

## 深層学習を用いた画像処理による軸重推定手法の開発

早稲田大学 学生会員 ○興水 良亮  
早稲田大学 正会員 佐藤 靖彦

### 1. はじめに

タイやマレーシアなどの東南アジア諸国では、過積載トラックが数多く通行しており、既設コンクリート構造物の疲労損傷に大きな影響を与えている。Changらの研究によると、静的耐力の60%を超える大きな荷重の繰返し载荷によって、部材レベルでの疲労損傷が生じるとしている。このように過積載トラックの通行量把握は、既設構造物の疲労寿命推定において非常に大きな意味を持つが、これらを正しく、かつ継続的に測定したデータは少なく、収集には非常に大きな人的コストがかかる。そこで著者らは、カメラによって撮影された画像をもとに、通過する車両の軸重を推定するAIを、ニューラルネットを用いて実装した手法を開発した。本論においてその概要を報告する。

### 2. 実験概要

本研究で用いた開発環境を以下の通りである。

- OS : mac OS Mojave 10.14
- Processor : 2.3 GHz Intel Core i5
- Python 3.6, Chainer 5.2.0, Chainer CV 0.11.0

データセットは、東南アジアの高速道路の料金所で Weigh-In-Motion を用いて測定した軸重データと、通過する車両が法定重量を超える場合に撮影される画像データをもとに構築した。画像データは全部で23,107枚存在し、その中から同条件の100枚を抽出してアノテーション作業を施すことで、データセットを作成した。使用した画像例を図1に、データセットの諸条件を表1に示す。学習を行うプログラムのコードは、Faster-R-CNN VGG16 という物体検出の為の既存モ



図1 使用した画像データ例

表1 データセットの諸条件

	Dataset 1	Dataset 2	Dataset 3
Extraction method	Random	Random	Select images shows target truck only
Classification (axil load)	Classified every 2 ton	Classified every 2 ton	Classified every 5 ton

デルのコードを Github から参照<sup>2)</sup>して用いている。このコードに対して、自作のデータセットを教師データとして学習させることで、軸重推定 AI システムの構築を行う。学習が収束した後、該当のモデルを用いて推定を行い、その精度検証を行った。推定に用いた画像は、画像データのうち、データセット作成に用いていない測定期間の画像12,215枚である。この推定値のボリュームと、実際にWIMで測定された軸重のボリュームを比較し、その実用性について検討する。

### 3. 実験結果および考察

各データセットについて学習を行ったところ、最も精度が高い(最も損失が小さい)結果が得られたのは、Dataset 3を教師データとした場合であった。ここで、最も精度が高かったモデルを用いて、車両検出および軸重推定を行った結果を以下の図2及び図3に示す。図2の車両の軸重測定値は15-19[ton]の分類であった為、画像内の車体を検出した上で、その軸重を正しく推定できていると言える。しかし図3では、車両の位置は正しく検出できているが、実際の軸重分類15-19[ton]に対して

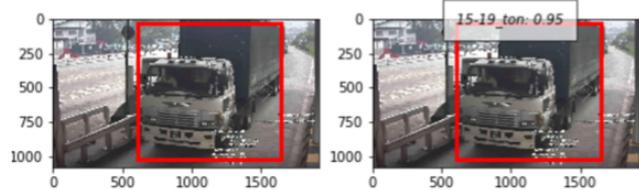


図2 正しく軸重を推定できた例

キーワード 人工知能, 深層学習, 荷重推定, 交通荷重, 疲労損傷

連絡先 〒169-8555 東京都新宿区大久保3丁目4-1 TEL 03-5286-3852

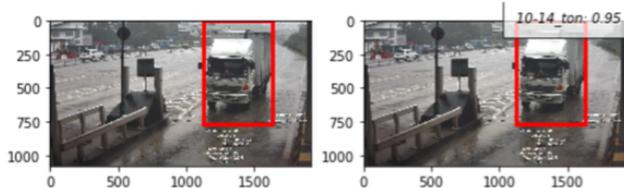


図3 軸重の推定値が間違っている例

推定分類が10-14[ton]であり、このような推定ミスも散見された。本研究では、橋梁など既設コンクリート構造物にかかる交通荷重を固有に把握することを目的としているので、画像1枚1枚に対する正誤ではなく、推定分類と実測値の全体ボリュームを比較することで、実用性について検討した。以下の表2に、それぞれのクラス分類における精度を示す。データ全体に対する精度は約61%程度であったことがわかる。加えて、軸重10-14[ton]のクラス分類以外の推定結果が著しく低く、軸重20[ton]を超えるトラックの推定結果は0であった。

これらの結果は全て、学習に用いた教師データの質の低さに起因すると考えられる。まず、データセットの種類による精度の違いについては、抽出方法の違いによる学習のノイズの有無が深く関係している。ランダムに抽出した画像データには、軸重が測定されていない他のトラックが映り込んでいるものも多く、それらが誤差の原因となり学習が収束しづらかったと考えられる。このノイズを減らすことで、精度向上が見込めると言える。次に、散見された推定ミスについてだが、そのほとんどが10-14[ton]のクラス分類に誤認されていた。これは表2に示した結果からもわかることだが、今回作成したモデルは、10-14[ton]のクラス分類について過学習を起こしていた可能性がある。その原因として、教師データのクラス分類に偏りが生じていたことがあげられる。今回用いた教師データであるDataset 3の6割は、10-14[ton]のクラス分類を持つ画像であり、24-29[ton]のクラス分類を持つトラックの画像はたった2枚であった。これにより、学習の過程で得たトラックの特徴量のほとんどが10-14[ton]トラックと関連付けられてしまい、このような推定結果になったと考えられる。また、教師データに含まれない見た目のトラックに対する推定も正しく行えていない可能性が高く、教師データに用いるデータ量にも課題が残った。その一方で、現時点での過積載トラックの検知度としては6割を超えている為、データの質と量に関する課題を解決することで、より高精度にトラ

表2 それぞれのクラス分類における精度

	実データ	推定結果	精度 (%)
Total	12,215	7,489	61.31
10-14ton	7,193	7,190	99.96
15-19ton	3,532	299	8.47
20-24ton	1,133	0	0
25-29ton	357	0	0
30-34ton	1	0	0

ックを識別し、実用的手段として十分活用していく可能性を持っているといえるだろう。今後の課題として、前述したデータの質を高める為、ノイズの少ない画像をクラス分類の偏りなく収集する手段を追求することが挙げられる。その為の一つの方法として、データ収集の段階から別のAIを導入することで、質の高い画像のみをスクリーニングするなど、AI同士を組み合わせることで、さらに低コストで高精度なシステムを構築することができると考えている。

#### 4. まとめ

- 測定された軸重に紐づくトラックの外観画像を教師データとすることで、画像に映り込むトラックの軸重を推定するAIシステムの構築に成功し、その推定精度は約60%程度であった。
- 推定精度を向上させるには、ハイパーパラメータの調整ではなく、データセットの質を向上させることが重要であり、用いる画像データをより選別する必要がある。
- 質の高い画像をスクリーニングするAIなどと組み合わせることで、さらなる精度向上を低コストで実現できる可能性がある。

#### 参考文献

- Chang, T.S., Kesler, CE. (1958). Static and Fatigue Strength in Shear of Beams with Tensile Reinforcement, Journal of the American Concrete Institute, Vol.54, pp.1033-1057, 1958
- mitmul. Object Detection with Faster R-CNN in Chainer, <https://github.com/mitmul/chainer-faster-rcnn>, 2017