

ドライブレコーダデータを利用した運転者ごとの挙動傾向把握の試み

A Study on Understanding Drivers' Behavior through Utilizing Vehicle Recorder Data

横山 大作[♡] 伊藤 正彦[◇] 豊田 正史[▲]

Daisaku YOKOYAMA Masahiko ITO
Masashi TOYODA

車に搭載して運転中の状況を自動的に記録するドライブレコーダは、安全運転のために役立つとして営業車を中心に普及し始めている。事故時の記録画像を後から人間が確認することで、原因の調査、ドライバー教育などに役立っているが、記録された運転動作を解析するなどの方法で、事故を未然に防ぐようなさらなる発展が現在望まれている。我々は、佐川急便株式会社が持つ配送車に取り付けられたドライブレコーダデータを利用し、ドライバーごとの運転動作の傾向を抽出することで、ドライバーの運転の安全性と運転操作の傾向との関係の有無を理解することを目指す。運転動作時のセンサーデータ分布を特徴量とし、SVMを用いてドライバーの事故履歴の有無を判定すると、再現率 70%、適合率 61%の性能で判別が可能であった。

Vehicle recorders have become widely used on commercial vehicles to improve driving safety. The recorded movies from dashboards are useful to investigate causes of the accidents or educate drivers. The recorded kinetic information, however, was not fully utilized even though some recent recorders can retrieve kinetic information during normal driving operations. These data will contain some information about drivers' skills or behaviors, and will help to predict future accidents. We analyze vehicle recorder data which collected from Sagawa Express Co., Ltd., one of the largest door-to-door delivery service companies in Japan, to understand the relationship between drivers' behavior and their safety. We try to classify drivers' accident histories from the information of current driving behaviors using machine learning technique. In our experiments, we can classify drivers with 70% recall and 61% precision using the distributions of each drivers' kinetic attributes as the input features of Support Vector Machine.

[♡] 正会員 東京大学生産技術研究所
yokoyama@tkl.iis.u-tokyo.ac.jp

[◇] 正会員 東京大学生産技術研究所 / 情報通信研究機構ソーシャル ICT 推進研究センター
imash@tkl.iis.u-tokyo.ac.jp

[▲] 正会員 東京大学生産技術研究所
toyoda@tkl.iis.u-tokyo.ac.jp




図 1: ハンドル動作記録の例

1. はじめに

総務省の統計¹によると、平成 25 年の全国の交通事故件数は 629,021 件であり、4,373 人の死者、781,494 人の負傷者という多大な被害が発生している。このうち、貨物運送用の自動車(自家用、事業用の双方を含む)による事故は 17.4%を占めており、この安全性を高めることは、社会と企業の双方にとって重要な問題となっている。このためには事故の状況を正確に把握することが必要であり、事故が発生した際に前後数秒間の画像を自動的に保存するドライブレコーダが、タクシー、運送業などの業種を中心に普及を始めている。ドライブレコーダの導入によって事故率が低下したという事例も報告されている [1]。近年では、GPS による走行経路記録、ブレーキなどの運転動作時の加速度などを記録する、高機能なドライブレコーダが開発されており、運転後に急ブレーキなどの好ましくない運転がなかったか検証するなどの取り組みを通して、安全運転教育に活かす試みも始まっている。しかし、急ブレーキは良くない、など経験的に理解しやすい事柄に関する教育が行われているのみであり、運転の安全性を客観的に判断できるほどの理解には至っていない。

ブレーキ、ハンドルなどの運転動作にはドライバーごとに特徴が現れることが考えられる。図 1 は、佐川急便株式会社の営業車両に搭載されたドライブレコーダに記録されたハンドル操作時の車速と左右方向加速度をプロットしたものである(記録された内容、収集対象ドライバーの情報などは 3.1 章に詳述する)。青色の濃淡は全ドライバーの記録を集めた分布、円で示されたポイントはある一人のドライバーの記録を表している。このドライバーは、ドライバー全体と比較した時、比較的車速が高い領域でのハンドル操作が存在しているが、左右方向加速度が高い領域では操作を行っていないことがわかる。このような運転操作のドライバーごとの特徴と、ドライバーの運転の安全性との間に関係があることがわかれば、事故の予防や安全教育に役立つ指標として利用できると期待される。

我々は、ドライバーの運転の安全性と運転操作との関連を理解することを目指すため、佐川急便株式会社の営業車両が記録したドライブレコーダデータを利用し、運転挙動からドライバーの事故・交通違反履歴を判別することを試みた。無事故無違反のドライバーと事故履歴のあるドライバーとの操作記録分布の違いに着

¹<http://www.stat.go.jp/data/nihon/zuhyou/n2602300.xls>

目し、まれに起きる外れたセンサ値を取る操作が運転経歴に関係しているのではないかと観察結果を得た。また、単純な基準を設定して外れ値を検出し、ドライバーごとにその数をカウントすることで、事故履歴のあるドライバーが多く発見されることがわかり、運転操作の外れ値と事故履歴との間には何らかの関係があることが判明した。

この観察に基づき、離散化した測定値の出現回数を2項分布を用いてモデル化し、期待される出現回数から離れるほど強調されるような特徴量を設計し、SVMを用いて判別器の性能評価を行ったところ、事故歴のあるドライバーの判別において、再現率70%、適合率61%の性能を得ることができ、提案する特徴量設計が有用であるとの結論を得た。

本論文の構成は以下の通りである。2章では関連研究を述べる。3章ではドライブレコーダデータの解析実験について記述する。このうち、3.1章では利用したデータの詳細を示し、3.2章ではドライバーの事故履歴の有無に対する操作記録分布の違いを観察し、外れ値と事故履歴との間の関係の有無を調査する。3.3章では操作記録の外れ値の分布に着目した特徴量を設計し、SVMを用いてドライバーの事故履歴に関する判別実験を行う。4章ではまとめを行い、今後の課題について述べる。

2. 関連研究

運転時の速度や位置情報などを記録し、様々な用途に役立てようという研究が提案され始めている [2][3]。位置情報の利用について、Ferreira ら [4] はニューヨークの、Veloso ら [5] はポルトガルのタクシーの位置情報をそれぞれ利用し、都市の社会活動の様子を解析する試みを行った。Zheng ら [6] は北京のタクシーのデータを利用することで、より短い時間で移動できる運転経路を発見するシステムを提案した。また、速度や加速度などの利用について、Li ら [7] は、運転時の記録を元にハイブリッド車のバッテリー利用状況を判別するようなモデルを提案した。

運転時の操作挙動に着目し、ドライバーの特徴を把握、分類しようという研究もいくつか存在する。Ly ら [8] は、車の制御系が持つ速度計やアクセル状況などの記録を元に、異なる2人のドライバーの運転挙動が分類できることを示した。また特に、安全運転への応用を視野に入れて、運転の急激さの観点からドライバーを分類することを目的とした研究が存在する。Higgs ら [9] は、3人のドライバーを対象に、車の後ろに付いている時の挙動を分類し、ドライバーごとに違いがあることを示した。Dang ら [10] は、レーン変更時の挙動に着目し、12人のドライバーの間に変更頻度などの違いが存在することを示した。Castignani ら [11] は、スマートフォンによって得られるGPSおよび加速度計などの情報を用い、5人のドライバーの運転操作の急激度の違いが検出可能であるかについて検証した。しかし、これらの研究では、違いがはっきりしていると想定される少数のドライバーの分類にとどまっている。

3. ドライブレコーダデータの解析実験

3.1 解析対象データ

株式会社データ・テックの協力の下、佐川急便株式会社の文京営業所に所属するドライバー80人程度、2014年7月からの4ヶ月分の運転動作記録を用いて解析を行った。株式会社データ・テックが開発した高性能ドライブレコーダである、セーフティレコーダ“SRVideo”を搭載した営業車の運転操作記録を収集した。対象車両は一般家庭への配達・集荷を行っており、区外にある営業所と文京区間の移動、ならびに文京区内の集配における運転が主に記録されている。

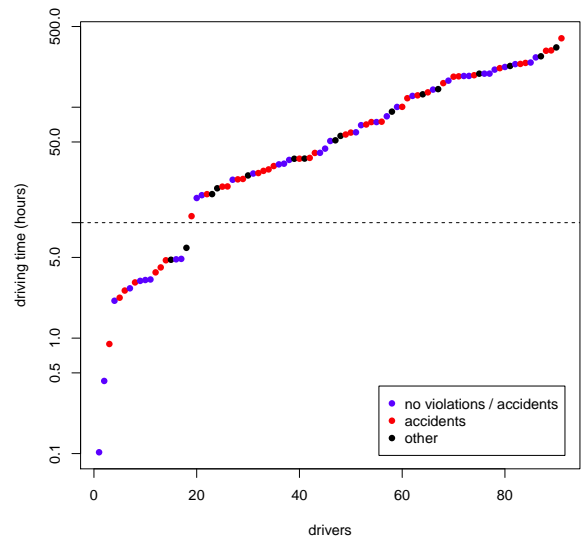


図 2: ドライバーごとの運転時間と事故・違反歴

3.1.1 ドライブレコーダの記録内容

ドライブレコーダは前後加速度計、左右加速度計、方位ジャイロ、GPSを搭載している。このセンサを利用して、ブレーキなどの基本的な運転動作を検出するとともに、ブレーキの急激さなどの情報を記録している。今回の論文では、以下の4動作を解析対象とする。

- ブレーキ動作
速度を調節するためにブレーキを踏んだ時の動作。ブレーキ時の前後方向加速度とその時間微分などを記録している。
- 停止動作
停止するときの動作。前述のブレーキ動作とは必ずしも重複しない。前後方向加速度、ブレーキ開始から停止までの所要時間などを記録している。
- ハンドル動作
カーブ、車線変更などにおけるハンドル操作。方位角速度とその時間微分などを記録している。
- 右左折動作
交差点で右左折を行った時の動作。前述のハンドル動作とは必ずしも重複しない。交差点への進入速度、曲がった後の速度、方位角速度のゆらぎなどを記録している。

ドライブレコーダは、これらの動作が1回行われるごとに1エントリを記録する。

3.1.2 解析対象ドライバー

記録されたドライバーごとの運転時間を図2に示す。横軸はドライバーを示し、運転時間の長さでソートされている。また、2004年1月1日以降に無事故無違反だったドライバーを青、1回以上交通事故があったドライバーを赤、それ以外(交通違反のみを起こしているドライバー)を黒でプロットしている。ただし、事故には無過失のもの、軽微な物損も含めている。また、ここでの交通違反には駐車違反、放置駐車、シートベルト装着違反、整備不良は含まれていない。事故・違反には営業車だけでなくマイカーでの履歴も含まれる。

ドライバーの運転時間には大きくバラつきがあり、配達エリアや業務内容、雇用形態などで様々な運転形態になっていることが予想される。事故・違反の経歴は運転時間とは特段関係があるよ

表 1: 解析対象ドライバー内訳

分類	人数
無事故無違反	25
事故あり	27
違反のみ	12
合計	64

表 2: 解析対象の運転動作数

運転動作	エントリ数
ブレーキ	260k
停止	302k
ハンドル	328k
右左折	139k

うには見受けられない。また、記録された運転行動の回数にも大きなばらつきがあった。ブレーキ、ハンドルなどの運転行動が少ないドライバーは、高速道路などを利用した長距離輸送業務に就いている可能性があり、一般的な家庭への配送業務とは異なった運転挙動をしていると考えられる。以降の実験においては、運転時間が 10 時間以上、かつブレーキとハンドルの運転操作が平均して 100 秒に 1 回以上記録されているドライバーのみを解析対象とした。図 2 では、運転時間 10 時間の境界を点線で示している。解析対象ドライバーの分類ごとの人数を表 1 に示す。また、解析対象のドライブレコーダデータに含まれる運転動作数を表 2 に示す。

3.2 操作記録分布と事故履歴との関係

図 1 に示したように、運転動作の際のセンサデータにはドライバーの特徴が現れていると考えられる。動作結果の違いがドライバーの運転の安全度合いと関連があるのかを確認するため、ドライバーを事故の履歴に基づいてグループ化し、その操作記録の分布を比較した。

操作記録には様々な属性が存在するが、以降では、ドライバーの事故履歴の有無に関して記録分布に比較的回数が異なる属性に関して紹介する。

3.2.1 操作記録分布の比較

図 3 は、ブレーキ操作時における速度と前後方向加速度 (G_x) の記録値分布を示したものである。左側が無事故無違反のドライバー (以後、優良者と記述する) の操作記録、右側が事故履歴があるドライバー (以後、事故者と記述する) の記録である。速度を横軸に、 G_x を縦軸に取ってプロットを行った。

ドライバーの両グループとも、概形としてはほぼ同じような分布を示しており、特に多くの操作が集中する領域 (点の密度の大きい領域) は分布にあまり違いが見られない。しかし、操作が比較的少ない領域では違いが見られる。速度が高く G_x が大きい領域では、事故者の方にやや多く操作記録が存在する。速度や G_x が大きい領域に通常とは外れた運転操作が存在することと事故履歴との間に何らかの関係があることが予想される。一方、速度が低く G_x が大きい領域については、優良者の方には記録が存在するが、事故者の方には存在しない。ある程度 G_x が大きい領域からは、事故者の方は全般的に速度が高い方に操作記録がシフトしているようにも見受けられる。これは、事故者はそもそもブレーキ操作時の速度が早いのではないかと考えられ、やはり操作時における速度・加速度の大きさと何らかの関係がありそうに見受けられる。

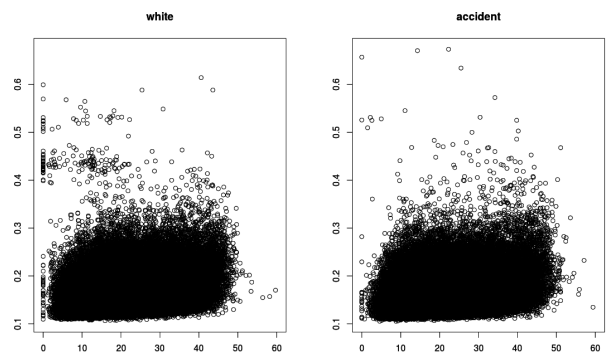


図 3: ブレーキ操作: 速度と G_x

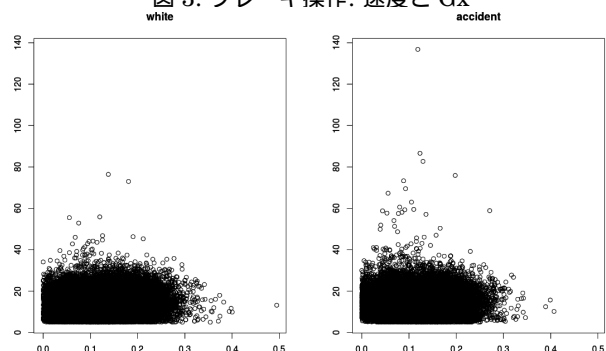


図 4: 交差点操作: 進入前 G_x と進入速度

図 4, 図 5, 図 6 は、交差点操作時における記録分布を、同様のドライバー区分で比較したものである。

図 4 は、進入前の G_x (横軸) と進入速度 (縦軸) の記録分布である。事故者の方には、進入速度が高い領域に操作記録が存在する。図 5 は、速度 (横軸) と合成加速度 (縦軸) の記録分布である。速度が高い領域に事故者の操作が存在する。図 6 は、方位角速度揺らぎ (横軸) と終了速度 (縦軸) の記録分布である。これも、終了速度が高い領域に事故者の操作が存在する。交差点操作においては全体的に、操作時の速度属性に関する記録の外れ値に事故者の特徴が存在することが予想される。

3.2.2 操作記録の特異値とドライバー属性との関係

3.2.1 章では、優良ドライバーのグループと事故履歴が有るグループとの間で、操作記録の様々な属性に関して分布の違いがあることを示した。特に、出現する回数が少ない、外れ値のような領域においてグループ間に違いが見られることがわかった。

そこで、分布に大きな違いが見られる代表的なセンサデータについて、特異値を抽出してドライバーの属性との関係を調査することにした。ここでは、3.2.1 章の観察に基づき、特に速度や加速度が大きい領域に着目して、以下の条件に適合するものを操作

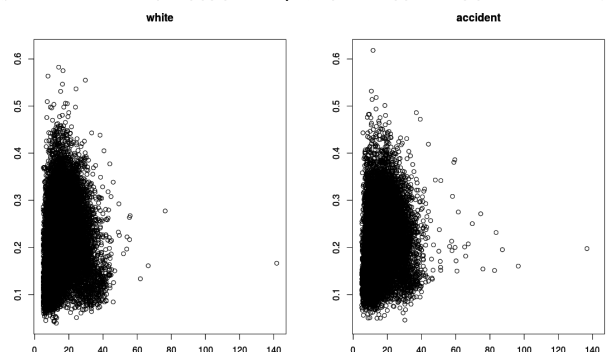


図 5: 交差点操作: 速度と合成 G

表 3: 外れ値が出現したドライバーの属性

交差点操作	ブレーキ操作	合計	属性
504	4	508	違反のみ
16	2	18	事故あり
13	2	15	事故あり
10	1	11	事故あり
3	7	10	事故あり
6	2	8	事故あり
5	3	8	事故あり
4	2	6	事故あり
2	3	5	無事故無違反
3	1	4	事故あり
2	2	4	無事故無違反
2	1	3	無事故無違反
1	2	3	違反のみ
1	2	3	事故あり
1	1	2	事故あり
1	1	2	無事故無違反
1	1	2	事故あり

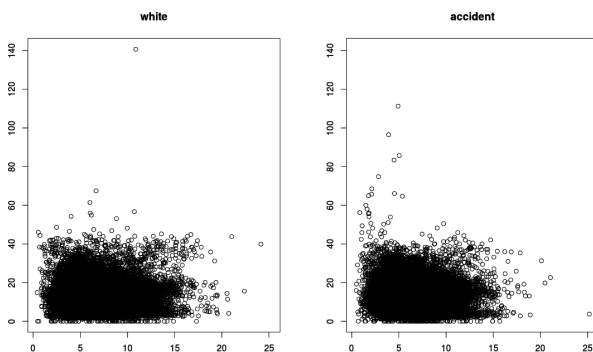


図 6: 交差点操作: 方位角速度揺らぎと終了速度




図 7: 交差点操作: 終了速度と終了時合成 G

中の特異な値として定義した。

- ブレーキ操作: (速度 > 30) かつ (Gx > 0.4)
- 交差点操作: (進入速度 > 35)

この条件に適合する特異値をドライブレコーダーの記録から抽出し、ドライバーごとに出現回数を集計した。2つの条件の両方に該当する操作が1回でも存在するドライバーは17人であった。出現回数の合計の多い順に並べたものを表3に示す。

2つの条件双方に外れ値が存在するドライバー17人中、事故を起こしたことがあるドライバーは11人であり、元々の事故発生率より偏った結果となっている。このような運転操作の発生と事故の経験との間には何らかの関連があることが示唆される。

3.3 機械学習手法を用いた分類

2章に示したように、運転操作時における各種センサデータの分布とドライバーの事故履歴の間には、何らかの関連があると考えられる。特に、外れ値に属するような値の分布が、事故履歴の推定に大きな情報量を持っていることが判明した。ここで、事故履歴の推定に役立つ分布特徴を、より自動的に、すなわち観察を必要とせず獲得することができれば、見逃されていた運転操作特徴の発見などに役立つと期待できる。そこで、取得されたセンサデータを素性とした機械学習手法の適用を試み、分布の特徴に関する知見を得ることを目指した。

3.3.1 特徴量設計

それぞれの運転動作について、前後方向加速度などのセンサデータの種類ごとに測定値を10分割し、データを離散化した。分割においては、測定値分布がおおむね含まれる領域を手で設定し、その領域を均等に8等分したものと、外れ値(過大、過小)の2つのビンの合計10個のビンを作成した。

全てのドライバーの操作記録について、離散化した測定値の出現回数を数え、それぞれのビンにおける測定値の出現確率を求め、これを p とする。あるドライバーについて、記録された操作回数を n 、あるビンに含まれる測定値の出現回数を i と記述する。それぞれの測定値の出現を独立事象であると仮定し、確率 p で値が

出現する試行を n 回実行した時に実際に i 回出現した、ということであると考えると、この測定結果が得られる確率 P_{bin} は

$$P_{bin} = {}_n C_i p^i (1-p)^{n-i}$$

で表せる。この確率の情報量 I_{bin} は

$$I_{bin} = -\log(P_{bin})$$

で表せ、観測された回数が期待される出現回数から外れるほど大きな値を取る。これにより、ドライバー全体の操作傾向と外れた測定値を強調する表現が得られると考えられるため、それぞれのビンにおける I_{bin} を並べたものをドライバーの特徴量とすることにした。ここでは、17種類のセンサデータを利用するため、各ドライバーは170個の数値列で表現されることになる。

3.3.2 SVM による判別結果

前述のように運転動作結果分布を素性として表現し、Support Vector Machine(SVM)を用いてドライバーの事故・違反履歴の有無に関する判定器を作成した。表1の分類に従い、全ドライバー64人中、事故ありのドライバー27人を正例としたもの、並びに無事故無違反ドライバー25人を正例としたものの2つの判定器を作成し、2-fold validation を行って再現率と適合率を求めた。SVMのハイパーパラメータ c 、及び利用したガウシアンカーネルのパラメータ γ についてグリッドサーチを行い、最大のF値が得られた判定器について、パラメータ設定と判別性能を表4に示す。

事故ありのドライバーを、170個の特徴量全てを用いて判定した時(表4の「全特徴量」の結果)には、F値は0.46とそれほど高くない。そこで、各センサデータの種類ごとに、値が高い方のビン4個のみを残し、17センサで合計68個の特徴量に限定した判定器を作成したところ、得られたF値は0.66まで上昇した(表4の「特徴量限定」の結果)。2章の観察でも示されたとおり、事故歴の有無で測定値の分布に違いが生じるのは、主に速度などが大きい領域においてであるため、数値の大きい領域のみの情報でも判別が行えることがわかる。

表 4: 判定器の性能

事故あり					
手法	c	γ	適合率	再現率	F 値
全特徴量	3	0.00001	0.52	0.41	0.46
特徴量限定	10	0.0001	0.61	0.70	0.66
無事故無違反					
全特徴量	10	0.00001	0.39	0.20	0.26




図 8: 事故歴ありドライバー判定の再現率と適合率, 及び F 値 (全特徴量を利用した場合)

一方, 無事故無違反のドライバーの判定結果は F 値 0.26 と悪い。今回利用した特徴量の設計は, 外れた測定値の存在を強調するものとなっているが, 無事故無違反のドライバーはむしろ, 外れた値が「存在しない」ことが特徴となっていると考えられるため, 特徴が素性にうまく現れていないことが予想される。

次に, 表 4 の最良の F 値を与える判定器において, 判別に際しての分離超平面からの距離しきい値を変更し, 再現率と適合率の変化の様子を観察した。図 8 は, 事故歴ありドライバーについて全特徴量を利用した時の結果を示している。「precision-recall」の系列が, 横軸を再現率, 縦軸を適合率として性能変化をプロットしたものである。「precision baseline」の適合率値は, 事故歴があるドライバーの割合であり, ドライバー割合が既知の時にランダムに予測を行った時の結果に相当する。全般的にランダムな予測よりはやや高い適合率が得られているが, 再現率を落としていっても適合率は横ばいであり, 良い結果とは言えない。「f-measure」の系列は, 横軸を再現率, 縦軸を F 値とした結果である。

特徴量を限定した場合の結果を図 9 に示す。全特徴量を利用した場合と比較してより高い適合率が得られており, 再現率を下げた時に適合率が上昇している。得られている F 値も高い。

また, 3.2.2 章で手動で設定した 2 つの外れ値基準を利用するヒューリスティックな判定器を考えた。これは, それぞれの条件に該当する測定値の出現数の和をそのまま用い, 出現数があるしきい値以上の時に「事故歴あり」と判定するものである。しきい値を変化させたときの再現率と適合率の変化を図 10 に示す。再現率が 3 割以下程度であれば, 高い適合率で予測を行うことができるが, それ以上の再現率になると急激に適合率が下がり, ランダムな予測と変わらない結果になっていることが見て取れる。また, この手法では再現率は半分程度までしか得られない。F 値も SVM を用いた場合と比較して低い値にとどまっている。

図 11 は, 無事故無違反ドライバーについて全特徴量を利用して判定した時の結果を示している。全体的に, ランダムな予測と




図 9: 事故歴ありドライバー判定の再現率と適合率, 及び F 値 (特徴量を限定した場合)




図 10: 事故歴ありドライバー判定の再現率と適合率, 及び F 値 (ヒューリスティックな判定)

変わりない適合率しか得られておらず, 今回の素性では判別に必要な特徴がうまく表現できていないことが示唆される。

3.3.3 SVM による判別実験の考察

今回の判別実験では, 利用する特徴量を限定することでランダム予測よりは良い判別性能を得ることができ, 外れ値の存在を強調するという特徴量設計が有効であることが確認できた。全特徴量を利用した場合でも, 無駄な特徴量の重みが小さくなるように学習できていれば性能は悪化しないと考えられるが, そのような学習ができなかったのは, 学習に用いるデータ数が少ないことが一因であると思われる。今後, ドライバー数を増やして同様の実験を行っていくことが重要であると考えている。

無事故無違反のドライバー判定においては, 今回の特徴量設計ではうまく判別が行えなかった。外れ値が「存在しない」ことが強調されるような特徴量の構築方法を今後考えていく必要がある。

4. 終わりに

本論文では, 佐川急便株式会社の営業車のドライブレコーダが記録した運転動作時のセンサデータを用い, ドライバーの運転の安全性と運転操作の傾向との関係に関する基礎的な知見を得るため, ドライバーの事故・違反履歴を判別することを試みた。ドライバーを事故履歴の有無で分けたグループ間で運転操作の記録分布を比較解析した結果, まれに起きる外れたセンサ値を取る操作が事故履歴に関係しているのではないかと観察結果を得た。ま




図 11: 無事故無違反ドライバー判定の再現率と適合率, 及び F 値

た, 単純な基準を設定して外れ値を検出し, ドライバーごとにその数をカウントすることで, 事故履歴のあるドライバーが多く発見されることがわかり, 運転操作の外れ値と事故履歴との間には関係があることが確認された. 離散化した測定値の出現回数を 2 項分布を用いてモデル化し, 観測された現象の持つ情報量として表現することで, 期待される出現回数から離れるほど強調されるような特徴量を設計し, SVM を用いて判別器の性能評価を行ったところ, ランダム予測より良い判別性能を得ることができた. 特に, 利用する特徴量を限定した判別器においては, 事故履歴のあるドライバーの判別において, 再現率 70%, 適合率 61% の性能を得ることができ, 提案する特徴量設計が有用であるとの結論を得た.

今後は, データの量を増やすとともに, 運転動作データの持つ情報を別のデータと組み合わせ, 運転動作の違いをより精度よく表現することが考えられる. 例えば, 運転動作が行われた地理的な場所と組み合わせれば, 誰もが高速走行中にブレーキを踏みがちな場所などがわかり, 異常な運転動作が分離できるのではないと思われる. あるいは, 天候データと組み合わせることで, 雨の日と晴れた日の運転動作の違いが考慮できるようになることが期待される.

【謝辞】

本研究の一部は情報通信研究機構による「ソーシャル・ビッグデータ利活用・基盤技術の研究開発 (課題 B 新たなソーシャル・ビッグデータ利活用基盤技術の研究開発): 交通ビッグデータに基づく運転者指向サービス基盤技術の研究開発」の助成を受けたものです.

特に, 佐川急便株式会社および株式会社データ・テックからは貴重なドライブレコーダデータをご提供頂き, ここに記して感謝の意を表します.

【文献】

- [1] 石川博敏. ドライブレコーダの効果と課題. 予防時報, Vol. 250, pp. 30–35, July 2012.
- [2] D.A. Johnson and M.M. Trivedi. Driving style recognition using a smartphone as a sensor platform. In *Intelligent Transportation Systems (ITSC), 2011 14th International IEEE Conference on*, pp. 1609–1615, Oct 2011.
- [3] Wei Wu, Wee Siong Ng, S. Krishnaswamy, and A. Sinha. To taxi or not to taxi? - enabling personalised and real-time transportation decisions for mobile users. In *Mobile Data Management (MDM), 2012 IEEE 13th International Conference on*, pp. 320–323, July 2012.
- [4] Nivan Ferreira, Jorge Poco, Huy T. Vo, Juliana Freire, and Cláudio T. Silva. Visual exploration of big spatio-temporal urban data: A study of new york city taxi

trips. *IEEE Transactions on Visualization and Computer Graphics*, Vol. 19, No. 12, pp. 2149–2158, December 2013.

- [5] Marco Veloso, Santi Phithakkitnukoon, and Carlos Bento. Sensing urban mobility with taxi flow. In *Proceedings of the 3rd ACM SIGSPATIAL International Workshop on Location-Based Social Networks, LBSN '11*, pp. 41–44, New York, NY, USA, 2011. ACM.
- [6] Yu Zheng, Jing Yuan, Wenlei Xie, Xing Xie, and Guangzhong Sun. Drive smartly as a taxi driver. In *Ubiquitous Intelligence & Computing and 7th International Conference on Autonomic & Trusted Computing (UIC/ATC), 2010 7th International Conference on*, pp. 484–486. IEEE, 2010.
- [7] Kun Li, Man Lu, Fenglong Lu, Qin Lv, Li Shang, and Dragan Maksimovic. Personalized driving behavior monitoring and analysis for emerging hybrid vehicles. In Judy Kay, Paul Lukowicz, Hideyuki Tokuda, Patrick Olivier, and Antonio Krger, editors, *Pervasive Computing*, Vol. 7319 of *Lecture Notes in Computer Science*, pp. 1–19. Springer Berlin Heidelberg, 2012.
- [8] Minh Van Ly, S. Martin, and M.M. Trivedi. Driver classification and driving style recognition using inertial sensors. In *Intelligent Vehicles Symposium (IV), 2013 IEEE*, pp. 1040–1045, June 2013.
- [9] B. Higgs and M. Abbas. A two-step segmentation algorithm for behavioral clustering of naturalistic driving styles. In *Intelligent Transportation Systems - (ITSC), 2013 16th International IEEE Conference on*, pp. 857–862, Oct 2013.
- [10] Ruina Dang, Fang Zhang, Jianqiang Wang, Shichun Yi, and Keqiang Li. Analysis of chinese driver's lane change characteristic based on real vehicle tests in highway. In *Intelligent Transportation Systems - (ITSC), 2013 16th International IEEE Conference on*, pp. 1917–1922, Oct 2013.
- [11] G. Castignani, R. Frank, and T. Engel. Driver behavior profiling using smartphones. In *Intelligent Transportation Systems - (ITSC), 2013 16th International IEEE Conference on*, pp. 552–557, Oct 2013.

横山 大作 Daisaku YOKOYAMA

2006 年東京大学より博士号取得. 博士 (科学). 2002 年より同大学新領域創成科学研究科助手などを経て, 2009 年より同大学生産技術研究所助教, 現在同特任助教. 並列プログラミング, 分散計算環境, ゲームプログラミングに関する研究に従事. IEEE CS, 日本データベース学会, 情報処理学会, 日本ソフトウェア科学会各会員.

伊藤 正彦 Masahiko ITO

2007 北海道大学大学院情報科学研究科博士後期課程修了. 博士 (情報科学). 同年, 同大学大学院博士研究員. 2009 東京大学生産技術研究所助教を経て, 現在, 同大学特任准教授, および, NICT 主任研究員. 情報可視化, ユーザインタフェースの研究に従事. IEEE CS, 日本データベース学会, 情報処理学会, 芸術科学会各会員.

豊田 正史 Masashi TOYODA

1999 年東京工業大学大学院情報理工学研究科博士後期課程修了. 博士 (理学). 同年科学技術振興事業団計算科学技術研究員. 2001 年東京大学生産技術研究所学術研究支援員, 同大学同研究所産学官連携研究員, 同大学生産技術研究所特任助教授, 助教授を経て現在, 同大学生産技術研究所准教授. ウェブマイニング, 実世界ビッグデータ分析, ユーザインタフェースに興味を持つ. ACM, IEEE CS, 日本ソフトウェア科学会各会員.