

コンクリート荷卸し時の画像による品質管理に関する研究

(株)大林組	正会員	○山本	哲
	フェロー会員	新村	亮
	正会員	田中	将希
(株)日立ソリューションズ		谷中	郁哉

1. はじめに

コンクリートを打設する際は、充填不良の原因となる、ワーカビリティの低下したコンクリートを、排除することが重要である。コンクリートのワーカビリティの管理は 20~150m³ 毎に、荷下ろし時のスランブ試験により行われる。さらに荷卸し時に随時、コンクリートのワーカビリティを技術者が目視で確認する必要がある¹⁾。しかし、スランブ試験は抜き試験であり、スランブ試験間の品質変動を把握することは難しい。また、目視による確認には、技術者の経験が必要となる。本研究ではコンクリート荷卸し時に、アジテータ車のシュート上のコンクリートの流動状況画像から、AIの深層学習によりスランブ推定を行った。

2. AI の深層学習によるスランプ推定方法

2. 1 荷卸し状況のコンクリートの画像撮影方法

アジテータ車のシュート上のコンクリートの流動状況の撮影には汎用のタブレットを使用した。動画は1080pHD、30fpsで撮影した。図-1に撮影状況を示す。カメラはシュート正面に三脚を立て、高さ1.8m程度にカメラを固定した。表-1に撮影ケースを示す。経時変化画像の撮影では、ポンプ車から荷卸したコンクリートを、アジテータ車のホッパーに圧送し、2時間程度循環させた。その際、スランプが経時変化したコンクリートの流動状況を、15分ごとに2分間撮影し、同時にスランプを測定した。現場画像の撮影では、土木工事現場のコンクリート荷卸し状況を撮影した。なお、現場撮影の際は日除けを行っていない。

2. 2 スランプ推定方法

動画から切り取った静止画を AI に学習させ、その際のスランプを教師データとして、スランプの推定を行った。図-2 に画像の切り取り位置と前処理方法を示す。画像は、アジテータ車のシュート排出口付近と中央部の 2 箇所から切り取った。画像のサイズは、前者は推定精度の高い AI の解析条件 (300×500pixel) で、後者は 150×150pixel で検討した。また、切り取った画像は色調の影響を排除し、凹凸を強調するために、グレイ化、ヒストグラム均一化処理を行った。AI 開発にはオープンソースソフトウェアの Keras、Tensorflow を使用し、スランプ (連続値) を回帰推定した。推定精度は式(1)に示す、平方根平均二乗誤差 RMSE で評価した。




図-1 撮影状況

表-1 撮影ケース

撮影分類	工場	画像名	配合	スランプの範囲	撮影日
経時変化撮影	A	A-1	30-12-20N	17.5～7.5	2/7
		A-2	30-18-20N	17.5～10.5	2/8
	B	B-1	30-12-20N	17.5～4.5	5/15
		B-2	30-12-20N	13.0～5.5	9/20
現場撮影	C	C	36-15-20N	15.0～16.5	5/9
	D	D	21-12-20N	11.5～12.5	11/1

$$\text{RMSE} = \sqrt{\frac{1}{N} \{ \sum (\hat{x}_i - x_i)^2 \}} \quad \text{式(1)}$$

N : 推定値の数、 $\hat{x}_i$: 推定値、 x_i : 測定値

3. 推定結果と考察

3. 1 AI の解析条件の検討

表-2 に AI の解析条件を検討した結果を示す。学

キーワード AI、画像処理、コンクリート、スランプ、深層学習、品質管理

連絡先 〒108-8502 東京都港区港南 2-15-2 (株) 大林組生産技術本部 TEL 03-5769-1322

習・推定には同配合、同一工場でシュート排出口付近の画像を使用した（学習：B-1、推定：B-2）。検討結果より、画像のサイズを比較すると 300×500pixel のとき精度が最も高くなった。また、コンクリートの排出方向が逆の場合は精度が低下し、排出速度については、精度に与える影響が小さかった。以上より、AI の解析条件により、精度が変動するため、最適な条件で検討する必要があると考えられる。

3. 2 各種学習・推定データの組合せ検討

表-3 に学習・推定データの組合せ検討結果を示す。また図-3 に、一例としてケース⑥⑦の排出口付近画像を用いたスランプ推定結果を示す。表-3 から、経時変化画像を使用した場合、学習・推定に④同一コンクリート、⑦同一工場の同配合、および⑧複数工場の多種配合のケースは、比較的精度は高くなったが、⑤同一工場の異配合、⑥異工場の同配合を用いたケースでは精度は低くなった。また、現場画像データを推定する場合には、⑨経時変化画像のみで学習したケースは精度が低かったが、⑩経時変化画像と一部の現場画像を学習したケースでは精度が向上した。加えて、中央付近の画像に比べて排出口付近の画像を使用した方が推定精度はやや良好な結果を示した。以上より、スランプが同じコンクリートでも、配合や工場が異なることで、表面形状が異なるためスランプの推定精度は高くないと考えられる。しかし、現場でのスランプ推定を行う場合には、現場画像を学習させることで精度が向上する可能性がある。また、排出口付近では、コンクリートが広がり、スランプの特徴が明確に表れるため、精度が向上すると考えられる。

4. まとめ

シュート上を流れるコンクリートの画像を用いた AI によるスランプ推定では、AI の解析条件が解析精度に大きく影響した。また、同配合、もしくは現場で使用したコンクリートの画像を学習に使用することで、推定精度を向上できる可能性が確認された。今後は、更に画像データを蓄積し、スランプの推定精度を高める予定である。

参考文献

- 1) 土木学会：2017 年制定コンクリート標準示方書 [施工編]、pp.203-206、2017



図-2 画像の切取り位置と前処理方法

表-2 AI の解析条件の検討結果

ケース	学習・推定 画像サイズ (pixel)	推定画像の 排出方向	推定画像の 排出速度	RMSE (cm)
①画像のサイズ	300×500	左	速い	1.40
	150×150	左	速い	3.13
	75×75	左	速い	4.07
②推定画像の向き	300×500	右	速い	3.26
③推定画像の排出速度	300×500	左	遅い	1.52

表-3 学習・推定データの組合せ検討結果

分類	ケース	学習 画像	推定 画像	RMSE (cm)	
				中央	排出口
学習・推定 に経時変化 画像を使用	④同一コン クリート	B-1	B-1	1.69	—
	⑤同一工場 の異配合	A-2	A-1	3.47	3.21
	⑥異工場の 同配合	B-1	A-1	3.99	4.22
	⑦同一工場 の同配合	B-1	B-2	2.06	1.40
	⑧複数工 場・多種配 合で学習	A-1 A-2 B-1	B-2	2.25	1.48
現場画像を 使用	⑨経時変化 画像を学習	A-1 A-2 B-1	D	-	4.38
	⑩経時変化 と現場画像 を学習	A-1 A-2 B-1 C	D	-	2.01




図-3 排出口付近のスランプ推定結果の一例