

車いすセンシングと機械学習による走行時異常行動検知

Detection of Unusual Wheelchair Driving Behavior by Machine Learning

矢野 耀次朗[†] 長峯 洸弥[†] 高橋 宏紀[‡] 岩澤 有佑^{††} 松尾 豊^{††} 矢入 郁子[‡]

Yojiro Yano Koya Nagamine Hiroki Takahashi Yusuke Iwasawa Yutaka Matsuo Ikuko Yairi

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。情報通信技術を用いた課題解決方法の1つに、歩道のアクセシビリティ情報を移動弱者に提供するための大規模な地理情報システムとしてのアクセシビリティマップを開発するという方法がある[1],[2]。アクセシビリティ情報を考慮した最適経路を推薦するパーソナライズドアクセシビリティマップ (PAM) の概念も提案されている[3]。アクセシビリティマップ開発には、歩道のアクセシビリティ情報をどのように大規模に収集するか、という課題がある。

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[4]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・金銭的成本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[5],[6]。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特徴を推定するシステムを提案・実装してきた[7]~[9]。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。

本稿では、路面情報抽出に用いた車いす走行時加速度データから、車いすユーザの疲労や転倒の予兆などの異常行動を抽出することを試みる。具体的には深層畳み込みニューラルネットワーク (以降 DCNN と表記) を用い、車いすセンサデータから DCNN が抽出した走行データの特徴量を AutoEncoder モデルの入力に使用し、得られた AutoEncoder モデル出力を再構築誤差の算出に利用する手法を提案する。AutoEncoder モデルは異常検知の分野において近年注目を浴びている手法である。

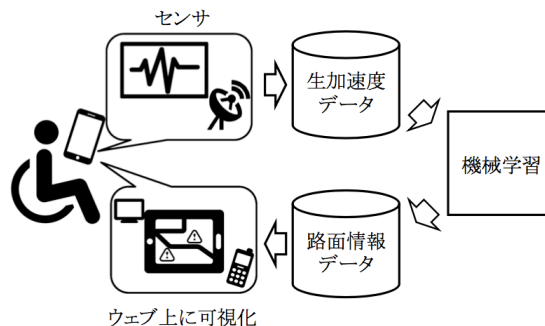


図1 車いすセンシングと DCNN による路面特徴自動評価システムの概要図

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および DCNN モデル、AutoEncoder モデル、再構築誤差について説明する。4章では、再構築誤差の検証。5章で結びとする。

2. 車いすセンシングと機械学習による走行時異常行動検知

筆者らはこれまで DCNN の出力層の1つ前の層である全結合層の反応ボタンが付したラベルよりも詳細な走行路面特徴を捉えていることを確認した[10]。本稿では、全結合層の反応ボタンを AutoEncoder モデルへの入力とし、出力との再構築誤差を算出することで、再構築誤差の大きいサンプルを危険な行動として抽出する手法を提案する。

車いす走行時の異常行動の抽出手法に AutoEncoder を用いた理由は、1章で前述したように異常データの検出方法として近年注目を浴びているからである。

具体的には、監視カメラによる人混みの異常値の検出に用いた例[10]、貨物の X 線画像の異常検出に用いた例[11]、宇宙実機の運用データの異常検出に用いた例[12]などがある。

AutoEncoder の入力に車いす走行時の生の加速度データではなく、それらを入力として得られた DCNN の全結合層の反応ボタン (以降、特徴量と呼ぶ) を用いた理由は、特徴量のほうが生データよりもユーザ行動や路面状態に関する重要な情報が抽出されていると考えられ、入力である特徴量と学習結果をもとに特徴量を再現しなおした出力との差は、軽微なユーザ行動や路面状態の違いを強調しうると期待できるからである。

[†] 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

[‡] 上智大学 理工学部 情報理工学科
Faculty of Science and Technology, Sophia University

^{††} 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

3. 走行時異常検知手法

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ーデータの取得方法、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、AutoEncoder の構造について述べる。

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ーデータは、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ー (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 1,255,900 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。

本稿の DCNN では、x, y, z の 3 軸の加速度データを入力するにあたり、ラベルを付す前のデータセットを、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切り出した。

x, y, z の 3 軸の 400 サンプルの加速度値が計測された地点がどのような路面の状況であったのかを実験動画を目視することによって、縁石/点字ブロック/坂/その他の 4 種類のラベルを付した。この 4 つを選択した理由は、ある程度のサンプル数 (最低 60 サンプル程度) が確保でき、また SVM を使った筆者らの研究との比較のためである [13]。

3.2 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 (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。学術的には、どこまでが特徴抽出器でどこからが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

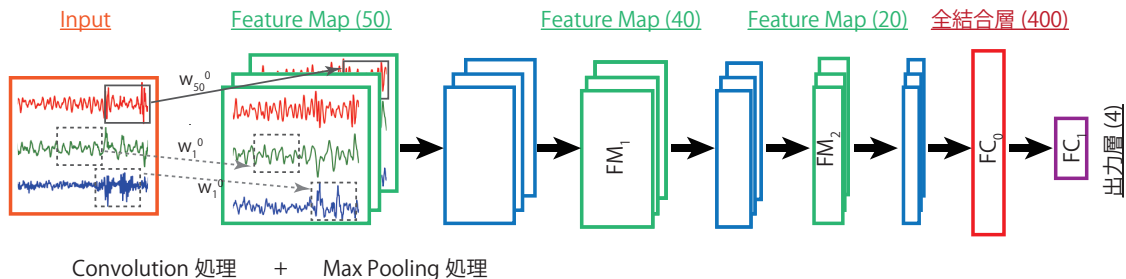


図 2 本稿で利用した DCNN の構造

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、関連研究 [14] にない、Convolution およびに Max Pooling の 2 つの処理を行った。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。

3.3 AutoEncoder の構造




図 3 本稿で利用した AutoEncoder の構造

図 3 に本稿で利用した AutoEncoder の構造を示す。本ネットワークは、

1. 入力層 (DCNN で得られた特徴量)
 2. 中間層
 3. 出力層
- の 3 層から構成される。

エポック数、バッチサイズ及び活性化関数はランダムサーチによって最適化を行なった。ニューラルネットワークの学習には Adam を利用した。その結果入力層と中間層の間の活性化関数は Relu 関数を出力層には softplus 関数を用

$$\text{再構築誤差} = \frac{1}{n} \sum_{i=1}^n |x_i - x'_i|^2 \quad (1)$$

いた。エポック数は 100、バッチサイズは 5 でモデルを構築した。

この AutoEncoder モデルによって出力された値と元々の入力値の値に関して以下のように再構築誤差をとる。再構築誤差は、入力値 x を、他の 8 人の特徴量によって事前に学習された AutoEncoder モデルの最終層まで順伝播させた値 (出力層の値) を x' とすると、下式で算出される。

AutoEncoder モデルの学習は少数の学習データのみ含まれる特徴が平滑化されて出力されるため、再構築誤差が大きいほど、特徴抽出の際に大きく平滑化処理が行われたことを意味する。よって再構築誤差が大きいということはその部分において何らかの異常現象が起きていると考えられる。

4. 機械学習による走行時異常行動検知

4.1 分析手順

AutoEncoder と再構築誤差を用いて分析を行った方法を 4 つの手順に分けて順に説明する。

Step1:全データの再構築誤差の算出

8 名のデータセットで訓練した DCNN モデルを作成し、残りの 1 名のデータセットをテストデータとして入力することを 9 名分繰り返すことで、データ毎の全結合層の 400 ユニット出力パターンを獲得した(以降この 400 ユニットの出力パターンを指す言葉として「特徴量」を用いる)。獲得した特徴量のうち 8 名分の特徴量で訓練した AutoEncoder モデルを作成し、残りの 1 名の特徴量をテストデータとして入力し、再構築データを算出した。その再構築データとテストデータを使用して再構築誤差を算出した。

Step2:地図上に可視化

再構築誤差のデータに含まれる個々のデータが得られた走行地点を地図上に色分けして可視化した。

Step3:各ユーザの再構築誤差の最大値を地図上に可視化

各ユーザの再構築誤差の中から最も再構築誤差の大きいもの、2 番目に再構築誤差の大きいもの、3 番目に再構築誤差の大きいものを取り上げ、一つの地図上に可視化した。

Step4:動画の目視による再構築誤差の分析

再構築誤差が得られた際の走行時撮影動画を目視することで、再構築誤差とそれに対応する路面状況の分析を行った。

4.2 結果と考察

地図上に可視化を行った結果は図 4 の通りである。図 4 における各点は青→緑→黄→赤の順番に再構築誤差が大きくなっている。再構築誤差が低い箇所(青色の箇所)は左上の箇所に固まっており、再構築誤差が高くなっている箇所(緑、黄、赤)は右側の通路に固まっていることが図から伺える。

各ユーザ 9 人の再構築誤差の大きさ上位 3 つの地点を地図上に赤い点としてプロットし可視化した結果は図 5 の通りである。図 5 から再構築誤差の大きい地点が図の右側地点、道路を渡る地点に固まっていることが伺える。

再構築誤差の高い地点と低い地点を動画データからキャプチャしたものをそれぞれ図 6、図 7 に示す。再構築誤差が得られた際の走行時撮影動画を目視した結果、再構築誤差が高い地点は段差や点字ブロック、マンホールといった障害物を走行車が乗り越えた時であり、再構築誤差が少ない地点においては障害物のない歩道を走行していることがわかった。ただし、段差や点字ブロック、マンホールといった障害物のある地点の全てが、再構築誤差が高い地点となった訳ではなく、これらの障害物のある地点を走行す

る際に、平常の走行とは違う異常が含まれてしまったケースのみが、再構築誤差が高くなったと考えることが妥当である。

これらの結果から、「異常」を「走行中に乗り越えなくては行けない障害物」であるとすると再構築誤差の値は異常を検知していると言える。AutoEncoder モデルを利用することで、再構築誤差として走行者の行動や路面の状態の微細な違いが把握でき、それを走行時の異常行動として検知可能になることがわかった。



図 4 手動車いすユーザー名の再構築誤差を地図上にマッピングした結果



図 5 各ユーザの大きさ上位 3 つの再構築誤差を地図上にマッピングした結果



図6 再構築誤差が大きい箇所



図7 再構築誤差が低い箇所

5. おわりに

AutoEncoder を利用することで横断歩道の段差、点字ブロック、マンホールといった障害物を乗り越える時を検知可能であることを示した。また、DCNN の全結合層の出力は、行動や路面の特徴が表現されているということがわかった。今後としてはよりわかりやすい異常行動パターンを検知するために異常行動パターンのデータを取ること、またデータを多くし、車いす走行者にとっての異常を正確に測れるように行い、新たな手法を開発する予定である。

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

- [1] M. Laakso, T. Sarjakoski, and L.T. Sarjakoski, "Improving accessibility information in pedestrian maps and databases," *Cartographica: The International Journal for Geographic Information and Geovisualization*, vol.46, no.2, pp.101–108, 2011.
- [2] H. Matthews, L. Beale, P. Picton, and D. Briggs, "Modelling access with gis in urban systems (magus): capturing the experiences of wheelchair users," *Area*, vol.35, no.1, pp.34–45, 2003.
- [3] H.A. Karimi, L. Zhang, and J.G. Benner, "Personalized accessibility map (pam): a novel assisted wayfinding approach for people with disabilities," *Annals of GIS*, vol.20, no.2, pp.99–108, 2014.
- [4] C. Ponsard and V. Snoeck, "Objective accessibility assessment of public infrastructures," *Computers Helping People with Special Needs*, pp.314–321, Springer, 2006.
- [5] M. Swan, "The quantified self: Fundamental disruption in big data science and biological discovery," *Big Data*, vol.1, no.2, pp.85–99, June 2013.
- [6] K. Nagamine, Y. Iwasawa, Y. Matsuo, and I.E. Yairi, "An estimation of wheelchair user's muscle fatigue by accelerometers on smart devices," *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*, pp.57–60, UbiComp/ISWC'15 Adjunct, ACM, New York, NY, USA, 2015.
- [7] Y. Iwasawa and I.E. Yairi, "Life-logging of wheelchair driving on web maps for visualizing potential accidents and incidents," *PRICAI 2012: Trends in Artificial Intelligence*, pp.157–169, Springer, 2012.
- [8] Y. Iwasawa, K. Nagamine, Y. Matsuo, and I. Eguchi Yairi, "Road sensing: Personal sensing and machine learning for development of large scale accessibility map," *Proceedings of the 17th International ACM SIGACCESS Conference on Computers & Accessibility*, pp.335–336, 2015.
- [9] Y. Iwasawa, I.E. Yairi, and Y. Matsuo, "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.
- [10] H. Takahashi, K. Nagamine, Y. Iwasawa, Y. Matsuo, and I.E. Yairi, "Classification and evaluation of features of road surface using wheelchair sensing and convolution neural network", *The 31st Annual Conference of the Japanese Society for Artificial Intelligence*, 2017.
- [11] M. Sabokrou, M. Fayyazb, M. Fathyc, Z. Moayed, and R. Kletted, "Deep-Anomaly: Fully Convolutional Neural Network for Fast Anomaly Detection in Crowded Scenes" *IEEE Transactions on Image Processing*, Volume: 26, 2017.
- [12] J. T. A. Andrews, E. J. Morton, and L. D. Griffin. Detecting anomalous data using auto-encoders. *International Journal of Machine Learning and Computing*, 6(1):21–26, 2016.
- [13] Mayu Sakurada and Takehisa Yairi. 2014. Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis (MLSDA'14)*, Ashfaqur Rahman, Jeremiah Deng, and Jiuyong Li (Eds.). ACM, New York, NY, USA, , Pages 4 , 8 pages. DOI
- [14] Y. Iwasawa, I.E. Yairi, and Y. Matsuo, "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.
- [15] J.B. Yang, M.N. Nguyen, P.P. San, X.L. Li, and S. Krishnaswamy, "Deep convolutional neural networks on multichannel time series for human activity recognition," *Proceedings of the 24th International Joint Conference on Artificial Intelligence (IJCAI)*, Buenos Aires, Argentina, pp.25–31, 2015.