

画像認識技術の鉄筋自動識別への試適用

Image Recognition Examination for Classification of Reinforcing Bar

市川 享祐^{*1}
Kyosuke Ichikawa

坂口 剛^{*1}
Go Sakaguchi

^{*1} 株式会社アーク情報システム
ARK Information Systems Co., Ltd.

In reinforcing bar works, prevention of misalignment is an important issue. There are rolling marks for identification on rebar in Japan, but it is small and hard to see, marks are different depending on the manufacturer, so human errors may occur. Therefore, we conducted experiments to classify reinforcing bar images by convolution neural networks (CNNs). In addition, we examined inference results via Gradient-weighted Class Activation Mapping (Grad-CAM). As a result, classification of reinforcing bar was possible, and it was confirmed that the system focused on the roll mark.

1. はじめに

鉄筋コンクリート構造物の工事では、鉄筋の種類や配置等についての検査(配筋検査)が行われる。配筋とその検査に誤りがあった場合、建物の耐久性・強度に問題が生じる危険性がある。そのため、正確な検査が必要とされるが、人間による配筋検査は検査品質にばらつきが生じる上、多くの時間と手間を要する。

日本建設業連合会等によって、配筋ミスの防止に決め手となる鉄筋識別方法が検討され、課題が整理されている[日建連14]。鉄筋識別の手段として、鉄筋表面のロールマークを目視する方法があるが、マークが小さくて見えにくい事、マークの間隔が広くて探しづらい事、メーカーによってマークが異なる事などが問題視されている。そこで本検討では、配筋検査における品質確保や検査の時間短縮を目的とし、畳込みニューラルネットワーク(CNN)によるロールマークの自動認識を試みた。尚、この検討には汎用 DeepLearning ソフトウェア ARK-AI を用いた。

2. 問題設定

使用した鉄筋は図 1 の 16 種(メーカー 4 社、径 4 種)である。鋼種はいずれも SD345 とした。ロールマークの認識問題を、メーカー認識問題と径認識問題に分けて検討した。メーカー認識問題では、鉄筋画像を 4 種のメーカー(朝日工業(株)、共英製鋼(株)、JFE 条鋼(株)、東京鐵鋼(株))に分類した。径認識問題では、メーカーごとにそれぞれ、4 種の径(D16、D19、D22、D25)に分類した。

	朝日工業	共英製鋼	JFE 条鋼	東京鐵鋼
D16				
D19				
D22				
D25				

図 1：使用した鉄筋 16 種 (鋼種はいずれも SD345)

3. 入力画像

用意した鉄筋画像の例を図 2 に、画像点数を表 1 に示す。

連絡先: 市川享祐, 株式会社アーク情報システム, 東京都千代田区五番町 4-2 東プレビル, 03-3234-9232, 03-3234-9403, ichikawa.kyosuke@ark-info-sys.co.jp

Traning set, Validation set, Test set の 3 種のデータセットを用意した。Traning set は学習用のセットである。このセットについては、カメラをずらしながら連続撮影することで、可能な限り多くの画像を用意した(そのため、同様な背景の画像が複数含まれる)。Validation set や Test set は、学習させていない画像を認識できるかどうかをテストするためのものである。特に Validation set は、学習のどの反復段階で得られたパラメータを採用するか の指標に用いた(原則として、Validation set に対する損失が最も低い段階でのパラメータを採用した)。Test set は採用したパラメータに対する精度評価に用いた。Traning set, Validation set, Test set のいずれの画像も重複はしていない。尚、画像は 256 × 192 ピクセルのカラー画像とした。



図 2：使用した鉄筋画像例

表 1：鉄筋画像点数

メーカー	径	画像点数		
		Training	Validation	Test
朝日工業	D16	1,294	20	20
	D19	1,250	20	20
	D22	1,226	20	20
	D25	1,291	20	20
共英製鋼	D16	1,262	20	20
	D19	1,208	20	20
	D22	1,254	20	20
	D25	1,158	20	20
JFE 条鋼	D16	1,263	20	20
	D19	1,236	20	20
	D22	1,165	20	20
	D25	1,297	20	20
東京鐵鋼	D16	1,269	20	20
	D19	1,102	20	20
	D22	1,248	20	20
	D25	996	20	20
計		19,519	320	320

4. CNN の設定

本検討で用いた CNN の構成を図 3 に示す. これは, VGG19[Simonyan 14]をベースとした. その他の設定を表 2 に示す. 尚, ドロップアウトは全結合層にのみ適用した.




図 3 : CNN の構成

表 2 : ハイパーパラメータ

エポック数	500
ミニバッチサイズ	128
ドロップアウト率	75%
重み行列初期値(乱数)の正規分布標準偏差	0.05
活性化関数	ReLU (出力層は Softmax)
損失関数	Cross-entropy
最適化手法	Adam
初期学習率	0.001

5. Grad-CAM の導入と調整

CNN の中間層の出力が, 出力層の出力に与える影響を可視化する手法として, Saliency map[Simonyan 13], Grad-CAM[Selvaraju 16]など, 複数提案されている. 本検討では Grad-CAM をベースに, max-pooling 層の出力が出力層の出力に与える影響を可視化した. あるクラス c に対応するヒートマップ L^c は式(1)によって得られる.

$$\begin{cases} \alpha_k^c := \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{i,j}^k}, \\ L^c = \text{ReLU} \left(\sum_k \alpha_k^c A^k \right). \end{cases} \quad (1)$$

ここで, A は特徴マップ, Z は特徴マップのサイズ, y は出力層の出力ベクトルであり, 添字の i, j は行列番号, k は特徴マップの番号を表す. すなわち, 特徴マップに対する出力 y^c の変化率を整理して可視化する.

ただし, 本検討では第一式に ReLU を適用することで, 負の変化率の影響を除外した. すなわち, 次の式(2)を用いた.

$$\begin{cases} \alpha_k^c := \frac{1}{Z} \sum_i \sum_j \text{ReLU} \left(\frac{\partial y^c}{\partial A_{i,j}^k} \right), \\ L^c = \text{ReLU} \left(\sum_k \alpha_k^c A^k \right). \end{cases} \quad (2)$$

これにより, 特徴マップ上の局所的な正の変化率が, 他の箇所の負の変化率によって相殺されることを防いだ. あるいは, 本検討では用いていないが, CAM[Zhou 16]のアプローチを利用した式(3)による方法もある(ただし, $\circ$ は行列成分ごとの積である).


$$L^c = \text{ReLU} \left(\sum_k \frac{\partial y^c}{\partial A^k} \circ A^k \right) \quad (3)$$

6. 検証結果

6.1 メーカー認識問題の結果

メーカー認識問題の学習結果を図 4 に示す. Validation set に対する正答率は 114 エポックで 100% となった. Validation set に対する損失が最小となった 203 エポックのパラメータを採用した(このときの Validation set に対する正答率は 99.7%).

採用したパラメータで Test set のメーカー認識を行った. 結果は表 3 のとおりであり, 98.1% の正答率が得られた. 認識の正答例を図 5 に示す. 上段は入力画像, 下段は Grad-CAM によって得られた(出力クラスに対する)ヒートマップである. Grad-CAM は出力層に最も近い max-pooling 層を対象としている. 基本的にメーカーのマークに着目していることが分かる. 径を表す数字もメーカーによって形が異なるためか, 数字に着目する様子も見られた. また, 誤答例を図 6 に示す.



(a) 損失推移 (b) Validation set 正答率推移

図 4 : メーカー認識問題の学習結果

表 3 : メーカー認識問題の結果(Test set)

画像点数	正答数	正答率
320	314	98.1%




図 5 : メーカー認識問題の正答画像例




図 6 : メーカー認識問題の誤答画像例


6.2 径認識問題の結果

径認識問題では、メーカーごとに径の分類を行った。基本的には Validation set に対する損失が最小となった時点でのパラメータを採用したが、東京鐵鋼については 2 エポックから損失が下がらなくなったため、500 エポックでのパラメータを採用した(2 エポックでは、Training set に対する損失も下がり切っていないため例外とした)。Test set に対する径認識結果を表 4 に示す。共英製鋼については 90%以上の正答率が得られたが、その他のメーカーについては 80%を下回った。

表 4 : 径認識問題の結果(Test set)

メーカー	画像点数	正当数	正答率
朝日工業	80	50	62.5%
共英製鋼	80	77	96.3%
JFE 条鋼	80	61	76.3%
東京鐵鋼	80	25	31.3%

共英製鋼の学習結果を図 7 に示す。Validation set に対する損失が最小となった 482 エポックのパラメータを採用した(このときの Validation set に対する正答率は 98.8%)。採用したパラメータで Test set のメーカー認識を行った。正答率は表 4 の通り 96.3%である。認識の正答例を図 8 に示す。上段は入力画像、下段は Grad-CAM によって得られた(出力クラスに対する)ヒートマップである。鉄筋には着目しているが、径の数字だけでなく他の箇所も見ていることが分かる。



(a) 損失推移 (b) Validation set 正答率推移

図 7 : 共英製鋼に対する径認識問題の学習結果




図 8 : 共英製鋼に対する径認識問題の正答画像例

7. Grad-CAM 比較

最後に Grad-CAM について、式(1)、式(2)、式(3)のヒートマップの例を図 9 に示しておく。これは、メーカー認識問題において、CNN の各 max-pooling 層に対して Grad-CAM を適用した例である。4 つめの pooling 層を見ると、式(1)ではヒートマップがなくなっているが、式(2)、(3)では表示されている。




図 9 : Grad-CAM の各調整の違い

8. まとめ

以上の検討により、CNN による鉄筋ロールマークの自動認識がある程度可能であることが分かった。ただし、径認識問題については精度が比較的悪く、教師データのバリエーションを増やす等の対策が必要である。今後の課題としては、組みあがった鉄筋への対応、鋼種・鉄筋本数・ピッチなどの認識がある。

謝辞

鉄筋を提供して頂いた朝日工業(株)、共英製鋼(株)、JFE 条鋼(株)、東京鐵鋼(株)に感謝の意を表す。また、本検討は日本建築学会の「建築構造の技術革新と人工知能特別研究委員会」で実施したものであり、その活動の中で委員会メンバーに参考となる意見を多くいただいた。ここに感謝の意を表す。

参考文献

[日建連 14] 一般社団法人日本建設業連合会 建築生産委員会: 鉄筋識別方法の改善についてーカラー識別マーキングとロールマークの現状と今後の課題ー, 2014.

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.

[Simonyan 13] Simonyan, K., et al.: Deep inside convolutional networks: Visualising image classification models and saliency maps, *arXiv preprint arXiv:1312.6034*, 2013.

[Selvaraju 16] Selvaraju, Ramprasaath R., et al.: Grad-CAM: Why did you say that? Visual Explanations from Deep Networks via Gradient-based Localization, *arXiv preprint arXiv:1610.02391*, 2016.

[Zhou 16] Zhou, B., et al.: Learning Deep Features for Discriminative Localization, In *CVPR*, 2016.