調査研究報告　　No. 462
RESEARCH REPORT 2026. 3

AI を活用した RC 造建築物外壁調査・診断等の支援技術の開発

Development of Supportive Technology for Reinforced Concrete Buildings Exterior Walls Inspection and Diagnosis Using AI

齊藤 隆典[1)]，今井 崇嗣[2)]，糸毛 治[3)]，川瀬 みなみ[4)]，鈴木 公平[5)]
Takasuke Saito[1)], Takashi Imai[2)], Osamu Itoge[3)], Minami Kawase[4)], Kohei Suzuki[5)]

地方独立行政法人北海道立総合研究機構
建築研究本部
北方建築総合研究所
Northern Regional Building Research Institute
Building Research Department
Local Independent Administrative Agency Hokkaido Research Organization

1) 建築研究部建築システムグループ 主査 博士（工学） 2) 地域研究部防災システムグループ 研究職員 3) 建築研究部 部長 博士（工学） 4) 株式会社コンステック 博士（芸術工学） 5) 株式会社コンステック 博士（工学）
1) Chief Coordinator of Building Engineering System Group, Dr. Eng. 2) Researcher of Disaster Prevention Group 3) Director of Building Research Division, Dr. Eng. 4) Constec Engi., Co., Dr. Des. Arch. 5) Constec Engi., Co., Dr. Eng.

本書の全部および一部の無断での転載はご遠慮ください。

No unauthorized reproduction

概　要
Abstract

AI を活用した RC 造建築物外壁調査・診断等の支援技術の開発
Development of Supportive Technology for Reinforced Concrete Buildings Exterior Walls Inspection and Diagnosis Using AI

齊藤 隆典[1)]，今井 崇嗣[2)]，糸毛 治[3)]，川瀬 みなみ[4)]，鈴木 公平[5)]
Takasuke Saito[1)], Takashi Imai[2)], Osamu Itoge[3)], Minami Kawase[4)], Kohei Suzuki[5)]

キーワード ： 画像認識 AI、RC 造建築物、外壁、劣化調査、省力化
***Keywords：** Image recognition AI, Reinforced concrete structures, Exterior walls, Deterioration inspection, Labor-saving*

１．研究概要

１）研究の背景

・道内には数万棟規模の鉄筋コンクリート（以下、RC とする。）造建築物が存在しており、建築から 30 年以上が経過して長寿命化診断や改修工事の必要性の高い、老朽化した建築物が年々増加している。
・建築物外壁の維持管理では、点検・調査で把握する劣化状況に基づく適切な補修や改修の実施が不可欠だが、劣化把握は目視調査が基本であり、作業労力や調査の正確性等から合理化が望まれている。
・AI による合理化が各分野で活発化しているが、建築物は外壁仕上げや劣化事象が多様なこと、民間の管理が一般的で学習用データの入手難しい等から、建築物の調査技術への AI 活用は進んでいない。
・当所では、既往研究において RC 造建築物を対象に AI を用いた外壁劣化検出の基礎検討を行い、実務で使用可能な技術開発に進められる状況にあり、一般の調査技術者が利用可能なソフトウェア等の整備を図ることで、点検・調査における労力の削減や調査の正確性の向上が期待できる。

２）研究の目的

RC 造建築物の外壁調査・診断等において、調査の合理化や正確性向上を図るため、AI を活用した調査・診断等の支援技術を開発する。

２．研究内容

１）外壁の撮影条件・撮影方法の検討・構築（R5～R6 年度）

・ねらい：一般的なデジタルカメラの撮影画像から劣化状況を検出するための AI の精度確保と調査時の支障の有無を検討し、外壁の撮影条件・撮影方法を構築する。また、ドローンによる建物撮影を実施し、AI による劣化検出の確認、撮影条件・撮影方法を構築する。
・試験項目等：撮影条件・撮影方法の検討、ドローン撮影・劣化検出の確認

２）外壁劣化検出 AI の構築（R5～R7 年度）

・ねらい：データが不足する外壁仕様と劣化種類の教師データを追加作成する。劣化検出に適する AI の学習パラメータ等の検討を行い、追加した教師データを含めた AI の学習を行う。実測調査の結果に基づき、外壁劣化の検出精度（目標：F 値[注 1]≧0.8）を確認する。

注 1：検出精度の評価指標

---

1) 建築研究部建築システムグループ 主査 博士（工学） 2) 地域研究部防災システムグループ 研究職員 3) 建築研究部 部長 博士（工学） 4) 株式会社コンステック 博士（芸術工学） 5) 株式会社コンステック 博士（工学）
1) Chief Coordinator of Building Engineering System Group, Dr. Eng. 2) Researcher of Disaster Prevention Group 3) Director of Building Research Division, Dr. Eng. 4) Constec Engi., Co., Dr. Des. Arch. 5) Constec Engi., Co., Dr. Eng.

・試験項目等：教師データ作成、学習パラメータ・学習ネットワーク設定、AI 学習、精度検証

３）調査・診断支援ソフトウェアの開発（R6～R7 年度）

・ねらい：２）の劣化検出 AI を搭載したソフトウェアを開発する。当所では実務で必要な仕様の検討や撮影画像の正対化等の画像処理の基本作成を行い、処理機能の実装等をシステム開発会社に業務委託する。開発段階では、調査技術者の試行に基づくソフトウェア改良を行う。

・試験項目等：ソフトウェア仕様・基本プログラムの作成、ソフトウェア開発、試行による検証・改良

４）調査・診断支援技術の有効性の検証（R7 年度）

・ねらい：３）で開発した調査・診断支援ソフトウェアを用い、実建物を対象とした調査試行を実施する。従来手法である目視調査との比較から、現地調査や検出処理での作業労力の負担低減効果（目標 50 ％低減）や調査結果の正確性（目標検出改善率 30 ％向上）等に関する検証を行う。

・試験項目等：実測調査、負担軽減効果・調査の正確性の検証

３．研究成果

１）外壁の撮影条件・撮影方法の検討・構築（R5～R6 年度）

・AI を用いた外壁劣化検出の必要条件として、検出実験の結果から「画像分解能：0.8±0.2 mm/px」を定めた。また、カメラ性能毎に外壁の撮影範囲を事前設定することで、現場では煩雑な撮影距離やレンズ焦点距離の調整なく、検出条件である画像分解能を簡単に得られる撮影方法を提示した。

・塗り仕上げ外壁の RC 造建築物を対象に、地上カメラ及びドローンによる外壁の撮影手順や留意事項を検討した。得られた知見は、一般技術者が活用できる外壁撮影マニュアルとして取りまとめた。

２）外壁劣化検出 AI の構築（R5～R7 年度）

・調査時の外壁撮影画像を活用し、主に検出精度の低かった劣化（欠損等）の教師データセットを追加作成（約 32,000 セット新規作成）し、これらを用いた劣化検出 AI の学習を実施した。

・ニューラルネットワーク選定や学習時パラメータの最適化により検出精度の向上を図った結果、開発した AI が塗り仕上げ外壁の劣化検出において目標の検出精度（F 値 ≧0.8）を満たすことを確認した。

３）調査・診断支援ソフトウェアの開発（R6～R7 年度）

・見上げ撮影で生じる画像のあおり変形等を正対化補正するプログラムや、分割撮影された外壁画像を従来調査での図面記録と同等の全体画像に自動結合するプログラムを開発した。

・開発した AI による劣化検出結果から、各劣化数量（ひび割れ長さ・幅、欠損や塗装はがれ等の面積、発生数等）を自動計数できるプログラムを作成した。また、検出結果のマニュアル編集機能（検出見逃し箇所の追記や誤検出箇所の削除等）や図面・数量表等での出力プログラムを構築した。

・２）で開発した外壁劣化検出 AI と上記の各種処理プログラムを機能統合するとともに、ユーザーインターフェースを備えた、調査・診断支援ソフトウェアを開発した。

４）調査・診断支援技術の有効性の検証（R7 年度）

・道内の実建物外壁を対象に、劣化検出精度、調査作業に要する時間及び調査費用について、従来手法の目視調査と開発手法で比較した。その結果、従来手法と比較して開発手法の劣化検出改善率は目標値を上回る結果（約 67 ％）が得られた。また、開発手法が、現地調査と机上作業を合わせた所要時間を約 87 ％低減、調査費用を約 84 ％低減できることを示し、負担低減効果の目標を達成した。

４．今後の見通し

・RC 造建築物外壁の劣化状況の把握、改修や建替の優先順位判断、改修工事費用の概算見積等での調査において、自治体や民間の一般技術者が活用可能な支援技術として、共同研究機関を通じて公開する。

・今後は、一般の調査技術者に向けた AI による画像検出に適した撮影方法や調査支援ソフトウェアの操作方法等に関する技術研修の開催、調査現場における実地訓練等の技術支援を実施し、開発した調査支援技術の円滑な普及を進める。

目　次

１．研究の背景・目的……1
１．１　背景……1
１．２　目的……1
１．３　本報の構成……1

２．AI 劣化検出に適した外壁の撮影条件・撮影方法の検討……2
２．１　撮影条件の検討……2
２．２　撮影方法の検討……4

３．外壁劣化検出 AI の構築……5
３．１　検出対象……5
３．２　画像セグメンテーション手法の概要……5
３．３　教師データセットの概要……6
３．４　学習用ニューラルネットワークの検討……7
３．５　ハイパーパラメータの最適化の検討……9
３．６　学習プロセスの概要……10

４．調査・診断支援ソフトウェアの開発……12
４．１　開発ソフトウェアのシステム構成……12
４．２　撮影画像の正対化補正機能……13
４．３　画像の自動結合機能……14
４．４　検出結果の編集機能……15
４．５　劣化定量値の計算方法……16
４．６　検出結果の出力機能……17

５．調査・診断支援技術の有効性の検証……18
５．１　調査対象の概要……18
５．２　検証内容……19
５．３　AI による外壁劣化検出結果……19
５．４　劣化検出精度の比較……20
５．５　作業時間及び調査費用の比較……22

６．まとめ……23

１．研究の背景・目的

１．１　背景

建築物の長寿命化および安全性確保の観点から、定期的な点検の実施と適切な調査に基づく計画的な維持管理の重要性が一層高まっている。特に、建築物は供用期間の経過とともに経年劣化が進行し、外壁表面には目視で確認可能な劣化現象として、ひび割れ、仕上げ材のはがれ、欠損等が発生する。このような外壁の劣化現象は、建築物の美観や機能維持に影響を及ぼすだけでなく、適切な対応がなされない場合には徐々に進行し、耐久性や安全性の低下、さらには外壁落下による第三者被害を引き起こすおそれがある。そのため、劣化の発生状況や進行度を的確に把握することは、適切な補修・改修時期の判断、保全計画の策定、維持管理コストの最適化を図る上で極めて重要な情報であり、外壁の劣化状態を継続的かつ客観的に把握するための調査の重要性はますます高まっている。

一方で、建築物外壁の点検・調査においては、発生している劣化の外観を観察して記録する必要があり、多大な労力と時間を要する作業となっている。加えて、従来の点検は調査者による目視確認に大きく依存しており、見落としや記録漏れといった人的ミスの発生や、調査者の技量や判定基準のばらつきによる調査結果の個人差が生じる可能性がある。そのため、調査結果の再現性や客観性の確保、作業効率の向上等が課題となっている。

このような状況を踏まえ、建築物外壁の点検・調査においては、作業の効率化と精度向上の両立を図ることのできる合理的な調査手法の確立が求められている。近年ではこうした課題に対応するため、デジタル技術や AI（人工知能）を活用し、画像情報からひび割れ等の劣化箇所を自動的に検出する技術開発が進められており、点検・調査の省力化及び高度化へ期待が高まっている。

しかしながら、これまでの適用事例の多くはコンクリート打放し仕上げを主とする土木構造物を対象としたものであり、仕上げ材の種類が多岐にわたり、かつ劣化形態も多様である建築物外壁への適用には、依然として技術的な課題が残されている。特に、仕上げ材ごとの外観特性の違いや汚れ・陰影等の影響を受けやすい環境下において、安定的かつ高精度に劣化を検出するための技術は十分に確立されているとは言い難いのが現状である。

１．２　目的

本研究では、RC 造建築物の外壁調査・診断等において、調査の合理化や正確性向上を図るため、AI を活用した調査・診断等の支援技術を開発することを目的とする。

１．３　本報の構成

本研究は、外壁劣化を検出する画像認識 AI の構築、これを実装した調査支援ソフトウェアの開発、並びに実建物への適用による妥当性検証で構成される。以下に、次章以降の各章の内容を示す。

第２章では、本研究で開発する画像認識 AI を用いて RC 造建築物外壁の劣化検出を行うにあたり、必要となる撮影条件及び撮影方法について記述する。

第３章では、建物調査で取得した外壁劣化の撮影画像を活用して作成した、AI 学習用の教師データセットの概要を示し、これらを用いて構築した外壁劣化検出 AI について記述する。

第４章では、本研究で開発した RC 造建築物外壁の調査支援ソフトウェアについて記述する。調査実務で必要となる画像結合機能や正対化補正機能等、各種機能を実現するためのプログラム開発の内容を示し、これら機能と第３章で構築した AI を搭載した調査支援ソフトウェアの概要を示す。

第５章では、第２章から第４章までの検討内容を踏まえ、実建物の塗り仕上げ外壁を対象に、開発手法を用いた劣化検出を試行する。従来手法である目視調査による検出結果と、開発手法による検出結果を比較し、本手法の有効性について検証する。

第６章では、各章で示した本研究の成果をまとめ、本研究で開発した技術の今後の活用策や普及に向けた展望について記述する。

２．AI 劣化検出に適した外壁の撮影条件・撮影方法の検討

AI による外壁劣化検出を実務で活用するためには、検出精度を確保できる撮影条件を明らかにし、現場調査において煩雑な作業を要せずに条件を満たすことが可能な撮影方法を確立することが必要である。そこで本研究では、AI による劣化検出に必要な撮影条件及びこれを踏まえた調査現場での外壁撮影方法について検討を行った。

撮影条件の検討として、撮影画像の画像分解能に着目し、AI による劣化検出精度への影響を検討した。模擬的にひび割れを生じさせた試験体を用いて、画像分解能を変化させた撮影と AI 検出を行い、試験体のひび割れの検出可否から、検出に必要となる画像分解能の閾値を明らかにした。

また、明らかとなった画像分解能の条件を踏まえ、現場調査における作業負担をできるだけ低減した上で、当該条件を満たすことのできる外壁撮影方法について検討した。

２．１　撮影条件の検討

（１）試験体の撮影方法

図 2.1 に、AI による劣化検出に必要な撮影条件を検討するための試験体の撮影方法を示す。試験体は北方建築総合研究所庁舎のバルコニー部に設置し、撮影を行った。設置高さは 2 階～4 階の 3 ケース、庁舎外壁とカメラ間の水平方向の撮影距離は 5 m と 10m の 2 ケースを設定した。一般的な撮影機材を想定して、デジタル一眼レフカメラとコンパクトデジタルカメラを使用した。試験体の撮影条件と撮影機材の概要を表 2.1 に示す。

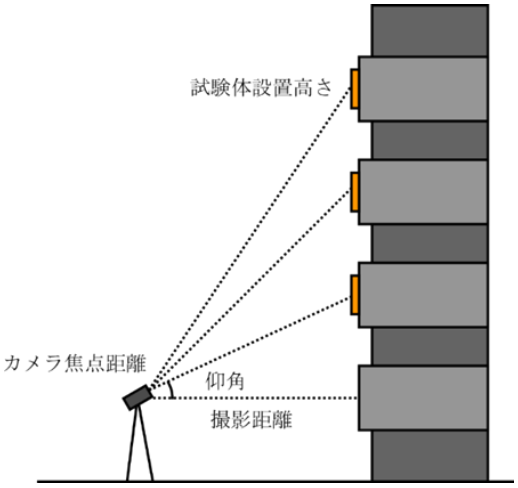


図 2.1　試験体の撮影方法

表 2.1　モデル試験体の撮影条件と撮影機材の概要

項目名	数値等
撮影距離	5 m, 9 m, 13 m
撮影機材	Nikon D7100（デジタル一眼レフカメラ） Nikon CoolPix W300（コンパクトデジタルカメラ）
センササイズ	APS-C サイズ（デジタル一眼レフカメラ） 1/2.3 型サイズ（コンパクトデジタルカメラ）
焦点距離	18～105 mm（デジタル一眼レフカメラ） 18～70 mm（コンパクトデジタルカメラ）
記録画素数	6,000×4,000 pixel（デジタル一眼レフカメラ） 4,608×3,456 pixel（コンパクトデジタルカメラ）

（２）試験体の概要

試験体は、厚さ 20 mm、縦・横 400 mm のビーズ法ポリスチレンフォーム（EPS）ボードを基材とし、その表面にモルタルを塗付して作製した（図 2.2）。試験体中央部に人為的にひび割れを生じさせ、幅 0.1～1.0 mm の範囲で 6 水準の模擬ひび割れを有する試験体を作製した。

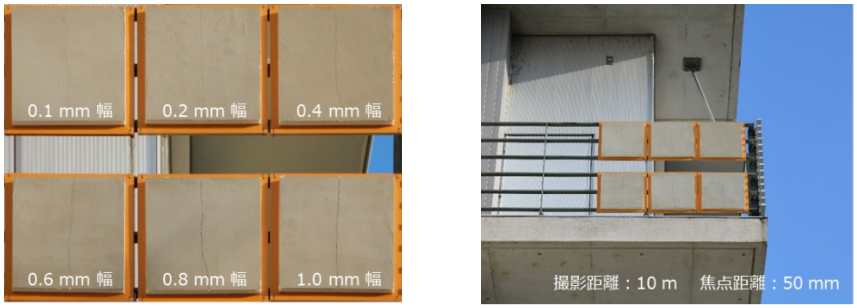


図 2.2　ひび割れ模擬試験体の概要

（３）AI 劣化検出に必要な撮影条件

AI を用いた劣化検出に必要な条件を検討するにあたり、外壁劣化の中でも最も画像検出における難易度が高いと想定される、ひび割れの検出可否を設定基準とした。また、外壁のひび割れ補修では、一般に幅 0.2 mm 以上のひび割れが対象とされることを踏まえ、幅 0.2 mm のひび割れを AI で画像検出できることを最低条件とした。なお、本検討で使用する劣化検出 AI の詳細については次章で述べる。

表 2.2 及び表 2.3 に、カメラごとの AI による劣化検出可否について示す。また、表中には、その際の画像分解能を示している。ここで、画像分解能とは、撮影画像上の 1 画素（ピクセル）が、実空間上でどの程度の大きさに相当するかを表す指標であり、本研究では単位として「mm/px」を用いる。画像分解能の値が小さいほど、1 画素あたりが表す実寸法は小さくなり、より微細な対象物まで画像上で判別可能な、高分解能の画像であることを示す。逆に、画像分解能の値が大きい場合は、1 画素あたりが表す実寸法が大きくなり、微細な対象物の判別が困難な、低分解能の画像となる。

これらの結果より、幅 0.2 mm のひび割れを AI で検出可能な画像分解能は、実測値で 0.6～1.1 mm/px の範囲であることが分かった。既往の研究[1)]でも、デジタル画像上での対象物の判別に必要な画像分解能は、対象サイズの 3～5 倍程度が目安とされており、本検討で得られた結果と概ね整合している。

以上の結果を踏まえ、本研究では、撮影時のばらつきを考慮した上で、幅 0.2 mm のひび割れを AI で検出するために必要な画像分解能を「0.8±0.2 mm/px」と定めた。

表 2.2　検出結果と画像分解能の関係（デジタル一眼レフカメラ使用）

（a）撮影距離 5 m の場合

設置高さ	f = 18 mm	f = 35 mm	f = 50 mm
13 m	× : 3.0 mm/px	× : 1.6 mm/px	△ : 1.2 mm/px
9 m	× : 2.3 mm/px	△ : 1.2 mm/px	○ : 0.8 mm/px
5 m	△ : 1.5 mm/px	○ : 0.8 mm/px	○ : 0.6 mm/px

【○ : 0.2 mm 幅検出可，△ : 一部検出可，× : 検出不可】

（b）撮影距離 10 m の場合

設置高さ	f = 18 mm	f = 35 mm	f = 50 mm
13 m	× : 3.6 mm/px	× : 1.9 mm/px	△ : 1.3 mm/px
9 m	× : 2.9 mm/px	△ : 1.5 mm/px	○ : 1.1 mm/px
5 m	△ : 2.5 mm/px	○ : 1.3 mm/px	○ : 0.8 mm/px

【○ : 0.2 mm 幅検出可，△ : 一部検出可，× : 検出不可】

表 2.3　検出結果と画像分解能の関係（コンパクトデジタルカメラ使用）

（a）撮影距離 5 m の場合

設置高さ	f = 24 mm	f = 35 mm	f = 70 mm
13 m	× : 4.4 mm/px	× : 3.0 mm/px	△ : 1.4 mm/px
9 m	× : 3.2 mm/px	△ : 2.2 mm/px	○ : 1.1 mm/px
5 m	△ : 2.3 mm/px	△ : 1.6 mm/px	○ : 0.7 mm/px

【○ : 0.2 mm 幅検出可，△ : 一部検出可，× : 検出不可】

（b）撮影距離 10 m の場合

設置高さ	f = 24 mm	f = 35 mm	f = 70 mm
13 m	× : 5.2 mm/px	× : 3.6 mm/px	△ : 1.7 mm/px
9 m	× : 4.2 mm/px	△ : 2.9 mm/px	○ : 1.3 mm/px
5 m	× : 3.5 mm/px	△ : 2.4 mm/px	○ : 1.1 mm/px

【○ : 0.2 mm 幅検出可，△ : 一部検出可，× : 検出不可】

２．２　撮影方法の検討

前節までの検討に基づき、検出条件とする画像分解能「0.8 mm/px」を満足するための撮影方法について検討する。

撮影画像の画像分解能を決定する要因としては、以下の 4 項目が挙げられる。

（a）センササイズ

（b）記録画素数（※使用カメラの最大設定とする）

（c）レンズ焦点距離

（d）撮影距離

このうち、（a）センササイズ及び（b）記録画素数は撮影機材に固有の値であり、機材を選定した時点で値が定まる。一方、（c）レンズ焦点距離及び（d）撮影距離は、調査現場の状況に応じて変化する値である。例えば、外壁とカメラ間の撮影距離が長くなる場合には、焦点距離を望遠側に設定するなど、撮影者が現場の状況に応じて適切な値を設定する必要がある。

しかしながら、実際の現場調査においては、撮影機材によっては（c）レンズ焦点距離の値を撮影時に容易に確認できず、必要な画像分解能を満足するための設定が困難となるケースも想定される。そのため、撮影者による煩雑な設定を要することなく、検出条件である画像分解能を満足した撮影をできるだけ簡便に行うことができる撮影方法が望ましい。

そこで本研究では、（c）レンズ焦点距離や（d）撮影距離を個別に設定するのではなく、以下の考え方によりあらかじめ外壁の撮影範囲を計算し、現場ではこの範囲が撮影できるようカメラ位置や焦点距離を調整するのみとする撮影方法を提案する。

【撮影範囲の計算の考え方】

① 撮影条件（画像分解能）: 0.8 (mm/pixel)

② 記録画素数：（幅）X (pixel) ×（高さ）Y (pixel)　※使用するカメラ性能により異なる

③ ①×② 撮影範囲：（幅）0.8 * X (mm) ×（高さ）0.8 * Y (mm)

この方法の利点は、調査者が撮影範囲の設定にのみ注力すればよく、現場で（c）レンズ焦点距離や（d）撮影距離を個別に意識した設定や画像分解能の計算を行う必要がない点にある。これにより、検出条件を満たした画像を簡便に取得できるとともに、現場での作業負担やミスの低減に寄与する。

図 2.3 に、撮影範囲の具体例を示す。使用例としたカメラ（APS-C サイズセンサ、記録画素数：幅 6,000 pixel×高さ 4,000 pixel）の場合、幅 4,800 mm（4.8 m）、高さ 3,200 mm（3.2 m）の範囲が画像内に収まるように撮影することで、検出条件とする画像分解能を満たした撮影が可能となる。

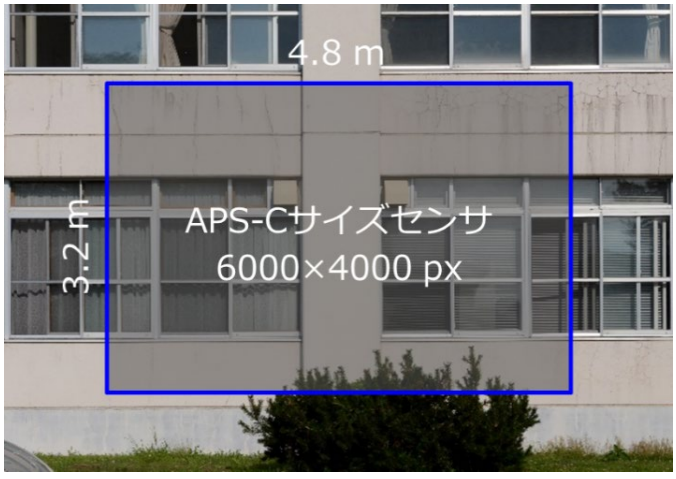


図 2.3　撮影条件を満たす撮影範囲の具体例

３．外壁劣化検出 AI の構築

３．１　検出対象

表 3.1 に、本研究で開発する AI の検出対象とした外壁仕上げ及び劣化等を示す。対象の外壁仕上げは、表中に示す塗り仕上げ（リシン吹付、マスチック塗装、弾性タイル）を主とし、基礎部等の塗装のない箇所も対象とするため、コンクリート打放し仕上げについても検出の対象としている。

対象とする劣化は、経年により外壁に生じる、ひび割れ、欠損、鉄筋露出、塗装はがれの４種類とした。これらは、外壁の美観を損なうだけでなく、放置すると内部鉄筋の腐食進行や構造躯体の耐久性の低下につながるおそれがあり、点検・改修の優先度を判断する上で重要な劣化事象である。

また、AI による誤検出を低減することを目的として、主にひび割れと類似した形状を持つ事象（外壁目地、水跡・汚れ、植栽）も併せて検出対象に設定した。これにより、劣化として誤って推定されやすい事象の学習データを含めることで、検出精度の向上を図っている。

表 3.1　検出対象とする外壁仕上げ及び劣化等

外壁仕上げ
・塗り仕上げ（リシン吹付／マスチック塗装／弾性タイル） ・コンクリート打放し仕上げ
外壁劣化
・ひび割れ ・欠損 ・鉄筋露出 ・塗装はがれ
劣化以外（誤検出回避のため）
・外壁目地 ・水跡／汚れ ・植栽

３．２　画像セグメンテーション手法の概要

本研究では、外壁の劣化検出が可能な AI を構築するにあたり、画像中の物体分類手法の一種であるセマンティックセグメンテーションを用いる。この手法は、デジタル画像を構成する画素単位にラベルやカテゴリを関連付けて分類を行う機械学習アルゴリズムの一つであり、画素単位での物体認識が可能である。

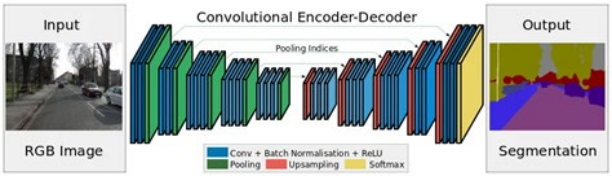
図 3.1 にセマンティックセグメンテーションに代表的な学習用ニューラルネットワークを示す。これらはいずれも Encoder-Decoder 型の完全畳み込みネットワーク（FCN：Fully Convolutional Network）に分類される機械学習アルゴリズムであり、入力画像と同サイズの画像として検出結果を出力できるため、処理前後で位置情報の一貫性が保持されるという特徴を持つ。

SegNet [2]は、Encoder 側で得たプーリング位置の情報を Decoder 側の復元処理に利用することで、復元時の境界形状を保持しやすい構造となっている。

U-Net [3]は、Encoder 各層の特徴マップを Decoder 側の対応する層へ直接連結するスキップ接続を持っており、少ないデータ数でも高精度な学習が可能とされる。

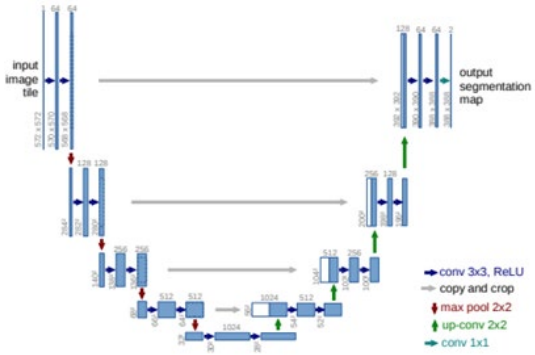
DeepLab v3+ [4]は、より広い受容野を確保しながら解像度の低下を抑える Atrous Spatial Pyramid Pooling と呼ばれる手法を採用しており、多様なスケールの対象物に対応しやすい構造を持つ。

これらのネットワークは、画素単位で意味付けされた検出結果が得られること、また一枚の画像から複数箇所・複数種類の対象物を同時に検出できることなど、共通した特徴を有している。



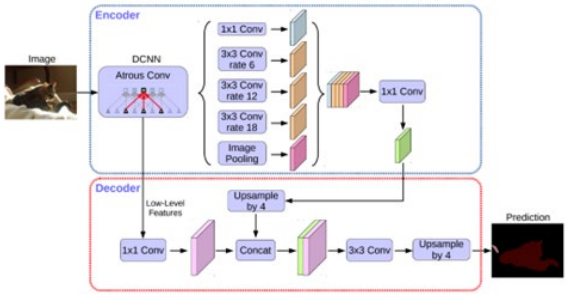
※文献 2)より転載

（a） SegNet



※文献 3)より転載

（b） U-Net



※文献 4)より転載

（c） DeepLab v3+

図 3.1　学習用ニューラルネットワーク（セマンティックセグメンテーション）

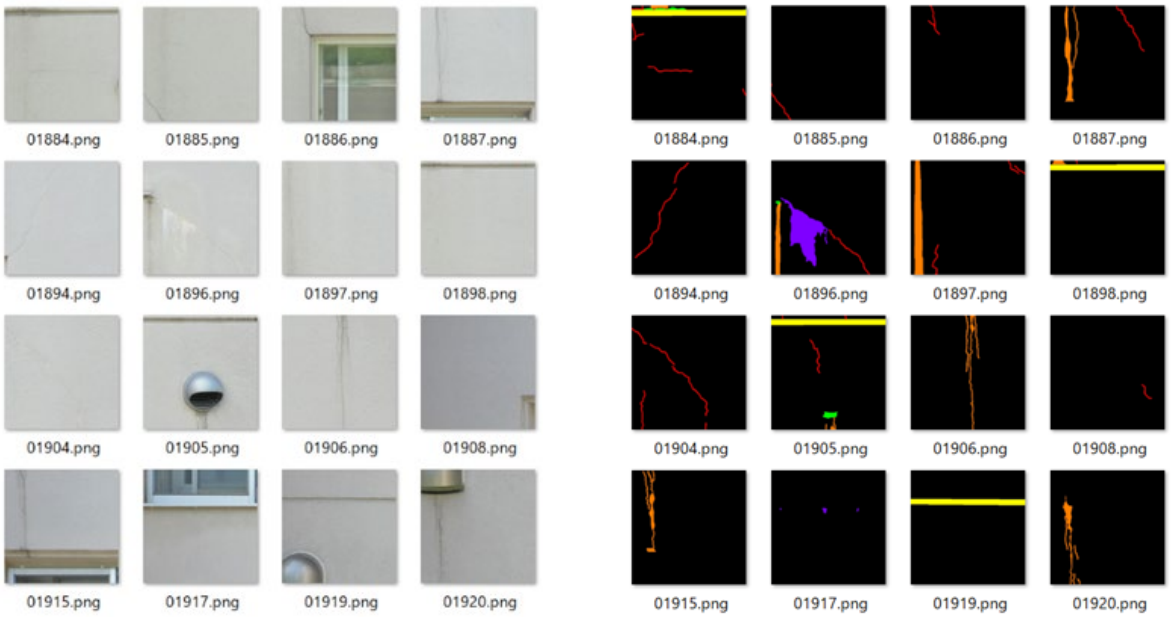
３．３　教師データセットの概要

セマンティックセグメンテーションによる画像分類 AI を構築するためには、検出対象の特徴量を学習により分析・抽出するための教師データセットが必要となる。教師データセットは、検出対象を学習するための例題となる原画像と、原画像における検出対象の種類及び位置の正解を示したラベル画像を一対として整備したデータ群である。表 3.2 に、作成した教師データセットの概要を示す。

ラベル画像は原画像に対して、検出対象とする劣化等の種類ごとに定めた色情報（RGB 値）を用いて、画素単位で分類情報（何が写っているか）と位置情報（どこに写っているか）を付与する作業（アノテーション）を行うことで作成した。図 3.2 中に示すように、原画像中でひび割れ等の劣化が生じている検出対象の画素には対応する色情報を、検出対象以外の画素には黒色を割り当てることで、画素単位で意味付けされたラベル画像を作成している。

表 3.2　教師データセットの概要

項目名	数値等
教師データ解像度	448×448 pixel
学習用データセット数（80 %）	33,480 セット
評価用データセット数（学習時）（10 %）	4,185 セット
評価用データセット数（学習後）（10 %）	4,185 セット
画像ビット深さ	24bit（RGB カラー）
画像保存形式	PNG



（a）原画像　　（b）ラベル画像

図 3.2　教師データセットの例

３．４　学習用ニューラルネットワークの検討

本研究では、外壁劣化検出 AI の構築にあたり、3.1 節で示した SegNet、U-Net、DeepLab v3+の 3 種類のニューラルネットワークを用いて同一の教師データセットによる学習をそれぞれ試行し、検出性能の比較検討を行った。比較にあたっては、学習精度に加え、学習過程における損失関数の収束速度についても評価対象とした。

表 3.3 に、各ニューラルネットワークによる試行結果を示す。前節で構築した教師データセットを用い、いずれの試行も学習回数を 10 エポックとして実施した。試行の結果、DeepLab v3+はその構造上の特性から、ひび割れのような線状かつ微細な対象と欠損のような広範囲に及ぶ対象とが混在する本研究における検出対象において、他の 2 手法と比較して最も高い検出精度を示した。また、学習損失についても、学習精度の高いネットワークほど低い値を示す傾向が確認された。一方、学習の収束速度については、いずれのネットワークを用いた場合もほぼ同様の結果であった。

図 3.3 に、各ニューラルネットワークで学習したモデルによる外壁劣化の検出例を示す。いずれのモデルにおいても劣化等の検出は可能であったが、このうち、誤検出及び見逃しが最も少なかったのは DeepLab v3+を用いた学習モデルであった。

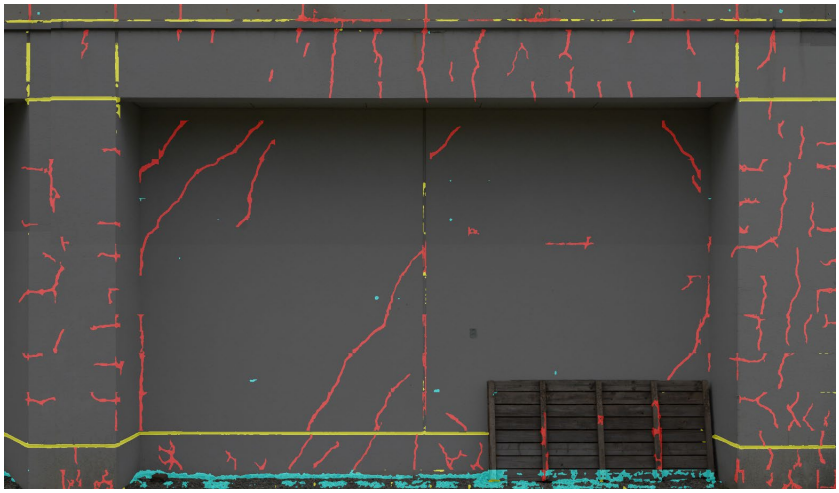
ここまでの検討の結果、本研究で対象とする外壁劣化等の画像検出においては、学習用のニューラルネットワークに DeepLab v3+を用いることで、最も高い性能を持つ学習モデルを構築できることが明らかとなった。このため、以降で展開する外壁劣化検出 AI の構築においては、ニューラルネットワークとして DeepLab v3+を採用して検討を進める。

表 3.3　各ニューラルネットワークの学習モデルにおける試行結果

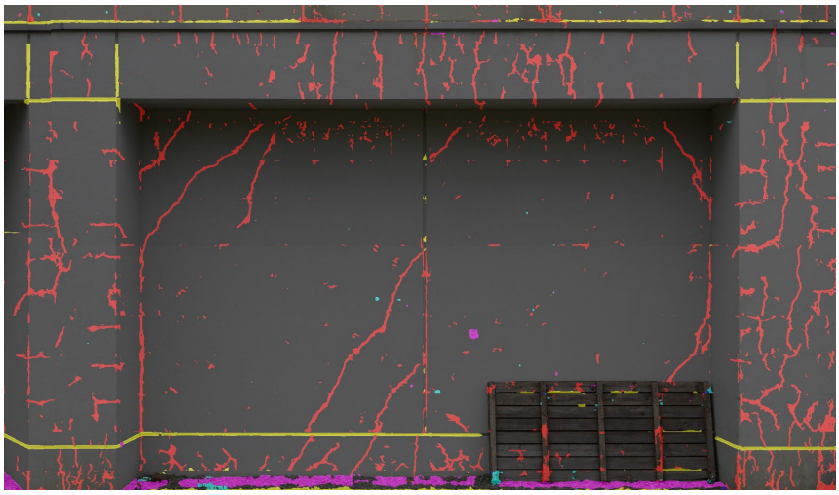
	学習用ニューラルネットワーク		
	SegNet	U-Net	DeepLab v3+
学習精度（%）	82.8297	77.7995	85.0620
学習損失	0.2712	0.3300	0.1481
学習時間	1 時間 8 分 34 秒	1 時間 1 分 27 秒	1 時間 2 分 30 秒

【検出対象凡例】

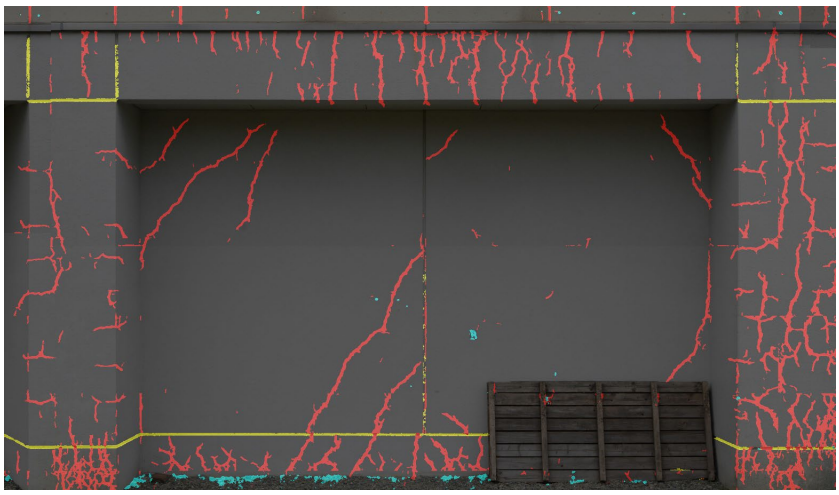
■：ひび割れ　■：欠損　■：鉄筋露出　■：塗装はがれ　■：外壁目地



（a）SegNet



（b）U-Net



（c）DeepLab v3+

図 3.3　各ニューラルネットワークの学習モデルを用いた外壁劣化の検出例

３.５　ハイパーパラメータの最適化の検討

ニューラルネットワークを用いた機械学習では、学習モデルの構造（重み等のパラメータ）は教師データから自動的に決定されるのに対し、学習の進め方を制御する設定値は、学習を開始する前に人間があらかじめ定める必要がある。この設定値をハイパーパラメータと呼び、代表的なものとして、学習させるデータ数を示すバッチサイズ、パラメータの更新幅を制御する学習率、学習データ全体を何回繰り返し学習させるかを示すエポック数等がある。

ハイパーパラメータは、その設定値により学習の収束速度や、最終的に得られる学習済みモデルの検出精度を大きく左右することが知られている。例えば、学習率を過大に設定した場合、学習は速く進行する一方でパラメータの更新が過剰となるために精度が安定しない（適切な解に収束しない）といった問題が生じやすくなる。逆に、学習率を過小に設定した場合には、学習は安定して進行するものの、収束までに多くの学習回数を要し、限られた学習回数の中では十分な精度に到達できないおそれがある。このように、ハイパーパラメータには一般的に唯一絶対の最適値は存在せず、対象とするデータや検出対象の特性に応じて適切な値を見出す必要がある。

そこで本研究では、作成した教師データセットを用い、前節の検討で採用した DeepLab v3+を採用した場合に検出精度を最大化するハイパーパラメータの組み合わせを見出すことを目的として、スイープ解析[注1]による最適化を行った（図 3.4）。最適化の対象としたハイパーパラメータと各パラメータのスイープ解析における探索範囲等を表 3.4 に示す。本手法を用いることで、客観的な根拠に基づいた、AI 学習のパフォーマンスを最大化できるハイパーパラメータの組み合わせを設定した。

注１：着目する複数のハイパーパラメータについて、それぞれ一定の範囲内で値を系統的に変化させながら学習を繰り返し実施し、各組み合わせにおける学習結果（検出精度や学習損失等）を比較することで、最も良好な結果が得られる組み合わせを探索する手法。

実験の詳細					メトリクス	
試行	ステータス	アクション	進行状況	経過時間	学習精度 (%)	学習損失
1	完了 (最大エポック数が完了)		100.0%	2 時間 15 分 55 秒	82.2285	0.7269
2	完了 (最大エポック数が完了)		100.0%	2 時間 18 分 27 秒	63.1920	1.7192
3	完了 (最大エポック数が完了)		100.0%	2 時間 13 分 25 秒	73.0544	2.1579
4	完了 (最大エポック数が完了)		100.0%	2 時間 15 分 8 秒	58.6732	2.1234
5	完了 (最大エポック数が完了)		100.0%	1 時間 31 分 12 秒	85.4483	0.5402
6	完了 (最大エポック数が完了)		100.0%	1 時間 32 分 26 秒	81.9459	0.4451
7	完了 (最大エポック数が完了)		100.0%	1 時間 29 分 34 秒	63.5123	1.0965
8	完了 (最大エポック数が完了)		100.0%	1 時間 30 分 47 秒	35.3052	1.7674
9	完了 (最大エポック数が完了)		100.0%	1 時間 13 分 40 秒	86.8191	0.3323
10	完了 (最大エポック数が完了)		100.0%	1 時間 13 分 26 秒	81.1215	0.5919
11	完了 (最大エポック数が完了)		100.0%	1 時間 12 分 36 秒	76.5504	0.7610
12	完了 (最大エポック数が完了)		100.0%	1 時間 13 分 4 秒	71.3671	1.1206
13	完了 (最大エポック数が完了)		100.0%	7 時間 31 分 39 秒	84.1934	0.3268
14	完了 (最大エポック数が完了)		100.0%	7 時間 20 分 12 秒	81.0685	0.3969
15	完了 (最大エポック数が完了)		100.0%	7 時間 22 分 28 秒	60.8374	0.9017
16	完了 (最大エポック数が完了)		100.0%	7 時間 32 分 21 秒	68.0070	1.3521

図 3.4　スイープ解析による最適パラメータの組み合わせ探索の例

表 3.4　最適化検討の対象としたハイパーパラメータ

パラメータ	設定範囲	備考
学習用ソルバー	SGDM／ADAM	学習時の収束演算方法
最大エポック数	任意	学習の繰り返し回数
ミニバッチサイズ	1～64	小：低負荷・低速／大：高負荷・高速
初期学習率	0.001～0.1	小：安定・低速／大：不安定・高速
学習率の低下率	0.5～0.9	学習初期：高／学習終期：低
モーメンタム	0～1	更新ステップの前回寄与度

３．６　学習プロセスの概要

表 3.5 に、AI の学習時において、学習アルゴリズムの挙動を制御する条件として設定した項目を示す。これらの設定値は、前節で述べたスイープ解析により学習プロセスを繰り返し試行し、過学習が生じずに、かつ検出精度の向上が確認できた組み合わせを採用した。作成した教師データセットを用いた学習を行った結果、検証用データによる検出精度が 95%程度に収束することを確認した（図 3.5）。

また、学習時には、同一の教師データセットを繰り返し入力することで過学習が生じやすくなること、及び未知の画像に対する検出の汎用性が頭打ちになりやすいことが課題として挙げられる。そこで本研究では、学習時にデータ拡張を併せて実施した。データ拡張では、教師データセットの入力時に、表 3.6 に示す範囲内で「水平・鉛直方向への平行移動」、「画像中心を基準とした回転」、及び「画像の拡大・縮小」の画像処理を、ランダムかつ複合的に加えることで、見かけ上の学習データを毎回異なる画像として生成する。この処理により、限られた枚数の教師データセットであっても、多様な条件下での画像を学習に用いたことと同等の効果が得られ、データセットの量的な制約を補いつつ、学習モデルの汎用性を高めることができる。

表 3.5　学習時の設定条件

パラメータ	設定値
ニューラルネットワーク	DeepLab v3+
事前学習済モデル	ResNet-50
学習用ソルバー	SGDM
最大エポック数	500
ミニバッチサイズ	8
初期学習率	1.0×10^{-2}
学習率の低下係数	0.9（100 エポック毎）
モーメンタム	0.9

表 3.6　データ拡張の概要

パラメータ	設定値
移動量（水平・鉛直）	-10 pixel ~ +10 pixel
回転量	-10° ~ +10°
拡大・縮小量	0.8 倍 ~ 1.25 倍

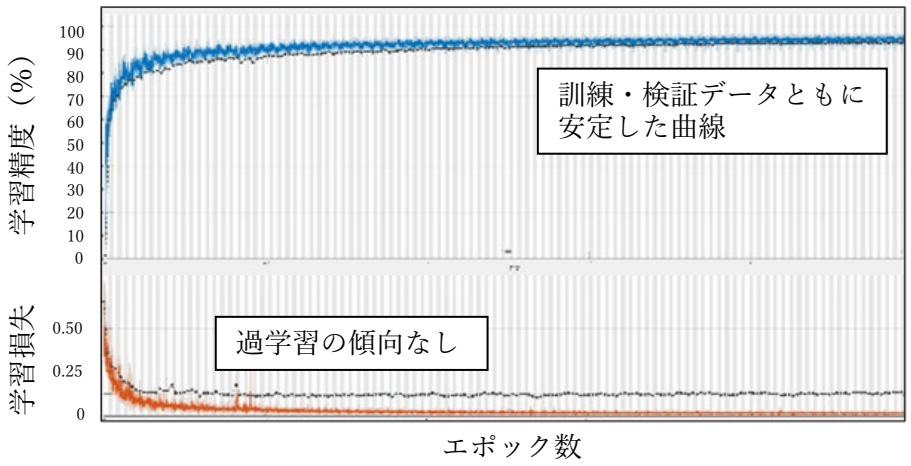
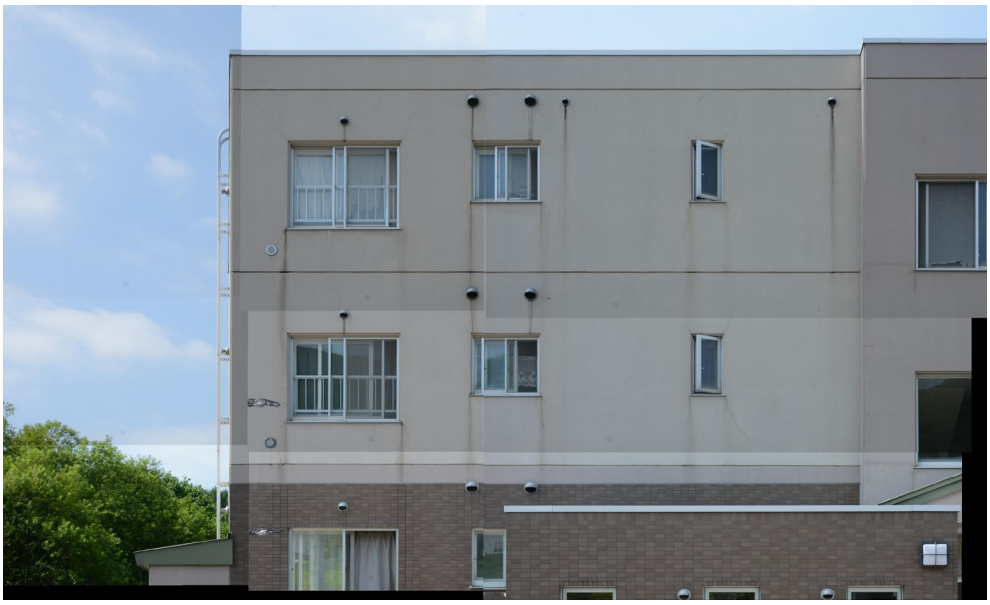


図 3.5　学習曲線の例

本研究で開発した画像認識 AI は、外壁撮影画像を入力とし、外壁の劣化及びその他の対象物をピクセル単位での自動検出が可能である。図 3.6 に開発 AI による外壁劣化等の検出例を示す。検出手法としてセマンティックセグメンテーションを用い、学習用ニューラルネットワークに DeepLab v3+を採用したことにより、線状かつ微細な検出対象であるひび割れから、エフロレッセンスや水跡等に代表される広範囲に及ぶ面状の検出対象まで、多様なスケールの対象に対して高い認識精度を発揮できる。

図に示すように、開発 AI による検出結果は対象ごとに予め定めた色情報（RGB 値）を用いて、該当する画素領域を着色表示して出力される。これにより、検出結果を撮影画像上に重畳表示した際、劣化等の発生箇所や範囲を視覚的に把握できる。また、撮影画像から劣化等の発生位置及び範囲をピクセル単位で自動抽出できるため、従来は、現場で目視確認していた外壁劣化の検出や手作業で行っていた劣化状況図面の作成・劣化数量のカウントといった人的労力のかかる作業を大幅に効率化できる。



（a）撮影画像



（b）検出結果

図 3.6　開発 AI による外壁劣化等の検出例

４．調査・診断支援ソフトウェアの開発

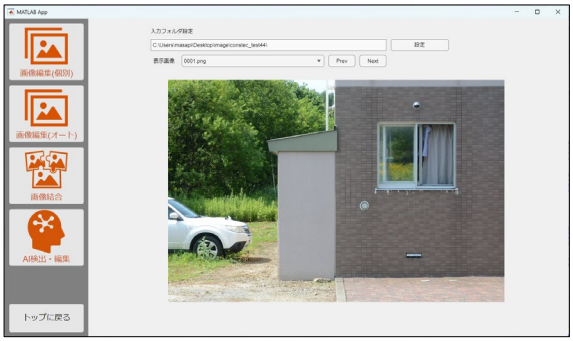
４．１　開発ソフトウェアのシステム構成

本研究で開発した外壁調査支援ソフトウェアは、調査実務で求められる成果物の出力ができるよう、①画像の正対化補正機能、②画像の結合機能、及び③AI による外壁劣化検出・編集・出力機能等を統合し、一つのソフトウェアとして操作できるシステム構成とした（図 4.1）。

本ソフトウェアの特徴として、撮影画像の入力から、正対化補正・画像結合といった前処理、AI による検出処理、検出結果の編集、そして各種形式での出力処理に至る一連の作業を、他のソフトウェアを併用することなく、本ソフトウェア単体でシームレスに完結できる点が挙げられる。これにより、複数のソフトウェアを使い分けることに伴う作業の煩雑さやデータ変換の手間を排除し、調査・診断業務における効率化が図られる。

また、図に示すように、本ソフトウェアは外壁調査の実務経験が浅い技術者であっても処理操作に迷うことのないよう、各モードへの遷移や操作手順が直感的に理解できる UI デザインを採用している。これにより、AI やソフトウェア操作に関する専門的な知識を有しない技術者であっても、円滑に調査業務へ活用できるよう配慮している。

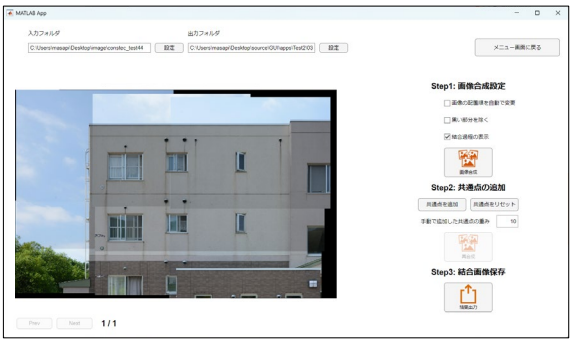
さらに、本ソフトウェアは、GPU 等の特殊な演算機器を必要とせず、一般に普及している性能のパーソナルコンピュータで十分に動作可能な仕様としている。これにより、専用機器の導入に伴う追加コストを抑えつつ、調査を行う自治体や民間事業者等が、本ソフトウェアを容易に導入・活用できる環境を実現している。



（a）メインコンソール



（b）正対化補正モード



（c）画像結合モード



（d）AI 検出・編集・出力モード

図 4.1　外壁調査支援ソフトウェアのシステム構成

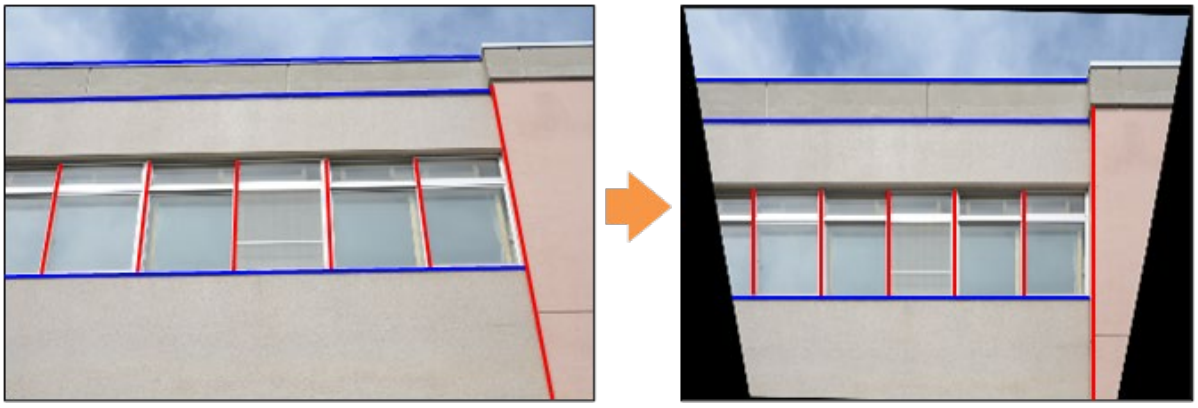
４．２　撮影画像の正対化補正機能

撮影時のカメラ位置や光軸の制約から、外壁面に対して正対した状態で撮影することが困難な場合が多い。特に地上撮影の場合、カメラの光軸が外壁面の法線方向からずれた状態で撮影されるため、画像には遠近感に起因する歪み（あおり）が生じ、外壁面内で本来等しい長さや角度が画像上では不均一に表現される。このような画像を劣化検出や外壁立面図との照合に用いた場合、劣化位置や範囲の把握に誤差が生じるおそれがある。

そこで本研究では、撮影画像を外壁面に正対した状態の画像へ補正する、正対化補正機能（射影変換）を構築した（図 4.2）。本機能では、まず画像中に含まれる直線成分を抽出する。対象とする直線成分は、外壁目地や窓サッシ等、外壁面上で本来直線かつ規則的に配置されている部材をターゲットとする。これらのターゲットを Hough 変換 [5]等の画像処理手法を用いて自動検出する、あるいは対象が不明瞭な場合を想定してマニュアル指定する方法のいずれかをユーザーが選択できる。

抽出した直線群は、鉛直方向に延びる成分と水平方向に延びる成分とに分類し、それぞれの交点から鉛直方向の消失点及び水平線を推定する。撮影画像には、カメラのあおりや傾きに応じて本来は平行であるはずの直線群が収束して見える現象（パースの歪み）が生じるが、この収束点である消失点の位置情報を利用することで、画像がどの方向に、どの程度歪んでいるかを幾何学的に計算できる。推定した消失点及び水平線の情報を基に、画像全体に射影変換を適用し、外壁面を正対視した状態、すなわち外壁面内の直線・直角関係が画像上でも正しく再現された状態へと補正する。この正対化補正により、画像上の位置と実際の外壁面上の位置との対応関係がより正確になり、劣化の発生位置や範囲を外壁立面図と精度良く対応付けることが可能となる。

■：鉛直方向の直線成分　　■：水平方向の直線成分



（a）正対化補正前　　（b）正対化補正後

図 4.2　画像の正対化補正（射影変換）機能

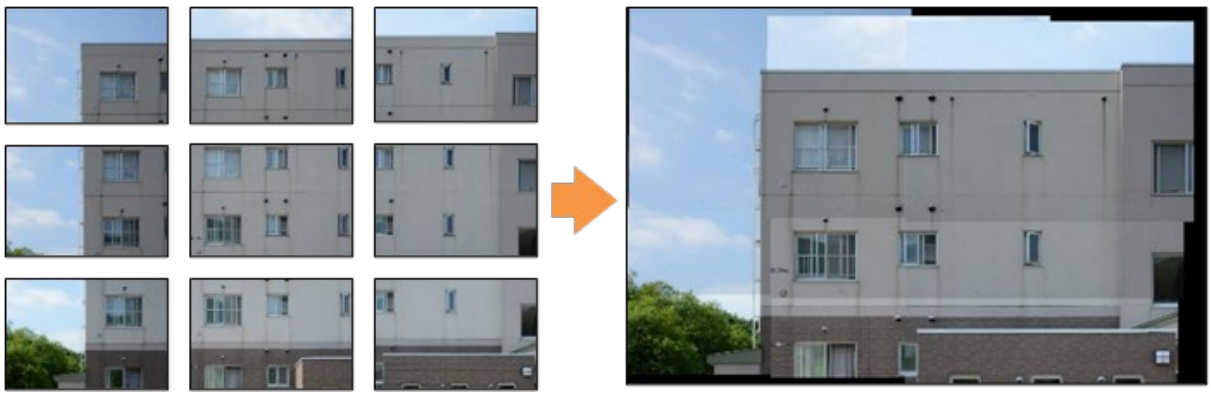
４．３　画像の自動結合機能

建築物外壁全面を撮影する場合、画像分解能を確保する観点から、一般には分割撮影が必要となる。一方、各種劣化の発生箇所や数量を把握するためには、分割撮影された画像と外壁立面図との位置関係を正確に対応付けることが重要であり、そのためには分割画像を一枚の連続した画像として集約できることが望ましい。そこで本研究では、分割撮影された複数の画像を位置合わせし、結合するための画像処理プログラムを構築した。

分割撮影された画像を結合するためには、まず隣接画像間の対応関係を求める必要がある。本手法では、SIFT（Scale-Invariant Feature Transform）[6] アルゴリズムを用いて各画像中の特徴点（キーポイント）を抽出し、その特徴量に基づいて隣接画像間のマッチングを行う。また、バンドル調整を導入することで撮影時の画角や距離の違いに起因する画像間の微小なずれや拡大率の差を補正し、複数画像の位置合わせを実現している。

図 4.3 に本手法を RC 造公営住宅の外壁撮影画像に適用した例を、表 4.1 に結合に用いた画像の概要を示す。撮影にあたっては、隣接する画像同士が水平・鉛直方向共に一定の撮影範囲をラップするよう設定しており、この条件下で良好な画像結合が可能であることを確認した。

なお、調査対象によっては、竣工図等の図面が現存しない場合や図面と現況が一致していない場合も少なくないが、本機能を用いることで、現況に即した外壁の全体画像を効率的に取得でき、図面再作成等に要する労力の削減にも寄与できるものと考えられる。



（a）分割画像　　（b）結合後画像

図 4.3　分割画像の自動結合機能

表 4.1　結合の検証に用いた画像の概要

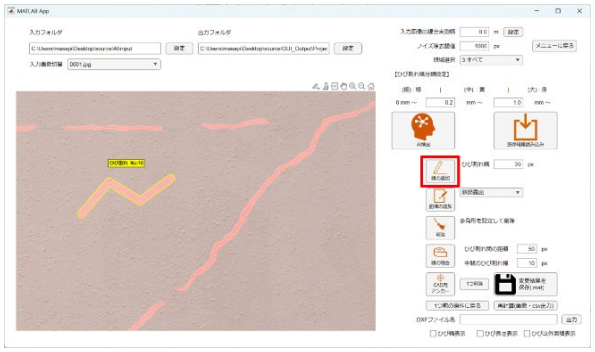
項目名	数値等
結合前画像サイズ	6,000×4,000 pixel
画像ビット深さ	24bit（RGB カラー）
画像保存形式	JPEG
処理画像枚数	9 枚
隣接画像間ラップ率（水平）	30 %
隣接画像間ラップ率（鉛直）	30 %
結合後画像サイズ	11,254×7,297 pixel

４．４　検出結果の編集機能

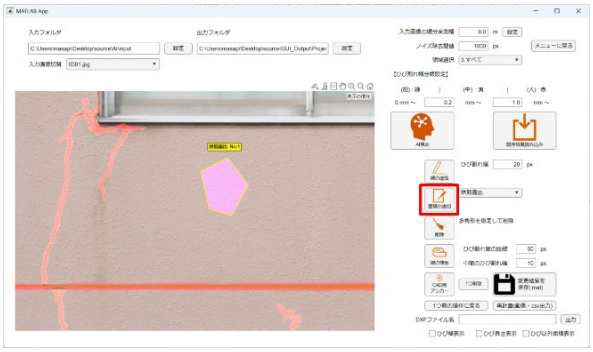
AI による画像認識では、その特性上、誤検出（劣化ではない箇所を劣化として検出する事象）や未検出（実際には存在する劣化を検出できない事象）が一定程度生じることは避けられない。そのため、AI による検出結果をそのまま調査結果として採用するのではなく、最終的に技術者の判断による確認や修正を経た上で、調査結果として確定させる必要がある。そこで、開発した調査支援ソフトウェアには、AI による検出結果に対して、技術者が任意に追記及び削除を行うことができる編集機能を実装した。本機能により、AI が検出できなかった劣化箇所を技術者が追記することで補完できるほか、誤検出箇所を任意に削除することができる。

編集の対象となる劣化等は、その形状特性に応じて、線状の劣化と面状の劣化とに大別される。線状劣化としてはひび割れが該当し、技術者は画像上でひび割れの経路を任意になぞることで、検出結果の追記を行うことができる（図 4.4（a））。一方、面状劣化としては、欠損、鉄筋露出、塗装はがれ及びエフロレッセンスが該当し、技術者は該当箇所の範囲を任意指定（塗りつぶし等）することで、検出結果の追記ができる（図 4.4（b））。いずれの場合も、既存の検出結果に対して、対象箇所を選択して削除が可能である（図 4.4（c））。

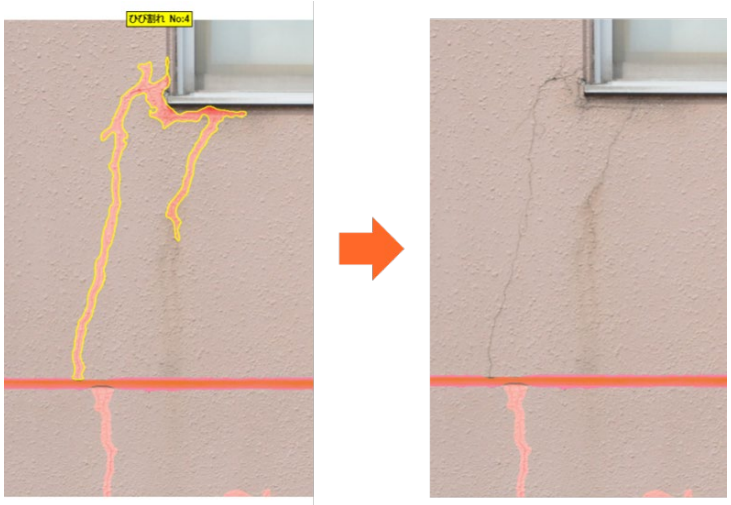
この編集機能により、AI による自動検出の効率性を活かしつつ、最終的な検出結果の信頼性を技術者判断で担保でき、AI と人間双方の強みを組み合わせることで、高い実用性が実現できる。



（a）線状劣化（ひび割れ）の追加



（b）面状劣化（鉄筋露出）の追加



（c）検出箇所の削除

図 4.4　検出結果の編集機能

４．５　劣化定量値の計算方法

開発した調査支援ソフトウェアは、AI による劣化検出結果に対し、長さや幅、面積といった定量値を算出する機能を有する。各劣化の定量値の算出方法を以下に示す。

（１）ひび割れの長さ

AI によるひび割れ検出領域に対して、画像処理により、その中心線に相当する骨格曲線を抽出し、この周長を求めた上で、その 1/2 の値として計算する。

（２）ひび割れの幅

検出ひび割れ箇所に対応する元画像の領域を抽出し、当該領域の輝度分布に基づき推定する。ひび割れは、健全な外壁表面と比較して通常暗部となり、輝度分布で谷型の低輝度領域となるため、この領域幅をひび割れ幅として算出する。なお、ひび割れ幅を精度良く推定するため、計算対象画素の周囲 8 画素の関係からひび割れの進展方向を求め、この方向と直交する断面の輝度分布から計算する。

（３）欠損・鉄筋露出・塗装はがれ・エフロレッセンスの面積

欠損、鉄筋露出、塗装はがれ、及びエフロレッセンスは、面的な広がりのある劣化であるため、AI による検出領域に含まれる画素数を計数し、これを面積として算出する。

（４）実寸法への変換

以上で求めた劣化の定量値は、いずれも画素を単位とした値のため、事前にソフトウェア上でユーザーが設定した画素と実寸法（mm 等）との変換係数を乗じることで、実際の定量値に変換する処理を行い、実寸法での数値を得ることができる。

４．６　検出結果の出力機能

本研究で開発した調査支援ソフトウェアでは、AI による劣化検出結果を複数の形式で出力できる機能を実装した。具体的には、①検出結果を可視化した画像データ、②検出結果を CAD データ化した図面データ、③各検出劣化の定量値をまとめた数量表データの 3 種類を出力可能としている。

① 検出結果の合成画像データ（JPG 形式等）

AI による検出結果を、正対化補正後の元画像と合成した画像データとして出力する機能である。検出結果は、劣化等の種類ごとに定めた色情報（RGB 値）に基づき、元画像上の該当箇所に半透明で重畳表示される。本形式は、報告書への掲載や現場担当者との情報共有等、検出結果を直感的に把握・確認する用途に適している（図 4.5（a））。

② 検出結果の CAD データ（DXF 形式）

AI による検出結果を、Jw_cad 等の汎用 CAD ソフトウェアで確認、編集が可能な DXF ファイル形式の図面データで出力する機能である。検出された劣化等の位置及び形状は、種類ごとに色分けされたデータとして出力されるため、既存の外壁立面の CAD 図面と重ね合わせての確認や、調査記録としての図面化・保管を、従来の手作業によるトレース作業を要することなく出力できる（図 4.5（b））。

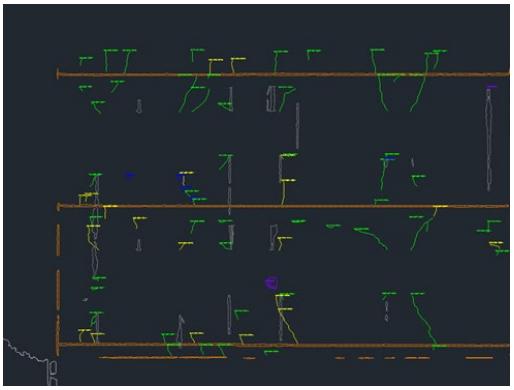
③ 劣化数量表データ（CSV 形式）

AI による検出結果を、劣化等の種類ごとに定量化した数量表データとして、CSV 形式で出力する機能である。出力される数量表には、検出された劣化等ごとに管理用の番号を付与した上で、劣化の種類に応じた定量値を記録する。具体的には、ひび割れについては番号ごとの長さ及び幅を、欠損等については番号ごとの面積を、それぞれ検出結果から算出してファイル出力する（図 4.5（c））。

本機能により、劣化等の発生状況を数値データとして一覧的に把握できるとともに、劣化状況の経年比較や、補修数量の算出等、調査・診断業務における各種検討への活用が可能となる。



（a）検出結果の合成画像データの例



（b）検出結果の CAD データの例

	A	B	C
1	No.	ひび割れ長さ（m）	ひび割れ幅（mm）
2	1	0.060512672	0.259558367
3	2	0.054038186	0.263036828
4	3	0.049888716	0.229166232
5	4	0.214369223	0.291005454
6	5	0.433565849	0.435536219
7	6	0.257990671	0.225792988
8	7	0.155553945	0.208170431
9	8	0.151886278	0.298180239
10	9	0.311887727	0.255976608
11	10	0.068626138	0.267631626
12	11	0.086102773	0.274500351
13	12	0.073795494	0.332756728
14	13	0.218581369	0.205589695
15	14	0.297529164	0.241002881
16	15	0.141685711	0.225801034
17	16	0.490635126	0.258091637
18	17	0.045960108	0.198254839
19	18	0.346670447	0.419413921
20	19	0.341757769	0.18182402
21	20	0.07783368	0.192784043
22	21	0.499846932	0.195478338
23	22	0.65219284	0.282196016
24	23	0.135168162	0.210153252
25	24	0.110564689	0.200652348
26	25	0.526643245	0.216015978
27	26	0.125822049	0.297134927
28	27	0.731188389	0.291990585

外壁ひび割れ

（c）劣化数量表データ

図 4.5　劣化検出結果の出力データ

５．調査・診断支援技術の有効性の検証

５．１　調査対象の概要

前章までに示した外壁の撮影方法、及び本研究で開発した外壁調査支援ソフトウェアを用いた調査の有効性を検証するため、実建築物の外壁を対象とした実測調査を実施した。

表 5.1 に対象建築物の概要を、表 5.2 に調査時の撮影条件を示す。対象は道内の商業施設の外壁であり、このうち南面外壁（幅約 90 m×高さ約 16 m）を本検証の対象範囲とした（写真 5.1）。当該建築物は塗り仕上げ外壁を有する RC 造 4 階建てであり、調査時点で竣工から 35 年が経過しているが、これまで外壁の一部を除いて改修等は行われていない。

外壁の撮影には、一般的に入手可能なデジタル一眼レフカメラを使用した。対象とした外壁の前面には車道が存在し、その先に民家が建ち並ぶ住宅街となっていたため、外壁とカメラ間の撮影距離は最大で 12 m が確保できる状況にあった。また、撮影時の天候は曇天が多く占める状況であったが、撮影時の外壁表面照度は、NDIS3418:2022「コンクリート構造物の目視試験方法」[7] を参考に、この規格で示されている下限値 500 lx 以上であることを照度計の計測により確認した。

表 5.1　対象建築物の概要

竣工年	1990 年（調査時：35 年経過）
構造	RC 造 4 階
外壁仕上げ	塗り仕上げ（複層塗材）
外壁改修履歴	なし（一部外壁に改修履歴あり）

表 5.2　調査時の撮影条件

撮影機器	Nikon D7100（デジタル一眼レフ）
撮像センサ	APS-C（23.5 mm×15.6 mm）
画像記録サイズ	6,000×4,000 pixel
撮影距離	12 m
外壁表面照度	34,000 lx（撮影時天候：曇天）



写真 5.1　対象建築物外壁（南面）の状況

５．２　検証内容

本検証では、前節の建築物の南面外壁を対象に、従来の目視調査による検出結果（以下、従来手法）と、本研究で開発した調査支援ソフトウェアを用いた検出結果（以下、開発手法）とを比較することで、開発手法の有効性を評価した。

従来手法では、調査技術者が対象外壁に近接し、目視及びクラックスケール等を用いた計測により、外壁に生じている劣化の位置、種類及び程度を野帳に記録した。さらに、事務所における机上作業として、野帳の記録を基にした劣化図面の作成、劣化量（ひび割れ長さ・幅、欠損面積等）のカウント、及びこれらを取りまとめた数量表の作成を行った。開発手法では、２章で示した方法に基づき外壁撮影をした後、４章で示した調査支援ソフトウェアを用いて、画像の正対化補正及び自動結合、AI による劣化検出、検出結果の確認・編集、並びにファイル出力までの一連の処理を行った。

両手法の比較・検証にあたっては、以下の 3 つの観点から検証を行った。

① 劣化検出精度

調査技術者が外壁の撮影画像上で劣化として判断した箇所をトレースした正解データ（人の手による画像検出結果）を別途用意し、従来手法及び開発手法の検出結果と正解データとの外壁劣化の照合を行った。この照合により、両手法の再現率、適合率及び F1 スコアを算出し、検出精度を評価した。

② 作業時間

現場での撮影・調査に要する時間、及び調査後の劣化図（展開図）作成やとりまとめに要する机上作業の時間について、従来手法と開発手法のそれぞれで計測・比較を行った。これにより、開発手法の導入による調査業務全体の効率化の程度を評価した。

③ 調査費用

従来手法及び開発手法について、調査に要する人員数や使用機材、作業日数等を踏まえた概算費用を算出し、比較を行った。これにより、開発手法の導入がもたらす費用面での効果について評価した。

５．３　AI による外壁劣化検出結果

開発手法により得られた外壁劣化の AI 検出結果について全体的な検出傾向を確認した（図 5.1）。AI による劣化検出結果は概ね良好な結果が得られており、特に、外観上判別が難しい、ひび割れと汚れ・水跡についても両者を明確に判別した検出結果で表示され、劣化と非劣化事象との判別性能の高さが確認できる。また、外壁周囲に存在する電柱や電線、室外機等の付属物も、これらを誤検出することはほぼ見られず、誤検出の防止を目的とした学習の効果が、実建物の劣化検出適用においても発揮されていると考えられる。



図 5.1　開発手法による外壁劣化検出結果の例

５．４　劣化検出精度の比較

（１）検出精度の評価方法

外壁劣化の検出精度を評価するため、撮影画像上の劣化箇所を調査技術者の目で確認し、画像上に劣化を描き入れた正解値を作成した。この正解値と評価対象とする「近接目視結果」と「AI 検出結果」のそれぞれの画像を 125 pixel（実世界で約 100mm 相当）四方の正方形でメッシュ分割し（図 5.2）、劣化箇所を含んでいるメッシュを「劣化あり」、含まれないメッシュを「劣化なし」とした [8]。さらに、メッシュ内の正解値と各評価値を比較して表 5.3 に示す混同行列に基づき分類し、各分類メッシュ数を用いて、以下に示す計算式から、セマンティックセグメンテーションによる劣化検出 AI の精度の評価指標値として「適合率」、「再現率」及び「F 値」を求めた。

・「適合率」　$Precision = \frac{TP}{TP+FP}$　（5-1）

・「再現率」　$Recall = \frac{TP}{TP+FN}$　（5-2）

・「F 値」　$F = \frac{2(Precision \times Recall)}{Precision+Recall}$　（5-3）

これらの指標は評価値と正解値との一致度を評価するものであり、表 5.3 に示す TP（True Positive：正しく「劣化あり」と検出したメッシュ数）、FP（False Positive：「劣化なし」を誤って劣化と検出したメッシュ数）、FN（False Negative：「劣化あり」を検出できなかったメッシュ数）を用いて計算する。

適合率は、AI が「劣化あり」と検出したメッシュのうち、実際に「劣化あり」だったメッシュの割合を示す指標であり、適合率が低い場合、劣化ではない箇所（外壁目地や汚れ等）を誤って検出する、誤検出が多いことを意味する。

再現率は、「劣化あり」のメッシュのうち、AI が正しく検出できたメッシュの割合を示す指標であり、再現率が低い場合は存在する劣化を AI が見逃した、未検出が多いことを意味する。

また、適合率と再現率は、一方を高めると他方が低下するトレードオフの関係にあることが一般に知られている。例えば、AI が劣化の可能性をわずかでも検知した場合に幅広く検出結果として出力する設定とすれば、再現率は向上する一方で誤検出が増加するために適合率は低下する。逆に、確信度の高い箇所のみを検出結果として出力する設定とすれば、適合率は向上するものの、微細な劣化等が検出されにくくなり再現率は低下する。そこで、両指標のバランスを総合的に評価する指標として、適合率と再現率の調和平均で計算される評価指標 F 値を用いる。F 値は 0 から 1 の間の値をとり、1 に近いほど適合率と再現率がともに高い水準でバランスよく確保できていることを示している。

表 5.3　二値分類問題の混同行列

		評価値（目視結果・AI 検出結果）	
		劣化あり (Positive)	劣化なし (Negative)
正解値	劣化あり (Positive)	真陽性 TP (True Positive)	偽陰性 FN (False Negative)
	劣化なし (Negative)	偽陽性 FP (False Positive)	真陰性 TN (True Negative)



図 5.2　メッシュ分類の例

調査対象の検証範囲のうち、代表的な目地間範囲（幅約 4 m×高さ約 16 m）における検出結果を用い、検出精度の評価指標である適合率、再現率及び F 値を算出した。図 5.3 に、劣化検出精度の評価に用いた正解値、並びに従来手法及び開発手法によるメッシュ評価結果の比較を、図 5.4 に、当該メッシュ評価結果から算出した評価指標の比較を示す。

図 5.3 より、従来手法では未検出（赤色メッシュ）が広範囲に分布しており、正解値との差異が比較的大きい。これは、現場での目視調査が調査員の視認距離や角度、集中力の持続等の人的要因の影響を受けやすく、特に微細なひび割れの見落としが生じやすいことが一因である。また、目視で確認した劣化位置を野帳等へ記録し、これを図面化する過程でも位置の転記誤差が生じることも想定される。

一方、開発手法では誤検出（黄色メッシュ）がやや多く見られ、この影響で適合率は 0.85 程度の値に留まっている。しかしながら、未検出は従来手法と比較して大幅に減少しており、再現率は 0.95 以上の値を示すなど、検出の見逃しに強い評価結果となった。また、適合率と再現率の調和平均で計算される F 値で比較すると、開発手法は 0.9 に近い値を示し、従来手法から約 67%の精度向上が確認された。これらの結果は、開発手法が目視調査での検出見逃し等の人的要因のミスを大幅に低減でき、外壁劣化調査の手法として実用的に活用できる可能性を示すものといえる。

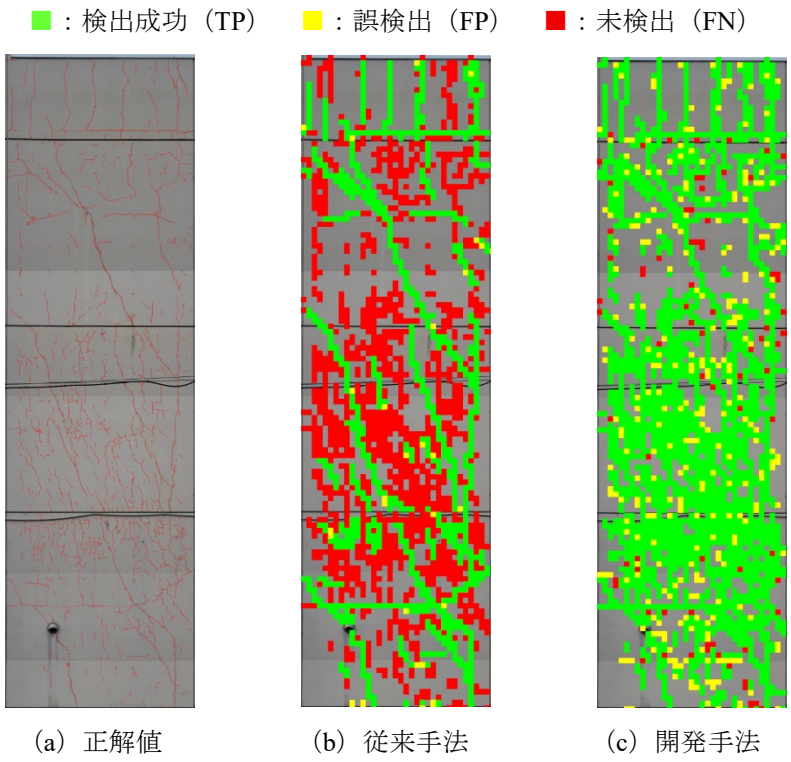


図 5.3　劣化検出精度のメッシュ評価結果の比較

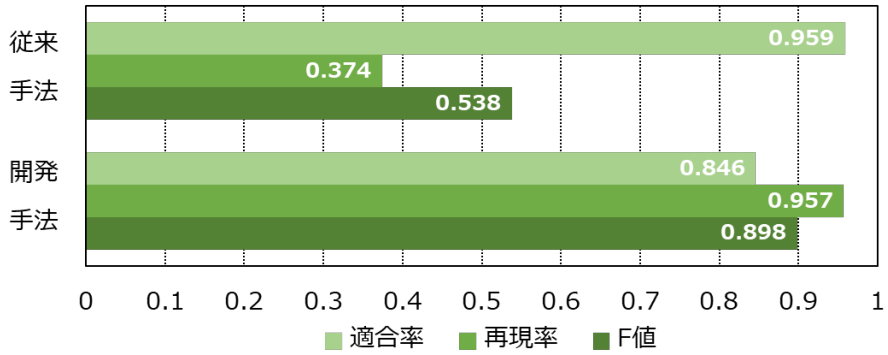


図 5.4　劣化検出精度の評価指標の比較

５．５　作業時間及び調査費用の比較

図 5.5 に従来手法と開発手法における作業時間の比較を、図 5.6 に調査費用の比較を示す。いずれの比較も、現地調査に要するものと、机上作業に要するものの内訳を積み上げて表示している。

作業時間（図 5.5）については、従来手法では現地調査に 17.1 時間、机上作業に 18.3 時間を要して合計 35.4 時間であったのに対し、開発手法では現地調査に 0.6 時間、机上作業に 3.9 時間の合計 4.5 時間となり、従来手法と比較して約 87 %の作業時間の低減が確認された。現地調査時間の大幅な短縮は、開発手法における現地作業が外壁の撮影のみで完結することによるものであり、また、机上作業時間の短縮は、AI による劣化検出から劣化図面・数量表の出力までを調査支援ソフトウェアが一貫して処理できることによる効果が表れているものと考えられる。

続いて、調査費用（図 5.6）についてみると、従来手法では現地調査に 72 万円、机上作業に 16 万円がかかり、合計 88 万円を要したのに対し、開発手法では現地調査に 8 万円、机上作業に 6 万円の合計 14 万円の所要額となり、従来手法と比較して約 84 %の調査費用の低減ができた。この低減は、主に現地調査に要する費用の差によるものであり、開発手法では外壁撮影のみで現地調査が完了することから、従来手法で必要となる目視での近接確認に要する人工の削減や高所作業車等の特殊機材の借り上げ等が不要になったことが、主な要因として挙げられる。

これらの結果から、開発手法は、前節で示した劣化検出精度の向上に加え、作業時間及び調査費用の両面においても大幅な効率化を実現できることが示され、外壁劣化調査の手法として高い実用性を有していることが確認できた。

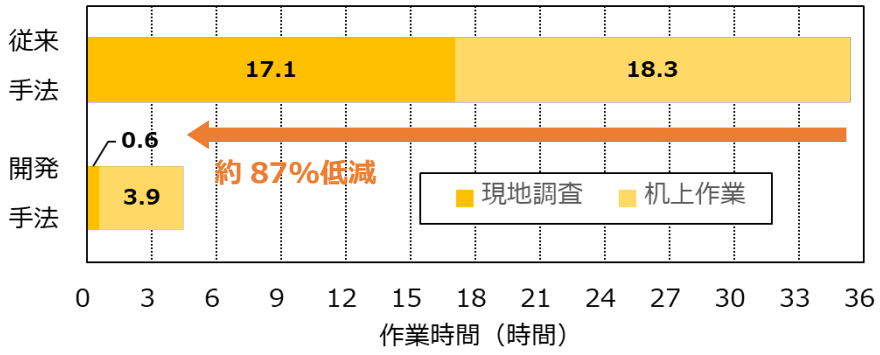


図 5.5　調査に要する作業時間の比較

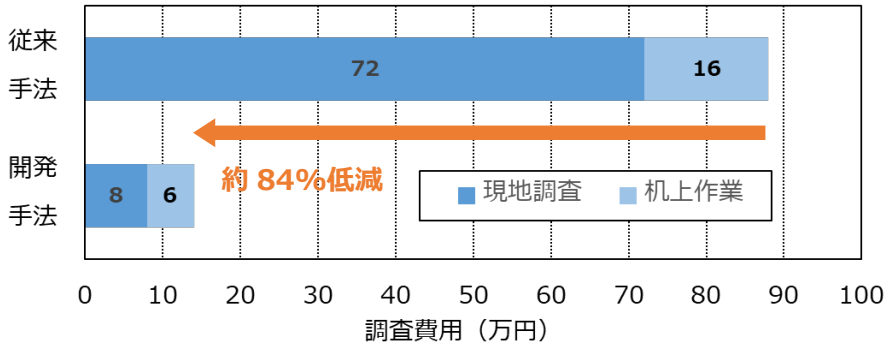


図 5.6　調査に要する費用の比較

６．まとめ

本研究では、AI の劣化検出に適した撮影条件・撮影方法を明らかにした上で、外壁劣化の教師データセットを増強した上で AI 学習を進め、塗り仕上げ外壁の実用的な劣化検出が可能となった。また、劣化検出や調査実務で必要な機能を実装したソフトウェアの開発及びその有効性検証に取り組んだ結果、各研究項目において以下に示す成果を得た。

１）外壁の撮影条件・撮影方法の検討・構築（R5～R6 年度）

・AI を用いた外壁劣化検出に必要な撮影条件として、検出実験の結果から画像分解能を定めた。また、カメラ性能毎に外壁の撮影範囲を事前に設定することで、現場では煩雑な撮影距離やレンズ焦点距離の調整なく、検出条件である画像分解能を簡単に得られる撮影方法を提案した。

・塗り仕上げ外壁を対象に、地上カメラ及びドローンによる外壁撮影手順や留意事項について検討した。得られた知見は一般技術者が活用できる外壁撮影マニュアルとして取りまとめた。

２）外壁劣化検出 AI の構築（R5～R7 年度）

・外壁調査時の撮影画像を活用し、これまで検出精度の低かった劣化（欠損や鉄筋露出等）を主とした教師データセットの追加作成（約 32,000 セット）を行い、これらを用いた劣化検出 AI の学習を実施した。

・ニューラルネットワークの選定や学習時パラメータの最適化によって検出精度の向上を図った結果、開発した AI が塗り仕上げ外壁の劣化検出において目標の検出精度（F 値≧0.8）を満たすことを確認した。

３）調査・診断支援ソフトウェアの開発（R6～R7 年度）

・見上げ撮影で生じる画像のあおり変形等を正対化補正するプログラムや分割撮影された外壁画像を従来調査での図面記録と同等の全体画像に自動結合するプログラムを開発した。

・開発した AI による劣化検出結果から、各劣化数量（ひび割れ長さ・幅、欠損や塗装はがれ等の面積、発生数等）を自動計数できるプログラムを作成した。また、検出結果のマニュアル編集機能（検出見逃し箇所の追記や誤検出箇所の削除等）や図面・数量表等での出力機能を作成した。

・項目２）で開発した外壁劣化検出 AI と上記の各種処理プログラムを機能統合するとともに、ユーザー操作用のインターフェースを備えた、調査・診断支援ソフトウェアを開発した。

４）調査・診断支援技術の有効性の検証（R7 年度）

・道内の商業施設建物の外壁を対象に、劣化検出精度、調査作業に要する時間及び調査費用について、従来手法である目視調査と開発手法との比較を行った。その結果、従来手法と比較した開発手法の劣化検出改善率は約 67%と目標値を上回る結果が得られた。また、開発手法を用いることで、現地調査作業と机上作業を合わせた所要時間を約 87 %低減でき、調査費用については約 84 %低減できることを示し、負担低減効果の目標を達成できた。

本研究で開発した外壁調査支援技術は、RC 造建築物における劣化状況の把握のみならず、改修や建替えの優先順位判断、改修工事費用の概算見積等、建築物の維持管理に係る幅広い場面での活用が期待できる。そのため、本技術については、自治体及び民間の一般技術者が広く活用できる調査支援技術として、共同研究機関を通じて今後公開予定である。

また、開発した調査支援技術の円滑な普及に向けて、一般技術者を対象とした導入支援を継続して実施していく予定である。ソフトウェアの操作方法や AI 検出に適した撮影方法等に関する研修や現場での技術支援等を通じて、経験の浅い技術者であっても本技術を円滑に活用できる環境を整備することで、外壁調査業務の効率化及び高度化に広く貢献できるものと考えている。

【参考文献】

1) 木本啓介，松田浩：デジタル画像の画素分解能とコンクリートの視認可能なひびわれ幅に関する検証，土木構造・材料論文集，第 35 号，115-122，2019.12
2) V. Badrinarayanan，A. Kendall and R. Cipolla : SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation，IEEE Transactions on Pattern Analysis and Machine Intelligence，Vol.39，pp.2481-2495，2017.1
3) Olaf Ronneberger，Philipp Fischer and Thomas Brox : U-Net: Convolutional Networks for Biomedical Image Segmentation，arXiv:1505.04597v1，2015.5
4) L.-C Chen，Y. Zhu，G. Papandreou，F. Schro and H. Adam : Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation，arXiv:1802.02611v3，2018.8
5) 新編 画像解析ハンドブック：高木幹雄，下田陽久，財団法人東京大学出版会，2011.11（第 3 刷）
6) Lowe, D.G. : Object recognition from local scale-invariant features，Proceedings of the Seventh IEEE International Conference on Computer Vision，1150–1157，1999.9
7) 日本非破壊検査協会 NDIS3418 : 2022「コンクリート構造物の目視試験方法」，2022.9
8) 南貴大，浦田渡，藤生慎，福岡知隆，須田信也，高山純一：超高解像度画像データを用いた橋梁の画像目視点検に関する基礎的分析～近接目視点検と比較して～，土木学会論文集 D3（土木計画学），Vol.75，No.5，pp.I_883-I_980，2019