4I1-5

# 車いすセンシングと畳み込みニューラルネットを利用した 路面特徴の分類と評価

Classification and evaluation of features of road surface using wheelchair sensing and convolution neural network

高橋 宏紀 \*1 長峯 洸弥 \*2 岩澤 有祐 \*3 松尾 豊 \*3 矢入 郁子 \*2 Hiroki Takahashi Koya Nagamine Yusuke Iwasawa Yutaka Matsuo Ikuko Yairi

\*1上智大学 理工学部 情報理工学科

Facility of Science and Technology, Sophia University

\*2上智大学大学院 理工学研究科理工学専攻情報学領域 Graduate School of Science and Engineering, Sophia University

\*3東京大学大学院 工学系研究科技術経営戦略学専攻

Graduate School of Technology Management for Innovation, The University of Tokyo

Towards the inclusive society, the online digital map which supports wheelchair users' accessibility become more and more important today. Accumulation of the road accessibility information on the map takes a lot of manpower, and is limitedly implemented even in densely populated urban areas. The purpose of this research is automatic visualization and mapping of the sidewalks accessibilities from the sensor data of wearable devices at wheelchair driving. This paper attempts to investigate a DCNN's internal representation which has been built for automatic visualization of the road accessibilities. The internal representations are obtained by the CNN after leaning to recognize the state of the road surface, which are most important to estimate physical burdens for users as the barriers on the road, from the wheelchair sensing data. This paper reports the analysis of the internal representations of the DCNN with the accelerometers' data of 27 rounds wheelchair driving on the same route with 9 persons.

### 1. はじめに

歩道のアクセシビリティ情報の提供は、高齢者や障害者の安全な移動を担保する重要な試みの1つである。しかし情報提供のためのアクセシビリティ情報収集は従来、専門家による評価[Ponsard 06] やクラウドソーシングを利用した方法 [Hara 14, Cardonha 13] といったマンパワーに基づいた手法に依存しているため、大規模な情報収集が困難という問題点がある。そのため、現在公開されているアクセシビリティ情報の多くは、大学や駅などの公共性の高い施設とその周辺に留まっている。そこで、筆者らはこれまで、車いすに3軸加速度センサを取り付け、車いすユーザが歩道を走行することで得られるセンシングデータから、路面の凹凸や傾斜といった路面特徴を機械が自動推定する方法の実現に取り組んできた。

車いすに加速度センサを設置する場合、その観測値は路面の凹凸のパターンや傾度などから影響される。そのため、間接的に路面特徴を計測することができると考えられる。しかし、一般にセンサの値はユーザやデバイスの違いなど多様な要因に影響され、観測したセンサ値からその要因の1つのみを抽出することは容易ではない。そのため、センサ値を路面の状態をよく表す何らかの指標(特徴量)に変換することが重要となる。

本稿では、ラベリングされた車いすセンシング加速度データをもとに、路面の凹凸や傾斜といった路面特徴を学習した深層学習の1種である深層畳み込みニューラルネットワーク(以降 DCNN と表記)を利用して、DCNN の内部に蓄えられたラベルよりも詳細な路面特徴を取り出す方法を提案する。以降2章では、関連研究を踏まえて提案手法の有用性について

連絡先: 高橋宏紀,上智大学理工学部情報理工学科,東京都千代田区紀尾井町 7-1,03-3238-3280,takahashi\_hiroki@eagle.sophia.ac.jp

論じ、3章で提案手法の有効性の検証に利用した加速度データの取得方法,DCNNの学習方法および DCNNの路面の分類精度を説明する。4章では、類似路面検索タスクを通じて、提案手法を定性的に評価した結果について報告し、5章で結論、将来課題を述べ本論文をまとめ結びとする。

# 2. DCNN と車いすセンシングを利用した路 面特徴の推定と蓄積

本稿の目的は、車いすセンサデータから路面状態を推定するタスクに DCNN を利用したことで、どのような路面特徴を捉えているかを分析することにある。DCNN を採用する利点は、認識精度が高い点、中間表現の活用により路面の効果的な特徴獲得が期待できる点の2点に集約される。この2つの論点について、「DCNN の類似データへの有効性」およびに「車いすセンシングを用いた路面特徴の評価」に関する関連研究を踏まえて説明する。

#### 2.1 DCNN **の**類似データへの有効性

DCNN は深層学習の手法の1つであり、特に画像認識の分野で高い認識精度を達成することが知られている手法である [Krizhevsky 12]. また、近年の研究では今回扱う車いすセンシングデータと類似したデータであるスマートフォンによる 健常者の行動センシングデータにおいても有効性が検証されている [Yang 15]. Liuらは、行動センシングデータに対して畳み込みニューラルネットワークを適用し、既存の手法と比較して 10%程度の認識能力の改善が見られることを確認した [Liu 14]. これらの理由から、DCNN の利用により路面の認識においても高い認識精度を達成することが期待できる.

#### 2.2 車いすセンシングを用いた路面特徴の評価

車いすセンシングデータから路面の状態(坂の有無,路面の種類,障害物の有無など)を予測したり、路面の状態をよく反映した何らかの特徴量を設計することができれば、これまでの人手による方法 [Ponsard 06, Hara 14, Cardonha 13] と比較して金銭的コストを低下させたり、より大規模な範囲の路面特徴情報を蓄積することができるようになる。

図1に、車いすセンシングを活用した路面特徴を推定・蓄積するシステムの概要図を示す。Iwasawa らは路面特徴の抽出を分類問題と考え、段差の有無/坂の有無/点字ブロックの有無といったラベルデータを利用して予測モデルを学習させる方法を提案しその有効性を検証している [Iwasawa 16]. 任意の路面を走行したときの加速度データを入力として、学習済みDCNNが反応パターンをもとに、その路面の段差の有無/坂の有無/点字ブロックの有無といった路面特徴を判断することができる。一方、教師あり学習ではラベルデータの付与が人手に依存しているため、路面を単純な分類タスクとして考えるアプローチでは、より細かな分類(例えば路面の舗装材の細かな種類)を推定することはラベルデータ確保の観点から難しい。

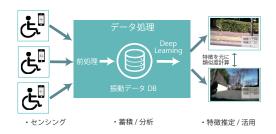


図 1: 車いすセンシングと DCNN による路面特徴の推定と蓄 積概要図

そこで本稿では、DCNN と車いす走行時に得られる加速度データを用いて、路面特徴を定量的に表現することを目指す。路面特徴を定量化するにあたり、DCNN が分類問題を解く際に生成する反応パターンに注目した。DCNN は反応パターンをもとに路面を分類していることから、分類精度の高い DCNN の反応パターンは路面特徴を表していると想像できる。以降本稿では、反応パターンが似ている路面同士の比較を通してDCNN の反応パターンが路面特徴を定量的に表現することができているのか検証していく。

# 3. DCNN モデルの作成

本章では、提案手法の有効性の検証に利用したデータの取得方法、提案手法に用いた DCNN の学習および分類精度について順に説明する.

### 3.1 利用データの取得方法

提案手法の有効性の検証に利用したデータの取得方法について説明する。データセットは、9名の車いすユーザが東京都四ツ谷周辺の指定された経路約1.4kmを各々走行した際の行動ログを、車いすの座席下側に設置した加速度センサ(iPod touch)およびに準天頂衛生システムにより計測したものである。利用した加速度センサでは、x軸,y軸,z軸の3軸方向のそれぞれの加速度値が計測される。結果として、合計1,255,900の加速度サンプル(約9時間)を得た。また、加速度サンプルを取得した場所がどのような状況であったのかを確認できるように、実験中は車いすユーザの行動している様子を撮影した。

実験が終了した後、実験動画を目視することによって路面特徴 に関するラベル付けを行った.

#### 3.2 DCNN の学習方法

図 2 に、本稿で利用した DCNN の構造を示す。本ネットワークは、1. 入力層(3 軸加速度データ、400 のウィンドウ幅で切り出し)、2. 畳み込み層(Convolution+Max Pooling)×3、3. 全結合層、4. 出力層、の6 層から構成されている。このような階層構造を持つネットワークを利用して入力から出力への関数を学習させることで、生データからの分類に有効な特徴抽出器 h と分類器 f の学習を同時に進めることができる.



図 2: 本稿で利用した DCNN の構造

DCNN の学習は入力である加速度データを、何らかへの出力へと写像する際の損失を最小化するように行われる。そのため、出力として何を予想させるかはどのような特徴量が獲得されるかに強く影響することが明らかである。ここでは、出力として縁石/点字ブロック/坂/その他の4クラスへと分類した。分類対象としてこの4つを選択したのは1. 既存研究との比較のため [Iwasawa 16], 2. それぞれ順に突発的な段差/継続する凹凸/傾斜という路面の代表的な特徴を表していると考えられる、3. ある程度のサンプル数(最低60サンプル程度)が確保できるためである。

畳みこみ処理部分では,関連研究 [Yang 15] にならい,Convolution およびに Max Pooling の 2 つの処理を行っている.ここで図中 w は入力データに対して畳み込まれる重みであり,入力を出力へうまくマッピングするように学習されるパラメタである.また,図中 Feature Map(N) とは,N 種類の異なる重みを学習しておりそれぞれ N 種類の異なる出力を得ていることを意味している.また,ニューラルネットワークの学習には Adam を利用し,学習率は 0.0001 とした.また,活性化関数には出力層で Softmax 関数を利用したのを除き,Rectified Linear Units を利用した.

#### 3.3 路面分類タスクによる定量的評価

本章では、単純な分類タスクで既存手法と DCNN を比較し、獲得された特徴量が路面特徴とどの程度対応しているのかを確認する。表1は、既存手法と DCNN の段差/点字ブロック/坂/その他路面の分類タスクにおける認識精度を比較したものである。ここで、各表の値はそれぞれ Leave-One-Subject-Out 法により得られた9回の試行の平均値である。Leave-One-Subject-Out 法とは、8 名のユーザで訓練したモデルを残りの 1 名のユーザのデータで評価することを繰り返し行う方法であり、学習データに存在しないユーザのデータで評価を行うことで、未知のユーザに対する認識精度を検証することができる。また、評価指標としては各クラスの平均 F値及びに正解率を利用した。ここで、今回の分類問題はクラスインバランスであり、平均 F値が高いことは珍しいサンプルについてもよく認識できていることを意味する。各ベースライン手法の詳細は次のとおりである。

(1) Raw: 生データを入力に, K-Nearest-Neighbor 法

(KNN) で分類. なお、生データは 3 軸加速度であるためそのまま入力することはできないが、ここでは単純に結合し KNNへの入力とした。 K の値としては K=1,5,10,15,20,25,30を検証し、検証データにおいて最も精度の高かった K=1 を利用した.

- (2) MV : Rawdata と同様に、K=1 の KNN を利用した。特徴量として、xyz 各軸の平均値及びに標準偏差の 6 つの特徴量を利用した。
- (3) SVM: MV と同様に、xyz 各軸の平均値及びに標準偏差の 6 つの特徴量を利用し、KNN の代わりに分類器として Support Vector Machine を利用した。カーネルとしては radial bias function を利用した。また、パラメタは  $\gamma(10^{-12}-10^2)$  およびに  $C(10^{-7}-10^7)$  についてグリッドサーチを行い、検証データにおいて最も精度が高かったパラメタを利用した。

結果として、DCNN を利用した方法により従来利用されていた特徴設計より高い精度が得られていた。具体的には、次点で認識精度の高かった SVM と比較して平均 F 値では 0.10 ポイント、およびに正解率で 0.14 ポイントの精度向上となった。したがって、今回用いた DCNN の車いす走行データの分類精度が高いことが定量的に示されているので、その 1 つ前の層である DCNN の  $FC_0$  の 400 ユニットでは、車いす走行データから何らかの走行路面特徴を捉えていることが想像される。

表 1: 既存手法と DCNN の認識精度の比較

指標	Raw	MV	SVM	DCNN
平均F値	0.22	0.58	0.61	0.71
Accuracy	0.36	0.79	0.74	0.88

# 4. 類似路面検索タスクによる獲得された表現 の定性的な評価

#### 4.1 分析手順

任意の地点を入力したときに、その地点と DCNN の反応パターンが近い地点を抽出することでその地点の類似路面が検索できていのるかを目視により確認した。以降本稿では、入力として使用した地点を Query と呼ぶこととする。入力した Query に対して類似路面を検索した方法を Step1 から Step3 に分けて説明する。

#### Step1:全データの特徴化

3.3 節と同様に8名のユーザで訓練したDCNNモデルを作成し、残りの1名のユーザの全地点の加速度データを入力することで全地点の特徴量を獲得した.

#### Step2: 地点間のユークリッド距離の計算

Step1 で算出した特徴量を用いて、任意の Query に対して他の全ての地点とのユークリッド距離を算出した.

#### Step3:類似路面の検索

任意の地点に対して、Step2で計算した特徴量空間における ユークリッド距離が近い地点上位4件をQueryとの類似地点 として抽出した。

また、比較対象として加速度の生データを用いても行った。加速度の生データを用いる場合は、特徴量と同様に上記の Step2 と Step3 を行う。上記の 3 つの Step を踏まえて、1. 類似路面の検索ができているのかどうかを評価するにあたり、ラベル付けし分類した 4 つのクラスより詳細な路面に該当する、上り坂、段差のある場所、点字ブロックを横切る場所の 3 つをQuery とし、類似した場所が正しく抽出されるかどうかを実験動画を目視することで確認する。また、2. 路面を連続値と

して表現できているのかを確認するために、同様の路面特徴を持つが段差と傾斜の大きさに差のある2つの地点をQueryとし、それぞれ類似路面がどのような路面なのかを確認する。

#### 4.2 類似路面検索結果

加速度の生データと DCNN の特徴量を用いてそれぞれ類似路面検索を行った結果を図 3 に示す。図中の Query は比較を行うため、加速度の生データを用いた場合と特徴量を用いた場合とも同一のものを用いた。また、Query に対してユークリッド距離が近い上位 4 つの場所を右側に示した。図の画像は、実験動画から各場所の走行時刻を参考に取り出したものである。画像の枠の色は、Query と同一の路面特徴を持つことが動画から読み取れる場合は黒とし、同一の路面特徴を持つことが読み取れない場合は赤とした。

図3の上り坂では、加速度の生データを用いた場合の上位 4 つ中 4 位だけが上り坂に該当しているが、DCNN の特徴量を用いた場合は上位 4 つ全てが上り坂に該当している。段差では、加速度の生データを用いた場合の上位 4 つ中 1、3 位が、DCNN の特徴量を用いた場合は上位 4 つ全てが該当している。点字ブロックを横切る場所では、加速度の生データを用いた場合に、車いすが停止状態のデータが類似と判断される結果となった。DCNN の特徴量を用いた場合には、上位 4 つの中で1 位だけが点字ブロックを横切る場所が正しく類似と判断されていた。誤判断された 2 位から 4 位について動画で詳細を確認したところ、いずれも目地の小さなタイルで構成された路面であった。

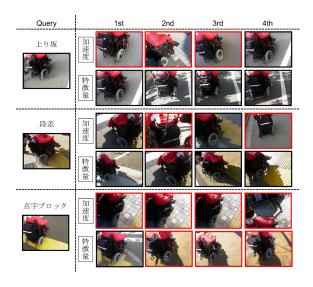


図 3: 加速度の生データと DCNN から得られた特徴量を用いたそれぞれの類似路面検索結果

次に、特徴量が走行時の路面特徴を連続的に表現できているのかを確認するために、歩道から車道に変わる(傾斜、点字ブロック、段差、横断歩道が連続的に含まれる)場所を含む地点2つをQueryとして、特徴量を用いてそれぞれ類似路面検索を行った結果を図4に示す。図4のQuery-1はQuery-2は、共通の路面特徴として段差や傾斜、点字ブロックや横断歩道が確認できるが、段差と傾斜に関してはQuery-1のほうが明らかに大きい。

Query-1 の類似路面として抽出された全ての地点で段差と大きな傾斜が確認できた。点字ブロックや横断歩道は上位 2位, 3位, 4位の地点で確認することができた。Query-2 の類

似路面として抽出された上位1位は3周目の同じ地点であり、 Query と同じ路面特徴を確認することができた。上位2位と3位では点字ブロックのみが確認でき、4位では横断歩道と傾斜が路面特徴として確認できた。



図 4: 歩道から車道に変わる場所を含む地点 2 つの地点をそれ ぞれ Query としたときの類似路面検索結果

#### 4.3 考察

図3で生データである加速度波形の類似性をユークリッド 距離から求めた場合, 点字ブロックについては4つの事例で, 上り坂では1つの事例で停止状態の波形を類似路面と判別し ていた. その他の赤枠で示した地点では、走行してはいるも のの点字ブロックや段差を通過することもなく, また坂でもな いほとんど平坦な路面であったことから、全く特徴を捉えるこ とができていないことがわかった。それに対して、特徴量を用 いた場合では、上り坂と段差の上位4つ全てがQueryと同様 にそれぞれ路面特徴を含む地点であった. 点字ブロックでも, 類似度上位2位から4位までは点字ブロックが含まれていな い路面となってしまったが、どれも目地の小さなタイルで構成 されている路面を走行しているときのものであった。このこと から、DCNN によって生成される特徴量を用いた場合の方が 加速度の生データを用いた場合よりも、詳細な路面特徴を捉え ていることがわかった。段差のような鮮明な特徴が含まれる事 例では生データからの分類も不可能ではないかもしれないが, DCNN によって生成される特徴量は加速度の生データより軽 微かつ精緻な路面特徴を捉えることが可能であると言える。

図4に示したQuery-1をQueryとした場合の結果から、大きな段差や大きな傾斜は点字ブロックや横断歩道などの路面の小さな凹凸よりも鮮明な路面特徴と捉えていることが考えられる。また、Query-2をQueryとした場合の結果から、小さな段差や小さな傾斜よりも点字ブロックや横断歩道といった路面の連続した小さな凹凸の方がより鮮明な路面特徴と捉えていると考えられる。このことから、DCNNによって生成された特徴量は凹凸の度合いや傾斜の度合いを表現できていることが推察される。

このように、本稿の DCNN によって生成される特徴量が、分類に指定した段差/坂/点字ブロック/その他の 4 つのラベルよりも細かい特徴を捉えていること、凹凸の度合いや傾斜の度合いを表現できていることが確かめられた。 DCNN によって生成される特徴量を用いることで路面特徴を定量的に表現することが可能であると考えられる.

## 5. おわりに

本稿では、車いす座席下側に設置した3軸加速度センサに よって取得した加速度データを入力として学習を行ったDCNN を利用して、走行した路面の特徴を表す特徴量を取り出し、そ の精度を評価した。その結果、DCNN が獲得した特徴量が生データよりも小さな路面特徴を捉えることが可能であり、路面特徴を定量的に表現する手段として有効であることを示した。一方でユーザごとに得られた特徴量には、路面特徴を捉える精度にばらつきがあることがわかった。今後は新規環境を含むより多くのデータセットの収集と解析・獲得された特徴量の定性的評価を通じて、ユーザごとの影響を低減可能な、より高精度な特徴表現を獲得する手法の提案を行う予定である。

### 謝辞

実験に参加・協力して下さった全ての皆様に感謝致します。 本研究は平成23年度,平成24年度立石科学技術振興財団及び平成26,27,28年度東京都千代田区からの研究助成金(千代田学)のもと行われました。

# 参考文献

[Cardonha 13] Cardonha, C., Gallo, D., Avegliano, P., Herrmann, R., Koch, F., and Borger, S.: A crowdsourcing platform for the construction of accessibility maps, in Proceedings of the 10th International Cross-Disciplinary Conference on Web Accessibility, p. 26ACM (2013)

[Hara 14] Hara, K.: Scalable methods to collect and visualize sidewalk accessibility data for people with mobility impairments, in *Proceedings of the adjunct publication of the 27th annual ACM symposium on User interface software and technology*, pp. 1–4ACM (2014)

[Iwasawa 16] Iwasawa, Y., Yairi, I. E., and Matsuo, Y.: Combining Human Action Sensing of Wheelchair Users and Machine Learning for Autonomous Accessibility Data Collection, *IEICE TRANSACTIONS on Informa*tion and Systems, Vol. E99-D, No. 4, pp. 115–124 (2016)

[Krizhevsky 12] Krizhevsky, A., Sutskever, I., and Hinton, G. E.: Imagenet classification with deep convolutional neural networks, in Advances in neural information processing systems, pp. 1097–1105 (2012)

[Liu 14] Liu, H., Taniguchi, T., Takano, T., Tanaka, Y., Takenaka, K., and Bando, T.: Visualization of driving behavior using deep sparse autoencoder, in *Intelligent Vehicles Symposium Proceedings*, 2014 IEEE, pp. 1427– 1434IEEE (2014)

[Ponsard 06] Ponsard, C. and Snoeck, V.: Objective accessibility assessment of public infrastructures, in Computers Helping People with Special Needs, pp. 314–321, Springer (2006)

[Yang 15] Yang, J. B., Nguyen, M. N., San, P. P., Li, X. L., and Krishnaswamy, S.: Deep convolutional neural networks on multichannel time series for human activity recognition, in *Proceedings of the 24th International Joint Conference on Artificial Intelligence (IJ-CAI)*, Buenos Aires, Argentina, pp. 25–31 (2015)