

ピギーバック型道路自動点検システムのための 白線の擦れ検出手法検討

河野 慎^{1,a)} 西山 勇毅¹ 米澤 拓郎¹ 中澤 仁¹ 徳田 英幸^{1,†}

概要: 人々の生活において、道路は交通機能や空間整備など様々な機能を担っている一方で、近年進行している老朽化に伴い、早急な修復が求められている。しかしながら、現在の道路状況管理は、各自治体などの人の目視によって行われており、非常にコストが高い。そこで、本研究では公用車に着目し、公用車に容易に脱着が可能な道路自動点検システムの実現を目指し、老朽化している道路状況の一つとして白線の擦れ検出を試みる。白線の擦れを検出する手法として、深層学習を用いたモデルを採用する。深層学習を用いることで、高い認識精度が期待される一方で、実際に運用する際に正しく白線の擦れを検出できているのかわからない性質がある。本実験では、従来の手法との精度比較による提案モデルの性能を評価し、さらにモデルの学習の様子を可視化することによるし、モデルの有用性について検討を行う。

キーワード: 深層学習, スマートシティ, 画像認識, 組み込みコンピューティング

Investigating Compartment Line Damage Detection for the Piggyback-type Road Management System

MAKOTO KAWANO^{1,a)} YUKI NISHIYAMA¹ TAKURO YONEZAWA¹ JIN NAKAZAWA¹
HIDEYUKI TOKUDA^{1,†}

Abstract: In people's lives, roads play a variety of functions such as traffic functions and space maintenance, but as soon as the aging progresses in recent years, urgent restoration is required. However, the present road condition management is performed by people's eyes such as local governments, which is extremely expensive. Therefore, in this research, focusing on public vehicles, we aim to realize a road automatic inspection system that can be easily detached from public vehicles and try to detect scratches on white lines as one of obsolete road conditions. As a method of detecting rubbing of a white line, a model using depth learning is adopted. Although high recognition accuracy is expected by using depth learning, there is a property that it is not known whether rubbing of a white line can be correctly detected correctly in actual operation. In this experiment, we evaluate the performance of the proposed model by comparing the accuracy with the conventional method, further visualize the state of learning of the model, and examine the usefulness of the model.

Keywords: Deep Learning, Smart City, Image Recognition, Embedded Computing

1. はじめに

道路は、まちづくりにおいて非常に重要な役割を担う。人々が歩行する際や自動車などで移動するための交通機能

や、地域開発の基盤整備及び生活基盤の充実のための土地利用誘導機能や災害時の避難路や地下鉄、ライフラインのための空間機能としての役割など様々なものが挙げられる。一方で、今日本に存在する道路は、日本の高度成長期に一斉に建設されたものが多く、近年その老朽化が進行している問題がある。道路を修復するには、各自治体が保有する道路を定期的に点検し、管理しておく必要がある。し

¹ 慶應義塾大学

[†] 現在、情報通信研究機構

^{a)} makora@ht.sfc.keio.ac.jp




図 1 提案システムの概要図。ゴミ清掃車をはじめとした公用車に搭載された組み込みコンピュータ上で、カメラによって区画線が撮影され、この区画線が擦れているか判定する。

かしながら、この点検を行うには膨大な時間と費用がかかる。例えば、白線などの道路標識を点検するためには、行政の職員が目視で行うしかなく、一人の職員が点検可能な距離も限られているため、全ての道路を点検するためには、多くの職員を要し、その人件費などは膨大になってしまう。^{*1}それ故に、頻繁な点検を行うことができず、また現在の社会情勢や財政事情に伴って道路に関する予算が削減されてしまっているため、点検及び修復が十分に行えていない。

この問題に取り組んでいる研究は数多く存在する [8][11][5][15][2]。例えば、前田ら [5] は千葉レポ^{*2}で投稿された道路のひび割れに関する情報を収集し、その投稿された画像内に写る道路のひび割れの度合いを推定している。またそのほかにも、道路の平坦性を推定するため、自転車に取り付けた加速度センサやスマートフォンの加速度センサを用いた研究が挙げられる [15][8][11]。本研究では、これらの研究では扱われていない道路標識の擦れ検出について取り組む。道路標識の擦れ具合は、カメラに撮影することで、前田ら [5] のように、画像から判断することが可能となる。一方で、千葉レポのように、市民などの人々が投稿するプラットフォームがない場合、依然として人件費が膨大にかかる問題が残る。

そこで、本研究ではゴミ清掃車をはじめとした公用車に着目する。ゴミ清掃車は、毎日業務のために運用されており、またその範囲も都市全域を網羅している。したがって、このゴミ清掃車にカメラを設置し、道路を撮影することで、新たに人を雇ったりすることなく道路標識の状況を判断することが可能となり、道路の点検を日々の業務に加えて行うことが可能となれば、前述の頻度や費用などの問題を解決することが可能となる。しかしながら、実際に走行しているゴミ清掃車の台数は非常に多いため、カメラで撮影した動画を物理的な記憶媒体に保存し、どこかに管理することは現実的ではない。またカメラを Raspberry Pi などを

^{*1} 神奈川県藤沢市の場合、市が管理する道路は約 1300km であり、土木担当の職員は約 220 人程度である。1 年間で点検を行おうとした場合、一人当たり 5km の道路を、他の業務と兼ねながらの点検となる。

^{*2} <https://chibarepo.secure.force.com>

はじめとした組み込みコンピュータに接続し、サーバに動画を送信した場合、動画のデータ量から通信帯域の圧迫や膨大な通信費がかかってしまうことが考えられる。以上の問題から、本研究が目指す道路標識の状況判断システムは、搭載が容易なデバイスでかつそのデバイス上で道路の状況推定が可能であることが求められる。

本研究では、ピギーバック型の道路標識の状況判断システムを構築するために、畳み込みニューラルネットワークを用いた白線の擦れ検出手法を提案する。畳み込みニューラルネットワークは、画像認識に関するタスクにおいてその性能は高く、本研究で扱う道路の撮影画像にも有用であると考えられる。一方で、多くの深層学習手法では、学習しているものが何であるかわからないという問題もある。そこで、まず実験にて先行研究で利用されているベースライン手法と白線の擦れ検出の精度を比較し、その有用性について評価する。次に、実験で学習させたニューラルネットワークが実際に白線の擦れを検出できているのか検証するため、実際に画像を入力した際のネットワークの活性化の様子やネットワークが擦れていると推定する画像の特徴などの可視化などを行う。そして最後に、可視化をもとにネットワークのパラメータを取り除き、これによる精度変化を分析し、パラメータの重要性について考察を行う。

本論文の構成は以下の通りである。2 章で、本研究が対象としている白線のデータについて詳細に説明し、次に 3 章で本研究提案する白線の擦れ検出手法について説明する。そして 4 章で、本研究で行った白線の擦れ検出の精度比較や可視化について述べ、提案手法の有用性について評価する。5 章で先行研究及び関連研究について紹介しながら、本研究の位置付けと今後の課題を述べ、6 章にて本論文をまとめる。

2. 白線のデータ

本研究では、道路標識の状況判断の一つとして、白線の擦れに着目し、特に区画線の擦れ検出に取り組む。道路標識の多くは、白線の組み合わせで構成されており^{*3}、区画線は最も単純な道路標識の一つであると考え、本研究の対象とする。区画線が写っている画像データを収集するため、一般乗用車の側面に 60fps の一般的なカメラを区画線が常に写るように設置した。そして、2016 年 3 月 30 日から 2016 年 4 月 2 日までの 4 日間の日中時に、時速 10 キロから 50 キロの間で走行し、撮影を行った。なお、撮影時の天候は晴天であった。

区画線の映像の各フレームを 1 枚の画像として保存した。この画像サイズは、1024×768 ピクセルとなっているが、モデルの学習速度を速めるため、224×224 ピクセルサイズにランダムで切り取った。次に、切り取った画像にお

^{*3} 一部黄色線などもある



図2 本研究で収集したデータの一部。各画像は、撮影された動画の各フレーム(1024×768ピクセル)からランダムにクロッピングされて224×224ピクセルになっている。上段は擦れている白線を、下段は擦れていない白線を示している。

いて、区画線が写っていない画像は取り除いた。そして1名の実験協力者によって、残った画像に写っている区画線が擦れている/擦れていないという2種類のラベルでアノテーションを行った。区画線の擦れに関するラベルづけの妥当性については、5章の考察にて言及する。

これらの処理の結果、32207枚の区画線が写っている画像データを収集した。実際に実験にて利用したデータセットの一部を図2に示す。実験時には、収集したデータを訓練用とテスト用に8:2に分割して利用した。

3. 白線の擦れ検出手法

白線の擦れ検出を、本研究では入力された白線の画像が擦れている白線なのか擦れていない白線なのかという2クラス分類問題として扱う。そして、畳み込みニューラルネットワークを用いて2クラス分類問題に取り組む。畳み込みニューラルネットワークは、画像に関するタスクにおいてその性能の高さが報告されており[4][10][9]、本研究においてもその性能を発揮することが可能と考える。

畳み込みニューラルネットワークは、複数の畳み込み層とマルチパーセプトロン層で構成されている。畳み込み層では、大きさが縦 n_i 、横 n_j で、 c チャンネルの画像($\mathbf{x} \in \mathbb{R}^{n_i \times n_j \times c}$)を入力とし、出力を d チャンネルの画像を出力するために、カーネル $\mathbf{f} \in \mathbb{R}^{n_i \times n_j \times c \times d}$ で畳み込まれる。入力画像 \mathbf{x} の各ピクセル $x_{i,j}$ は、

$$\mathbf{z}_{i,j} = \sum_{i'=1}^{n'_i} \sum_{j'=1}^{n'_j} \phi(\mathbf{f}_{i',j'}^T \mathbf{x}_{i+i',j+j'}) \quad (1)$$

によって畳み込み演算が行われる。ただし、 $\mathbf{f}_{i',j'} \in \mathbb{R}^{c \times d}$ 、 $x_{i+i',j+j'} \in \mathbb{R}^c$ 、そして $\mathbf{z}_{i,j} \in \mathbb{R}^d$ であり、 ϕ は非活性化関数を示す。本研究において、出力層を除いた全ての層で正規化線形関数(Rectified Linear Init, ReLU) $\max(0, x)$ を採用し、出力層は2クラス分類タスクを解くため、シグモイド関数 $\frac{1}{1+e^{-x}}$ を適用した。式(1)によって畳み込み処理が行われたのち、プーリング層を適用する。本研究で対象

にしている白線の位置は道路によって異なる。プーリング層を適用することによって、出力される画像の次元数を削減することができ、また隣り合う特徴の活性がよやくされるため、白線の画像内における平行移動に対して不変性を獲得することが可能となる。複数の畳み込み層とプーリング層を経たあと、入力画像はベクトル表現に変形され、マルチパーセプトロンによって最終的な入力画像に写っている白線の擦れ検出結果を出力する。

4. 実験

本章では、3種類の実験について述べる。1つ目は、提案手法とベースライン手法による白線の擦れ検出精度の比較評価である。2つ目は、提案手法が実際に白線の擦れを検出しているか確認するための可視化である。そして3つ目は、2つ目の実験での可視化を踏まえたカーネルの削除によるモデルの縮小化と精度変化の検証である。

4.1 ベースライン手法との精度比較

本実験では、提案手法が白線の擦れ検出に有用であるか評価する。Kawasakiら[2]は、本研究と同様、白線の擦れを検出するため、ランダムフォレストを適用している。そこで、ランダムフォレストをベースライン手法の一つとしてみなす。また本研究での白線の擦れ検出は、2クラス分類問題であり、この問題において性能が良いとされているサポートベクトルマシン(SVM)もランダムフォレストと同様にベースライン手法として採用する。

ベースライン手法と比較するため、次の指標を用いる。

精度

正解率。テストデータに対して、手法が正しく検出できた割合を示す。

AUC

分類器の性能を表し、1に近いほど完全な予測、0.5で完全ランダムとなる。

再現率

正例のうち正しく検出できた割合を示す。

適合率

予測結果に正しい答えが含まれる割合を示す。

F1スコア

再現率と適合率のバランスを評価する。

ベースライン手法は、グリッドサーチによる最適なパラメータを決定し、実行した。また、提案手法の畳み込みニューラルネットワークのパラメータは、Adamアルゴリズム[3]を用いた勾配降下法によって最適化され、その際の学習率を0.001、モーメントを0.9とした。図3に本実験で用いた畳み込みニューラルネットワークの構造を示す。構造の設計方針として、パラメータ数を抑えるため、カーネルサイズは 3×3 にし、プーリングによる次元削減を優先した。そして、最後のマルチパーセプトロンでは、

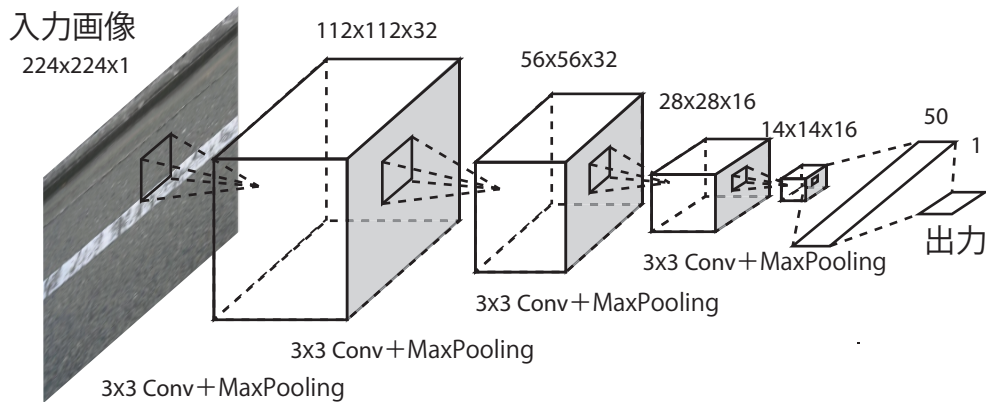


図 3 精度比較のための畳み込みニューラルネットワークの構造。カーネルサイズを 3×3 にし、ストライドを 1、そしてプーリングは最大値を選択するマックスプーリング層で、 2×2 のカーネルサイズで、ストライドを 2 にした。なお、チャンネル数は $1 \rightarrow 32 \rightarrow 32 \rightarrow 16 \rightarrow 16$ となっている。

表 1 精度比較：ベースライン手法と畳み込みニューラルネットワークによる各指標。

手法	精度	AUC	再現率	適合率	F1
線形 SVM	82.4	0.82	0.87	0.83	0.85
ランダムフォレスト	84.0	0.83	0.91	0.83	0.87
CNN	93.4	0.92	0.90	0.95	0.94




図 4 学習前と学習した後の一層目のカーネルの可視化。

ネットワークの汎化性能を向上させるため、Dropout[1] を取り入れた。学習には nVIDIA 社製の GeForce GTX1080 を用いた。

精度比較の結果を表 1 に示す。この結果から、ベースライン手法に比べ、提案手法が白線の擦れ検出において有用であることが確認できる。特に、適合率に関しては、ベースライン手法よりも 10% ほど高く、提案手法による検出結果がより正確であることを示している。

4.2 学習したモデルの可視化

一般に、畳み込みニューラルネットワークをはじめとした深層学習手法は、その認識精度が高いことが評価されている一方で、何を学習しているかわかりにくいという問題がある。そこで本研究では、実験にて学習した畳み込みニューラルネットワークが白線の擦れを正しく認識できているか検証を行うため、可視化を行う。

各層の活性化

学習の様子を可視化する方法として、図 4 に示すように各畳み込み層のカーネルを可視化する方法がある。しかしながら、カーネルの大きさが 3×3 ピクセルで非常に小さいため、その学習結果がわかりにくいという問題がある。

そこで、本研究ではまず実際に白線の画像を入力し、各畳み込みが行われた結果を可視化する。擦れている白線の画像を入れた際の出力結果を図 5 に示す。(擦れていない白線の画像を入れた際のものを図 A-1 に示す。) この画像では、画像下部に白線があり、擦れていることが目視で確認できる。そして、提案モデルの 4 層目において、白線の箇所のみが様々な濃淡で表現されていることが確認できる。一方で、図 A-1 では、同様に画像の下部に擦れていない白線があり、提案モデルの 4 層目にて、白線の箇所が強調されているが、擦れている白線のように様々な濃淡がない。これらのことから、畳み込みニューラルネットワークが白線の擦れを学習できていることが確認できる。

入力画像の生成

さらに、本実験では、ネットワークが学習した結果を理解するため、畳み込みの出力を最大化する入力画像の生成による、その学習結果を可視化する。ネットワークの最終的な出力は、シグモイド関数となる。シグモイド関数 sigmoid は、 $y = 0$ と $y = 1$ を漸近線に保ち、

$$\lim_{x \rightarrow \infty} \text{sigmoid}(x) = 1 \quad (2)$$

$$\lim_{x \rightarrow -\infty} \text{sigmoid}(x) = 0 \quad (3)$$

という性質を持つ。したがって、 sigmoid は、入力 x が大きいければ大きいほど 1 に近い出力をもつことから、任意の画像を入力した際にネットワークの最終層において sigmoid に入力する値が大きい場合、最終的な出力は 1 となり、この画像は擦れているとネットワークが検出することになる。この性質を応用して、ネットワークのパラメータを学習済みの値に固定し、入力画像 x を変化させることで、ネットワークの出力を調節することが可能となる。

入力する画像を一様分布からサンプリングされたランダムな値で作成し、勾配上昇法：




図 5 擦れている白線が写った画像を入力とした場合のネットワークの各層における出力の可視化. 1, 2 層目ではあまり特徴的に強調されているカーネルはない. 一方で 3, 4 層目になると, 実際に擦れている部分が黒くなり, 強調されていることがわかる.

$$x \leftarrow x + \eta \frac{\partial a_i(x)}{\partial x} \quad (4)$$

を用いて, 画像を変化させて行く. ただし, x は入力画像を, η は学習率を示す. そして $a_i(x)$ は, 今回学習させたネットワークの最終層で, シグモイド関数 *sigmoid* を取り除いた出力を意味する. 出力 $a_i(x)$ の値を大きくするように変化した場合と, 小さくするように変化した場合の入力画像を図 6 に示す. なお, これらの画像は, その特徴を強調するため, 値を変更する際に, L_p ノルム正則化:

$$\|x\|_p = (|x_1|^p + |x_2|^p + \dots + |x_n|^p)^{\frac{1}{p}} \quad (5)$$

及び Total Variation 正則化:

$$V(x) = \sum_{i,j} \sqrt{|x_{i+1,j} - x_{i,j}|^2 + |x_{i,j+1} - x_{i,j}|^2} \quad (6)$$

を追加する. これらの正則化によって, 生成される画像を滑らかにすることが可能となる.

図 6 の左側が小さくした場合の画像で, ネットワークが擦れていないと検出する画像である. 画像は全体的に白の部分が多く, 擦れていない白線であれば, 連続した白色の範囲が多いと考えられるため, 適切に学習されていると言える. 一方で図 6 の右側は, 出力を大きくした場合の画像であり, ネットワークが擦れていると検出する画像である. 擦れがないと判断する画像に比べて, 黒色の割合が非常に多く, 擦れていない白線と同様に適切にネットワークが学習されていると言える.

以上の可視化から, 畳み込みニューラルネットワークに白線の画像と白線の擦れの有無を学習させることで, 擦れの位置などを付加情報として与えなくても, 畳み込みニューラルネットワークが適切に擦れを検出することができていることが確認できた.

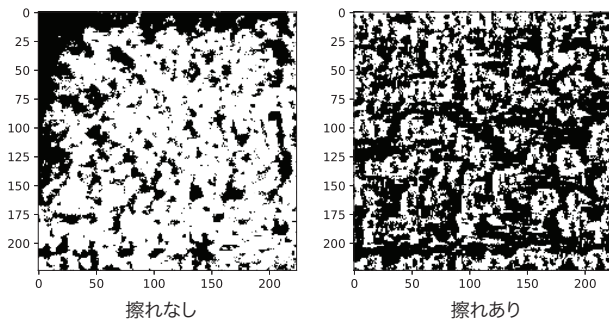


図6 畳み込みニューラルネットワークの出力調節によって生成された画像例。左側は、ニューラルネットワークが擦れていないと検出する画像となり、右側は擦れていると検出する画像になっている。2枚の画像の比較により、ネットワークが擦れていることを学習できていることがわかる。

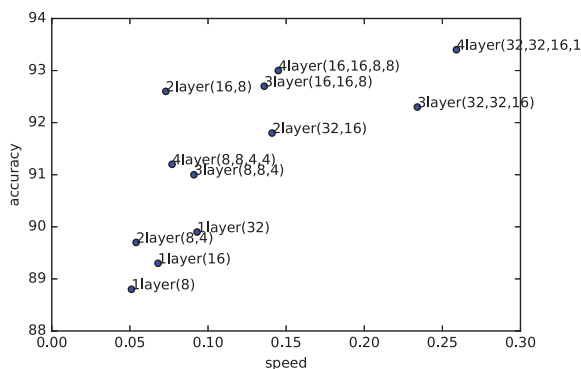


図7 ネットワークの構造を変化させたときの精度及びその速度の変化の様子。層数及び各層のパラメータを削減するにつれ、処理速度は向上する一方で、その精度が低下している。

4.3 パラメータの削減による精度変化

最後に、本研究で提案したニューラルネットワークを実際に Raspberry Pi3 で実行したときのその精度と速度を検証する。本研究では、最終目標が公用車に容易に装着が可能な道路状況診断システムの実装であるため、本論文で提案しているニューラルネットワークも組み込みコンピュータ上で実行が可能である必要がある。そのために、組み込みコンピュータの一つである Raspberry Pi3 を利用する。Raspberry Pi3 は CPU の性能も一般的な CPU と比較すると低く、またメモリも 1GB しかないため、提案手法であるニューラルネットワークの構造が大きくなり、パラメータ数も膨大になると、実行できないという問題が考えられる。

本実験では、実際に Raspberry Pi3 上でニューラルネットワークのパラメータ数などを調節し、その精度の変化と速度の変化を評価する。その結果を図 7 に示す。ネットワークの総数及び、各層のチャンネル数を削減することにより、その実行速度が向上している一方で、その精度が低下していることが確認できる。また、図 5 の可視化において、3 層目と 4 層目で白線が強調されていることを確認したが、実際に 1 層目と 2 層目のみで行なった場合、精度が

低下していることも確認できる。以上のことから、本研究で提案した畳み込みニューラルネットワークを用いた白線の擦れ検出手法が、実際に組み込みコンピュータで運用した場合も、実用に耐えうると言える。

5. 関連研究と議論

都市が抱えている問題の解決を試みる研究は数多く存在する。Zheng ら [14] は、タクシーの移動経路からガソリンスタンドの位置を推定し、都市のエネルギー問題の解決や都市計画に貢献している。他にも、地理的な側面から都市の生活に関する分析 [6] や都市における犯罪の発生場所を検出する研究 [13] なども挙げられる。

こうした都市に関する研究の中でも、本研究のように道路に着目した研究も多い。道路の修復対象は、本研究で対象にしている道路標識の擦れ以外に、道路の平たんやひび割れ、わだち掘れが挙げられる。道路の平たん性は、多くの研究で、スマートフォンや加速度センサなどを用いてその値の変化から推定している [15][8][11][12][7]。しかしながら、本研究が対象としている白線の擦れは、加速度センサなどでは値がほとんど変化しないため、これらの研究と同様の手法を取るのには難しい。

また道路のひび割れを検出する研究では、Maeda ら [5] は、深層ニューラルネットワークを適用し、検出に成功している。しかしながら、利用しているデータがちばレポに基づいたものであり、参加型センシングの観点から、市民からの投稿がなければ画像データを収集することが難しく、またこの参加型センシングのプラットフォームを新しい自治体などで運用するには非常にコストがかかってしまう問題がある。一方で、本研究で利用しているデータは、安価な組み込みコンピュータを用いて容易に装着が可能なデバイスを公用車に搭載し、日々の業務の中での撮影を想定している。したがって、導入コストはこのデバイスの開発及び装着のみであり、またデータも毎日取得が可能という点で異なる。

そして、本研究と同様に白線の擦れ検出に関する研究では、Kawasaki ら [2] が挙げられる。本研究と同様に道路の白線検出をカメラの画像とランダムフォレストを用いて検出しているが、精度も十分とは言えない。一方で本研究では、深層学習手法を適用しており、精度もランダムフォレストより良いことが確認できている。

本研究の今後の課題としては、実際に公用車にデバイスを設置し、運用を行うことが挙げられる。本研究で用いたデータは、あらかじめデータの整形が行われており、提案手法では、撮影された映像を加工せずに白線の擦れを検出することができない。したがって、撮影された映像から直接白線の擦れを検出が可能となるような手法の改良が求められ、さらに、実際に公用車に設置し、白線の擦れに関する情報をサーバに送信し、地図上に表示するなどのアプリ

ケーションの実装が求められる。

最後に、本研究では白線の擦れ検出の最初の取り組みとして、区画線を対象にしたが、そのほかの道路標識の擦れも検出可能になる必要があり、さまざまな道路標識に対応可能なより汎用的な手法の提案も今後の展望として挙げられる。

6. まとめ

人々の生活において、重要な機能を担う道路の老朽化に伴い、早急な修復が求められているが、現在の道路状況管理は人件費など非常にコストが高い。そこで、本研究では公用車に着目し、公用車に容易に脱着が可能な道路自動点検システムの実現を目指し、老朽化している道路状況の一つとして白線の擦れ検出を試みた。白線の擦れを検出する手法として、深層学習手法の一つである畳み込みニューラルネットワークを用いたモデルを採用した。本実験では、従来の機械学習手法であるSVMやランダムフォレストと白線の擦れ検出精度の比較を行い、提案モデルの有用性を示した。さらにモデルの学習の様子を可視化し、提案モデルが適切に白線の擦れを検出できていることを確認した。最後に、提案モデルを組み込みコンピュータの一つであるRaspberry Pi3上で実行し、実際の運用を見据えた評価実験も行い、実際に運用に耐えうることを示した。

謝辞 本研究の一部は国立研究開発法人情報通信研究機構に支援頂いた。本研究の一部は国立研究開発法人理化学研究所に支援頂いた。

参考文献

- [1] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. R.: Improving neural networks by preventing co-adaptation of feature detectors, *arXiv preprint arXiv:1207.0580* (2012).
- [2] Kawasaki, T., Kawano, M., Iwamoto, T., Matsumoto, M., Yonezawa, T., Nakazawa, J. and Tokuda, H.: Damage Detector: The Damage Automatic Detection of Compartment Lines Using A Public Vehicle and A Camera, *EAI MOBIQUITOUS2016IWWSS2016*, pp. ppNA–ppNA (2016).
- [3] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014).
- [4] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: ImageNet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097–1105 (2012).
- [5] Maeda, H., Sekimoto, Y. and Seto, T.: An Easy Infrastructure Management Method Using On-Board Smartphone Images and Citizen Reports by Deep Neural Network, *Proceedings of the Second International Conference on IoT in Urban Space*, ACM, pp. 111–113 (2016).
- [6] Mashhadi, A., Bhattacharya, S. and Kawsar, F.: Understanding the Impact of Geographical Context on Subjective Well-Being of Urban Citizens, *Proceedings of the Second International Conference on IoT in Urban Space*, ACM, pp. 29–35 (2016).
- [7] Mohamed, A., Fouad, M. M. M., Elhariri, E., El-

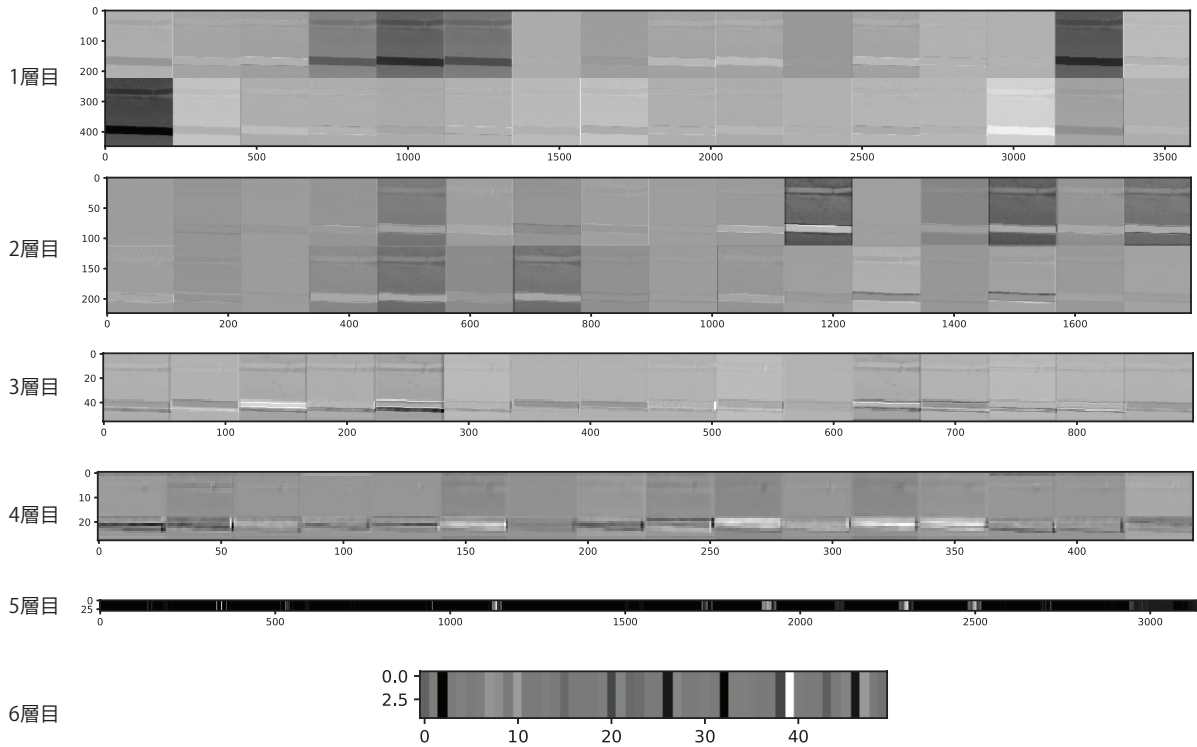

- Bendary, N., Zawbaa, H. M., Tahoun, M. and Has-sanien, A. E.: RoadMonitor: an intelligent road surface condition monitoring system, *Intelligent Systems' 2014*, Springer, pp. 377–387 (2015).
- [8] Nagayama, T., Miyajima, A., Kimura, S., Shimada, Y. and Fujino, Y.: Road condition evaluation using the vibration response of ordinary vehicles and synchronously recorded movies, *Proceedings of the SPIE Smart Structures and Materials+ Nondestructive Evaluation and Health Monitoring*, p. 86923A (2013).
 - [9] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556* (2014).
 - [10] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A.: Going deeper with convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1–9 (2015).
 - [11] Takahashi, J., Kobana, Y., Tobe, Y. and Lopez, G.: Classification of Steps on Road Surface Using Acceleration Signals, *proceedings of the 12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services on 12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), pp. 229–234 (2015).
 - [12] Tomiyama, K., Kawamura, A., Fujita, S. and Ishida, T.: An Effective Surface Inspection Method of Urban Roads According to the Pavement Management Situation of Local Governments, *Journal of Japan Society of Civil Engineers, Ser. F3 (Civil Engineering Informatics)*, Vol. 69 (2013).
 - [13] Venerandi, A., Quattrone, G. and Capra, L.: Guns of Brixton: which London neighborhoods host gang activity?, *Proceedings of the Second International Conference on IoT in Urban Space*, ACM, pp. 22–28 (2016).
 - [14] Zhang, F., Yuan, N. J., Wilkie, D., Zheng, Y. and Xie, X.: Sensing the pulse of urban refueling behavior: A perspective from taxi mobility, *ACM Transactions on Intelligent Systems and Technology (TIST)*, Vol. 6, No. 3, p. 37 (2015).
 - [15] Zhao, B., Nagayama, T., Makihata, N., Toyoda, M., Takahashi, M. and Ieiri, M.: IRI Estimation by the Frequency Domain Analysis of Vehicle Dynamic Responses and Its Large-scale Application, *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, ACM, pp. 41–46 (2016).

付 録

A.1 擦れていない白線画像を入力とした時の活性化

4章の実験において、白線が擦れていない画像を入力した時の学習済みネットワークの各層の出力結果を図A-1に示す。図5と同様に白線の位置が適切に強調されている一方で、擦れている箇所がないため、白く強調されるのみとなっている。

入力画像



出力:0.0048

図 A.1 擦れていない白線が写った画像を入力とした場合のネットワークの各層における出力の可視化.