

ドローン自動航行撮影と AI 画像認識による 製鉄所護岸ひび割れ自動検知技術の開発

Development of Automated Crack Detection on Steelworks Seawalls Using Autonomous Drone Imaging and AI Vision

齋藤 直之 SAITO Naoyuki JFE スチール 西日本製鉄所（倉敷地区） 環境・防災部 主査
秋山 浩一 AKIYAMA Koichi JFE スチール 西日本製鉄所（倉敷地区） 環境・防災部長
【現 プラントエンジニアリング本部 プラント建設部 プラント建設戦略室長】

要旨

製鉄所護岸で発生するコンクリートひび割れによる石灰成分の地下水流出を防ぐため、船による目視点検を行っているが、広範囲であることから人員と時間を要し、また早期発見が困難であるという課題もあった。これら 2 つの課題を解決するため、ドローン自動航行による高精度撮影と、AI 画像認識によるひび自動検知を組み合わせ、点検作業の効率化と高精度化を図った。ドローン撮影では条件最適化および RTK（Real Time Kinematic）測位導入、AI 画像認識では護岸表面ノイズ除去、ひびの種類別追加学習および風化ひび特化モデルの開発により、ひび検知率は 28.9% から 92.4% へ向上した。さらにドローン自動航行遠隔監視化およびひび検知エンジン最適化により、さらなる効率化および高精度化を進めている。

Abstract:

Cracks in the concrete revetments of the steelworks can allow groundwater containing lime components to seep into the sea, creating environmental concerns. Traditionally, inspections have been conducted visually from boats, but the vast inspection area and obstacles along the shoreline make the process time-consuming and hinder early crack detection. To solve these issues, a new system combining automatically navigated drone imaging with AI-based crack recognition was developed. The approach improves efficiency and accuracy by optimizing flight conditions, introducing RTK (Real Time Kinematic) positioning, removing surface artifacts, and applying additional learning for different crack types. Specialized AI models for weathered and seepage-covered cracks were also created, significantly improving overall detection performance. As a result, the crack detection rate increased from 28.9% to 92.4%. Ongoing enhancements to the detection engine and more efficient annotation methods continue to advance the precision and productivity of the inspection workflow.

1. はじめに

製鉄所護岸は、原料岸壁や製品出荷岸壁として利用される重要インフラであるが、気温差や風浪によるひび割れや崩落等が発生し、特にひび割れの発生が顕著である。図 1 にコンクリート護岸のひび割れメカニズムを示す。護岸コンクリートは風浪等の過酷な環境下で季節的な熱膨張・収縮を繰り返すため、経年的にひび割れが発生しやすく、土壌中の石灰層を浸透した高 pH の地下水が、ひび部分から海へ流出する可能性がある。この現象は環境問題に直結するため、西日本製鉄所（倉敷地区）（以下、倉敷地区）では早期補修を目的として、総延長約 21 km の護岸を船で巡回する目視点検を、図 2 に示すルートで月 1 回行っている。

しかし、この点検方式には以下の課題が存在する。

- (a) 内周部を含む複雑地形および漂流物補足ネット・オイルフェンスなどの障害物のため、移動が困難
- (b) 停泊船により点検不可部分は、後日再点検が必要




図 1 コンクリート護岸のひび割れメカニズム

Fig. 1 Crack mechanism of concrete revetment

2026 年 2 月 20 日受付




図2 護岸点検ルートと障害物の位置

Fig. 2 Bank inspection route and location of obstacles

(c) 築堤等がある場合、護岸に接近できず一定距離の離隔を保つ必要があるためひびの早期発見が困難。従来の点検作業では、点検に多くの時間を要すること、およびひび割れの早期発見が困難であることが主要な課題として指摘されていたことから、本検討にあたっては、「データ収集時間の短縮」と「ひび検知方法の自動化」を改善目標とした。具体的には、護岸構造物に対する効率的かつ高精度な点検技術の確立を目的として、ドローン自動航行撮影と AI 画像認識を組み合わせた点検手法の高度化を進めた。

2. ドローン自動航行による護岸撮影技術

2.1 ドローンでの護岸撮影における技術的課題

データ収集時間短縮には、産業用ドローンを用いた自動航行撮影の導入が有効である。既存の産業用ドローンおよびカメラ技術を活用することで、護岸側面の撮影が可能であることは確認した。しかし、護岸撮影には適切な高度・離隔の維持、さらに護岸の複雑な壁面形状に追従できる航行経路が必要であり、ドローンオペレーターの技量に依存した操縦では点検品質の維持・向上が困難であることから、既存技術では不十分と判断した。

図3に自動航行撮影に必要な技術要件を示す。①機体性能、②搭載カメラ性能、③高度、④離隔、⑤自動航行ソフトウェア高度化の5点に整理した。このうち①および②は既存技術で対応できたが、③、④および⑤は新たな開発項目として取り組む必要があった。特に高度・離隔の制御については、衛星測位 (GNSS) 単独では数十センチ～数メートル

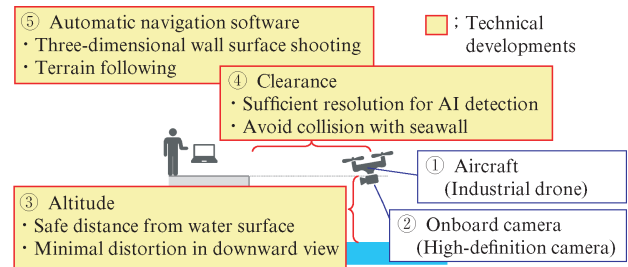


図3 ドローン自動航行撮影に関する技術要件

Fig. 3 Technical requirements for drone automatic navigation and photography

ルの誤差が発生し、安全性の確保や高解像度撮影に支障をきたすことが明らかとなった。

2.2 ドローン自動航行技術の開発

表1に前項の課題に対する解決策を示す。③高度、④離隔に関してはジャイロセンサーと加速度計 (Inertial Measurement Unit : IMU)、気圧計、電子コンパスなど複数のセンサー情報を統合することで自機位置推定精度を向上させ、高度・離隔の誤差を±50 cm 程度まで低減できた。また、⑤自動航行ソフトウェア高度化に関し、微細な地形変化起因により撮影対象が画角から外れる課題については、Digital Elevation Model (DEM) を利用した地形追従型航行ルート生成機能を開発し、護岸形状に見合った最適な飛行経路を自動設定できる飛行アプリを実装することで解決した。

2.3 ドローン自動航行精度の向上

さらに、より高い飛行精度を実現するため、Real Time Kinematic (RTK) 測位システムを搭載した新型機体を導入した。RTK は基準局からの補正データを活用することで誤差数 cm 程度の高精度測位を可能とする技術である。今回採用した RTK 搭載機は水平・垂直ともに±5 cm の高い飛行精度を保証しており、高さ方向および水平方向のズレの大幅改善が期待できる。テストフライトでの RTK 導入効果を

表1 各技術要件に関する解決手法

Table 1 Solutions for each technical requirement

Subjects	Solution
③ Altitude ④ Clearance	1) Inertial navigation system (IMU: gyro sensor + accelerometer), barometer, and electronic compass ⇒ Self-positioning accuracy (± 50 cm) 2) Relative and carrier-phase positioning (RTK) ⇒ Self-positioning accuracy (± 5 cm)
⑤ Automatic navigation software	Automatically sets Routes following terrain using DEM data




図 4 RTK 導入によるドローン自動航行撮影

Fig. 4 RTK drone automatic navigation and photography

図 4 に示す。RTK 搭載機では縮尺誤差や画角誤差がほぼ解消され、護岸壁面を安定的かつ高精度に撮影できることが実証された。

これらの技術開発と航行精度向上により、内周部の点検時間を月当たり約 5 時間削減できた。

2.4 遠隔でのドローン自動航行技術開発

前項までは、点検者が現地護岸でドローンを自動操縦させて撮影する自動航行技術開発について述べたが、事務所等から遠隔で監視人を置かずドローン操縦を行う自動航行技術の開発にも着手している。倉敷地区は航空法で人口集中地区（DID）に指定されており、製鉄所上空で飛行を実施するには国土交通省による飛行承認が必須である。今回、製鉄所内におけるドローン飛行技術開発を目的とした飛行申請を国土交通省へ行い、看板等による構内周知を条件として飛行承認を得られた。2025 年 3 月に所内試験飛行を実施し、以降種々の課題の検討を進めている。

3. 撮影画像の AI 認識によるひび割れ検知

3.1 AI 画像認識の基本構成と初期評価

本開発では、AI 画像認識技術を用いた護岸のひび検知手法の高性能化を目的として、既存 AI モデルの適用性評価、画像前処理技術の開発、および追加学習による検知精度向上を検討した。従来、護岸点検は人手による目視に依存しており、個人差および精度差が課題であった。AI 自動検知は、これらを解決する新たな手段として期待される。

本開発にあたっては、画素ピクセルごとにひびであるかを判断する市販の AI ひび検知ソフトウェアを流用し、開発コストおよび開発時間の削減を図った。市販のソフトウェアは製鉄所護岸の環境への最適化が未実施であり、データ前処理や学習戦略の最適化が不可欠である。AI 画像認識は、①学習（教師画像収集・前処理・アノテーション→学習モデル構築）と②検知（構築モデルで対象検出）の二段構成とした。また、学習の反復（追加学習）により精度向上を図った。

図 5 に護岸ひびの検知状況を示す。未学習のひび検知モデルを適用した検知率は 28.9%（76 本中 22 本）であった。




図 5 AI 画像認識結果（初期）

Fig. 5 AI image recognition results (initial)

低検知の要因としては、①建設時の工事痕跡や海上浮遊物、風浪等による表面荒れ（ノイズ）の多さ、②通常コンクリートに生じるひびと異なる特徴、の 2 点が挙げられる。

3.2 AI 画像認識におけるノイズ除去対策

AI 画像認識によるひび割れ検知率向上対策として、まず海上浮遊物や風浪により生成した撮影画像の微細なキズの除去に取り組んだ。

微細キズ除去のために、近傍連結ピクセルの面積に基づき微細キズ（ノイズ）を除去するフィルタを構築した。護岸表面のひびは、先述のとおり、護岸自体の伸縮膨張による縦割れが主¹⁾であり、撮影画像における検知したひびピクセルの縦長連結群が該当する。今回は処理リソースやマンパワーを考慮して、検知したひびピクセルをすべて連結化して評価した。図 6 に本評価法の詳細を示す。護岸表面に広大に生じたキズの経時調査を行い、検知部の連結群からピクセル数を算出して閾値を決定、それ未満の連結群はすべてノイズと判定して自動的に削除した。また、護岸ひびと見分けが付きにくいノイズについては、補修時の水漏れひび採寸データから、特定の長さおよび幅未満のものはノイズとみなす設定を併せて導入した。




図 6 護岸キズ（ノイズ）判別手法

Fig. 6 Method for identifying noises in revetments

3.3 AI 画像認識によるひび検知結果と課題

護岸ひびは、先述したように、製鉄所が埋立地に立地している点や石灰質土壌である等の事情が特性に影響している。図 7 に護岸ひびの分類と AI 追加学習後の検知結果を示す。現地特性を考慮し、(a) 通常、(b) 地下水滲み、(c) 表面研削、(d) 滲出物被覆、(e) 風化に 5 分類した。

(a) から (e) の各分類ごとに、最大 240 枚の画像を先述の護岸表面キズ除去フィルタと組み合わせて追加学習を実施して検知エンジンを製作し、これらを用いてひびを検知した結果、検知率は当初の 28.9% から 80.1% へと大幅に改善した。タイプ別の検知率は、(a) 通常 88%、(b) 地下水滲み 75%、(c) 表面研削 72% で顕著に改善したが、(d) 滲出物被覆および (e) 風化はそれぞれ 18% および 17% と改善は限定的であった。これらの結果を詳細に分析した結果、検知率向上に向けた課題は以下のとおりである。

① 難検知ひび（風化）への対応

風化ひびは、先述の護岸経年ひび割れ部が積年の風浪によりさらに浸食されてひび幅および長さが伸長したものである。地下水位の関係上、海洋流出までのリスクはないものの、放置は危険である。通常ひびを追加学習した AI モデルでは風化ひびの認識が困難であることから、風化ひび検知に特化した学習モデルの構築が必要である。

② 護岸ひびと表面ノイズの分別手法

連結ひびピクセルとひび閾値で判断させるフィルタにより、表面ノイズはある程度除去できたものの、護岸ひびと表面ノイズを高精度には分別できない。護岸表面のノイズは海上浮遊物等が寄せ波等で護岸に衝突してきたものであり、護岸自体を貫通しているものではない

	(a)	(b)	(c)	(d)	(e)
	Normal cracks	Water seepage	Surface grinding	Exudate covering	Weathering
Shape					




図 7 護岸ひびの分類と AI 追加学習による各ひび検知結果

Fig. 7 Revetment crack classification and crack detection results using AI additional learning

ため、地下水流出の懸念はなく本画像認識においては排除すべきものである。よって、ひびとノイズを高精度で分別する手法の開発が必要である。

4. ひび割れ AI 画像認識の検知率向上策

4.1 難検知ひび（風化）検知率向上

前章で説明した風化ひびは、護岸下部において、(a) 通常、(b) 地下水滲み、(c) 表面研削タイプのひびが成長し、風浪によりひび幅が拡大し、ひび内部は藻類の繁殖や海上浮遊物による汚染により護岸色に対して濃淡さまざまな様相を呈するものである。従って、風化ひびの撮影態様是一件ごとに異なり、AI 検知モデルにひびと認識させるのは非常に困難であった。そこで、風化ひび検知率向上策として、風化ひびに特化した学習モデルの開発に着手した。

まず、学習モデルへのアプローチとして、風化ひび撮影画像について図 8 に示すような要素分類を行った。撮影画像はひびと風化部分、背景の 3 部分で構成されているが、ひびと風化部分を分類する手法により、表面キズ除去等に必要マンパワーや解析精度が異なる。(i) のようにひびと風化部分を合成した場合、解析処理リソースは小さくできるが、検知性能低下の恐れがある。ひびと風化部分を分離した場合は、おのおのに背景を含める場合と分離する場合の 2 パターンが想定される。(ii) のようにひびと風化部分を分離（背景含めて 2 分類化）した場合、個々の分類で高精度にひびと風化部分の検知が期待できるが、解析処理リソースや表面キズ除去等のマンパワーが倍増する。(iii) のようにひびと風化部分を分離（背景分離して 3 分類化）した場合、元々のひび検出そのものであり検出精度低下リスクは低く、解析処理時間は微増であり有力である。よって、今回は (iii) 案でひび検知率向上を図ることとした。

上記 (iii) 案で学習させた AI モデルでひびを検知し、通常ひびの下部に風化部分が存在するひびを中心に改善効果を評価した。先述の (iii) 分類の適用により、下部の風化部検出率は改善されたが、全体的に上部通常ひびの検出率低下が見られた。本現象への対応を図 9 に示す。①風化ひび検知画像を透過、②風化部分のみを切り取り、③通常ひび検知画像に自動で重ね合わせるロジックをひび検知エンジ




図 8 要素分類手法

Fig. 8 Element classification methods




図9 風化ひび検出精度向上手法

Fig. 9 Method for improving accuracy of weathering crack

ンに追加した。これらを使用することにより、不鮮明であった通常ひび部分も鮮明化し、ひび検知率の約 11% 改善に寄与した。

4.2 護岸ひびと表面ノイズの高精度分別

前節では検知画像ピクセルブロック化による護岸ひびと表面キズの判別を説明した。さらに高精度のひび検知のためには学習データ作成や AI 検知モデル評価用正解データ作成段階での画像アノテーションをいかに効率良く精緻に実施できるかが重要²⁾である。画像アノテーション手法については表 2 にまとめたとおりであり、検知対象が定形か不定形かにより実施手法が異なる。不定形である護岸ひびに対しては、画像中の対象を画素単位で詳細に領域分割する手法で、高精度分割が可能な、表 2 右のセマンティックセグメンテーションを用いた。

今回開発した検知モデル評価用正解データ作成段階での画像アノテーション手法を図 10 に紹介する。従来手法では、AI 検知後、目視により護岸ひび部分とそれ以外（表面キズ等）の部分に分類した上で、それ以外の部分を画像ピクセル単位でラベリングする画像アノテーションが必要であった。そのため膨大なマンパワー投入が必要となり、また画像アノテーション後の再学習も必要であることから非効率である。そこで、AI 検知画像を特定画素数ごとにブロック化し、ブロック内のひび検知画素数（含有率）を計算させ、ブロック内ひび検知画素数の閾値を定め、閾値以上を「ひびブロック」、それ未満を「非ひびブロック」と定義することとした。本手法³⁾を導入することにより、仮定から導出し




図10 画像アノテーション手法（正解データ作成用）

Fig. 10 Image annotation method (for creating correct data)

た閾値変更のみでさまざまな画像アノテーションを実行できるようになり、検知率向上につながった。本画像アノテーション手法を専用ツール化することで、複数の AI 検知画像の効率的な処理を実現した。

次に「ひびブロック」および「非ひびブロック」を判別するピクセル閾値の選定方法について説明する。本検証は上記閾値の設定方法によりひび検知モデルの解が、「ひびブロック」と検知したものが護岸ひびである（True Positive; TP）, 「ひびブロック」と検知しないが護岸ひびである（False Negative; FN）, 「非ひびブロック」と検知したものが護岸ひびでない（True Negative; TN）, 「非ひびブロック」と検知したものが護岸ひびである（False Positive; FP）の 4 パターンの構成（混同行列）に分類され、表 3 に示す AI 検知モデルの感度指標となる。また、その評価基準は全ひび数の中から AI が正解と判断した割合の再現率（Recall; R%, 式（1））と AI が正と判断したものの中で実際の正解数である適合率（Precision; P%, 式（2））であり、これら 2 基準⁴⁾はトレードオフの関係にある。

$$R(\text{再現率}) = \frac{TP(\text{AI 検知の正解ブロック数})}{TP + FN(\text{正解データブロック数})} \quad (1)$$

$$P(\text{適合率}) = \frac{TP(\text{AI 検知の正解ブロック数})}{TP + FP(\text{AI 検知ブロック数})} \quad (2)$$

これら 2 指標の調和平均の値を F 値（F-measure）といい、閾値変化による F 値変化の軌跡から最適閾値を選定し

表 2 画像アノテーション手法²⁾
Table 2 Image annotation methods²⁾


	Bounding box	Polygon	Semantic segmentation
Image			
Objects	Fixed	Fixed	Irregular
Manpower	Low	Middle	High
Features	Not suitable for irregular shapes	- Resistant to shape changes - High manpower (Irregular detection)	- High performance of detection - High manpower (All processes)

表 3 ひび検知に関する混同行列
Table 3 Confusion matrix of crack detection

		AI detection	
		Positive (Cracks)	Negative (Not cracks)
Actual measurement	Positive (Cracks)	TP (True Positive)	FN (False Negative)
	Negative (Not cracks)	FP (False Positive)	TN (True Negative)




図 11 「ひびブロック」閾値と再現率、適合率、F 値の変化

Fig. 11 Block threshold and variation of recall, precision, F-measure

た。図 11 に「ひびブロック」閾値と再現率、適合率、F 値の変動を示す。本エンジンは微細な護岸ひびを検知するものであるため、閾値を小さくする（右側へ移行）と再現率は上昇、適合率は低下する傾向を示す。本結果から「ひびブロック」と最適閾値について、以下 2 点を考慮して選定した。

① 護岸ひび割れの見逃しによる水漏れを抑止する観点から式 (1) の再現率を採用（過検知側の設定）

② 検知エンジンの性能を最大限発揮させる観点から単位ブロックの画素サイズは 200×200 ピクセル

これらを考慮して、閾値を選定すると 0.1% 近傍が最適値となることが分かった。

4.3 AI 検知率向上策による効果

護岸ひび AI 検知エンジンにおけるひび写真学習数とひび検知率の関係を図 12 に示す。3 章で述べた検知エンジン構築と追加学習（240 枚）により護岸ひび検知率が 80.1% になっていたものが、特化モデル構築による風化ひび検知、




図 12 ひび検知向上対策と検知率の推移

Fig. 12 Measures to improve crack detection and detection rate

画像アノテーション手法の開発、および「ひびブロック」ピクセル最適閾値の選定により、護岸ひび検知率を 92.4% まで高めることができた。

5. おわりに

JFE スチールでは、既製ドローンを使用した自動航行による撮影飛行技術を開発し、広大なコンクリート護岸面の水漏れ点検に適用した。また、AI 画像認識による護岸ひび割れ検知エンジンを開発し、ドローン飛行により撮影した高精度な画像を使用することにより、点検作業の効率化と高精度化を実現した。今後、ドローン自動航行については、遠隔での目視外飛行も視野に技術開発を推進していく。AI 画像認識については、さらなるひび検知率向上を目指し、追加学習等で検知エンジンのレベルアップを図っていきたいと考えている。

参考文献

- 1) 荻野和彦, 氏家勲. ひび割れ部の透水性および透気性に影響を及ぼす要因に関する研究. コンクリート工学年次論文集. 2000, vol. 22, no. 2, p. 811-816.
- 2) Analytics.ai. Image Annotation Services. Image Annotation for Machine Learning. <https://www.analytics.ai/image-annotation-services/> (accessed 2026-01-30)
- 3) 内場崇之. ディープラーニング入門. 【全 3 回】AI・人工知能時代のための PC 実習で学ぶはじめての統計・機械学習入門シリーズ講座 第 3 回はじめてのディープラーニング【PC 実習付き】. 2019, p. 49-55.
- 4) Vincent, L.; Hocine, C. Evaluation of Performance Measures for Classifiers Comparison. Ubiquitous Computing and Communication Journal 6. 2011, p. 21-34.