

機械学習による走行プローブデータからの異常走行箇所発見

川谷, 卓哉

廣川, 佐千男
九州大学情報基盤研究開発センター

峯, 恒憲
九州大学大学院システム情報科学研究院

伊東, 栄典
九州大学情報基盤研究開発センター

<https://hdl.handle.net/2324/2244134>

出版情報：情報処理学会研究報告．ITS，高度交通システム．7，pp.1-6，2019-02-28．Information Processing Society of Japan

バージョン：

権利関係：利用は著作権の範囲内に限られる

機械学習による走行プローブデータからの異常走行箇所発見

川谷 卓哉^{1,a)} 廣川 佐千男^{2,b)} 峯 恒憲³ 伊東 栄典²

概要: 自動車の走行状況や道路状況などを知るため、スマートフォンセンサーをはじめ、GPS を利用した Automatic Vehicle Location (AVL) など、様々な装置を利用し、プローブデータ（自動車の走行データ）の獲得が行われて、機械学習手法を利用した走行挙動の分析が行われてきている。本研究では、機械学習手法と特徴選択手法を組み合わせた、通常とは異なる走行挙動（異常走行挙動）の識別手法を提案する。具体的には会津若松市オープンデータ活用実証事業により提供されている公用車・公共交通車両走行情報履歴データに SVM (Support Vector Machine) と特徴選出の手法を用いた異常走行挙動の識別手法を提案する。本手法を適用した際の、異常走行挙動の識別結果と識別精度、識別に寄与した特徴についても考察する。

キーワード: 走行プローブデータ, 機械学習, SVM:Support Vector Machine, 属性選択, 特徴分析

Unusual driving spots discovery from driving probe data using machine learning

TAKUYA KAWATANI^{1,a)} SACHIO HIROKAWA^{2,b)} TSUNENORI MINE³ EISUKE ITO²

Abstract: Driving probe data are captured to analyze driving behavior of a car and the road conditions. Probe devices are realized by smartphone or AVL (Automatic Vehicle Location) with GPS (Global positioning system). Some researchers apply machine learning methods for analysis of driving probe data. In this research, we propose a method to distinguish unusual driving behavior (sudden braking) using machine learning method. We apply SVM (support vector machine) and feature selection method to the driving probe data provided by Aizuwakamatsu City Open Data Utilization Verification Project. We report the effect of feature selection for unusual driving behavior detection, using F-measure and accuracy. We also show that selected features identify unusual driving condition (place and date).

Keywords: Driving probe data, Machine Learning, SVM: Support Vector Machine, Feature Selection

1. はじめに

自動車の走行状況や道路状況などを知るため、スマートフォンセンサーをはじめ、GPS を利用した Automatic Vehicle Location (AVL) など、様々な装置を利用し、プローブデータ（自動車の走行データ）の獲得が行われている。プローブ機器には、自動車に組み込む専用機器（ドライブレコーダ）、スマートフォンを用いるもの、簡易センサを

用いるものなどが有る。ドライブレコーダによるプローブデータはドライブレコードと呼ばれることもある。

走行時のプローブデータを分析すれば、車両の挙動把握や路面状況の把握が可能である。バスのような公共交通機関にプローブ機器を搭載すれば、バスの運行状況やドライバーによる運行の差異も把握可能であろう。プローブデータからの分析では従来、危険走行を定義し、定義に合う状況を数え上げる頻度解析や、危険走行の確率を求めるものなど統計的手法に基づくものが多い。近年、人工知能技術、とりわけ機械学習技術が進展している。それに伴い、取得したプローブデータの分析に様々な機械学習手法を利用した研究も行われている。

¹ 個人

² 九州大学情報基盤研究開発センター

³ 九州大学大学院システム情報科学研究院

^{a)} t-kawatani@kyudai.jp

^{b)} hirokawa@cc.kyushu-u.ac.jp

我々は長らく機械学習手法に基づくデータ分析を行ってきた [1]。本研究では、機械学習手法と特徴選択手法を組み合わせた、通常とは異なる走行挙動（異常走行挙動）を識別する手法を提案する。具体例として、会津若松市オープンデータ活用実証事業により提供されている公用車・公共交通車両走行情報履歴データを用いる。このデータに SVM (Support Vector Machine) と特徴選出手法を用いて、異常走行挙動を識別する手法を提案するとともに、本手法を適用した際の、異常走行挙動の識別精度と、その識別に寄与した特徴について考察する。

本論文の構成を述べる。2 節では関連研究を述べ、本研究の立場を明らかにする。3 節で会津若松市の「公用車・公共交通車両走行情報」について説明する。4 節で異常走行としての「急ブレーキ」を説明し、5 節で本研究で SVM に適用した属性および特徴語について述べる。6 節で適用した SVM+属性選出手法について説明し、7 節で適用結果を説明する。8 節では、正の重みの大きな特徴語と、その特徴語が起こる地点との関係について述べる。最後に 9 節でまとめと今後の課題を述べる。

2. 関連研究

自動車の走行履歴データ（プローブデータ）を活用し、移動時間予測や到着、遅れ予測のほか、速度低下の要因分析、道路の混雑状況推定、道路の劣化状態（穴ぼこ、ひび割れなどの損傷）の推定、急減速、急発進などの危険運転挙動の推定など、様々な研究が進められている。危険運転挙動は、ヒヤリハット事例や事故との関連性も深く、その要因の特定は重要である。

牧野ら [2] は、Electronic Toll Collection (ETC) 2.0 プローブ情報の活用方法に関する議論の中で、高速道路と一般道のヒヤリハット率の比較分析事例を示している。尾崎ら [3] は、プローブデータを利用し、急減速データの特徴調査および急減速データの収集状況と事故発生状況の関係比較を行っている。畠中ら [4] は、ヒヤリハットを「急ハンドルや急減速などの通常とは異なる車両挙動の発生」と定義し、これら挙動に基づく危険事象の検出のための閾値設定手法とヒヤリハット情報提供方法について検討している。西堀ら [5] は、「大きな加速度が多発する箇所は、交通安全上なんらかの問題を持つ可能性が高い」という視点から、豊田市内の 2005 年から 2008 年の人身事故データを活用し、プローブ情報と事故発生状況との比較分析を行っている。

これらは、車両に取り付けられた装置を基に、プローブデータの収集を行っているが、スマートフォンセンサーを利用し、道路品質の推定や、運転挙動の推定などの研究も盛んにおこなわれている。

スマートフォンセンサーを利用した先駆的な研究に、Eriksson ら [6] の Pothole Patrol や、Mohan ら [7] らの

Nericell がある。これらはヒューリスティックな閾値に基づく手法である。Bhoraskar ら [8] は、Wolverline と呼ぶ機械学習に基づき、路面の穴やマンホール蓋などによる揺れ (bump) や、急減速事象を識別する手法を提案した。また、Carlos ら [9] は、従来手法と比較評価をするためのプラットフォーム Pothole Lab を提案し、さらに、SVM ベースの穴ぼこなどの道路異常を識別する手法を提案した。

スマートフォンセンサーは、人の数に合わせてスケールするという特徴もあるが、車両に搭載された装置から得られたデータに比べて品質が劣るという問題がある。

本稿では、車両に搭載された装置から得られたプローブデータと、機械学習手法 SVM を利用した急減速挙動の識別手法を提案する。従来研究との違いは、利用したプローブデータの記録期間の長さ（4 年間）と、SVM を利用した特徴選出手法の適用がある。

3. 会津若松市「公用車・公共交通車両走行情報」

会津若松市が提供する「公用車・公共交通車両走行情報」について説明する。このデータは、「会津若松市オープンデータ活用実証事業」で収集された道路パトロール車および公用車、市内循環バス「エコロ号」、市内コミュニティバスの走行情報履歴データ（位置情報 + XYZ の加速度情報）である。表 1 にデータの概要を示す。各走行プローブデータは CSV 形式で提供されている。内部の構造はシンプルで、1 行に表 2 に示す項目が含まれている。

表 1 会津若松・走行記録データ概要

項目	データ量
取得期間	2015 年 10 月 1 日～2018 年 5 月 15 日
測定頻度	走行時, 100 msec (0.1 秒)
車の種類数	6 台。 道路パトロールおよび公用車, 市内循環バス「エコロ号」, 市内コミュニティバス
データ件数	263,035,146 件 (約 2.6 億件)
全ファイル量	25.8 GiB

表 2 会津若松・走行記録データの項目

	項目	説明	データ例
1	car_name	車の名前	aizu.BL-01.3
2	data_id	開始時刻	20180416.152926
3	datetime	測定時刻	2018/04/16 15:29:26
4	ms	測定時刻 (Unix time)	1523860179979
5	latitude	緯度	37.524830
6	longitude	経度	139.937097
7	GPS Error	GPS 誤差	8
8	accel_x	X 加速度 (右が+)	1.494
9	accel_y	Y 加速度 (前が+)	0.607
10	accel_z	Z 加速度 (下が+)	10.232

4. 異常走行「急ブレーキ」

会津若松市が提供する「公用車・公共交通車両走行情報」に、6節で述べるSVM+FS手法を適用する。SVMは2値分類器であるため、適用するには学習用の正例と負例データを与える必要がある。またSVMは様々な特徴量(数値)を分類時の属性として用いる。そのため、正例と負例および特徴量の定義が必要である。

本研究では定義した異常走行に対し、機械学習手法による異常走行条件の抽出を目指す。最初から多様な異常走行を定義するのは困難であるため、今回は最も基本的な異常走行である急ブレーキ(減速)を考える。いくつかの研究では急ブレーキを後方向の加速度が0.3G以上あるいは0.5G以上としている。本論文では、急ブレーキ走行をY方向加速度が-0.5G以下の場合とした。

約2.6億のプロブデータのうち、Y方向加速度が-0.5G以下のデータを正例とし、それ以外のデータを負例とする。全負例データを扱うには件数が多すぎるため、ランダムに約40万件の負例を選んだ。SVMモデルの作成に用いた学習データ、正例(急ブレーキ)と負例の件数を表3に示す

表3 SVMモデル作成用学習データの件数

項目	説明
正例	1,337,645
負例	419,709
合計	1,757,354



図1 走行プローブデータ件数(月ごと)



図2 急ブレーキのデータ件数(月ごと)




図3 Y方向加速度の分布(2017年月1~15日)

5. SVMに用いた属性

表2で示したプローブデータのうち、Y方向(前後方向)の加速度が、判別に用いる目的関数値となる。本研究では、Y方向加速度が-0.5G(4.8m/sec²)以下を正例(急ブレーキ)、それ以外は負例となる。

従来の走行プローブデータ分析では、場所に注目したものが多く、例えば長い直線に続くカーブ、見通しの悪いカーブなど、急ブレーキしやすい場所と事故との相関を分析する研究は多い。場所以外にも季節、曜日、時間帯が影響する可能性がある。例えば降雪や梅雨時期には天候の影響で急ブレーキが増加、通勤路は平日の8時台や17時台の交通量増加で急ブレーキが増加、同じ道でも平日昼間や土日には急ブレーキ減少などの可能性がある。

そこで本研究では危険走行条件となる要因を網羅的に検討するため、表4に示す多様な属性を走行プローブデータ(測定値)から算出した。

表4 算出した属性の種類

No.	記号	説明	算出方法
1	k	車名	表2の項目1
2	y	年(2015~2018)	表2項目4から算出
3	m	月(1~12)	表2項目4から算出
4	w	曜日(mon, ..., sun)	表2項目4から算出
5	t	時間帯(0~23)	表2項目4から算出
6	p	位置情報(緯度x経度)	表2項目5と6
7	x	横方向の加速度(G)	表2項目8から算出
8	y	前後方向の加速度(G)	表2項目9から算出
9	z	下方向の加速度(G)	表2項目10から算出
10	d	車の進行方向(1~12)	表2項目5と6から算出
11	v	速度	表2項目5と6から算出

5.1 時刻からの派生情報

走行挙動は季節、曜日、時間帯で異なる可能性があるため、季節(何月が)、曜日、時間帯(何時か)を特徴量に追加した。表4項目4に、走行プローブデータ取得時刻(Unix Time)が有る。Unix Timeの値から、年月日、曜日、時分秒に変換可能である。年、月、曜日、時間しめす記号y m w tをつけ、記号と値を組み合わせたものを生成した。例えば2018年5月1日8時15分から「y:2018, m:5, w:tue, t:8」を生成する。これらを単語として扱う。

5.2 走行地点：経度・緯度の曖昧化

走行地点は緯度と経度の組み合わせで特定できる。表 2 で示すように、地点を表す経度・緯度は詳細すぎるため、小数点以下 3 桁までを用いた。例えば走行情報の取得地点が北緯 37.524830, 東経 139.937097 の場合、「p:37.525x139.937」を生成する。

5.3 走行方向

道路の走行方向で挙動が変わる。例えば坂道の下り方向では急ブレーキが増え、上り方向では減りやすい。そこで走行プローブデータから走行方向を算出した。走行方向は、1 つ前の走行地点と現時点の走行地点の差から算出した。走行方向の詳細化は意味が少ないと考え、時計の数値を用いて走行方向を表す。北を 12 時、東を 3 時、南を 6 時、西を 9 時の方向と表す。例えばある時点の走行方向が南の場合は「d:6」と表す。

5.4 組合せ属性

本論文の分析では表 4 の 11 属性のうち X 方向加速度・Z 方向加速度・速度 (項目 7, 9, 11) を除く 8 属性を用いた。また、8 個の組合せも属性とした。組合せ数は $2^8 - 1 = 255$ 個になる。各属性の値を考えると組合せで生成される特徴語は膨大になる。

線形 SVM は計算量が小さく高速に処理できるため、組合せで出来る膨大な属性を追加しても問題無い。学習用としたプローブデータに出現する、全属性の組み合わせた属性数は 151,677 個である。

6. SVM + FS

我々は、機械学習手法 SVM (Support Vector Machine) における属性選択 (Feature Selection, FS) について研究してきた [1]。SVM は多量の属性からなるデータを用いた分類で優れた性能を示すと言われている [10]。一方、属性を増加しすぎると推定性能が悪化すると示す研究や、多くの属性を用いた場合と同程度の推定性能を少数の属性でも実現できると示す研究も有る [11]。

分類問題における属性選択の目標は、多属性を用いた場合と同程度の推定性能を少数属性で実現することで、少数属性の方が多数属性を用いるよりも推定性能が高くなることではない。属性選択を適切に行うことで全属性を用いた場合と同程度の推定性能を少数属性でも実現している [1]。

SVM+FS は、分類対象のドキュメント内の各単語の *svm-score* に従って単語属性選択を行う。*svm-score* の計算は、次のように行う。

svm-score の計算

- (1) N 個の文書集合 D を M 個 (ここでは $M = 2$) のクラスに分類する。
- (2) 文書 $d_i \in D$ ($1 \leq i \leq N$) が、 m 個の異なり語を含む時、

SVM+FS は、文書 d_i から、1 語だけを含む m 個の文書を生成する。ここで、 $d_{i,j}$ は、単語 $w_{i,j}$ ($1 \leq j \leq m$) のみを含む文書である。

- (3) 次に SVM+FS は各文書 $d_{i,j}$ を、単語ベクトル $v(d_{i,j}) = \{v_1, \dots, v_k, \dots, v_n\}$ に変換する。ここで、 n は、 D に含まれる異なり語の総数であり、もし $w_{i,j}$ がベクトル $v(d_{i,j})$ 中の k 番目の要素に対応する場合、 $v_k = 1$ であり、そうでなければ $v_k = 0$ である。
- (4) 各分類対象クラスに対して、もし、 d_i が、分類対象クラスに属していれば、SVM+FS は、 $d_{i,j}$ に正例のフラグを割り当て、そうでなければ、負例のフラグを割り当てる。
- (5) SVM+FS は、ステップ (3) で生成された単語ベクトル集合を基に、SVM を使って、分類モデルを構築し、その分類モデルによって計算された各文書 (文書は 1 語のみを含むため、各語) のスコアを求める。このスコアを *svm-score* と呼ぶ。

上記の *svm-score* を使って、SVM+FS は次の 3 ステップで実行される。

SVM+FS

- (1) SVM+FS は、上位 K 個の正例の語と、(絶対値の意味で) 上位 K 個の負例の語を各語の *svm-score* に従って選択する。
- (2) SVM+FS は、ステップ (1) で選択した K 個の正例語と K 個の負例語からなる入力ベクトルに、各文書を変換する。
 - 文書から変換された入力ベクトルは、 K 個の正例語と K 個の負例語からなる hot-BoW ベクトルである。つまり、ベクトル中の要素は、その要素の語と対応する語が文書中に 1 語以上含まれる場合、その要素の値は 1 で、そうでない場合は 0 である。
 - もし、文書が、分類対象クラスに属している場合、その文書から変換された入力ベクトルには、正例のフラグが付けられ、そうでない場合には負例のフラグが付けられる。
- (3) SVM+FS は、ステップ (2) で生成された入力ベクトルから、SVM を使って、分類モデルを構築する。

7. SVM+FS 手法の適用結果

図 4 に処理の流れを示す。

7.1 SVM モデル作成

表 3 に示した学習用データ 175 万件を SVM に投入し、各属性の重みを算出した。5 節の最後で示したように、属性数は 151,677 個である。SVM のソフトウェアは「SVM-perf」を用いた [12]。今回用いるカーネルは線形カーネルである




図 4 SVM+FS 手法適用の流れ

ことと、計算速度の高速さから SVM-perf^{*1} を選択した。

7.2 属性選択の結果

表 5 は、急ブレーキデータ 1337645 件、それ以外のデータをランダムに選んだ合計 1757354 件のデータについて、5 分割交差検定での識別性能を示している。性能は Precision, Recall, F-measure, Accuracy の 4 つで評価した。まず、約 176 万件のデータをランダムに 5 分割し、4/5 のデータで全単語を使って学習して判別モデルを構築する。次に、このモデルにおける属性の重要度を示すスコアを求める。スコアが正の上位 K 個、負の K 個合計で $2 * K$ 個の特徴語で対象をベクトル化しモデルを構築し、残りの 1/5 のデータについて構築したモデルの性能を評価した。これを 5 回繰り返し平均を求めた。

表 5 最初の All 行は全属性 (15 万語以上) を使う場合の値で、以下は K 個の正の特徴語および負の特徴語だけを用いて判別した場合の値である。 $K = 600$ の正と負の属性を 600 個使う場合、F 値 0.9778, Accuracy 0.9666 となり高い識別性能が得ている。

表 5 属性選択の効果 (1,757,354 件の学習用データ)

K	Precision	Recall	F-measure	Accuracy
All	0.9859	0.9873	0.9866	0.9796
5	0.0000	0.0000	0.0000	0.0000
10	0.0000	0.0000	0.0000	0.0000
100	0.9925	0.0303	0.0588	0.2617
200	0.9924	0.2336	0.3782	0.4153
300	0.9899	0.3742	0.5431	0.5207
400	0.9937	0.6677	0.7987	0.7438
500	0.9905	0.5674	0.7215	0.6666
600	0.9906	0.9653	0.9778	0.9666
700	0.9877	0.9805	0.9841	0.9759
800	0.9872	0.9824	0.9848	0.9770
900	0.9866	0.9853	0.9860	0.9787
1000	0.9865	0.9860	0.9863	0.9791
5000	0.9859	0.9873	0.9866	0.9796

*1 http://www.cs.cornell.edu/people/tj/svm_light/svm_perf.html

8. 正例の特徴語と地点との関係

表 3 の学習データを SVM に入れることで、各特徴語の重みが計算できる。線形カーネル SVM で算出された特徴語の重みは、値が正の場合は正例 (急ブレーキ) の特徴を表すものとなり、重みが負の場合は負例 (急ブレーキではない) の特徴を表す。

表 6 に正の重みが上位 10 個の特徴語を示す。表には、その特徴語を含む走行プローブデータ件数、急ブレーキ件数、および急ブレーキの位置 (緯度と経度) の数も記載する。

重み 1 位の特徴語「ymwt:2018:01:thu:08」は「2018 年 1 月の木曜 8 時台」を意味する。2 位の特徴語「kymwt:1:2018:02:fri:13」は「車 1 で 2018 年 2 月金曜 13 時台」を、3 位の特徴語「kymwt:1:2018:03:fri:08」は「車 1 で 2018 年 3 月金曜 7 時台」を、意味する。

表 6 には特徴語の位置数も示す。例えば 1 位の特徴語の位置数は 114 箇所である。Google map を用いて位置をアイコンで描いた。1 位の特徴語の位置 114 箇所をプロットしたものを図 5 に示す。図 6 は 2 位の特徴語の位置である。




図 5 1 位の特徴語「ymwt:2018:01:thu:08」の急ブレーキ地点

これらを見ると、特定の車が、特定の時間帯に、特定場所を走行中に急ブレーキが多い事がわかる。道路状況、天候、時間帯、運転手、車の特徴 (故障) などが原因として考えられる。急ブレーキ原因の特定には、プローブデータだけでなく、車両の運行記録や当時の天候など外部情報との照合が必要である。

9. おわりに

本論文では、機械学習手法を用いての走行プローブデー

表 6 正例の特徴語 (上位 10 個) と地点

順位	SVM-score	急ブレーキ件数	件数	特徴語	急ブレーキ位置数
1	0.2505	11161	11499	ymwt:2018:01:thu:08	114
2	0.2483	45520	45605	kymwt:1:2018:02:fri:13	97
3	0.2459	19096	19167	kymwt:1:2018:03:fri:08	142
4	0.2364	2048	2114	kymwt:20:2017:07:fri:08	135
5	0.2309	45520	45683	kmwt:1:02:fri:13	97
6	0.2290	9683	9865	kymwt:0:2016:02:thu:13	3
7	0.2290	9683	9865	kmwt:0:02:thu:13	3
8	0.2206	3496	6361	mwt:02:mon:08	34
9	0.2185	31660	31715	kymwt:10:2017:02:thu:09	218
10	0.2159	8742	9313	kymt:20:2017:08:13	256




図 6 2 位の特徴語「kymwt:1:2018:02:fri:13」の急ブレーキ地点

タからの危険走行条件抽出を試みた。走行データは会津若松市提供の「公用車・公共交通車両走行情報」で、手法は SVM+FS 手法 (SVM と属性選択手法) である。危険走行「急ブレーキ」に着目し、Y 方向 (前後方向) で -0.5G 以下を急ブレーキとした。判別に 11 個の属性を考え、各属性値と属性名 (属性記号) の組合せ属性も追加した。

学習用データとして約 176 万件を用いた。学習データから得られた SVM 判別モデルを用いて学習データ 176 万件を判別した。全属性 (15 万個以上) を使う場合の F 値 0.987 に対し、正と負の特徴語 600 個だけで F 値 0.9778 となり、少ない特徴語で高い判別性能を得た。重み上位の特徴語を含む走行データから抽出した地点を地図上に示した。その結果、特定の車が特定時間帯に特定場所の走行中に急ブレーキが多いことを抽出できた。

今後は、急ブレーキ原因の特定として、天候情報や運行記録などの外部データとの照合を行いたい。また、前方向、下方向、左右方向の加速度変化についても調査したい。下方向の加速度変化を調べることで、道路の穴がわかる可能性がある。将来は、走行プローブデータ分析における機械学習手法の効果も調査したい。

参考文献

[1] Sakai, T. and Hirokawa, S.: Feature words that classify problem sentence in scientific article, *Proceedings of ii-WAS2012*, ACM, pp. 360–367 (2012).

[2] 牧野浩志, 井坪慎二, 後藤梓: 道路政策評価における ETC2.0 プローブ情報の活用方法に関する研究, *Policy and Practice*, Vol. 3, No. 1, pp. 15–30 (2017).

[3] 尾崎悠太, 矢田淳一, 神谷翔: 急減速データを利用した危険箇所抽出手法の確立に向けた調査 (特集 IT 活用による道路交通の高度化), *土木技術資料 = Civil engineering journal: 土木技術の総合情報誌*, Vol. 56, No. 8, pp. 28–31 (2014).

[4] 畠中秀人, 平沢隆之, 真部泰幸, 渡邊寧, 井上洋, 竹中憲郎, 川崎弘太, 国土交通省: プローブデータを活用した安全走行支援サービスに関する検討, 第 6 回 ITS シンポジウム 2007, pp. 315–319 (2007).

[5] 西堀泰英, 稲垣具志, 加知範康, 安藤良輔, 三村泰広: 自動車走行時の加速度発生状況と交通事故発生箇所の関連分析, *土木計画学研究・講演集*, Vol. 42, pp. 16–20 (2010).

[6] Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S. and Balakrishnan, H.: The pothole patrol: using a mobile sensor network for road surface monitoring, *Proceedings of the 6th international conference on Mobile systems, applications, and services*, ACM, pp. 29–39 (2008).

[7] Mohan, P., Padmanabhan, V. N. and Ramjee, R.: Neri-cell: rich monitoring of road and traffic conditions using mobile smartphones, *Proceedings of the 6th ACM conference on Embedded network sensor systems*, ACM, pp. 323–336 (2008).

[8] Bhoraskar, R., Vankadhara, N., Raman, B. and Kulka-rni, P.: Wolverine: Traffic and road condition estimation using smartphone sensors, *2012 Fourth International Conference on Communication Systems and Networks (COMSNETS)*, IEEE, pp. 1–6 (2012).

[9] Carlos, M. R., Aragón, M. E., González, L. C., Escalante, H. J. and Martínez, F.: Evaluation of Detection Approaches for Road Anomalies Based on Accelerometer Readings—Addressing Who’s Who, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 19, No. 10, pp. 3334–3343 (2018).

[10] Joachims, T.: *Learning to Classify Text Using Support Vector Machines: Methods, Theory and Algorithms*, Kluwer Academic Publishers Norwell (2002).

[11] Taira, H. and Haruno, M.: Feature selection in SVM text categorization, *Proceeding on AAAI '99/IAAI '99*, pp. 480–486 (1999).

[12] Joachims, T.: A support vector method for multivariate performance measures, *ICML'05 (The 22nd international conference on Machine learning)*, pp. 377–384 (2005).