

A I 鏡吹付けコンクリートクラック検知システムの開発

清水建設(株) 正会員 ○淡路 動太
有家 舜祐 邊見 涼
三原 泰司 伊原 広明

1. はじめに

山岳トンネル工事では、切羽で岩盤が剥離、脱落する「肌落ち」が切羽付近での作業中に発生した場合、重大災害に繋がる恐れがある。肌落ちを災害化させないためには、肌落ち発生の前に警報を発し、作業員を切羽から退避させる時間を確保する必要がある。肌落ち発生時に作業員の切羽からの退避時間を確保するためには、肌落ち発生の予兆の一つである鏡吹付けコンクリート面に発生するクラックを瞬時に認識し、警報を発することが有効であると考えられる。平成30年に改正された「山岳トンネル工事の切羽における肌落ち災害防止対策に係るガイドライン」では、専任された切羽監視員により切羽の状態を常時監視することが求められている。しかし、切羽周辺は狭隘な作業空間内に人と機械が混雑し、人による目視のみで監視を行うことは困難になる状況も想定されるため、切羽監視員による監視、判断を補佐する技術が必要と考えられる。そこで、筆者らはAIを用いた画像解析の一手法である **Semantic Segmentation** によるディープラーニングを用いて、鏡吹付けコンクリート面に発生するクラックを識別することで、常時監視を実現するシステムの開発を行った。

本報告では、鏡吹付けコンクリート面のクラックをリアルタイムで検知することができるAIモデルの構築方法、および構築したモデルのクラック検知性能について述べる。

2. システム概要

本システムの概要図を図-1に示す。切羽近傍の側壁部もしくは重機等にカメラを設置し、作業員が切羽近傍に立ち入らなければいけない作業において、常に切羽映像を取得できるようにしている。カメラ映像と解析用PCはオンサイトで接続されリアルタイムに解析を実施できるため、切羽崩壊の前兆現象の一つであるクラックを常に監視し、発生と同時に検知できるようになっている。また、PCでの解析の状況をタブレット等のスクリーンに映すことで切羽監視員が自身の目で切羽を監視しつつ、死角から撮影されている映像の解析結果と比較することができ、クラックの検知をいち早く確認することができる。クラックを検知した際に、素早く警報を行うことで作業員の退避を促すことが可能となる。



図-1 システムの概要

キーワード 山岳トンネル, 肌落ち災害, 切羽監視, AI, ディープラーニング, 教師データ

連絡先 〒104-8370 東京都中央区京橋二丁目16-1 清水建設株式会社 土木技術本部地下空間統括部 TEL03-3561-3887

鏡吹付けコンクリート面に発生するクラックの検知は、発生クラックパターンをディープラーニングを用いて学習したAIにより、撮影中の動画をリアルタイムに解析することで行う。本システムにディープラーニングを適用するメリットは、撮影動画中に入り込む人や機械などのノイズに対して強いこと、シンプルな設備群でシステム化が可能でオンサイトで計算処理を完結できることが挙げられる。一方、検知されたクラックの信頼性や有効性については十分な検証が必要である点に注意が必要である。

現場で本システムを実運用する際には、切羽監視員による判断の補助として使用することを想定している。切羽監視員より早期のクラック検知や死角に発達するクラックの検知が可能になるため、本システムの開発により、より綿密な切羽監視を実現し、山岳トンネル工事での事故の低減に寄与することを期待している。

3. AIモデルの構築方法

(1) AIモデルの概要

a) ディープラーニング

ディープラーニング（深層学習）とは、簡単な関数を組み合わせて表現力の高い「深い関数」を作り、そのパラメータをデータから推測する機械学習技術である²⁾。また、人間の脳が持つ神経回路（ニューロン）の一部分と類似した計算アルゴリズムであり、コンピュータ自身が処理のルールを学習できるものである。

従来の制御工学においては、人がルールを定義しコンピュータにプログラムしていた。このルールは非常に堅く、かつ人が無理なく設定できる数量であるため、プログラムではその入力を適切に処理できず、予期せぬ動作やエラーが発生してしまうという弱点があった。その一方でディープラーニングでは、バリエーションのある実データを用い、人がプログラムできない程の多数のパラメータやルールを「学習」させることで、人が未知の事象に対し経緯を以って判別するように曖昧さを吸収するルールをコンピュータが作り出すことができる。したがって、トンネル坑内の切羽近傍のような環境変化の厳しい条件下でも、クラック抽出を高い精度で実施できる可能性が高い手法であると考えられる。

b) Semantic Segmentation

本システムでは、撮影画像からクラックを抽出するために、ディープラーニングを用いた学習方法の中でも、Semantic Segmentationを用いた画像解析方法を採用している。Semantic Segmentationとは、画像の特徴をピクセルレベルで把握する手法のことである。ピクセル単位でオブジェクトごとに色付けされた教師データを用いて学習を行い、推論の際には入力画像の全てのピクセルに対して、クラス分類を行う。したがって、撮影画像の中からクラックに相当する箇所をピクセル単位で識別することが可能となる。

Segmentationを行う最も単純な方法は、全てのピクセルを対象としてピクセルごとに推論処理を行うことである。しかし、そのような方法ではピクセルの数だけ画像処理を行う必要があり、多くの時間が必要になってしまう（正確には、畳み込み演算で多くの領域を再計算するという無駄な計算が発生してしまうことが問題になる）。本開発では、Semantic Segmentationで適用される多くのネットワークの内、ContextNet³⁾、PixelNet⁴⁾、BiSeNet⁵⁾の3つの手法で検知性能の比較を行い、より要求性能に見合うネットワークの選定を行った。

1) ContextNet

ContextNetは2018年に提案された手法であり、低解像度画像+深いネットワークの構造でコンテキストを抽出するネットワークと、高解像度画像+浅いネットワークで細部を抽出するネットワークを組み合わせたモデルである。この二つのネットワークを組み合わせることによって計算量を減らし、高速・高精度なSegmentationを行い、リアルタイム処理を実現している。本手法では、低解像度+深いネットワーク構造により画像全体のコンテキストの認識を担って全体のラベルの作成を行い、高解像度+浅いネットワーク構造が高解像度の入力を受け取り、画像細部の改良を担当している。

2) PixelNet

PixelNetは2017年に提案された手法であり、完全畳み込みニューラルネットワークを始めとする従来の手

法は、畳み込み構造を利用して空間的情報の冗長性を持って特徴を抽出する事により **Segmentation** を行っていた。しかし、このような手法は近傍ピクセル間で抽出可能な情報量を制限してしまうという欠点がある。本手法では、浅いレイヤからの特徴マップを抽出し、それらをチャネル方向に結合した後、複数の畳み込み層を経てヒートマップを再生成することで、バッチ学習における多様性の確保を行っている。マルチケースに特徴抽出を行うことで非線形構造を効率良く抽出し、高品質な **Semantic Segmentation** を実現している。ただし、**PixellNet** は近年使用されている **Semantic Segmentation** モデルと比較し、高精度ではあるが計算量が大きく処理速度が遅いという欠点もある。

3) BiSeNet

BiSeNet は従来の **Semantic Segmentation** において課題であったリアルタイム性と精度のトレードオフを解消する作りとなっており、空間的情報を保持する高品質な特徴マップを生成する **Spatial Path** と呼ばれるネットワークと高速なダウンサンプリング手法により十分な数の受容野を持つ **Context Path** と呼ばれるネットワークを組み合わせた手法である。入力画像に対し **Spatial Path** の3つの畳み込み層によって高品質な空間情報を持った特徴マップを生成し、**Context Path** で様々な注目領域を持つ特徴マップを生成する。これら高次元特徴マップと **Spatial Path** から得られる低次元特徴マップを **Feature Fusion Module** で組み合わせることで高品質な **Semantic Segmentation** を実現できる。

(2) 学習方法

a) 教師データの収集方法

鏡吹付けコンクリート面のクラックをリアルタイムで検知する AI モデルを構築するためには、あらゆるパターンのクラックが記録されている映像を教師データとして用意して学習を行う必要がある。教師データとして最もふさわしいものは実際に検知対象とする鏡吹付けコンクリート面に自然発生したクラック映像であるが、大量に様々なパターンのクラック映像を用意することは困難である。そこで、検知対象とする山岳トンネル現場において鏡吹付けコンクリート面の撮影を行い、そこに想定される様々なパターンのクラックを画像編集ソフトにて描写した疑似クラック画像を作成し教師データとすることで学習を行うこととした。この方法により、大量に必要な教師データを短時間に用意することができ、飛躍的に学習効率を向上させることができる。ただし、この方法で構築された AI モデルは基本的に疑似クラックを学習したモデルであるため、実際に自然発生した鏡吹付けコンクリート面のクラックに対して検知性能を確保していることを確認するために、実際の鏡吹付けコンクリート面にクラックが発生する画像を検証用データとして活用した。



図-2 監視用カメラの設置状況



図-3 撮影した鏡吹付けコンクリート



図-4 崩落前に出現したクラックの例



図-5 学習用の疑似クラックの例

b) 撮影方法

山岳トンネル工事現場において、切羽後方 10m 程度の壁面に設置したアクションカメラで切羽照度 200 lx 程度の条件の下、継続的に鏡吹付けコンクリート面の撮影を行った(図-2, 図-3)。撮影サイズは 3200×1800pixel である。なお、この条件下では 1pixel あたり約 6mm に相当する。

c) 学習方法

本システムで AI モデルを構築するにあたり、教師あり学習によるディープラーニングを採用している。教師あり学習では、収集された教師データを任意の 2 つのグループに分け、1 つを学習に用いる訓練用データとし、もう片方を、テストに用いる検証用データとする。訓練用データで学習したモデルを用いて、検証用データに適用し、その正答率でモデルの精度を評価する。

教師データとして疑似クラックを描写するにあたり、実際に崩落前に認識されるクラックの幅を参考として描写するクラック幅は 1~4pixel とした(図-4, 図-5)。また、背景パターンとして用意した 240 パターンの中で、クラック濃度や形態を変化させたものを作成した。作成した教師データ数は、訓練用データとして 6251 枚、検証用データとして 575 枚である。

(3) 検知性能の検証方法

a) 評価指標

訓練用データで学習した AI モデルを用いて、検証用データに対して解析を行い、その正答率を求めることで検出精度の検証を行う。検証に用いる評価指標を下記に示す。

1) IoU (Intersection over Union)

実際に検出すべき対象部位(教師データ A)

に対して AI モデルによる予測結果(検出データ B)の重なり具合の割合を表す。(IoU=A∩B/A∪B, 図-6)

2) Precision

予測された検出データ B のうち検出すべき教師データ A の割合を表し、この指標が高ければ誤検知が少ないと言える。(Precision=A∩B/B)

3) Recall

検出すべき教師データ A に対し、予測された検出データ B の割合を表し、この指標が高ければ検出漏れが少ないと言える。(Recall=A∩B/A)

b) クラックの検知性能の確認

Semantic Segmentation に用いる最適なネットワークを選定するために、ContextNet, PixelNet, BiSeNet の 3 つの手法で同じ教師データでそれぞれ学習を行ったモデルを作成し、検証用データにおける正答率の検証を行った。それぞれのネットワークが、どの程度のクラック(太さ、不透明度)まで検出できるかに着目して、比較を行った。

c) 実在クラックにおける検知性能の確認

モデルの作成には、疑似クラックを用いた学習を行っているために、実際に鏡吹付けコンクリートに発生する実在クラックに対する検知性能を確認する必要がある。ここでは、鏡吹付けコンクリートに対して、ブレーカ掘削を行う際に、鏡吹付けにクラックが生じて崩壊する状況を撮影した動画に対して、本検証で構築された AI モデルを適用する

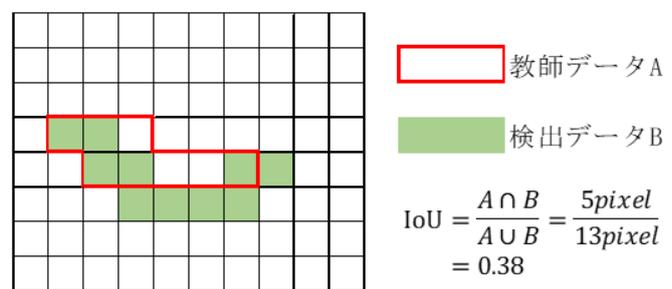


図-6 IoU の計算方法



図-7 クラック検知状況の例

(上: 疑似クラック, 下: 検出状況)

ことで、実際のクラックに対する検出性能の確認を行った。

4. AI モデルの検知性能の検証結果および考察

(1) 教師データの収集方法の有効性

本開発における教師データの収集は、疑似クラックを用いる手法を採用することで、訓練用 6251 枚、検証用 575 枚を 2 ヶ月程度の短時間で用意することができた。また、解析対象とする鏡吹付けコンクリートの撮影には、特別な機器を用いることなく、一般的なアクションカメラを用いて、切羽側面に設置して継続的に撮影を行えることから、映像収集を容易に進めることができた。このように、本学習方法は AI モデルを構築するために常に課題となる教師データの収集効率を飛躍的に高めることができる手法であると考えられる。

(2) クラックの検出性能

画像全体に対して対象物とするクラックは非常に小さい（細い）ため、評価時に検出すべきピクセルを中心に周辺 8 ピクセルの領域を検出対象とするラベル付けを行った。疑似クラックの太さは 1~4pixel、クラック自体の不透明度を 30%、50%、70%に変化させたクラックに対して、IoU、Precision、Recall を算出した。

a) ContextNet を用いた検証結果

ContextNet を用いた検出結果として、検出対象の大きさが 1~4pixel の時の結果を表-1 に、不透明度 30%、50%、70%に対する結果を表-2 に示す。1~4pixel を比較すると各指標において大きな差は見られないが、不透明度 30%、50%、70%に着目すると検出対象の不透明度によって精度が大きく変化していることが分る。不透明度 70%においては、Recall が 0.83 と高いことから検出漏れは少ないが、Precision が 0.46 と低いことから誤検出が多いと考えられる。不透明度 30%においては Precision が 0.16、Recall が 0.13 とほとんど検出できていない。

本結果より、検出対象であるクラックの幅（ピクセル）の違いは検出精度への影響を小さく、クラックの濃さ（不透明度）の違いが検出性能に大きく影響することが分かった。したがって、以下、PixelNet、BiSeNet に対しては、1pixel 程度のクラックを対象して、不透明度を変化させた時の検出性能の違いに着目して検証を行う。

b) PixelNet を用いた検証結果

PixelNet を用いた検証結果を表-3 に示す。ContextNet と比較して IoU、Precision、Recall 全てにおいて高精度であることが分る。ただし、IoU および Recall に関しては、不透明度が小さくなるにつれ検出精度も低くなっている。また Precision に関しては、不透明度の違いに関わらず高くなっている。このことから、誤検知率は低い但不透明度が低くなると検出漏れの発生率が高くなると考えられる。

c) BiSeNet を用いた検証結果

BiSeNet を用いた検証結果を表-4 に示す。本手法も同様に ContextNet と比較して IoU、Precision、Recall 全てにおいて高精度であることが分る。本手法での結果に注目すると、PixelNet と同様に IoU および Recall に関しては、不透明度が低くなるにつれ検出精度も低くなる傾向が認められ、Precision に関しては不透明度の違いに関わらず高くなる傾向が認められる。ただし、PixelNet よりも各数値は相対的に低くなっており、PixelNet の方が高い精度を実現していると考えられる。したがって、機械掘削現場にて鏡吹付けコンクリート面に発生するクラックに対して行う検

表-1 ContextNet のクラック太さ別の精度

クラック幅	IoU	Precision	Recall
1pixel	0.29	0.45	0.46
2pixel	0.32	0.48	0.51
3pixel	0.34	0.49	0.53
4pixel	0.38	0.52	0.58

表-2 ContextNet の不透明度別の精度

不透明度	IoU	Precision	Recall
30%	0.10	0.13	0.16
50%	0.30	0.39	0.58
70%	0.43	0.46	0.83

表-3 PixelNet の精度（1pixel 対象）

不透明度	IoU	Precision	Recall
30%	0.57	0.86	0.63
50%	0.73	0.87	0.82
70%	0.78	0.89	0.86

表-4 BiSeNet の精度（1pixel 対象）

不透明度	IoU	Precision	Recall
30%	0.46	0.72	0.63
50%	0.58	0.74	0.73
70%	0.62	0.76	0.77

証では、PixelNet で構築された AI モデルを使用することとした。

(3) 機械掘削現場での検証結果

機械掘削現場にて鏡吹付けコンクリートが崩落する状況を撮影した映像を用いて、本検証で構築された AI モデルを適用し、実際のクラックに対する検出性能の確認を行った。崩落発生 10 秒前の状況を図-8 に、崩落発生の瞬間を図-9 に示す。このように、疑似クラックを用いて学習した AI モデルでも、実際のクラックに対しても十分に検知精度を確保していることが分かる。また、BiSeNet を用いた Semantic Segmentation により、クラック発生のリアルタイム検知を可能としているため、崩落発生の前兆として発達し始めているクラックを瞬時に識別し、警告を発することも可能になると期待される。



図-8 崩落発生 10 秒前のクラック検知状況



図-9 崩落発生時のクラック検知状況

5. まとめ

肌落ち災害の前兆現象として期待される鏡吹付けコンクリート面のクラックをリアルタイムに検知する AI モデルの開発を行い、以下の知見が得られた。

- (1) 疑似クラックを用いた AI モデルの構築方法は、常に課題となる教師データの収集効率を飛躍的に高めることに寄与する手法である。
- (2) 疑似クラックの教師データで学習した AI モデルでも、実際に発生する鏡吹付けコンクリートのクラックを十分に検知可能な AI モデルを構築することができる。

今後、様々な現場での検証を継続し、肌落ち災害防止に寄与することができれば幸いである。

参考文献

- 1) 厚生労働省：山岳トンネル工事の切羽における肌落ち災害防止対策に係るガイドライン，2018
- 2) 独立行政法人情報処理推進機構：AI 白書，2019
- 3) Rudra PK Poudel, Ujwal Bonde, Stephan Liwicki, and Christopher Zach. Contextnet: Exploring context and detail for semantic segmentation in real-time. arXiv:1805.04554, 2018.
- 4) Changqian Yu, Jingbo Wang, Chao Peng, Changxin Gao, Gang Yu, and Nong Sang. Bisenet: Bilateral segmentation network for real-time semantic segmentation. Lecture Notes in Computer Science, page 334–349, 2018.
- 5) Aayush Bansal, Xinlei Chen, Bryan Russell, Abhinav Gupta, and Deva Ramanan. Pixelnet: Representation of the pixels, by the pixels, and for the pixels. arXiv:1702.06506, 2017.