

車いす走行ライフログの時空間解析による路面状況推定システム Spatiotemporal Life-Log Mining of Wheelchair Driving for Visualizing Accessibility of Roads

岩澤有祐

Yusuke Iwasawa

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

矢入郁子

Ikuko Eguchi Yairi

This paper introduces a novel system for computational estimation and geo mapping of potential accidents and incidents from wheelchair users' life-logs with three-axis accelerometers mounted on smart devices. Three wheelchair users participated in outdoor experiments and all their actions were measured. In total, four iPods attached on left and right wheels, seats, and user's body recorded approximately 1,800,000 signals during 10,000 seconds. The life-logs were classified into moving/resting state and rough/flat state of the ground surface with finding optimal window size and optimizing feature vectors by SVM. As the result of classifications, estimation of moving/resting was achieved 99.8% accuracy rate and estimation of rough/flat surface was achieved 88.3% accuracy rate. Estimation results were also visualized on Google Map, and were evaluated by comparing with actual states of roads about wheelchair driving difficulty.

1. はじめに

近年ライフログの活用が、巨大なコンピュータやデバイスだけのものに留まらなくなっている。スマートフォンの普及に伴い、ライフログはより一般的になり、ビッグデータ分析や、ユーザ向けシステムなど、様々なシステムを発展させるためになくはならない要素となっている。我々は、重度歩行困難者向けのライフログ収集と解析による支援システムの開発を行ってきた。[Fukushima *et al.*, 2011][Iwasawa and Yairi, 2012]

本稿では、加速度センサを用いた車いす移動支援のための路面危険性推定システムを提案、およびにシステム構築のための時空間両面からの車いすライフログ解析結果について述べる。SVM によって行動分類を行い、ウィンドウ幅と分類精度の関係を調査する。ライフログは安価で小型な加速度センサによって実環境で取得した様々なノイズを含んだデータである。ノイズを含むデータからの知識獲得には、データの特性に合致したアルゴリズムが必要だが、本稿ではアルゴリズムに SVM を利用し、最適なアルゴリズムについては言及しない。本稿の目的は、データセットの特性を SVM による解析を通して明らかにする事である。また、時系列データ分類による評価のみでなく、行動推定結果と実際の走行経路およびに被験者が行った特異な行動を地図上にマッピングして比較し、評価する。空間的な評価によって、我々のシステムの有用性や適応範囲を調査する。2 章ではシステムの全体像について先行研究、関連研究をレビューして再度まとめる。3 章は解析した車いす走行ライフログについて取得方法や量的な観点から示す。4 章で時空間両面から本システムの評価を行い、5 章で本稿の結論、将来課題とする。

2. システム全体像およびに関連研究

2.1 概要

車いす事故の典型的な事例として、次のようなものがあげられる。1) 車歩間の縁石で転倒、2) 坂で車いすをコントロールできずに衝突、3) 路面の凸凹を避けるために車道を走り追突される。このように、車いす事故は路面要因によって引き起こされている事例が多い。また、このような重大事故の背景では数えきれないほどの精神的な負担感やインシデントが発生している。しかし、

事故やインシデント発生場所は、可視化に大量のマッピングや路面評価に関する特殊なスキルが必要となり存在しない。そのため車いす利用者は未知の危険の中で身体的、精神的にストレスを感じる移動を強いられている。ストレス低減のために、過去の事故やインシデントを記録し、事故の可能性を可視化することが重要である。可視化によって利用者はより安全なルートを選んだり、事故に備えたりすることが可能となる。

提案システムでは事故可能性評価のために、事故の発生や走行時の不快感など推定し事故の可能性が高い箇所を抽出する。本システムは大別して次の 3 つの機能を持つ。1) ウェアラブルセンサを利用した車いす利用者の行動の記録、2) 取得したライフログによる行動認識、3) 認識行動を利用した路面危険性の評価及びに可視化。それぞれの機能の詳細について、関連研究について言及しながら 2.2~2.4 にて述べる。

2.2 路面アクセシビリティ情報の可視化

[Collins and Coyle, 2008]や[Yoon, 2009]はロボットに搭載したセンサやカメラによる路面評価システムを提案している。これらの研究は路面状況を推定する事を目的にしており、われわれの目指す車いす利用者にとっての危険性の抽出とは異なっている。[Miura *et al.*, 2012] は、バリアフリー情報に関する情報収集プラットフォームを提案し、車いす利用者にとっての深い箇所抽出を目指している。しかし、一般の人々にとってはどのような状況が障害物であるかを判断するのは困難であり、収集できる情報量に限りがある。また、人によって悪路の基準は異なり、収集した情報から路面状況を評価するのは困難である。我々が行った先行研究 [Fukushima *et al.*, 2011] では、車いすに設置したセンサの振動値を可視化して路面状況の評価を行っている。しかし、振動値はゆっくり走行した場合には小さくなるなど路面状況以外の要因によって大きく影響をうけ、路面危険性可視化に十分ではなかった。本システムは、ライフログから行動認識を行い、転倒しかけ、ふらつきといったアクシデントやインシデントを示唆する行動を抽出する。抽出したアクシデントやインシデントと位置情報とのマッピングによって事故頻発箇所を推定する。本稿では、ライフログデータから点字ブロック上の走行、段差上り行動、段差下り行動を抽出し、地図上に可視化して路面状況を評価する。

連絡先: 岩澤有祐, 上智大学大学院理工学研究科理工学専攻情報学領域, 102-8554, 東京都千代田区紀尾井町 7-1, yuusuke.0519@sophia.ac.jp

2.3 人間行動センシング

人間行動認識はヘルスケアなどさまざまな領域のアプリケーションで注目を集めている技術である。人間行動認識の手法には大別して、動画ベース行動認識 (VSAR)、ウェアラブルセンサベース行動認識 (WSAR)、オブジェクト利用行動認識 (OUAR) の3種類がある [Guan *et al.*, 2011] が、本稿では、日常生活に根ざしやすい WSAR を採用する。 [Long, 2009] によれば、加速度センサやジャイロセンサ、磁気センサなどの inertial sensor が広く用いられており、有効とされている。特に、加速度センサは [Chua *et al.*, 2010; Moghadam *et al.*, 2011; Coulter *et al.*, 2011] など幅広い領域で用いられている。本研究でもこれらの研究を踏襲して加速度センサによる行動認識を行う。

加速度センサを車いすに設置して、調査をおこなった事例としては [Chua *et al.*, 2010] の事例がある。この研究では調査結果をもとに路面状況を評価するための数学的なモデリングを行うことを目的としており、危険行動認識を目指す我々の研究とは目的が異なっている。 [Moghadam *et al.*, 2011] や [Coulter *et al.*, 2011] は、加速度データを用いた行動認識を行っているものの、実験環境が研究室に限定されている。本稿では、車いす利用者の外部環境での行動をセンシングし、解析する。

2.4 時系列データ分類

Figure 1 は本稿で用いた基本的な時系列データ分類手法を示している。分類器としては、もっとも有名な機械学習の手法の1つである SVM を用いた。 [Xing *et al.*, 2010] が報告している通り、SVM は時系列データ分類において有効な手法であり、さまざまな研究分野で利用されている [Kampouraki *et al.*, 2009; Kim, 2003; Kim *et al.*, 2009]。時系列データ全体を一定の時間幅で各ウィンドウが重ならないように分割し、各ウィンドウをラベリングした。今回は独立した4つのセンサによって取得したセンサデータを利用するため、サンプル数で時系列データを分割すると各センサの時間のずれが大きくなってしまい、適切に行動を表現できないことがある。そのため、時系列データを実時間によって分割した。各ウィンドウの加速度シグナルを前処理によって特徴ベクトルによって変換し分類を行う。本稿では、4つの前処理によって特徴ベクトルへと変換した。具体的な特徴ベクトルについては4.1で述べる。

ラベルデータは、実験時に後方から作成したビデオデータを肉眼で確認して作成した。ビデオのサンプリングレートは30Hzである。本稿では、静止、段差のぼり、段差下り、および点字ブロック上の走行の4種類の行動を調べ、各行動の開始時間と終了時間をフレーム単位で記録した。より詳細には、車いすの全てのタイヤが静止している際に静止している、少なくとも1つ以上のタイヤが縁石上か点字ブロック上にある場合に段差乗り

越え、段差乗り降り、点字ブロック上の走行動作にあると判断した。各ウィンドウがある行動としてラベリングされるかどうかは、あるウィンドウとある行動の重なった時間によって判断した。すなわち、ウィンドウ W_i と行動 A_i がある閾値よりも長い時間とられている場合には W_i を A_i とラベリングし、どの行動においても上記の条件を満たさない場合に通常走行であるとラベリングした。

3. データセット

本稿では、3名の車いす利用者が参加した実験時に取得した走行ライフログ (D1~D3) を用いて行動分類と地図上への可視化を行う。実験では、車いすの両輪、椅子の下、およびに被験者のポケットに iPod touch を設置し、上智大学周辺の1周約1.5kmの経路を1人3周ずつ走行した。車いすは統一せず、各被験者が普段利用している車いすで実験を行った。実験時には2名の協力者が並走し、走行行動をビデオおよびにテキスト媒体で記録した。各センサのサンプリング周波数は50Hzにセットされており、1人あたり50分ほどの走行データである。サンプル数は3人合計で1,817,230サンプルであった。加速度データ全サンプルに、実験時に撮影した動画データを観察して1) 静止、2) 段差上り、3) 段差下り、4) 点字ブロック上の走行、5) その他の5つの行動データにラベリングしてある。

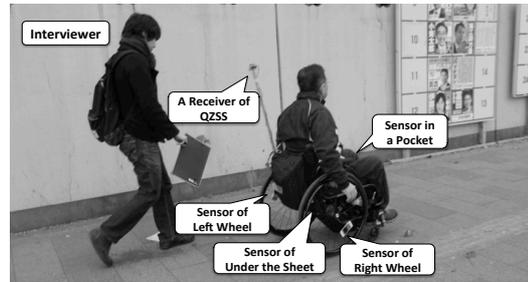


Figure 2: A snapshot of an experiment

4. 評価

4.1 時系列データ分類の評価

本節では、静止/移動 (分類1) と、粗い路面/平らな路面の走行 (分類2) の2つの分類結果について述べる。本稿では、点字ブロックおよびに縁石を粗い路面とする。図3、図4はウィンドウ幅と2つの分類に関するF値の関係を、4つのデータセット (D1~D4) について示したグラフである。D4は先行研究で Sun SPOT を用いて取得したデータであり、比較対象として利用する。ウィンドウ幅は、0.5秒から10秒まで変化させた。各グラフは次の4つの異なる特徴量 (f1~f4) での分類精度を比較している。f1: 車いす下部センサの3軸加速度平均値の系列データ、f2: 車いす下部センサの3軸標準偏差の系列データ (3次元)、f3: 全てのセンサの3軸標準偏差の系列データ (12次元)、f4: 車いす下部に設置したセンサの、周波数成分。なおD4では椅子の下のセンサのみで計測したデータであるため、f3は車いす下部センサが取得した値が他の3つのセンサでも取得されたときのみ計算した。サブウィンドウ幅は、基礎分析の結果から各分類に対して1.0と0.1として定めた。また、全てのグラフでNaNは0に置き換えた。

Figure 3は次の4つの点を示している1) 標準偏差は静止/移動の分類に適している。2) 複数センサの利用によって、特にウィンドウ幅が大きい場合にF値を改善できる。3) 新しいデータセットは、Sun SPOT で記録したデータと異なる性質を有しており、高いF値を達成できる。4) 静止/移動の分類では、ウィンドウ幅

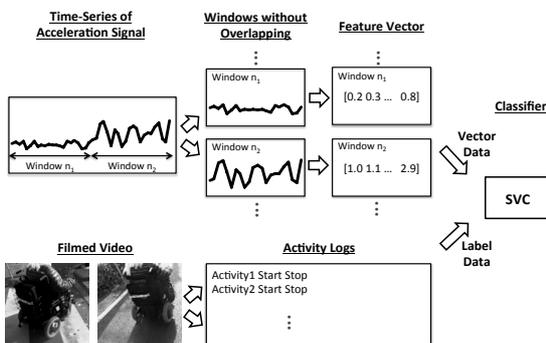


Figure 1: Basic method of time-series classification with SVM

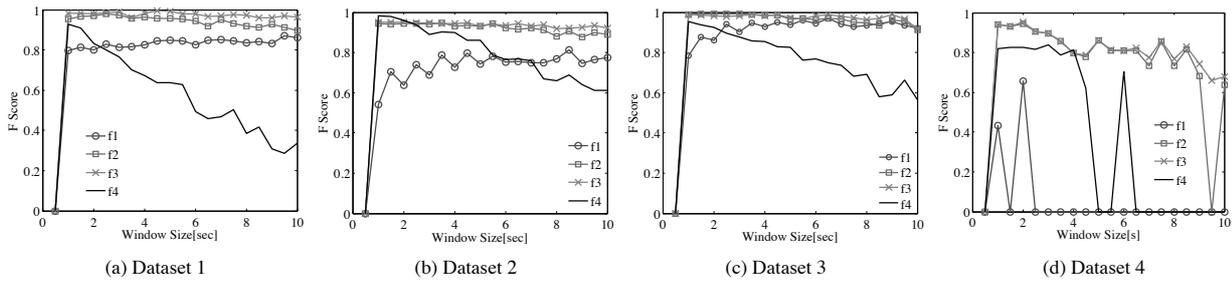


Figure 3: Relationships between F-score of static class and window size, feature vector, and datasets.

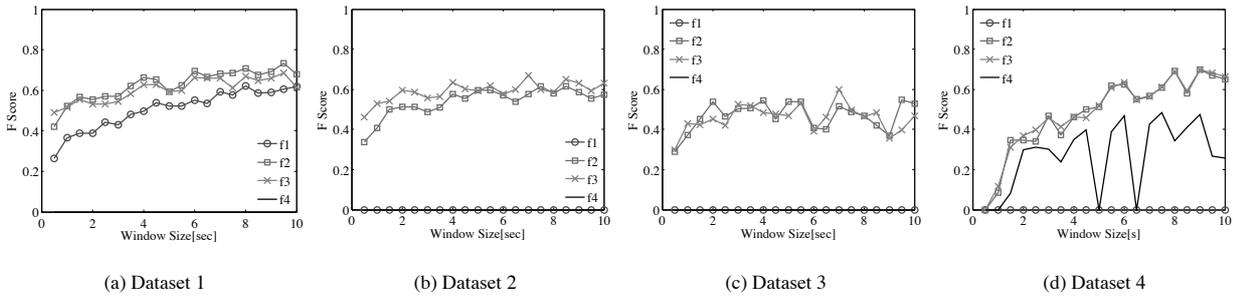


Figure 4: Relationships between F-score of rough class and window size, feature vector, and datasets.

は分類精度にほとんど影響を及ぼさない. 具体的な値は D1, f3 を用いてウィンドウ幅を 4.5 秒とした場合に次の通りであった. 分類精度:99.9%, 移動再現率:99.9%, 静止再現率:99.8%, 移動適合率:99.9%, 静止適合率:99.2%.

Figure 4 は, 粗い/平らに関する分類の結果を示している. 結果として, f2 や f3 を利用した場合に F 値が比較的高く, 一方で f1 や f4 のスコアはゼロに近い値となっている. ウィンドウ幅については, 電動車いす利用者の行動データを記録した D1 と D4 では, ウィンドウ幅が大きいくほど高いスコアを記録していた. D1 と D4 の分類で適合率はどのウィンドウ幅でも 80%および 70%ほどで変わらず, 再現率はウィンドウ幅が大きくなるに従って 65%程度まで増加していた. 一方で, 手動車いすユーザの行動を記録した D2, D3 の分類では, F 値は 3.0 秒ほどでピークとなり, それ以降はほとんど増加していない. 具体的には, 適合率に関しては電動車いす利用者の場合と同様に 70%~80% の精度で推移しているのに対して, 再現率は 3.5 秒~4.0 秒ほどでピークとなっており, 30%から 40%程度に留まっていた.

これらの結果から次の 3 つの事が推察される. まず第 1 に特徴量に関しては, 分類 1 の場合と同様に, 標準偏差が粗い/平らの分類にとっても適しているといえる. 一方で, 特徴量が高次元となる平均値列 (f1) や周波数成分 (f4) では適切な学習が出来ていない. ウィンドウ幅を 2.0 秒とした場合, D1 のサンプル数は全体で 1585 サンプルであり, うち粗い路面クラスのサンプル数は 119 サンプルであり, 2つのクラス間でサンプル数の不均衡が生じている. SVM を含む既存の手法は, 特に高次元特徴量による分類の場合にサンプル数が不均質なデータに対して適切な分類を行えない可能性がある事が知られており[Garcia, 2009], 今回のデータにおいても高次元特徴量とサンプル数の不均衡によって分類精度が低下していることが推察される. 粗い/平らの分類に関しては標準偏差を用いることによって最高で 90%近い分類精度を達成出来たもの, より複雑な分類や精度の高い分類のために, 小さな特徴ベクトルでありながら十分な情報量を持つ特徴ベクトルの探索, および SMOTE[Chawala et al., 2002]やダウンサンプリングなどのインバランス学習に対応する手法の適応を検討する必要がある.

2 番目に, 利用者の属性によって F 値とウィンドウ幅の関係が大きく異なることがあげられる. 今回の結果では, 車いすの種

類によって粗い路面クラスの再現率が大きく異なっていた. 手動車いすでは, 段差の大きさなどの状況に応じて前輪をあげて衝撃を和らげることもあり, この行動を行ったかどうかによって加速度パターンが大きく変化すると予想される. このように, 手動車いすに関しては, 電動車いすと比較して行動のバリエーションが多く, より複雑な分類モデルが必要となる可能性がある.

最後に, 電動車いすに関してはより大きなウィンドウ幅が, 手動車いすでは 4.0 秒付近が最適なウィンドウ幅であった. D1, f2 を用いてウィンドウ幅を 9.5 秒とした場合の具体的な精度は次の通りである. 分類精度:88.3%, 粗い再現率:66.6%, 平ら再現率:95.1%, 粗い適合率:81.4%, 平ら適合率: 90.1%.

4.2 空間マッピングの評価

Figure 5 は, 分類精度の高かった D1 について, 各周での実際の路面環境と推定結果を可視化して比較している. 上側のグラフが実際の走行環境を, 下側の図が推定結果を示している. 各グラフ中において, 1) 濃い色の直線:粗い路面, 2) 薄い色の直線:平らな路面, 3) 中抜き円:本来粗い箇所であるが推定できなかった箇所, 4) 中抜き四角:本来平らであるが粗いと推定された箇所, をそれぞれ意味している. すなわち, 濃い色で表現された中抜き図形で囲われていない箇所は, 点字ブロックまたは車歩間の縁石が正しく推定されていたことを示している. なお, マッピングの際の位置情報としては準天頂衛星で取得したデータを手動で補正した位置情報を利用した. 3 周合計で 75 カ所の点字ブロックまたは車歩間の縁石があり, 39 カ所が点字ブロックと縁石がどちらも含まれる箇所, 30 カ所が点字ブロックのみ, 6 カ所が車歩間の縁石のみの箇所であった.

結果として, 59/75 (約 79%) で正しく粗い路面であると推定されていた. 誤推定が生じた 15/16 は点字ブロックであり, 残りの 1 カ所は点字ブロックと縁石が近接している箇所であった. 誤推定された場所に物理的な特徴は見られなかったものの, 次のような行動がとられていた. 1) 片輪のみが点字ブロック上を走行していた. 2) 速度を緩めて点字ブロック上を走行していた. 3) 段差を降りた直後に人との衝突を避けるために速度を緩めた(2 周目左上角). このように, 被験者のイレギュラーな行動により誤った推定となっている. このようなイレギュラーな行動は, そのカ所

で被験者が危険や不快感や危険を感じていることを示唆している可能性があり、注意が必要である。

逆に、2 周目の 2 カ所と 3 周目の 1 カ所で粗いと誤推定された場所があった。2 周目の左上角に着目すると、この場所はおおむね平らであるが、誤推定が生じた 2 周目ではマンホールが大きな体の揺れを引き起こしていた。他の 2 周では正しく平らと推定されており、大量のデータを比較する事によってマンホールのような視認しにくい段差の推定が出来る可能性がある。さらなるシステム発展のために、推定結果のばらつきが大きいカ所を抽出するなど大量データによる経路評価アルゴリズムの検討を通して、前述したようなイレギュラーな行動や見えにくい段差のような路面要因を抽出する必要がある。

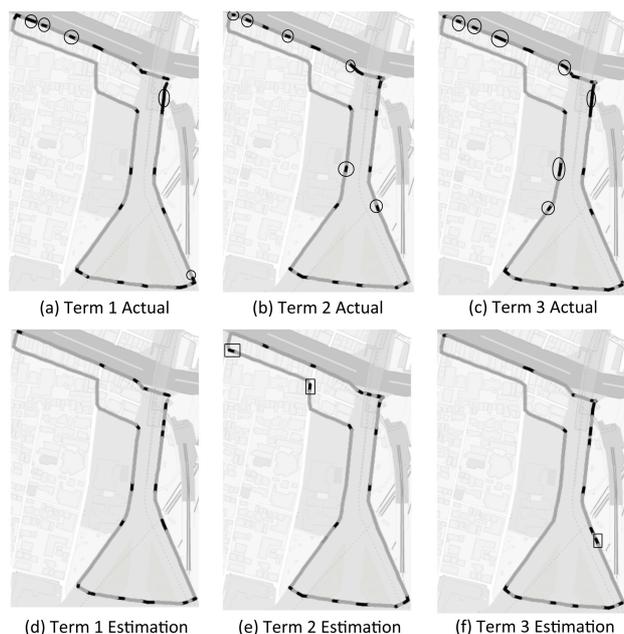


Figure 5: Comparison between actual status of ground surfaces and estimated status. Top three illustrations shows actual status of ground surfaces, and bottom three shows estimated status.

5. 結論・将来課題

本稿では車いすユーザのより安全な移動を可能にするシステムとして、車いす走行ライフログから転倒や衝突などの危険行動や、不快感を表す行動を抽出し事故の可能性可視化を行うシステムを提案し、加速度データとして取得した走行ライフログの時空間解析を行った。具体的には、1) 20 種類のウィンドウ幅、4 つの特徴量、4 つのデータセットについて移動/静止行動、段差・点字ブロックの有無を分類し F 値により評価、2) 推定結果を地図上にマッピング、実際の走行状況との比較により評価を行った。結果、特徴量としては標準偏差が適切であり、最適ウィンドウ幅(それぞれ 4.5 秒と 9.0 秒)において、移動/静止を 99.8%、段差・点字ブロックの有無を 89.6%の精度で達成した。また、点字ブロックに関しては 24/39、縁石に関しては 35/36 を正しく推定できていた。誤推定が発生した場所では、マンホールによって大きな衝撃を受けていたり、衝突を避けるために減速したりといった、イレギュラーな行動が発生していた。大量のデータを処理する事によって、これらのインシデント情報の抽出が期待される。最後に将来課題を 3 つあげて、本稿の結びとする。

1. データの特性に合ったアルゴリズムの開発・適応

解析の結果、サンプル数の不均衡が不適切な学習を引き起こしている可能性が示唆された。初期評価として、今回のデータ

セットに SMOTE を適応した結果、特に粗い路面の再現率に関して良好な結果が得られている。

2. より複雑な行動分類ツリーの構築

より詳細な分類を行うために、方向転換、スロープ上の走行、あるいは転倒などの行動を分類するためのモデル作成、分類ルールの策定が必要である

3. 大量データの評価による路面評価および知識獲得

大量データによる路面評価にむけ、同環境で新たに 8 名分の走行データを取得している。また、より身体的負担感の高い道を含む経路の走行実験も同様に行いデータを収集している。これらの大量のデータを用いた路面評価アルゴリズムを開発することによって、インシデント行動やさまざまな特異点などの高いリスクを持った箇所を推定・発見する事を目指している。

謝辞

実験に参加して下さった全ての皆様に感謝します。本研究は立石財団の助成のもと行われました。

参考文献

- [Chawla et al., 2002] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer. SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, Vol. 16, pages 321-357, 2002
- [Fukushima et al., 2011] Robert Baumgartner, Georg Gottlob, and Sergio Flesca. Sensing Human Movement of Mobility and Visually Impaired People. In *Proceedings of the 13th International ACM SIGACCESS Conference on Computers and Accessibility*, pages 279-280, 2011
- [Garcia, 2009] E.Garcia. Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering*, vol. 21, pages 1263-1284, 2009
- [Guan et al., 2011] D. Guan, et al. Review of Sensor-based Activity Recognition Systems. *IETE Technical Review*, vol. 28, pages 418-433, 2011
- [Iwasawa and Yairi, 2012] 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*, pages 157-169, 2012
- [Kampouraki et.al, 2009] Kampouraki A., Manis G., Nikou C. Heartbeat Time Series Classification With Support Vector Machines. *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, pages 512-518, 2009
- [Kim, 2003] Kyoung-jae Kim. Financial time series forecasting using support vector machines, *Neurocomputing*, vol. 55, pages 307-319, 2003
- [Kim et.al, 2009] S.K.Kim, et al. SVM-based feature extraction for face recognition. *Pattern Recognition*, vol. 43, pages 2871-2881, 2010
- [Miura et al., 2012] T. Miura, et al. Barrier-free walk: A social sharing platform of barrier-free information for sensory/physically-impaired and aged people. In *Proceedings of IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 2927-2932, 2012
- [Xing et.al, 2010] Z.Xing, J.Pei, and E.Keogh. A brief survey on sequence classification. *ACM SIGKDD Explorations Newsletter*, vol. 12, pages 40-48, 2010