

テーマ番号	IEP16		
プロジェクト テーマ	和文	深層学習に基づくコンクリートの締固め判定システムに関する研究	指導教員 長田 茂美 教授
	英文	A Study on Concrete Compaction Judgment System Based on Deep Learning	
プロジェクト メンバー	4EP3-22 小島 弘道 (KOJIMA Hiromichi)		

Abstract The degree of concrete compaction is judged visually by skilled engineers based on their senses and experience. So far, the authors have proposed and evaluated a concrete compaction judgment system based on deep learning, which is an alternative to visual judgment by skilled engineers. In this paper, we propose a learning method that focuses on the decision boundary acquired by the deep learning model and clarifies to further improve the decision accuracy. As a result of the system evaluation experiment, it was confirmed that the proposed method and the system can provide more accurate judgment of the completion of compaction.

Keywords deep learning, concrete compaction, visual judgment, metric learning, between class learning.

1. はじめに

コンクリートは、主にセメント、水、砂（細骨材）および砂利（粗骨材）で構成される。これらの材料を練り混ぜ、型枠に打ち込み、バイブレータ等を用いた“締固め”によって充填し、湿潤状態に養生することで、コンクリートは硬化の準備が整う。この締固めの程度の判定は、従来から熟練技術者の経験に基づく目視や感覚で行われており、このような判定方法はコンクリートの品質のばらつきや品質低下の一因となる懸念がある。昨今、技術者の減少や働き方改革に伴う作業時間の短縮により、コンクリート工の生産性向上が求められており、品質を確保した上での省人化、省力化、あるいは無人化技術の開発が望まれている。

これまでに当研究室では、熟練技術者による目視判定の代替となり得る深層学習に基づくコンクリートの締固め判定システムを提案してきた^[1]。本論文では、システムのさらなる判定精度向上を目指し、深層学習モデルが獲得するクラス間の決定境界に着目して、Metric Learning^[2]および Between-Class(BC) Learning^[3]の両者をうまく併用することによって、その決定境界をより明確化できる学習手法を提案する。さらに、提案手法を導入した深層学習に基づくコンクリートの締固め判定システムの評価実験について述べる。

2. システムと評価方法

2.1 システム概要

図1に、提案システムの概要と深層学習モデルの構造を示す。システムへの入力は、締固め工程におけるコンクリート表面の撮影映像のフレーム画像と、そのコンクリートのフレッシュ性状（まだ固まらない状態の性状）であり、出力は締固め未完了状態を表す [before] と締固め完了状態を表す [just] の 2 クラスの尤度である。予めシステムにフレーム画像およびフレッシュ性状と締固め状態との対応関係を学習させておくことで、システムに入力されたフレッシュ性状をもつフレーム画像は尤度の高いクラスに分類される。

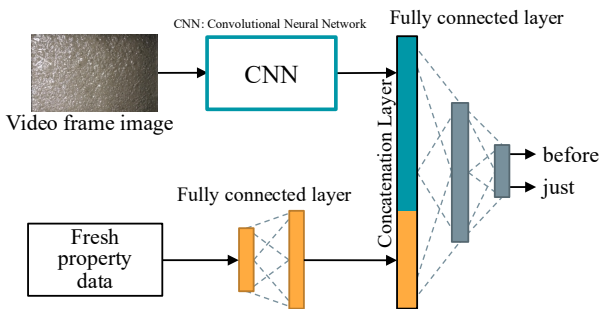


図1 システム概要と深層学習モデルの構造
Fig.1 System overview and its deep learning model.

2.2 データの取得およびラベルの作成

システムの評価データとして、比較的、撮影環境が安定している屋内環境下において、コンクリートをバイブレータにより締め固める際のコンクリート表面の映像を 39 本取得した。締め固めはバイブレータの振動が伝播した部分領域から徐々に完了するため、コンクリート表面全体ではなく、より小さな領域ごとに締め固め状態を判定する必要がある。図2に示すように、締め固め映像のフレーム画像を 24 個のメッシュ領域に分割し、これらを締め固め判定の対象領域とした。また、取得した映像すべてのフレーム画像(30fps)の領域ごとに、3 名の技術者が判定した締め固め完了の適正時間の平均値に基づいて、[before] および [just] の正解ラベルを付与した。このようにして作成された 270×270 画素の画像とそのコンクリートの性状 5 種類からなるフレッシュ性状データ（5次元ベクトル）が、システムの入力となる。




図2 締固め判定対象領域（メッシュ領域）

Fig.2 Target area for compaction judgment (mesh area).

2.3 評価方法

取得した 39 本の締め固め映像から作成した [before] および [just] の 2 クラスのラベル付きフレーム画像とそのフレッシュ性状データからなるデータセットに対し、学習、検証、評価データセットがそれぞれ 3:1:1 となるように、k-分割交差検証(k=5)を適用し、システムの判定精度を評価する。

3. 精度向上に向けたアプローチ

3.1 提案手法

CNN に Network in Network(NIN)を採用した従来システム^[1]では、上述の評価方法および評価データセットに対する正解率は 82.4%であり、コンクリートの性状に依っては、正解ラベルの [before] と [just] が切り替わる境界付近での誤判定、すなわち、締め固め適正時間よりも早い締め固め完了判定や逆に遅れた締め固め完了判定が、解決すべき課題として残されていた。本研究では、この正解ラベルの境界付近での誤判定の課題を解決するために、深層学習モデルの学習データ（特徴ベクトル）間の類似度に着目し、埋め込み空間におけるデータ間の距離を、類似度の高い場合は小さく、類似度の低い場合は大きく学習する Metric Learning と、異なるクラス間のデータに着目し、異なるクラスの 2 つのデータをランダムな比率で合成して、そ

の合成比率を出力するように学習する BC Learning を併用することで、判定精度向上を図る学習手法を提案する。

図3に、提案手法の期待効果のイメージを示す。BC Learning により生成された合成データに Metric Learning を適用することで、決定境界付近に位置するデータ(mixed)を含め、同一ラベルのデータ間の距離は小さく、異なるラベルのデータ間の距離は大きく学習できるため、締固め映像の正解ラベルの [before] と [just] が切り替わる境界付近のデータの誤判定の改善が期待できる。また、BC Learning の適用は、データ数の少ないデータセットの有効活用にも繋がる。




図3 提案手法の期待効果

Fig.3 Expected effect of the proposed method.

3.2 学習方法

提案手法では、BC Learning, Metric Learning の各々を適用する2段階の学習を実行する。まず、BC Learning を深層学習モデル全体に適用する。次に、図4に示すように、その重みを連結層まで凍結し、連結層以降の全結合層に SphereFace の学習、すなわち、Metric Learning を適用する。

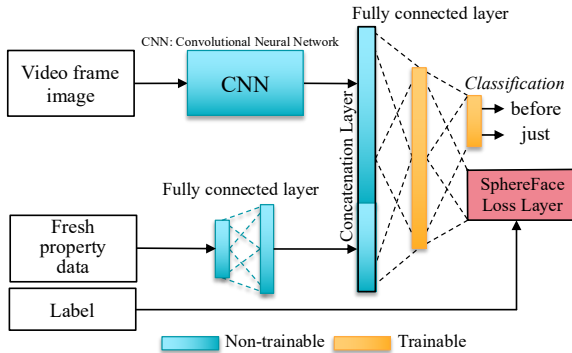


図4 提案手法の学習方法

Fig.4 Learning of the proposed method.

4. 提案手法およびシステムの評価

提案手法およびシステムの有用性を確認するために、従来および提案システムにおいて、CNN として NIN/ResNet18 を用いた場合、Metric Learning, BC Learning を併用した提案手法の導入なし/ありの場合の各々について、判定精度の評価実験を実施した。

表1に、各評価実験の正解率と [before], [just] のクラスごとの F 値を示す。CNN として NIN, ResNet18 を用いたいずれの場合においても、提案手法の導入による判定精度の向上が確認できた。また、図5に、CNN には ResNet18 を用いて、提案手法の導入なし/ありの各々の場合について、1本の締固め映像のテストデータに対するメッシュ領域ごとの判定結果を示す。さらに、図6に、出力層への入力特徴ベクトルを、UMAP を用いて2次元に低次元化し、可視化した結果を示す。これらの結果からも、提案手法の導入により、[before] と [just] のラベル境界での誤判定が減少していること、また、提案手法の導入なしの CNN では顕著な構造を持たずに疎に分布していた特徴ベクトルが、クラスごとに異なる程度構造化され、[before] と [just] の異なるクラスの特徴ベクトルが分離されて分布していることが確認できる。

表1 評価実験結果

Table 1 Result of evaluation experiment.

learning method	CNN		ResNet18	
	conventional	proposed	conventional	proposed
accuracy	82.4%	84.9%(+2.5%)	88.3%	90.4%(+2.1%)
[before] f1-score	0.784	0.808(+0.024)	0.853	0.875(+0.022)
[just] f1-score	0.850	0.875(+0.025)	0.902	0.922(+0.020)

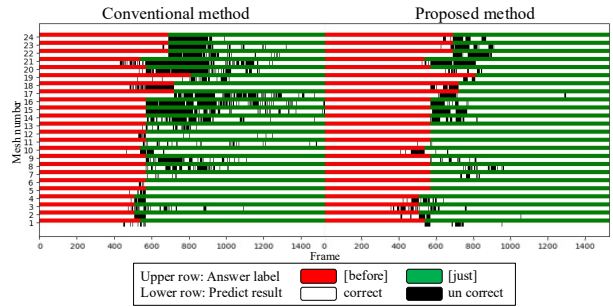


図5 システムの判定精度

Fig.5 Judgment accuracy of the system.

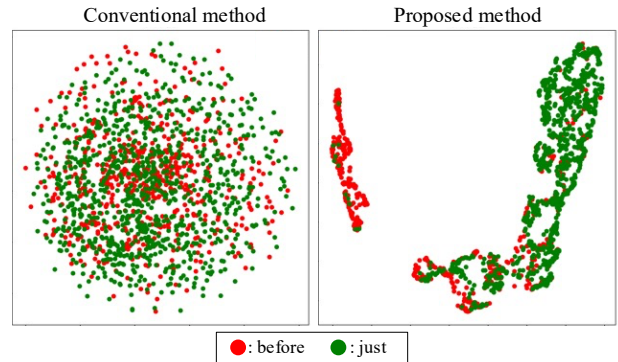


図6 特徴ベクトルの分布

Fig.6 Distribution of feature vectors.

5. おわりに

本研究では、システムのさらなる判定精度向上を目指し、深層学習モデルが獲得するクラス間の決定境界に着目して、Metric Learning, BC Learning を併用し、決定境界をより明確化する学習手法を提案した。さらに、提案手法を導入したシステム評価実験の結果、提案手法およびシステムは、より高精度な締固め完了判定を実現でき、その有用性を確認した。

参考文献

- [1] 林俊斉, 齋藤淳, 小島弘道, 長田茂美: “AI によるコンクリートの締固め自動判定システム開発の試み,” AI・データサイエンス論文集, 2巻 J2号, pp.79-86 (2021).
- [2] Weiyang Liu, Yandong Wen, Zhiding Yu, Ming Li, Bhiksha Raj, Le Song: “SphereFace: Deep Hypersphere Embedding for Face Recognition,” arXiv:1704.08063 (2017).
- [3] Yuji Tokozume, Yoshitake Ushiku, Tatsuya Harada: “Between-class Learning for Image Classification,” arXiv:1711.10284 (2018).
- [4] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: “Deep Residual Learning for Image Recognition,” arXiv:1512.03385 (2015).

本プロジェクトに関する業績

- [1] 林俊斉, 高木亮一, 小島弘道, 長田茂美: “AI を活用したコンクリートの締固め完了判定技術,” コンクリート工学 Vol. 60, No. 3 (2022).
- [2] 小島弘道, 山崎晃平, 長田茂美, 林俊斉: “深層学習に基づくコンクリートの締固め判定システム -システムの学習手法の提案と評価-,” 動的画像処理実用化ワークショップ, DIA2022 (2022).