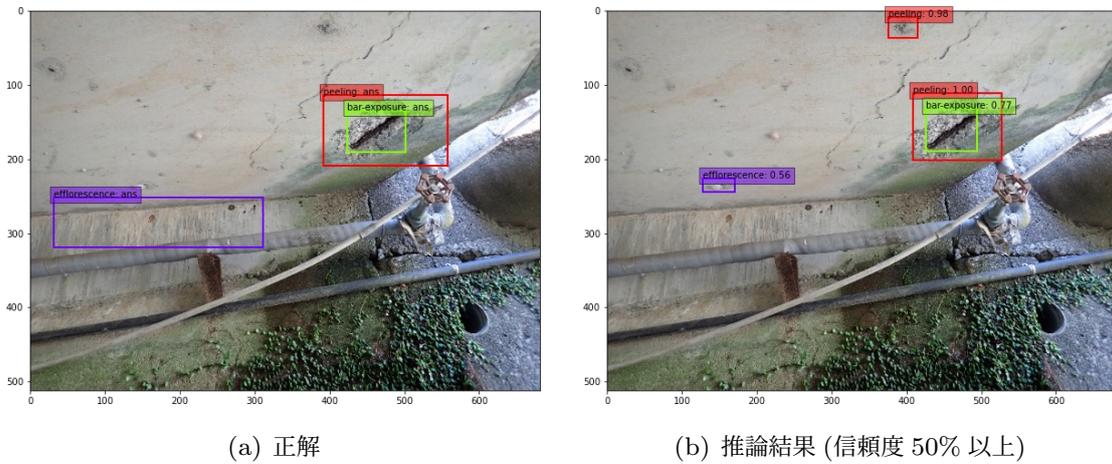


図 4.12 解析結果 (画像 No.8)

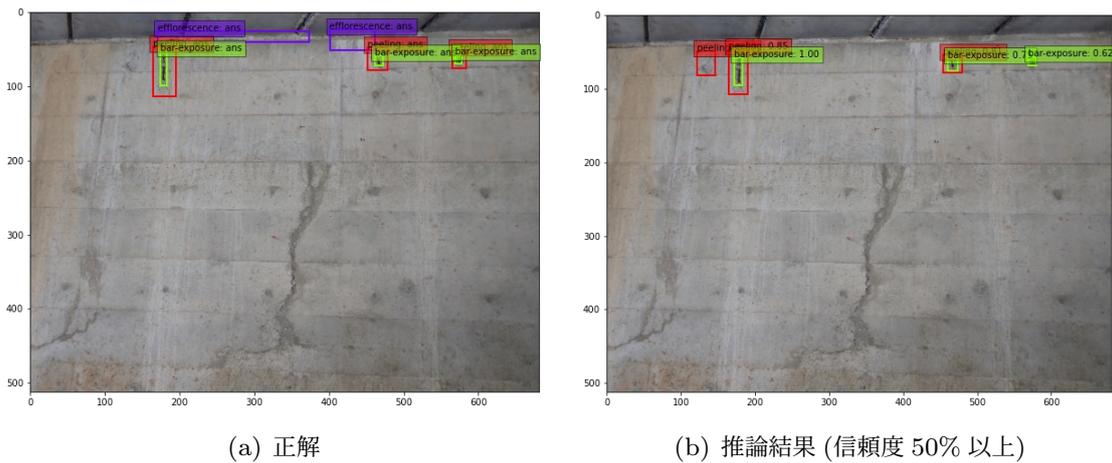


図 4.13 解析結果 (画像 No.9)

図 4.10~4.13 を見ると、剥離 (peeling) が最もよく検出できており、続いて鉄筋露出 (bar-exposure) もある程度検出できている。一方、漏水 (leakage) や遊離石灰 (efflorescence) については、検出精度が低い傾向であった。この理由としては、剥離や鉄筋露出は局所的な損傷であり、矩形領域での指定が容易であるのに対して、漏水や遊離石灰は線状に分布する損傷であるため、写真の角度によっては矩形領域の指定が難しかった点が考えられる。また、物体検出を用いた損傷検出では、損傷が重なっている部分についても複数の損傷を同時に検出できていることがわかる。

図 4.14 は、各損傷のラベルについて AP(Average Precision)[38] を計算し可視化したものである。AP は、物体検出処理において、広く利用されている指標で、適合率 (Precision)

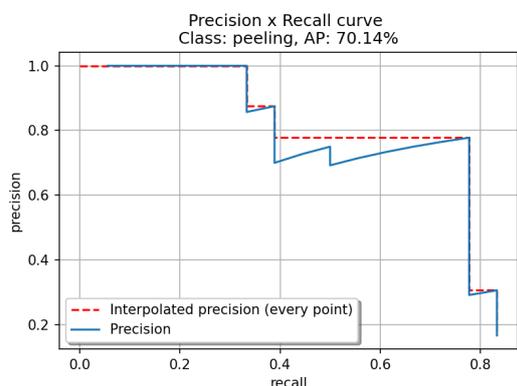
と再現率 (Recall) から計算される。適合率 (Precision) は、推論がどれだけ正しかったかを示す指標で、例えば、あるラベルの位置を 4 つ推測して、そのうち 2 つのバウンディングボックスの Jaccard 係数が 0.5 以上であれば、適合率 (Precision) は 50% となる。正解だった推論の数を TP(True Positive)、不正解だった推論の数を FP(False Positive) とすれば、適合率 (Precision) は式 (4.3) のように計算できる。再現率は (Recall) は、正解のうちどれぐらいを正答できたかを示す指標で、例えば、あるラベルの位置が 4 つある際に、3 つの位置を正答することができたら、再現率 (Recall) は 75% となる。推論されなかったあるラベルの位置を FN(False Negative) とすれば、再現率 (Recall) は式 (4.4) のように計算できる。AP の詳細な計算手順については、文献 [39] の Github レポジトリ等を参照されたい。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (4.3)$$

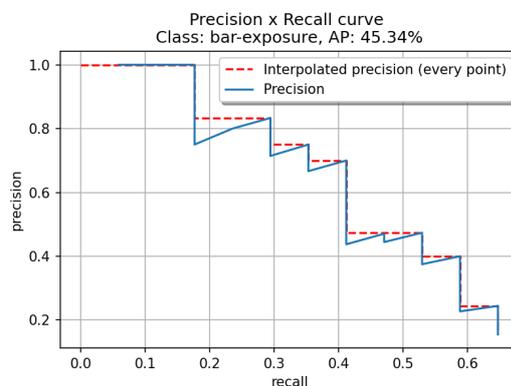
$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4.4)$$

図 4.14 を見ると、(a) 剥離の AP が 70.14% と最も高かった。(b) 鉄筋露出と (c) 漏水の AP は 40% 台と低い結果であった。(d) 遊離石灰については、AP が 17.84% と低い結果であった。これは、図 4.10~4.13 での推論結果とも概ね一致している。

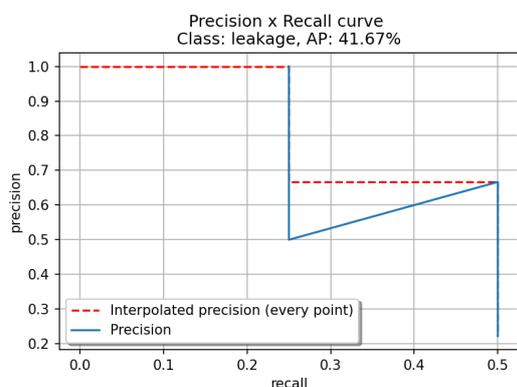
各ラベルにおける AP を平均した mAP(mean Average Precision) は、43.75% であった



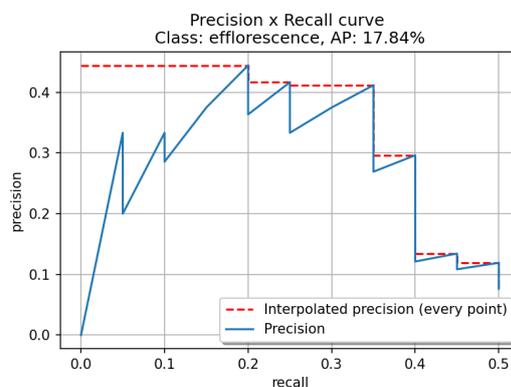
(a) 剥離 (peeling)



(b) 鉄筋露出 (bar-exposure)



(c) 漏水 (leakage)



(d) 遊離石灰 (efflorescence)

図 4.14 AP の計算結果

## 4.7 おわりに

本章では、物体検出 AI を用いて橋梁の損傷を検出する手法について検討するため、剥離 (peeling)、鉄筋露出 (bar-exposure)、漏水 (leakage)、遊離石灰 (efflorescence) の 4 つの損傷を対象として教師データを作成し、AI モデルの構築を行った。構築した AI モデルを用いて、テスト用データに対して推論を行ったところ、各ラベルの AP の平均値である mAP(mean Average Precision) は 43.75% であり、まだ十分な精度が得られていないと考えられる。十分な精度が出ていない原因としては、教師データ数が不足している、一部のラベルで矩形領域の指定が難しい点が考えられる。

また、それぞれの AP について見ると、AP が最も高い剥離で 70.14%、鉄筋露出 45.34%、

漏水 41.67%, 最も低い遊離石灰で 17.84% と, ラベルによって大きな開きがあった。鉄筋露出の精度が低い原因としては, 今回用いた教師データでは, 画像全体に比べ鉄筋露出部が小さな写真が多く, 小さな物体の検出に弱い SSD の弱点が出たためであると考えられる。鉄筋露出の精度を上げるためには, 鉄筋露出部をもう少し大きなバウンディングボックスで指定するなど, 教師データ作成時の工夫が必要である。次に, 漏水の精度が低い原因としては, 今回用いた教師データ全体で, 漏水の正解データのバウンディングボックスが表 4.2 に示すように少なく, 十分に学習できていない可能性がある。漏水の精度を上げるには, 教師データの数を増やして, 漏水の正解データの数を増やす必要がある。遊離石灰の精度がかなり悪かった原因としては, 今回用いた写真では, 遊離石灰が線状に分布していたため, 正解データのバウンディングボックスをどのように指定するかが難しかったことが考えられる。線状に分布した遊離石灰を大きなバウンディングボックスが指定するのか, 小さなバウンディングボックスの集まりとして指定するかで精度に影響がでると考えられる。遊離石灰については, 矩形領域を指定する物体検出の手法ではなく, 3 章で示した領域分割の AI モデルを用いたほうが, 精度良く検出できる可能性がある。今後の課題としては, 物体検出と領域分割など複数の AI モデルを用いて損傷を検出する手法を検討する必要があると考えられる。

## 参考文献

- [2] 国土交通省『道路の維持修繕に関する省令・告示の制定について（道路法施行規則の一部改正等）』, 2014-03, URL: [https://www.mlit.go.jp/report/press/road01\\_hh\\_000412.html](https://www.mlit.go.jp/report/press/road01_hh_000412.html).
- [12] Karen Simonyan and Andrew Zisserman. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2014. DOI: 10.48550/ARXIV.1409.1556. URL: <https://arxiv.org/abs/1409.1556>.
- [29] The PASCAL VOC project. *The PASCAL Visual Object Classes Homepage*. URL: <http://host.robots.ox.ac.uk/pascal/VOC/index.html>.
- [30] 田畑佑, 党紀, 春田大二郎, AshishSHRESTHA, 松永昭吾, 全邦釘「UAV 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証」『土木学会論文集 F4 (建設マネジメント)』74.2 (2018), L62-L74.
- [31] 青島亘佐, 河村伸哉, 中野聡, 中村秀明「深層学習による画像認識を用いたコンクリート構造物の変状検出に関する研究」『土木学会論文集 E2 (材料・コンクリート構造)』74.4 (2018), pp. 293-305.
- [32] 党紀, 水元大雅, 全邦釘, 劉佳明, 藤嶋斗南「YOLO を用いた多種類橋梁損傷の同時検出」『AI・データサイエンス論文集』2.J2 (2021), pp. 447-456.
- [33] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. “Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation”. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. 2014, pp. 580-587. DOI: 10.1109/CVPR.2014.81.
- [34] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. *You Only Look Once: Unified, Real-Time Object Detection*. 2015. DOI: 10.48550/ARXIV.1506.02640. URL: <https://arxiv.org/abs/1506.02640>.
- [35] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, and Alexander C. Berg. “SSD: Single Shot MultiBox Detector”. In: *Computer Vision – ECCV 2016*. Springer, 2016, pp. 21-37.
- [36] Papers With Code. *Object Detection on PASCAL VOC 2007*. URL: <https://paperswithcode.com/sota/object-detection-on-pascal-voc-2007>.
- [37] Tzutalin. *LabelImg*. 2015. URL: <https://github.com/tzutalin/labelImg>.

- [38] Rafael Padilla, Wesley L. Passos, Thadeu L. B. Dias, Sergio L. Netto, and Eduardo A. B. da Silva. “A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit”. In: *Electronics* 10.3 (2021). ISSN: 2079-9292. DOI: 10.3390/electronics10030279. URL: <https://www.mdpi.com/2079-9292/10/3/279>.
- [39] Rafael Padilla, Wesley L. Passos, Thadeu L. B. Dias, Sergio L. Netto, and Eduardo A. B. da Silva. *Open-Source Visual Interface for Object Detection Metrics*. URL: [https://github.com/rafaelpadilla/review\\_object\\_detection\\_metrics](https://github.com/rafaelpadilla/review_object_detection_metrics).

## 第5章

# たわみ影響線およびたわみの時刻歴 応答の変化率を用いた橋梁劣化箇所 同定手法

### 5.1 はじめに

近接目視中心の点検では、ひび割れや腐食等といった外観変状や材料劣化が分かるのみで、安全性の保証や落橋の危険性、補強や架替えの判断基準を明確に評価することができない。この問題を解決するには、最終的にはたわみや振動特性のような剛性の評価しかないと考えられる。

橋梁の劣化評価に関する既往の研究としては、剛性評価法として振動特性に着目したものが多く、

河村ら [40]、林ら [41] の研究では、実橋梁に対しては劣化を与えることは困難であるということで、鋼トラス橋に対して損傷を与えた数値解析を実施している。しかし、劣化を与えても固有振動数の変化は極めて小さく、昼夜や季節による温度変化による固有振動数の変化と劣化による固有振動数の変化が微小かつ同程度で区別が難しく、劣化の有無を評価することは困難であると結論づけられている。

武田、中島ら [42] の研究では、劣化による振動数の変化が微小であること、劣化の有無を評価できたとしても、劣化箇所を特定することは難しいことなどを考慮し、振動特性よりも構造物の劣化に対して敏感に反応すると考えられる橋梁のたわみに着目したヘルスマニタリング方法について検討している。その結果、解析と実験において劣化箇所 (20% 断面欠損) をおおよそ見つけることができることを確認している。さらに、劣化度が小さい

場合への検討, 実橋梁の場合の適切なたわみ計の選定, 実験の実施方法などを検討課題として挙げている。

渡邊ら [43] の研究では, 既存の小規模橋梁を対象に, 特定の車両を走行させて桁のたわみを計測し, そのたわみが一致するように桁の剛性低下度を同定する簡易的な構造ヘルスマニタリングを提示している。短支間橋桁において, 桁の損傷分布や損傷度を個別に求めることは困難であるので, 橋桁の平均的な曲げ剛性の低下度を推定するために, 部材の曲げ剛性を一様に低下させた場合 (低下度 10%~60%) について, 車輛通過時の桁のたわみを解析によって求めている。

林ら [44] の研究では, 鋼トラス橋に対してたわみ影響線の変化率に注目したヘルスマニタリング方法について報告している。報告では, 断面欠損を想定した場合, 固有振動数に与える影響は小さいが, たわみの影響線の変化率に与える影響は大きいこと, たわみの影響線の変化率を算定することにより, 損傷の有無・程度, 欠損箇所を特定することができることが示されている。

また, 宮濱ら [45] の研究では, かぶりコンクリートが剥離し鉄筋が剥き出しとなっている RC 桁に対して, トラック荷重による載荷試験を実施したわみを計測して報告している。報告では, 健全な橋梁のたわみ解析結果を用いて, たわみの影響線の変化率に注目して劣化箇所同定について検討しており, たわみの影響線の変化率の値が最大となっている箇所に, 大きな剥離・鉄筋露出が見られることを確認している。

これらの研究では, 比較的劣化度が大きい場合の橋梁を対象としている。

本章では, 劣化度が小さい橋梁を対象として, 実験と解析により, たわみの影響線およびたわみの時刻歴応答の変化率を用いた橋梁劣化箇所同定手法について検討する。

## 5.2 たわみ影響線の変化率を用いた橋梁劣化箇所同定手法

本節で検討する方法は, 劣化による橋梁の剛性の変化を, たわみの影響線の変化率を算出することで変状箇所を特定・評価しようとするものである。

RC 梁の載荷試験では, 図 5.1 に示すように [46], 最初のひび割れ発生で剛性が減じ, その後ひび割れ定常状態まではわずかに小さくなり, ひび割れ定常状態以降はひび割れ幅が大きくなるが剛性の変化はほとんどない。そして, 鉄筋降伏後に急激にたわみが大きくなり破壊に至る。一方, インフラの経年劣化という観点からは, RC 橋の場合には, ひび割れだけでなく, コンクリートのかぶり剥離, 鉄筋露出, 鉄筋断面欠損, 浮き等の変状により, 剛性が変化する。また, 鋼橋の場合は, 亀裂, 腐食等の劣化による断面欠損やボルト抜け落ち等により, 剛性が変化する。しかしながら, 変状の種類やその損傷度が剛性変化に及ぼ

す影響を詳しく調べた事例は少ない。このような状況を考慮して、永松ら [47] の研究を参考に、鉄筋が錆びて断面欠損した場合の荷重たわみ曲線を解析的に検討した。

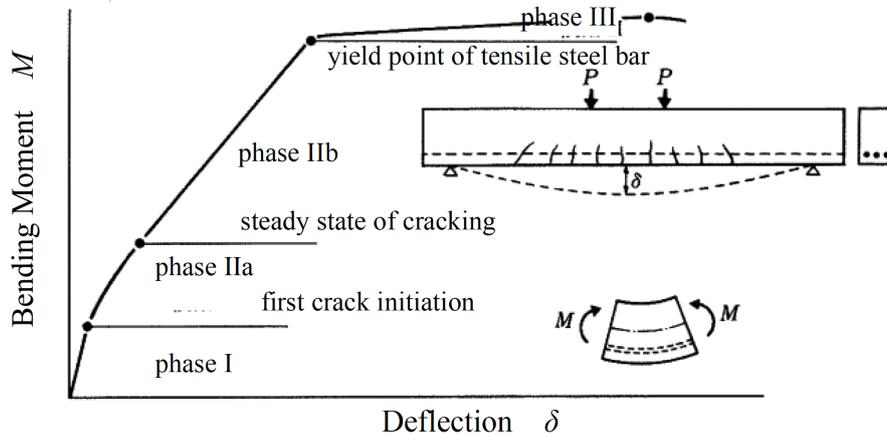


図 5.1 RC はりの  $M - \delta$  曲線

国土交通省が長さ 2m 以上の橋について、5 年に 1 回の近接目視を基本とする点検を省令で規定 [48] したことにより、コンクリート橋や鋼橋の劣化変状が調査されてきた。しかし、現時点においては、コンクリートや鋼材の劣化を評価する技術と、それに伴う構造性能を評価する技術に大きな開きがあり、供用を終了した構造物を用いて載荷実験などを実施してデータ収集し、構造性能を評価する技術の精度を向上を目指す必要があることなどが指摘されている [49]。

本章では、健全状態と劣化が生じた変状状態におけるたわみ量を比較し、その変化率によって、劣化箇所を特定する。本章では文献 [40] に倣って式 (5.1) の算出式を用いた [42]。

$$\text{変化率} = \left| \frac{\text{健全状態} - \text{変状状態}}{\text{健全状態}} \right| \times 100(\%) \quad (5.1)$$

## 5.2.1 たわみ影響線の変化率による実験

### (1) 実験概要

実験では、図 5.2 に示すように、高さ 50mm、幅 50mm、ウェブ厚 3mm、フランジ厚 4mm のアルミ製 H 型材を用いて、支間長 3,000mm の梁試験体を製作し、たわみ影響線の変化率を用いて構造部材の変状箇所が検知可能か否かの検証試験を行った。

載荷試験状況を図 5.3 に示す。梁の両端を剛な H 型材の上に置き、支点はピン支持状態となるように設置した。載荷は 294N(30kgf) の錘を吊り下げて行った。

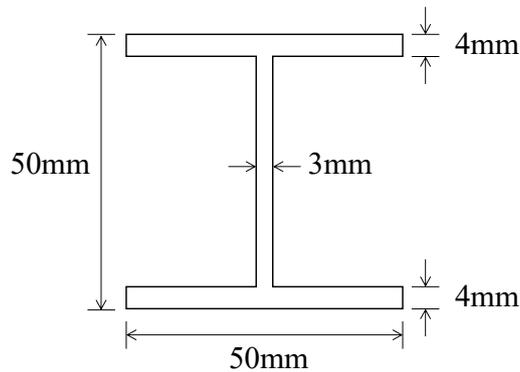


図 5.2 H 型アルミ材の断面

たわみ影響線法では，載荷点 (LP:Loading Point) を複数必要とするため，図 5.3(a) に示すように，載荷点を 5 ヶ所取った．計測点は MP(Measurement Point) と表記した．なお，たわみは接触式高感度変位計 ((株) 東京測器研究所製 CDP-10) を使用して計測した．

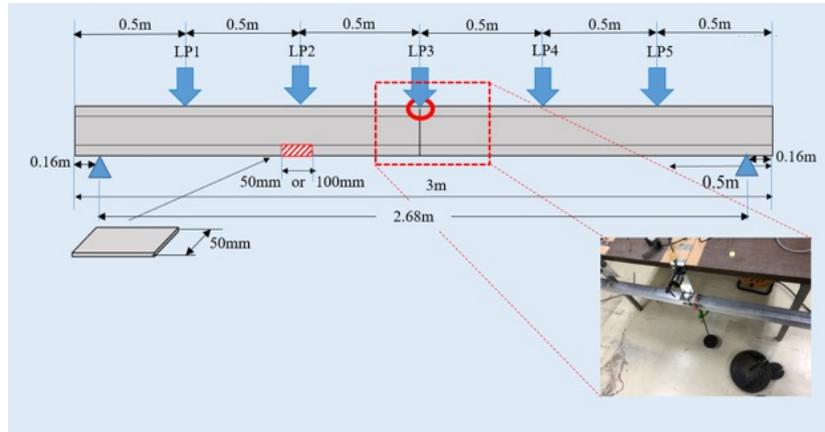
本研究の目的は，劣化した橋梁の剛性低下を評価することであるが，ここでは，剛性変化を，劣化ではなく補強することにより評価する実験方法で検討することとした．すなわち，剛性変化の与え方として，厚さ 3mm，奥行長 (フランジ幅) 50mm，幅 50mm または 100mm のアルミ板を下フランジ (フランジ幅 50mm) に貼り付けて補強することにより剛性を変化させた．なお，接着は市販の金属用強力接着剤を使用した．アルミ板での補強前を健全状態，補強後を変状状態として，各状態で 294N(30kgf) の錘を載荷点 (LP1~LP5) に載荷し，たわみを計測した．本実験では，アルミ板の幅，計測点，アルミ板補強位置を表 5.1 に示す 3 ケースを実施した．各ケースの条件を表 5.1 および図 5.4~5.6 に示す．

表 5.1 実験ケース

	補強位置	アルミ板の幅	測定点 (MP)
Case 1	LP2 の下面	100mm	LP3(MP3)
Case 2	LP2 の下面	50mm	LP3(MP3)
Case 3	LP1 の下面	50mm	LP2(MP2)

LP: 載荷点, MP: 計測点

実験結果と比較するため，骨組解析を実施した．一例として Case 1 での条件の計測点 1~5 におけるたわみ影響線の変化率曲線を図 5.7 に示す．同図において，一番上側の灰色



(a) 荷重試験の概略



(b) 荷重点および支持点

図 5.3 アルミはりの荷重試験の概要

の線は MP2 を示す。この線 MP2 は、荷重がそれぞれ 1~5 点 (図 5.7) に荷重されたときの計測点 2 のたわみを表す。以後、これをたわみの影響線と称す。

アルミ板の補強箇所である MP2 での変化率が最も大きく、計測点が MP2 から離れるほど変化率が小さくなっているが、いずれの計測点においても、アルミ板での補強箇所 (LP2) の変化率が最大となっている。すなわち、どの点を計測しても、アルミ鋼板を接着した補強箇所の変化率が大きくなった。したがって、実橋梁の点検を考慮した場合、変位計の設置が容易な箇所を任意に選択して、計測点位置を決定することができるので、たわ

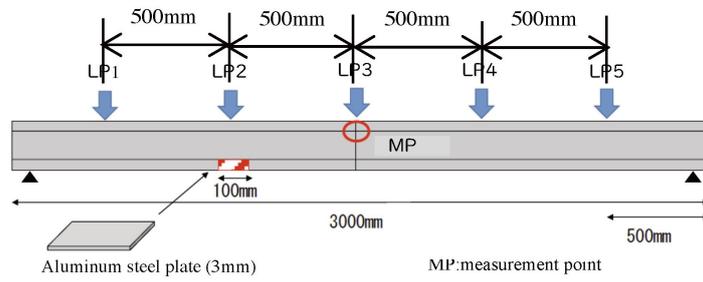


図 5.4 Case 1 の実験条件

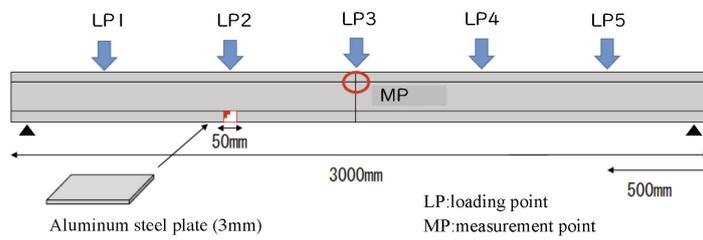


図 5.5 Case 2 の実験条件

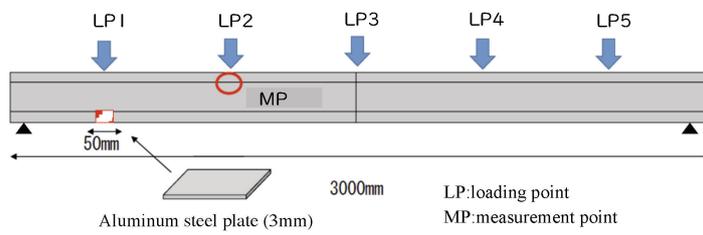


図 5.6 Case 3 の実験条件

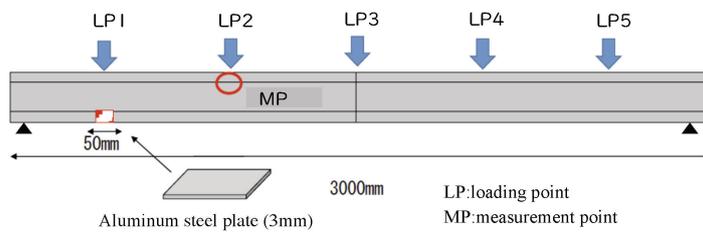


図 5.7 たわみ影響の変化率 (解析)

みの影響線の変化率を用いる本法の有用性は高いと考えられる。

## (2) 実験結果および考察

まず、健全状態におけるたわみの影響線の実験値と解析値を比較した結果について、Case 1(MP3)の結果を図 5.8 に示す。実験結果と解析結果はよく一致している。

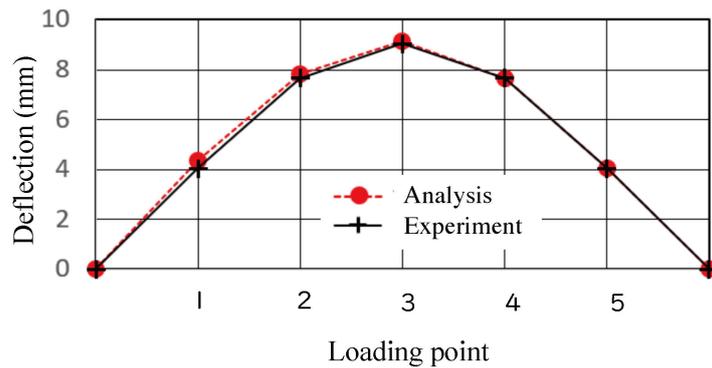


図 5.8 健全状態でのたわみの影響線の実験および解析結果の比較

次に、実験における、健全状態とアルミ板で補強した状態のたわみ影響線 (MP3) を比較した結果を図 5.9 に示す。図 5.9 では、健全状態とアルミ板で補強した状態の 2 つの結果はほとんど差がなく、たわみ影響線のみを用いて変状箇所を特定することは困難である。

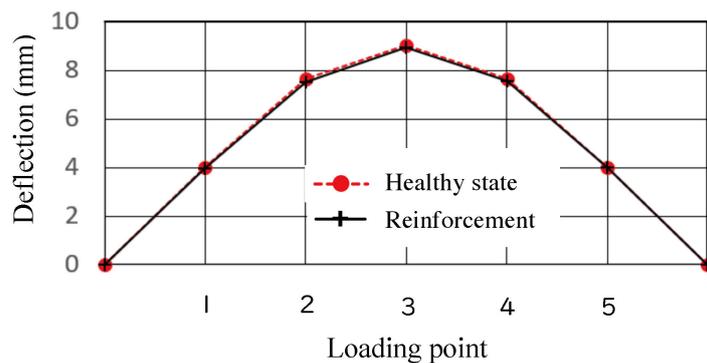


図 5.9 補強前後のたわみの影響線の比較

以上の結果を踏まえ、各 Case のたわみ影響線の変化率の実験値と解析値の比較結果を図 5.10~5.12 に示す。Case 1, Case 2 においては、実験値および解析値ともに、アルミ板で補強した LP2 箇所の変化率が最大となった。

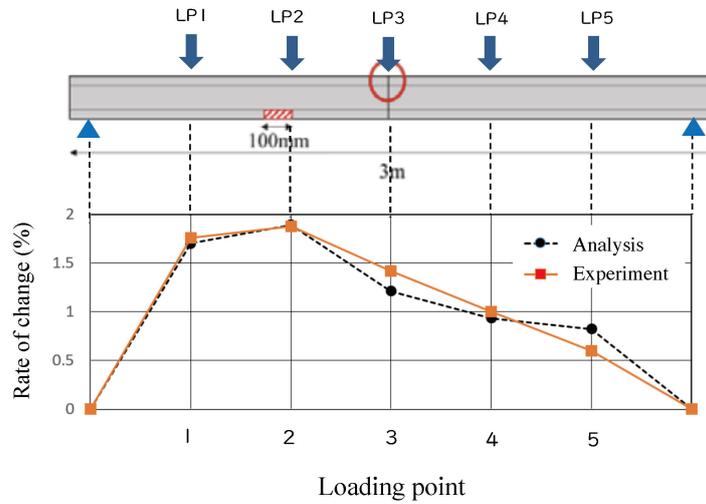


図 5.10 たわみ影響線の変化率 (Case 1)

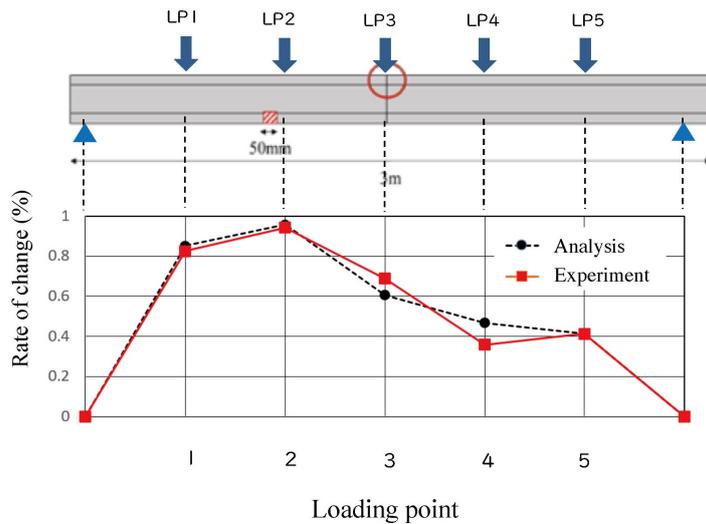


図 5.11 たわみ影響線の変化率 (Case 2)

Case 3 においても、アルミ板で補強した LP1 に変化率の最大値が現れたが、実験値と解析値で差が生じた。この差の発生要因を検討した結果、骨組解析により、LP2 を補強後の段階で、支点側に 1.6mm、LP5、LP6 をそれぞれ支点側に 2.5mm、1.0mm だけずらしたところ、実験値と解析値は一致した。アルミ板での補強前と補強後とで、載荷点がわずかにずれていたことによるものであることが確認できた。このようにたわみ影響線の変化率は敏感であることが確認できる。

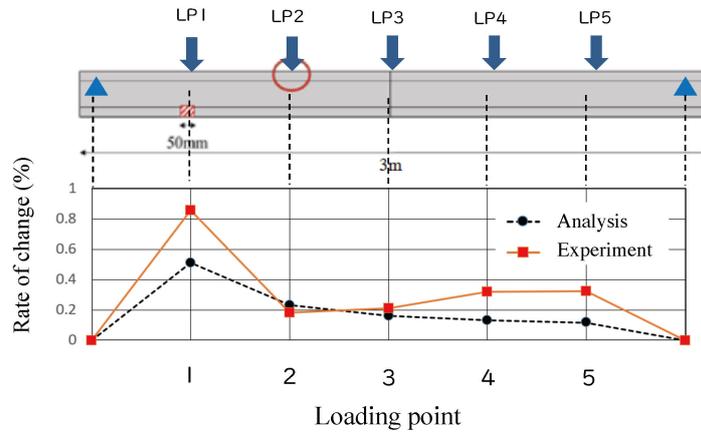


図 5.12 たわみ影響線の変化率 (Case 3)

本研究の実験においては、試験体が 3,000mm の H 型材であるため、荷重において 1.0mm 程度のずれでも影響が出てしまった。しかし、解析値と実験値の差異より、変化率の最大箇所の特特定が本研究の目的であることを考慮すると、実橋梁で適用する場合は計測対象物が大きい分、荷重点のずれの許容量が大きくなると考えられるため、実橋梁に適用する場合にはその影響は小さいと考えられる。

さらに、振動特性に着目し、骨組解析により 1 次および 2 次の固有振動数を算出した結果を表 5.2 に示す。いずれの Case においても、1 次、2 次の固有振動数の変化はほとんどなかった。

以上の結果から、たわみ影響線の変化率を用いた手法は剛性の変化に対して、振動特性よりも敏感であり、たわみ影響線の変化率曲線により、変状箇所を視覚的に捉えられることが確認できた。また、たわみ影響線の変化率を用いた変状検知は、解析だけでなく、実験によっても実現可能であることが確認できた。

表 5.2 各ケースにおける補強前後の固有振動数

	1 次モード (Hz)		2 次モード	
	補強前	補強後	補強前	補強後
Case 1	11.68	11.69	19.35	19.36
Case 2	11.68	11.68	19.35	19.35
Case 3	11.68	11.68	19.35	19.35

## 5.3 たわみの時刻歴応答の変化率を用いた橋梁劣化箇所同定手法

5.2 節で示した方法では、実橋梁で考えた場合、交通規制が必要となる。一方、走行荷重を想定し、移動荷重によるたわみの時刻歴応答を用いることができれば、交通規制をせずに短時間、低コストで劣化箇所を同定すること可能になると考えられる。

本節では、走行荷重を受ける橋梁の劣化箇所を推定することを目的として、フーリエ級数による解析解、3次元 FEM を用いた動的応答解析を行い、たわみの時刻歴応答の変化率を用いた損傷検知手法を提案するとともに、非接触方式による移動荷重を受ける損傷のないはりのたわみの計測実験を行い、実橋梁への適用可能性について検討する。

### 5.3.1 解析解を用いた動的応答解析

3次元 FEM を用いた動的応答解析の比較対象とするため、フーリエ級数による解析解を用いて動的応答解析を行う。

図 5.13 に示すような、一定の集中荷重  $P_0$  がはり上を等速度  $v_0$  で通過する場合について考える。座標系は図中に示す通り、 $y$  は上向きを正としている。

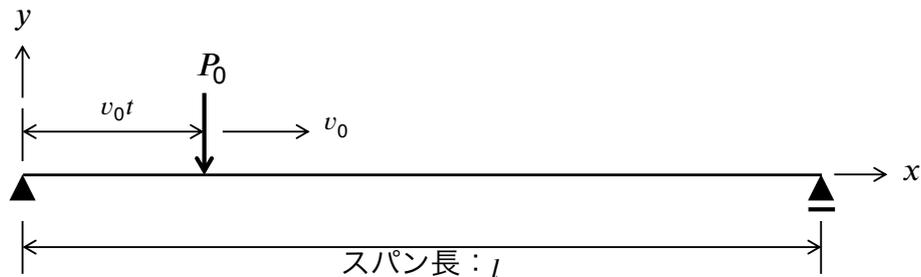


図 5.13 移動荷重を受ける両端支持はり

#### (1) 基礎微分方程式と解

振動形解析法を用いると、移動する一定の集中荷重  $P_0$  を受けるはりの基礎微分方程式は、式 (5.2) のように表される [50].

$$\frac{d^2}{dt^2} \Psi_s + n_s^2 \Psi_s = \frac{2P_0}{wAl} \sin \omega_s t \quad (5.2)$$

ここに、 $t$  は荷重がはりに進入する時刻を  $t = 0$  とした場合の経過時間であり、 $\Psi_s$  は基準座標、 $A$  は断面積、 $l$  はスパン長、 $w$  は単位質量である。また、 $\omega_s$  は円振動数、 $n_s$  は両端支持はりの固有円振動数であり、式 (5.3), (5.4) のように表される。

$$\omega_s = \frac{s\pi v_0}{l} \quad (5.3)$$

$$n_s = \frac{s^2\pi^2}{l^2} \sqrt{\frac{EI}{wA}} \quad (5.4)$$

ここに、 $v_0$  は荷重の移動速度、 $E$  は弾性係数、 $I$  は断面 2 次モーメントである。

式 (5.2) の解は式 (5.5) のように表される。

$$\Psi_s = \bar{A}_s \cos n_s t + \bar{B}_s \sin n_s t + \frac{2P_0}{wAl} \frac{1}{n_s^2 - \omega_s^2} \sin \omega_s t \quad (5.5)$$

両端支持はりの基準関数を  $X_s$  とすれば、たわみ  $y$  は式 (5.6), (5.7) のように表される。

$$y = \sum_s \Psi_s X_s \quad (5.6)$$

$$X_s = \sin \frac{s\pi x}{l} \quad (5.7)$$

式 (5.5) に式 (5.6), (5.7) を代入すると、式 (5.8) が求まる。

$$y = \sum_s \left\{ \bar{A}_s \cos n_s t + \bar{B}_s \sin n_s t + \frac{2P_0}{wAl} \frac{1}{n_s^2 - \omega_s^2} \sin \omega_s t \right\} \sin \frac{2\pi x}{l} \quad (5.8)$$

荷重がはりに進入する前に、はりは静止しているとすれば、初期条件は式 (5.9) のようになる。

$$t = 0 \text{ において } y = 0, \frac{dy}{dt} = 0 \quad (5.9)$$

式 (5.8) と式 (5.9) より  $\bar{A}_s, \bar{B}_s$  が式 (5.10) のように求まる。

$$\bar{A}_s = 0, \bar{B}_s = -\frac{\omega_s}{n_s} \frac{1}{n_s^2 - \omega_s^2} \frac{2P_0}{wAl} \quad (5.10)$$

最終的に、たわみ  $y$  は式 (5.11) のように表される。

$$y = \frac{2P_0}{wAl} \sum_s \frac{1}{n_s^2 - \omega_s^2} \left\{ -\frac{\omega_s}{n_s} \sin n_s t + \sin \omega_s t \right\} \sin \frac{s\pi x}{l} \quad (5.11)$$

## (2) 解析結果

5.2 節と同様に, 図 5.14 のような寸法および H 型の断面を有するはり解析対象とする.

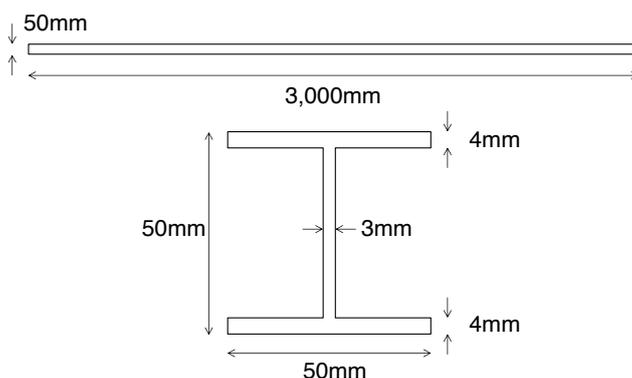


図 5.14 解析対象の寸法および断面

材料はアルミ合金 6063 を想定し, 解析パラメータを表 5.3 のように設定した.

表 5.3 解析パラメータ

パラメータ名	記号	値
スパン長 (mm)	$l$	3,000
断面積 ( $\text{mm}^2$ )	$A$	526
断面 2 次モーメント ( $\text{mm}^4$ )	$I$	230,655
弾性係数 ( $\text{N}/\text{mm}^2$ )	$E$	68,300
ポアソン比	-	0.3
密度 ( $\text{ton}/\text{mm}^3$ )	$w$	$2.69 \times 10^{-9}$
荷重 (N)	$P_0$	-19.6

図 5.15 は,  $v_0 = 100\text{mm}/\text{s}$  とし, 級数和を取る範囲を  $s=1, 3, 5, 7, 9, 11, 13, 15$  と変化した場合の, 時刻  $t=15\text{s}$ (荷重がはり中央) 時点でのたわみの収束状況である.  $s=15$  まで級数和を取ると値がほぼ収束することが確認できた. 以降の計算では,  $s=15$  を用いることとする.

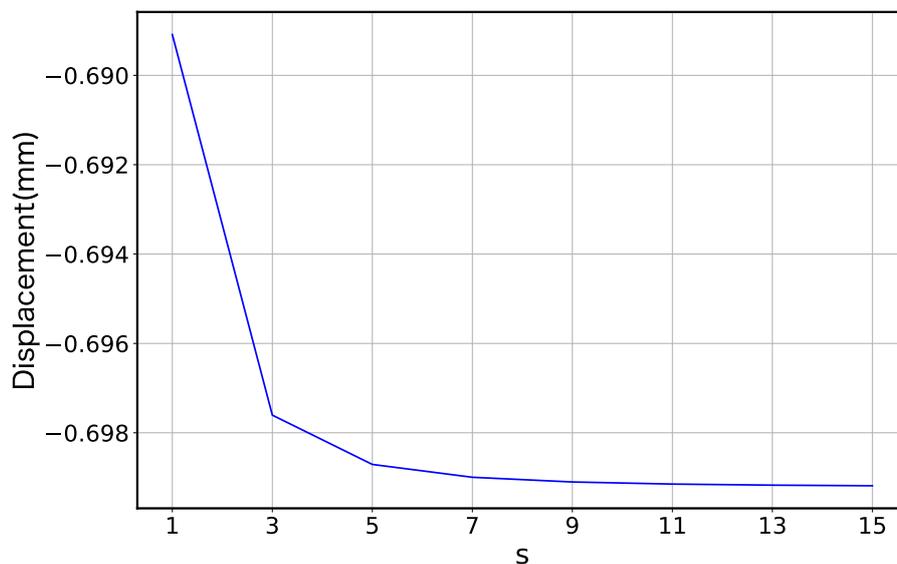


図 5.15 たわみの収束状況

図 5.16 (a)~(d) は, それぞれ  $v_0$  を 100mm/s, 500mm/s, 1,000mm/s, 3,000mm/s と変化させた場合のはり中央のたわみの時刻歴応答である. 速度  $v_0$  が大きくなるにつれ, たわみの振幅が大きくなっていくことが確認できる. 3,000mm/s では, 明確に移動荷重による過渡応答の影響を確認できる. このことから, 同じ大きさの荷重であっても移動速度が速ければ, はりの時刻歴応答へより影響を与えることがわかる.

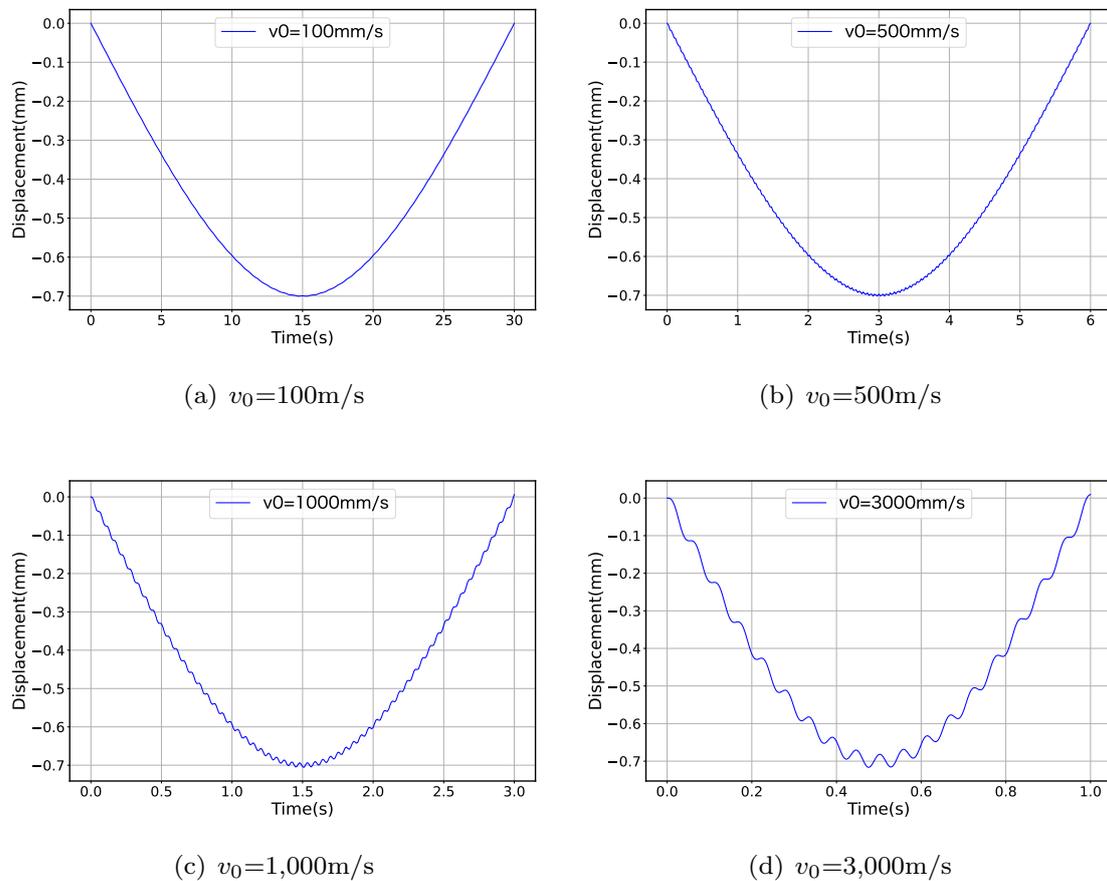


図 5.16 たわみの時刻歴応答 (はり中央)

### 5.3.2 3次元 FEM を用いた動的応答解析

前項では、解析解を用いて移動荷重を受ける両端支持はりのたわみの時刻歴応答を求めたが、解析解では一部に損傷があるはりを解析することは困難である。本項では 3 次元 FEM を用いて、移動荷重をうけるはりの動的応答解析を行い、損傷が時刻歴応答に与える影響を検討する。また、荷重通過後の過渡応答解析についても検討する。なお、FEA ソフトウェアとしては、MSC Marc/Mentat 2017 を用いている。

#### (1) 解析方法

解析解と同じく、図 5.14 のような寸法および H 型の断面を有するはりを解析対象とする。移動荷重を再現するため、はりを長さ方向に要素分割し、各要素は 2 節点開断面 3 次元梁要素とした。境界条件は片側ピン、片側ローラーの両端支持とした。材料定数等は解

析解と同じく表 5.3 の値を用いている。また、解析条件は表 5.4 のように設定した。移動荷重は、解析の荷重ステップ毎に載荷する節点を変えることでシミュレートした。例えば、要素分割を 300 とした場合、ステップ数を 300 とし 1 ステップ毎に異なる節点に荷重がかかるような集中荷重を境界条件に設定している。このような境界条件は、Marc のテーブル機能と数式機能を用いることで設定することが可能である。今回は、2 独立変数のテーブルを用い、独立変数 1 のタイプを「time」、独立変数 2 のタイプを「x0\_coordinate」とし、式 (5.12) のような数式を設定している。

$$\max(0, (-1) \times (v_2 - v_1 \times v_0)^2 + 1) \quad (5.12)$$

ここに、 $v_0$  は荷重の移動速度、 $v_1$  は独立変数 1、 $v_2$  は独立変数 2 である。

また、荷重の移動速度については、全荷重ケース時間により制御した。例えば、スパン長 3,000mm のはりで全荷重ケース時間を 30s とすれば、荷重の移動速度は 100mm/s となる。このような荷重制御を行うことから、解析結果は要素分割数の影響を受けるものと考えられるため、予備解析として、要素分割数を変化させた場合のはり中央のたわみの時刻歴応答を解析解による結果と比較する。

表 5.4 FEM の解析条件

条件	設定内容
要素タイプ	3次元薄肉開断面梁要素 (2 節点), 要素 79
梁断面	梁断面機能で I 型の断面を作成
荷重ケース	動的過渡応答

解析解による結果と、要素分割数を 300, 600, 1,200, 2,400 と変化させた場合の結果を図 5.17 に示す。図 5.18 はグラフの 0.5s 付近を拡大したものである。なお、移動速度は、波形の一致が確認しやすいように 3,000mm/s としている。

図 5.17 および図 5.18 からわかるように、分割数 300 の FEM の結果では、時刻歴応答の波形が解析解と大きく異なり、分割数が大きくなるにつれ、結果は解析解に近づいていく。これは、荷重を与える節点を荷重ステップごとに変化させることで移動荷重をシミュレートしているため、分割数が少ない、すなわち、節点数が少ない場合は、荷重が次の節点に移動するまでの時間が長くなるため、分割数が少ないほど、解析解と比べて時刻歴応答にずれが生じるものと考えられる。以上のことから、本解析は要素分割の影響を大きく受けることがわかる。本節の以降の解析では、損傷位置の設定の容易さを考慮し、各要素の

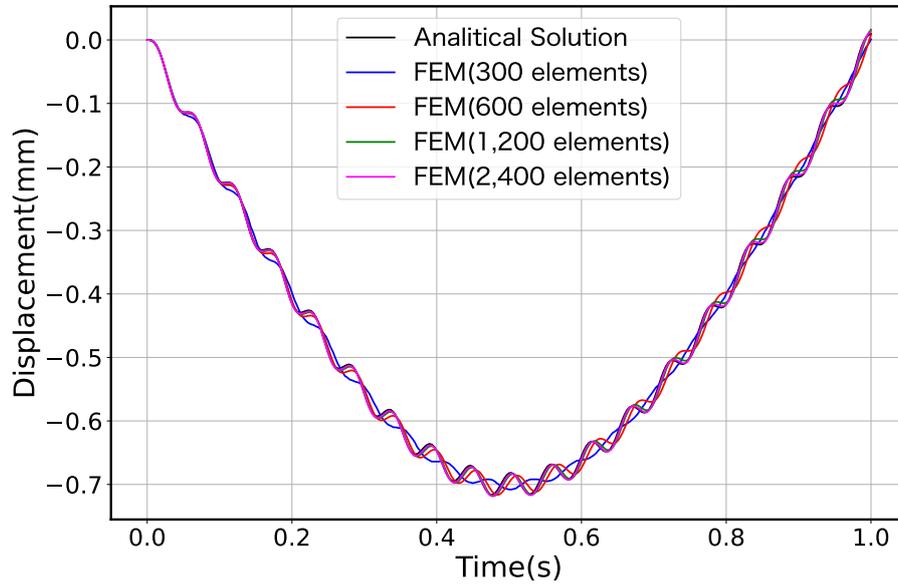


図 5.17 解析解と FEM による時刻歴応答の比較

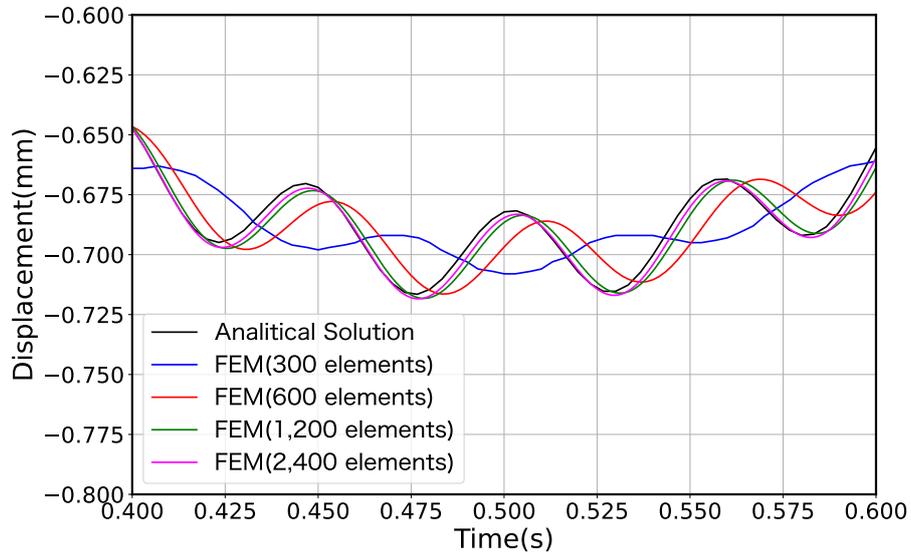
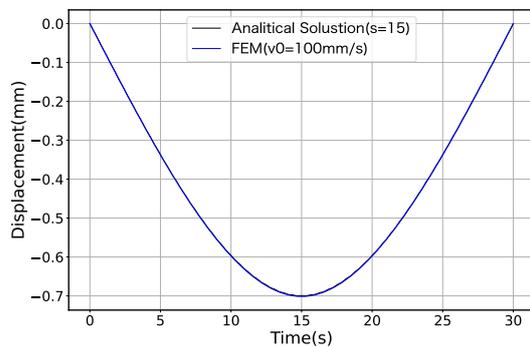


図 5.18 解析解と FEM の比較 (拡大図)

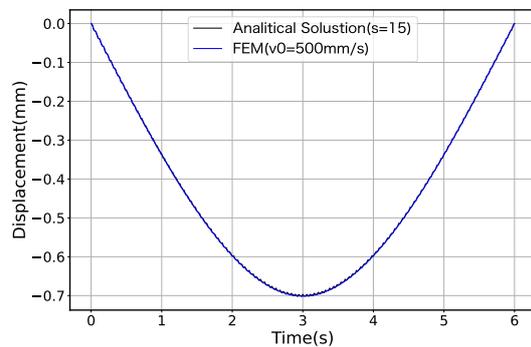
長さが 1mm となる分割数 3,000 で解析を行うこととする。

## (2) 移動速度の影響

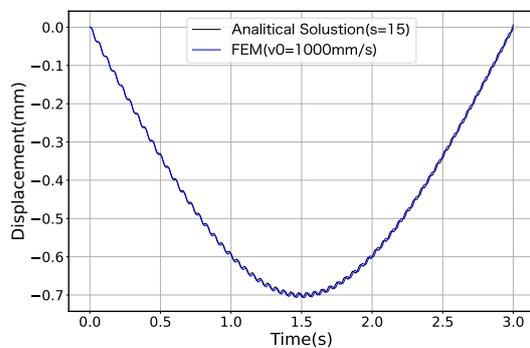
荷重の移動速度  $v_0$  を 100mm/s, 500mm/s, 1,000mm/s, 3,000mm/s と変化させた場合の、はり中央たわみの時刻歴応答を図 5.19 (a)~(d) に示す。図 5.19 より、移動速度が増加した場合のたわみ振幅の増加を FEM 解析でも再現できている。また、解析解ともほぼ一致している。なお、要素分割数は 3,000 である。



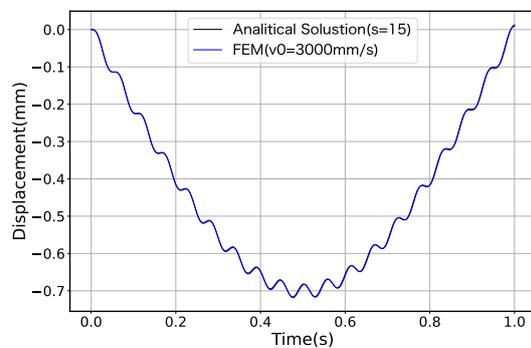
(a)  $v_0=100\text{m/s}$



(b)  $v_0=500\text{m/s}$



(c)  $v_0=1,000\text{m/s}$



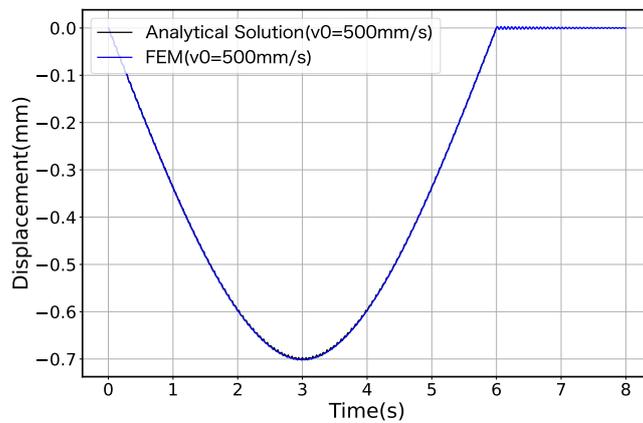
(d)  $v_0=3,000\text{m/s}$

図 5.19 移動速度の時刻歴応答への影響

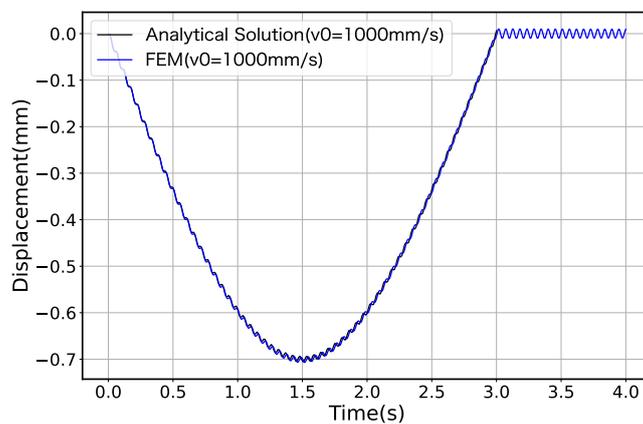
## (3) 荷重通過後の過渡応答

移動荷重がはりを通り過ぎた後の過渡応答を FEM で解析した結果を図 5.20 (a)~(c) に示す。荷重の移動速度  $v_0$  は 500mm/s, 1,000mm/s, 3,000mm/s である。荷重通過後の過渡応答を解析するには、全荷重ケース時間を荷重通過時間より大きくする。図 5.20 よ

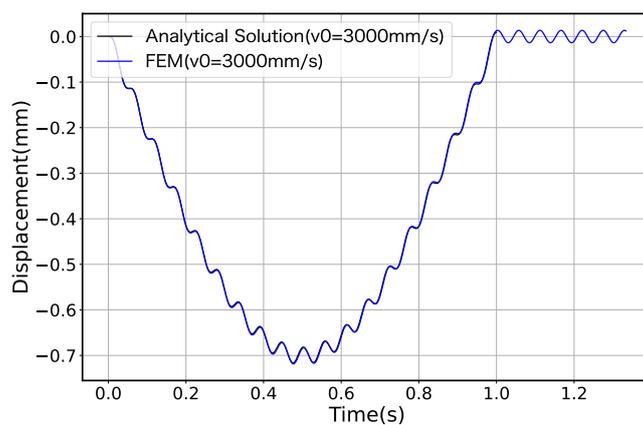
り、過渡応答のたわみは荷重の移動速度が増加すると大きくなることがわかる。なお、本論文の解析解では荷重通過後の過渡応答解析はできないため、図中の解析解による結果は、荷重がはり上にある範囲のみとなっている。



(a)  $v_0=500\text{m/s}$



(b)  $v_0=1,000\text{m/s}$



(c)  $v_0=3,000\text{m/s}$

図 5.20 荷重通過後の過渡応答

#### (4) 損傷のあるはりの解析

はりの損傷が生じた場合の影響を検討するため、はりの一部区間において、断面欠損が生じたモデルの解析を行う。解析においては、一部の要素の形状特性(はり断面)を変更することによって、断面欠損をシミュレートする。図 5.21 に設定したはり断面を示す。断面欠損ありのはり断面では、桁下面に一様な錆による腐食が発生した場合を想定し、下フランジの厚さを 4mm から 2mm に減らしている。

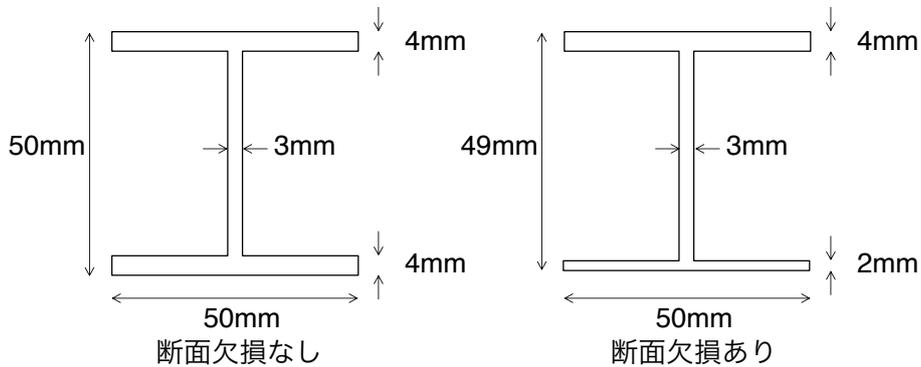


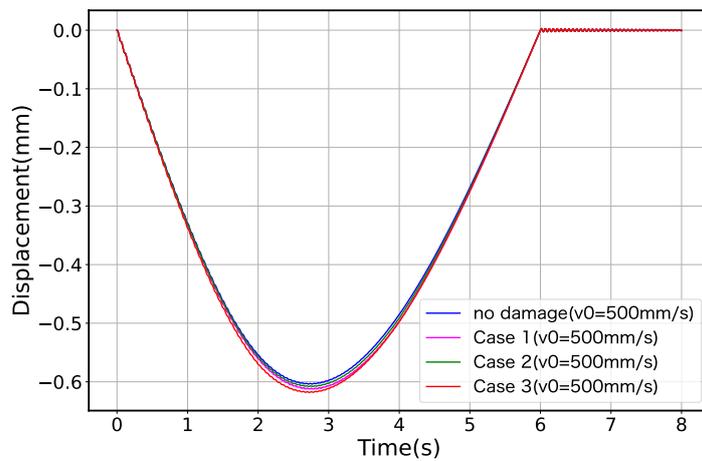
図 5.21 断面欠損を有するはり断面

図 5.22 に断面欠損を設定した位置を示す。Case 1 では、左端からスパン長の 2/3 の位置に 100mm の断面欠損区間、Case 2 では、スパン長の 2/3 の位置に 50mm の断面欠損区間、Case 3 ではスパン長の 1/3、2/3 位置に 50mm の断面欠損区間を設定している。

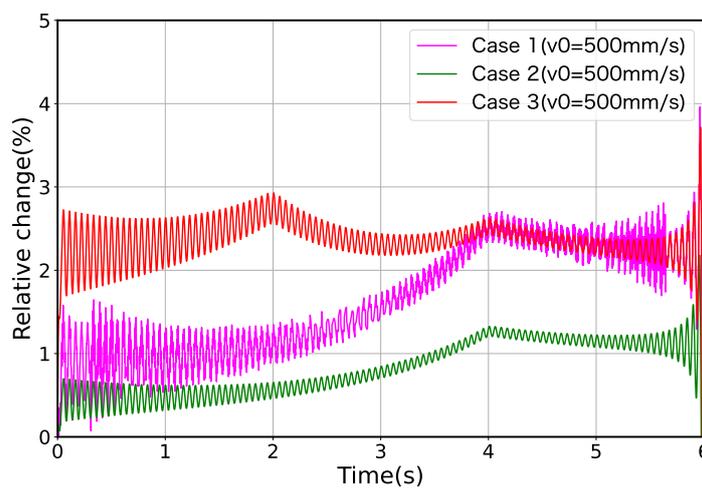


図 5.22 断面欠損を設定した区間

図 5.23, 5.24, 5.25 に損傷なしおよび損傷ありモデル (Case 1, 2, 3) の左端から 1/3 の距離のたわみ, 中央のたわみ, 左端から 2/3 の位置のたわみの時刻歴応答およびたわみの時刻歴応答の変化率を示す。荷重の移動速度  $v_0$  は, 500mm/s である。

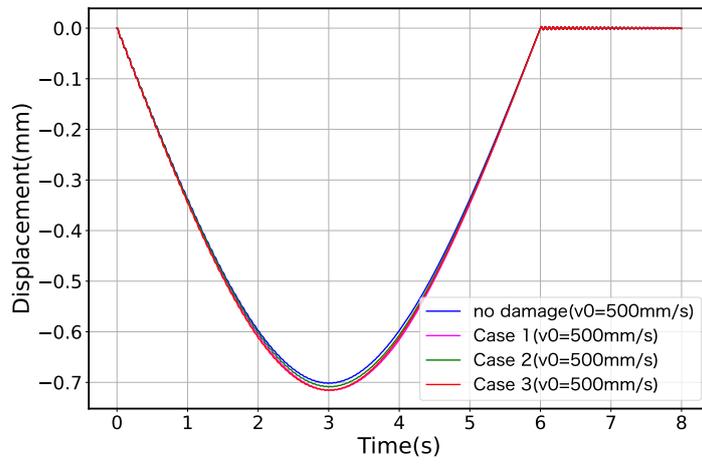


(a) 時刻歴応答

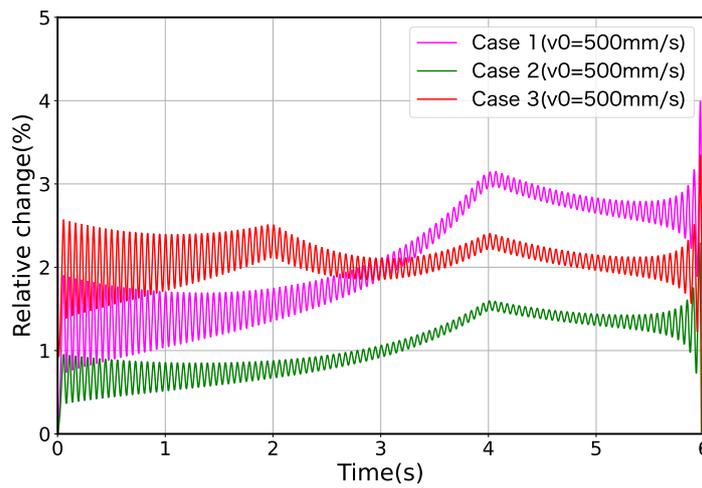


(b) たわみの時刻歴応答の変化率

図 5.23 左端から 1/3 の距離 ( $v_0 = 500 \text{ mm/s}$ )

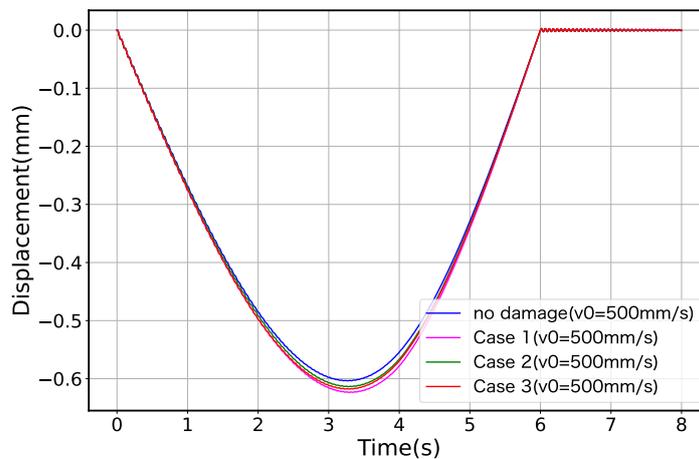


(a) 時刻歴応答

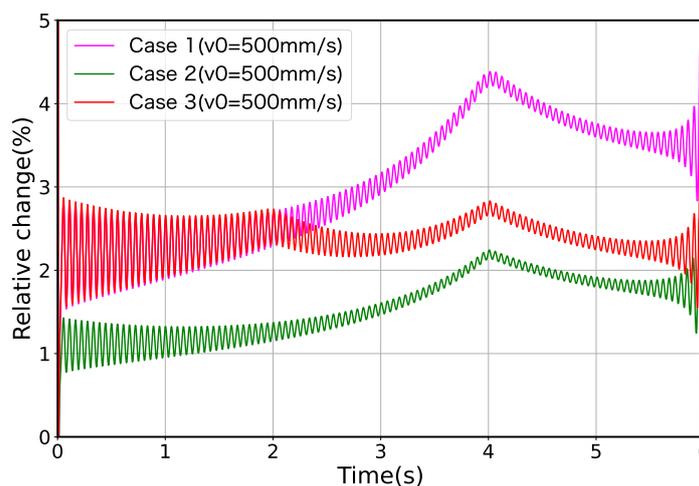


(b) たわみの時刻歴応答の変化率

図 5.24 はり中央の距離 ( $v_0 = 500 \text{ mm/s}$ )



(a) 時刻歴応答



(b) たわみの時刻歴応答の変化率

図 5.25 左端から 2/3 の距離 ( $v_0=500\text{mm/s}$ )

なお、図 5.23, 5.24, 5.25 の (b) のたわみの時刻歴応答の変化率は以下のような式で算出している。

$$\text{たわみの時刻歴応答の変化率} = \frac{(v_d - v_n)}{v_n} \times 100 \quad (5.13)$$

ここに、 $v_d$  は損傷があるはりのたわみの時刻歴応答、 $v_n$  は損傷がないはりの時刻歴応答である。

たわみの時刻歴応答の変化率に振幅が生じているのは、損傷があるはりのたわみの時刻歴応答と損傷がないはりのたわみの時刻歴応答が異なる周期で変化しているためであると

考えられる。また、たわみの時刻歴応答の変化率は式 (5.13) のように求めているため、たわみが小さい支点付近では値が発散するような現象が生じている。

図 5.23, 5.24, 5.25 の (a) を見ると、損傷の有無によるはり中央たわみの時刻歴応答の差はわずかで、時刻歴応答の結果を用いてはりの損傷の有無や損傷位置を推定することは困難である。しかしながら、損傷を有するはりのたわみの時刻歴応答と損傷のないはりのたわみの時刻歴応答の変化率を求めてみると、それぞれ損傷の位置を荷重が通過した時刻付近において、特徴的な変化を見せている (図 5.23, 5.24, 5.25 (b))。この変化率の特異点は、損傷のあるはり左端から  $1/3$ ,  $2/3$  の位置のたわみ (図 5.23, 5.25) だけでなく、損傷のないはり中央のたわみ (図 5.24) でも確認できている。これらの結果は、損傷のない状態で走行荷重による時刻歴応答を取得し、定期的にモニタリングを行えば、損傷の有無と、さらに損傷位置同定の可能性があることを示唆している。

### 5.3.3 移動荷重を受けるはりの振動計測実験

前項で、たわみの変化率を利用することで、はりの損傷位置を推定することが可能であることを示したが、走行荷重を受ける実橋梁の劣化箇所を推定する場合は、なんらかの方法で、たわみの計測が必要となる。本項では、実橋梁でのたわみ計測を想定し、レーザードップラー速度計および高速度カメラを用いて、移動荷重を受ける損傷のないはりの試験体のたわみを計測し、解析結果と比較検討する。

#### (1) 実験概要

試験体は、H 型のアルミ合金製で、長さ 3,000mm、断面寸法は  $500 \times 500 \times 3 \times 4$ mm である。寸法や材料特性は解析で用いたものと同じである (図 5.14, 表 5.3)。試験体の支持条件としては、左端をローラー支持、右端をピン支持とした。荷重としてテフロンシートを下面に貼り付けた 2kg の重りをモーターにより牽引した。試験では、レーザードップラー速度計 (以下, LDV) と高速度カメラを用いた画像相関法 [51] でスパン中央点 (×印) のたわみを計測した。図 5.26 に試験条件の概要を示す。

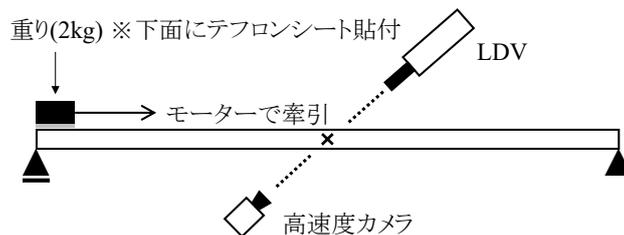


図 5.26 試験条件の概要

図 5.27 に計測に用いた LDV を示す．図 5.28 は計測に用いた高速度カメラ，図 5.29 は重りの定速移動使用したモーター，図 5.30 ははりの支持方法である．



図 5.27 レーザードップラー速度計 (LDV)



図 5.28 高速度カメラ



図 5.29 使用したモーター



図 5.30 ばりの支持方法

## (2) 実験結果

図 5.31, 5.32 に実験により得られたはり中央たわみの時刻歴応答を示す。荷重の移動速度は 500mm/s, 1,000mm/s である。図 5.31, 5.32 を見ると、どちらの速度においても、LDV および高速カメラで計測したはり中央たわみの時刻歴応答は、FEM による解析結果と近い値となっている。しかしながら、応答曲線のばらつきや偏りが大きく、前章で示したたわみの変化率を用いた損傷の有無、損傷位置の推定に用いるにはまだまだ改善が必要であると考えられる。

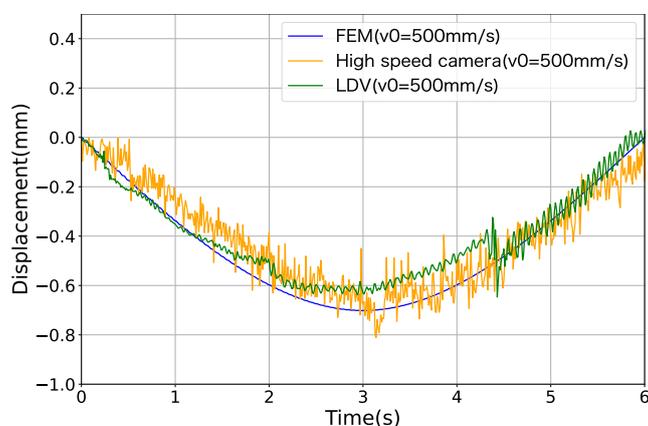


図 5.31 実験による時刻歴応答 ( $v_0=500\text{mm/s}$ )

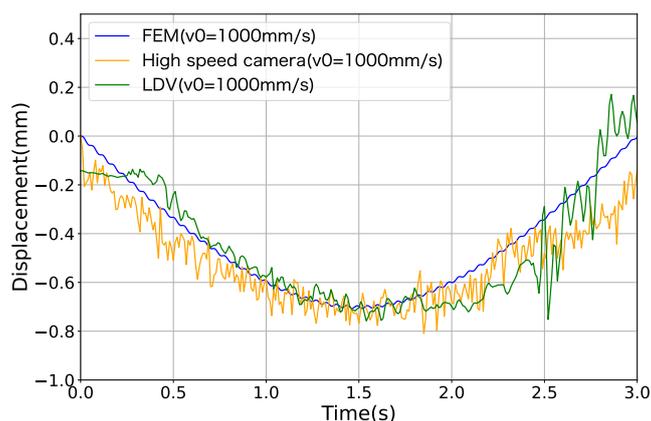


図 5.32 実験による時刻歴応答 ( $v_0=1,000\text{mm/s}$ )

## 5.4 おわりに

本章では、たわみ影響線およびたわみの時刻歴応答の変化率を用いた橋梁劣化箇所同定手法を確立することを目的として、静的問題として、荷重に受けるはりのたわみ影響線の変化率について実験および解析的に検討した。また、動的問題として、移動荷重を受けるはりのたわみの時刻歴応答の変化率について、フーリエ級数による解析解、3次元FEMを用いた動的応答解析を行った。さらに、非接触方式による移動荷重を受ける損傷のはりのたわみの計測実験を行い、実橋梁への適用可能性について検討した。

静的問題では、アルミ板を貼り付けて剛性を変化させたアルミニウム製H型材を用いた実験において、たわみ量や固有振動数の差がないような剛性変化に対して、たわみ影響線の変化率を用いることにより剛性変化箇所を同定できることが確認できた。

動的問題では、フーリエ級数による解析解によるたわみの時刻歴応答と3次元FEMによる時刻歴応答の解析結果を比較したところ、3次元FEMによる解析結果は、移動速度を変化させた場合でも解析解による結果とほぼ一致することが確認できた。また、はりの左端から1/3の距離、2/3の距離の断面形状を変え、損傷を模擬したモデルについて、3次元FEMを用いて解析を行ったところ、たわみの時刻歴応答のみでははりの損傷の有無や損傷位置の推定は困難であったが、損傷のないはりのたわみの時刻歴応答と損傷のあるはりの時刻歴応答について変化率を求めたところ、損傷の有無および損傷位置を推定することができた。さらに、走行荷重を受ける実橋梁の劣化箇所同定手法の確立を目的として、試験体を利用した実験を行った。実験では、レーザードップラー速度計および高速度カメラを利用してたわみの時刻歴応答を計測したところ、3次元FEMとほぼ同じ結果を計測することができた。計測結果には、まだばらつきや偏りが見られるが、今後計測方法を工夫することで、本研究の手法を実橋梁へも応用できると考えられる。

## 参考文献

- [40] 河村太紀, 木本啓介, 森田千尋, 西川貴文, 松田浩「橋梁の構造同定による性能評価と安全性評価に関する研究」『土木学会第 72 回年次学術講演会』, 土木学会, 2017.
- [41] 林謙介, 河村太紀, 松田浩「光学的計測法による損傷を有する鋼トラス橋の構造同定および変状検知」『土木学会第 73 回年次学術講演会』, 土木学会, 2018, pp. 1027–1028.
- [42] 武田龍國, 中島章典, Nguyen MinhHai「たわみの影響線を利用した橋梁の劣化箇所同定の試み」『土木学会第 71 回年次学術講演会』, 土木学会, 2016, pp. 141–142.
- [43] 渡邊学歩, 内藤慎也, 友廣郁也「小規模橋梁のたわみ影響線観測に基づく構造ヘルスマモニタリング」『土木構造・材料論文集』32-20 (2016), pp. 125–134.
- [44] 林謙介, 木本啓介, 河村太紀, 奥松俊博, 山口浩平, 松田浩「損傷を有する鋼トラス橋の固有振動数とたわみ影響線変化率の関係」『鋼構造論文報告集』(2018-11), pp. 390–395.
- [45] 宮濱晃一, 林謙介, 松田浩, 山口浩平, 古賀掲維「光学的計測法を用いた撤去 RC 桁の検査, 診断及び実橋への利活用に関する研究」『土木学会全国大会第 74 回年次学術講演会』, 2019-09.
- [46] 大塚浩司, 庄谷征美, 外門正直, 原忠勝『鉄筋コンクリート工学』, 第 3 版, 技報堂出版, 1997.
- [47] 永松牧子, 出水享, 鶴田健, 岡本賢治, 宮本紘貫, 松田浩「PIC 板で補強した RC はりの補強効果に関する実験及び解析的研究」『長崎大学大学院工学研究科研究報告』95.50 (2020), pp. 65–70.
- [48] 国土交通省道路局『道路橋定期点検要領』, 2014-06, URL: <https://www.mlit.go.jp/common/001044574.pdf>.
- [49] プレストレストコンクリート工学会『コンクリート構造診断技術』, プレストレストコンクリート工学会, 2016.
- [50] 小坪清眞『入門建設振動学』, 第 1 版, 森北出版, 1996, p. 197.
- [51] 小原生也, 高木健, 石井抱「振動ベースド画像特徴量を用いた高速ターゲットトラッキング」『日本機械学会論文集 (C 編)』78.788 (2012), pp. 1143–1153.

## 第6章

# 3次元CADを援用したRCはりのFE解析手法

### 6.1 はじめに

コンクリートは鉄鋼と並び、社会インフラ基盤を支える安価で施工が容易な基本材料であり、建設工事において不可欠な材料である。しかし、コンクリート構造物が置かれる過酷な環境下、例えば海岸近辺、融雪材として塩が使用される環境、または、季節や1日の寒暖差、化学的作用、当初計画時より過大な荷重が作用する環境などでは、常に耐荷性が減じる方向にある。

日本では1950年代後半からの高度経済成長期以降、大量の道路構造物が建設されてきた。近年、塩害や凍害、中性化、アルカリシリカ反応、車両の繰り返し走行荷重等の因子によって老朽化が進行し、コンクリートのひび割れやはく離、鉄筋の腐食などの損傷が顕著になってきている。2030年頃には、供用期間50年を超過する橋梁がこれまでに建設された全橋梁数の半数以上となるため、さらに損傷などの不具合が多発するとされている。また、維持管理の対象となるRC構造物の劣化損傷の1つとして、塩害、アルカリシリカ反応(以後、ASRと呼称)、中性化などの要因で進行する鉄筋腐食による膨張圧力や疲労荷重等により発生するひび割れが問題となっている。

鉄筋腐食などの損傷を有するRCはりに関する既往の研究として、千々和ら [52] の研究では、主鉄筋付近での水平方向のひび割れが生じた場合、鉄筋とコンクリートの付着力が落ち、耐荷力が著しく低下することが報告されている。また、千々和らの別な研究 [53] では、定着部に引張鉄筋に沿った腐食ひび割れを有するRCはりに対して、予防保全的な面的補強を行った場合の効果について報告し、腐食による引張鉄筋定着部の劣化に対しても、

予防保全的な補強コンセプトが成立する場合が存在することを例示している。ただし、予防保全的な補強の適用範囲と一般性は不明であり、補強強化の定量評価には今後、実証例の積み上げと耐力照査法の開発が不可欠であるとまとめている。

松田ら [54] の研究では、PIC 板や鋼板など比較的曲げ剛性の大きい材料を補強材として用いた RC はりを対象として、2 次元および 3 次元非線形 FE 解析を行い、鉄筋の平均応力 - 平均ひずみ関係の構成則と鉄筋の有効付着領域のモデルを考慮することによって、RC はりのコンクリートのひび割れ後の挙動を精度良くシミュレーションできること、有効付着領域モデルを拡張した換算断面を用いることによって、PIC 板および鋼板などの異種材料で補強された RC はりにおいてもコンクリートのひび割れ後の挙動を精度よくシミュレーションできること、異種材料間に適切な接触要素を用いることによって、鋼板のはく離などの終局時の非線形挙動をシミュレーションできることを示している。

本章では、様々な損傷や補強材を有する RC はりをコンピュータ上でシミュレーションする手法を提案する。3 次元 CAD を援用し、汎用 FEM ソフトウェアの接触解析機能の利用を前提とすることで、要素分割の複雑さを解消し、可能な限り実構造物に近い解析モデルを作成する手法について説明する。本手法を用いた解析対象としては、健全な RC はり、鉄筋定着部の損傷を模擬した RC はり、および、損傷を模擬しポリマー含浸コンクリート (Polymer Impregnated Concrete, 以後、PIC と呼称) 板で補強した RC はりとし、試験体を用いた載荷試験と 3 次元非線形 FE 解析を実施し、試験結果と解析結果を比較することにより解析法の妥当性について検討した。

## 6.2 RC はりの実験および 3 次元 FE 解析の概要

### 6.2.1 載荷試験の概要

本項では、塩害、ASR、中性化などの要因で進行する鉄筋腐食による膨張圧力によって、ひび割れが主鉄筋の両端で生じた場合を想定し、損傷のない試験体、損傷を模擬した試験体、および損傷を模擬し PIC 板で補強した試験体について行った載荷試験の概要を示す。本研究で用いる PIC 板とは、金属短繊維で補強した繊維補強コンクリート板を PIC 化したプレキャスト埋設型枠である。また、鉄筋腐食によるひび割れを模擬する方法としては千々和らの研究 [53], [55] を参考に、スチレンボードを主鉄筋上に導入する方法を採用した。

### (1) 使用材料

コンクリート, PIC の材料特性を把握するためにいくつかの強度試験を実施した. 試験内容は, 圧縮, 割裂引張, 曲げ, せん断強度試験である. 試験方法は圧縮, 割裂引張, 曲げ強度試験は JIS の規格 [56] に準拠し, せん断強度試験は参考文献 [57] を参考に実施した.

使用材料を表 6.1 に, コンクリートの配合表および試験結果を表 6.2, 表 6.3 に, PIC の配合表および試験結果を表 6.4, 表 6.5 に示す. また, 主鉄筋に用いる D19 の鉄筋の引張試験も実施し, D19 の鉄筋の材料特性も確認した. D19 鉄筋の引張試験の結果を表 6.6 に示す.

表 6.1 使用材料

セメント	太平洋セメント社製普通ポルトランドセメント
砕砂	マテラス青梅工業社宮城工場使用砕砂
7号砕砂	マテラス青梅工業社宮城工場使用7号砕砂
鋼繊維	(株)サンゴ社製テッサ, SUS304, 寸法 3315
混和剤	花王社製高性能減水剤マイティ 150

表 6.2 コンクリートの配合表

粗骨材の最大寸法 (mm)	20	
水セメント比 (%)	49	
細骨材率 (%)	45.9	
単位量 (kg/m <sup>3</sup> )	水	163
	セメント	333
	細骨材	810
	粗骨材	1,019
	混和剤	3.33

表 6.3 コンクリートの強度試験結果

圧縮強度 (N/mm <sup>2</sup> )	引張強度 (N/mm <sup>2</sup> )	曲げ強度 (N/mm <sup>2</sup> )	せん断強度 (N/mm <sup>2</sup> )	縦弾性係数 (kN/mm <sup>2</sup> )
34.6	2.23	3.58	6.98	29.0

表 6.4 PIC の配合表

水セメント比 (%)		35
単位量 (kg/m <sup>3</sup> )	水	175
	セメント	500
	砕砂	958
	7号砕砂	715
	鋼繊維	95
	混和剤	3.5

表 6.5 PIC の強度試験結果

圧縮強度 (N/mm <sup>2</sup> )	引張強度 (N/mm <sup>2</sup> )	曲げ強度 (N/mm <sup>2</sup> )	せん断強度 (N/mm <sup>2</sup> )	縦弾性係数 (kN/mm <sup>2</sup> )
170	16.0	33.9	31.0	44.0

表 6.6 D19 鉄筋の引張強度試験結果

引張強度 (N/mm <sup>2</sup> )	降伏強度 (N/mm <sup>2</sup> )	縦弾性係数 (kN/mm <sup>2</sup> )
567	409	189

## (2) 試験体

表 6.7 に試験体の概要を、図 6.1 に試験体の断面、側面図を示す。試験体は無損傷の試験体 A、損傷のある試験体 B、PIC で補強した試験体 C の 3 種類である。試験体 B は RC

はりの両端の主鉄筋上に、鉄筋定着部の損傷を模擬するためにスチレンボードを導入した試験体である。試験体 C は RC はりの両端の主鉄筋上にモデル損傷があり、埋設型枠として PIC 板を設置し、ボルトにより固定して補強した試験体である。スチレンボードは試験体 B, C とともに同じ大きさであり、RC はりの両端から 305mm の位置まで主鉄筋の上に導入した。スチレンボードの大きさは、W160×L305×厚さ 1mm である。試験体 C の PIC 板は計 4 枚用い、両側面に 2 枚ずつ設けている。また、PIC 板同士はスパン中央部で建築土木用エポキシ樹脂系接着剤を用い、突き合わせて接着する。ボルトは PIC 板 1 枚につき 8 本をインサートナットにより取付け、PIC 板とコンクリートとの一体化を図った。組立て筋として上側に圧縮鉄筋 D6 を 2 本用い、主鉄筋として D19 を 3 本用いた。せん断補強筋として D6 を 3 本取り付けた。

表 6.7 試験体概要

試験体	欠陥	PIC 板	ボルト (M12)	主鉄筋 (SD345)
A	なし	なし	なし	3×D19
B	あり	なし	なし	
C	あり	4 枚	8 本/1 枚	

### (3) 設計値

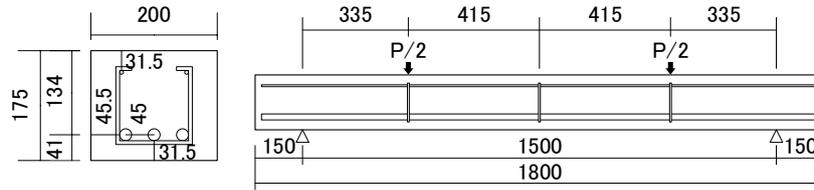
各試験体の設計値を表 6.8 に示す。この設計値は表 6.3, 表 6.5 の強度試験より得られた実測値により計算した値である。せん断強度 ( $V_c$ ) の算出方法については、式 (6.1) の二羽による斜め引張破壊時における修正トラス理論式 [58] で求めた。

表 6.8 設計値

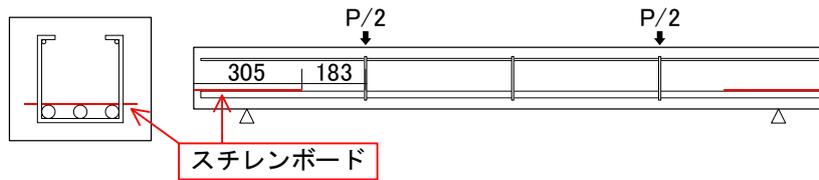
試験体	$P_{cr}$ (kN)	$P_y$ (kN)	$P_u$ (kN)	$V_c$ (kN)
A	27.2	230	214	112
B	27.2	230	214	50.4(112)
C	37.5	232	224	85.5(190)

※  $V_c$  の ( ) 内の値は定着部に損傷がない場合の設計値

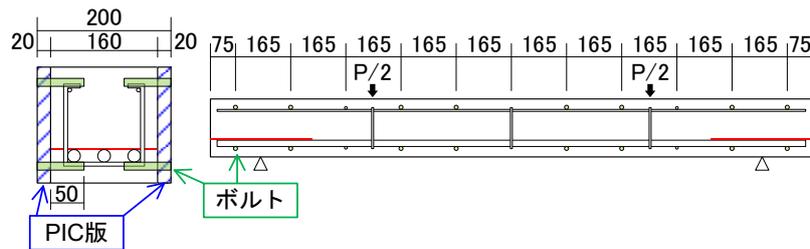
$$V_c = 0.20f_c^{1/3}p_w^{1/3}d^{-1/4} \left( 0.75 + \frac{1.4}{a/d} \right) b_w d \quad (6.1)$$



(a) 試験体 A



(b) 試験体 B



(c) 試験体 C

図 6.1 試験体の断面・側面図

ここに、 $f'_c$  はコンクリートの圧縮強度 ( $\text{N}/\text{mm}^2$ )、 $p_w$  は引張鉄筋比、 $d$  は有効高さ (mm)、 $a$  はせん断スパン (mm)、 $b_w$  は断面幅 (mm) である。鉄筋定着部にモデル損傷を導入している試験体 B、C の設計値に関しては算出ができないため、曲げひび割れ発生荷重 ( $P_{cr}$ )、鉄筋降伏荷重 ( $P_y$ )、曲げ終局荷重 ( $P_u$ ) は鉄筋定着部に損傷がない場合の設計値である。 $V_c$  に関しては、千々和らの研究 [53]、[55] で、鉄筋定着部に損傷のある場合が無損傷の場合の約 45% と示されていたため、定着部に損傷がない場合の 45% の値を設計値としている。

試験体 C の設計値は、PIC のみおよびコンクリートのみの RC はりの設計値を式 6.1 で求め、2 つの材料の体積比から設計値に関する複合則 (式 (6.2)) により算定した。なお、PIC 板の付着強度は考慮せず、一体化しているものと仮定した。ひび割れ発生後におけるコンクリートの有効断面の高さの変化は、PIC 板もコンクリートも同等になっていくもの

として計算した.

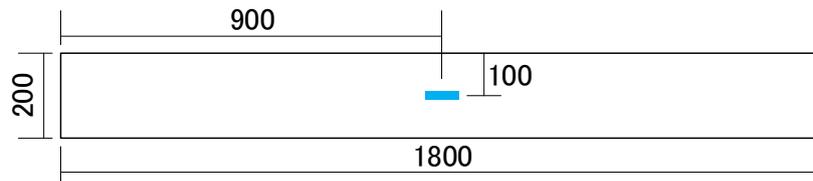
$$V_{c(total)} = \frac{160}{200}V_{c(concrete)} + \frac{40}{200}V_{c(PIC)} \quad (6.2)$$

#### (4) 計測位置

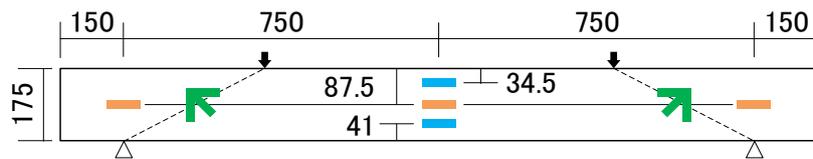
図 6.2 は荷重試験の状況である. 図 6.3 にひずみおよび変位を計測するために貼り付けた, ひずみゲージの位置および変位計の計測位置を示す. コンクリートにはスパン中央部に 60mm のひずみゲージを貼り付け, せん断スパン内にロゼットゲージを貼り付けた. 鉄筋には 1 カ所につき 5mm のひずみゲージを横側に 2 枚貼り付け, その平均値からひずみを求めた.



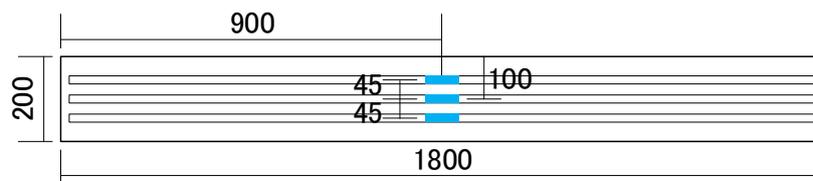
図 6.2 荷重試験の状況



(a) 試験体 A



(b) 試験体 B



(c) 試験体 C

—: ひずみ    : ロゼット    —: 変位計

図 6.3 計測箇所

## 6.2.2 3次元 FE 解析の概要

本項では、前項で示した損傷のない RC はり、損傷を模擬した RC はり、および損傷を模擬し PIC 板で補強した RC はりの解析モデルについて示す。

### (1) 解析モデル

鉄筋定着部損傷による挙動をより正確に表現するため、コンクリート、PIC だけではなく鉄筋やボルトも 3次元ソリッド要素でモデル化する。本研究では、FEA ソフトウェアとして MSC Marc/Mentat を用いるが、モデルの高精細化、モデルの作成時間の短縮化、作業工程の簡略化のため、3次元 CAD(Autodesk 社 Fusion360) を用いてソリッドボディモデルを作成し、そのモデルを Mentat に取り込みメッシュ分割することによって、有限

要素モデルを作成した。

図 6.4 は 3 次元 CAD を用いて作成したソリッドボディモデルである。なお、本論文で取り扱うモデルは長手方向と短手方向で対称となるため、1/4 領域のみをモデル化している。

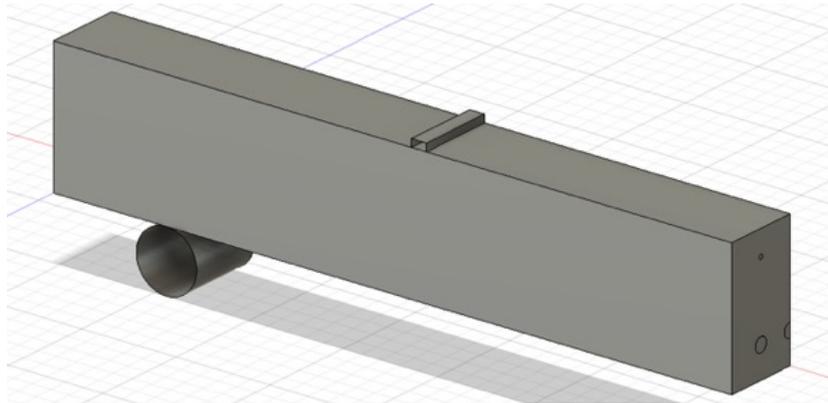


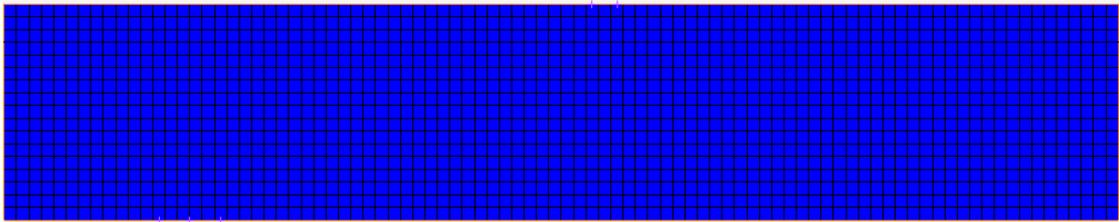
図 6.4 3 次元 CAD 上のソリッドボディモデル

図 6.5 はメッシュ分割された試験体 A の解析モデルである。要素分割, 要素の長辺が 10mm 以内となるように分割を行っている。また, コンクリートと各鉄筋は異なる接触ボディでモデル化し, 接触解析機能を用いて接着している。

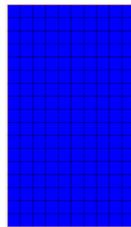
図 6.6 は試験体 B の解析モデルである。鉄筋定着部の損傷については, スチレンボード導入部の W160×L305×1mm の隙間を作ることによって, モデル化を行った。

図 6.7 は試験体 C の解析モデルである。PIC 板, ボルトをモデル化し, 試験体 B と同じ手法で鉄筋定着部の損傷もモデル化している。

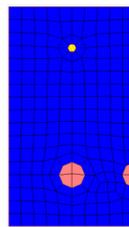
なお, 支点は直径 50mm の円筒サーフェス, 載荷点は幅 20mm の四角形サーフェスで剛体とし, 接触解析機能を用いて支持および載荷する。接着条件は完全付着である。



(a) 長手方向の側面

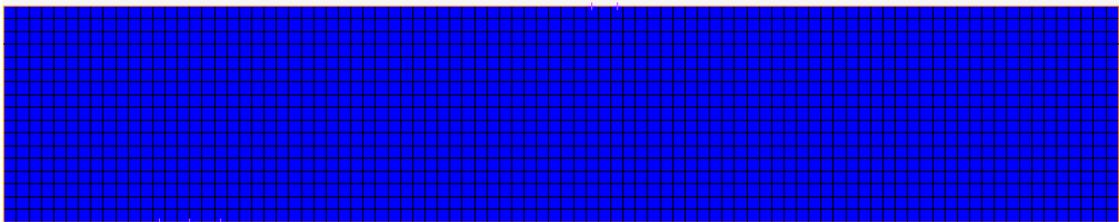


(b) 短手方向の側面

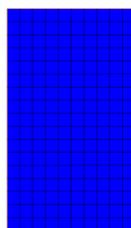


(c) 中央断面

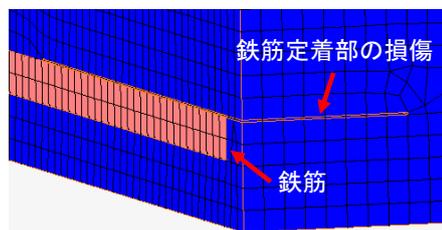
図 6.5 解析モデル (試験体 A)



(a) 長手方向の側面

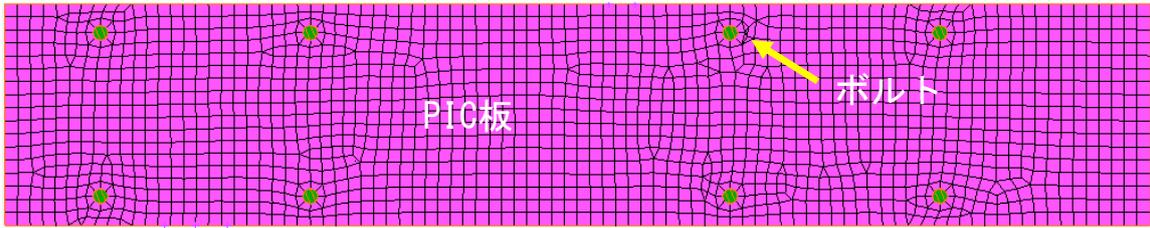


(b) 短手方向の側面



(c) 鉄筋定着部の損傷

図 6.6 解析モデル (試験体 B)



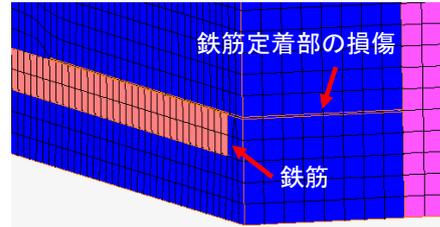
(a) 長手方向の側面



(b) 短手方向の側面



(c) 中央断面



(d) 鉄筋定着部の損傷

図 6.7 解析モデル (試験体 C)

## (2) 境界条件

境界条件としては、荷重点に下向き (Y) 方向の強制変位をかけ、支点は完全固定としている。また、対称面である X-Y 平面, Y-Z 平面には、それぞれ Z 方向, X 方向の変位拘束を与えている。図 6.8 に各境界条件を示す。

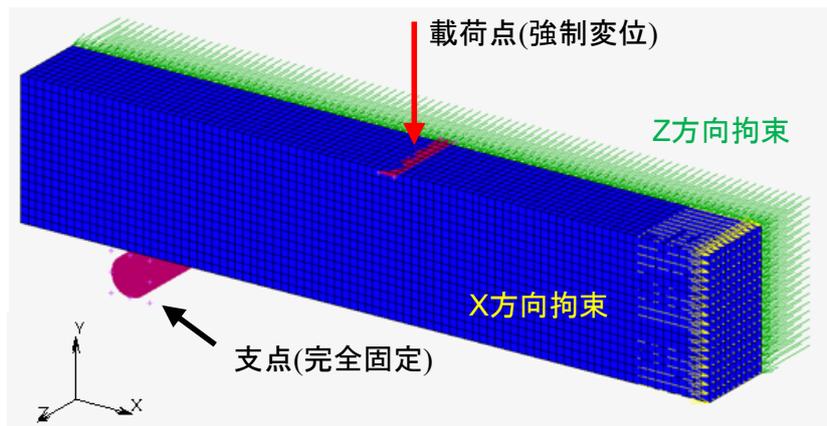


図 6.8 境界条件

### (3) 鉄筋の構成則

鉄筋およびボルトについても Von Mises の降伏条件を用いた。D19 の鉄筋の弾性係数は  $191,693\text{N/mm}^2$ 、降伏強度  $409\text{N/mm}^2$  は強度試験から得られた値で、D6 の弾性係数  $191,693\text{N/mm}^2$  は D19 と同じ値とし、降伏強度はミルシートから得られた値である。ポアソン比は 0.3 とした。降伏強度到達以降は、応力一定でひずみのみ増加するモデルとしている。

### (4) コンクリートの構成則

コンクリートは Von Mises の降伏条件を用いた。コンクリートの材料定数は、強度試験による結果から、圧縮強度 ( $f'_c$ )  $34.6\text{N/mm}^2$ 、引張強度  $2.23\text{N/mm}^2$ 、弾性係数  $28,970\text{N/mm}^2$  としている。ポアソン比は 0.2、破壊ひずみは 0.0035、せん断保持率は 0.5 としている。図 6.9 に圧縮側構成則を示す。圧縮強度の  $1/3$  までは線形とし、その後の最大圧縮応力までの圧縮上昇域は式 (6.3) に示す Saenz の提案式を用いた [59]。

$$\sigma = \frac{E_0 \varepsilon}{1 + [(E_0/E_s) - 2](\varepsilon/\varepsilon_{cu}) + (\varepsilon/\varepsilon_{cu})^2} \quad (6.3)$$

ここに、 $E_0$  は無応力時の弾性係数、 $\varepsilon_{cu}$  は  $f'_c$  に対するひずみ、 $E_s = f'_c/\varepsilon_{cu}$  である。最大応力に至った後は  $(4\varepsilon'_{cu}, 1/5 f'_c)$  の点まで線形的に応力が減少し、その後、応力は  $1/5 f'_c$  の一定値を保ちながらひずみのみが増加するモデルとした。

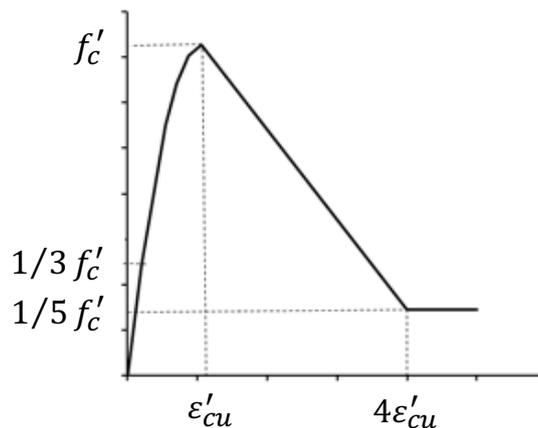


図 6.9 コンクリート圧縮側構成則

図 6.10 に引張側構成則 [60] を示す。引張強度まで線形弾性、引張強度到達以降は直線

軟化モデルを採用した。終局ひずみが引張強度到達時のひずみの3倍となるような軟化係数  $14,484\text{N}/\text{mm}^2$  を用いた。

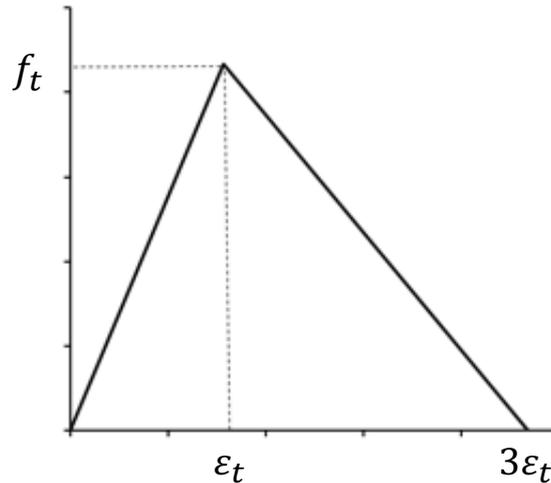


図 6.10 コンクリート引張側構成則

#### (5) PIC の構成則

PIC についても Von Mises の降伏条件を用いている。PIC の材料定数は強度試験による結果から、圧縮強度 ( $f'_c$ )  $157\text{N}/\text{mm}^2$ 、引張強度  $12.2\text{N}/\text{mm}^2$ 、弾性係数  $43,500\text{N}/\text{mm}^2$  としている。ポアソン比は 0.2、破壊ひずみは 0.01、せん断保持率は 0.5 とする。図 6.11 に圧縮側構成則 [61] を示す。PIC の応力-ひずみ関係は破壊応力まで直線的であり脆性破壊を呈することが多い。そこで圧縮強度の  $3/4$  倍まで線形とし、その後の最大圧縮応力までの圧縮上昇域は強度試験の結果から抜き出したデータを反映させている。圧縮強度到達以降は  $(0, f'_c)$  まで直線軟化するモデルとしている。

図 6.12 に引張側構成則 [60] を示す。引張強度まで線形弾性、引張強度到達以降は直線軟化モデルを採用した。終局ひずみが引張強度到達時のひずみの3倍となるような軟化係数  $22,000\text{N}/\text{mm}^2$  を用いた。

#### (6) 材料定数

表 6.9, 表 6.10 は、解析に用いたコンクリート、PC および鉄筋、ボルトの材料定数をまとめたものである。

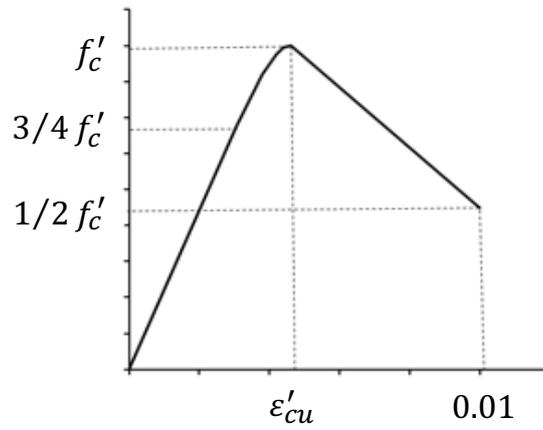


図 6.11 PIC 圧縮側構成則

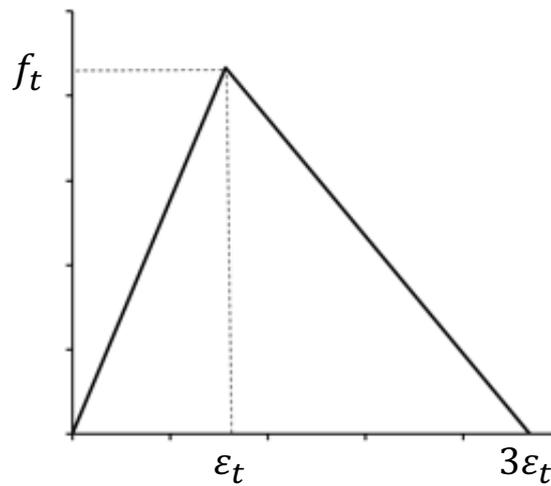


図 6.12 PIC 引張側構成則

表 6.9 材料定数 (コンクリート, PIC)

	弾性係数 (N/mm <sup>2</sup> )	ポアソン比	圧縮強度 (N/mm <sup>2</sup> )	引張強度 (N/mm <sup>2</sup> )
コンクリート	28,970	0.2	34.6	2.23
PIC	44,000	0.2	170	16.0

表 6.10 材料定数 (鉄筋, ボルト)

	弾性係数 (N/mm <sup>2</sup> )	ポアソン比	降伏強度 (N/mm <sup>2</sup> )
引張鉄筋 (D19, SD345)	191,693	0.3	409
圧縮鉄筋 (D6, SD295)	191,693	0.3	351
ボルト (M12, SS400)	205,000	0.3	250

## 6.3 実験結果および解析結果

### 6.3.1 載荷試験結果および考察

#### (1) 破壊性状と耐荷力

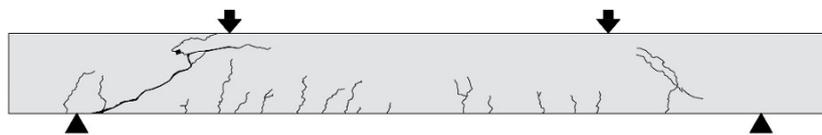
RC はりの載荷試験の結果を表 6.11 に示す. 全ての試験体においてせん断破壊を呈し, 試験体 B, C は鉄筋定着部損傷があることにより, せん断圧縮破壊からせん断引張破壊に移行した. 試験体 A と試験体 B の載荷試験の結果を比較すると, 試験体 B は試験体 A に対して曲げひび割れ発生荷重 ( $P_{cr}$ ) が約 68% まで, せん断耐力 ( $V_c$ ) は約 55% まで低下している. 試験体 B の  $V_c$  が著しく低下した原因としては, 主鉄筋に沿った損傷があり, 荷重がかかることで損傷の先端からせん断ひび割れが進展し, 損傷の上下のコンクリートでずれが生じたためと考えられる. 試験体 B と試験体 C の載荷試験の結果を比較すると, 試験体 C は試験体 B に対して  $P_{cr}$  が約 152% まで,  $V_c$  が約 194% まで増大した. これは, モデル損傷の先端からひび割れの進展やずれによるコンクリートの変形に対して, PIC 板が変形を抑制し, ひび割れ発生後も, PIC 板が有効断面として機能し続けたためと考えられる.

図 6.13 は試験終了後のひび割れ図である. 図 6.13 の (a), (b) のひび割れ図を比較すると, 試験体 A のほうがひび割れの本数は多くなっているが, 試験体 B のひび割れ長さが長く進展していることがわかる. これは, 定着部の損傷により, 損傷部から上側のコンクリートと下側のコンクリートがずれるため, 鉛直方向のひび割れ本数は少ないが, 一度ひび割れが生じると急激にひび割れが進展したためと考えられる. 図 6.13 の (c) を見ると, ひび割れはインサートナットの穴がある箇所に生じており, ひび割れ誘発の効果を示した. しかしながら, 試験体 C の表面上のひび割れは短く, 本数が少ないため, PIC 板はひび割れ抑制効果もあると考えられる.

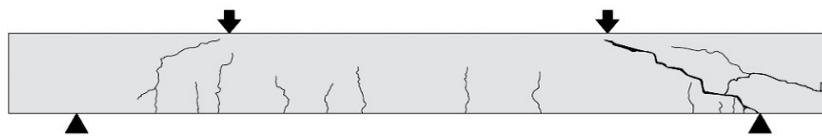
表 6.11 載荷試験結果

試験体		$P_{cr}$ (kN)	$P_y$ (kN)	$P_u$ (kN)	$V_c$ (kN)	破壊形状
A	実験値	29.0	-	-	181	せん断
	設計値	27.2	230	214	112	圧縮破壊
	実/設	1.07	-	-	1.62	
B	実験値	19.7	-	-	98.8	せん断
	設計値	27.2	230	214	50.4	引張破壊
	実/設	0.72	-	-	1.96	
C	実験値	29.9	-	-	192	せん断
	設計値	37.5	230	214	85.8	引張破壊
	実/設	0.8	-	-	2.2	

※試験体 B の  $V_c$  の設計値は損傷がない場合の 45% の値



(a) 試験体 A



(b) 試験体 B



(c) 試験体 C

図 6.13 ひび割れ図

図 6.14 は試験体 B のひび割れ状況である。(a) の短手方向に沿った側面では、荷重がかかることで主鉄筋上に設置したスチレンボードによる疑似損傷から、損傷の先端からせん断ひび割れが進展し、疑似損傷の上下のコンクリートにずれが生じた結果、主鉄筋の下端部からはり下端面まで鉛直方向にひび割れが伸びている。



(a) 短手方向側面

(b) 主筋とスチレンボード

図 6.14 ひび割れ状況 (試験体 B)

## (2) 荷重 - 変位関係

荷重 - 変位曲線を図 6.15 に示す。試験体 C のひび割れ発生後の曲げ剛性が試験体 A、試験体 B より高くなった。これは、定着部の損傷によるひび割れやその他のひび割れ発生直後では、曲げ強度が高い PIC 板にはひび割れが発生せず、PIC 板が有効断面として機能したためと考えられる。PIC 板にひび割れが発生した後においても、PIC 板の鋼繊維の架橋効果により PIC 板が引張力を負担するため、この場合も PIC 板は有効断面として機能し、曲げ剛性が高くなったと推察できる。また、試験体 B の曲げ剛性が最も低くなった要因としては、定着部のモデル損傷により、定着部損傷の上下のコンクリート同士で滑動し、鉄筋も含めた損傷部の下側が有効断面として機能しなかったためと考えられる。なお、図 6.15 の荷重 - 変位曲線が階段状になっているのは、他の研究で用いるために、実験途中で超音波探傷試験を行った影響である。

## (3) 荷重 - ひずみ関係

荷重 - スパン中央鉄筋ひずみおよびコンクリート上縁ひずみ曲線を図 6.16 に示す。荷重 - ひずみ関係は荷重 - 変位関係とは異なり、定着部損傷や PIC 板の有無に関わらずほぼ同じ挙動を示した。PIC 板をスパン中央部で接着していることが影響したと考えられる。

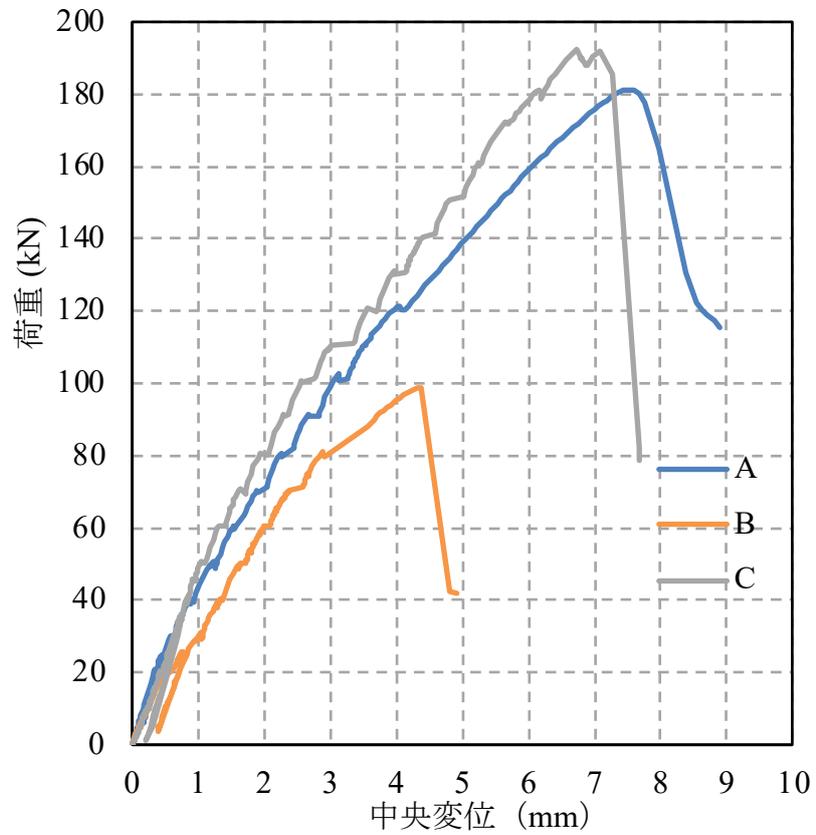


図 6.15 荷重 - 変位曲線

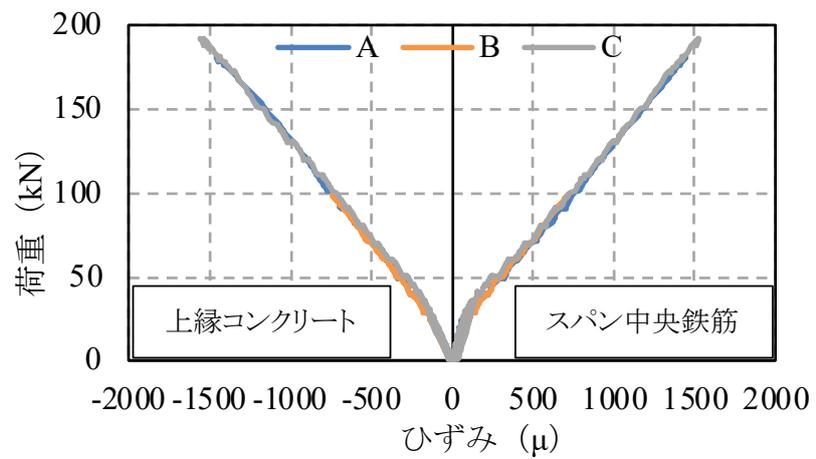
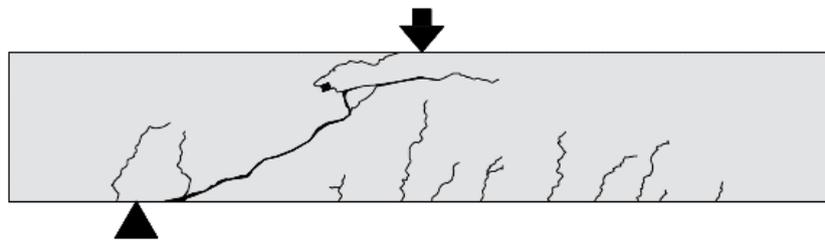


図 6.16 荷重 - ひずみ曲線

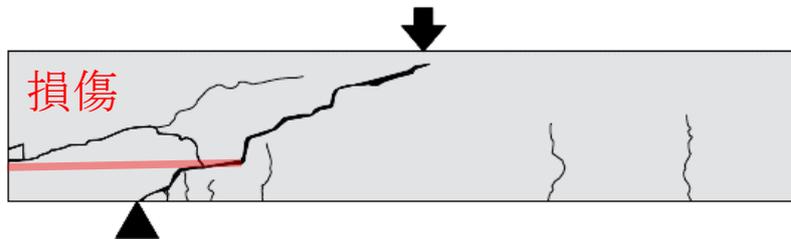
### 6.3.2 3次元 FE 解析結果および考察

#### (1) ひび割れ性状

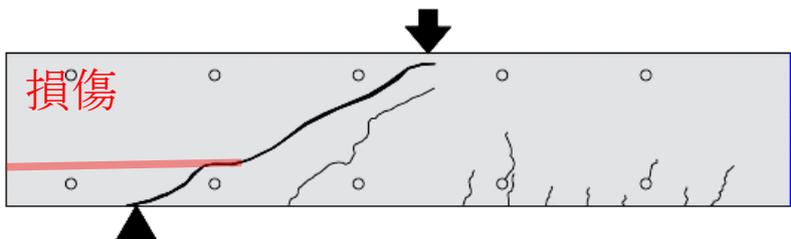
試験体 A, B, C について, 長手方向に沿った表面と中央断面, および短手方向に沿った中央断面におけるひび割れ性状の検討を行い, 鉄筋定着部損傷がある場合のひび割れ性状の検討を行う. 実験におけるはり側面のひび割れ図を図 6.17 に, 解析におけるはり側面のひび割れ性状を図 6.18 に, 解析におけるはり中央断面 (1/4 モデルの反対側側面) のひび割れ性状を図 6.19 に示す. なお, 解析のコンター図については, 実験値における最大荷重時のものとしている.



(a) 試験体 A(損傷なし)

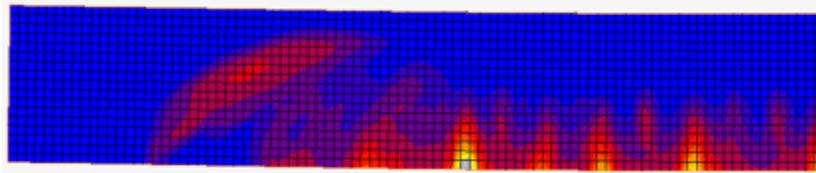


(b) 試験体 B(損傷あり)

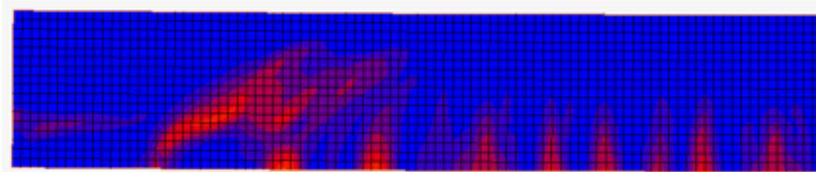


(c) 試験体 C(損傷あり +PIC)

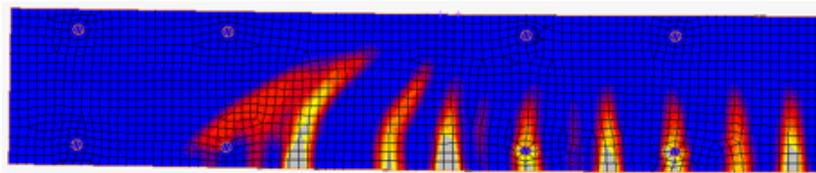
図 6.17 実験における側面のひび割れ図



(a) 試験体 A(損傷なし)



(b) 試験体 B(損傷あり)



(c) 試験体 C(損傷あり +PIC)

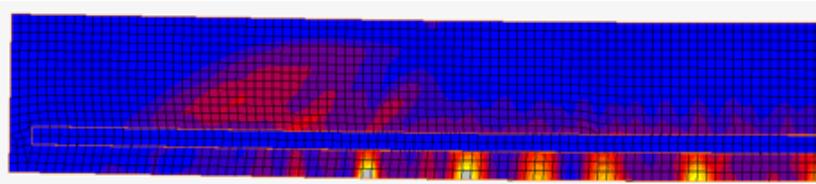
0  6,000  $\mu$   
 (Maximum Principal Value of Cracking strain)

図 6.18 解析における側面の最大主ひび割れひずみ

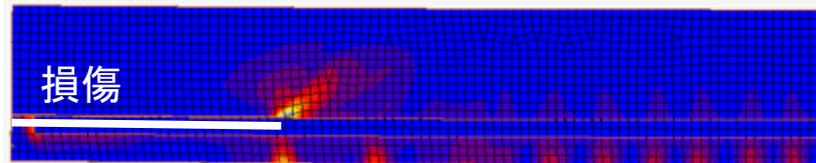
試験体 A について、長手方向を側面のせん断ひび割れや、曲げひび割れを解析により再現することができた。また、解析においては試験体 A の長手方向に沿った中央断面を確認できるが、中央断面においても表面と同じようにせん断ひび割れが進展していることがわかる。

試験体 B について、側面において実験では鉄筋に沿ったせん断ひび割れが確認でき、解析にもはり端部から鉄筋に沿ったひび割れがみられ、欠陥コンクリートについてもモデル化できたといえる。中央断面では、定着部損傷付近の主ひずみが小さく、損傷により応力が伝達していないことがコンター図よりわかる。中央断面では載荷点から支点の間にせん断によるひずみが広く分布しているわけではなく、定着部損傷端部にひずみが集中し、低い荷重でひび割れが発生したと考えられる。また、試験体 B では、鉄筋端部に接着するコンクリートにひずみが集中しており、鉄筋のすべりが大きくなっていることも確認できた。

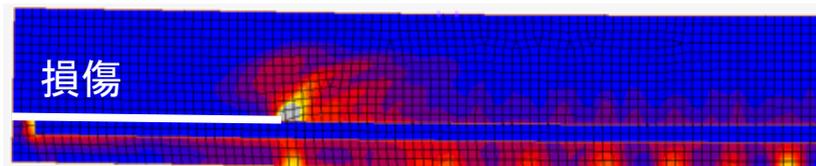
試験体 C について、載荷点と支点を結ぶ斜めひび割れが、PIC 板に発生した。これは定



(a) 試験体 A(損傷なし)



(b) 試験体 B(損傷あり)



(c) 試験体 C(損傷あり +PIC)



図 6.19 解析における縦断面の最大主ひび割れひずみ

着部損傷による影響と考えられるが、解析においても、斜めのせん断ひび割れが確認でき、最大荷重に大きな差はあるが、PIC 板とコンクリート間の応力伝達機構は整合性がとれていると考えられる。また、長手方向に沿った中央断面では、試験体 B と同じように、損傷付近の応力伝達の消滅と、損傷端部の応力集中がコンター図よりみてとれた。

また、試験体 B, C では、鉄筋端部に接着するコンクリートにひずみが集中しており、鉄筋のすべりが大きくなっていることも確認できた。

## (2) 荷重 - 変位関係

荷重 - 変位曲線を図 6.20, 6.21, 6.22 に示す。試験体 A は損傷のない RC はりであり、実験値と解析値はほぼ一致した。鉄筋定着部損傷を有する試験体 B においても、せん断耐力および曲げ剛性の解析値は実験値とほぼ一致し、試験体 A, B のどちらも最大荷重の差

が 6.5% 以内に収まった。このことから、欠陥のみを有する RC はりにおいても、解析法の妥当性が得られた。鉄筋定着部損傷を有し、PIC 板 (ボルト有り) で補強した試験体 C は、曲げ剛性はおおむね一致したものの、最大荷重は実験値のものより大きくなった。解析では PIC 板とコンクリートを完全付着させているため、PIC 板のひび割れ発生後も有効断面として機能し、定着部損傷の上下に応力を伝達し続けたためと考えられる。PIC 板で補強した RC はりの解析においては、今後、剥離やずれの検討が必要である。

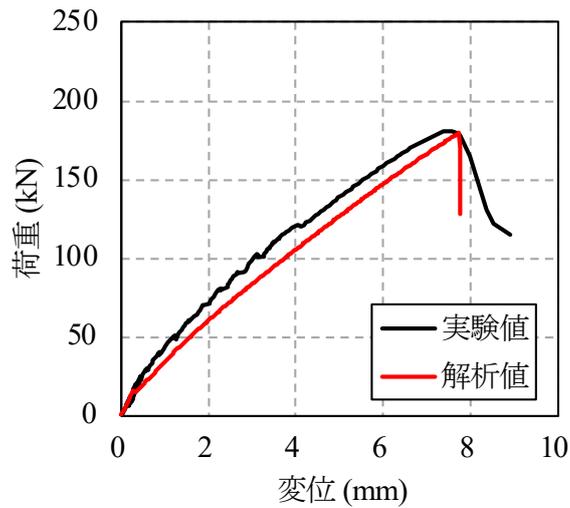


図 6.20 荷重 - 変位曲線 (試験体 A(損傷なし))

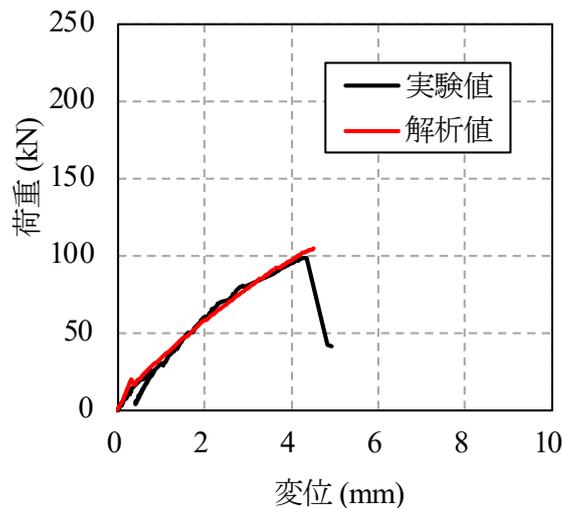


図 6.21 荷重 - 変位曲線 (試験体 B(損傷あり))

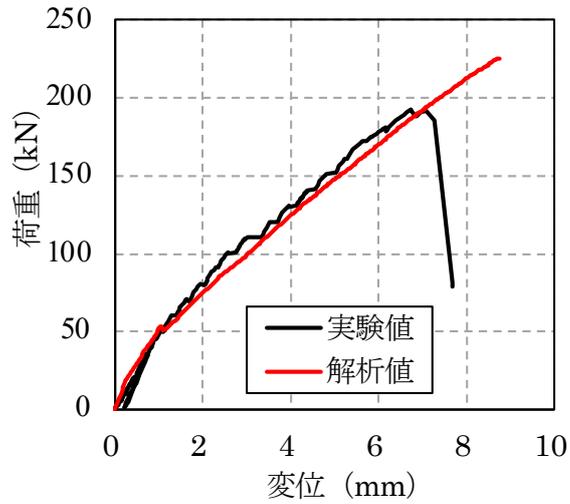


図 6.22 荷重 - 変位曲線 (試験体 C(損傷あり +PIC))

### (3) 荷重 - ひずみ関係

試験体 A, B, C の荷重 - スパン中央鉄筋ひずみおよびコンクリート上縁ひずみ曲線を図 6.23, 6.24, 6.25 に示す。試験体 A は同じ荷重時で見たとき、 $200\mu$  程度のひずみの差が生じたが、どちらの試験体において荷重 - ひずみ曲線はおおむね一致した。

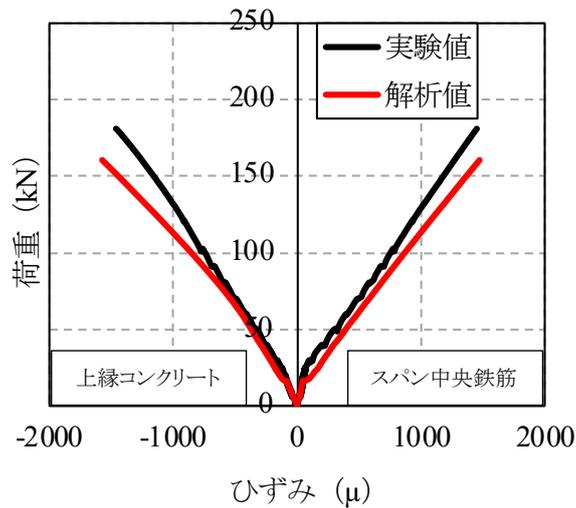


図 6.23 荷重 - ひずみ曲線 (試験体 A(損傷なし))

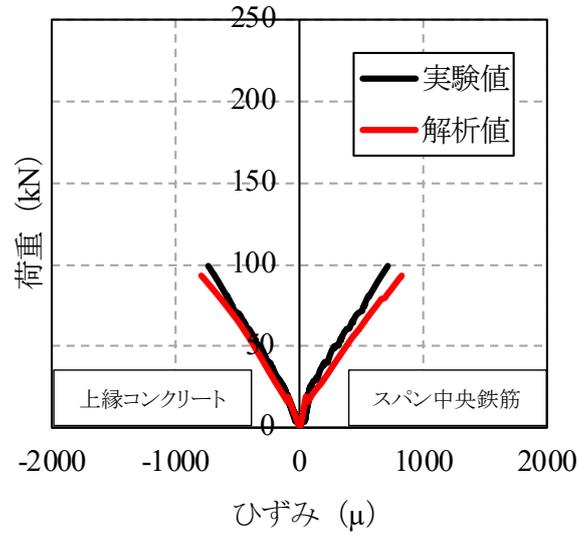


図 6.24 荷重 - ひずみ曲線 (試験体 B(損傷あり))

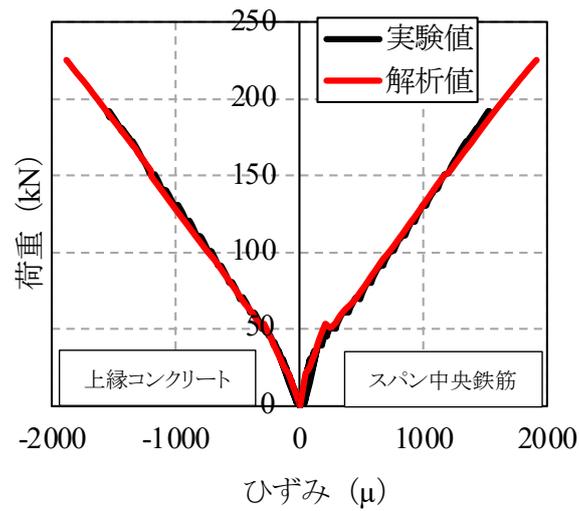


図 6.25 荷重 - ひずみ曲線 (試験体 C(損傷あり +PIC))

## 6.4 おわりに

本章では、様々な損傷や補強材を有する RC はりをコンピュータ上でシミュレーションする手法を提案することも目的として、3次元 CAD を援用し、汎用 FEM ソフトウェアの接触解析機能の利用を前提とした FE 解析手法について説明した。解析対象としては、健全な RC はり、鉄筋定着部の損傷を模擬した RC はりおよび損傷を模擬しポリマー含浸コ

ンクリート (PIC) 板で補強した RC はりとし、試験体を用いた載荷試験と 3 次元非線形 FE 解析を実施し、試験結果と解析結果を比較することにより解析法の妥当性について検討した。

載荷試験を行った結果、鉄筋定着部に損傷がある場合、曲げひび割れ発生荷重は損傷のない試験体の約 68%、せん断耐力は約 55% まで低下することがわかった。せん断強度が大きく定価した原因として、せん断伝達機能の低下や、損傷面 (ひび割れ面) のずれにより、先端からせん断ひび割れが進展したためと考えられる。鉄筋定着部に損傷がある場合、RC はりのせん断強度が著しく低下することが示され、鉄筋定着部の損傷が RC はりにとって深刻な問題であることが確認された。また、鉄筋定着部にモデル損傷ある RC はりについて PIC 板で補強した場合、PIC 板で補強していない RC はりと比べ、曲げひび割れ発生荷重は約 152%、せん断耐力は約 194% まで強度が回復した。また損傷がない試験体と比較した場合でも、曲げひび割れ発生荷重は約 103%、せん断強度は約 106% となり、PIC 板の優れた付着特性による、ずれやせん断ひび割れ等の変形の抑制効果が確認でき、せん断補強効果が得られた。

3 次元非線形 FEM による解析では、損傷のない試験体、損傷のある試験体および PIC で補強した損傷のある試験体において、荷重 - 変位曲線、荷重 - ひずみ曲線、ひびわれ性状を、おおむねシミュレーションすることができ、本論文で作成したモデルおよび構成則等の妥当性が検証できた。また、内部でのひび割れ性状を明らかにでき、鉄筋定着部損傷による応力の伝達機構の変化を観察することができたことから、他の損傷を有する RC はりの解析への応用も可能であると考えられる。

## 参考文献

- [52] 千々和伸浩, GEBREYOUHANNES Esayas, 藤山知加子, 前川宏一「定着部に損傷を有する RC 梁のせん断耐荷機構」『コンクリート工学年次論文集』29.3 (2007), pp. 709–714.
- [53] 千々和伸浩, 川中勲, 前川宏一「引張鉄筋定着部に腐食劣化を有する RC 梁の残存耐力と未損傷領域への面的補強」『土木学会論文集 E2 (材料・コンクリート構造)』67.2 (2011), pp. 160–165.
- [54] 松田浩, 崎村陽介, 安東祐樹, 鶴田健, 林山豊, 森田千尋, 崎山毅「PIC 板または鋼板で補強された RC はりの鉄筋の付着領域を考慮した非線形 FEM 解析」『応用力学論文集』7 (2004), pp. 1213–1223.
- [55] 千々和伸浩「定着部に損傷を有する RC 部材の残存構造性能評価と補強に関する研究」, 博士論文, 東京大学, 2009.
- [56] 土木学会『2002 年制定コンクリート標準示方書 [規準編]』, 2002, pp. 291–294, 302–303, 328–329.
- [57] 笠井芳夫, 池田尚治『コンクリートの試験方法 (下)』, 2 面せん断法, 株式会社技術書院, 1993, pp. 84–86.
- [58] 二羽淳一郎『コンクリート構造の基礎』, 株式会社推理工学社, 2006, p. 77.
- [59] 色部誠, 河角誠, 安達洋『コンクリート構造物の塑性解析』, 丸善株式会社, 1985.
- [60] 松田浩, 崎山毅, 森田千尋「高耐久性埋設型枠を設置した RC 梁の弾塑性挙動解析」『長崎大学工学部研究報告』30.55 (2000), pp. 199–205.
- [61] 水野生「新設壁開口を有する壁式鉄筋コンクリート構造の弾性挙動に関する解析的研究」『コンクリート工学年次論文集』29.3 (2007).

## 第7章

# 結論

### 7.1 はじめに

本論文では、著者がこれまで行ってきた AI およびデジタルツインに関連した研究のうち、インフラ維持管理分野の DX に資すると思われる一連の研究を取り纏めた。本章では、各章ごとの研究内容と得られた成果をまとめ、続いて、実際のインフラ維持管理において本成果に期待できる役割と残された課題についてまとめて結論とする。

### 7.2 各章の成果の検討内容および成果のまとめ

まず第1章では、本研究の背景、目的および本論文の構成について述べた。我が国の道路網をはじめとした社会インフラ構造物の現状について、その大部分が建造から50年以上を経て老朽化が進行しており、21世紀は維持管理の時代として既存の構造物を如何に延命していくかが課題となっていること、特に、少子高齢化や都市部への人口流出・過疎化による人口減少が進行しつつある地方自治体においては、社会保障費支出が増加する中で、道路や橋梁などの社会インフラを限られた財源や人材の中で適切に維持管理していくことは、住民生活の利便性確保だけでなく、防災・減災の面からも非常に大きな課題となっていることを示した。そのような背景の中、2012年12月に発生した中央自動車道の笹子トンネルの崩落事故を機に、「道路法等の一部を改正する法律」が2013年6月に公布され、さらに、「道路法施行規則の一部を改正する省令」および「トンネル等の健全性の診断結果の分類に関する告示」が2014年3月に公布されたが、そこで求められる手法は、膨大な作業時間と作業量を要する、検査者の知識および経験に依存する、地方自治体の技術者不足、検査者の個人差によるばらつきがある、高精度かつ客観的な評価が難しい、など多くの

問題を抱えていることを示した。

また、近年、様々な分野でデジタルトランスフォーメーション (DX) が推進されているおり、これからのインフラ維持管理においては、ビッグデータ等のデータや、AI, IoT に代表されるデジタル技術、現実の情報をデジタル上で表現し、分析やシミュレーションなどを行うデジタルツインなどを活用してデジタルトランスフォーメーション (DX) を推進していく必要があると研究の方向性を定めた。

第 2 章では、代表的なアスファルト舗装の路面性状評価法である路面の維持管理指数 (MCI) について説明し、MCI の指標の一つであるひび割れ率を、高価な路面性状専用測定車を使用せず、スマートフォンやドライブレコーダーで撮影した動画から画像処理と画像認識 AI を用いて算出する手法を詳細な手順で示すとともに、本手法で算出したひび割れ率の精度検証を行い、正解のひび割れ率と本手法との誤差が MCI 値に与える影響について考察し、路面性状専用測定車による測定の代替手段となりうることを確認した。また、さらなる精度向上のためには、教師データの数および各分類カテゴリーの画像数を揃えること、誤検知が多いマンホール等の構造物を分類カテゴリーを増やすこと、画像の質を向上させることが必要であると考察した。

第 3 章では、コンクリートのひび割れを、領域分割 AI を用いて自動抽出する手法について述べた。画像処理タスクの一つであるセマンティック・セグメンテーションについて説明するとともに、教師データの作成方法、AI の訓練パラメーターの精度への影響について考察し、本手法で算出したひび割れの精度を IoU (Jaccard 係数) という指標を用いて検証した結果を示した。

第 4 章では、橋梁の損傷を、物体検出 AI を用いて写真から検出する手法について示した。物体検出 AI モデルの一つである SSD (Single Shot Multibox Detector) について説明するとともに、教師データの作成方法、物体検出処理における精度検証方法について言及している。剥離、鉄筋露出、漏水、遊離石灰の 4 つの損傷を対象とした物体検出 AI の学習状況、AP (Average Precision)、mAP (mean Average Precision) といった指標による精度検証結果について示し、物体検出 AI を橋梁の損傷検出に適用する場合の留意点や精度向上について考察した。

第 5 章では、たわみ影響線の変化率およびたわみの時刻歴応答の変化率を用いて、橋梁の劣化箇所を同定する手法を開発するため、まず、たわみ影響線の変化率について、実験と FEM シミュレーションを行った結果を示し、たわみ影響線の変化率を用いた手法は、剛性の変化に対して振動特性よりも敏感であり、たわみ影響線の変化率曲線により、変状箇所を視覚的に捉えられることが確認した。次に、たわみの時刻歴応答の変化率について、移動荷重を受ける単純支持はりについて、フーリエ級数を用いた解析解による結果と FEM

によるシミュレーション結果を比較検討し、FEM シミュレーションにおける解析手法の妥当性を示した。さらに、FEM シミュレーション上で損傷を有するモデルを作成し、損傷を有するはりと損傷の無いはりについて、移動荷重による変位の時刻歴応答の変化率を求めることで、損傷の有無だけでなく、損傷位置を検出できることを示した。

第 6 章では、様々な損傷や補強材を有する RC はりをコンピュータ上でシミュレーションする手法を提案することを目的とし、3 次元 CAD を援用し、汎用 FEM ソフトウェアの接触解析機能の利用を前提とする手法について説明した。本手法を用いて、健全な RC はり、鉄筋定着部の損傷を模擬した RC はりおよび損傷を模擬しポリマー含浸コンクリート (PIC) 板で補強した RC はりを解析対象として、試験体を用いた载荷試験と 3 次元非線形 FE 解析を実施し、試験結果と解析結果を比較することにより解析法の妥当性について検討した。

### 7.3 インフラ維持管理における本成果の意義と残された課題

最後に、インフラ維持管理において、本研究の成果に期待できる役割と今後の課題のついてまとめる。

第 2 章における画像分類 AI を用いたアスファルト舗装路面のひび割れ率の算出方法は、MCI で用いられている路面性状専用測定車による手法に準拠したものとなっており、路面性状専用測定車による測定の代替手段として用いることができると考えられる。路面性状専用測定車による測定の代替手段として用いることにより、低コスト化、より高い頻度での路面性状の測定が可能になると考える。本手法の今後の課題としては、より多くの路面データを収集して教師データの質を向上させ、AI の精度を高めることだと考える。

第 3 章におけるコンクリートのひび割れの自動抽出法は、橋梁などのひび割れを自動的に抽出する手法として有効であると考えられる。画像の画素サイズに関する情報を加えれば、ひび割れ幅を求めることも可能である。

第 4 章の橋梁の損傷検出法は、近接での撮影画像だけでなく、望遠レンズやドローンを使って撮影した写真から橋梁の損傷を検出する手法として活用できると考えられる。また、3 次元計測されたデータについても活用可能であると考えられるため、撮影時は損傷を意識せずに、橋梁全体を 3 次元計測し、計測後構成された 3 次元データから損傷検出するような手法を確立することもできると考える。本手法の今後の課題としては、さらに多くの損傷に対応するため、教師データの質の向上が考えられる。また、損傷の種類によっては、矩形領域での物体検出が不向きなものがあるため、第 3 章の手法と組み合わせて損傷検出方法を検討する必要があると考える。

第5章のたわみの影響線の変化率およびたわみの時刻歴応答の変化率による橋梁の損傷箇所同定法については、目視での損傷確認が難しい橋梁において、損傷箇所を推定する手法として活用できると考える。ある時点における静的荷重や移動荷重によるたわみを計測しておき、定期的にモニタリングを行うことによって、損傷発生および損傷発生箇所の検知に活用できると考える。さらに、モニタリングする箇所は支点以外であれば損傷発生位置でなくとも構わないため、例えば、各スパンにおいて測定しやすい位置で測定できるというメリットもある。本手法の今後の課題としては、実橋梁への適用を考慮した場合、たわみ量や固有振動数がほとんど変化しないような剛性変化に対して、本法を用いる場合には如何に微小なたわみ量を計測するかが重要になるため、微少なたわみ量を計測する手法を合わせて確立する必要があると考える。また、現在はシミュレーション状況下における検証となっているので、実験室レベル、実橋梁への適用を行っていく必要がある。

第6章の3次元CADを援用したRCはりのFE解析手法については、3次元CADと汎用FEMソフトウェアを組み合わせた手法となっているため、様々な鉄筋コンクリート構造物の解析に応用できると考えられる。また、本手法では3次元CADを用いており損傷の設定が容易なため、様々な損傷を有する鉄筋コンクリート構造物をシミュレーション解析できると考える。さらに、本研究では、コンクリート、鉄筋、PICを完全付着としていたが、接触解析機能を用いることで、付着強度を考慮したシミュレーションに発展できると考える。

## 参考文献

- [1] 国土交通省『道路法等の一部を改正する法律案について』, 2013-03, URL: [https://www.mlit.go.jp/report/press/road02\\_hh\\_000005.html](https://www.mlit.go.jp/report/press/road02_hh_000005.html).
- [2] 国土交通省『道路の維持修繕に関する省令・告示の制定について（道路法施行規則の一部改正等）』, 2014-03, URL: [https://www.mlit.go.jp/report/press/road01\\_hh\\_000412.html](https://www.mlit.go.jp/report/press/road01_hh_000412.html).
- [3] Erik Stolterman and Anna Croon Fors. “Information Technology and the Good Life”. In: *Information Systems Research* 143 (2004), pp. 687–692.
- [4] 経済産業省『DX レポート, ~IT システム「2025 年の崖」克服と DX の本格的な展開~』, 2018-09, URL: [https://www.meti.go.jp/shingikai/mono\\_info\\_service/digital\\_transformation/20180907\\_report.html](https://www.meti.go.jp/shingikai/mono_info_service/digital_transformation/20180907_report.html).
- [5] 内閣官房情報通信技術 (IT) 総合戦略室『世界最先端デジタル国家創造宣言・官民データ活用推進基本計画』, 政府 CIO ポータル, 2020, URL: <https://cio.go.jp/node/2413>.
- [6] 国土交通省 国土技術政策総合研究所インフラ DX 研究推進本部『国土交通省が進める DX』, URL: [http://www.nilim.go.jp/japanese/organization/infradx\\_honbu/indexinfradx.htm](http://www.nilim.go.jp/japanese/organization/infradx_honbu/indexinfradx.htm).
- [7] 日本道路協会『舗装調査・試験法便覧』, 第 1 分冊, 第 II 章, 日本道路協会, 2019, pp. 147–176.
- [8] 中村博康, 井原務「道路舗装のひび割れ率の簡易評価手法の検討」『舗装』48.11 (2013), pp. 12–15.
- [9] 佐々木博「スマートフォンを活用した新たな舗装維持管理技術」『舗装』51.6 (2016), pp. 23–28.

- [10] 全邦釘, 井後敦史, 南免羅裕治, 黒木航汰, 大窪和明「車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価」『土木学会論文集 E1 (舗装工学)』73.3 (2017), I.97–I.105.
- [11] 浅田拓海, 亀山修一, 川端伸一郎, 佐々木克典「走行車両から撮影した路面画像を用いた舗装のひび割れ評価手法の開発」『土木学会論文集 E1 (舗装工学)』70.3 (2015), I.9–I.16.
- [12] Karen Simonyan and Andrew Zisserman. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2014. DOI: 10.48550/ARXIV.1409.1556. URL: <https://arxiv.org/abs/1409.1556>.
- [13] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. “ImageNet: A large-scale hierarchical image database”. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009, pp. 248–255. DOI: 10.1109/CVPR.2009.5206848.
- [14] Diederik P. Kingma and Jimmy Ba. *Adam: A Method for Stochastic Optimization*. 2014. DOI: 10.48550/ARXIV.1412.6980. URL: <https://arxiv.org/abs/1412.6980>.
- [15] 鵜飼正人「画像処理によるトンネル構造物ひび割れ検査精度の向上」『特集: 信号通信技術』24.3 (2010), p. 53.
- [16] 全邦釘, 片岡望, 三輪知寛, 橋本和明, 大賀水田生「統計的特徴および幾何学的特徴に着目したコンクリート表面ひび割れの画像解析による検出」『土木学会論文集 F3 (土木情報学)』70.2 (2014), I.1–I.8.
- [17] 全邦釘, 井後敦史「Random Forest によるコンクリート表面ひび割れの検出」『土木学会論文集 F3 (土木情報学)』71.2 (2015), I.1–I.8.
- [18] 全邦釘, 嶋本ゆり, 大窪和明, 三輪知寛, 大賀水田生「ディープラーニングおよび Random Forest によるコンクリートのひび割れ自動検出手法」『土木学会論文集 F3 (土木情報学)』73.2 (2017), I.297–I.307.
- [19] 山根達郎, 全邦釘「Deep learning による Semantic Segmentation を用いたコンクリート表面ひび割れの検出」『構造工学論文集 A』65A (2019), pp. 130–138.
- [20] Liang-Chieh Chen, George Papandreou, Florian Schroff, and Hartwig Adam. *Rethinking Atrous Convolution for Semantic Image Segmentation*. 2017. DOI: 10.48550/ARXIV.1706.05587. URL: <https://arxiv.org/abs/1706.05587>.

- [21] Vijay Badrinarayanan, Alex Kendall, and Roberto Cipolla. *SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation*. 2015. DOI: 10.48550/ARXIV.1511.00561. URL: <https://arxiv.org/abs/1511.00561>.
- [22] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. 2015. DOI: 10.48550/ARXIV.1505.04597. URL: <https://arxiv.org/abs/1505.04597>.
- [23] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, and Jiaya Jia. *Pyramid Scene Parsing Network*. 2016. DOI: 10.48550/ARXIV.1612.01105. URL: <https://arxiv.org/abs/1612.01105>.
- [24] Liang-Chieh Chen, George Papandreou, Iasonas Kokkinos, Kevin Murphy, and Alan L. Yuille. *Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs*. 2014. DOI: 10.48550/ARXIV.1412.7062. URL: <https://arxiv.org/abs/1412.7062>.
- [25] Liang-Chieh Chen, George Papandreou, Iasonas Kokkinos, Kevin Murphy, and Alan L. Yuille. “DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs”. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 40.4 (2018), pp. 834–848. DOI: 10.1109/TPAMI.2017.2699184.
- [26] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, and Hartwig Adam. *Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation*. 2018. DOI: 10.48550/ARXIV.1802.02611. URL: <https://arxiv.org/abs/1802.02611>.
- [27] The PyTorch Foundation. URL: <https://pytorch.org/>.
- [28] The GIMP Team. URL: <https://www.gimp.org/>.
- [29] The PASCAL VOC project. *The PASCAL Visual Object Classes Homepage*. URL: <http://host.robots.ox.ac.uk/pascal/VOC/index.html>.
- [30] 田畑佑, 党紀, 春田大二郎, AshishSHRESTHA, 松永昭吾, 全邦釘「UAV 撮影と深層学習を用いた橋梁損傷の自動検知に関する検証」『土木学会論文集 F4 (建設マネジメント)』74.2 (2018), I.62–I.74.
- [31] 青島亘佐, 河村伸哉, 中野聡, 中村秀明「深層学習による画像認識を用いたコンクリート構造物の変状検出に関する研究」『土木学会論文集 E2 (材料・コンクリート構造)』74.4 (2018), pp. 293–305.

- [32] 党紀, 水元大雅, 全邦釘, 劉佳明, 藤嶋斗南「YOLO を用いた多種類橋梁損傷の同時検出」『AI・データサイエンス論文集』2.J2 (2021), pp. 447–456.
- [33] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. “Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation”. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. 2014, pp. 580–587. DOI: 10.1109/CVPR.2014.81.
- [34] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. *You Only Look Once: Unified, Real-Time Object Detection*. 2015. DOI: 10.48550/ARXIV.1506.02640. URL: <https://arxiv.org/abs/1506.02640>.
- [35] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, and Alexander C. Berg. “SSD: Single Shot MultiBox Detector”. In: *Computer Vision – ECCV 2016*. Springer, 2016, pp. 21–37.
- [36] Papers With Code. *Object Detection on PASCAL VOC 2007*. URL: <https://paperswithcode.com/sota/object-detection-on-pascal-voc-2007>.
- [37] Tzutalin. *LabelImg*. 2015. URL: <https://github.com/tzutalin/labelImg>.
- [38] Rafael Padilla, Wesley L. Passos, Thadeu L. B. Dias, Sergio L. Netto, and Eduardo A. B. da Silva. “A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit”. In: *Electronics* 10.3 (2021). ISSN: 2079-9292. DOI: 10.3390/electronics10030279. URL: <https://www.mdpi.com/2079-9292/10/3/279>.
- [39] Rafael Padilla, Wesley L. Passos, Thadeu L. B. Dias, Sergio L. Netto, and Eduardo A. B. da Silva. *Open-Source Visual Interface for Object Detection Metrics*. URL: [https://github.com/rafaelpadilla/review\\_object\\_detection\\_metrics](https://github.com/rafaelpadilla/review_object_detection_metrics).
- [40] 河村太紀, 木本啓介, 森田千尋, 西川貴文, 松田浩「橋梁の構造同定による性能評価と安全性評価に関する研究」『土木学会第 72 回年次学術講演会』, 土木学会, 2017.
- [41] 林謙介, 河村太紀, 松田浩「光学的計測法による損傷を有する鋼トラス橋の構造同定および変状検知」『土木学会第 73 回年次学術講演会』, 土木学会, 2018, pp. 1027–1028.
- [42] 武田龍國, 中島章典, Nguyen MinhHai「たわみの影響線を利用した橋梁の劣化箇所同定の試み」『土木学会第 71 回年次学術講演会』, 土木学会, 2016, pp. 141–142.
- [43] 渡邊学歩, 内藤慎也, 友廣郁也「小規模橋梁のたわみ影響線観測に基づく構造ヘルスマモニタリング」『土木構造・材料論文集』32-20 (2016), pp. 125–134.

- [44] 林謙介, 木本啓介, 河村太紀, 奥松俊博, 山口浩平, 松田浩「損傷を有する鋼トラス橋の固有振動数とたわみ影響線変化率の関係」『鋼構造論文報告集』(2018-11), pp. 390–395.
- [45] 宮濱晃一, 林謙介, 松田浩, 山口浩平, 古賀掲維「光学的計測法を用いた撤去 RC 桁の検査, 診断及び実橋への利活用に関する研究」『土木学会全国大会第 74 回年次学術講演会』, 2019-09.
- [46] 大塚浩司, 庄谷征美, 外門正直, 原忠勝『鉄筋コンクリート工学』, 第 3 版, 技報堂出版, 1997.
- [47] 永松牧子, 出水享, 鶴田健, 岡本賢治, 宮本紘貫, 松田浩「PIC 板で補強した RC はりの補強効果に関する実験及び解析的研究」『長崎大学大学院工学研究科研究報告』95.50 (2020), pp. 65–70.
- [48] 国土交通省道路局『道路橋定期点検要領』, 2014-06, URL: <https://www.mlit.go.jp/common/001044574.pdf>.
- [49] プレストレストコンクリート工学会『コンクリート構造診断技術』, プレストレストコンクリート工学会, 2016.
- [50] 小坪清真『入門建設振動学』, 第 1 版, 森北出版, 1996, p. 197.
- [51] 小原生也, 高木健, 石井抱「振動ベースド画像特徴量を用いた高速ターゲットトラッキング」『日本機械学会論文集 (C 編)』78.788 (2012), pp. 1143–1153.
- [52] 千々和伸浩, GEBREYOUHANNESEsayas, 藤山知加子, 前川宏一「定着部に損傷を有する RC 梁のせん断耐荷機構」『コンクリート工学年次論文集』29.3 (2007), pp. 709–714.
- [53] 千々和伸浩, 川中勲, 前川宏一「引張鉄筋定着部に腐食劣化を有する RC 梁の残存耐力と未損傷領域への面的補強」『土木学会論文集 E2 (材料・コンクリート構造)』67.2 (2011), pp. 160–165.
- [54] 松田浩, 崎村陽介, 安東祐樹, 鶴田健, 林山豊, 森田千尋, 崎山毅「PIC 板または鋼板で補強された RC はりの鉄筋の付着領域を考慮した非線形 FEM 解析」『応用力学論文集』7 (2004), pp. 1213–1223.
- [55] 千々和伸浩「定着部に損傷を有する RC 部材の残存構造性能評価と補強に関する研究」, 博士論文, 東京大学, 2009.
- [56] 土木学会『2002 年制定コンクリート標準示方書 [規準編]』, 2002, pp. 291–294, 302–303, 328–329.
- [57] 笠井芳夫, 池田尚治『コンクリートの試験方法 (下)』, 2 面せん断法, 株式会社技術書院, 1993, pp. 84–86.

- [58] 二羽淳一郎『コンクリート構造の基礎』，株式会社推理工学社，2006，p. 77.
- [59] 色部誠，河角誠，安達洋『コンクリート構造物の塑性解析』，丸善株式会社，1985.
- [60] 松田浩，崎山毅，森田千尋「高耐久性埋設型枠を設置した RC 梁の弾塑性挙動解析」『長崎大学工学部研究報告』30.55 (2000)，pp. 199–205.
- [61] 水野生「新設壁開口を有する壁式鉄筋コンクリート構造の弾性挙動に関する解析的研究」『コンクリート工学年次論文集』29.3 (2007).

# 謝辞

本研究を進めるにあたり御懇篤なる御指導と御教授を頂いた次の方々に深甚な謝意を表します。本論文は、長崎大学工学研究科松田浩教授の全面的な御指導を賜って取りまとめたものです。松田先生には本研究の方向性について貴重な御意見を頂戴するとともに、研究心の大切さについて常に叱咤激励を賜り、その度に心機一転してまいりました。ここに、衷心より感謝と共にお礼申し上げます。

さらに、さらに長崎大学工学研究科中村聖三教授、奥松俊博教授、山口浩平准教授には、本論文に対して貴重な御指導と御教授を頂きました。深く感謝いたします。

また、長崎大学工学部構造工学コースの出水亨技術専門職員、田邊はつみ様、松田研究室の卒業生、修了生、在学生の各位にも終始温かい激励と御配慮をいただきました。この場をお借りして深く感謝するとともに、厚く御礼申し上げます。

最後になりましたが、本論文を作成できましたのは、先に記して感謝の意を表しました松田浩先生の公私に亘る御尽力の賜物です。ここに重ねて心から感謝の意を表します。