

車いす走行路面の特徴を抽出する DCNN のための GPS を用いた学習用データラベリング手法の検討

Study on data labeling method using GPS for DCNN learning to extract road surface characteristics from wheelchair sensing data

高橋 宏紀^{*1}
Hiroki Takahashi

岩澤 有祐^{*2}
Yusuke Iwasawa

長峯 洸弥^{*1}
Koya Nagamine

矢入 郁子^{*1}
Ikuko Yairi

^{*1}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

^{*2}東京大学
The University of Tokyo

Recent expansion of intelligent gadgets, such as smartphones and smartwatches with vital sensors, make it easy to sense a human behavior. We are developing a road accessibility evaluation system inspired by human behavior sensing technologies. Our proposed system aims to estimate road accessibility as environmental factors, e.g. curbs and gaps, which directly influence wheelchair bodies, and human factors, e.g. wheelchair users' feeling tired and strain, which are results of the environmental factors. This paper introduces a data labeling method using GPS for DCNN learning to extract road surface characteristics from wheelchair sensing data. As a conventional method, the manpower based labeling have been used by comparing wheelchair sensing data with recorded video of wheelchair traveling. This paper evaluates and reports the effectiveness of the proposed method.

1. はじめに

歩道のアクセシビリティを確保し、高齢者や障がい者などの移動弱者の負担を軽減することは、重要な社会的課題の1つである。データ収集方法には現在、歩道が撮影された画像等から専門家が事例毎に評価するもの [Ponsard 06] や、クラウドソーシングを利用して歩道の撮影や評価を一般人の協力を募って行うもの [Hara 14, Cardonha 13] などがある。これらのマンパワーに基づいた手法では、時間的・金銭的コストを要することから大規模な情報収集が困難という問題があり、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のが現状である。スマートフォンやスマートウォッチのような多彩なセンサを搭載した電子デバイスの普及により、近年、人間行動を計測し活用する動きが活発化している [Swan 13, Nagamine 15]。車いすユーザが持ち歩く電子デバイスが計測する人間行動データからそのユーザが通った路面の特徴を推定することができれば、ローコストで大規模でのアクセシビリティ情報の収集が可能になる。

そこで筆者らはこれまで、車いすに設置した加速度センサの観測値が路面の凹凸のパターンや傾度などに影響されることに着目し、機械学習を用いて路面の特徴を推定するシステムを提案してきた。図1にシステムの概要図を示す。提案システムは、車いす座面下部に装着されたスマートフォンの3軸加速度センサを用いて、走行時の加速度データを収集し、機械学習を用いることで加速度データから路面情報を抽出した後、路面情報を蓄積し地図上に可視化するものである。

機械学習を用いて加速度データから路面情報を抽出する場合、加速度データに路面情報の正解ラベルを付与する必要がある。これまでの研究では、実験時の様子を撮影したビデオデータを利用して手作業でラベルの付与を行っていた。そのため大量のデータに正解データのラベルを付けるのは非常に作業量が多く困難である。

本稿の目的は、車いすセンサデータをもとに路面の特徴を学習する DCNN を用いる場合、路面の特徴を学習するために必




図1: 車いすセンシングと機械学習による路面の特徴の自動評価システムの概要図

要な路面情報ラベルを GPS を元手軽に用意することで、より人手に依存しないシステムの構築を目指すことである。GPS による位置情報データを用いる研究には、日常・非日常エリアの推定や滞在・移動経路の予測する研究 [Liao 07] がある。本稿では、GPS による位置情報データを用いて、特定の路面を走行したかを判定し自動でラベルを付与する方法を提案し、その精度を評価する。

以降本稿では、2 章において関連研究を踏まえた提案手法の有用性について論じ、3 章で提案手法の検証に用いた加速度データと位置情報データ、DCNN モデルについて説明する。4 章で提案手法を定量的に評価するため、ほぼ正確な位置情報データを用いた分類と意図的に誤差を加えた位置情報データを用いた分類の精度をそれぞれ確認する。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. 車いす走行路面の特徴を抽出する DCNN のための GPS を用いた学習用データラベリング手法の検討

本章では、DCNN を採用する理由と、GPS を採用する理由について述べる。

連絡先: 高橋宏紀, 上智大学大学院 理工学研究科理工学専攻情報学領域, 東京都千代田区紀尾井町 7-1, 03-3238-3280, takahashi_hiroki@eagle.sophia.ac.jp

2.1 DCNN と人間行動認識

車いすセンサデータから交通弱者にとって有益な情報である路面状態（坂の有無、路面の種類、点字ブロックの有無、障害物の有無など）を反映した特徴量を機械学習によって抽出し、路面状態の機械による認識に利用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、人的・金銭的・時間的コストを劇的に低下させ、広大な地域のアクセシビリティ情報を蓄積・提供することができるようになる。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]。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対して、DCNN の有効性が検証されている [Yang 15]。例えば 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 の利用により路面状態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 GPS

筆者らはこれまで、路面の特徴の抽出を分類問題と考え、坂/縁石/点字ブロック/その他（「前記 3 つ以外のバリアおよびバリアなし路面」の意味で以降用いられる。）の 4 種類のラベルデータを付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きた [Iwasawa 12, Iwasawa 15, Iwasawa 16]。しかし、このような教師あり分類学習では、学習に用いるラベルデータの付与はマンパワーに依存したままである。

そこで本稿では、加速度データ取得の際に GPS を用いた位置情報データを獲得することに注目した。システム構築のためのデータ収集において、位置情報に紐付いた路面情報と、ユーザがどこを走行しているのかがわかれば、ユーザが走行することによって得られる加速度データに路面情報ラベルを自動で付与することができるようになると考えた。しかし、GPS から得られる位置情報データには誤差が含まれているため、そのまま利用すると分類精度が下がってしまう。以降本稿では、指定した範囲の中でランダムな値の誤差を含んでいる位置情報データを元に、2 種類の方法でそれぞれラベルデータの付与を行ったものを入力データとした DCNN の分類精度を比較・検証する。

3. DCNN モデルの作成

本章では、提案手法の有効性の検証に用いた車いすセンサデータの取得方法、ラベル付けをしたデータセットの作成方法、提案手法に用いた DCNN の構造および分類精度について順に説明する。

3.1 検証用データ取得方法とデータセット作成方法

検証に用いられた車いすセンサデータは、6 名の手動車いすユーザ、3 名の電動車いすユーザ、計 9 名の車いすユーザが東京都四ツ谷駅周辺の約 1.5km の経路を走行した際の行動を、車いすの座席下側に設置した加速度センサ (iPod touch) により 1 秒間に 50Hz でサンプリングされ x 軸、y 軸、z 軸の 3 軸の加速度値として計測されたものである。9 名の車いすユーザの走行を通して、合計 1,405,824 サンプル（約 9 時間）が得られた。経路全体の傾向として平坦な歩道が多く、建物等に設置された車いす用スロープの上り下りに問題のないユーザであれば、身体への過度な負担や事故の危険性は発生しにくいと考

えられる経路となっている。実験中は車いすユーザの走行している様子と走行路面の動画撮影も行われた。

x 軸、y 軸、z 軸の 3 軸の加速度値が計測された地点がどこなのかを実験動画を目視することによって確認し、位置情報データを付与した。このとき付与した位置情報データは、Google Map のウェブサイトを利用して得たものである。同様に、走行経路に含まれていた坂/縁石の位置情報もウェブサイトから獲得した。x 軸、y 軸、z 軸の 3 軸の加速度値が計測された地点がどのような路面状態であったのかを示すために、付与した位置情報データと坂および縁石の位置情報データを比較して、坂/縁石/その他、の 3 種類のラベルを付した。

本稿の DCNN では、x 軸、y 軸、z 軸の 3 軸の加速度データを入力するにあたり、ラベル付きデータ（以降、データと略記）を、ウィンドウ幅を 400 サンプル（約 8 秒）、重なり率を 0.5 としたスライディングウィンドウ方式により 7016 個切り出した。この幅と重なり率は、同じデータを用いた研究によって適した値を探索して決定された [Iwasawa 16]。これ以降、6 名の手動車いすユーザの走行によって得られたデータセットはそれぞれ M1~M6 (Manual Wheelchair)、3 名の電動車いすユーザの走行によって得られたデータセットはそれぞれ P1~P3 (Powered Wheelchair) と表記され、用いられる。

3.2 DCNN の学習方法




図 2: 本稿で利用した DCNN の構造

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、2~4. 畳み込み層 (Convolution+Max Pooling)、5. 全結合層、6. 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、データ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。学術的には、どこまで特徴抽出器でどこから分類器であるかが厳密には定義されておらず、解釈には自由度がある。本稿では単純化のため入力から全結合層までの部分を特徴抽出器と考え、全結合層から分類対象の One-Hot な表現への写像を分類器として議論をすすめる。

畳み込み処理部分では、代表的な研究 [Yang 15] にない、Convolution および Max Pooling の 2 つの処理を用いた。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。その他の設定として、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。

4. 分析結果と考察

4.1 GPS 路面分類タスクによる定量的評価

本章では、路面分類タスクを通して GPS を用いたラベル付与の方法が路面状態をどの程度認識できるのかを検証する。表

1 と表 2 は、意図的に誤差を加えた位置情報データを入力とした DCNN の坂/緑石/その他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 名分のデータセットで訓練したモデルを残りの 1 名分のデータセットで評価することを繰り返す方法であり、学習データ含まれ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。評価指標には各クラスのアverage F 値及び正解率 (Accuracy) を用いた。今回の分類問題はクラスインバランスであり、平均 F 値が高いことはデータセット中に出現する地点が少ないバリアについてもよく認識できていることを意味する。

ラベル付与は坂と緑石でそれぞれ異なるルールでラベル付けを行った。坂は一定区間継続しているものなので、坂の端と端の各 2 点ずつ取り、計 4 つの点で四角形を描くように位置情報を獲得した。ある地点に含まれる加速度データに紐付いている位置情報データの 1 つでも坂を表す四角形の内部に位置する場合、その地点に坂ラベルを付与した。それに対し緑石は、歩道と車道の境目であり線分として表せる。走行経路内に存在した緑石を表現できるように、1 つのまっすぐな緑石に対しては、緑石の端となる部分の位置情報データを余裕を持って獲得した。曲がっていてどのように緑石を通過したかわかりにくいようなところでは、位置情報データを多めに獲得し曲線を表現することとした。得られた位置情報データから作られる緑石を表す線分と、ある地点に含まれる加速度データに紐付いている位置情報データの 1 つ、時系列の連続した 2 つの点からなる線分が交差した場合、その地点に緑石ラベルを付与した。また、ラベル付与には各地点に含まれる複数の位置情報データを用いているが、その扱いによってラベル付与の仕組みが異なる 2 種類の方法で、それぞれ路面分類タスクを行う。扱いの詳細は次の通りである。

- **方法 1** : 緑石かどうかの判定は、1 つの地点 400 個の加速度データの内、それぞれ連続している 2 つの加速度データに付随している位置情報データを線分とし、線分で表している緑石の位置情報データと交差しているものが 1 組でもあれば緑石とした。坂かどうかの判定は、1 つの地点 400 個の加速度データの内、1 つでも坂と定義した四角形の内部に含まれる位置情報データを持つものがあれば坂とした。
- **方法 2** : 1 つの地点 400 個の位置情報データを前半と後半で 200 個ずつに分け、それぞれの平均値を算出した。緑石の判定はその 2 つの点を結んだ線分と線分で表している緑石の位置情報データと交差していれば緑石とした。坂かどうかの判定は、位置情報データの 2 つの平均値の内 1 つでも坂と定義した四角形の内部に含まれる値であれば坂とした。

表 1: 位置情報の誤差による DCNN の認識精度変動の比較、ラベル付与方法 1

誤差 (m)	13-10	8-5	4-1	0
平均 F 値	0.37	0.44	0.49	0.62
Accuracy	0.70	0.74	0.82	0.90

表 2: 位置情報の誤差による DCNN の認識精度変動の比較、ラベル付与方法 2

誤差 (m)	13-10	8-5	4-1	0
平均 F 値	0.42	0.44	0.53	0.53
Accuracy	0.87	0.88	0.88	0.89

結果として、表 1 と表 2 が示すように、方法 1 も方法 2 も誤差が大きいくほど F 値が落ちていくことから、ほとんど分類できなくなっていくのがわかる。しかし、方法 2 は方法 1 と比べるとその値は小さい。このことから、位置情報データを 1 つ 1 つ判定するよりも前半と後半でそれぞれ平均値を算出して判定する方が、誤差に対して強くなるという結果が得られた。

5. おわりに

本稿は、車いすセンサデータから走行路面の特徴を抽出する DCNN のために必要となる学習用の路面情報ラベルを、走行時に同時に取得された GPS データを用い、マンパワーに依存せず作成する方法を提案し、その評価を行った。その結果、誤差が少ない位置情報データほど、正確に路面情報ラベルを付与することがわかった。また得られた位置情報データに対して何らかの処理を行うことで、誤差の影響を減少させることも可能であることがわかった。

今後はより誤差の影響を少なくすることのできる路面情報ラベル付与の手法の検討を行う予定である。本稿では GPS の位置情報データのみを用いたが、スマートフォンやスマートウォッチなどの電子デバイスから、その他に加速度データやジャイロデータも取得することもできるので、これらを利用して位置情報の補正を行う方法について検討を進める予定である。また、本稿ではランダムに誤差を加えた位置情報データを使用して精度の検証を行ったが、実際には周りの建物の大きさや有無、衛星の位置などで誤差の偏りが起きているはずである。実際の利用シーンを想定して、誤差の偏りを踏まえた路面情報ラベル付与の方法を検討していく予定である。

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 29 年度、科学研究費基盤研究 B (17H01946) 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 12] Iwasawa, Y. and Yairi, I. E.: Life-logging of wheelchair driving on web maps for visualizing poten-

- tial accidents and incidents, in *PRICAI 2012: Trends in Artificial Intelligence*, pp. 157–169, Springer (2012)
- [Iwasawa 15] Iwasawa, Y., Nagamine, K., Matsuo, Y., and Eguchi Yairi, I.: Road Sensing: Personal Sensing and Machine Learning for Development of Large Scale Accessibility Map, in *Proceedings of the 17th International ACM SIGACCESS Conference on Computers & Accessibility*, pp. 335–336 ACM (2015)
- [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 Information 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)
- [Liao 07] Liao, L., Fox, D., and Kautz, H.: Extracting places and activities from gps traces using hierarchical conditional random fields, *The International Journal of Robotics Research*, Vol. 26, No. 1, pp. 119–134 (2007)
- [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. 1427–1434 IEEE (2014)
- [Nagamine 15] Nagamine, K., Iwasawa, Y., Matsuo, Y., and Yairi, I. E.: An Estimation of Wheelchair User’s Muscle Fatigue by Accelerometers on Smart Devices, in *Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers*, UbiComp/ISWC’15 Adjunct, pp. 57–60, New York, NY, USA (2015), ACM
- [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)
- [Swan 13] Swan, M.: The Quantified Self: Fundamental Disruption in Big Data Science and Biological Discovery, *Big Data*, Vol. 1, No. 2, pp. 85–99 (2013)
- [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 (IJCAI), Buenos Aires, Argentina*, pp. 25–31 (2015)