

# 論文 AI 技術を利用したコンクリート表面形状の評価方法

石関 嘉一\*1・中林 拓馬\*2・国島 広弥\*3・小俣 光弘\*4

**要旨:** レイタンス処理後のコンクリート表面の評価方法として、一般には熟練技術者による目視評価が採用されている。しかし、少子高齢化に伴い熟練技術者は減少し、評価基準が正確に伝承されない危険性が発生する。そこで、レイタンス処理を実施したコンクリート表面を撮影し、AI 技術を利用した評価方法を検討した。その結果、熟練技術者が4種類に分類した評価基準に対して、画像を用いたAI 評価の正答率が98%以上であることを確認できた。また、レイタンス処理を行ったコンクリート表面の凹凸状態においても、画像による定量評価が可能であることが確認できた。

**キーワード:** レイタンス, レイタンス処理, AI, ニューラルネットワーク, ダム, 打継ぎ

## 1. はじめに

コンクリート構造物を施工する場合、ほとんどの部位で打継部が生じることは避けられない。特に上空に高い構造物などは数十回の打継部が生じるため、適切な施工や処理を行わないと構造物の弱点となり、耐久性や力学的特性の低下につながる。特に、ダムや水路などの水密性が要求される構造物では、打継部からの漏水<sup>1)</sup>が問題となる。そのため、コンクリートの打継面処理では既に打ち込まれた下層コンクリート上部の打継面処理を行い、レイタンスや品質の悪いコンクリート、緩んだ骨材などを取り除いてから打ち継ぐことが重要である。

コンクリートダムなどの施工において、従来工法の打継ぎは、粗骨材の表面が現れる程度とし、表面の15mm程度を取り除く方法が行われていた。しかし、近年ではダム施工において打継面をコンクリート運搬用のダンプトラックや、作業機械も随時走り回る状態になっている。その結果、従来工法と同様なレイタンス処理を行うと若材齢の打継面の骨材が緩んで表面が傷む現象<sup>2)</sup>が生じやすくなった。そこで、現行の施工においてレイタンス処理を行う際、カット後の粗骨材の露出状態が重要な要件となった。

粗骨材の露出状態を評価する目的で、コンクリートのレイタンス処理量を調整して4つの処理深さを再現し、せん断試験および表面の凹凸度計測を実施した。その結果、レイタンス処理後の粗骨材の凹凸を評価することで、適切な打継ぎ施工が行えることが確認<sup>3)</sup>できた。現状では、レイタンス処理後のコンクリート表面の評価を熟練技術者の目視によって行っている。しかし、ダム等大規模構造物の構築において、一度にコンクリート表面を評価する面積は数千 m<sup>2</sup>に及ぶ。そのため、評価に1日程度

費やす場合がある。その間、次工程に入れず生産性が低下してしまう。また、今後少子高齢化により熟練技術者は減少し評価基準等が正確に伝承されない危険性を生じている。そこで、熟練技術者に頼らない評価方法として、レイタンス処理したコンクリート表面を撮影し AI 技術を利用したコンクリート表面の評価方法を検討した。この手法を用いることで、熟練技術者不在でも短時間で大面積の評価が行え、生産性が向上するものと考えた。

本稿ではレイタンス処理をした試験体を製作し、表面画像から熟練技術者と同等の判断ができるか(人の主観的な判定を再現できるか) AI 機能を用いて検討した。また、試験体のコンクリート表面の凹凸の定量的評価を画像のみで判断できるか、コンクリート表面の評価とともに検討した。




写真-1 施工品質の評価基準例

\*1 株式会社大林組 技術研究所 生産技術研究部 主任研究員 博士(工学) (正会員)  
 \*2 株式会社大林組 技術研究所 生産技術研究部 主任 博士(工学)  
 \*3 株式会社大林組 土木本部 ダム技術部 副課長  
 \*4 株式会社大林組 大阪本店 工事長

## 2.コンクリート表面評価

### 2.1 AI 技術を用いた表面評価手法

施工面を対象に、AI 技術を利用して熟練技術者と同等の施工品質判定が可能であるかを検証した。ここではその手法と検証結果について述べる。本稿では、熟練技術者の目視によるレイタンス処理施工面の施工品質確認作業の自動化を試みた。写真-1 に評価基準例を示す。評価基準については前報<sup>3)</sup>に記載したとおり、コンクリートダム施工に 10 年以上従事し、監理技術者として発注者と施工状態を検討した技術者 2 名により決定した。現場作業員は通常、「ノーマル I」「ノーマル II」に示した程度の粗骨材の露出状況を適正な施工状況だと判断している。一方、「アンダー」「オーバー」はそれぞれ粗骨材の露出不足、もしくは浮きが生じているため望ましくない施工状況だと判断している。本検証では、これら 4 つのクラスを判定対象とした。

この目視判定を自動化するため、本稿では AI 技術の一つである畳み込みニューラルネットワーク (Convolutional Neural Network, 以降 CNN) を用いた。CNN は多くの良質な学習用データを学習することで、特に画像認識で高い認識精度を示す技術<sup>4)</sup>である。本検証の目的は、入力画像を 4 つのクラスに判定する分類問題を解くことであるため、出力として入力されたデータがそれぞれのクラスと推定される確率を算出するネットワークを用いた。本検証では、次節で述べる教師データを準備し、現場作業員と同等の施工品質判定が可能であるかを検証した。図-1 に本検証で利用した CNN のネットワーク図を示す。特徴抽出部では畳み込み層と称される画像特徴量を抽出するフィルタを 2 層と、得られた画像特徴量を集約するフィルタを 1 層利用している。また、判定部では全結合層と称されるニューロン接続を模した層により目的の推定処理が高精度に実行できるような関数を内部で生成する処理を行っている。ニューラルネットワークは脳神経回路に着想を得た技術であり、ネットワークがどれだけ複雑な関数を表現できるかを層数やニューロン数の設定により調整することができる。また、学習処理とはフィルタ、ニューロン間の接続の重みを学習用データを用いてパラメーター調整する処理を指す。

### 2.2 準備したデータセット

2.1 節で述べたように、CNN では多くの良質な学習用データを準備する必要がある。本検証で必要となるデータセットは、ラベルと称される学習の対象である値が付与された画像データである。例えば、図-1 ではそれぞれの画像に対し、「ノーマル I」「ノーマル II」などといったラベルを付与できるが、このような情報を教師データ全てに対して付与する必要がある。

データセット作成のため、写真-1 に示す 4 段階のコ

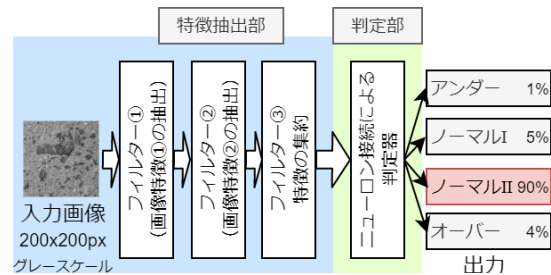


図-1 施工品質判定用の CNN のネットワーク



写真-2 試験体写真および撮影状況




写真-3 実際に CNN で処理した範囲

ンクリート表面の施工品質を模した 4 つの試験体<sup>3)</sup>を利用した。データセット用の画像撮影のため、1,000mm×1,000mm の試験体表面を縦横 10×10 グリッドに分割した。各グリッドの中心で 200mm 撮影面から離れた地点から写真-2 に示す通り写真を撮影し、各試験体から 100 枚ずつの画像データを得た。なお、写真撮影の際には、現場環境に近づける意図で水湿しを行った。また、CNN を含む画像認識技術は光環境の差異の影響を非常に受けやすいことが知られている。現場環境では様々な天候が予想されるが、本検証では手法の有効性がより確実に検証できるよう、撮影はいずれの試験体も屋内の同一の人工照明環境下のもと撮影した。撮影には一般的なデジタルカメラ (有効画素数 1600 万画素程度) を用い、3200×2400 ピクセルの写真として保存した。

また、撮影した写真のすべての領域をそのまま利用すると左右の写真で重複する箇所が生じる。同一箇所が映り込んだ画像が学習用データ・テストデータ双方に存在する場合、既知の画像がテストに使われることになり、正確な精度評価結果が得られない可能性が高い。そのた

め、写真-3の赤枠に示した中心部 1,000×1,000 ピクセルの正方形領域部だけ抽出して学習・テストに利用することとした。なお、撮影距離・画角から算出した正方形領域の実寸法は約 123×123mm となる。例として図-2に「ノーマルⅡ」から得た全画像を示す。

各写真へのラベリングについては、抽出した画像ごとではなく、予め試験体ごとに設定した施工品質のラベルを付与した。これは、全体を均一にレイタンス処理をしたとしても、粗骨材の露出状況は完全に均一にはなり得ないことを考慮したためである。よって、100 枚ずつ計 400 枚を検証実験に用いた。

### 2.3 検証実験

これまでに述べてきた CNN モデルとデータセットを用い、精度検証実験を行った。本節では検証条件について述べる。

まず、データ入力前に実施した前処理について述べる。CNN では学習処理に膨大な計算リソースが必要となることから、本検証ではデータセットの画像サイズを 200×200 ピクセルに縮小した。縮小後、さらに光環境の影響を軽減するため、カラー画像をグレースケール画像へ変換する処理を行い、CNN へ入力することとした。

次に、学習処理に利用したデータ数を表-1 に示す。正確な精度評価のため、テスト時に利用するデータを各分類から 50 枚ずつ、計 200 枚の画像を予めデータセットから取り分けた。そのため、学習時に利用したデータ数は 200 枚であった。

### 2.4 検証結果

表-1 の学習用データを利用し CNN にて学習処理を行い、得られた学習済みモデルを利用してテストデータでの精度評価を行った。表-2 に結果を示す。

結果として、98%以上の非常に高い正答率が得られた。この結果から、本検証で準備したデータセットのように、同一条件で撮影された画像データに対しては、CNN を利用することで粗骨材の露出状況を正確に認識できることが分かった。

## 3. AI 技術を利用した画像データからの凹凸度推定

これまでの検証で、AI 技術を利用することで現場作業員と同等の施工品質判定が実現できそうであることが確認できた。本稿では次に、AI 技術を利用して施工品質を定量的に評価する技術について検証した。ここではその手法と検証結果について述べる。

### 3.1 AI 技術を用いた凹凸推定手法

定量的な評価手法においても、これまでの検証と同じく CNN をベースとしたネットワークを用いる。図-3 に本検証で用いたネットワーク図を示す。2.1 節で用いたネットワークとほぼ同様であるが、判定部に全結合層を一




図-2 1つの試験体から得たデータ例

表-1 検証実験に用いたデータセットの内訳

	データセット	
	学習用データ	テスト用データ
画像枚数	200 枚	200 枚

表-2 CNN を用いた施工品質状況の検証結果

	アンダー	ノーマルⅠ	ノーマルⅡ	オーバー
正答率	100.0%	98.0%	100.0%	98.0%

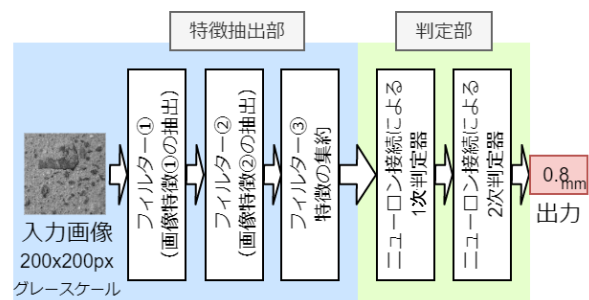


図-3 凹凸度判定用の CNN のネットワーク図

表-3 データセット用に用いた 3D スキャナ仕様

機種名		Artec Eva 3D Scanner
方式	①	非接触・光投影法
	②	ハンドヘルド
最小スキャン規模	214×148mm	
最大スキャン規模	536×371mm	
スキャン範囲・距離	400mm - 1,000mm	
X/Y・深度分解能	0.5mm	

層追加した形のネットワークである。本検証においては、凹凸度合いを表す指標としてコンクリート表面の高さ方向のばらつき具合、すなわち Z 値の標準偏差を指標として利用した。本検証の目的は AI 技術を利用して定量的に凹凸度合いを推定するという回帰問題を解くことであるため、出力層の値がそのまま凹凸度合いを表す Z 値の標準偏差となるネットワークを用いた。

### 3.2. 凹凸度合いと計測手法

前報<sup>3)</sup>では50mm間隔でマス目を設定し、ノギスを用いて手で凹凸を計測した。しかしながら、本検証ではデータセットの画像の範囲123mm角の領域毎の凹凸を正確に計測する必要があるため、3Dスキャナを利用し試験体全面の詳細な凹凸を測定した。使用した3Dスキャナの仕様を表-3に示す。

それぞれの試験体から取得した表面の深度画像の一部を図-4に示す。深度画像のZ値は、輝度が高い箇所では深度が大きく、輝度が低い箇所では深度が低いことを示す。図から、「アンダー」には微細な起伏しかないが、「ノーマルⅠ」、「ノーマルⅡ」では適度に粗骨材が露出しており、「オーバー」では、全面で粗骨材がかなり露出していることが確認できる。なお、本稿には視認性を考慮し、コントラストを強調した図を示している。

図-5にそれぞれの試験体の表面全体のZ値の標準偏差を示した。図に示したとおり、「アンダー」「オーバー」は「ノーマルⅠ」「ノーマルⅡ」は視認できる違いのほか、凹凸度合いにおいても数値的に区別できることを確認できる。

なお、3Dスキャナにより得られたコンクリート表面の点群は型枠の天端を基準に水平になるよう座標変換した。また、現場の環境と同じく試験体の表面には局所的に多少の不陸がある。正確な表面の凹凸度合いを計測するためにデータセットの各画像の範囲ごとに深度画像の全体の勾配が水平になるよう座標変換処理を行い、不陸の影響を極力除去している。

### 3.3 準備したデータセット

本検証では、画像データに凹凸度合いを表す値を付与したデータセットを準備した。凹凸度合いを定量化する方法はいくつも考えられるが、本稿では前報と同様、コンクリート表面の高さ方向の標準偏差を凹凸度合いとして扱うこととした。なお、単位はmmとした。

ラベルとして凹凸度合いを与えた以外、撮影条件等については施工品質判定の検証実験に用いたデータセットと同様である。

### 3.4 検証実験

これまでに述べてきたCNNモデルとデータセットを用い、精度検証実験を行った。

まず、データ入力前に実施した前処理について述べる。施工品質判定の検証と同様、本検証でもデータセットの画像サイズを縮小して凹凸度合い判定を行うこととした。予備実験として、28×28, 100×100, 200×200ピクセルの三段階の解像度にて精度検証を行った結果、最も高い精度が得られた200×200ピクセルへ縮小した画像にて本検証を行った。また、グレースケール化処理についても施工品質判定の検証と同様に行った。加えて、本検証で




図-4 3Dスキャナで取得した表面の深度画像




図-5 Z値の標準偏差

表-4 検証実験に用いたデータセットの内訳

	データセット	
	学習用データ	テスト用データ
画像枚数	1,440 枚	160 枚




図-6 推定値と実測値の比較

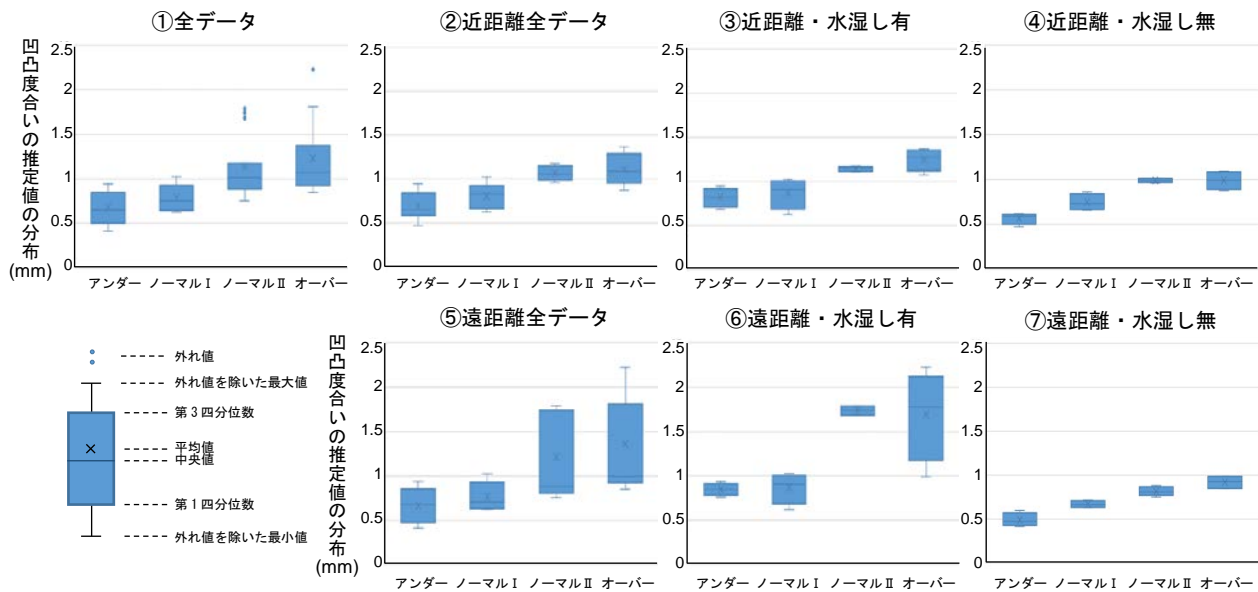


図-7 様々な条件下での凹凸度合い判定結果

はグレースケール化処理後、より粗骨材を強調する意図で閾値処理を加えることとした。一般的な二値化処理をはじめ様々な閾値処理を検討したが、予備実験の結果から輝度が閾値を超える画素の輝度を閾値に、閾値未満の画素には変更を加えないという手法を採用した。このほか、CNNの学習においては元データに簡易な画像加工を加えたデータを追加することで多少の精度向上が期待できることが知られている。本検証の入力データは上下や左右方向に制約がないため、反転させた画像パターンを用いて学習させることは精度向上に有効だと考えた。そのため閾値処理後の画像を上下左右に反転させた画像を追加し、データセットのデータ量を4倍に増大させた。

最後に、学習処理に利用したデータ数を表-4に示す。正確な精度評価のため、テスト時に利用するデータを各分類から10枚ずつ、計40枚の画像を予めデータセットから取り分けた。先述した画像加工処理により、テスト用データとして160枚、学習用データとして1,440枚を利用し、凹凸度合いの判定を試みた。

なお、通常は精度検証に用いるテスト用データには画像加工処理は用いない。しかしながら、本検証においては上下左右の反転のみを行っており、加工後の画像と撮影方向が異なれば実際に発生し得ると判断し、これらの画像もテスト用として利用した。

### 3.5 検証結果

表-4の学習用データを利用しCNNにて学習処理を行い、得られた学習済みモデルを利用してテストデータでの精度評価を行った。テストデータから各分類10枚ずつ抽出して検証した結果を図-6に示す。

結果から、全体の傾向としては3Dスキャナの計測値に見られた傾向と同様の傾向が見られた。「アンダー」「ノ

ーマルI」では計測値と推定値が大きく異なる場合もあったが、「ノーマルII」「オーバー」では計測値と推定値に一定の差はあったが追従性は見られ、凹凸度合いの傾向そのものは推定できていることが分かる。また、分類ごとの平均値としても、計測値と同様に「アンダー」<「ノーマルI」<「ノーマルII」<「オーバー」となる傾向が確認できた。凹凸度合いの推定値については改善の余地が大きい。データセットを拡充することである程度の改善は期待できるため、今後は実現場にてデータを収集し、精度向上に努めたい。

## 4. 現場適用に向けた追加検証

### 4.1 屋光環境下での凹凸度合い判定

前節までの検証では、屋内で同一の光環境下で撮影したデータのみを扱った。本節では、実際の現場環境に近いデータを用いて現場での実現可能性を確認するため、屋外の屋光環境下で以下の条件それぞれにおいて試験ごとに4枚ずつ写真を撮影して検証を行った。

- ・近距離撮影(500mm)／遠距離撮影(1,000mm)
- ・水湿し有／無

様々な条件を設定し実施した検証結果を図-7に示す。ここでは、各分類の写真データを前節の学習済みモデルに入力し、得られた推定値の範囲を表現している。傾向として、推定された凹凸度合いの平均値は常に「アンダー」<「ノーマルI」<「ノーマルII」<「オーバー」の関係を保って推定できていることが分かった。また、学習用データの撮影距離よりも遠距離から撮影したデータを利用する場合には、基本的に標準偏差の値が大きく推定されることが分かった。これは凹凸度合いの推定が画像データのみを手掛かりにしているため、距離が離れば

粗骨材が小さく映るため、推定値の大きさに変化が生じたと考えられる。このことから、AI技術により現場作業員よりも正確に凹凸度合いを判定するためには、常に同一の撮影環境で撮影できる機器設計が必要になることを確認できた。

#### 4.2 現場適用に向けた機材の検討

本稿では実現場外にて学習用データを準備して精度検証を行った。今後は実現場にてデータを収集し精度向上する必要がある。学習用データとしては、写真データと3Dスキャナで計測した写真データ範囲内の凹凸度合いの標準偏差が必要となる。この目的に対して必要十分な性能を確認するため、2機種の3Dスキャナを検証した。

表-5にそれぞれの仕様を示す。現場でのデータ収集用の機器としてこれら2機種を選定した理由は、3Dデータを取得した範囲の画像データを同時に取得できることが挙げられる。この機能により、凹凸度合いがラベリングされた画像データセットを容易に得ることができる。

仕様表から確認できるとおり、3Dスキャナ②と比較すると3Dスキャナ①の深度分解能は高くない。しかしながら、粗骨材自体の大きさから、凹凸自体がサブミリ単位よりも大きな値を取るため、本稿の目的のように標準偏差にて凹凸度合いを評価する場合には要求性能を満たせると仮定した。図-8にそれぞれの3Dスキャナで得られた深度画像を、表-6に測定結果を示す。

計測結果から、3Dスキャナ①で取得できる深度画像は3Dスキャナ②と比較すると骨材周りの輪郭部の階調が乏しいことが分かる。これは分解能の性能差に起因するものと推察される。Z値の標準偏差についても、詳細部が取得できていない影響からか、3Dスキャナ①で取得したデータの方が3Dスキャナ②よりも常に小さくなる結果となった。しかしながら、どちらも「アンダー」から「オーバー」に向かって標準偏差が大きくなる傾向は正確に計測することができており、本稿の目的に対してはどちらの機種も十分な性能を有していると結論付けた。

#### 5. まとめ

本稿では、少子高齢化による熟練技術者の減少への対策として、これらの技術者に頼らない評価方法を実現するため、AI技術を利用したコンクリート表面の評価方法を検証した。

検証では、レイタンス処理したコンクリート表面を撮影した写真を入力データとして、①熟練技術者がランク付けした施工品質判定をAI技術でも再現できるか、②3Dスキャナで計測した表面の凹凸度合いをAI技術により数値的に推定できるか、という2つの検証を行った。結果として、①については良好な結果が得られ、主観的な評価の代替は出来るとの結論を得た。また、②について

表-5 検証した3Dスキャナの仕様表

比較項目	3Dスキャナ①	3Dスキャナ②	
方式	①	非接触・光投影法	
	②	ハンドヘルド	ハンドヘルド/固定
最小スキャン規模	200×200mm	135×100mm	
最大スキャン規模	3,000×3,000mm	225×170mm	
スキャン範囲・距離	350mm～3,000mm	400mm±100mm	
X/Y分解能@0.5m	0.9mm	0.16mm	
深度分解能	1mm	0.16mm	




図-8 3Dスキャナで得られた深度画像の比較

表-6 スキャン結果比較

	Z値の標準偏差 (mm)	
	3Dスキャナ①	3Dスキャナ②
アンダー	0.47	0.56
ノーマルI	0.65	0.81
ノーマルII	0.82	0.94
オーバー	1.03	1.53

は正確な凹凸度合いの推定にはより多くのデータを学習させる必要があることが分かったが、凹凸度合いの傾向をつかむことはできていることは確認できた。

今後は、実現場にて学習用データを取得し精度向上に取り組み、早期の現場適用に取り組む所存である。

#### 参考文献

- 1) 斯波明宏, 樋口正典, 佐々木亘: コンクリート水平打継部の耐久性向上に関する検討, 三井住友建設技術開発センター報告 第9号, pp59-64, 2011
- 2) 日本ダム協会: コンクリートダムの施工, 2015.3
- 3) 石関嘉一, 中林拓馬, 宮入斎, 小俣光弘, コンクリート打継面の形状が構造物の力学特性に与える影響, 日本コンクリート工学年次論文集, Vol.41, No.1, 1295-1300, 2018.
- 4) A. Krizhevsky, I. Sutskever, and G. E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. In NIPS, 2012.