


深層学習^(注1)を用いた軌道内の 落下物検出

山本大樹 Taiki Yamamoto

キーワード 鉄道, 落下物検出, 深層学習

概要



軌道内の落下物検出の概要図

鉄道設備の保守・改良工事後、軌道内に工具やボルトなどの部品が落ちていると重大な事故につながる危険性がある。このような落下物による事故を無くすために、作業後に落下物の確認作業を行っている。この確認作業を自動化するために、カメラを用いた画像処理による軌道内の落下物検出技術を開発した。

落下物の検出には、近年認識や予測問題で高い性能を示し注目されている深層学習を採用し、画像内の落下物の有無を識別する。本技術によって落下物の識別精度99.3%を達成した。鉄道設備の保守・改良工事後の支障物の確認作業に使用されている確認車に本技術を採用することで、落下物の確認作業の自動化に貢献する。

1 まえがき

鉄道設備の保守・改良工事は、主に列車運転時間終了後から始発までの夜間に行われる。このとき、保守・改良工事で使用した工具やボルトなどの部品が軌道内に落ちていると脱線などの事故につながる危険性がある。そのため、作業終了後に作業員が設備内に置き忘れなどが無いかの確認作業を行う。

確認作業は、専用の確認車で行うことがある。確認車には、車両の下部に支障物検知用のバーが設置され、バーに抵触するものを支障物として検知する。しかし、軌道内の落下物は車両限界に抵触しないことが多いため、支障物検知用のバーでは発見されない可能性がある。現状の確認作業は、複数人が線路に横一列に並び、足元を手持ちのライトで照らしながら確認しているため、作業員の負担が大きい。このような背景から、軌道内の落下物を自動で検出す

る技術が望まれている。本稿では、深層学習を用いた軌道内の落下物の自動検出技術を紹介する。

2 落下物検出手法

落下物を検出するために、車両の上部に下方向に傾けたエリアカメラを搭載し撮影することを想定している。第1図に入力画像例を示す。本手法では、バラスト（道路・線路などに敷く砂利）・枕木・線路のみが写っている画像（正常画像）と落下物が写っている画像（異常画像）の2クラス識別に対して深層学習を用いる。近年、深層構造を持つ大規模ニューラルネットワークを用いた機械学習手法の一つである深層学習は、認識や予測問題で高い性能を示し注目されている。

本手法では、数多くある深層学習のネットワーク構造の中でも、画像物体認識分野で実績のある Alex

らが提案したネットワーク構造（以下、AlexNet）を用いる。AlexNetは8つの層で構成され、最初の5つの層が畳み込み層で、残りの3つの層が全結合層である。AlexNetは画像を1000クラスに識別するネットワーク構造であるため、全結合層の出力は1000クラスである。一方、本手法での出力は正常画像か異常画像かの2クラスである。そのため、AlexNetの全結合層を本手法に適合させるためにファインチューニングする必要がある。ファインチューニングとは、ある問題で学習させたネットワークの最後の一部分の重みを再学習させて、別の問題にも適合できるようにすることである。深層学習の畳み込み層は特徴抽出器として利用することが

できる上に、画像認識分野では様々な問題に共通して抽出すべき特徴があるため、ファインチューニングが有効であると言われている。加えて、ファインチューニングは少ない学習データで効率的な学習ができる利点がある。本手法では、AlexNetの畳み込み層で得られる4096次元のベクトルを入力として、3層から成る全結合層を新たに学習させる。**第2図**に自動検出技術で使用しているネットワーク構造を示す。上記の学習によって得られたネットワークを用いて、正常画像と異常画像の2クラス識別を行う。




第1図 入力画像例

左に正常画像、右に異常画像を示す。正常画像はバラスト・枕木・線路のみが写り、異常画像は落下物が写っている。


3 精度検証

日中に軌道内の正常画像と異常画像を撮影し、本技術の精度を検証した。データ数は、正常画像と異常画像を合わせて26,562枚用意した。正常画像と異常画像それぞれの総データ数の87.5%を学習用データとし、残りの12.5%を評価用のデータとした。**第3図**に学習回数と識別精度の関係を示す。学習回数300回周辺で識別精度が収束し、学習用データで99.7%、評価用データで99.3%の識別精度が得られた。**第4図**に落下物の検出成功例を示す。左が入力画像、右が識別への影響度を可視化した画像である。




第2図 自動検出技術で使用しているネットワーク構造

Alexnetの全結合層をファインチューニングによって本手法に適合させた構造を示す。



第3図 学習回数と識別精度の関係

縦軸が識別精度，横軸が学習回数を示す。青線は学習に含まれている画像での識別結果を，黒線は学習に含まれていない画像での識別結果を示している。



第4図 落下物の検出例

落下物を検出した画像の例を示す。左が入力画像，右が識別への影響度を可視化した画像で，深層学習による識別への影響度を濃淡値で示している。白に近いほど影響度が大きい。

4 むすび

深層学習を用いた軌道内の落下物検出手法を紹介した。本技術で落下物の確認作業の自動化への可能性を示すことができた。今後は，実車両で実運用を想定した検証を行い，実用化を目指す。

- ・本論文に記載されている会社名・製品名などは，それぞれの会社の商標又は登録商標である。

(注記)

注1. 音声の認識・画像の特定・予測など人間が行うようなタスクを実行できるようにコンピュータに学習させる手法

《執筆者紹介》



山本大樹
Taiki Yamamoto
ICT 統括本部開発部
架線検測装置の製品開発に従事