

ディープラーニングを用いた画像解析による土砂性状判別

Determination of Muck Properties using Image Analysis by Deep-Learning

本間 伸一*¹
Shinichi Honma

森田 順也*¹
Junya Morita

吉迫 和生*¹
Kazuo Yoshizako

本田 和之*¹
Kazuyuki Honda

*¹ 鹿島建設株式会社
KAJIMA Corporation

In the muddy soil pressure balanced shield method, it is necessary to grasp the properties of the muck and to take appropriate measures in order to proceed with stable excavation. Confirming the properties of the muck so far has been done by collecting the muck, performing a slump test, checking with a touching with hand, etc. However, it was dangerous to collect the muck flowing on the belt conveyor. Therefore, the operator sees the image shown on the monitor and discriminates the muck properties. In this study, we tried to determine the muck properties shown in the monitor using image analysis by Deep-Learning such as convolutional neural networks(CNN). Since the possibility of discriminating muck properties can be found by this verification, we will report on the implementation contents and results.

1. はじめに

都市部のトンネル工事などで採用されている泥土圧シールド工法¹⁾では、切羽(掘削面)の安定性を確保するために、掘削土砂の流動性などの性状を把握し、適切な処置を施している。

一般に土砂の流動性の評価は触手で確認するかスランプ試験で実施される。そのためには土砂の採取が必要となるが、今回の工法では掘削土砂がベルトコンベアを通して排出されるため、そこで採取できるとよい。しかし、稼働中のベルトコンベアから土砂を直接採取することは危険を伴い、また、噴発(多量の水と土砂が噴き出す現象)気味の状態になると採取できないこともある。このため、シールドマシンの操作者は土砂排出部のモニター画像から、目視により土砂性状の良し悪しを判断して操作に反映している。

筆者らは、モニター画像に映る土砂性状の目視による判別作業を、ディープラーニングによる画像解析を用いて自動化する可能性について検討を行ったので、以下に報告する。

2. 実験設定

本研究で解析に用いた画像を図1に示す。実際の画像は動画であり、右奥から左手前に映っているベルトコンベア上を土砂が流れる。この画像を解析し、流れている土砂の硬軟(硬い・軟らかい)を判別出来るか否かの検証を行った。



図1 解析画像(実際には動画)

また、画像解析の標準的なステップを図2に示す[Deng 2009][原田 2017]。解析データを収集・加工・整理する「前処理」の後、「データセットの作成」を実施する。次にそのデータセットを用いて「モデル作成」を行い、そのモデルの精度を上げるための「検証」「考察」を経て、最終的にモデルを確定させるといった流れとなっている。

なお、土砂自体の性状判別を対象とした画像解析の研究はほとんどないため、本研究においても同様の解析ステップで評価を進めることとした。



図2 画像解析の標準的なステップ

2.1 前処理

本研究での解析対象は動画画像であるが、動画解析は取扱いが困難であるため、今回の検証では実績のある静止画像での解析とした。そこで、以下の2点を前処理として実施している。

(1) 動画画像を静止画像へ

動画画像は静止画像の集合体であるため、OpenCVを用いたフレーム抽出処理により静止画像へ分割・抽出した。



図3 動画画像データから静止画像データの抽出

(2) 特徴の明確化

分割・抽出した静止画には、今回の判別対象である土砂以外も映っている。そこで、対象としている土砂の特徴を明確化させるために、土砂が映っている部分のみを切り出した画像を生成した。

その画像の切り出しにおいて、映像の手前側は動画の動きが速くなっているため、静止画へ切り出した際に対象をできるだ

連絡先: 本間伸一, 鹿島建設株式会社, 〒107-8348 東京都港区赤坂 6-5-11, Tel/Fax: 03-5544-1457/03-5544-1760, s-homma@kajima.com

1) 泥土圧シールド工法 :http://shield-method.gr.jp/construction-method/cm_ol_dk/

け認識可能となる部分を考慮し、本研究では静止画像の中央にある 64×64pixel の部分に着目・切り出しを行なった。




図 4 判別対象部分の切り出し

2.2 データセット作成

前処理で生成した静止画像に「硬い」「軟らかい」の分類項目をラベリングし、クラス分けを実施した。ただし、実際にはベルトコンベア上に対象物が存在しない画像もあったため、この画像は「対象物なし」の分類項目をラベリングした。結果として 3 つの分類項目にクラス分けしたデータセット(各ラベリング 300 枚ずつの計 900 枚のデータセット)を作成した。なお、分類の判断として、比較的大きな塊が映っている画像を「硬い」、細かく崩れているような土砂が映っている画像を「軟らかい」としてラベリングした。



図 5 ラベリングの一例

2.3 モデル作成

本研究では 2 種類の手法で判別モデルの作成を実施した。

(1) サービスを利用する手法

モデル作成が自動化されているサービスを利用する手法であり、今回は Microsoft Azure の Custom Vision Service を利用した。モデル作成で実施するデータ登録から作成実行といった全ての処理が、ドラッグアンドドロップやクリックなどのシンプルなマウス操作だけで可能となっている。




図 6 サービスを利用したモデル作成(Custom Vision)

非常に手軽で容易にモデルを作成することができるが、そのモデル作成のロジックが非公開であるため、細かな調整が出来ない、かつシステムへの組み込みには手間を要するなど、自由度が低いことも特徴の一つである。

(2) オープンソースを利用する手法

独自に環境構築・プログラミングすることによりモデルを作成する手法で、今回はオープンソースとして TensorFlow、ニューラルネットワークライブラリとして Keras、そして画像解析に適した CNN(Convolutional Neural Network)[Krizhevsky 2012]などを利用した。プログラミングを必要とするため、サービスを利用した手法よりも困難に感じるが、各種のリソースがインターネット上に多数公開されているため、上手く取得・活用することでプログラミ

ングの手間を軽減することが出来、比較的容易にモデルを作成することが可能である。

今回用いた CNN 構造の概要を図 7 に示す。




図 7 CNN 構造

実際には CNN 層や全結合層の数、各種のパラメータ(ハイパーパラメータ)を変化させ、多種多様なモデルを作成した。この各種設定の変更が可能であることから、サービスを利用したモデル作成と比べて自由度が高くなっている。

3. 実験結果

3.1 クラス判別正答率

今回はデータセット(900 枚)の 1 割(各ラベリング 30 枚ずつの計 90 枚)をテストデータとして作成したモデルの判別結果を確認した。なお、3 分類の判別であるため、Confusion Matrix として結果をまとめている。表 1 にサービス利用パターンによって作成されたモデルの判別結果、表 2 にオープンソース利用パターンによって作成されたモデルの判別結果を示す。

表 1 サービスを利用した手法の判別結果

		正解		
		硬い	軟らかい	対象物なし
予測	硬い	27	4	0
	軟らかい	2	18	6
	対象物なし	1	8	24

判別精度: 76%(69/90)

表 2 オープンソースを利用した手法の判別結果

		正解		
		硬い	軟らかい	対象物なし
予測	硬い	29	13	0
	軟らかい	0	15	11
	対象物なし	1	2	19

判別精度: 70%(63/90)

いずれの結果においても、「硬い」の判別精度が比較的高いことが分かる。このことから「硬い」の画像には判別し易い何らかの特徴が存在することが想定される。一方、「軟らかい」の判別精度は他の分類と比較して低くなっている。これは静止画からは「軟らかい」の特徴が捉えにくく、「軟らかい」の判別が曖昧なってしまったことが原因の一つではないかと推測する。

3.2 パラメータによる正答率の変化

オープンソースを利用したモデル作成の場合にはパラメータを変化させることで作成されるモデルが変化し、判別の精度にも影響する。

図 8 に、学習データで作成されたモデルの正答率(青線)とテストデータに対するモデルの正答率(オレンジ線)がパラメータによって変化していることを示す。青線にオレンジ線が近似するほ

どに精度の良いモデルということになる。そのようなモデルを作成できる最適なパラメータを設定すれば良いのだが、このパラメータの最適値を求める手段は確立していない。そのため、試行錯誤で模索するしかないのが現状である。




図 8 パラメータの違いによる正答率の変化

なお、最近では最適なパラメータ値の選出を自動化させる研究も進められている。

4. まとめ

本研究の結果により、ディープラーニングの画像解析による土砂性状判別の可能性が見出せた。しかしながら、

- 今回の判別精度としては 70%程度であること
- クラス判別の精度に偏りが生じていること

から、実用化に向けては目標とする精度を明確にし、それに近づけるための更なる精度向上を図る必要があると考えている。

また、今回の結果から、解析の各ステップにおける課題や留意事項も認識できた。一例としてはデータオーグメンテーションなどの技術活用によるデータ不足の解消や高解像度のカメラを用いての画質向上などが挙げられる。今後は新たに開始される工事でのデータ収集や撮影環境の見直しなど、その対策や改良・改善を実施していき、精度向上を図りたい。

参考文献

- [Deng 2009] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. and Fei-Fei, Li.: ImageNet: A Large-Scale Hierarchical Image Database, CVPR, 2009.
- [原田 2017] 原田達也: 機械学習プロフェッショナルシリーズ「画像認識」, 講談社, 2017.
- [Krizhevsky 2012] Krizhevsky, A., Sutskever, I. and Hinton, E., : ImageNet Classification with Deep Convolutional Neural Networks, NIPS, 2012.