

AI 技術を用いたフレッシュコンクリートのスランプ予測

太平洋セメント(株) 正会員 ○早野 博幸 工藤 正智
パシフィックシステム(株) 尾崎 奨 大木 宗一

1. はじめに

生コン工場の製造工程においては、現状、オペレータが主にミキサ練混ぜ時のコンクリートの動きと、ミキサ電力負荷値を目視で確認し、経験と勘によってスランプの管理をしながら出荷を行っている。これを、人間の判断に頼るのではなく、機械的かつ定量的に判断できれば省力化につながるものと考えられる。そこで、本研究ではこの工程に AI 技術を適用し、コンクリートの練混ぜ時における動画から、瞬時にスランプの予測を行うことができる技術の構築を目指し、実験的な検討を行った。

2. 実験概要

W/C60%のコンクリートを目標スランプ 3 水準設定し(8, 12, 18cm)、同じ配合で 10 バッチずつ計 30 バッチ練り混ぜ、スランプと空気量を測定した。練混ぜはできるだけ生コン工場に近くなるように 2 軸ミキサ(容量 60L)を用い、練混ぜ中の動画を上部からビデオカメラで撮影し、ミキサの電力負荷値をモニタリングした。

AI 解析は、1)練混ぜ画像の抽出、2)深層学習(ディープラーニング)モデルの構築、3)検証の手順で実施した。

1)練混ぜ画像の抽出では、練混ぜ開始から終了までの動画で、どの時期を、どれくらいの期間、どの領域を解析対象とするかが重要である。解析対象時期については、今回はミキサ電力負荷値が安定し始めた注水 60 秒後、120 秒後の 2 水準とした。期間については、動画は 30 フレーム/秒で構成されており、上記時期においてそれぞれ 5 秒間(150 フレーム)、15 秒間(450 フレーム)とした。最も重要な領域(場所)については、図-1 に示すように、2 軸ミキサの羽根が外から回ってきてコンクリートをかき上げる部分の中央部 $256 \times 256 \text{pixel}$ を抽出した。各フレームで抽出したこの静止画像を、縦横 4 等分($64 \times 64 \text{pixel}$)して計 16 枚とした場合、そのまま $256 \times 256 \text{pixel}$ の大きさに縦横 5pixel ずつ移動させ異なる画像を 25 枚とした場合の 2 水準とした。

2)深層学習モデルの構築では、2Step に分けて検討した。Step1 画像分類モデルの構築では、スランプ 3 水準の各画像を入力してそれぞれのスランプの特徴を学習させる画像認識を行い、最終的に 8, 12, 18cm に分類するモデルを構築した。これが可能であれば、練混ぜ画像にスランプ値を推定できる特徴が含まれていることになる。Step2 回帰予測モデルの構築では、練混ぜ画像を入力し、スランプ値自体を予測するモデルの構築を行った。具体的には、スランプを y 、画像を変数 x とした回帰式を作成するもので、この式は極めて複雑な式となる。学習ライブラリとしては Google 社で開発されオープンソースとして公開している TensorFlow を使用した。

3)検証では、構築した学習モデルを用い、学習モデルで使用していない別のバッチのコンクリートの画像を使用し、モデルの妥当性を正解率によって検証した。




図-1 画像の抽出方法

3. 実験結果および考察

スランプ 3 水準における実測値を表-1 に示す。目標値 $\pm 2.5 \text{cm}$ の範囲に実測値は入っているが、やや目標値に対して上下に振れている。また、ミキサの羽根を同じ位置とした場合の練混ぜ画像の一例を図-2 に示す。

60 秒後の電力負荷値平均(5 秒間)と実測スランプの関係を図-2 に示す。18cm の負荷値は小さいが、8, 12cm

表-1 スランプ 3 水準の実測値

目標値	実測スランプ (cm)				
	8.0	8.5	8.5	9.5	10.0
8.0cm	10.5	10.5	9.5	9.0	9.5
	12.5	12.5	14.0	12.0	13.0
12.0 cm	14.0	12.5	12.5	13.0	12.5
	17.5	18.0	17.0	18.0	18.5
18.0 cm	19.0	19.0	18.5	19.0	18.0

は同じような範囲となり、スランブと電力負荷値には本試験結果からは明確な関係は認められない。

3. 1 Step1 画像分類モデル

検証結果の一例を表-2 に示す。①画像サイズが 64pixel の場合の正解率は 51%と低い、②256pixel に大きくした場合は正解率が大幅に向上した。③画像取得時間(学習画像数)を 3 倍にすると正解率が若干上昇、④学習回数を 2 倍にすると正解率は 92%と高い結果になった。個々のスランブの正解率は、8cm : 86%、12cm : 91%、18cm : 99%であり、8cm は他より低くなった。これには明確な理由があり、各 3 バッチずつ用いた学習用画像と検証用画像について、12cm および 18cm では表 1 に示す学習用 (灰色)と検証用(黒色)はほぼ同じスランブとなっているのに対し、8cm ではやや差異がみられる傾向となっており、この点が正解率に影響しているものと推察される。学習画像数と学習回数をさらに増やすことで正解率はさらに上昇すると考えられ、本結果より練混ぜ画像にはスランブ予測に繋がる特徴が含まれているといえる。

3. 2 Step2 回帰予測モデル

本検討では、画像サイズ、取得時期・時間は画像分類モデルの最も正解率が高い条件とした。学習用画像は 8.5、12.5、18.0cm のスランブ各 2 バッチ、検証用画像は学習用で使用していない 9.0、10.0、12.5、13.0、14.0、17.0、18.0cm を各 1 バッチ使用し、目標スランブ 3 水準の間についても予測できるか検証した。その結果、実測値 ± 1.0 cm 以内で予測できた場合を正解とすると正解率は 54%、 ± 1.5 cm 以内の場合の正解率は 75%と低い値となった。これは、学習用画像がスランブ 3 水準のみとしていることから、学習用データが不足していると考えられ、8、12、18cm の間を補完するように、9.5、10.5、13.0、14.0cm を 2 バッチずつ増やし、検証用画像を各 1 バッチずつとした。

検証結果の正解率を表-3 に示す。実測値 ± 1.0 cm 以内の正解率は 91%、 ± 2.5 cm 以内では 99%の高い正解率を得た。今回は限られた 30 バッチのデータを有効利用した結果で、例えば 8~18cm の 1cm 間隔など細かく各スランブの画像データを用いることにより、さらに精度が高い予測を行うことができる。

また、上記正解率は実験上、1 枚の画像のみでスランブを予測した検証結果である。実際の工場での運用時においては、図-3 に示すように練混ぜ中の動画から複数の連続した静止画を随時取得して瞬時に予測できるため、例えば明らかに他と異なる値を予測したエラーデータを排除したり、移動平均などを採用することで、正解率はさらに上がることが期待できる。本検証で使った各バッチの全画像 4050 枚の予測の平均値は、実測値 ± 1.0 cm 以内になっており、各バッチごとにスランブ予測した場合の正解率は 100%となった。

4. まとめ

コンクリートミキサの練混ぜ画像には、スランブ予測に繋がる特徴が含まれており、AI の深層学習モデルを構築することで、スランブを予測することが可能である。今後は、工場の実機ミキサにおいて本技術の有効性を検証する予定である。




図-2 電力負荷値とスランブの関係

表-2 画像分類による検証結果の一例

No.	画像サイズ (pixel)	画像取得時期 ／時間	学習 画像数	学習 回数	正解率
①	64 × 64	120 秒／5 秒間	17,280	10,000	51%
②	256 × 256	60 秒／5 秒間	27,000	10,000	86%
③	256 × 256	60 秒／15 秒間	81,000	10,000	88%
④	256 × 256	60 秒／15 秒間	81,000	20,000	92%

表-3 回帰予測モデルによる正解率

スランブ許容範囲	± 1.0 cm	± 1.5 cm	± 2.0 cm	± 2.5 cm
正解率	91%	96%	98%	99%




図-3 生コン工場での運用イメージ

キーワード AI, ディープラーニング, コンクリート, スランブ, 予測, 練混ぜ

連絡先 〒285-8655 千葉県佐倉市大作 2-4-2 太平洋セメント (株) 中央研究所 TEL043-498-3902