

論文 骨材粒度の予測性能に及ぼす画像処理方法の影響

市川 翔太郎*1・瀬川 実暉*1・玉滝 浩司*2・高原 幸之助*3

要旨：本研究では、骨材の画像から粒度を推定することを目的に、畳み込みニューラルネットワークの手法を用いて機械学習を行い、5種類の画像処理方法が骨材粒度の予測性能に及ぼす影響を実験的に比較した。その結果、画像の前処理を行うことで、未処理のカラー画像よりも予測精度が向上することが示された。特に、背景のノイズを効果的に低減するために、画像全体の明るさを低下させる「暗転化处理」の後に適応二値化を行った場合、他の手法と比較しても予測精度の向上とばらつきの低減が確認された。さらに、本手法は予測結果に偏りが見られず、最も安定した予測結果を提供することがわかった。

キーワード：大津の二値化, 適応二値化, エッジ検出, 暗転化, 畳み込みニューラルネットワーク, 粗粒率

1. はじめに

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、出荷量も年々減少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な要素である。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課題となっている。そこで、品質管理の省力化と更なる品質の安定化を図る目的で、人工知能(Artificial Intelligence, 以下 AI)の活用により出荷時や荷卸し時のフレッシュコンクリートの品質を予測する技術¹⁾が開発されている。

一方で、標準配合どおりのコンクリートを製造するため、製造時における使用材料の状態に応じて標準配合を補正することも日常の工程管理において重要である。特に、骨材は使用材料のなかでも品質の変動が比較的大きく、「生コン工場品質管理ガイドブック²⁾」では、補正項目として骨材の表面水率、粗骨材の過小粒、細骨材の過大粒などが挙げられている。骨材の表面水率を測定する技術として、マイクロ波式や RI 式などの水分計が普及している。しかし、骨材の粒度を測定する技術に関しては、生産工場での実用化が進んでいない現状がある。

フレッシュコンクリートの品質に影響を及ぼす骨材の粒度は、JISA 1102「骨材のふるい分け試験方法」によって試験される。しかし、本試験は試料の採取・縮分、高温乾燥・冷却、ふるい分け、計算といった一連の作業を含み、結果が判明するまでに数時間から1日の時間を要する。そのため、日中における粒度の変動を把握することは困難である。

これらに対処するために、即時に粒度を予測できる技

術の確立を目指し、AI技術の活用により骨材の撮影画像から粒度を予測することを試みた。その検討のなかで、粒度の予測のために使用する画像に対して種々の画像処理を施し、予測精度の向上が期待される方法について調査した。本論文では、画像の前処理方法別に粒度の予測を行い、予測性能を比較した結果について詳述する。

2. 画像処理の概要

画像処理は、予測に不要な情報(ノイズ)の低減や、特徴抽出のために用いられ、医療、監視、自動運転、農業、製造業などの様々な分野における画像認識で重要な役割を果たす。本章では、検討した画像処理の具体的な手法について説明する。

2.1 グレースケール変換

一般的なカメラで取得されるカラー画像の多くは、RGB (Red, Green, Blue) の3成分別に0~255の数値を示し、色情報を表現する。一方で、グレースケール(濃淡)画像は1成分に0~255の数値を示し、明るさの情報だけを表現する。カラー画像はグレースケール画像に比べて情報量が多いが、画像解析ではカラー画像における色情報が不要な情報となりうる可能性がある。本検討では、式(1)によりグレースケール変換を行った。

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (1)$$

ここで、 Y : グレースケール変換後の画素値, R , G , B : 赤成分, 緑成分, 青成分のそれぞれの画素値を表す。

2.2 二値画像処理

二値画像変換は、グレースケール画像をあるしきい値にもとづき黒(0)と白(255)の2色だけで表現する処理である。この処理により、画像のコンターや特徴を際立たせることが可能である。二値画像変換にはさまざまな手法があるが、検討した2つの手法について説明する。

*1 UBE三菱セメント(株) 研究所コンクリート研究室生コン・特殊コングループ 工修 (正会員)

*2 UBE三菱セメント(株) 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 工博

*3 UBE三菱セメント(株) 研究所コンクリート研究室 室長 工修

(1) 大津の二値化 (判別分析法) ³⁾

大津の二値化は、画像全体の画素値に基づき最適な閾値を自動的に決定するアルゴリズムである。全体の画素を考慮するため、背景と前景の明度の差が明確な画像には効果的であるが、照明条件が不均一な画像に対しては最適な閾値が得られない場合がある。図-1 に二値化後の画像例を示す。背景が大理石模様の画像では文字だけが抽出されているのに対し、背景の明度が不均一な画像では文字の一部が判別されていないことがわかる。

図-2 に閾値の算出イメージを示す。まず、画像から各画素(図の例では 147,456 画素)における画素値を読み込み、画素値のヒストグラムを作成する。作成されたヒストグラムを2つのクラスに分け、式(2)および式(3)によりクラス内分散 σ_w^2 とクラス間分散 σ_b^2 を画素値ごとに算出する。その後、式(4)により2つのクラス間の分離度 X を画素値ごとに算出し、その分離度が最大となる画素値を閾値として設定する。図の例では閾値が135となる。

$$\sigma_w^2 = \frac{n_1\sigma_1^2 + n_2\sigma_2^2}{n_1 + n_2} \quad (2)$$

$$\sigma_b^2 = \frac{n_1(\mu_1 - \mu)^2 + n_2(\mu_2 - \mu)^2}{n_1 + n_2} \quad (3)$$

$$X = \frac{\sigma_b^2}{\sigma_w^2} \quad (4)$$

ここで、 n : 画素数、 σ^2 : 分散、 μ : 平均を示す。なお、添字の1, 2 はそれぞれクラス1, クラス2を表す。

(2) 適応二値化

適応二値化は、二値化を行う画素(着目している画素)を中心に、その周辺領域を含む各画素の画素値に基づく統計量から閾値を設定して二値化を行う手法である。適応二値化では、局所領域ごとに二値化を行うため、画像内の照明条件が均一でない場合でも、その影響を低減し処理を実行できる。また、複雑な形状やパターンに対して、その情報を保持したまま二値化が可能である。図-1 に示すように、背景が大理石模様の画像では文字と模様が抽出されているのに対し、背景の明度が不均一な画像では文字だけが判別されていることがわかる。本検討では、閾値を算術平均により算出した。

2.3 エッジ検出処理 ^{4), 5)}

エッジ検出処理とは、画像中の画素値が急激に変化する部分を抽出する処理である。換言すれば、画像内における物体の輪郭を検出する処理ともいえる。本検討では、Canny 法に基づく画像処理によりエッジ検出を行った。

Canny 法に基づくエッジ検出では、まず2種類の空間フィルタ処理を適用した。図-3 に空間フィルタ処理の概要を示す。空間フィルタ処理は、オペレータ(またはカーネル)と呼ばれる重みづけのための矩形行列を用いて積和演算(畳み込み演算)を行う。



図-1 二値化後の画像例




図-2 閾値の算出イメージ (大津の二値化)

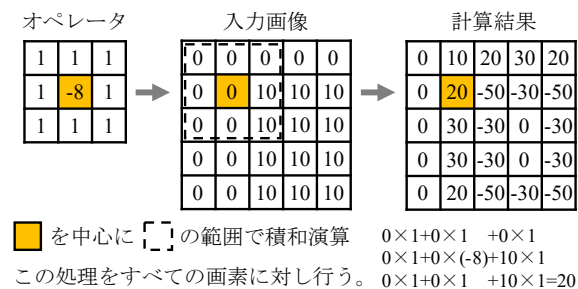


図-3 空間フィルタ処理の概要

1 つ目の空間フィルタ処理では、平滑化フィルタ処理と呼ばれる画像をなめらかにする処理が行われ、画像をぼかしたり、画像のノイズを除去したりすることに使用される。平滑化フィルタ処理では、5×5画素の Gaussian オペレータを適用した。

2 つ目の空間フィルタ処理では、エッジ検出フィルタ処理を行う。この処理では3×3画素の Sobel オペレータを使用した。水平方向および垂直方向の積和演算を行ったあとの画素値(勾配) I_x, I_y を用いて、式(5)および式(6)により勾配強度 I と勾配方向 θ を算出した。

$$I = \sqrt{I_x^2 + I_y^2} \quad (5)$$

$$\theta = \tan^{-1} \left(\frac{I_y}{I_x} \right) \quad (6)$$

次に、勾配強度 I と勾配方向 θ に基づき、勾配強度画像からエッジの画素だけを残すため、非最大抑制(細線化)を行った。非最大抑制は、エッジの画素を1画素幅の細線状にし、エッジを強調するための処理である。

続いて、元の画像全体における画素値の中央値 m を算出した。そして、式(7)および式(8)により中央値 m から上側閾値 T_1 および下側閾値 T_2 を設定した。

$$T_1 = \min[255, (1+\alpha) \times m] \quad (7)$$

$$T_2 = \max[0, (1-\alpha) \times m] \quad (8)$$

ここで、 α : 調整係数 (本検討では 0.33) を示す。なお、 $\min[a, b]$ ($\max[a, b]$) は、 a および b の小さい(大きい)値を出力する演算である。

最後に、エッジの候補である画素ごとに、算出された勾配強度と、上側閾値 T_1 および下側閾値 T_2 とを比較し、エッジの判別を行った。

3. 実験概要

本実験では、学習時と異なる粒度分布を有する骨材をテストデータに使用して、予測精度を向上させつつ、予測結果のばらつきを低減することができる画像の前処理方法について検討した。

3.1 データの取得方法

骨材の種類は硬質砂岩とし、気乾状態の粗骨材を使用した。試料は、合計量が 4 kg となるように、事前にふるい分けられた単一粒径の骨材をそれぞれ計量し、所定の粒度分布になるよう調整した。写真-1 に試料の撮影状況を示す。骨材の撮影には、スマートフォン (Apple 社製、製品名: iPhone 12 mini) を使用し、撮影時の画素数は 3,024×3,024 画素 (画像分解能: 0.15 mm/画素) とした。照明機器には、LED 照明 (エス・エフ・シー社製、製品名: テクニカルライト LED2) を使用した。試料が静置される箇所での照度は、3,400 lx 程度であった。

作業者間の予測結果のばらつきを低減する目的で、試料の静置方法を定めた。写真-2 に試料静置の様子を示す。まず、試料を注ぎ口付のバケツ容器 (寸法: ϕ 320 mm × H275 mm) に移し、粒の偏りが生じないように鍋振りの要領でバケツ容器内の試料を混合した。次に、試料を静置



写真-1 試料の撮影状況




写真-2 試料静置の様子

するための容器 (寸法: W435 mm × D435 mm × H52 mm) の中央にスランブコーンを逆さにして配置した。その後、試料を一方向からスランブコーン内に投入したのち、スランブコーンを鉛直に引き上げて骨材を山の形に敷き並べた。なお、試料の投入時間および 300 mm の高さまでスランブコーンを引き上げる時間は 1 秒~2 秒とした。

表-1 粒度水準 (実測値)

(a) 訓練データおよび評価データ

質量分率 (%)					粗粒率 F.M	質量分率 (%)					粗粒率 F.M	質量分率 (%)					粗粒率 F.M
~2.5 mm	2.5 ~5.0 mm	5.0 ~10 mm	10 ~20 mm	粗粒率		~2.5 mm	2.5 ~5.0 mm	5.0 ~10 mm	10 ~20 mm	粗粒率		~2.5 mm	2.5 ~5.0 mm	5.0 ~10 mm	10 ~20 mm	粗粒率	
0	0	15	85	6.85	2	5	8	85	6.76	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			

(b) テストデータ

質量分率 (%)					粗粒率 F.M
~2.5 mm	2.5 ~5.0 mm	5.0 ~10 mm	10 ~20 mm	粗粒率	
0	0	27	73	6.73	
0	2	52	46	6.44	
1	3	26	70	6.65	
2	2	32	64	6.58	
2	4	55	39	6.31	
3	3	16	78	6.69	
3	5	43	49	6.38	
4	6	27	63	6.49	
4	7	13	76	6.61	
4	8	44	44	6.28	

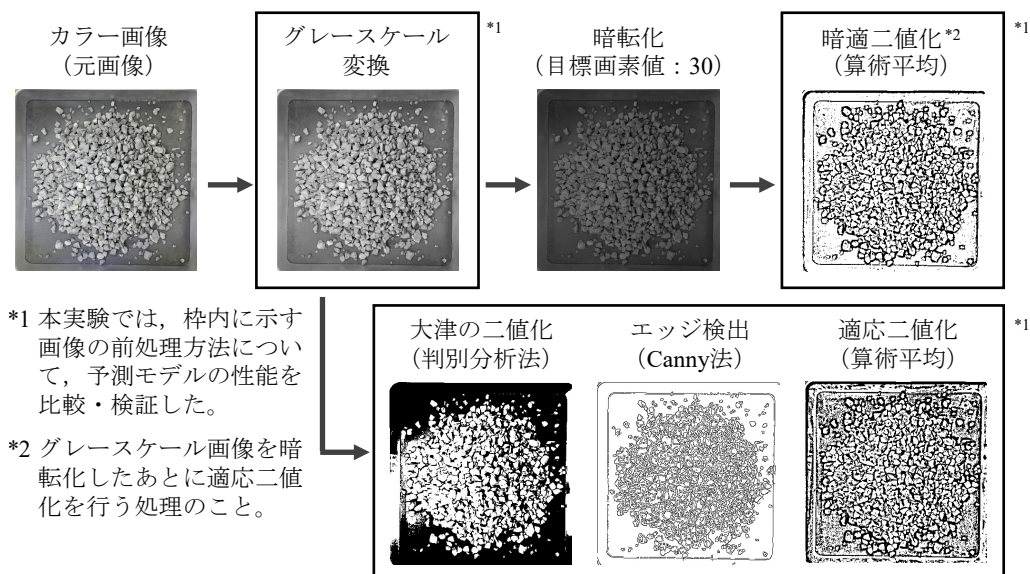


図-4 画像の前処理手順と画像例

画像データの取得は、試料を敷き並べて一定の高さから撮影する操作を繰り返し、1水準につき10回行った。表-1に「訓練データおよび評価データ」と「テストデータ」に使用した粗骨材の粒度水準を示す。粗骨材は所定の質量分率と粗粒率になるよう、粒度区分ごとに事前にふるい分けされた単一粒径の骨材をそれぞれ計量および混合して使用した。なお、表中の数値は「実測値」を意味する。

3.2 データの前処理方法

図-4に画像の前処理手順と画像例を示す。まず、カラー画像に対しグレースケール変換を行ったのち、大津の二値化、エッジ検出、および適応二値化のそれぞれの処理を行った。一方で、適応二値化については、グレースケール画像を暗転化したあとに適応二値化を行う手法(以下、暗適二値化と称する)も準備した。暗転化の目的は、全体的な画像の明るさを低下させることで、相対的に明るい部分(対象物)を際立たせ、背景のノイズを低減することである。暗転化は、目標画素値(本実験では30に設定した)と画像内における画素値の平均値との比率を各画素に乘じることで行った。

3.3 予測モデルの準備方法

入力データは、384×384画素(画像分解能:1.18mm/画素)にリサイズした画像を使用した。予測精度の向上および過学習の抑制を図る目的で、画像データ数を拡張した。データの拡張方法は、元画像の明るさおよびコントラストをランダムに変化させ、画像1枚につき9枚の画像を生成した。さらに、元画像および生成画像に対して上下左右を反転させ、画像1枚につき3枚の画像をさらに生成し、計12,000枚(300枚×10種類×4種類)の画像データを得た。得られた画像データは、9,240個の訓練

データ(77%)と2,640個の評価データ(23%)にランダムで分割し、予測モデルの作成に使用した。その後、前述した画像の前処理方法別に予測モデルを作成した。

図-5にディープニューラルネットワークの構成および予測値の出力方法を示す。予測モデルの作成には、6層の畳み込み層を有する畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)を使用した。畳み込み層の後にバッチ正規化および最大値プリーング層を、全結合層の後にドロップアウト(欠損率:30%)を適用した。損失関数には式(9)に示すHuber損失を使用し、損失値(Loss)を算出した。

$$\text{Loss} = \begin{cases} \frac{1}{2}|\epsilon|^2, & (|\epsilon| \leq \delta \text{ の場合}) \\ \delta \left(|\epsilon| - \frac{1}{2}\delta \right), & (|\epsilon| > \delta \text{ の場合}) \end{cases} \quad (9)$$

ここで、 $|\epsilon|$: 予測値と実測値の絶対誤差(以下、単に絶対誤差という)、 δ : 任意の値(本実験では1.0)を表す。

損失値に基づく重みの最適化は、エポック数(学習回数)を10,000、バッチサイズを64、L2正則化(荷重減衰)の係数を0.1として、最適化アルゴリズムにAdam⁶⁾を使用したミニバッチ勾配降下法により行った。

畳み込みニューラルネットワークの出力は、粒度区分ごとの質量分率(粒径2.5mm以下, 2.5mm~5.0mm, 5.0mm~10mm, 10mm~20mmの4項目)とした。また、出力された粒度区分ごとの質量分率に基づき粗粒率を算出し、出力された質量分率と算出した粗粒率はいずれも「予測値」とした。

3.4 予測モデルの評価方法

予測モデルの汎化性能(未知データに対する予測性能)を評価するため、訓練データと異なる粒度水準のテストデータを使用した(表-1参照)。予測精度の評価には、

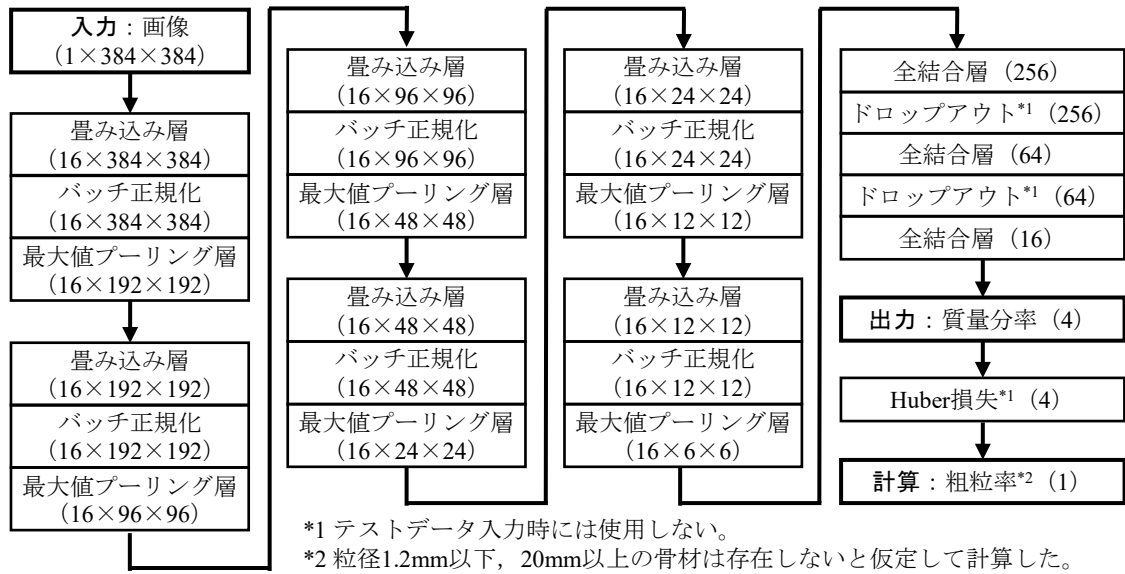


図-5 ディープニューラルネットワークの構成および予測値の出力方法

式(10)に示す正解率(Accuracy)を用いて行った。また、ばらつきの評価は、各絶対誤差の平均値および標準偏差の合計($\mu + \sigma$)により行った。これらの指標により、予測モデルの性能を包括的に評価した。

$$\text{Accuracy} = \frac{a}{N} \times 100 \quad (10)$$

ここで、 a ：粗粒率の実測値と予測値との誤差が ± 0.10 以内であるテストデータ数、 N ：テストデータの総数

4. 実験結果および考察

図-6に画像の前処理方法別の予測精度とばらつきを示す。上側のグラフは正解率(Accuracy)を示し、数値が高いほど、予測精度が高いことを表す。下側のグラフは各絶対誤差の平均値および標準偏差の合計($\mu + \sigma$)を示し、数値が小さいほど、ばらつきが小さいことを表す。

まず、画像の前処理を行っていないカラー画像と、グレースケール変換、大津の二値化およびエッジ検出の処理を行った画像を比較した結果について説明する。正解率は、いずれの前処理方法でも、カラー画像と比較すると高くなった。特に、グレースケール変換を行った画像の正解率は92%(+12%)と最も高く、次いで大津の二値化を行った画像の正解率は87%(+7%)と高かった。エッジ検出を行った画像の正解率は、カラー画像の正解率よりも若干高い82%(+2%)であった。また、各絶対誤差の平均値および標準偏差の合計は、グレースケール変換、大津の二値化、エッジ検出、カラー画像の順に小さく、一貫した結果が得られた。以上の結果から、色情報に起因するノイズを排除し、明るさの情報だけを保持することが、予測精度の向上やばらつきの低減に影響が大きいものと考えられる。





図-6 画像の前処理方法別の予測精度とばらつき

大津の二値化では、一定の精度改善が認められたものの、グレースケール変換には及ばなかった。その理由として、静置された試料に対する影の部分と明るい部分が同一画像内に混在しているケースがあり、これが閾値の決定を不安定にしたものと推察する(図-1参照)。また、図-7にエッジの誤検出要因を示す。エッジ検出で精度の改善効果が小さかった一因として、骨材の模様や陰影がエッジとして検出されたこと、重なった骨材どうしが区別されないケースがあることが挙げられる。

続いて、カラー画像と、適応二値化を行った画像を比較した結果について説明する。カラー画像の正解率と比較して、適応二値化の正解率は77%(-3%)と低かった。

予測精度への寄与が小さかった理由として、骨材に含まれる粉塵が、撮影を繰り返すなかで容器の下地(背景)に付着し、色むらを生じさせたことが一因であると考えられる。図-4を見ると、適応二値化を行った画像では、背景にノイズが多く存在していることは明らかであり、このノイズが予測精度に負の影響を与えた可能性がある。

そこで、背景のノイズを低減した暗適二値化の結果に着目する。暗適二値化を行った画像の正解率は、適応二値化の処理を行った画像の正解率と比較して13%高くなった。これは、暗転化によるノイズの低減が、予測精度の向上に寄与することを示唆している。

図-8に質量分率の実測値と予測値の関係を示す。なお、図中のプロットは、重なっている点数が多いほど色濃く反映される。粒度区分ごとの質量分率で見ても、カラー画像と比較して、グレースケール変換、大津の二値化、エッジ検出および暗適二値化では、予測結果のばらつきが小さいことが確認できる。しかし、暗適二値化以外の手法では、粒径が10mm~20mmの予測値は実測値よりも大きく、粒径が5mm~10mmの予測値は実測値よりも小さくなる傾向にあった。一方で、暗適二値化では、予測結果の偏りは見られず、予測値は実測値±10%の範囲に概ね収まっていた。このことから、暗適二値化は他の手法よりも安定した結果を提供することがわかった。

5. まとめ

画像の前処理方法別に骨材粒度の予測を行い、予測性能を比較した結果、以下のことが明らかとなった。

- (1) グレースケール変換が最も高い正解率を示し、次いで大津の二値化、エッジ検出が続くことが確認された。これにより、色情報を排除し、明るさの情報だけを保持することが予測精度の向上に寄与することが判明した。
- (2) 適応二値化は、粉塵による背景の色むらが影響し、カラー画像と比較して正解率が低下した。一方、暗適二値化はノイズを低減し、予測精度を向上させることが示唆された。
- (3) 暗適二値化は他の手法よりも優れた予測性能と安定性を提供し、本手法の有効性が示された。

参考文献

- 1) たとえば、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) 全国生コンクリート工業組合連合会：生コン工場品質管理ガイドブック（第6次改訂版）、p.191-196、2019.10



図-7 エッジの誤検出要因

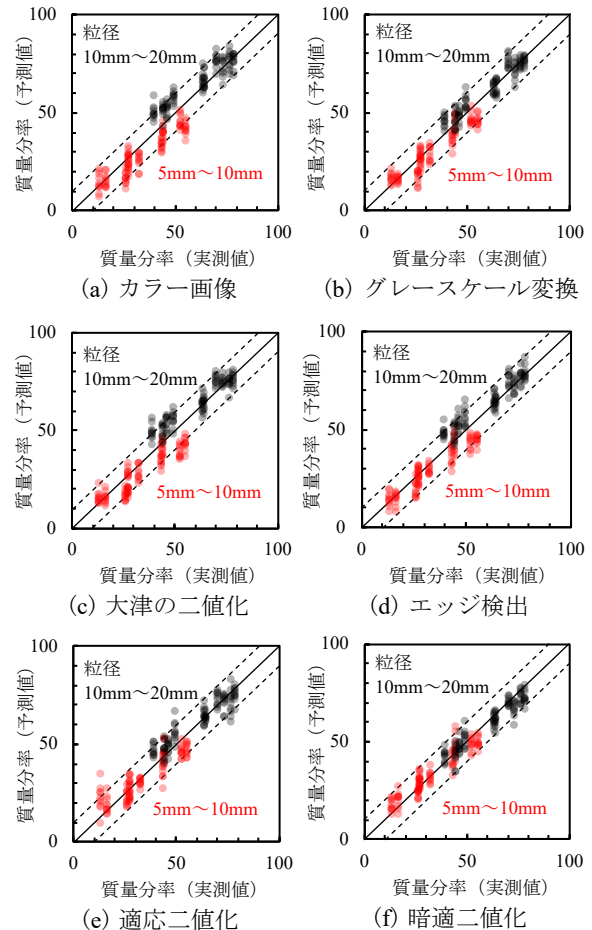


図-8 質量分率の実測値と予測値の関係

- 3) 大津展之：判別および最小2乗規準に基づく自動しきい値選定法、電子通信学会論文誌D、Vol.63、No.4、pp.349-356、1980
- 4) 小枝正直、上田悦子、中村恭之：OpenCVによる画像処理入門 改訂第3版、p.129-148、2022
- 5) J. Canny: A Computational Approach to Edge Detection, IEEE Transactions of Pattern Analysis Machine Intelligence, vol.8, No.6, pp.679-698, 1986.11
- 6) D. Kingma, J. Ba: Adam: A Method for Stochastic Optimization, International Conference on Learning Representations (ICLR), pp.1-15, 2015