

# 表面色を特徴量とした機械学習による コンクリートの変状・内部品質の検出モデルの基礎的検討

Preliminary study of a detection model of defects in concrete using machine learning with surface color as a feature.

北海道大学大学院工学院  
北海道大学大学院工学研究院  
北海道大学大学院工学研究院

○学生員 登坂 直紀(Naoki Tosaka)  
正員 鄧 朋儒(Deng Pengru)  
正員 松本 高志(Takashi Matsumoto)

## 1. はじめに

コンクリートは多孔質材料であり、放湿が進むと表面色は白変し、吸湿が進むと表面色は黒変する。またひび割れ部分では吸水が促進され、水セメント比が高い低品質コンクリートでは透水係数が大きくなること<sup>2)</sup>が知られている。したがってコンクリート表面色を経時的に観測することで、コンクリートの変状や内部品質を推測できる可能性がある。

本研究の目的は、経時的なコンクリート表面色のデータを解析して変状・内部品質を検出するための関係を検討することである。深層学習を用いた既往の分類器<sup>3)</sup>では、コンクリート表面変状画像から特徴パターンを学習させて変状を検出するものがある。本論文では、表面変状に加えて内部品質の検出を可能にするために、時間経過に伴うコンクリート表面色の変化を学習させた分類器を作成して、性能評価を行う。学習ではニューラルネットワークを用いた機械学習を使用し、教師データの表面色変化と変状・内部品質との対応を学習させた分類器を作成する。分類ではテストデータの表面色変化を分類器に入力して、出力された変状・内部品質の分類をその正解と比較することで性能評価を行う。

## 2. 実験概要

実験装置と供試体を図1に示す。表面色を観測するコンクリート供試体は高さ160mm、幅40mm、奥行40mmの直方体供試体を4つ組み合わせた。供試体同士の接触面は接着せず、接しているのみである。本論文ではW/C=0.41の供試体を「通常」とし、供試体同士の接触面を「ひび割れ」と見立て、W/C=0.69の供試体を「低品質」とする。各供試体の配合を表1に示す。表面色を変化させるために、水を張った容器に供試体下部を浸した。表面色を記録するためにBrinno製のHDRタイムラプスカメラLTC200Proを用いて、供試体を浸水させた時点から1分間隔で3時間観測を行った。なお画像記録サイズは1280×720ピクセル(約92万画素)とした。本実験では温湿度の操作は行っていない。一定の露出で観測することが望ましいため、環境試験器を暗室としてLED照明で間接的に供試体を照らした。

## 3. データセット

### 3.1 グレイスケール値への変換

コンクリート表面色を数値化するためにグレイスケール

ル値を用いた。グレイスケール値によって人間の視覚に近い表面輝度値での表現が可能となる。カラーをグレイスケールに変換するために式(1)を用いた。

$$Y = 0.2216 \times R + 0.7125 \times G + 0.0722 \times B \quad (1)$$

ここでYはグレイスケール値であり、R、G、BはそれぞれRGB色空間でのR値、G値、B値である。式中の係数はRGBカラーをグレイスケールに変換するとき一般的に使われる値であり、人間の三色型色覚における各色の認識の強さを測定したものを表している<sup>4)</sup>。

### 3.2 教師データとテストデータ

機械学習で分類を行う際には、前もって特徴量を決めて教師データを作成し、教師データを学習した分類器にテストデータを入力して分類を行う工程が必要となる。本論文では撮影したタイムラプス動画180フレーム分のグレイスケール値を特徴量とした。図2のように撮影した画像に長方形の解析領域を設けてそれを縦横5ピクセルの正方形に分割した(分割したセルを観測点と呼ぶ)。今回の実験では解析領域を775×120ピクセルとし、縦24点、横155点の3720個の観測点を設けた。図3のように全観測点を学習に使用する教師データ2480点、分類に使用するテストデータ1240点に分割した。各観測点25画素のグレイスケール値の平均値を、その観測点



図1 実験装置と供試体

表1 供試体の配合

	単位量[kg/m <sup>3</sup> ]				水セメント比 [%]
	水	セメント	粗骨材	粗骨材	
通常	179	438	764	1055	0.41
低品質	198	286	571	1143	0.69

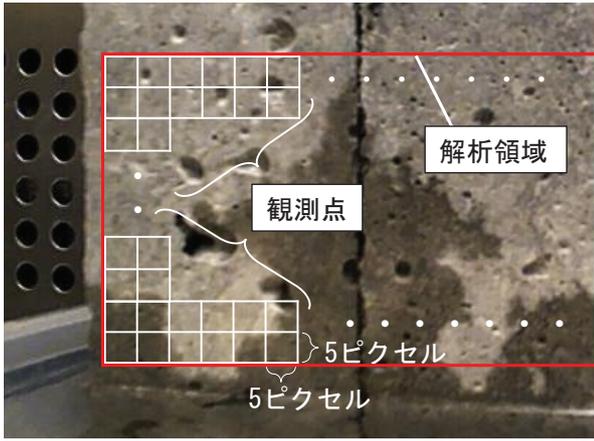


図2 解析領域と観測点の設置例

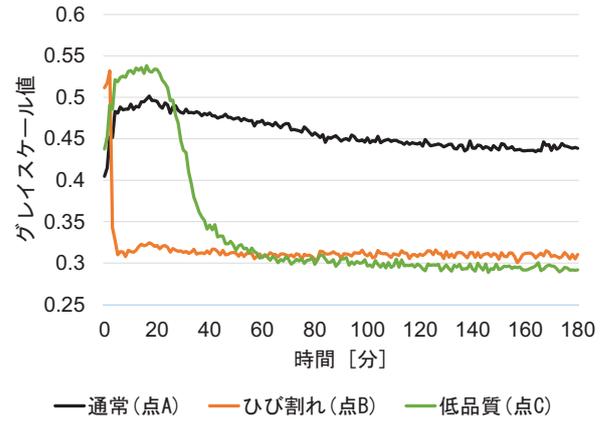


図4 各クラスのグレイスケール値変化

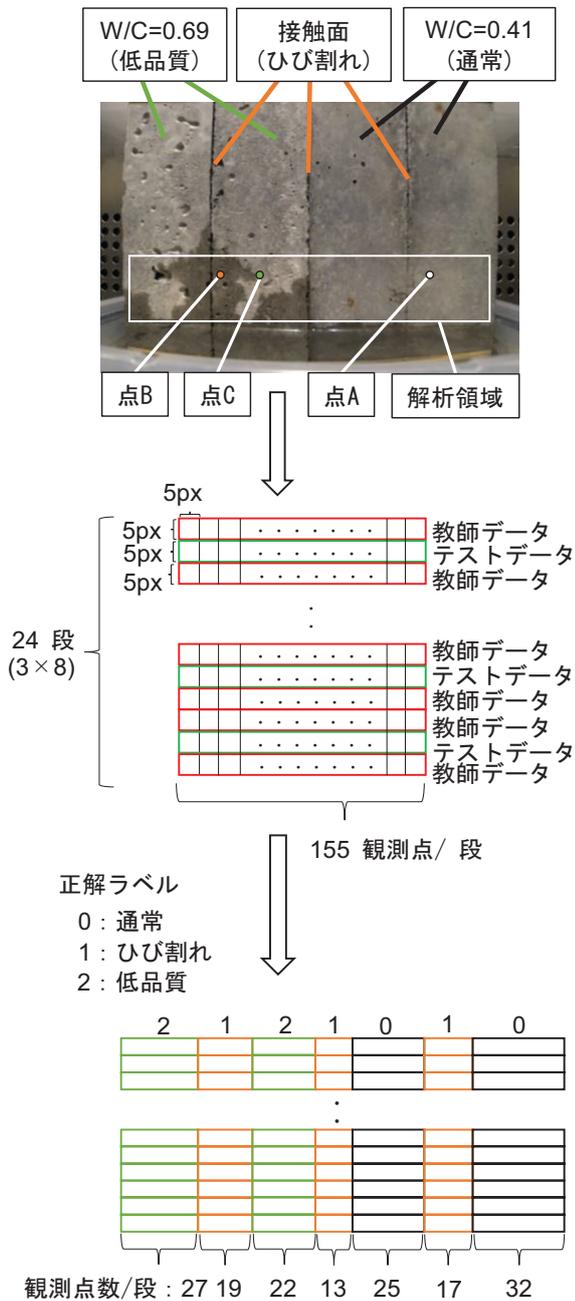


図3 教師データとテストデータ

におけるグレイスケール値とした。そして、配合種類と撮影した動画中の色変化挙動から、教師データとテストデータの各観測点に、図3のように通常、ひび割れ、低品質の3クラスの正解ラベルをつけて整理した。

各クラスの時間経過に伴うグレイスケール値変化の例を図4に示す。また点A、点B、点Cの供試体中の位置は図3中に示す。通常部分では徐々に吸水してグレイスケール値も徐々に変化したが、ひび割れ部分では観測開始直後に急激に吸水してグレイスケール値も急激に変化し、低品質部分では緩やかに吸水してグレイスケール値も穏やかに変化したことが分かる。なお観測開始直後は記録画像の明るさが暗く、全観測点でグレイスケール値が低く記録されている。本論文の機械学習は、このグレイスケール値変化挙動の差を利用して、各クラスの180フレーム分のグレイスケール値挙動と変状・内部品質の対応を学習するモデルである。

#### 4. 機械学習

##### 4.1 ニューラルネットワーク

本論文では図5のような全結合型ニューラルネットワークで学習を行った。中間層は5層で、各層のニューロン数は200である。入力層では、教師データのある観測点における180フレーム分のグレイスケール値を入力する。中間層では、重みづけされた各ニューロンからの数値を合計して活性化関数に代入して、その値に再び重みづけをして次の層の全ニューロンに伝える。出力層では、通常、ひび割れ、低品質のそれぞれの確率を出力する。

出力した確率から式(2)による交差エントロピー誤差Hを求めて損失関数を得た。

$$H(p, q) = -\sum_x p(x) \ln q(x) \quad (2)$$

ここでpは正解の確率分布、qは予測の確率分布、xは観測点である。予測ラベルが正解ラベルと一致しない場合や、一致しても確率が低い場合は損失が大きくなる。このモデルは損失関数が小さくなるように重みを更新して性能を上げていくモデルである。

##### 4.2 学習過程

3.2節で作成した教師データのグレイスケール値と正解ラベルの対応を4.1節の全結合型ニューラルネットワークで学習させた。本学習では機械学習ライブラリであ

る scikit-learn の機能のうち MLPClassifier を用いた。表 2 に学習に用いた MLPClassifier のパラメータの名称、役割、値を示す。各パラメータは損失関数が小さくなるものを設定した。設定した最大試行回数より前に損失が収束したので、その時点で学習を終了し、図 6 の損失関数を得た。図 6 で損失が収束していることから、この学習では過学習が起きていないことが分かる。収束後の損失は 0.35 であった。

5. 分類結果及び考察

4 章で教師データを学習させたニューラルネットワークに、テストデータを入力して得られた予測ラベルの分布を図 7 に示す。観測開始 0 分後、15 分後、45 分後、180 分後のタイムラプス画像を図 8 に示す。ここで 3 か所のひび割れを左からひび割れ 1、ひび割れ 2、ひび割れ 3 とし、2 か所の低品質を左から低品質 1、低品質 2 とした。また、テストデータの観測点をそれぞれの予測ラベルと正解ラベルで分類した混同行列を表 3 に示す。このモデルの分類性能を評価するために再現率・適合率・F 値を表 4 に示す。

5.1 予測ラベルの分布

図 7 より低品質 1 左下部（図 7 中および図 8 中の青枠）とひび割れ 2 上部（図 7 中および図 8 中の赤枠）で予測ラベルが正解ラベルと一致していないことが分かる。図 8 より供試体端部からの吸水により低品質 1 左下部では他の低品質領域より速く色変化が起きたことが分かる。この色挙動の差によって低品質部 1 左下部はひび割れと予測されたと考えられる。端部は吸水しやすいので解析領域から除外する必要がある。

図 8 よりひび割れ 2 上部（図 7 中および図 8 中の赤枠）では他のひび割れ領域と比べて色変化が起きた時間が遅いことが分かる。この色挙動の差によってひび割れ 2 上部は低品質と分類されたと考えられる。またひび割れ 1、ひび割れ 2、ひび割れ 3 の正解ラベルは「ひび割れ」で同じものであるが、ひび割れ 3 の色挙動はひび割れ 1 およびひび割れ 2 の色挙動と全く異なっている。低品質供試体上のひび割れに「ひび割れかつ低品質」と正解ラベルをつけて 4 クラスの分類をし、性能を評価することが課題である。

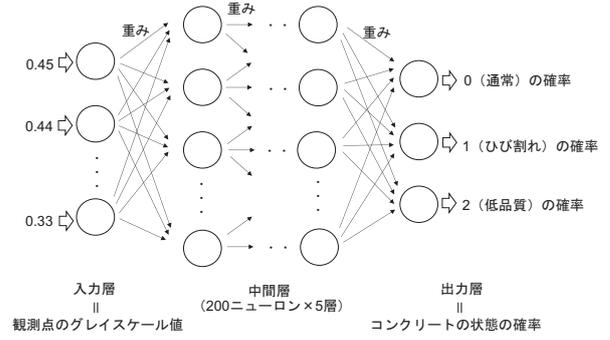


図 5 全結合型ニューラルネットワーク

表 2 学習パラメータ

パラメータ	役割	値
hidden_layer_sizes	中間層の層数とそのニューロン数を設定	200×5層
activation	活性化関数を設定	relu
solver	最適化手法を設定	sgd
learning_rate	重みの学習率を設定	0.0099
max_iter	最大試行回数を設定	1000
momentum	重みの修正量を設定	0.99
tol	収束のトレランスを設定 10連続試行でこの値より損失が減少しなかった場合に、収束したと判断して学習を止める	0.00001

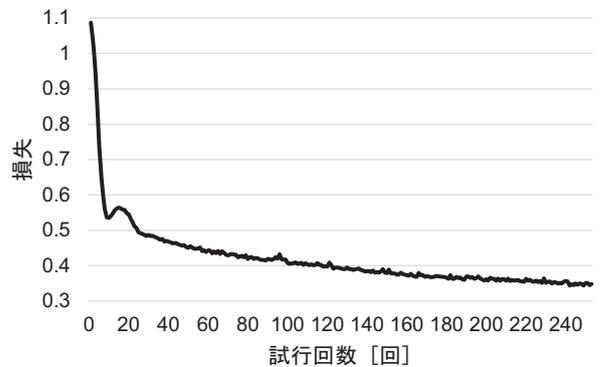


図 6 損失関数

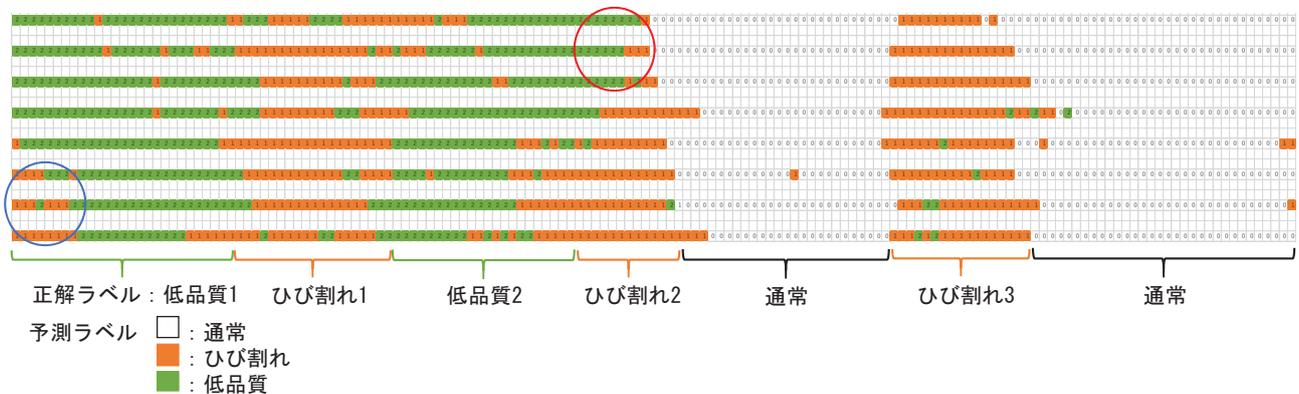


図 7 分類結果



図 8 実際の表面色変化挙動

表 3 混同行列

		予測ラベル		
		通常	ひび割れ	低品質
正解ラベル	通常	439	15	2
	ひび割れ	27	299	66
	低品質	0	81	311

表 4 分類性能

	再現率	適合率	F値
通常	0.963	0.942	0.952
ひび割れ	0.763	0.757	0.760
低品質	0.793	0.821	0.807

### 5.2 分類性能

図 6 および表 3 より、テストデータで正解ラベルと予測ラベルが一致した観測点は 1049/1240 であり、分類精度は 84.6%であった。表 3 および表 4 より、全クラスにおいて再現率と適合率は似たスコアであり、バランスのとれたモデルであると言える。しかし通常の F 値は高いが、ひび割れと低品質の F 値は比較的低いことから、ひび割れと低品質の分類性能は通常の分類性能と比べて低いことが分かる。これは図 3 のように供試体を長方形に区切って正解ラベルを簡易に設定していることが原因であり、観測点ごとにグレイスケール値を確認して正解ラベルをつける必要がある。また本論文では供試体同士の接触面をひび割れと見立てて学習・分類を行っており、見立てではない実際のひび割れのある供試体においても学習・分類を行ない、分類性能を評価する必要がある。

この検出モデルでは、一つの動画を教師データとテストデータに分割して学習・分類を行った。現実のコンクリート構造物に適用するには、変状・内部品質が既知のコンクリートから教師データを作成して学習したニューラルネットワークに、対象のコンクリート構造物のデータを入力して変状・内部品質を予測するという工程が必要である。今後の検出モデルでは、テストデータを教師データのタイムラプス動画とは別の動画から作成することが課題である。

### 6. まとめ

コンクリート表面色変化と変状・内部品質との対応の教師データを機械学習させて、表面色変化のテストデータに対して変状・内部品質の分類を行い、正解と比較を行った。学習過程において収束後の損失は 0.35 であり、過学習を起こすことなく教師データの学習が行われた。学習済みのニューラルネットワークを用いてテストデータを分類した結果、精度は 84.6%であった。しかし通常の分類性能が高い一方で、ひび割れと低品質の分類性能は比較的低く、現状の検出モデルには改善の余地がある。

### 参考文献

- 1) 工藤めい・下村匠：コンクリート部材への水の浸透・乾燥に及ぼすひび割れの影響に関する実験と数値解析, 土木学会論文集 E2 (材料・コンクリート構造), Vol.75, No.3, pp196-207, 2019.
- 2) 村田二郎：コンクリートの水密性の研究, 土木学会論文集, Vol.77, pp69-103, 1961.
- 3) 岸下達哉・松本高志：機械学習によるコンクリート表面変状の自動検出モデルの改善, 平成 30 年度土木学会北海道支部論文報告集, Vol.75, A-10, 2019.
- 4) Michael STOKES, Matthew ANDERSON, Srinivasan CHANDEASEKAR, and Ricardo MOTTA : A Standard Default Color Space for the Internet - sRGB, <https://www.w3.org/Graphics/Color/sRGB.html>, (参照 2020/12/11), 1996