

周辺環境変化を捕捉するための深層学習の活用

○ [土] 三須 弥生（東日本旅客鉄道株式会社）

Application of deep learning to capture changes in surrounding environment

○Yayoi Misu (East Japan Railway Company)

In order to maintain and improve safety and stability of railway operations, it is necessary to understand changes in surrounding environment outside the railway site and to take appropriate measures to prevent transportation obstacles. In this study, the effectiveness of applying trained neural networks in two ways, “Change judgment based on attributes” and “Classification method by transfer learning”, to capture the changes in environment is verified using actual images taken by maintenance vehicles.

キーワード：畳み込みニューラルネットワーク（CNN）、GoogLeNet、Places365、転移学習

Key Words：Convolutional Neural Network (CNN), GoogLeNet, Places365, transfer learning

1. はじめに

鉄道運行の安全性、安定性を維持、向上するためには、鉄道敷地内だけでなく、周辺の環境変化を捉え、適切な対策を行う必要がある。これまでに、鉄道設備の整備の目的で保守用車の先頭車で定期的に撮影されるパノラマ画像に対し、ステレオ解析で得られる対象物までの距離（3D 情報）を主なパラメータとする環境変化の捕捉手法を開発した（特許出願済み）¹⁾。この手法では、変化を一定精度で把握できるものの、含まれる誤差を取り除くため、変化の度合いや詳細な内容を人が再度確認し、データベースの更新をする必要があった。

そこで本研究では、周辺環境変化の判定精度の向上による人手作業の軽減を目的に、深層学習技術（ディープラーニング（DL））の活用を二種類の手法で検討した。一つは「特徴量による変化判定手法」で、パノラマ画像から切り出した側面水平画像を対象として、新旧の画像をニューラルネットワークで学習した際に計算される特徴量を比較することで、変化の有無を判定する手法である。もう一つは、「転移学習による分類判定手法」で、同じくパノラマ画像から切り出した側面水平画像に対し、既存の沿線の粗度区分を分類としてネットワークの学習を実施し、新しい画像の粗度区分を判定する手法である。これらの手法について、実際の画像でその精度を検証し、有効性を明らかにした。

2. 特徴量による変化判定手法

パノラマ画像から切り出した側面水平画像を対象として、新旧の画像をニューラルネットワークで学習した際に計算される特徴量を比較することで、変化の有無を判定する手法を検討した。比較の基準とするため、画像に埋め込

まれているキロ程情報を補助情報とした。

2.1 判定手順

（１）パノラマ画像からの画像の切り出し

パノラマカメラは、6 方向に個別のカメラを持ち、その画像を合成することにより、360 度のパノラマ画像を実現する。本研究においては、周辺環境のみを対象とすることから、線路に対して平行で水平な画像のみを対象とすればよい。そこで三須ら¹⁾の手法により、車体の映り込みの除去と立体画像を平面画像に修正するオルソ補正を実施し、線路に対して並行で水平な画像を切り出した。画像データにはキロ程情報を付加した。切り出した画像の例を図 1 に示す。図 1 の左側が古い画像、右側が新しい画像である。図 1 からわかる通り、撮影された風景はおおむね同じ位置を撮影しているものの、若干位置がずれている。既研究より、パノラマ画像では撮影時の速度等により数 m～十数 m の画像の位置の相違があることが分かっている。そのため画像を切り出した際に、多少の位置ずれが起きた場合でも、判定の対象とする物体が含まれるよう、水平距離 20m 毎の切り出しとした。また図 1 から、新旧のパノラマ画像では、撮影時間や天候で、画像の色調等が大きく異なることが分かる。そこで、色調等による判定誤差を少なくするため、白黒画像への変換を行った。（図 2）

画像の位置ずれについては、各ピクセルの数値から、位置や大きさのずれを判定し調整する画像処理技術（レジストレーション技術）がある。その技術を用い、20m 毎に切り出した画像に対し、位置合わせ（水平移動と拡大縮小）を行った。図 3 に位置合わせ後の新旧の画像を重ねた様子を示す。緑とピンクで示した部分が、新旧の画像のずれとなる。位置合わせを行った後の画像に対し、GoogLeNet



(旧) (新)

図1 切り出した画像例




図2 白黒画像への変換



図3 新旧画像の位置合わせの結果



図4 中心の縦横 224 ピクセルの画像の切り出し結果



(a) うまく判定できた例 (b) うまく判定できなかった例
(下の写真は位置合わせの状況の例)

図5 判定結果

で解析が可能な大きさとするため、解像度を下げたうえで図4のように中心の縦横 224×224 ピクセルの画像を取り出した。

(2) 学習済みネットワークでの判定

本研究が対象とするパノラマ画像については、パノラマ

カメラ導入後の期間が短く、同一箇所で時期が異なる画像の数が限られるため、ニューラルネットワークを一から作成(学習)することは難しい。そのため、事前学習済みの公開された畳み込みニューラルネットワークである GoogLeNet を使用することとした。GoogLeNet は、深さが 22 層の事前学習済みの畳み込みニューラル ネットワーク (CNN : Convolutional neural network) であり、そのうち Places365 (学校や駅、スタジアムといった場所に関連する画像 365 種類を分類するために学習されたネットワーク) を使用することとした。一般の GoogLeNet も試行したが、Places365 ほどの精度が出ないことを確認している。このネットワークを使用することにより、入力した画像に示された場所が、学習した 365 種の場所のどれにあたるかといった分類問題に活用することができる。しかし本章の検討では、分類は問題ではなく、変化があった場合にその変化が捉えられるかが問題となる。よって、ネットワーク中で求められた重み配列の値を、変化をとらえるためのパラメータとした。

2.2 判定結果

本検討では、GoogLeNet/Places365 で求められる重み配列の各要素の値の二乗平均値を判定パラメータとして求め、その値の相違の有無によって、変化をとらえることとした。判定パラメータの例を図5に示す。図5の事例は共に環境変化が含まれていることが分かっている事例である。横軸がキロ程で縦軸が判定パラメータの値である。凡例の青丸が古い画像であり、赤丸が新しい画像である。(a)は 48k400m 付近で新しく建物が建った事例、(b)は 82k500m 付近で建物が解体された事例である。

図5より、(a)については、48k400m 付近で判定パラメータの急激な増加がみられ環境の変化をとらえることができていたのに対し、(b)では、判定パラメータの相違は顕著ではなく環境の変化をとらえることができていない。(b)の連続画像を詳細に確認した結果、解体現場周辺に工事用フェンスが比較的長く設置されており、その位置を境に、位置合わせがうまくできていないことが分かった。よって、位置合わせがうまくできた場合には、本手法で判定ができるものの、位置合わせがうまくいかなかった場合には、本手法での判定が難しいことが分かった。

3. 転移学習による分類判定手法

パノラマ画像から切り出した線路に対して平行で水平な画像に対し、粗度区分を分類対象として、周辺風環境変化の判定を試みた。前章と同様に、画像データ数に限りがあるため、一からの学習は難しいと判断し、既存の学習済みネットワークを使用し、転移学習により判定することとした。

3.1 判定手順

(1) 対象とするデータ

車両の風に対する転覆耐力を評価するための計算システム(転覆限界風速計算システム)が 2011 年度から開発さ

れており²⁾、その中で風規制区間の沿線 20m 毎に粗度区分が整備されている³⁾。粗度区分データは、風況に影響する周辺の建物等の密集度を表す I～V の区分である⁴⁾。そこで、切り出した画像を対応する粗度区分ごとに分類することにより、後述する学習および検証に用いるデータとする。GoogLeNet では入力画像を 224×224 ピクセルとしているため、本研究でも最終的には入力データとして 224×224 ピクセルの画像を用意する必要がある。しかし、元の画像の解像度は、1m を 30 ピクセルとしていることから、そのまま 224×224 ピクセルを抜き出すと 7m 程度の画像となり、対象とする周辺環境を十分に捉えられない可能性がある。そこで、入力データに対し 3 倍となる 672×672 ピクセルの画像を 20m 毎に取り出し、それを圧縮し 224×224 ピクセルの画像とした。

本研究では、三須ら¹⁾の検討で対象とした約 30 km の沿線画像を対象とした。粗度区分毎に整理した画像数を表 1 に示す。表 1 より、分類ごとに数にばらつきがあることがわかる。切り出した全データを対象として学習を行った結果、学習の収束が進まないことが判明した。そこで、データ数が比較的多い粗度区分 1 から 3 までのデータのみを対象とし、さらにその中でも最も数が少ない粗度区分 2 の 243 を基に、同数ずつの画像データを対象とすることとした。ネットワークの学習過程では、学習に使用する訓練データと、学習後にテストを行うためのテストデータに分けておく必要がある。また、学習中もその学習の程度を検証するための検証データを分けておく必要がある。表 2 に本研究で用いた各データ数を示す。

(2) 学習済みネットワークを利用した転移学習

転移学習に使用するネットワークは、2 章と同様に GoogLeNet の Places365 とした。Places365 は、学校や駅、スタジアムといった場所に関連する画像 365 種類を分類するために学習されたネットワークであり、そのままの状態では、365 個の出力を行う。これを、今回の対象とする粗度区分 1 から 3 の 3 分類とするため、全結合層の出力数を 3 に変更して行う。また、転移学習のテクニックとして、既に学習されている上位（入力に近い方）の層のパラメータの学習はあまりせずに、新しく設定した全結合層の学習を進めることにより、効率的な学習が行える。そのため、全結合層の学習率を高い値に変更する。

多層のニューラルネットワークでは、誤差逆伝播法（Back propagation）により、ネットワーク中の重みである特徴量が調整される。その調整の際に、更新量を決める方法として確率的勾配降下法（Stochastic gradient descent）を用いる。今回は、モーメンタム項付き確率的勾配降下法（SGDM）と適応モーメント推定（Adam: adaptive moment estimation）を比較し、同じ繰り返し計算数で精度が高かった Adam を使用した。ネットワーク全体の学習率は、前述の全結合層の学習率とは逆に、 $1e-5$ と低くした。

ネットワークの学習では、全てのデータを一度に使うの

表 1 対象線区的全データ数

分類	数
粗度区分 1	406
粗度区分 2	243
粗度区分 3	841
粗度区分 4	26
粗度区分 5	12
計	1528

表 2 学習、検証、テストに使用した画像データ数

分類	総数	訓練データ	検証データ	テストデータ
粗度区分 1	243	120	50	73
粗度区分 2	243	120	50	73
粗度区分 3	243	120	50	73
計	729	360	150	219

ではなく、学習セットを少量のサブセットに分けて、逐次パラメータを調整していく方法がとられる。これをミニバッチ法といい、サブセット数をミニバッチ数という。本検討では、ミニバッチ数を 60 程度から順次減らして、評価精度を比較した結果、ミニバッチサイズを 1（逐次学習）とした場合が最も精度が高いことを確認したため、ミニバッチサイズは 1 とする。一般的にミニバッチサイズを小さくすることにより、過学習を抑制する。

ミニバッチ数毎の学習を繰り返して、全てのデータを使った学習の 1 回分を 1 エポックという。このエポック数が、全データを学習させる回数となる。本検討では、3, 10, 20, 50 エポックについて検証した。その結果、10 エポック付近で、精度が落ち着くことが判明したが、10 エポックを超えても若干の精度の変動があることも確認できた。そこで、20 エポックとすることとした。

3.2 結果

(1) 学習結果

前節の設定で実施した学習状況の結果を図 6 に示す。上のグラフが判定の精度、下のグラフが判定に対する確率（どの程度確信をもって判定したか）から求められる損失を示す。判定に対する確率は、出力層近くで、ソフトマックス関数により求められ、その値を用いてクロスエントロピー関数により損失を求める。横軸がミニバッチごとの反復回数で、エポック毎に背景の色が変わっている。

上のグラフの精度では、個々の判定と結果の差から求められる精度として、0%と 100%の間を変化する青い線が示されている。黒い点が検証データを用いて 1/3 エポック毎に示した判定精度であり、検証用の全データから求められた精度を示す。10 エポックを過ぎたあたりから、検証データの判定精度が 80%程度で落ち着くが、14 エポックで、一度判定精度が悪くなっていることがわかる。

下の損失のグラフでは、低エポックでは損失が大きく出

ているものの、エポックが進むにつれて 0 に近い値となる。ただし、精度のグラフでも現れた 14 エポックでの誤判定により、一旦損失が上昇している。ネットワークの学習では、ミニバッチごとに逐次確率的に学習が進むため、データの選択によっては、学習精度や損失が変動することがあるが、エポック数を増やすことにより、一般的にそれらの値は落ち着く。ただし、データ数が十分でない場合には、過学習の可能性があるため、注意が必要である。本研究では、精度と損失共に 20 エポックで落ち着き、判定精度は 84.7% となった。

(2) テストデータに対する判定結果

前節で学習したネットワークを用いて、73×3 クラスのテストデータに対して判定を行った。その結果を混合行列として図 7 に示す。3×3 の行列様の図の縦に真の分類（元々の粗度区分）を示し、横に予測した分類を示し、内側にそれらの数を示す。また、3×3 の行列様図の右側に真の分類に対する判定割合である真の分類の中で正しく判定できた割合（捕捉率）と、真の分類の中で正しく判定できなかった割合（見逃し率）を示す。下側に予測した中で正しかった割合（的中率）と予測した中で正しくなかった割合（空振り率）を示す。また、画像に対する真の分類（ここでは粗度区分 2）と予測結果との比較の例を図 8 に示す。




図 6 ネットワークの学習状況

真の分類 (数)	予測した分類 (数)			真の分類の中で 正しく判定できた割合 (捕捉率)		真の分類の中で 正しく判定できなかった割合 (見逃し率)	
	粗度区分1	粗度区分2	粗度区分3				
粗度区分1	67	1	5	91.8%		8.2%	
粗度区分2	4	65	4	89.0%		11.0%	
粗度区分3	2	14	57	78.1%		21.9%	
予測した中で正しかった割合 (的中率)				91.8%	81.3%	86.4%	
予測した中で正しくなかった割合 (空振り率)				8.2%	18.8%	13.6%	

図 7 テストデータに対する判定結果（混合行列）



図 8 真の分類と判定の分類の比較（例）

図 7 より、粗度区分 1 については、捕捉率と的中率共に最も高い割合となった。粗度区分 1 は海岸等を示しており、他の区分と異なり構造物等の割合が少なく、判定がしやすかった可能性がある。粗度区分 2 と粗度区分 3 は、捕捉率と的中率が逆転しており、特に本来粗度区分 3 である分類を粗度区分 2 と誤判定した場合が 14 件発生している。粗度区分 2 は主に田園地帯、粗度区分 3 は森林地帯や住宅地との違いがあるが、図 8 のように、切り出した画像だけでは区別が難しい画像が含まれており、一定の誤判定が発生していると考えられる。全体の平均としては、的中率が 89.8%、捕捉率が 86.3% となった。

4. まとめ

本研究では、周辺環境変化の判定精度の向上を目的に、深層学習技術（ディープラーニング（DL））の活用を検討した。その結果以下のことが判明した。

1. パノラマ画像から切り出した側面水平画像を対象として、新旧の画像を学習済みのニューラルネットワーク（GoogLeNet/Places365）で学習した際に計算される特徴量を比較することで、変化の有無を判定する手法を検討した。その結果、画像処理による位置合わせがうまくできた場合には判定ができるものの、位置合わせがうまくいかなかった場合には本手法での判定が難しいことが分かった。
2. 既存の粗度区分を分類として、学習済みのニューラルネットワーク（GoogLeNet/Places365）を用いて転移学習を行うことにより、新しい画像の粗度区分判定を試みた。その結果、分類ごとに画像データ数にばらつきがある場合には、学習の収束が進まないことが判明した。画像データが比較的多い粗度区分 1 から 3 の同数を対象とした場合には、的中率、捕捉率共に 80% 程度からそれ以上の精度で判定できることを確認した。

参 考 文 献

- 1) 三須弥生・土井賢一：パノラマ画像を活用した周辺環境変化の捕捉手法の開発，第 24 回鉄道技術連合シンポジウム J-RAIL2017, S7-5-6 (2017)
- 2) 日比野有・三須弥生・栗原智亮・森山淳・島村誠：強風時の新しい運転規制方法の検討，JR EAST Technical Review, No.35 p.36-41 (2011)
- 3) 竹田進治・大山安紀子・三須弥生・土井賢一：転覆限界風速計算システムの機能・精度向上，第 23 回鉄道技術連合シンポジウム J-RAIL2016, S7-5-3 (2016)
- 4) 日本建築学会編：構造物荷重指針・同解説，pp347-349, 2004.10