

論文 機械学習を活用した目視評価による表層品質評価システムに関する一検討

濱田 那津子*1・中村 真人*2・有坂 壮平*3・渡邊 賢三*4

要旨: コンクリート構造物の品質評価手法の一つに「目視調査による表層品質評価」がある。これは、「打重ね線」や「表面気泡」など7つの項目に対して、点数付けされたサンプル写真と実構造物を比較することで、評価を行うものであり、施工におけるPDCAのC(チェック)のツールとして活用する。本論文では、この評価手法のデータ化を目的に、目視調査の項目のうちの「表面の色つや」および「表面気泡」に対して、技術者が評価済みの画像を用いて、画像から評価点を出力する畳み込みニューラルネットワークの構築を行った。その結果、実規模試験体の目視評価を技術者と大きな差がなく評価できることを確認した。

キーワード: コンクリート, 表層品質, 目視評価, 機械学習, 畳み込みニューラルネットワーク

1. はじめに

トンネルや橋梁をはじめ、社会インフラとして重要な役割を果たすコンクリート構造物には、高い耐久性が要求される。また、コンクリート施工は、温度や湿度など環境条件の異なる自然環境下において行われ、現場ごとに使用する材料、コンクリート配合、さらには施工に取り組む人員もそれぞれ異なり、施工条件が日々変動する。このような中で、耐久性の高いコンクリートを安定して施工するには、使用する材料を常に管理・品質確保しつつ、適切な改善を続けていくことが極めて重要になる。しかし、これまでは構築したコンクリート構造物の品質に影響を及ぼしている要因同士の関係性を明らかにすることは難しく、現場技術者の経験に基づいて施工計画、施工方法が決められることが多く、品質向上への改善活動も感覚的に行っているのが実情であった。

そこで、現在、図-1に示すようなコンクリート工事のすべての工程に関する情報をデータ化するプラットフォームの構築に取り組んでいる。製造、運搬、受入れ、打込み、締固め、仕上げ、打継面の処理、養生、検査、評価の各工程におけるコンクリートの品質、施工管理の情報をデータ化し、それぞれを連携させることで、リアルタイムにコンクリートの状態を把握し、情報化施工を進めるものである。これにより前工程のデータを引き継いで次の工程に改善を加える小さなPDCAや一連の工程を一周したうえで次の周回の品質を向上させる大きなPDCAを回すことが可能になり、コンクリート構造物の品質および生産性の更なる向上を図ることができると考えている。筆者らは、このうち最終的な評価の項目にあたるコンクリートの表層品質評価をAI技術を用いて行うことを検討している。

本論文では、AIによる表層品質評価手法の検討の第一歩として、目視評価法の7つの項目から、画像全体から相対的に点数の予測が可能で、比較的難易度が低いと考えられる「表面気泡」および「表面の色つや」に着目し、コンクリートの画像と技術者による評価からデータセットを作成し、畳み込みニューラルネットワークを用いてモデルの作成を行った。そして、実規模試験体を評価対象として作成したモデルの精度を検証した。

2. 目視調査に基づく表層品質評価システム

コンクリートの品質評価項目の一つとして、筆者らは目視調査に基づいて表層品質を評価する手法(以下、目視評価法と称する)に着目した検討を行ってきた。目視評価法は、打重ね線や表面気泡など、現場で生じることの多い変状の中から7つの項目に対して、サンプル写真と実構造物を比較することで、点数付けを行い評価するものである。この手法により従来はコンクリート構造物の表層品質の良否を漠然と判定してきたものに対して、品質の劣る項目が明らかになるとともに、どの事象を改善すればいいのか明確にすることができる。さらに、対象

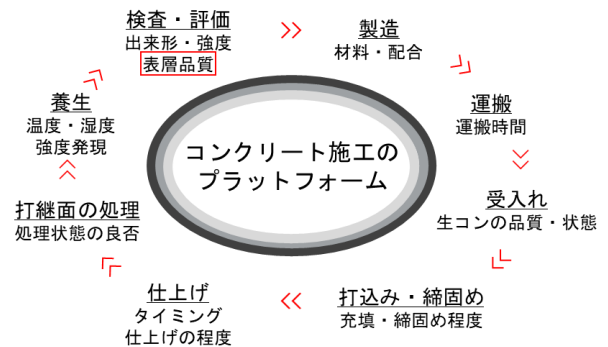


図-1 コンクリート施工のプラットフォーム

*1 鹿島建設(株) 技術研究所 土木材料グループ 研究員 (正会員)

*2 鹿島建設(株) 技術研究所 土木材料グループ 研究員 (正会員)

*3 鹿島建設(株) 技術研究所 AI×ICTラボ 研究員 修士(理学)

*4 鹿島建設(株) 技術研究所 土木材料グループ グループ長 博士(工学) (正会員)

部位全体の迅速な評価が可能であり、材料・工法に過大なコストをかけることなく、施工方法の工夫や改善につなげ易く、コンクリート構造物の美観および表層品質の向上が容易にできるなどの高い効果が得られることをこれまで確認してきている²⁾。

「目視評価法」²⁾は、写真-1に示すように施工の良否によって異なる外観(見栄え)となったコンクリートに対して「美しいコンクリートは品質と耐久性の高いコンクリートである」¹⁾という概念のもと、打重ね線、表面の色つや、表面気泡、沈みひび割れ、型枠継ぎ目のノロ漏れ、砂すじの6項目に対し点数化して評価する。なお、豆板についてはその有無で評価し、全7項目としている。

図-2に本論文の検討項目である「表面の色つや」および「表面気泡」の点数付けされたサンプル写真を示す。評価の点数化は、点数付けされたサンプル写真を実構造物と比較しながら、1~4点まで0.5点刻みで行った。

3. 機械学習

3.1 概要

機械学習は、人間がすべての動作を決めておく従来型のプログラムとは異なり、与えられた情報を元に学習し、自律的に法則やルールを見つけ出す技術・手法である。多数のデータ内に潜む規則や構造の認識に適しており、音声、画像、言語など様々な分析に使用されている。

機械学習の学習方法は、「教師あり学習」、「教師なし学習」、「強化学習」に分類され、さらに「教師あり学習」は求める答えが数値のような連続値の場合は「回帰」、車、人のようにクラス分けされる場合は「分類」と呼ばれる。

本検討では、画像から点数の推定を行う「教師あり学習」の「回帰」モデルの作成を行った。これはデータとして入力(ここではコンクリート表面の画像)と正しい出力(評価の点数)を与えて学習させることで、ある入力を

すれば正しい出力ができるようにするものである。

3.2 畳み込みニューラルネットワーク

本研究では、機械学習モデルとして畳み込みニューラルネットワークを利用した。畳み込みニューラルネットワークは画像認識の分野で優れた性能をもつアルゴリズムである。従来の機械学習手法では、検出したい特徴量(物体の輪郭や画像の輝度など)を人為的に指定する必要があったが、畳み込みニューラルネットワークでは検出してほしい特徴量を指定せずとも、学習の中で自動で最適な特徴量を大量に探し出すことが可能である³⁾。

本検討では、畳み込みニューラルネットワークのモデルとして画像認識の分野で多数使用されているResNetモデル⁴⁾を選択した。

3.3 機械学習の検証方法

機械学習モデルの検証は以下の二つのフェーズで行った。

(1) データセットによるモデルの作成

用意したデータセット内で、後述のK-分割交差検証を用いてモデルの訓練、検証を行い、誤差が最小となるモデルを選択した。

(2) 作成したモデルにテストデータを適用して検証

新たなテストデータを使用して、(1)で作成したモデルが未知のデータに対して正しく評価できるか検証を行った。



写真-1 見栄えの相違の事例

評価基準 評価項目	一般的に「良」とされる範囲			
	4点	3点	2点	1点
表面の色つや	 ・色が均一で、全体的に色の変化がない	 ・部分的な色むらがある	 ・部分的に剥離剤が攪拌されたような色むらが発生している	 ・2点の状態よりも劣る
表面気泡	 ・5mm以下の気泡がほとんどない (目安: 概ね50個以下/m ²)	 ・5mm以下の気泡が認められる (目安: 概ね50個以上/m ²)	 ・10mm以下の気泡が認められる (目安: 概ね50個以上/m ²)	 ・2点の状態よりも劣る

図-2 目視評価によるグレードの一例³⁾から抜粋

4. データセットによるモデルの作成

4.1 データセット

データセットは、学習用データとして一般的に少ない数であるが、様々な場所、時間に撮影されたコンクリート構造物の 891 枚の画像および画像に対するコンクリートの専門家 3 人の「表面の色つや」および「表面気泡」の評価点の平均値とした。モデル作成に使用する画像は 1920×1440 ピクセル以上とし、コンクリート以外のもの（背景など）が含まれた 377 枚の画像は画像の中からコンクリートの範囲のみトリミングを行い、さらに画素数を一定とするため、256×256 ピクセルにリサイズした。また、専門家による評価は目視評価法のマニュアル²⁾に準じ、1～4 点の範囲で 0.5 点刻みで点数付けを行った。

図-3 に 3 人の専門家による評価点の平均値のヒストグラムを示す。2 つの項目ともに 2.5 点以下のデータが 10% 程度であったが、これまで現場で行われてきた目視評価法でも全体の 2.5 点以下のデータは少ない。また、3 人の専門家による点数は最大で 1.0 点の差があり、データセット全体のうち専門家間での点差が 1.0 点である割合は、「表面の色つや」が 19.9%、「表面気泡」が 17.4%であった。本検討では、AI による推定値を 3 人の専門家による評価点の平均値に対して ±0.5 点とすることを目標に今後の検討を行った。なお、本検討は「回帰」モデルで行ったため AI による推定値は連続値となる。

4.2 作成したモデルの検証方法

限られたデータの中で検証の信頼性を向上させるため、本研究では、図-4 に示す K-分割交差検証により評価を行った。K-分割交差検証は、データセットを K 個に分割し、そのうち(K-1)個をモデルの調整(訓練)に用いる学習データとし、残りの 1 個を評価に用いる検証データとして、K 個に分割されたデータをそれぞれ K 回検証するものである。これにより、検証データのとり方による評価のばらつきを考慮し、モデルの性能をより正確に評価することが可能になる。本研究では、訓練に要する時間と検証結果の信頼性から K=5 としてデータセットを 5 分割してモデルの検証を行った。

4.3 モデルの最適学習回数の決定

図-5 に、交差検証 1 回目の学習回数と MAE(Mean Absolute Error)の関係を示す。モデルの学習とは、訓練データを用いてモデル中のパラメータを更新することであり、検証データを用いたモデルの評価は学習 1 回ごとに行った。モデルの評価には MAE を使用した。MAE がより小さくなるようにモデルの更新が行われる。MAE は、データセットの点数(3 人の専門家による評価点の平均値)と AI による推定値との差の絶対値の平均を示しており、式(1)のように表される。

$$MAE = \frac{1}{n} \sum_{k=1}^n |f_i - y_i| \quad (1)$$




図-3 目視評価の点数のヒストグラム




図-4 K-分割交差検証




図-5 学習回数と MAE の関係(交差検証 1)

表-1 5分割交差検証による検証結果

	最小 MAE	最適学習回数
交差検証 1	0.24	171 回
交差検証 2	0.24	160 回
交差検証 3	0.24	184 回
交差検証 4	0.24	299 回
交差検証 5	0.24	300 回

ここで、データの数 : n 、データセットの点数 : y_1, \dots, y_n 、AI による推定値 : $f_1 \dots f_n$ とする。

学習回数が増えるに従い、訓練および検証データの MAE は徐々に小さくなり推定の精度が向上する傾向にあった。特に、学習回数が 171 回の時、検証データの MAE が 0.24 と最も小さい結果となった。なお、学習回数が 250 回以上のときに訓練データの MAE が低下し、検証データの MAE が増加傾向にあるが、これは過学習と呼ばれる状態である。過学習とは、モデル内のパラメータが訓練データに過剰に適合してしまい、訓練データに対しては非常に高い推定精度となるが、訓練データと異なるデータに対しては精度が低くなる状態である。なお、これらの傾向はすべての交差検証において確認された。

表-1 に、5 分割交差検証による最小 MAE と最適学習

表-2 学習モデルによる検証結果

	表面気泡	色つや
MAE	0.23	0.24
差が 0.5 点以下の割合	88.9%	87.3%

回数の一覧を示す。本検討では、交差検証ごとに検証データの MAE が最小となる学習回数を最適学習回数とし、計 5 つのモデルを選択した。

4.4 最適モデルでの 5 分割交差検証の結果

表-2 に最適モデルとして選択した 5 分割交差検証後のデータセット全体の MAE と、データセットの点数と AI の推定値の差が 0.5 点以下になる割合を示す。AI による推定の結果、「表面の色つや」、「表面気泡」とともに MAE は 0.25 以下になり、データセットの点数と AI による推定値の差は 90% 程度の割合で 0.5 点以下になることを確認した。また、図-6 および図-7 に「表面の色つや」、「表面気泡」に対するデータセットの点数と AI による推定値の関係を示す。なお、図中の点線は ±0.5 点以内となる範囲を示す。どちらの項目においても、点数の差はおおむね 0.5 点以下であるが、2.0~3.0 点の範囲のデータは差が 0.5 点以上になりやすい傾向が得られた。これは 2.5 点以下のデータが少なく、十分に学習できていないためである。今後、2.5 点以下のデータを拡充し、精度を向上する必要があると考える。

5. 実規模試験体を用いたモデルの評価

実規模試験体の画像をテストデータとして、データセットから作成したモデルの検証を行った。

5.1 試験体の概要

図-8 に試験体の形状と寸法を示す。試験体は、ボックスカルバートの底版および中壁を模擬したものである。底版の寸法は厚さ 1.2m、幅 9.0m、延長 9.0m であり、高さ 0.8m のハンチを設けた。また、壁の寸法は厚さ 1.5m、高さ 6.0m、延長 9.0m とし、高さ 3.0m ずつ 2 リフトに分けて打ち込んだ。表-3 にコンクリートの使用材料、表-4 に配合をそれぞれ示す。使用したコンクリートは、高炉セメント B 種を用いた水セメント比 52.2% のものとした。目標スランブは 12.0 ± 2.5cm、目標空気量は 4.5 ± 1.5% とした。

試験体の構築は 3 月から 5 月にかけて行われ、壁の 1 リフト目は 5 月上旬にコンクリートの打込みを行った。なお、外気温は 16.3℃ であった。壁は 1 リフトあたり 5 層に分けて打ち込み、φ 50 mm のバイブレータを用いて締固めを行った。その後の締固め方法の要因を表-5 に示す。後追いバイブレータを用いて締固めを実施したケースは、各層打込みから 5~10 分後に、かぶり部に 50cm 間隔で φ 30mm のバイブレータを用いて 15 秒程度締固めを実




図-6 学習モデルによる検証結果(表面の色つや)




図-7 学習モデルによる検証結果(表面気泡)




図-8 試験体の概要

表-3 使用材料

材料	記号	摘要
水	W	地下水
セメント	C	高炉セメント B 種, 密度: 3.04g/cm ³
細骨材	S1	砕砂, 表乾密度: 2.63g/cm ³ , 粗粒率: 3.10
	S2	山砂, 表乾密度: 2.59g/cm ³ , 粗粒率: 1.70
粗骨材	G	砕石, 表乾密度: 2.65g/cm ³ , 実積率: 59.0%
AE 減水剤	Ad	リグニンスルホン酸塩(標準形)





表-4 コンクリートの配合

W/C (%)	スランブ (cm)	Air (%)	単位量 (kg/m ³)					
			W	C	S1	S2	G	Ad
52.2	12.0	4.5	168	322	546	293	960	3.22

表-5 締固め方法

施工方法	後追いバイブレータ	表面気泡抜き取り装置
A	あり	あり
B		なし
C	なし	あり
D		なし

表-6 締固め方法による目視評価の違い

施工方法 A	施工方法 B	施工方法 C	施工方法 D
後追いパイプレータあり		後追いパイプレータなし	
表面気泡 抜き取り装置あり	表面気泡 抜き取り装置なし	表面気泡 抜き取り装置あり	表面気泡 抜き取り装置なし
			
表面の色つや：3.6点 表面気泡：3.7点	表面の色つや：3.3点 表面気泡：3.4点	表面の色つや：3.5点 表面気泡：3.6点	表面の色つや：3.3点 表面気泡：3.3点

施した。表面気泡抜き取り装置⁹⁾を使用したケースは、後追いパイプレータによる締固めを実施した後もしくは各層打込みから5~10分後に表面気泡抜き取り装置を使用した。

5.2 試験体の目視評価

目視評価は、1リフト目の壁部を対象とし、脱型後、目視評価の経験がある技術者8名で実施した。点数は目視評価法に準じ、1~4点の範囲で0.5点刻みで評価点をつけた。

5.3 施工方法による目視評価の違い

表-6に施工方法A~Dのそれぞれの外観写真と目視評価の結果を示す。目視評価の点数の技術者による平均値は、「表面の色つや」、「表面気泡」とともに3.3~3.7点と狭い範囲に分布していた。施工方法AとB、CとDを比較すると、表面気泡抜き取り装置を使用した施工方法AとCの方が、BとDに比べ「表面の色つや」、「表面気泡」とともに点数が0.2~0.3点程度改善する傾向にあった。また、施工方法AとCを比較すると、表面気泡抜き取り装置を使用した場合、締固め後に後追いパイプレータによる再振動を実施することで「表面の色つや」、「表面気泡」とともに点数が0.1点程度改善する傾向が得られた。一方、表面気泡抜き取り装置を使用しない施工方法BとDを比較すると、締固め後に後追いパイプレータによる再振動を実施しても「表面の色つや」は改善しなかったものの、「表面気泡」は点数が0.1点程度改善する傾向が認められた。最後に、施工方法AとDを比較すると、今回の配合、施工条件では、後追いパイプレータによる再振動と表面気泡抜き取り装置の使用を併用することが最も目視評価のよい施工方法であり、どちらも行わない場合よりも点数が0.3~0.4点程度改善する傾向が得られた。

5.4 テストデータを用いたモデルの検証

5.4.1 テストデータの検証方法

実規模試験体の画像をテストデータ(未知のデータ)として入力することで、前述した891枚の画像と点数のデータセットから5分割交差検証を用いて作成した5つのモデルの検証を行った。テストデータは、実規模試験体




図-9 技術者による評価点の分布




図-10 AIによる推定値の分布

の目視評価を行った箇所から施工方法ごとに全面がコンクリートとなるように撮影した1920×1440ピクセルのコンクリートの画像10~14枚とした。AIによる推定値は交差検証ごとに選択した計5つのモデルからそれぞれ推定された値の平均値とした。

5.4.2 データの分布に関する考察

図-9に技術者8人による評価点の分布を、図-10にAIによる画像10~14枚の推定値の分布を示す。技術者による評価点は、「表面の色つや」が2.5~4.0点と最大で1.5点、「表面気泡」が3.0~4.0点と最大で1.0点ばらついていて、これは、技術者による評価は0.5点ごとにしか行えないことと、サンプル写真があるものの技術者によって評価基準に差異が生じてしまうことによると考え

られる。一方、AIによる画像10~14枚の推定値のばらつきは、「表面の色つや」が2.9~3.2点と最大で0.3点、「表面気泡」が3.1~3.8点と最大で0.7点ばらついていた。AIによる推定のうち施工方法Bの「表面気泡」の推定値が0.7点と大きくばらついた原因として、画像ごとに表面気泡の分布に差異があり、表面気泡の量によって推定に差が出てしまったことが考えられる。同じ構造物に対して複数の画像を撮影した場合には、画像の違いによるAIの推定の差を考慮する必要があると考えられる。

表-7に、技術者による評価とAIによる推定の分散を示す。AIによる推定値は連続値であることから一概に比較することは難しいが、技術者による評価の分散が0.023~0.579であったのに対し、AIによる評価の分散は0.001~0.058であり、AIによる推定の方が、ばらつきが小さくなることを確認した。

5.4.3 テストデータの検証結果

図-11に施工方法ごとの技術者8人による評価点と10~14枚の画像のAIによる推定値の関係を示す。技術者による評価点とAIによる推定値の差は全ての施工方法で0.3点以内であり、本検討のデータセットから作成したモデルによってテストデータに対しても正しく評価できることが検証できた。本検討のテストデータの技術者による点数は2.5~4.0点の範囲であったため、今後2.5点以下のデータを拡充し精度を検証する必要がある。

6. まとめ

本研究では、AIによる表層品質評価手法の検討の第一歩として、目視評価法の「表面の色つや」「表面気泡」に対して、コンクリート構造物の画像からAI技術を用いて点数を算出することを試みた。

(1)891枚の画像と、技術者による点数からデータセットを作成し、畳み込みニューラルネットワークを用いてモデルの構築を行った。交差検証ごとに最適な学習回数を選択した結果、「表面の色つや」、「表面気泡」ともにデータセット内では、データセットの点数とAIによる推定値の差の平均値が0.25以下になり、9割程度の割合で差が0.5点以下になることを確認した。

(2)実規模試験体の画像と技術者による評価点をテストデータとして使用し、データセットから作成したモデルの検証を行った。その結果、技術者による評価点とAIによる推定値の点差は0.3点以内であった。また、技術者による評価点のばらつきよりも、AIによる推定値のばらつきの方が小さく妥当な評価が可能であることを確認した。

表-7 技術者による評価とAIによる推定の分散

評価方法	施工方法	表面の色つや	表面気泡
技術者による評価	A	0.023	0.579
	B	0.163	0.174
	C	0.073	0.128
	D	0.213	0.095
AIによる推定	A	0.001	0.006
	B	0.008	0.058
	C	0.001	0.016
	D	0.007	0.030




図-11 テストデータの検証結果

参考文献

- 1) 坂田昇, 渡邊賢三, 細田暁: コンクリート構造物の品質向上と表層品質評価手法, コンクリート工学, Vol.50, No.7, pp601-606, 2012.7
- 2) 坂田昇, 渡邊賢三, 細田暁: テクニカルレポート「目視調査に基づくコンクリート構造物の表層品質評価の実績と調査結果を反映した表層品質向上技術」, コンクリート工学, Vol.52, No.11, p999-1006, 2014.11
- 3) 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」, pp.170-178, 2017
- 4) Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)
- 5) 進藤拓未, 渡辺健, 橋本親典, 井上裕史: 表面気泡抜き取り装置の使用条件と中性化抑制効果の関係, コンクリート工学年次論文集, Vol.33, No.1, 2011