

3 軸加速度時系列データからの車いす走行行動分析の研究

Life-Logging of Wheelchair Driving on Web Maps
for Visualizing Potential Accidents and Incidents

岩澤有祐

Yusuke Iwasawa

矢入郁子

Ikuko Eguchi Yairi

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 Technology, Sophia University

Purpose of this study is to digitize and visualize the potential accidents and incidents of wheelchairs from wheelchair life-log obtained by single, cheap, and mini-sized three-axis accelerometer. To visualize this information will help all wheelchair users to prevent accidents and to choose maneuverable routes on driving. This paper employs Support Vector Machine to estimate moving/static and tough/smooth surface for digitizing difficulty of wheelchair mobility, and shows the result of classification and of visualizing the result.

1. はじめに

近年、スマートフォン等のモバイル機器を用いたライフログが注目を浴びている。本稿は、小型で安価な 3 軸加速度センサによって取得した、データのばらつきなどを含む車いすライフログに関する研究報告である。3 軸加速度センサは近年の一般的なスマートフォンに搭載されており、その時系列データには様々な有益な人間行動が含まれている。本稿では 3 軸加速度センサの時系列データを複数の行動パターンに分類することによって、車いす移動時の危険性の推定を行う。蓄積した車いすライフログから移動の危険性を推定し、地図上で可視化することによって、車いす移動の可能性を広げる新たな支援へと発展させることが可能である。

本研究と同様に、人間行動を分類し危険な行動を抽出する研究事例としては[Mathie:2004]があるが、車いすライフログデータを利用して行動分類を目指した同様の研究事例はない。車いす移動の危険性を推定することを試みた先行研究としては[Coyle:2008], [Hashizume:2008], [Kuwahara:2010]などがある。しかし、[Coyle:2008]や[Hashizume:2008]は移動環境の改善に焦点を当てたものであり、移動困難性の可視化を目指したものではない。[Kuwahara:2010]では、本研究と同様にライフログデータから特徴抽出を行っているが、通行可能かどうかの評価に留まっており、本研究が目指す移動時の危険性可視化することによって、移動時の負担を低減する支援と異なっている。また本稿では、時系列データのクラス分類に SVM を用いる。Xing [Xing:2010]によれば、SVM は近年系列データの分類に関して効果的であることが示されており、機械学習の代表的な手法である[Li:2005][Ratsch:2005][Kampouraki:2008]。本稿では最適な分類方法を探すことには焦点を置かず、SVM を用いたクラス分類を通して、取得した車いすライフログをより詳細に分析し、データの特徴を明らかにすることを目的としている。以降 2 章では車いすライフログとそれを利用した移動支援の意義について、3 章では取得したデータおよびそのクラス分類方法について述べ、4 章で分類結果と Google Map への可視化結果を示す。最後に 5 章で結論と将来課題を示す。

2. 潜在的な事故およびに問題の可視化

典型的な車いす事故として、1)車道と歩道との縁石による転倒、2)坂道を走行中に、制御不能になり交通事故が発生、3)段差や表面の粗い路面を避けるために道路を走行し、交通事故が発生、といった事例が報告されている。これらの事故の背景には、段差やスロープなどの路面上の障害が存在している。またこのような重大な事故の背後に、“事故に至らなかったために報告されることのない軽微な出来事(以降「インシデント」と表記)”が路面上の障害によって、日々多数引き起こされている。このような重大事故やインシデントがどこで発生しているのかを記録・蓄積・情報発信するためには、現状では多くのマンパワーや路面を評価するための高度な知識が必要であるため、重要な情報と認識されながら整備されていないという問題がある。そのため、車いす利用者は日々の生活の中でどのような危険があるか分からない路面を走行し続けている。このような状況は、車いす利用者にとって身体的な障害となるだけでなく、移動に対する心理的負担も引き起こしている。

そこで本研究では、移動時の問題が発生しやすい場所を車いすログデータをもとに可視化し、経路に存在する潜在的なリスクを事前に確認できるようにする支援を提案する。先行研究として、我々は秋葉原電気街において7人の車いすユーザのライフログを取得し、振動レベル(VAL)という指標によって色分けし、地図上に可視化して評価した[Fukushima:2011]。しかし VAL は、走行時に車いす利用者が体感する振動の大きさを表すものであり、速度を緩めたり突然停止したりといった車いす利用者の行動に大きく影響されるため、十分に路面の障害を可視化することは出来なかった。そこで本稿では、路面状況を可視化するために機械学習の手法を用いた路面状況の推定を行う。推定のための車いす走行行動の分類を図1に示す。1 段階目の分類では、車いす走行行動を移動行動と静止行動に分類する。2 段階目の分類では、移動行動をバリアのある路面の走行とバリアの無い路面の走行で分類する。この 2 つの分類を通して、本稿は取得した車いす走行時の 3 軸加速度時系列データから、車いす移動時の問題を引き起こす大きな要因である路面上に存在するバリア推定の可能性について議論する。




図 1. 走行行動分類ツリー

3. ライフログからの車いす移動バリアの推定

3.1 車いす走行データ

本稿で用いた7名の車いす走行行動データは、車いす下部に設置した Sun SPOT の 3 軸加速度センサによって取得されたものである。実験では参加者が普段利用している車いすを用い、秋葉原電気街の歩道を自由に走行してもらい、2台のビデオでその様子を詳細に撮影した。ライフログの収集は1人あたりおよそ 20 分前後、走行経路には段差や点字ブロックなど多数のバリアが含まれていた。図1の分類に教師あり学習を用いるため、撮影された動画から路面状態に関する信頼性の高い教師データが作成できることが重要である。本稿では両方の車輪と路面状態の全てが記録されていた 30 代女性の電動車いす利用者1名分のデータ(以降、データとのみ表記)を用いた。

図 2 は用いるデータの 3 軸加速度センサのサンプリングレートのばらつきを示すヒストグラムで、横軸がサンプリング時間、縦軸がサンプル数である。Sun Spot の理論上のサンプリング周波数は 50Hz であったが実際に計測されたサンプリングレートは 50Hz 付近に固まらず、広い範囲にばらついていた。当然のことながら、センシングデータは出来るだけ精度が高いことが分類を行う上では望ましい。しかし、実際にスマートフォン等で取得できる 3 軸加速度センサデータが必ずしも高精度とは限らない。そこで本稿では、データのサンプリングレートにばらつきがあるデータであっても、どの程度の精度でどのような分類が行えるのかを調査する。




図 2. 実験で測定された 3 軸加速度センサデータのサンプリングレートのばらつき

3.2 教師データ作成方法

本稿では、時系列データ一定のフレーム数単位で複数のウィンドウに分割し、分割されたウィンドウごとのクラス分類を SVM によって行う。時系列データを分割してクラス分類を行う際には、分割されたウィンドウ幅が分類能力に大きく影響する。本稿では最適なウィンドウ幅を探索することを一つの目的とし、各ウィンドウにおいてどのような走行行動が行われていたかのラベルデータとして、データを分割するフレーム数を変化させたものを、2つのステップで作成した。ステップ 1 では、実験時に撮影した動画データを目を確認し、1 フレーム単位でどのようなイベントが発生したかを記録した。図 3 に例として、(a)凹凸の激しい路面の移動時、(b)舗装されたアスファルトの移動と判断した際の動画の 1 フレームをそれぞれ示す。また、静止状態としてはタイヤが

動いていない状態を抽出した。ステップ 2 では、5~120 フレームまで 1 フレームごとに、ウィンドウを作成する際の各ウィンドウにおけるラベルを、ステップ 1 で作成したイベントデータをもとに機械的に作成した。具体的には、人間行動の分類においては、ウィンドウ中の全てのフレームにおいて静止状態であった場合にあるウィンドウが静止中であると判定し、路面状況の分類においては粗い路面の走行イベントがあるウィンドウの半分以上を占める場合、あるいは粗い路面の走行イベントの半分以上があるウィンドウに含まれる場合に、ウィンドウを粗い路面の走行イベントと規定している。




図 3. 実験時に後方から撮影した動画のキャプチャ (a)粗い路面の走行 (b)平らな路面の走行

4. 推定および可視化の結果

4.1 人間行動の分類

車いすが移動しているか静止しているのかという人間行動を分類に関して、3 つの方法で分類を行った。1 つ目の手法では、最も基本的な分類としてウィンドウに含まれる生データを特徴量とした。2 つ目の手法では、時間幅のばらつきを小さくする前処理を加えた上で生データを特徴量とした。具体的には、時間幅が平均値 + 2 σ を超えた場合にはデータが連続していないと判断し、同じウィンドウに含まないという処理を加えた。3 つ目の手法では、統計量の特徴量として用いた。統計量の特徴量とすることで、時間的な波形の特徴は丸められるが、誤差に強い分類が可能になることが期待される。また、次元を圧縮することにも繋がるため、汎化能力の向上も期待できる。

図 4 は、各分類での F 値の比較結果をクラスごとに示している。横軸がフレーム数であり、縦軸が F 値を表している。フレーム数は実際には 5 フレームから 120 フレームまで 1 フレームおきに変化させてプロットさせているが、図 4 では表記の問題上 5 フレームおきの結果を示している。(a)が移動クラスの結果、(b)が静止クラスの結果である。なお、F 値は 10-交差検定を 100 回行った際の平均値を示している。この結果、どの分類度のフレーム数においても F 値が 0.978 以上と、非常に高い値となっていた。静止クラスに関しては、移動クラスにおける F 値の比べると値が小さくなっており、フレーム数が大きくなると大幅に低下する傾向がある。なお、グラフ上値が消えてしまっている箇所は静止クラスのデータ数が少なすぎて、再現率もしくは適合率が Not A Number となっていた箇所である。

結果を分類方法ごとに比較すると、移動状態、静止状態のどちらにおいても大きな差は見られなかったが、シンプルに前処理を行わずに生データで分類する手法が、分割するフレーム数を大きくした際の静止クラスの F 値の低下が最も遅くなっていた。この結果から、前処理や特徴量を統計量としても大きな効果が期待できないことが示唆されており、前処理を行わずに生データで分類を行えば良いと考えられる。




図 4. フレーム数を変化させた際の各分類手法における F 値の変化 (a)移動クラス (b)静止クラス

前処理を行った場合の結果に着目すると、特に静止クラスの結果に関して 25 フレーム付近までは増加傾向、25 フレームから 55 フレームまでが横ばい傾向、その後が減少傾向となっている。また移動クラスに関しては、25 フレームから 75 フレーム程度で最も値が高い傾向にあった。このことから、加速度データから移動状態と静止状態を分類するのに最適な 1 ウィンドウあたりのフレーム数は 25 フレーム(約 1.75sec)から 55 フレーム(約 3.85sec)であると考えられる。具体的な値として、フレーム数を 25, 35, 45, 55 とした際の全体の正解率および各クラスの再現率および適合率を表 1 に示す。

表 1. 前処理を用いない生データによる分類の具体的な分類精度 (25~55 フレーム)

the Number of Frames	Accuracy	Recall Ratio (Moving)	Recall Ratio (Static)	Precision Ratio (Moving)	Precision Ratio (Static)
25 frames	98.85%	99.30%	89.66%	99.49%	86.47%
35 frames	98.80%	98.98%	94.12%	99.76%	78.75%
45 frames	99.04%	99.31%	92.86%	99.70%	85.10%
55 frames	99.30%	99.27%	100%	100%	83.33%

4.2 路面状況の分類

移動時のバリアの有無の分類に関して、分類に用いる特徴量が異なる 3 つの手法で分類を行った。移動と静止の分類の際にも用いた生データ、統計量の特徴量とする場合に加えて、周波数成分を特徴量として用いている。周波数成分を用いることで、単純な生データでは分かりにくい周期性の抽出が可能となり、より詳細な分類が可能になることが期待される。

図 5 に、各分類での F 値をクラスごとに図 4 と同様に表示する。(a)がバリア有り路面移動クラス、(b)がバリア無し路面移動クラスの結果である。結果として、(a)(b)双方の結果で統計量による F 値が最も高い値となっている。また(a)の F 値はフレーム数が大きいほど増加し、(b)の F 値はフレーム数を大きくするほど低下する傾向にあった。この結果は、特徴空間上で 2 つのクラスを分割できない領域が存在していることを示唆している。統計量を用いた場合に最も(b)の F 値の低下が抑えられていることから、特徴量を統計量として分類するのが最も適切である結果となった。

図 6 に、統計量を用いた際の全体の分類正解率を示す。縦軸が正解率、横軸が 1 ウィンドウあたりのフレーム数であり、5 から 120 フレームまで 1 フレームおきに示す。値は 10-交差検定の 100 回平均値である。結果として、60 フレーム前後までが増加傾向であり、その後は横ばいとなっている。このことから、移動状態におけるバリアの有無の分類に関する最適ウィンドウ幅は、1 ウィンドウあたりのフレーム数を 60(4.2 秒)フレームより大きくした場合であると考えられる。具体的な値として統計量による分

類において 60 フレームとした場合には、バリア有り路面走行クラスの再現率が 89.2%、バリア無し路面の再現率が 67.9%となっており、全ウィンドウでは 82.1%の分類精度となっていた。

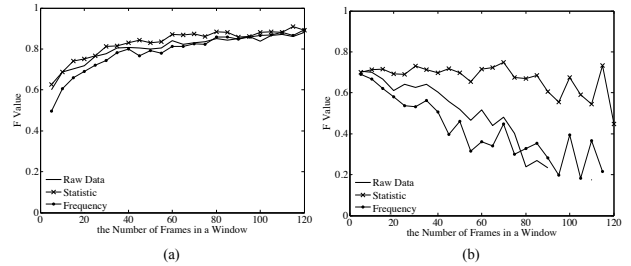


図 5. フレーム数を変化させた際の各分類手法における F 値の変化 (a)バリア有りクラス (b)バリア無しクラス

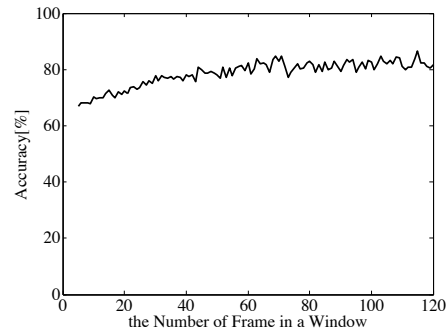


図 6. 統計量を用いた分類における各フレーム数における分類精度

4.3 Visualization

図 7 は、4.1 節および 4.2 節で行った分類結果を、走行した経路に可視化した結果を示している。4.2 節で行った路面状況の分類においてバリアがある路面を移動していると判定されたウィンドウを薄い色のマーカーで、バリアが無い路面を移動していると判定されたウィンドウを濃い色のマーカーで示している。なお、1 ウィンドウあたりのフレーム数は 60 フレームとし、可視化には Google Map を用いている。図中 A~D の各箇所での実際の走行経路と可視化結果を説明する。まず、目地の小さい路面や舗装された道を移動していた A や C における可視化結果は、可視化結果でバリアが無いことを示す濃い色のマーカーが多くなっている。また、凹凸の激しい路面を移動していた B や目地の粗い路面を走行していた D における可視化結果は、バリアが有ると路面を移動していることを意味する薄い色のマーカーが多い傾向となっている。

次に、今回の可視化手法と、先行研究で行った VAL を可視化した結果の比較する。図 8 は 2 つの可視化結果を比較したものである。どちらの可視化も同じ加速度センサデータを利用しており、図中矢印方向に移動している、図 8-(a)における可視化は図 7 におけるものと同様であり、図 8-(b)加速度値が大きくなるほど薄い色のマーカーがマッピングされている。また、図 8-(c)は地点 F の様子を示している。各地点は 2 つの段差に囲まれており、「段差乗り降り」→「平らな路面走行」→「段差乗り越え」という動作が必ず発生する。

段差を乗り越えていた箇所(図中各地点における左側の矢印)で 2 つの可視化結果を比較すると、どちらも薄い色のマーカーが多く存在しており、身体的なバリアの大きい路面であると判断することが出来る。一方で、車いすが段差を乗り越っていた

箇所(図中各地点における右側の矢印)では、2つの可視化結果は大きく異なっている。すなわち、加速度値から路面状態を推定して可視化した我々の今回の手法では、バリアのある路面を走行していると正しく判定できていたのに対して、VALの可視化結果では、振動値が小さくなっており、身体的な負荷が小さいと誤った判断を引き起こす結果となっている。段差乗り越え時に振動を避けるために速度を緩めるといった行動を利用者が行ったためであると考えられる。一方で今回の加速度値から走行行動を推定するという手法では、利用者の癖のようなノイズを除去することが出来ている。このように、今回の提案手法が路面に存在する潜在的な危険や問題をデジタル化して可視化し、車いす移動を支援する上で効果的であると言える。




図 7.SVM を用いた路面負荷推定結果の可視化

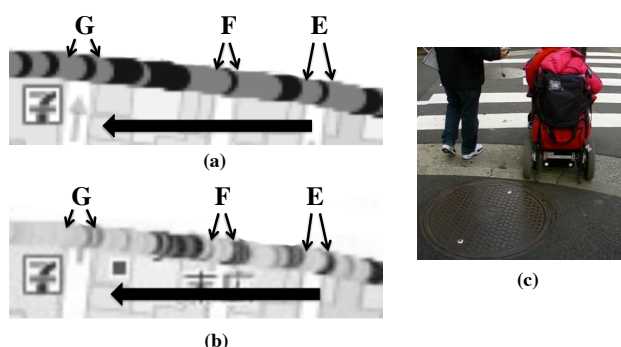


図 8.推定結果の可視化と VAL の可視化の比較 (a)推定結果の可視化 (b)VAL の可視化 (c)地点 F の様子

5. 結論・将来課題

本稿では、車いす下部に設置した 3 軸加速度センサによって取得した、サンプリングデータのばらつきなどを含む車いす移動時ライフログデータから、SVM を用いて加速度データの分類を行った。その結果、移動しているか静止しているかという人間行動レベルの分類では生データを 30 フレーム単位で分割した際に 98.2%の分類精度を、また路面状況レベルの分類では統計量を特徴量として使い、フレーム数を 60 フレームとした場合

に 82.1%の分類精度となった。そして分類結果を地図にプロットすることによって、路面状況の特徴を可視化可能であることを示した。今後の課題には、(1)様々な属性を持つ大量の被験者のライフログデータを分析すること。(2)分類精度の向上および、より詳細な分類を行うために准天頂衛星の高精度の位置情報を利用すること、(3)汎用的な手法である SVM でなく、車いす走行時ライフログデータの分析に適したアルゴリズムを考案することがある。これらの課題をクリアにすることで、路面に存在する潜在的な危険を可視化可能な車いす移動支援システムの実現を目指したい。

謝辞

実験に参加くださった皆様、矢入研究室の福島裕介博士、鈴木秀孝氏、三橋遼太郎氏、ならびに実験に協力して下さった皆様に深く感謝を示させていただきます。

参考文献

- [Coyle:2008] Eric Coyle, et al.: Vibration-based terrain classification for electric powered wheelchairs, Telehealth/AT, 2008, 978-0-88986-740-6
- [Hashizume:2008] Hashizume, T, et al. : Study on the wheelchair user's body vibration and wheelchair driving torque when wheelchair is ascending/descending the boundary curb between pavement and roadway, SICE Annual Conference, 2008, 1273-1276
- [Mathie:2004] M.J.Mathie, et al. ; Classification of basic daily movements using a triaxial accelerometer, Med.BioI.Eng.Comput, 2004, 42, 679 – 687
- [Mathie:2003] M.J.Mathie, et al. ;Detection of daily physical activities using a triaxial accelerometer, Med.BioI.Eng.Comput, 2003, 41, 296 – 301
- [Kuwahara:2010] Noriaki, Kuwahara, et al.. ; A study on ubiquitous system for collecting barrier-free information for wheelchair users, CASAME, 2010, 978-1-4503-0213-5
- [Xing:2010] Zhenzheng Xing, Jian Pei, and Eamonn Keogh, A Brief Survey on Sequence Classification, SIGKDD Explorations, 2010, Volume 12, Issue 1, pages 40-48
- [Li:2005] M. Li and R. Sleep, A robust approach to sequence classification, In ICTAI '05, Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence, pages 197-201, 2005
- [Ratsch:2005] G. Ratsch, and C. Schafer, Learning interpretable SVMs for biological sequence classification, In RECOMB '05: The Ninth Annual International Conference on Research in Computational Molecular Biology, pages 389-407, 2005
- [Kampouraki:2008] Kampouraki A, Manis G, and Nikou C, Heartbeat Time Series Classification With Support Vector Machines, Information Technology in Biomedicine, IEEE Transactions on, Volume 13, Issue 4, pages 512-518, 2008
- [Fukushima:2011] Yusuke, Fukushima, et al., Sensing human movement of mobility and visually impaired people, ASSETS, 2011, 279 -280