

AI 技術を活用したコンクリートと使用材料の品質予測

市川翔太郎・瀬川実暉・板橋庸行・玉滝浩司・高原幸之助

レディーミクストコンクリート工場における工程検査の効率化を目指し、ニューラルネットワークの手法やハイパースペクトルカメラを活用することで、コンクリートのフレッシュ性状（スランプ、スランプフロー、空気量）、骨材の表面水率および粗粒率の予測に取り組んだ。その結果、フレッシュ性状の予測では、スランプの許容差を $\pm 2.5\text{cm}$ 、スランプフローの許容差を $\pm 7.5\text{cm}$ 、空気量の許容差を $\pm 1.5\%$ とした場合、各試験値の正解率は90%程度となり高い精度で予測できた。また、骨材の表面水率および粗粒率は、室内の一定な条件下では予測値と実測値の差が小さく、精度良く予測できることがわかった。

キーワード：ニューラルネットワーク、工程検査、フレッシュ性状、表面水率、粗粒率

1 緒言


レディーミクストコンクリート業界は、技術者の高齢化や若手人材の不足が深刻である。そのうえ、出荷量も漸減する状況が続いており、厳しい経営環境にある。また、良質な骨材の確保が難しくなるなか、コンクリートの品質安定化は、顧客への品質保証と信頼性向上の面で重要である。こうした状況下で、より少ない人員で効率的に製造を行い、安定した品質のコンクリートを出荷することが事業を維持するための重要な課題となっている。

一方で昨今、AI (AI: Artificial Intelligence) 技術を活用することにより様々な業界で DX (DX: Digital Transformation) が進められており、レディーミクストコンクリート業界においても DX 推進の機運が高まっている。例えば、工場で製造したコンクリートに関連するデータを収集し、材料・配(調)合、製造および運搬条件に関連する数値データから、ディープニューラルネットワークを用いて、荷卸し時のスランプを製造時に予測する手法について検討した事例⁽¹⁾や、レディーミクストコンクリート工場の試験室業務の簡素化・自動化に向けた取組みとして、AIを用いてコンクリートの配合を導出する事例⁽²⁾などがある。

そこで本報では、レディーミクストコンクリート工場における工程検査に着目し、AI 技術を活用してレディーミクストコンクリートのフレッシュ性状、ならびに、骨材の表面水率および粒度の予測可否を検討した結果について報告する。

2 レディーミクストコンクリート工場の現状

図1に都市部のあるレディーミクストコンクリート工場における品質管理業務の人工調査結果を示す。調査の結果、自主的に実施する工程検査に多くの人員と時間を要していることがわかった。JIS Q 1011 附属書 A では、例えば、細骨材の粗粒率、粗骨材の粗粒率又は実積率は1回以上/週、細骨材の表面水率やコンクリートのフレッシュ性状は1回以上/午前、1回以上/午後測定することが規定されている。しかし、生産工場では安定した品質のコンクリートを出荷するため、最低限の検査頻度より多くの検査を自主的に行っているケースが多く、これが工程検査の人工割合を高める要因となっている。



※ 2020年に当社が実施した調査結果による。

図1 都市部のレディーミクストコンクリート工場における品質管理業務の人工

3 コンクリートのフレッシュ性状予測

3.1 データの取得方法

表 1 に品質予測で使用した入力データを示す。使用材料および配合条件に関するデータは、製造記録、配合計画書、計量印字記録から取得した。練混ぜ条件に関するデータは、工場のスランブ管理システムから取得した。画像情報はカメラモジュールにより取得した。振動情報は、コンクリートの落下・流下に起因する積込みホップの振動を 3 軸加速度センサにより 0.5 秒おきに取得した。

本実験では、(1) 画像情報のみを使用、(2) 画像情報と振動情報を併用、(3) 全データ項目を使用、の 3 ケースを比較して検討を行った。

3.2 予測方法および評価方法

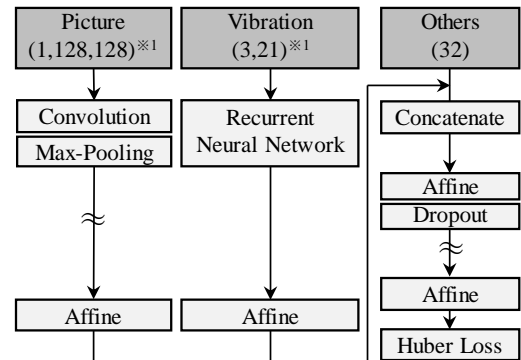
図 2 にニューラルネットワークの構成概要を示す。画像情報を使用する場合には畳み込みニューラルネットワーク (Convolutional Neural Network; 以下、CNN) を、振動情報を使用する場合には再帰型ニューラルネットワーク (Recurrent Neural Network; 以下、RNN) を使用した。CNN は主に画像認識の分野で活用され、RNN は音声や文章などの時系列データの学習に使用される。損失関数には Huber 関数を使用した。重みの最適化には、エポック数を 2,000、バッチサイズを 100 とし、最適化アルゴリズムに Adam を使用したミニバッチ勾配降下法を適用した。学習に際し 24,200~28,200 個の学習用の入力データセットと、4,850~5,150 個の評価用の入力データセットを準備した。予測モデルの評価には評価用の入力データセットを使用し、全データセット数に対する所定の許容差の範囲内に収まったデータセット数の割合を正解率として評価した。

3.3 検証結果

図 3 に各種フレッシュ性状の許容差と正解率の関係を示す。スランブおよびスランブフローの正解率

表 1 品質予測で使用した入力データ

| 分類 | データ項目 |
|-----------|---|
| 使用材料 | セメント種類 (N、BB、M、L、SFC)、 混和剤種類 (AD、SP)、材料密度、 表面水率の設定値 |
| 配合条件 | 呼び強度、水セメント比 (または水 結合材比)、細骨材率、単位量、混和 剤添加率 |
| 練混ぜ 条件 | 練混ぜ量、練混ぜ時間、ミキサ電力 負荷値 (初期値、最大値、終局値)、 気温 |
| 画像情報 | 積込みホップ内を流下するフレッシュ コンクリートの画像 |
| 振動情報 | 積込みホップ側面部の加速度データ (時系列データ) (x、y、z 軸) |



※1 画像情報は (色数, 高さ, 幅)、振動情報は (軸数, 時刻データ数) のフォーマットで指定する。

図 2 ニューラルネットワークの構成概要




図 3 各種フレッシュ性状の許容差と正解率の関係

は、画像情報だけを使用したモデルと比べ、画像情報と振動情報を併用したモデルの方が高い結果となり、全データを使用することで更に正解率は向上した。空気量の正解率は、許容差±0.5%の場合を除き、画像情報だけを使用したモデルと比べ、画像情報と振動情報を併用したモデルの方が高かった。JIS A 5308 に規定される許容差 (スランプ : ±2.5cm、スランプフロー : ±7.5cm、空気量 : ±1.5%) で判定した場合、全データを使用したモデルの正解率は約 90% であった。

4 細骨材の表面水率予測

ここでは、ハイパースペクトルカメラを使用し、反射光スペクトルの特性から細骨材の表面水率の予測可否を検討した。

4.1 データの取得方法

表 2 に本実験で使用した細骨材の概要を示す。各細骨材の表面水率は、0~7%の範囲とし、0.5%刻みで調整した。細骨材と水を混合し調整した後、ポリ袋内で密閉し、20°Cの室内で1日間静置させた細骨材を試料とした。

試料の撮影には、ラインスキャン型のハイパースペクトルカメラを使用した。写真 1 にハイパースペクトルカメラによる撮影状況を示す。容器 (内寸 : 200×200×15 mm) に試料を移し、ならし定規で試料の表面を均した後、可動ステージの上に静置した。その後、上方からハロゲンランプを試料に照射させた状態で、可動ステージを移動させ撮影を行った。なお、試料が乾燥しないよう、ポリ袋の開封から撮影までの時間を 30 秒以内とした。

4.2 予測方法および評価方法

予測方法には二次関数による最小二乗法を適用した。まず、取得したスペクトル画像を 9 つの領域に分割し、各領域における全 164 波長の反射光強度の平均値を取得した。その後、式 [1] により領域ごとに予測指標 I を算出し、9 つの予測指標 I のうち、7 つを予測式作成用データとして、2 つを評価用データとして取得した。この操作を各表面水率に応じて実施し、計 105 個の予測式作成用データと、計 30 個の評価用データを使用した。

$$I = (S_{1363nm} - S_{1413nm}) / S_{1413nm} \quad [1]$$

ここに、 I : 予測指標

S_{1363nm} : 1363nm での反射光強度の平均値

S_{1413nm} : 1413nm での反射光強度の平均値

式[1]の作成にあたっては、スペクトルデータの変曲点付近である 1363nm および 1413nm の 2 波長を選定した。なお、多項式適合法 (Savitzky-Golay 法) によりスペクトルデータを二次微分し、得られた二次微分値のピークが変曲点である。

予測モデルの評価には、計 30 個の評価用データを使用し、式 [2] に示す二乗平均平方根誤差 (Root Mean Squared Error ; 以下、RMSE) により評価を行った。RMSE は、値が小さいほど予測精度が高いことを意味するものである。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad [2]$$

ここに、 N : 評価用の入力データ総数

y_i : 予測値

t_i : 実測値

表 2 実験で使用した細骨材の概要

| 種類 | 産地 | 物性値 | 外観※1 |
|----------|-------------|---|---|
| 山砂 | 千葉県 君津市 | 表乾密度 : 2.59g/cm ³ 吸水率 : 1.82% |  |
| 石灰石 | 福岡県 北九州市 | 表乾密度 : 2.69g/cm ³ 吸水率 : 0.75% |  |
| 硬質 砂岩 | 茨城県 桜川市 | 表乾密度 : 2.60g/cm ³ 吸水率 : 1.24% |  |
| 安山岩 | 山梨県 大月市 | 表乾密度 : 2.61g/cm ³ 吸水率 : 2.99% |  |

※1 絶乾状態における細骨材の外観。



写真 1 ハイパースペクトルカメラ撮影状況

4.3 実験結果

図4に骨材種類別の予測指標 I と表面水率の関係を示す。いずれの細骨材でも予測指標 I と表面水率には強い相関があることが確認されたが、骨材の種類によってその関係は異なることがわかった。

図5に骨材種類別のRMSEおよび明度 (L^* 値) を示す。RMSEは、石灰石、山砂、硬質砂岩、安山岩の順で小さく、細骨材の種類によって予測精度が異なった。また、表面水率が0%の各種細骨材の明度とRMSEを比較した場合、細骨材の明度が高いほどRMSEが小さい結果となった。本実験でのハイパースペクトルカメラによる細骨材の表面水率の予測精度には、細骨材の明度が影響することがわかった。

けされた骨材を計量および混合して使用した。




図4 骨材種類別の予測指標 I と表面水率の関係

5 粗骨材の粒度予測

5.1 データの取得方法

使用した骨材の種類は、硬質砂岩および石灰石の2種類とした。2つの骨材は単独で使用することを想定し、それぞれの粗骨材の画像データを学習に使用した。また、粗骨材は所定の粒度分布もしくは粗粒率になるように調整して使用した。

撮影にはデジタルカメラを使用し条件に応じてLED照明を併用した。黒色ゴムシート上に8kgの気乾状態の粗骨材を敷き並べて撮影する操作を1水準につき10回行った。撮影は一定の高さから行った。

5.2 検討要因とその水準

表3に粗骨材粒度の水準を示す。粗骨材が所定の粒度になるように、粒度区分ごとに事前にふるい分

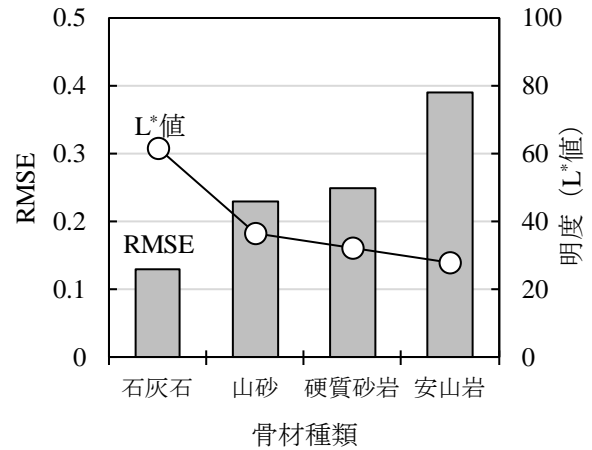


図5 骨材種類別のRMSEおよび明度 (L^* 値)

表3 粗骨材粒度の水準

| | 質量比率 (%) | | | | 粗粒率 F.M. | | 質量比率 (%) | | | | 粗粒率 F.M. | | 質量比率 (%) | | | | 粗粒率 F.M. |
|----------|------------|------------|-----------|----------|-------------|----------|------------|------------|-----------|----------|-------------|----------|------------|------------|-----------|----------|-------------|
| | 1.2-2.5 mm | 2.5-5.0 mm | 5.0-10 mm | 10-20 mm | | | 1.2-2.5 mm | 2.5-5.0 mm | 5.0-10 mm | 10-20 mm | | | 1.2-2.5 mm | 2.5-5.0 mm | 5.0-10 mm | 10-20 mm | |
| Series 1 | 0 | 0 | 15 | 85 | 6.85 | Series 2 | 2 | 5 | 8 | 85 | 6.76 | Series 3 | 4 | 8 | 8 | 80 | 6.64 |
| | 0 | 0 | 20 | 80 | 6.80 | | 2 | 5 | 13 | 80 | 6.71 | | 4 | 8 | 13 | 75 | 6.59 |
| | 0 | 0 | 25 | 75 | 6.75 | | 2 | 5 | 18 | 75 | 6.66 | | 4 | 8 | 18 | 70 | 6.54 |
| | 0 | 0 | 30 | 70 | 6.70 | | 2 | 5 | 23 | 70 | 6.61 | | 4 | 8 | 23 | 65 | 6.49 |
| | 0 | 0 | 35 | 65 | 6.65 | | 2 | 5 | 28 | 65 | 6.56 | | 4 | 8 | 28 | 60 | 6.44 |
| | 0 | 0 | 40 | 60 | 6.60 | | 2 | 5 | 33 | 60 | 6.51 | | 4 | 8 | 33 | 55 | 6.39 |
| | 0 | 0 | 45 | 55 | 6.55 | | 2 | 5 | 38 | 55 | 6.46 | | 4 | 8 | 38 | 50 | 6.34 |
| | 0 | 0 | 50 | 50 | 6.50 | | 2 | 5 | 43 | 50 | 6.41 | | 4 | 8 | 43 | 45 | 6.29 |
| | 0 | 0 | 55 | 45 | 6.45 | | 2 | 5 | 48 | 45 | 6.36 | | 4 | 8 | 48 | 40 | 6.24 |
| | 0 | 0 | 60 | 40 | 6.40 | | 2 | 5 | 53 | 40 | 6.31 | | 4 | 8 | 53 | 35 | 6.19 |

表 4 に検討要因とその水準を示す。基準となる条件は、粗骨材粒度が Series1 (過小粒含まず)、粗粒率の予測方法が 5.3 で後述する直接予測、粗骨材の種類が硬質砂岩、撮影環境が室内灯、画像サイズ比が 0.25 とした。特に指定がない場合は、基準となる条件で実験を行ったものとする。

5.3 予測方法および評価方法

機械学習には CNN を使用した。損失関数には Huber 関数を使用した。重みの最適化には、エポック数を 5,000、バッチサイズを 10 とし、最適化アルゴリズムに Adam を使用したミニバッチ勾配降下法を適用した。

入力データには所定のサイズに調整した RGB 画像を使用した。学習方法は、粒度区分 (粒径 2.5 mm 以下、2.5~5.0 mm、5.0~10 mm、10~20 mm) ごとの質量比率および粗粒率を予測値として同時に出力する、マルチタスク学習とした。粗粒率の予測方法は、直接的に粗粒率を出力する方法 (以下、直接予測) と、出力された粒度区分ごとの質量比率を用いて間接的に粗粒率を算出する方法 (以下、間接予測) の 2 種類とした。

学習用の入力データには 80 枚/series の画像を使用した。事前に画像の上下左右を反転させてデータ数を拡張した。予測モデルの評価には、評価用の入力データとして 20 枚/series の画像を使用し、4.2 で前述した式 [2] に示す RMSE により評価を行った。

5.4 実験結果

図 6 に粗骨材粒度別の実測値と予測値の関係を示す。粒径が 5mm 以下の過小粒を含まない条件 (Series1)、過小粒を含む条件 (Series1~3) のいずれにおいても、粗粒率の予測値の全てが目標とする許容差 ± 0.10 の範囲内に収まることを確認した。したがって、過小粒の有無によらず粗骨材の粗粒率を精度良く予測できることがわかった。

図 7 にそれぞれの予測方法での予測精度 (RMSE) を粗骨材の種類別に示す。直接予測と間接予測の予測精度に明確な差異は認められず、いずれの方法でも精度良く予測できた。また、粗骨材の種類に関して、硬質砂岩と石灰石を比較しても明確な差異は見られず、骨材の種類によらず精度良く予測できた。

図 8 に予測精度に影響を及ぼす画像サイズ比の影響を撮影環境ごとに示す。撮影環境による予測精度の違いについて、LED 照明を併用した場合は室内灯

表 4 検討要因と水準

| 検討要因 | 水準 |
|----------------------|---|
| 粗骨材粒度 | Series1 ^{※1} 、Series1~3 |
| 粗粒率の予測方法 | 直接予測 ^{※1} 、間接予測 |
| 粗骨材の種類 | 硬質砂岩 ^{※1} 、石灰石 |
| 撮影環境 | 室内灯 ^{※1} 、室内灯+LED 照明 |
| 画像サイズ比 ^{※2} | 1.0、0.75、0.50、 0.25 ^{※1} 、0.125 |

※1 太字は基準となる条件。

※2 1024×756 pixel の画像を 1.0 とした時の画像サイズ比。

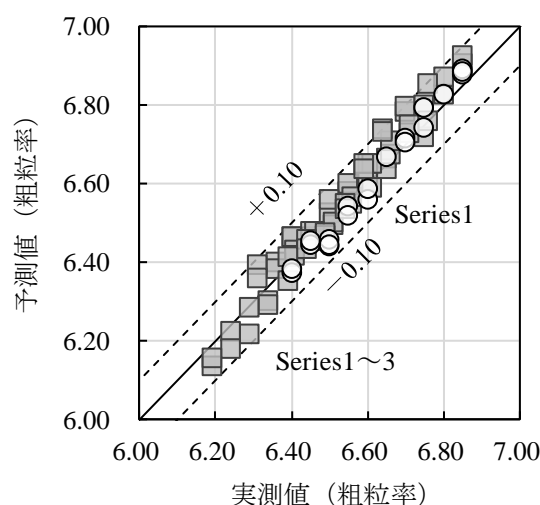


図 6 粗骨材粒度別の実測値と予測値の関係




図 7 予測方法別、粗骨材の種類別の予測精度

のみを使用した場合に比べて、予測精度がやや高かった。LED 照明を使用することで骨材縁の影が際立ち、畳み込み層において骨材の特徴を検出し易くなったことが一因と推察する。また、画像サイズ比が

予測精度に及ぼす影響は、画像サイズ比が変化しても RMSE はほぼ一定の値を示していることから、LED 照明の有無にかかわらず小さいことがわかる。また、元の画像サイズの 0.125 倍まで画像サイズを小さくしても精度良く予測できることを確認した。




図8 撮影環境別の画像サイズ比と予測精度

5.5 本技術のアプリケーション化

確立した粗骨材の粒度予測技術は現場で簡易的に利用できるようアプリケーション化を行った。図9に骨材の粒度予測アプリケーション画面を示す。骨材のふるい分け試験には、骨材の縮分、高温での乾燥、ふるい分け、粗粒率の計算等の多くの作業があり、結果が判明するまでに半日から1日を要する。しかし、本技術を応用することで、スマートフォンやタブレットなどの端末で撮影した骨材の画像を事前に機械学習を行った予測モデルに入力し、数秒で骨材の粒度を予測することができる。粒度の予測が容易かつ短時間に行えるため、骨材の受入れ時や、コンクリート製造時に骨材の品質変動の有無を確認することが可能となる。また、本技術をベルトコンベア上で連続的に骨材の粒度を予測することに応用することができる。骨材粒度の予測結果をコンクリート製造時の配合修正に適用することができ、コンクリートの品質安定化を図ることができる。

これまでの検討では、比較的粒径の大きい粗骨材を対象に、室内の静的な状態で実験を進めてきたが、今後は、より粒径の小さい細骨材を対象にした場合やベルトコンベア上での動的な状態など、より工場の実態に即した条件での予測の可否判断とその精度を検討する予定である。

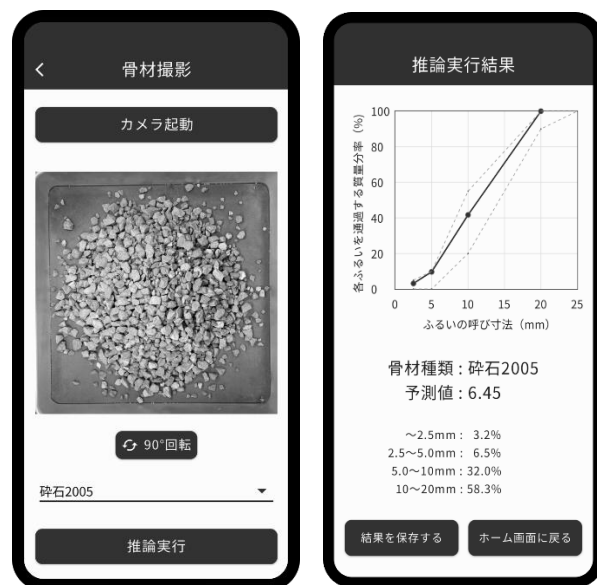


図9 骨材の粒度予測アプリケーション画面

6 結 言

AI 技術を活用して、コンクリートのフレッシュ性状や骨材の表面水率および粗粒率の予測可否を検討した。その結果、以下のことがわかった。

- (1) コンクリートのフレッシュ性状予測については、積込みホップ内を流下するコンクリートの画像データやコンクリートの落下・流下に起因する積込みホップの振動データに加え、コンクリートの材料・配合や練混ぜに関するデータを使用することで、JIS A 5308 に規定される許容差で判定した場合のスランプ、スランプフロー、空気量の正解率は約 90%であった。
- (2) 細骨材の表面水率予測については、ハイパースペクトルカメラを用いて 4 種類の細骨材の表面水率を予測した結果、石灰石、山砂、硬質砂岩、安山岩の順で RMSE が小さくなり、細骨材の明度 (L*値) が高いほど予測精度は高くなった。
- (3) 粗骨材の粒度予測については、過小粒の有無や粗骨材の種類、撮影環境、画像サイズ比によらず、粗骨材の粒度を精度良く予測可能であった。

参考文献

- (1) 工藤正智、小池耕太郎、星健太、早野博幸：「AI を用いたフレッシュコンクリートのスランプ予測技術」、太平洋セメント研究報告、No.182、pp.38-46 (2022)
- (2) 中西縁、本田和也、小田部裕一：「AI を用いたコンクリート配合導出技術の開発」、コンクリートテクノ、Vol.41、No.10、pp.50-53 (2022)

市川翔太郎・いちかわ しょうたろう
研究所 コンクリート研究室
生コン・特殊コングループ 研究員

瀬川実暉・せがわ みき
研究所 コンクリート研究室
生コン・特殊コングループ 研究員

板橋庸行・いたばし のぶゆき
研究所 コンクリート研究室
生コン・特殊コングループ 研究員

玉滝浩司・たまたき こうじ
研究所 コンクリート研究室
生コン・特殊コングループ グループリーダー

高原幸之助・たかはら こうのすけ
研究所 コンクリート研究室 室長