

論文 AI を用いた練混ぜ画像からの VC 値の予測に関する検討

工藤 正智^{*1}・大森 寛人^{*1}・岸良 竜^{*2}

要旨：超硬練りコンクリートの製造時の品質を簡便に評価できる方法が求められている。本研究では、粗骨材の最大寸法 20mm および 40mm の超硬練りコンクリートを対象に、AI を用いた練混ぜ画像からの VC 値の予測方法を検討した。予測モデルは、学習を練混ぜ画像のみとする場合と、練混ぜ画像に配合情報を加えた場合の 2 種類とした。いずれの予測モデルでも VC 値の実測値と予測値の間には正の相関が得られ、特に練混ぜ画像に配合情報を加えた予測モデルで高い正解率が得られた。学習させる配合情報のうち、粗骨材の最大寸法、単位水量および単位容積質量は予測精度に及ぼす影響が大きかった。

キーワード：VC 値、練混ぜ画像、AI、ニューラルネットワーク

1. はじめに

重力式コンクリートダムでは、経済性および施工性の高さから、RCD (Roller Compacted Dam) 工法が採用されることが多い。ゼロスランプの超硬練りコンクリートが用いられ、JSCE F 507-2023「超硬練りコンクリートのコンシステンシー試験方法」(以下、VC 試験)で品質管理が行われる。VC 試験では、試料の入った容器を振動台に固定し、上載用重りを試料に載せ、振動開始からモルタルの浮き上がりまでに要した時間を VC 値として求める。VC 試験は、産業用電源が必要かつ試験者の労力も非常に大きいことが課題となっている。

現在、画像処理技術の発展やコンピュータの高性能化にともない、コンクリート分野で品質安定や生産性向上に向けた様々な DX 技術の開発が進められている^{例えば 1)}。著者らは、AI を用いてコンクリートの練混ぜ画像から練上がり直後のスランプを予測する方法を開発し、既に実用化している²⁾。この方法では、あらかじめコンクリート製造時の練混ぜ画像を AI に学習させ、予測モデルを構築することで、未知の練混ぜ画像からスランプの予測値を得ることができる。解析用カメラの設置は比較的容易であり、実プラントへの適用性が高い。また、継続的な学習が予測精度の維持、向上に有効であることを確認している²⁾。練混ぜ画像とスランプの関係性の抽出には畳み込みニューラルネットワークを用いており、スランプに加えて、インターロッキングブロックの触感評価についても一定の予測が可能であること確認している³⁾。同様の方法が超硬練りコンクリートの VC 値予測に適用できれば、品質管理の省力化や品質向上が期待できる。

本研究では、AI を用いて練混ぜ画像および配合情報から VC 値を予測することを試み、予測精度を評価した。既往の研究でもニューラルネットワークを用いた検討は見られるが⁴⁾、比較的容易にデータ取得ができる練混ぜ画像を VC 値予測に用いた点に本研究の特色がある。対

象とするコンクリートの粗骨材の最大寸法 (Gmax) は 20mm および 40mm とし、単位水量および細骨材率を変化させた場合の練混ぜ画像を取得した。取得した練混ぜ画像および配合情報を用いて AI により VC 値を予測するモデルを構築し、予測精度を評価した。さらに、学習数や練混ぜ画像の輝度値、学習させる配合情報に着目し、予測精度に及ぼす影響について分析した。

2. 試験概要

2.1 使用材料・配合

使用材料を表-1 に示す。セメントは普通ポルトランドセメントを、細骨材は砕砂および海砂を、粗骨材は砕石 2005 および砕石 4005 を使用した。細骨材は、コンクリート標準示方書ダムコンクリート編⁵⁾に示される粒度分布となるように所定の割合で混合した。なお、一般にダム用コンクリートでは Gmax150mm が使用されるが、使用したミキサの都合上、Gmax40mm とした。

コンクリートの配合および実測 VC 値を表-2 に示す。なお、配合名は、第一項目は Gmax、第二項目は s/a、第三項目は単位水量を表している。W/C は 80% で一定とした。VC 値で管理される RCD 用コンクリートでは、VC 値の管理目標を 20±10 秒とする場合が多い⁶⁾。ここでは目標 VC 値は 20 秒を基準とし、単位水量および細骨材

表-1 使用材料

材料名	記号	備考
水	W	上水道水
セメント	C	普通ポルトランドセメント 比表面積 3310cm ² /g, 密度 3.16g/cm ³
細骨材	S1	海砂, 表乾密度 2.58g/cm ³ , 唐津産
	S2	砕砂, 表乾密度 2.64g/m ³ , 宮野産
粗骨材	G1	砕石 2005, 表乾密度 2.69 g/cm ³ , 実積率 62.1%, 宮野産
	G2	砕石 4020, 表乾密度 2.71g/cm ³ , 実積率 60.1%, 宮野産
混和剤	Ad	AE 減水剤 (遅延形)

*1 太平洋セメント (株) 中央研究所 高機能コンクリートチーム (正会員)

*2 太平洋セメント (株) 中央研究所 高機能コンクリートチーム リーダー 博 (工) (正会員)

表－2 配合および実測 VC 値

配合名	W/C (%)	Gmax (mm)	s/a (%)	単位量(kg/m ³)					Ad (C×%)	実測 VC 値* (秒)
				W	C	S	G1	G2		
G20-s32-W115	80	20	32	115	144	689	1509	0	0.25	20.8
G20-s37-W105			37	105	131	810	1422	0		40.3
G20-s37-W110				110	138	804	1410	0		26.8
G20-s37-W115				115	144	797	1399	0		19.9
G20-s37-W125				125	156	783	1375	0		8.0
G20-s47-W115			47	115	144	1013	1176	0		27.7
G40-s32-W110		40	32	110	138	695	761	766		8.9
G40-s37-W90			37	90	113	830	728	734		60.1
G40-s37-W100				100	125	817	717	722		30.5
G40-s37-W105				105	131	810	711	716		19.9
G40-s37-W110				110	138	804	705	710		12.5
G40-s37-W120				120	150	790	693	698		3.9
G40-s47-W110			47	110	138	1021	593	597		29.8

* 連続 8 バッチの平均

率を変化させることで、VC 値を変化させた。Gmax20mm の場合、単位水量は 105, 110, 115 および 125kg/m³ の 4 水準とし、Gmax40mm の場合、単位水量は 90, 100, 105, 110 および 120kg/m³ の 5 水準とした。いずれの Gmax においても細骨材率は 37%を基準とし、32%および 47%を加えた 3 水準とした。

2.2 試験項目および方法

試験項目および方法を表－3 に示す。VC 試験は、JSCE F 507-2007 による標準 VC 試験に準拠した。ただし、Gmax が 20mm および 40mm のため、VC 試験およびスランブの測定においてウェットスクリーニングは実施していない。なお、各配合において代表的なバッチでスランブ試験も実施したが、実測スランブは 0.0cm であった。

2.3 練混ぜ方法

練混ぜは 20±2℃、70±5%RH の恒温室内で行った。練混ぜには、強制練りミキサ水平二軸形（公称容量 60L）を用いた。練混ぜ量は 35L とし、まずセメントおよび細骨材をミキサに投入し練混ぜを 20 秒間行い、注水した後に 30 秒、粗骨材投入後に 120 秒間練混ぜを行った。1 配合につき 8 バッチを連続して練混ぜを行い、計 104 バッチのデータ収集を行った。

2.4 練混ぜ画像の取得方法

ミキサ直上に設置したデジタルカメラにより、コンクリートの練混ぜ画像を取得した。練混ぜ画像の解像度は 1920×1080px とし、フレームレートは 30FPS、撮影領域はミキサ全体とした。

2.5 予測モデルの構築および検証


まず、練混ぜ画像と実測 VC 値の関連付けを行った。撮影したミキサ全体の 1920×1080px の画像から、ミキサ中央部 256×256px（120×120mm）を切り出し、さらに 64×64px に圧縮した。その後、輝度値 0 を黒、輝度値 255 を白とした 256 階調でグレースケール化した。ミキサからのコンクリート排出の 20 秒前を基点に、基点か

表－3 試験項目および方法

試験項目	対象	試験方法
VC 値	全バッチ	JSCE F 507-2023
スランブ	1 回/配合	JIS A 1101

表－4 画像+配合 AI 構築に用いた配合情報

入力項目	値
Gmax(mm)	20, 40
s/a(%)	32, 37, 47
単位水量(kg/m ³)	90～125
単位セメント量(kg/m ³)	113～156
単位細骨材量(kg/m ³)	689～1021
単位粗骨材量(kg/m ³)	1176～1527
単位容積質量(kg/m ³)	2439～2495



図－1 グレースケール化した練混ぜ画像の例

ら 15 秒間の画像を抽出し、1 バッチあたり計 450 枚の練混ぜ画像と 1 つの実測 VC 値を関連付けた。使用したデータセット数は、合計 46,800 である。

グレースケール化した練混ぜ画像の例を図－1 に示す。画像サイズが一定のため、1 つの骨材粒子が画像内で占める割合は Gmax20mm より Gmax40mm が大きくなる。

予測モデルは、練混ぜ画像のみを学習させた畳み込みニューラルネットワークの一種である 3D-Mix Conv Model⁷⁾（以下、画像 AI）と、練混ぜ画像に加え配合情報も学習させた Multi Modal Model⁸⁾（以下、画像+配合 AI）の 2 種類を構築した。画像+配合 AI における学習に使用した配合情報は表－4 のとおりである。

予測モデルの構築および検証では、交差検証を行った。交差検証では、使用データを学習データと未学習の検証

データに分割する。学習データを用いた予測モデルの構築と、検証データを用いた検証を行い、この学習・検証の過程を1セットとする。1セットあたりの検証データは3バッチまたは2バッチのデータとし、検証データに未使用の5バッチのデータを学習データとした。学習データと検証データを入れ替えて複数セットの学習・検証を行うことで、学習データと未学習データを区別しつつ、全バッチが検証対象となるようにした。本検討では3セットの学習・検証を行った。検証データが2バッチの場合の検証データは、ランダム抽出した。

3. 試験結果

3.1 実測 VC 値

実測 VC 値と単位水量の関係を図-2 に示す。Gmax によらず、単位水量の増加にともない実測 VC 値は直線的に減少した。単位水量が同一でも、Gmax40mm より Gmax20mm の実測 VC 値は大きい。これは、砕石 4005 より砕石 2005 の実積率が小さく、さらに粗骨材の表面積も大きいためと考えられる。

実測 VC 値と s/a の関係を図-3 に示す。VC 値が最小となる s/a が存在するとされる⁹⁾が、本研究では s/a を 32～47%と比較的大きく変化させたものの、Gmax20mm の実測 VC 値の変化は緩やかであり、明瞭なピークは確認できない。これは、VC 試験においてウェットスクリーニングを行っていないため、試験容器中のコンクリートのモルタル量が相対的に少ないことが影響したものと推察される。Gmax40mm では、s/a を Gmax20mm と同一としたこともあり、最小ピークの確認には至らなかった。

3.2 実測 VC 値と予測 VC 値の関係

実測 VC 値と予測 VC 値の関係について、画像 AI を図-4 に、画像+配合 AI を図-5 に示す。なお、図中の点線は許容差±5 秒、破線は許容差±10 秒を示している。予測モデルによらず相関係数は 0.7 以上となり、実測 VC 値と予測 VC 値の間には一定の正の相関が認められた。画像+配合 AI では、相関係数 0.9 以上の強い相関が得られ、Gmax によらず全プロットが許容差±10 秒の範囲内となった。一方、画像 AI では、実測 VC 値が大きいほど Gmax40mm の予測 VC 値は実測値より低くなる傾向がみられた。次節で各 VC 値における学習数を示しているが、学習数は実測 VC 値 50～70 秒が少なく、10～30 秒が最も多い。学習数が不十分なため図-4 に示すように実測 VC 値 60 秒付近の予測値は実測値から乖離し、さらに学習数の多い VC 値 10～30 秒に近づく側に予測する傾向を示したと考えられる。

3.3 正解率

予測値と実測値の差分を算出し、検証した全件数に対し差分が許容差内に収まる割合を正解率とした。正解率




図-2 実測 VC 値と単位水量の関係




図-3 実測 VC 値と s/a の関係




図-4 予測 VC 値と実測 VC 値の関係(画像 AI)




図-5 予測 VC 値と実測 VC 値の関係(画像+配合 AI)

と許容差の関係を図-6 に示す。当然ながら、許容差が大きくなると正解率は高くなる。図より、Gmax によらず全般的に画像 AI より画像+配合 AI の正解率が大きくなった。VC 値の管理目標は±10 秒とすることが多く⁹⁾、また±5 秒で評価した検討事例⁴⁾も見られることを参考に、本検討では許容差±5 秒、10 秒とした場合の正解率を評価した。画像 AI の正解率は、許容差±5 秒で 47~63% であり、許容差 10 秒でも 70%程度に留まった。画像+配合 AI の正解率は、許容差±5 秒で 98~100%、許容差±10 秒では 100%になった。Gmax の違いに着目すると、予測モデルによらず Gmax が大きいほど正解率は小さくなる傾向がみられた。

3.4 学習数と正解率

実測 VC 値の学習数および画像 AI における正解率(許容差±5 秒、10 秒)を図-7 に示す。ここで、実測 VC 値は 0~10 秒、10~30 秒、30~50 秒および 50~70 秒の 4 つに区分した。図より、学習数は 10~30 秒が最も多く、その他はおおむね同程度である。Gmax20mm の実測 VC 値が 0~50 秒の範囲に分布しているのに対し、Gmax40mm では 50~70 秒のデータを含むより広範囲のデータが得られている。Gmax によらず学習数と正解率は類似した分布となり、学習数が多いほど正解率が高くなる傾向がみられた。ただし、Gmax40mm では学習数のピークと正解率のピークにずれがみられる。これは、Gmax20mm と比べより広範囲の実測 VC 値を学習させたことが影響したものと考えられる。既往のスランプ予測に関する検討²⁾では、同様の画像 AI の予測モデルにおいて学習数の増加が正解率の向上に有効であることを確認している。VC 値についても、学習数の増加は正解率向上に有効であると考えられる。

同様に実測 VC 値の学習数および画像+配合 AI における正解率(許容差±5 秒)を図-7 に示す。実測 VC 値の学習数は画像 AI と同一であるが、Gmax によらず、いずれの実測 VC 値でも正解率はほぼ 100%となった。この結果は、画像 AI と比較して画像+配合 AI は一定の予測精度を確保するために必要となる学習数が少ないことを

示すものといえる。実測 VC 値 30~50 秒および 50~70 秒の正解率から判断すると、許容差±5%においておおむね 30 件の学習で 90%以上の正解率を確保できるものと考えられる。

3.5 練混ぜ画像の輝度値の分布

各配合における全 8 バッチの練混ぜ画像を用いて、輝度値の分布を求めた。グレースケール化した練混ぜ画像に対し、ある輝度値を有するピクセル数を集計した。なお、練混ぜ画像内の大半はコンクリートが占めているが、一部にはミキサの攪拌翼および回転軸も写っているため、攪拌翼および回転軸の輝度値も含む集計となっている。

s/a を 37%とし、単位水量を変化させた時の輝度値の分布について、Gmax20mm および Gmax40mm の結果を図-8 に示す。細骨材率および単位水量が同一の場合、Gmax20mm と比較して 40mm の輝度値のピーク高さは小さい。また、Gmax によらず、単位水量が大きいほど輝度値のピークが低くなり、ブロードな分布となる傾向がみられた。単位水量を変化させると、モルタル中のセメントペーストと細骨材の比率が変化するが、このことが輝度値の分布の変化に影響した可能性が考えられる。

単位水量が 20kg/m³ 変化した時のピーク高さは、Gmax20mm では 65×10⁶px、Gmax40mm では 44×10⁶px 変化し、わずかではあるが Gmax20mm の変化が大きい。粗骨材径の違いにより、表面積や粗骨材粒子が形成する凹




図-6 正解率と許容差の関係




図-7 学習数および正解率




図-8 輝度値の分布(s/a37%)




図-9 輝度値の分布(単位水量 115kg/m³)

凸が異なると考えられ、このことが輝度値に影響を及ぼした可能性があるが現時点では不明である。

単位水量を同一とし、s/a を変化させた時の輝度値の分布について、Gmax20mm および Gmax40mm の結果を図-9 に示す。s/a の変化によりピークの高さおよびピーク位置が変化するものの、Gmax の違いによりその傾向は一定ではなかった。

Gmax, 単位水量および s/a の違いにより実測 VC 値が変化するが、同様に練混ぜ画像の輝度値の分布も変化することが確認された。図-6 において、Gmax 40mm より Gmax20mm の正解率は高く、輝度値の分布の変化の違いが正解率に影響を及ぼしている可能性が考えられる。

3.6 画像+配合 AI における入力項目の重要度分析

要因分析では、画像+配合 AI における入力項目が正解率に及ぼす影響について Permutation Importance¹⁰⁾を用いた。Permutation Importance では、表-5 に示す全ての入力項目を用いて構築した予測モデルの正解率を基準とする。その後、評価したい入力項目の数値をランダムに並び替え（シャッフル）したものを検証データとして正解率を算出し、基準とシャッフル後の正解率の変化量（正解率の低下量）が大きいほど、その入力項目が予測モデルにとって重要であると判断する。ここでは入力項目の Gmax, 単位水量, s/a および単位容積質量に着目した。

Permutation Importance の評価結果を表-5 に、入力項

目ごとの正解率の変化量を図-10 に示す。許容差 5 秒では、単位水量, Gmax および単位容積質量による正解率の変化量が大きく、これらの入力項目の予測結果への影響は大きいと判断される。単位容積質量については、セメントペーストと細・粗骨材の密度差を考慮すると、同一 W/C の場合、単位水量の変化に対し単位容積質量はおおむね直線的に変化することから、両者は従属関係にあるといえる。したがって、単位水量の予測結果への影響が大きいのであれば、単位容積質量の影響も大きくなるのは当然といえる。s/a については、正解率の変化量は小さかった。図-9 で示したとおり、s/a の変化により練混ぜ画像の輝度値の分布には変化が見られたものの、画像と併用して学習させる情報としての s/a の重要度は高くないといえる。

許容差 5 秒と異なり、許容差 10 秒では単位容積質量による正解率の変化量は小さくなった。単位水量による正解率の変化量は依然として大きいため、従属関係にある単位容積質量のみ正解率に及ぼす影響が小さくなる理由は不明であるものの、許容差が大きくなると入力項目が少なくてよい可能性を示唆する結果と考えられる。

4. まとめ

本研究では、AI を用いて練混ぜ画像および配合情報から VC 値を予測することを試み、予測精度および予測の

表-5 Permutation Importance の評価結果

評価項目	許容差(秒) 入力項目	±1	±2	±3	±4	±5	±6	±7	±8	±9	±10
基準の正解率	-	49%	82%	95%	100%	100%	100%	100%	100%	100%	100%
シャッフル後 正解率の 変化量	Gmax	-15%	-18%	-26%	-26%	-26%	-26%	-26%	-23%	-23%	-23%
	s/a	-5%	-5%	-8%	-13%	-8%	-5%	-3%	-3%	-3%	-3%
	単位水量	-18%	-28%	-38%	-38%	-38%	-38%	-33%	-28%	-28%	-28%
	単位セメント量	-18%	-36%	-41%	-41%	-36%	-31%	-31%	-26%	-26%	-23%
	単位細骨材量	-8%	-13%	-15%	-18%	-10%	-8%	-5%	-3%	-3%	-3%
	単位粗骨材量	-13%	-10%	-8%	-8%	0%	0%	0%	0%	0%	0%
	単位容積質量	-15%	-18%	-21%	-23%	-21%	-18%	-13%	-5%	-3%	-3%

影響因子について検討した。得られた知見を以下に示す。

- (1) AI により VC 値を予測した結果、実測値と予測値の関係における相関係数は 0.7 以上となった。画像に加えて配合情報を AI に学習させた場合の相関係数は 0.9 以上となり、強い相関が得られた。
- (2) 練混ぜ画像を学習させた AI の正解率は、許容差 10 秒でも 70%程度となった。画像に加え配合情報を学習させた場合の正解率は、許容差±5 秒で 98~100%、±10 秒で 100%となり、高い正解率が得られた。
- (3) 実測 VC 値ごとの学習数および正解率はおおむね類似した分布となり、正解率への学習数の影響がみられた。
- (4) Gmax、単位水量および s/a の違いにより実測 VC 値は変化するが、同様に練混ぜ画像の輝度値の分布も変化する事が確認された。
- (5) 画像に加え配合情報を学習させた場合に正解率に及ぼす影響が大きい入力項目は、Gmax、単位水量および単位容積質量であった。

本研究では、AI により練混ぜ画像から VC 値を予測できる可能性があることを示した。ただし、使用ミキサの制約から Gmax40mm の粗骨材を使用し、VC 試験ではウェットスクリーニングを実施していない。また、Gmax が大きくなると、予測精度が低下する結果も得られている。今後、本方法の RCD 用コンクリートへの適用性を評価するには、使用データ数を増やし、さらに Gmax150mm の粗骨材を用いた検討が必要と考えられる。

謝辞

本研究の AI の構築にあたりパシフィックシステム(株)にご協力を頂いた。

参考文献

- 1) 倉田和英, 松本修治, 橋本学, 柳井修司: 動画画像解析を活用したフレッシュコンクリートの性状判定手法に関する研究。コンクリート工学年次論文集, Vol.42, No.1, pp.959-964, 2020.6
- 2) 工藤正智, 千石理紗, 立岩華英, 江里口玲: AI を用




図-10 入力項目ごとの正解率の変化量

いた練混ぜ画像によるスランプ予測の精度評価に関する検討, コンクリート工学年次論文集, Vol.45, No.1, pp.754-759, 2023.6

- 3) 小池耕太郎, 工藤正智, 石井祐輔, 早野博幸: AI による練混ぜ画像を用いたインターロッキングブロックの品質予測, セメント技術大会講演要旨, Vol.76, No.1313, 2022.5
- 4) 安田登, 堤知明, 松島学, 村上祐治: ニューラルネットワークを利用した超硬練りコンクリートの練混ぜ品質管理手法, コンクリート工学年次論文集, Vol.18, No.1, pp.1329-1334, 1996.7
- 5) 土木学会: 2023 年制定コンクリート標準示方書[ダムコンクリート編], p.53, 2023.10
- 6) 国立研究開発法人土木研究所: CSG の動的引張強度・破壊特性等に関する実験的検討, 土木研究所資料, 第 4320 号, pp.14-15, 2016.3
- 7) Mingxing Tan, Quoc V. Le: MixConx: Mixed Depthwise Convolutional Kernels, arXiv:1907.09595, 2019.12
- 8) Cheick Abdoul Kadir A Kountan: Multimodal deep learning for predicting the choice of cut parameters in the milling process, Intelligent Systems with Applications, Vol.16, 200112, 2022.11
- 9) 国土技術研究センター: RCD 工法技術指針, p.15, 1981.7
- 10) 大場勇樹, 手塚太郎, 讃岐勝, 我妻ゆき子: 健康診断データを用いた疾患予測における解釈可能なモデルの構築: データ工学と情報マネジメントに関するフォーラム, I2-2, 2020.3