

推薦論文

交通状況把握のための 運転行動の時系列性を考慮した車両挙動分析手法

横山 達也^{1,a)} 白石 陽^{2,b)}

受付日 2018年4月11日, 採録日 2018年10月2日

概要: ドライバは道路上の交通状況によって快適な運転を妨げられることがある。たとえば右折待ちをしている車列が走行経路上に存在する場合、その車列の後続車両は急な減速や車線変更を強いられることがある。このような状況を回避するには、走行予定経路上の交通状況をドライバーが事前に把握する必要がある。そこで本論文では、こうした交通状況を形成する車群の挙動を把握するための車両挙動推定に向けた車両挙動分析手法を提案する。ここで車両挙動を、ドライバーの運転行動の時系列から構成されるものと定義する。運転行動の時系列性から車両挙動を分析することは、車群の挙動の把握に有用であると考えられる。本研究では、車載スマートフォンで収集したセンサデータにSAX (Symbolic Aggregate Approximation) を適用することで、時系列データを文字列へ変換する。そして、自然言語処理技術である N-gram により、車両挙動を表す文字列から運転行動を部分文字列として抽出し、BoW (Bag of Words) モデルとして車両挙動を表現することで、運転行動の時系列性を考慮した車両挙動分析を行う。評価実験として、BoW モデルを用いた SVM (Support Vector Machine) による車両挙動の分類精度を 5 分割交差検定で評価した結果、F 値が 8 割以上となり、提案手法の有効性が示唆された。

キーワード: プローブ情報システム, 車両挙動, 運転行動, センシング, SAX (Symbolic Aggregate Approximation)

A Method for Analyzing Vehicle Behaviors Considering a Sequence of Driving Actions towards Grasping Traffic Situations

TATSUYA YOKOYAMA^{1,a)} YOH SHIRAISHI^{2,b)}

Received: April 11, 2018, Accepted: October 2, 2018

Abstract: Traffic situations on a traveling route can hinder comfortable driving. For example, inefficient driving is forced on a succeeding vehicle's driver by a line of vehicles waiting for turning left or right. Drivers need to grasp traffic situations on their traveling route to avoid the situations in advance. Therefore, this paper proposes a method for analyzing vehicle behaviors to grasp the behavior of a group of vehicles forming traffic situations. We define a vehicle behavior as a sequence of driver's driving behaviors. An analysis of vehicle behaviors by using a sequence of driving behaviors will be beneficial for grasping vehicle group's behaviors. This study analyzes vehicle behaviors considering a sequence of driving behaviors. Our method collects sensor data by a smartphone mounted on a vehicle, and converts the collected time-series data to string expression by SAX (Symbolic Aggregate Approximation) and adopts the techniques of natural language processing such as N-gram and BoW (Bag of Words) model in order to express each vehicle behavior. We conducted an experiment to classify typical vehicle behaviors with BoW model by SVM (Support Vector Machine) and examined the classification accuracy by 5-fold cross validation test. The experimental results suggest that the proposed method is effective for estimating vehicle behaviors.

Keywords: probe information system, vehicle behavior, driving behavior, sensing, SAX (Symbolic Aggregate Approximation)

¹ 公立はこだて未来大学大学院システム情報科学研究科
Graduate School of Systems Information Science, Future
University Hakodate, Hakodate, Hokkaido 041-8655, Japan

² 公立はこだて未来大学システム情報科学部
School of Systems Information Science, Future University
Hakodate, Hakodate, Hokkaido 041-8655, Japan

a) g2117055@fun.ac.jp

b) siraisi@fun.ac.jp

本論文の内容は 2017 年 6 月のマルチメディア, 分散, 協調とモバイル (DICOMO2017) シンポジウムにて報告され, 高度交通システムとスマートコミュニティ研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

1. はじめに

近年、車が持つセンサ情報を、ネットワークを介して共有することにより、生活に役立つ情報を作り出すことを目的としたプローブ情報システムが実用化されている [1]。代表的なプローブ情報システムとして VICS (Vehicle Information and Communication System) [2] があげられる。VICS とは、道路交通における渋滞情報や規制情報などのデータを各車両へリアルタイムに配信を行う情報通信システムのことである。VICS を利用したカーナビゲーションシステムを利用することによって、ドライバーは交通状況を事前に把握し、渋滞していない道路を選択し走行できる。また、プローブ情報システムを前提とした研究 [3], [4], [5], [6], [7] がさかんに行われており、交通状況把握のために車両から収集した位置情報や動画像が用いられている。しかし、渋滞していない道路を選択した場合においても、快適な運転を妨げられてしまうことがある。たとえば、右/左折待ちをしている車列や乗降中のバス待ちの車列が走行経路上に存在する交通状況があげられ、こうした交通状況をドライバーが事前に把握できない場合、急な減速や車線変更を強いられることがある。ドライバーが、これらの急な操作を回避するには、走行予定経路上の交通状況を形成する車群の挙動を把握し、事前に走行する車線を選択する必要がある。

図 1 に、交通状況把握による快適な運転の例を示す。図 1 において、片側 2 車線道路で交差点での右折を行う予定があるドライバー (図 1 における赤色の車両) は、右折のために右車線変更する必要があるが、右車線変更するタイミングによっては、ドライバーが右折したい交差点の手前に存在する右折待ちの車列 (図 1 における青色の車両) によって急な減速や車線変更を強いられることがある。そこで、右折待ちの車列が発生しやすい道路であるか否かの判断材料として交通状況の予測結果を、事前に提示することで、ドライバーの快適な運転を促進できる。しかし、現在のカーナビゲーションシステムや文献 [3], [4], [5], [6], [7] の手法では、位置情報や動画像を用いていることから、ドライバーが交通状況を把握するうえで必要となる、走行経路上に右折待ちの車列が存在しやすいといった車両の挙動に関する情報を提供できないと考えられる。

交通状況把握に必要な情報として、どのような車両挙動




図 1 交通状況把握による快適な運転

Fig. 1 Comfortable driving by grasping traffic situations.

が、いつ、どの地点で行われたのかという情報が必要になる。本研究では、交通状況を形成する複数の車両から収集した車載センサ情報により車両挙動を推定し、その推定結果を蓄積して集合知として活用することで、交通状況を形成する車群の挙動 (時間的変化) を予測する。そして、予測結果を事前にドライバーに提示することで、ドライバーの快適な運転の促進を行う。この際、車両挙動推定に必要な車両の動きに関するデータと、推定結果と紐づける位置情報と時間に関する情報が必要となる。

交通状況の予測結果の提示方法として、アイコンの表示と音声での注意喚起により、経路案内時に情報として付加することを想定している。ドライバーに提示される情報は、快適な運転に影響しうる車群の挙動に関する予測結果 (例: 右/左折待ちをしている車列や乗降中のバス待ちの車列の存在) である。図 1 の例において、交差点で右折したいドライバーに対して、交差点の手前で右折待ちの車列が発生しやすい道路であるか否かを、経路案内時にアイコンの表示と音声での注意喚起によって提示する。これにより、ドライバーは右車線変更を行う適切なタイミングを判断することができる。経路案内時に情報を付加している例として、CYBER NAVI [8] があげられる。CYBER NAVI では、従来のカーナビゲーションシステムで行われる経路案内時に、地図上へのアイコンの表示、音声での注意喚起により「ヒヤリハット地点」に関する情報を提示することで、ドライバーの安全な運転を支援している。ここで、「ヒヤリハット地点」は、ネットワークを介して収集された過去のドライバーの走行データの分析結果から、急ブレーキが多いと判断された地点のことを指す。ドライバーに対して、「ヒヤリハット地点」を回避させるために、急な車線変更を促すといった経路案内を行うのではなく、経路案内時にアイコンの表示と音声での注意喚起によって「ヒヤリハット地点」の存在を提示している。情報提示後の運転をドライバーの判断に委ねることで、ドライバーの安全運転を妨げない提示方法となっている。このような CYBER NAVI における情報提示は、ドライバーの安全運転を妨げないものであると考えられ、本研究においても同様なアプローチをとることで、安全にドライバーの快適な運転の促進を図る。

本論文では交通状況を形成する車群の挙動把握に向けて、車載スマートフォンから、車両の挙動に関する情報として、センサデータ (加速度, 角速度, 位置情報, タイムスタンプ) を収集し、各車両挙動の分析を行う。車両挙動の例として、直進, 停止, 右/左折, 車線変更などがあげられる。本研究においては、車両挙動をペダル操作による加減速や、ハンドル操作による右/左折といったドライバーの一連の運転行動の時系列の結果として成り立つと定義する。運転行動の時系列性を考慮して車両挙動分析を行うことで、右折待ち車列の存在の有無だけでなく、その形成過程や車列を回避する車両の挙動などに着目することができ

る。その結果、より詳細に車群の挙動を把握することができる。また、各運転行動を行うタイミングは、同一のドライバーや異なるドライバー間において差があると考えられる。本研究では、多数の車両から車載センサ情報を収集するプローブ情報システムとして提案手法を構成することを想定している。そして、車載センサ情報から車両挙動を推定し、その推定結果を集合知として活用することを想定している。したがって、複数車両の車載センサ情報を用いた車両挙動分析では、運転行動のタイミング差を吸収し、同一の車両挙動として扱う必要がある。本研究では車載スマートフォンで収集したプローブ情報に SAX (Symbolic Aggregate Approximation) [15] を適用して、時系列データの文字列への変換を行い、自然言語処理技術を用いることで、運転行動の時系列性を考慮した車両挙動分析を行う。

本論文の貢献として、提案手法の新規性と有用性について述べる。まず、提案手法の新規性については、「運転行動の時系列性の考慮」があげられる。車両挙動に関するセンサデータに対して、SAX を適用して自然言語処理により、文献 [12], [13], [14] における車両挙動よりも細かい単位で車両挙動を扱うことが、交通状況の予測に向けて有用である。次に、提案手法の有用性については、「提案手法による車両挙動推定の可能性の示唆」があげられる。4.3 節における実験結果から、本論文における提案手法による車両挙動の特徴抽出が、車両挙動推定に対して有効であることが示唆されている。

以降、2 章では、交通状況把握のために位置情報や動画画像を利用した研究や、車載センサ情報を利用した車両挙動の分析に関する研究について述べる。3 章では、本研究で提案する交通状況把握のための車両挙動推定に向けた車両挙動分析手法について述べる。4 章では、提案手法における各種パラメータ値設定のための予備実験と提案手法による車両挙動推定の実現性についての評価実験について述べる。5 章では、本論文についてまとめる。

2. 関連研究

2.1 交通状況把握に関する研究

交通状況把握に関する研究として、車両から収集した位置情報に基づいて交通状況把握を行う研究がある [3], [4], [5]。これらの研究では、プローブ車両から収集した位置情報や速度を用いている。文献 [3] では、Kinematic Wave 理論による 2 台のプローブ車両間の交通状態の補完により、2 台の車両間に存在する車両の台数を推定している。文献 [4] では、道路をリンクと呼ばれる単位で区切り、収集した車速と過去のデータより取得した $k-v$ 曲線より、各リンク上のプローブ車両通過時刻における交通量をベイズ理論により推定している。文献 [5] では、車速、位置情報に加えて信号パラメータも用いており、交差点内で赤信号の経過時間から到着する車両数、青信号の経過時間から交差点の交

通容量の推定を行い、各交差点の関係性を考慮することでリンク交通量の推定を行っている。しかし、本研究が想定する交通状況の把握を行うためには、これらの手法による交通量だけでは、どのような車両挙動が、いつ、どの地点で行われたのかという情報が不足すると考えられる。

また、カメラを用いた交通状況把握に関する研究がある [6], [7]。文献 [6] では、交通状況把握のために車載カメラで撮影した動画を、ドライバー間で共有している。位置情報や撮影時の方角、撮影時刻を車載カメラで撮影した動画とともに記録し車々間通信や広域無線通信を介して共有している。文献 [7] では、車載スマートフォンで撮影した動画を、ドライバー間で共有することで渋滞に関する交通状況把握を行っている。スマートフォンから取得した位置情報から算出した車速に基づき、渋滞区間を検出することで、渋滞に関する動画を収集し、共有を行っている。しかし、これらの手法では、夜間や逆光時などに対してカメラの外界に対するロバスト性が低いことが問題となり、挙動に関するセンサデータ (加速度や角速度など) と比較して、車両挙動に関する動きの情報を取得することが難しい。また、車載カメラを用いる場合は、センサデータの取得が容易なスマートフォンと比較して普及率が低く、プローブ情報システムを想定するとデータ収集のための車両数の確保が難しい。

2.2 車載センサによる車両挙動の分析に関する研究

車両挙動に関する動きの情報を含んだ車載センサ情報を用いて車両挙動の分析を行っている研究として、車両挙動のパターン抽出に関する研究 [9], [10], [11]、車両挙動の推定に関する研究 [12], [13], [14] がある。

まず、車両挙動のパターン抽出に関する研究 [9], [10], [11] では、ドライバーの運転時に見られる特徴的な車両挙動をパターンとして抽出している。文献 [9] では、車載センサ情報に、画像解析分野で用いられる手法である BoS (Bag of Systems) を適用することで、特徴的な車両挙動のパターンを抽出している。この手法では、「緩やかな右転回」といったドライバーの意図が反映された車両挙動を抽出している。また、道路の一定区間ごとで、抽出したパターンの分布をクラスタリングにより求めることで、その道路区間で起きやすい車両挙動を推定している。文献 [10] では、車載センサ情報に対して、二重分節解析を行うことで運転行動パターンを抽出し、センサデータ上の運転行動を意味のあるパターンに分割している。ドライバーの運転意図を抽出することにより一連の運転挙動を特定することが、運転支援や車の知能化の視点から重要と考え、ドライバーの運転行動に二重分節構造の存在を仮定し、二重分節解析を行っている。文献 [11] では、車載センサ情報に対して、DTW (Dynamic Time Warping) を用いて、クラスタリングを行い、加減速に関する運転特性パターンの抽出を行っている。

る。個人や運転経路によって頻出する運転行動パターンが異なる傾向が、実験により示されている。

文献 [9], [10], [11] で抽出されたパターンは、ペダル操作による加減速や、ハンドル操作による右/左折といった運転行動を扱っている。そのため、文献 [9], [10] では車両挙動を運転行動の時系列としてパターンの分析を行っており、文献 [11] では抽出された加減速のパターンにドライバーの意図が反映されていると考える。しかし、これらの手法では、抽出されたパターンの意味の理解が課題とされており、抽出されたパターンが、どのような運転行動に対応しているかという情報が得られなければ交通状況把握への応用は難しい。

次に、車両挙動の推定に関する研究 [12], [13], [14] では、ドライバーの運転時に見られる特定の車両挙動を対象として、車載センサ情報を収集し、機械学習や閾値による判別を適用することで車両挙動の推定を行っている。文献 [12] では、車載センサ情報に対して、アンサンブル学習である Random Forest を適用することで、車両挙動（車線変更、車線維持）の推定を行っている。車線変更中は、車線維持中と比較して、車速が維持されやすいこと、操舵角が特徴的な変化をしやすいことに着目している。文献 [13] では、車載センサ情報に対して、閾値による判別を適用することで、右/左折、Uターン、右/左車線変更、カーブ走行といった車両挙動の推定を行っている。角速度に見られる極値の数、角速度の変位、加速度と角速度から算出した水平方向の移動距離に対して、閾値による判別を行っている。文献 [14] では、車載センサ情報に対して、SAX (Symbolic Aggregate Approximation) [15] を適用してセンサデータの文字列への抽象化を行って車両挙動を文字列のパターンとして扱い、閾値を用いた文字列照合を行うことで急な加減速、右/左折、Uターン、右/左車線変更といった運転行動、車両挙動の検出を行っている。SAX の利点として、メモリ消費や実行時間の削減、センサデータに含まれるノイズの除去、センサデータの容量の削減があげられているが、提案手法の正解率は車両挙動によってばらつきがある。

文献 [12], [13], [14] では、抽出されたセンサデータのパターンが、どの車両挙動に対応するか明確であり、文献 [9], [10], [11] のような車両挙動のパターン抽出に関する手法で抽出されたパターンと比較して、交通状況把握への応用が容易であると考えられる。しかし、これらの研究では、ペダル操作による加減速や、ハンドル操作による右/左折といった運転行動を考慮しておらず、車両挙動を運転行動の時系列として分析していない。そのため推定した車両挙動にドライバーの意図が含まれておらず、交通状況の形成過程や車列を回避する車両の挙動といった本研究が目指す交通状況把握に必要な情報を得るためには、これらの手法を適用することは不十分であると考えられる。

3. 提案手法

3.1 研究目的

本研究では、ドライバーの快適な運転支援に向けて交通状況を形成する車群の挙動（時間的変化）を予測して、その結果を事前に提示することで、ドライバーが交通状況の把握を行うことを最終目的とする。

そこで、本論文では交通状況把握に向けて、車載センサ情報による車両挙動分析を行う。スマートフォンなどの車載センサを用いたプローブ情報システムを想定することで、カメラを用いた手法の外界に対するロバスト性と普及率の課題を解決できると考える。本研究では、車両挙動は、ペダル操作による加減速や、ハンドル操作による右/左折といったドライバーの一連の時系列的な運転行動の結果として成り立つと定義する。運転行動の時系列性を考慮して車両挙動分析を行うことで、車両挙動をペダル操作やハンドル操作といったドライバーの意図が反映された運転行動の単位で抽出し、車両挙動の推定を行う。そして、その推定結果を蓄積して集合知として活用することで、交通状況を形成する車群の挙動（時間的変化）の予測を行う。最終的に、交通状況の予測結果を事前にドライバーに提示することで、ドライバーの快適な運転の促進を目指す。

3.2 交通状況に関する定義

本研究では、交通状況を、複数の車両により形成される車群の挙動と定義する。道路上には、直進する車両、右/左折する車両といった様々な挙動を行う車両が存在している。本研究が想定するドライバーの快適な運転を妨げる交通状況による渋滞の例として、右/左折待ちをしている車列や乗降中のバス待ちの車列が走行経路上に存在する交通状況があげられる。図 1 は、右折待ちの車列が走行経路上に存在している場合で、右折を行う前に必要となる右車線変更のタイミングによっては、右折待ちの車列によって急な減速や車線変更を強いられることがある。左折待ちの車列やバス待ちの車列も同様に、左折を行う前に必要となる左車線変更のタイミングによっては、これらの車列によって急な減速や車線変更を強いられると考えられる。以上のような、本研究が想定する交通状況で起こりうる渋滞は、渋滞を形成する車両群と、それを回避する車両群によって形成されている。図 2 に渋滞に関する交通状況の様子を示す。図 2 では、右折車両が多いが右折レーンがない状況で発生しうる状況であり、対向車線の車両の通過待ちのために右折待ちの車列が形成され、その車列を回避する車両も発生する。同様の交通状況は、交差点や左折車両が多い場合でも発生しうる。また、本研究では、車両挙動をドライバーの運転行動の時系列と定義する。たとえば、「右折」の挙動は図 3 のように、車道の右側へ車を寄せ（以下、右寄せ）、減速し、右折するという一連の運転行




図 2 渋滞に関する交通状況
Fig. 2 Traffic situations on congestion.




図 3 「右折」挙動の運転行動の時系列
Fig. 3 A sequence of driving behaviors at turn right.

動の時系列の結果として成り立つ。

右折待ちの車列が、周囲の車両のドライバーに影響を及ぼす範囲は右折する地点ではなく、車道の右側へ車を寄せる地点から始まっていると考えられる。そのため「右折」という車両挙動を推定するだけでは、どの地点から右折待ちが発生しているかという交通状況を把握する際に、ドライバーへ提供する情報として不十分である。そこで、右折を運転行動の時系列として扱うことで、ドライバーの右寄せをはじめた地点や減速をはじめた地点といった情報を考慮することができ、図 1 における右折待ちをしている車列が走行経路上に存在する交通状況を、車両挙動の推定結果から予測する際には有用である。

予備実験として、運転行動の時系列性が成り立つかどうかを確認するために、車載スマートフォンを用いてセンサーデータを収集した。図 4 において、前後方向の車両の動きをとらえる加速度センサの値には、ペダル操作の結果として「減速」の影響が表れており、横方向の車両の動きをとらえる角速度センサの値には、ハンドル操作の結果として「右寄せ」や「右折」の影響が表れている。また、図 4 では、図 3 における「右折」挙動を構成する各運転行動がセンサーデータ上で時系列的な変化として現れている。したがって、本論文では交通状況を形成する車群の挙動把握に向けて、車載スマートフォンから、車両の挙動に関する情報として、センサーデータ（加速度、角速度、位置情報、タイムスタンプ）を収集し、車両挙動分析を行う。

車両挙動を長期的な動きとしてとらえると、車両挙動はいくつかの短期的な動きの時系列として構成されていると考えられる。たとえば図 3、図 4 の「右折」に関する車両挙動は、右寄せの行動、減速の行動、右折の行動という運転行動の時系列として構成されていると考える。本論文では、車両挙動の部分的な箇所（図 4 における右寄せ、減速、

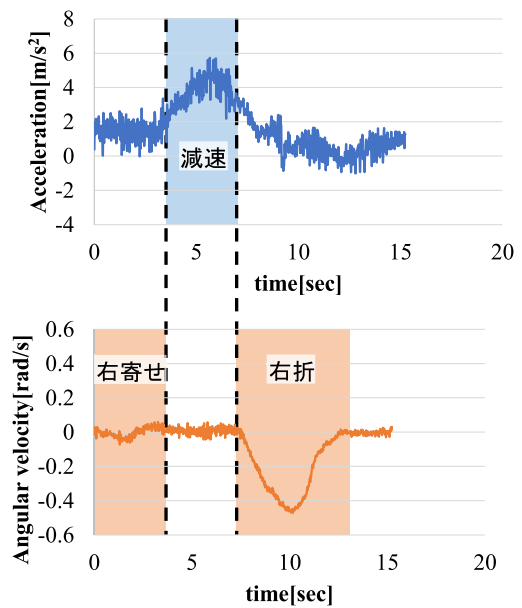


図 4 センサデータにおける運転行動の時系列
Fig. 4 A sequence of driving behaviors on sensor data.

右折) を運転行動と定義する。

3.3 研究課題とアプローチ

本論文では、交通状況を形成する車群の挙動（時間的変化）の把握による交通状況把握の要素技術として、車両挙動の推定に向けた車両挙動分析手法を提案する。研究課題を以下に示す。

- 課題 1. 車両挙動に関する動きの情報の取得
- 課題 2. 運転行動の時系列性の考慮
- 課題 3. 特徴的な運転行動の抽出

課題 1 について、本研究では、交通状況を形成する複数の車両から収集したプローブ情報により車両挙動を推定し、その推定結果を蓄積して集合知として活用することで、交通状況を形成する車群の挙動（時間的変化）の予測を目指している。よって、車両挙動の推定に向けて車両挙動に関する動きの情報を取得する必要がある。また集合知としての活用に向けて、プローブ情報システムを想定し、多くのドライバーから収集する必要がある。そこで、課題 1 に対するアプローチとして、まず車載カメラと比較して外界に対するロバスト性が高く、車両挙動に関する情報の収集を見込むことができる加速度や角速度といったセンサーデータを収集する。次にセンサーデータの収集には、広く普及しているスマートフォンを利用する。スマートフォンには、加速度センサ、角速度センサなど多くのセンサが搭載されているため、多くのドライバーからセンサーデータの収集を見込むことができる。

課題 2 について、運転行動の時系列性を考慮するために、収集した車載センサ情報から、運転行動に対応する部分を抽出する必要がある。文献 [12], [13], [14] では、抽出されたセンサーデータのパターンが、どの車両挙動に対応するか明

確であり、文献 [9], [10], [11] のような車両挙動のパターン抽出に関する手法で抽出されたパターンと比較して、交通状況把握への応用が容易であると考えられる。しかし、これらの研究では、車両挙動を運転行動の時系列として分析していない。そこで課題 2 に対するアプローチとして、車両挙動に対応する時系列データを文字列へ変換することで離散化し、その変換された文字列からドライバーの運転行動に関する部分文字列を抽出する。具体的には、収集したセンサーデータに SAX (Symbolic Aggregate Approximation) [15] を適用してセンサーデータを文字列へ変換する。そのうえで、文字列に対して部分文字列を抽出する自然言語処理技術である N-gram を適用する。抽出された部分文字列は、運転行動によるセンサーデータの変動を示すと考えられる。SAX により抽象化された車両挙動に関する文字列から、車両挙動を構成する運転行動を部分文字列として抽出することで、車両挙動を運転行動の時系列として表現する。

課題 3 について、本研究では、交通状況把握のための車両挙動の推定に向けて、各車両挙動における運転行動を、特徴的な部分文字列として抽出する必要がある。たとえば、図 4 における右寄せや右折、減速といった運転行動によるセンサーデータの変動を、特徴的な部分文字列として抽出し、車両挙動推定に利用することで、運転行動の時系列性を考慮した車両挙動推定が可能になると考える。

そこで課題 3 に対するアプローチとして、部分文字列の「出現頻度」の観点に基づいて、特徴的な部分文字列の抽出を行う。「出現頻度」に着目する理由として、各車両挙動において高い頻度で出現する運転行動が、その車両挙動における特徴的な運転行動を表すと考えられることがあげられる。具体的には、課題 2 に対するアプローチによって得られた文字列に対して、ランレングス符号化を行うことで得られた文字列を用いる。文献 [16] では、屋内における人の位置をカメラで取得した座標を、SAX を拡張した手法である Universal SAX を用いて文字列化し、ランレングス符号化し、数値部分を除去した文字列を用いることで、人が移動した座標の軌跡を抽出している。本論文では、車載センサーの時系列データを対象としているが、文献 [16] と同様にランレングス符号の文字部分に着目することで、「出現頻度」の観点に基づいた特徴抽出を行う。文字部分に着目することは、車両挙動に関するセンサーデータにおける値の変動に着目することになり、異なるドライバー間、また同一のドライバーにおける運転行動のタイミング差を吸収することも期待できる。そのため、ランレングス符号の文字部分に対して、N-gram を適用して抽出した各部分文字列の「出現頻度」を分析することで、運転行動のタイミング差を考慮し、「出現頻度」の観点から特徴的な運転行動に該当する部分文字列を抽出することができる。

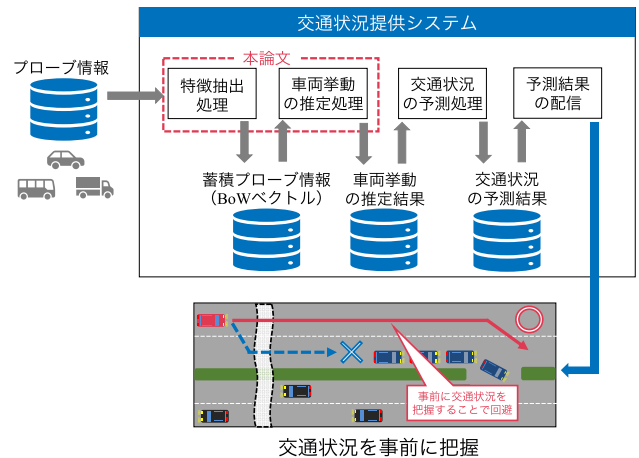


図 5 交通状況提供システムの全体像

Fig. 5 An overview of our system for providing traffic situations.

3.4 提案手法の流れ

図 5 に、本研究が目指す交通状況提供システムの概念図を示す。まずプローブ情報として、センサーデータの収集を行う。そして、提案システムにおいて、特徴抽出、車両挙動推定、推定結果による交通状況の予測、最後に交通状況の予測結果の配信を行うことで、ドライバーの交通状況の把握の促進を目指す。本論文では、交通状況提供システムの概念図における特徴抽出処理と車両挙動の推定処理に着目して、車両挙動の推定に有効であると考えられる特徴的な部分文字列の抽出と、提案手法の車両挙動推定に対する提案手法の有効性の評価を行う。

本論文における提案手法は、データ収集と特徴抽出に向けた車両挙動分析から構成される。データ収集として、車載スマートフォンを用いて車両走行時のセンサーデータの収集を行う。詳細は、3.5 節で述べる。車両挙動分析として、交通状況把握のための車両挙動の推定に向けた特徴抽出を行う。車両挙動分析の手順としてまず SAX を、収集したセンサーデータに対して適用し、文字列への抽象化を行う。詳細は、3.6 節で述べる。次に、変換した文字列に自然言語処理を適用することで、「出現頻度」の観点から、車両挙動の推定に有効であると考えられる特徴的な部分文字列の抽出を行う。詳細は、3.7 節で述べる。

3.5 車両挙動に関するデータの収集

本研究では、スマートフォンを車両のダッシュボード上に設置し、車両走行時のセンサーデータを収集する。スマートフォンに搭載された加速度センサ、角速度センサからセンサーデータを取得する。収集するセンサーデータは、3 軸加速度センサ値、3 軸角速度センサ値、緯度、経度であり、タイムスタンプとともに記録する。スマートフォンの加速度センサの X 軸が車両の左右方向、Y 軸が鉛直方向、Z 軸が進行方向となるようにスマートフォンを設置する (図 6)。




図 6 スマートフォンの設置環境とセンサの各軸の向き

Fig. 6 The setting of a smartphone and the orientation of each axis of its sensors.

3.6 SAX によるデータの抽象化

SAX とは、時系列データを文字列に変換することで、データの抽象化を行う手法である [15].

SAX の手順を以下に示す.

- (I) 時系列データが正規分布に従っていると仮定し、時系列データの正規化を行う。
(平均が 0, 分散が 1 になるように線形変換する)
- (II) 時系列データを、時間軸に対して等間隔の区間に分割する.
- (III) 数値軸上に分布する正規分布を仮定し、正規分布の各区間の累積確率が等しくなるような境界を定め、区分ごとに文字を割り振る.
- (IV) 区間ごとに時系列データの平均値を算出する.
- (V) 算出した平均値を境界に基づき、文字に変換する.

SAX のパラメータとして、変換率 R と文字の種類 W を用いた. 変換後の文字列の長さ L_{after} と、変換する前の時系列データの長さ L_{before} により、 $R = L_{after}/L_{before}$ として計算する. たとえば、 $R = 1/5$ は、連続する 5 つのセンサデータで平均値を算出し、1 文字に変換することを意味する. また、 $W = 4$ のときは、 $\{a, b, c, d\}$ の 4 種類の文字を利用して、センサデータを文字列に変換することを意味する. SAX は、 W を増減させることで、時系列データの抽象度を変化させることができる. W が小さいほど、センサデータの抽象度は高くなり、 W が大きいほど、センサデータの抽象度は低くなる. 図 7 に SAX による抽象化の例 ($W = 4$) を示す.

文字の種類 W を変化させることで、割り当てられる文字の種類も変化するため、センサデータを抽象化した文字列の表現も変化する. 図 8 に、右折時の Y 軸角速度のセンサデータに SAX を適用する際の、 $W = 8$ のときの境界値を示す.

図 8 から、 W を増加させることで、より細かなセンサデータの変動がとらえられることが分かる. SAX は、正規分布に従って各文字の境界値を算出している. そのため、センサデータ値の中央値付近に割り当てられる文字の境界値が示す範囲ほど、範囲が狭くなる傾向がある. この傾向




図 7 SAX による抽象化の例
Fig. 7 An example of SAX.




図 8 右折時の Y 軸角速度と SAX における境界値 ($W = 8$)
Fig. 8 Sensor data of Y-axis angular velocity at turn right and boundaries on different conditions ($W = 8$).

は、右/左寄せ、右/左への車線変更といったセンサデータの変動が小さい運転行動の抽出に有用であると考えられる.

SAX を適用してセンサデータを文字列へ抽象化することにより、車両挙動を構成する運転行動を部分文字列として抽出し、それらの時系列的な順序を考慮することで、車両挙動を運転行動の時系列として表現する. また将来的にプローブ情報システムを想定すると、SAX を適用することは、メモリ消費や実行時間の削減、センサデータの容量の削減が見込めることができるため、システム構築の観点から見ても、有用性が高いと考えられる.

3.7 特徴的な部分文字列の抽出

3.6 節で述べた手順で SAX を適用してセンサデータを抽象化した文字列 (以下、センサデータ文字列) から、「出現頻度」に着目することで、車両挙動を構成する特徴的な部分文字列を抽出する. この特徴的な部分文字列の抽出は以下の手順で行う. 3.7.1 項以降で、各手順について述べていく.

- (I) センサデータのランレングス符号化
- (II) N-gram による部分文字列の抽出
- (III) 「出現頻度」に着目した特徴的な部分文字列の抽出

3.7.1 センサデータのランレングス符号化

図 9 に、センサデータデータ文字列のランレングス符号化による変換 (Step1-Step3) と部分文字列の抽出 (Step4) 様子を示す.

センサデータ文字列に対して、ランレングス符号化を行い、文字部分と数値部分へ変換する (図 9 における Step1-

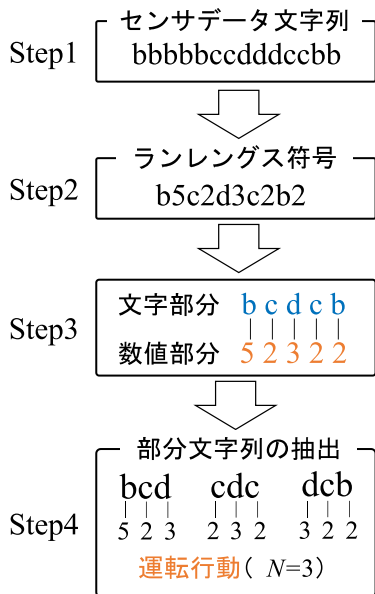


図 9 ランレングス符号化と部分文字列の抽出

Fig. 9 Run length encoding and extraction of partial character strings.

Step3). 本論文では、ランレングス符号の文字部分を用いることで、「出現頻度」の観点から特定の車両挙動を構成する運転行動に該当する部分文字列を抽出する。また、将来的には、ランレングス符号の文字部分とあわせて数値部分を用いることで、文字の連続数からセンサデータの変動の「時間長」を考慮して、各運転行動を表す特徴的な文字列を抽出することも期待できる。本論文では、「出現頻度」に着目し、分析手法の検討を行う。

3.7.2 N-gram による運転行動の抽出

車両挙動を運転行動の時系列として表現するために、ランレングス符号に対して N-gram を適用することで、車両挙動における各運転行動を部分文字列として抽出する (図 9 における Step4)。N-gram とは、 N 文字で構成される部分文字列を元の文字列から抽出する処理である。N-gram のパラメータとして、抽出する部分文字列の長さ N が存在する。N-gram によって抽出した部分文字列は、運転行動にあたる局所的なセンサデータと対応していると考えられる。そのため、各車両挙動のセンサデータから、各運転行動を抽出できると考えられる。

3.7.3 「出現頻度」に着目した特徴的な部分文字列の抽出

N-gram によって抽出した部分文字列を用いて、各車両挙動に対する BoW (Bag of Words) モデルを作成する。BoW モデルとは、文章に含まれる各単語の出現頻度により、文章を表現するという自然言語処理で用いられるモデルである。本研究では BoW モデルを用いることで、各車両挙動を、運転行動に対応する各部分文字列の出現頻度の分布により表現する。このとき、BoW モデルを構成する部分文字列の数が、特徴の次元数に対応する。図 10 に、部分文字列の長さ $N = 3$ のときの BoW モデルの例を示す。




図 10 BoW モデルの例 ($N = 3$)

Fig. 10 An example of BoW model.

各車両挙動において特徴的な運転行動を部分文字列として表現できているか、各車両挙動の BoW モデルを比較することで分析可能である。また、BoW モデルとして表現し、機械学習を適用することで車両挙動の推定が可能になる。

本論文では、車両挙動の推定に向けて、各車両挙動の BoW モデルから、車両挙動の推定に有効であると考えられる特徴的な部分文字列群の抽出を行う。以下の条件 C1、条件 C2 をともに満たした部分文字列を「特徴部分文字列」として定義する。

条件 C1 各車両挙動のセンサデータの 8 割以上で出現する。

条件 C2 他の車両挙動のセンサデータでは、出現しない。

まず、条件 C1 に関して、実環境を想定すると、同一の車両挙動でもセンサ値の微小な変動が異なる場合が考えられる。そこで、本研究では、8 割以上で出現する部分文字列は、その車両挙動において頻出する運転行動であると考え、その車両挙動に対する特徴的な部分文字列として扱うこととする。次に、車両挙動の推定には、特定の車両挙動にのみ出現する部分文字列が有効であると考えられる。そこで、特徴部分文字列の条件 C2 を、以上のように定義した。一方で、特定の車両挙動にのみ出現するわけではないが、各車両挙動の特徴を表している可能性がある部分文字列も、車両挙動の推定に有用性が高いと考える。そこで、特徴部分文字列の条件 C1 を満たすが、条件 C2 を満たさない部分文字列を「準特徴部分文字列」として定義する。

4. 実験および考察

4.1 センサデータの収集

センサデータ収集時の実験条件を表 1 に示す。

本論文では、図 6 に示すようにスマートフォンを設置し、センサデータを収集した。本研究で対象とする交通状況を構成する代表的な車両挙動として、直進、右折、左折、右車線変更、左車線変更の 5 種類を収集対象とした。本研究では、道路を一定間隔で区切った区間ごとで、交通状況把握を行うことを想定しており、また実環境に近いデータで車両挙動分析を行う必要がある。そこで、一般道における最高速度である時速 60 km/h に達した地点から 100 m 走行し、その区間内でペダル操作やハンドル操作を含んだ各車両挙動を行った際のセンサデータを、各車両挙動 20 回分

表 1 センサデータ収集時の実験条件

Table 1 Experimental conditions in collecting sensor data.

使用センサ	加速度, 角速度, GPS
サンプリングレート (加速度, 角速度)	50Hz
サンプリングレート (GPS)	1Hz
対象とする車両挙動	直進, 右折, 左折 右車線変更, 左車線変更
各車両挙動の収集回数	20 回
収集時の速度	60km/h
収集時の走行距離	100m
対象とする車両	TOYOTA パッソ (1 台)

表 2 提案手法における各種パラメータ

Table 2 Parameters in the proposed method.

SAX のパラメータ	
変換率 R	1/5
文字の種類 W	4,8,16
N-gram のパラメータ	
部分文字列の長さ N	1,2,3,4,5

について収集した。実験環境として、直進、右/左への車線変更は直線道路、右/左折は T 字路でセンサデータの収集を行った。道路の凹凸による振動の影響を考慮して、道路の舗装が整備された環境で実験を行ったため、本論文では道路の凹凸によるノイズの影響は考慮しないものとする。

4.2 「出現頻度」に着目した特徴的な部分文字列の抽出

提案手法を各車両挙動時 20 回分のセンサデータに適用し、各パラメータ値を設定した際の BoW モデルを作成した。今回、適用する各種パラメータ値を表 2 に示す。

SAX における文字の種類 W 、N-gram における部分文字列の長さ N をそれぞれ変化させ、各パラメータ値において、N-gram で抽出される全部分文字列から、3.7.3 項で定義した特徴部分文字列、準特徴部分文字列の抽出を行い、抽出された部分文字列から BoW モデルを作成した。特徴的な部分文字列（特徴部分文字列と準特徴部分文字列を指す）として抽出できる部分文字列の数が多いほど、交通状況把握に向けた車両挙動推定の際に有効と考えられる BoW モデルの特徴が多くなることを意味する。そこで、本論文では、BoW モデルにおける特徴的な部分文字列の抽出数に着目して、各種パラメータ値の検討を行う。本節では、右/左折などの左右方向に関する運転行動の影響が見られた Y 軸角速度に関する分析結果を述べる。

4.2.1 SAX における文字の種類 W に着目した分析

N-gram における部分文字列の長さ N の値を固定し、文

表 3 各車両挙動の特徴的な部分文字列の抽出数 ($N = 3$)

Table 3 Characteristic partial character strings of each vehicle behavior ($N = 3$).

車両挙動	特徴部分文字列数 (準特徴部分文字列数)		
	$W=4(a-d)$	$W=8(a-h)$	$W=16(a-p)$
直進	0 (2)	0 (2)	0 (5)
右折	右寄せ 0 (2)	0 (4)	0 (4)
	右折 0 (4)	3 (5)	5 (7)
左折	左寄せ 0 (2)	0 (2)	0 (6)
	左折 3 (2)	5 (4)	8 (5)
右車線変更	0 (2)	0 (5)	0 (7)
左車線変更	0 (2)	0 (5)	0 (8)

表 4 各車両挙動の特徴的な部分文字列の抽出数 ($N = 4$)

Table 4 Characteristic partial character strings of each vehicle behavior ($N = 4$).

車両挙動	特徴部分文字列数 (準特徴部分文字列数)		
	$W=4(a-d)$	$W=8(a-h)$	$W=16(a-p)$
直進	0 (2)	0 (2)	0 (6)
右折	右寄せ 0 (2)	0 (4)	0 (1)
	右折 0 (4)	4 (4)	5 (6)
左折	左寄せ 0 (2)	0 (1)	0 (2)
	左折 2 (0)	3 (0)	6 (0)
右車線変更	0 (2)	0 (3)	0 (4)
左車線変更	0 (2)	0 (3)	0 (0)

字の種類 W の値を変化させた際の、各車両挙動の特徴的な部分文字列の抽出数の傾向を分析した。

抽出結果として、文字の種類 W が多いほど、各車両挙動の特徴を部分文字列として抽出できる傾向が見られた。特徴部分文字列は、右折時と左折時にのみ出現し、 W が多いほど、特徴部分文字列の数が増加する傾向にあった。しかし、 $W = 4$ の場合は右折時においても、特徴部分文字列を抽出することができなかった。一方、準特徴部分文字列の数は、すべての車両挙動において、 $N = 1, 2, 3$ の場合は、 W が多いほど増加する傾向にあったが、 $N = 4, 5$ の場合は、 W が多いほど減少する、または変化しない傾向が一部で見られた。 $N = 3, 4$ の場合の特徴的な部分文字列の抽出結果を、表 3、表 4 に示す。

表 3、表 4 の結果になった理由として、文字の種類 W が増加するほど、センサデータ値の抽象度が下がり、より細かなセンサデータの変動がとらえられることが要因であると考えられる。図 11 は、文字の種類 W によるセンサデータ文字列の違いを表しており、右寄せによるセンサ値の変動部分を、 $W = 4$ の場合には文字列上で表現できていない。一方、 $W = 16$ の場合には減少部分、ピーク地点、増加部分というように、細かなセンサデータの変動を文字列上で表現できていると考えられる。

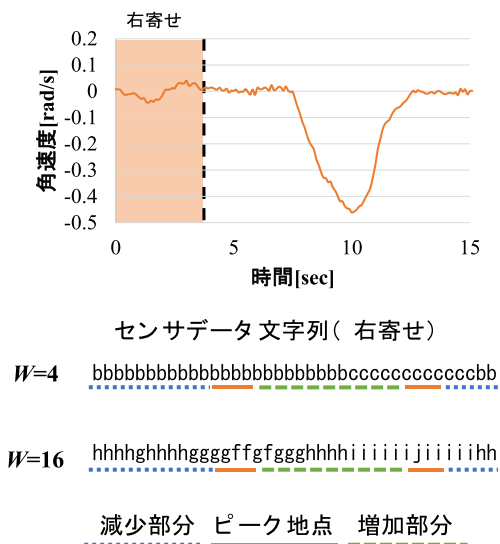


図 11 右折時における右寄せの Y 軸角速度のセンサーデータ文字列の様子

Fig. 11 Sensor data character string of Y-axis angular velocity on approach to the right at turn right.

以上の結果から、文字の種類 W については、 $W = 4$ の場合に、センサ値の変動が大きい右折を特徴部分文字列として抽出できなかった。よって、今回対象とした車両挙動の特徴を、特徴部分文字列としてより多く抽出するためには、今回の実験条件では $W = 8, 16$ が適していると考えられる。しかし、文字の種類 W にかかわらず、右/左への車線変更、右寄せ、左寄せといったセンサ値の変動が小さい運転行動は、特徴部分文字列を抽出することができない傾向が見られた。一方で、右/左への車線変更、右寄せ、左寄せの際に抽出された準特徴部分文字列に着目すると、同様な部分文字列が、これら複数の車両挙動間で抽出されている傾向が見られた。このことから、車両挙動推定に向けて、準特徴部分文字列を考慮することの有用性が示唆された。

4.2.2 N-gram における部分文字列の長さ N に着目した分析

SAX における文字の種類 W の値を固定し、部分文字列の長さ N の値を変化させた際に、各車両挙動の特徴的な部分文字列を抽出した結果を分析した。4.2.1 項の分析結果から、今回は $W = 8, 16$ の場合の各車両挙動の特徴的な部分文字列の抽出数の傾向を分析した。

抽出結果として、4.2.1 項と同様に、特徴部分文字列は、右折時、左折時にのみ出現した。傾向として、右折時は、特徴部分文字列が $W = 8, 16$ の場合は出現し、 $N = 1, 2, 3$ の場合は特徴部分文字列が一定数まで増加して、その後は変化しない傾向にあった。左折時は、特徴部分文字列が $W = 8, 16$ の場合に出現し、 $N = 1, 2, 3$ の場合は、特徴部分文字列が、 N が多いほど増加し、 $N = 4, 5$ の場合は、減少する傾向にあった。一方、準特徴部分文字列の数は、すべての車両挙動において、おおよそ $N = 1, 2, 3$ の場合まで

表 5 各車両挙動の特徴的な部分文字列の抽出数 ($W = 8$)
Table 5 Characteristic partial character strings of each vehicle behavior ($W = 8$).


車両挙動		特徴部分文字列数 (準特徴部分文字列数)				
		$N=1$	$N=2$	$N=3$	$N=4$	$N=5$
直進		0 (2)	0 (2)	0 (2)	0 (2)	0 (1)
右折	右寄せ	0 (3)	0 (4)	0 (4)	0 (4)	0 (2)
	右折	1 (4)	2 (6)	3 (5)	4 (4)	4 (4)
左折	左寄せ	0 (2)	0 (2)	0 (2)	0 (1)	0 (0)
	左折	2 (3)	4 (4)	5 (4)	3 (0)	2 (0)
右車線変更		0 (3)	0 (4)	0 (5)	0 (3)	0 (2)
左車線変更		0 (4)	0 (6)	0 (5)	0 (3)	0 (0)

表 6 各車両挙動の特徴的な部分文字列の抽出数 ($W = 16$)
Table 6 Characteristic partial character strings of each vehicle behavior ($W = 16$).

車両挙動		特徴部分文字列数 (準特徴部分文字列数)				
		$N=1$	$N=2$	$N=3$	$N=4$	$N=5$
直進		0 (3)	0 (4)	0 (5)	0 (6)	0 (3)
右折	右寄せ	0 (4)	0 (5)	0 (4)	0 (1)	0 (0)
	右折	3 (6)	5 (8)	5 (7)	5 (6)	5 (4)
左折	左寄せ	0 (4)	0 (6)	0 (6)	0 (2)	0 (0)
	左折	4 (5)	8 (8)	8 (5)	6 (0)	4 (0)
右車線変更		0 (6)	0(10)	0 (7)	0 (4)	0 (0)
左車線変更		0 (7)	0(12)	0 (8)	0 (0)	0 (0)

は増加し、その後、減少する、または変化しないという傾向を示した。また、 $N = 4, 5$ の場合は、特徴部分文字列、準特徴部分文字列が 1 つも抽出できない傾向が一部で見られた。抽出結果を、それぞれ表 5、表 6 に示す。

表 5、表 6 より、 $N = 1, 2, 3$ の場合は特徴部分文字列の数、準特徴部分文字列の数が基本的には増加傾向を示しており、 N が長いほど特徴的な部分文字列を抽出できる傾向にある。しかし、 $N = 4, 5$ の場合は、特徴部分文字列、準特徴部分文字列が減少する傾向や、特徴部分文字列、準特徴部分文字列が抽出できない傾向が見られた。これは、 $N = 1, 2, 3$ の場合が、比較的、各車両挙動による局所的なセンサデータの変動を抽出しやすいことが考えられる。たとえば、 $N = 1, 2, 3$ の場合は、図 12 のようにセンサ値の変動部分を、減少部分、ピーク地点、増加部分に該当する部分文字列に分割して抽出を行っていると考えられる。一方で、 $N = 4, 5$ の場合は、センサ値の変動部分を 1 つの部分文字列として抽出を行っていると考えられる。したがって、 $N = 1, 2, 3$ の場合の方が、特徴的な部分文字列を抽出できると考えられる。このことから、今回対象とした車両挙動の特徴を抽出するためには、 $N = 1, 2, 3$ が適している



センサデータ変動文字列 (右折)




図 12 部分文字列の長さ N による部分文字列の様子
 Fig. 12 An overview of partial character strings.

と考えられる。

4.3 車両挙動推定に向けた提案手法の有効性の検討

提案手法により作成した BoW モデルを用いた機械学習により、4.1 節において収集対象とした 5 つの車両挙動の分類実験を行った。以下に、検討事項を示す。

検討事項 1. BoW モデルによる車両挙動推定の実現性

検討事項 2. 「出現頻度」に着目した特徴抽出の有効性

検討事項 1 に関しては、提案手法により作成した BoW モデルによる車両挙動推定の実現性を、各車両挙動の BoW モデルの分類精度から検討を行う。検討事項 2 に関しては、提案手法による「出現頻度」に着目した特徴的な部分文字列の抽出の有効性について、特徴的な部分文字列の抽出を行う前と抽出後の BoW モデルによる分類精度の比較を行うことで検討する。

実験に用いるセンサデータは、4.1 節で収集したものを使用し、右/左折などの左右方向に関する運転行動の影響が見られた Y 軸角速度、加減速などの前後方向に関する運転行動の影響が見られた Z 軸加速度を用いる。また、提案手法における各種パラメータは、4.2 節の実験結果に基づいて設定した。本実験における各種パラメータを表 7 に示す。

提案手法では、各車両挙動の特徴の抽出に適した文字の種類 W の設定が重要である。そこで本論文では、 $W = 4, 8, 16$ のそれぞれの場合で BoW モデルを作成し、分類精度の比較を行う。また本論文では、 $N = 1, 2, 3$ のすべての場合で抽出される部分文字列を特徴として用いる。

各車両挙動の BoW モデルの分類精度の評価には、RBF カーネルを用いた SVM (Support Vector Machine) によって分類器を構築し 5 分割交差検定を行い、分類精度の評価指標として F 値 ($F\text{-measure}_{total}$) を用いた。車両挙動ラベル $L = \{\text{直進, 右折, 左折, 右車線変更, 左車線変更}\}$ に

表 7 分類実験に用いる各種パラメータ

Table 7 Parameters in the classification experiment.

SAX のパラメータ	
変換率 R	1/5
文字の種類 W	4,8,16
N-gram のパラメータ	
部分文字列の長さ N	1,2,3




図 13 条件別の F 値の比較 (Y 軸角速度)

Fig. 13 Comparison of F-measure by condition (Y-axis angular velocity).

対する F 値を $F\text{-measure}_{total}$ 、各車両挙動ラベル L_i の F 値と適合率、再現率をそれぞれ $F\text{-measure}_{L_i}$ 、 $Precision_{L_i}$ 、 $Recall_{L_i}$ とし、式 (1) から式 (4) を用いて計算する。

$$F\text{-measure}_{total} = \frac{\sum_{i=1}^5 F\text{-measure}_{L_i}}{5} \quad (1)$$

$$F\text{-measure}_{L_i} = \frac{2 \times Precision_{L_i} \times Recall_{L_i}}{Precision_{L_i} + Recall_{L_i}} \quad (2)$$

$$Precision_{L_i} = \frac{\text{推定結果の中で実際に } L_i \text{ である数}}{L_i \text{ と推定された数}} \quad (3)$$

$$Recall_{L_i} = \frac{L_i \text{ と推定された数}}{\text{実際に } L_i \text{ である数}} \quad (4)$$

RBF カーネルを用いた SVM によって分類器を構築する際には、コストパラメータ ($cost$) と RBF カーネルパラメータ ($gamma$) を適切な値に設定する必要がある。本論文では、複数のパラメータ値の組合せで分類器を構築して 5 分割交差検定による F 値を算出し、最も F 値が高くなるパラメータ値の組合せを設定した。以降の実験では、F 値として、 $F\text{-measure}_{total}$ の値を示す。

4.3.1 左右方向に関する運転行動に対する実験結果

本項では、右/左折などの左右方向に関する運転行動の影響が見られた Y 軸角速度に対する実験結果を述べる。図 13 に条件別の F 値を示す。

図 13 における「全パターン」は、N-gram により抽出されたすべての部分文字列を使用しており、「提案手法」は、すべての部分文字列から「出現頻度」に着目して抽出された特徴的な部分文字列 (特徴部分文字列と準特徴部分文字列を指す) を使用している。本実験では、これらの部分文字列からそれぞれ BoW モデルを作成し、車両挙動の分類に用いるが、BoW モデルを構成する部分文字列の数が分




図 14 条件別の F 値の比較 (Z 軸加速度, 車両挙動の分類)

Fig. 14 Comparison of F-measure by condition (Z-axis acceleration, classification of vehicle behavior).

類のための特徴量の次元数に対応する。

結果として、まず Y 軸角速度に関する提案手法の F 値は、文字の種類 $W = 8, 16$ の場合において 0.8 以上となった。このことから検討事項 1 に関しては、BoW モデルに左右方向に関する車両挙動の特徴を反映できていることが示唆された。

次に、図 13 から提案手法により「出現頻度」に着目して抽出された部分文字列を用いた場合の F 値が、「全パターン」用いた場合の F 値と同程度になるという結果となった。BoW モデルの特徴の次元数に着目すると、「全パターン」の場合では、 $W = 8, 16$ のときに、それぞれ 68 次元、255 次元であるのに対して、「提案手法」の場合では、 $W = 8, 16$ のときに、それぞれ 38 次元、75 次元となり、「提案手法」の BoW モデルの方が特徴の次元数が少ない傾向にあった。このことから、検討事項 2 に関して、提案手法による「出現頻度」に着目した特徴抽出によって特徴の次元数を削減した場合でも、車両挙動の特徴を維持できていると考えられるため、提案手法は有効であることが示唆された。

4.3.2 前後方向に関する運転行動に対する実験結果

本項では、加減速などの前後方向に関する運転行動の影響が見られた Z 軸加速度に対する実験結果を述べる。図 14 に条件別の F 値を示す。

まず Z 軸加速度に関する車両挙動の分類精度は、 $W = 4, 8, 16$ において「全パターン」、「提案手法」のいずれにおいても F 値が 0.8 以下となり、高い分類精度とはいえない結果となった。しかし、センサデータ収集時には前後方向に関する運転行動として、右左折時にのみ加減速を行うという条件を設定した。そのため、今回使用したセンサデータ上には、車両挙動間で加減速において違いが現れないため、図 14 のような分類精度になったと考えられる。そこで、加減速あり (右折, 左折) と加減速なし (直進, 右車線変更, 左車線変更) の 2 ラベルに再分類すると、図 15 に示す F 値となる。F 値は、文字の種類 W にかかわらず 0.9 以上となり、加減速の有無という観点からは精度が高い結果となっている。このことから検討事項 1 に関しては、加減速の有無という観点では、BoW モデルによ




図 15 条件別の F 値の比較 (Z 軸加速度, 加減速の有無の分類)

Fig. 15 Comparison of F-measure by condition (Z-axis acceleration, classification of acceleration/deceleration).

て車両挙動の特徴を反映できていることが示唆された。

次に、図 15 より「提案手法」の F 値が、「全パターン」用いた場合の F 値と同程度に高い精度で分類できていることが分かる結果となった。BoW モデルの特徴の次元数に着目すると、「全パターン」の場合では、 $W = 4, 8, 16$ のときに、それぞれ 45 次元、219 次元、919 次元であるのに対して、「提案手法」の場合では、 $W = 4, 8, 16$ のときに、18 次元、46 次元、63 次元となり、「提案手法」の BoW モデルの方が特徴の次元数が少ない傾向にあった。このことから、検討事項 2 に関して、提案手法による「出現頻度」に着目した特徴抽出によって、特徴数を減らした場合でも、車両挙動の特徴を維持できていると考えられるため、提案手法は有効であると考えられる。

4.3.3 考察

4.3.1 項, 4.3.2 項の実験結果により、検討事項 1 の BoW モデルによる車両推定の実現性、検討事項 2 の「出現頻度」に着目した特徴抽出の有効性を確認することができた。

まず、検討事項 1 に関して、Y 軸角速度に関しては 5 つの車両挙動に関する特徴、Z 軸加速度に関しては加減速の有無を BoW モデルに反映することができていると考えられる。Y 軸角速度に関しては、センサ値の変動が大きい右左折が特徴部分文字列として抽出されていたが、右/左への車線変更、右寄せ、左寄せといったセンサ値の変動が小さい運転行動は特徴部分文字列として抽出されていなかった。しかし今回の実験では、右左折と右/左への車線変更を精度よく分類できていることから、本研究における準特徴部分文字列がそれぞれの車両挙動の特徴を表現していると考えられる。そのため、本研究における車両挙動推定では、特徴部分文字列だけでなく、準特徴部分文字列を利用することが有用であることが示唆された。Z 軸加速度に関しては、本論文に掲載していないが、減速に関する部分文字列が特徴部分文字列として抽出されていた。このことから、加減速の有無という観点で分類することができたと考えられる。

次に、検討事項 2 に関して、Y 軸角速度、Z 軸加速度、ともに、「出現頻度」に着目した特徴抽出後に F 値を同程

度に維持できていることから、提案手法による特徴抽出は有効であることが示唆された。

4.4 今後の課題

今後の課題として、主に4つの課題があげられる。

まず1つ目の課題として、運転行動の時系列性を考慮した車両挙動の推定に向けて、まず各車両挙動を構成するすべての運転行動を特徴的な部分文字列として抽出することがあげられる。今回の提案手法では右/左への車線変更、右寄せ、左寄せといったセンサ値の変動が小さい運転行動を、特徴部分文字列として、明示的に特徴的な部分文字列として扱うことができていない。将来的には、運転行動の時系列性を考慮して車両挙動推定を行うことで、右/左折待ちの車列や乗降中のバス待ちの車列といった、後続車のドライバーが急な減速や車線変更を強いられる交通状況の把握を目指している。よって、センサ値の変動が小さい運転行動を明示的に特徴的な部分文字列として扱うことが、車両挙動推定の交通状況把握への応用を検討する際には必要であると考えられる。今回は「出現頻度」に着目したが、センサデータの変動の「時間長」を考慮して特徴部分文字列を抽出することで、各運転行動（ハンドル操作やペダル操作）にかかる時間の違いを特徴として考慮することができると考える。

次に2つ目の課題として、車両挙動の推定に向けて、今回抽出した部分文字列間の関係を分析し、複数のセンサデータにおける運転行動の時系列性を部分文字列間の関係として表現する必要がある。本論文では、SAXによるセンサデータの抽象化のアプローチの車両挙動の推定に対する有効性を検討するために、それぞれのセンサデータに対して提案手法を適用して評価を行った。部分文字列の時系列的な順序関係を利用することで、複数のセンサデータを統合して扱うことが、車両挙動推定手法には必要であると考えられる。

3つ目の課題として、多様性への対応があげられる。本研究ではプローブ情報システムを想定しており、多数の車両から大量のセンサデータを収集し、ドライバーに有益な情報として加工・提供するために、サンプリングレートの違いや車種の違いなど様々な多様性を吸収する必要がある。たとえば、今回の実験ではサンプリングレート50Hzでデータ収集を行っており、50Hzより低いサンプリングレートでデータ収集を行う場合には車両の動きにともなうセンサデータの変動をとらえられない可能性がある。一方で、50Hzよりサンプリングレートが高い場合には、計測されるセンサデータの数値軸上のデータ分布が同様になると考えられるため、提案手法の特性上、ある運転行動に対して、ランレングス符号化の数値部分が異なるだけで同様の文字列が得られる可能性がある。したがって、サンプリングレートの多様性を吸収できる可能性があるが、実際に

サンプリングレートを变化させたデータ収集、データ分析を行いたいと考えている。また、今回の実験では車両1台のみでデータ収集を行ったが、車種が異なる場合には、車両サイズや車両特性の影響により、同一の車両挙動でも、センサ値の変化が異なり、車両挙動に対する文字列が異なる可能性がある。今後は、こうした車種の多様性についての検討も進めていきたい。

最後に、4つ目の課題として、本研究が目指す交通状況提供システムの有効性の評価があげられる。図5に示す交通状況提供システムを構築するにあたり、情報提供を行うサーバ側にとって、SAXの利点としてあげた実行時間の削減、センサデータの容量の削減などが、どの程度影響しているのかを評価する必要がある。また、応用の観点から、ドライバーの快適な運転に向けて、どのようなタイミングで提示を行うのがよいのか、交通状況予測結果の適切な提示のタイミングについて、今後多数の車両からの挙動データの収集を進めることで検討を進めていきたいと考えている。

5. まとめ

本論文では、交通状況を形成する車群の挙動（時間的変化）の把握による交通状況把握の要素技術として、運転行動の時系列性を考慮した車両挙動分析手法を提案した。提案手法では、車載スマートフォンから収集したセンサデータにSAXを適用することで、時系列データを文字列へ変換し、自然言語処理技術を用いることで、車両挙動の分析を行った。提案手法による車両挙動分析により、左右方向における運転行動を表す部分文字列の抽出には、今回の実験条件においてSAXにおける文字の種類 W は $W = 8, 16$ 、N-gramにおける部分文字列の長さ N は $N = 1, 2, 3$ が適していることが示唆された。また、提案手法で抽出された特徴的な部分文字列が、各車両挙動における特徴的な運転行動を表しているか、SVMによる車両挙動分類を行うことで検討を行った。その結果、提案手法により抽出された特徴的な部分文字列から構成されるBoWモデルによる車両挙動推定が実現可能であること、提案手法による「出現頻度」に着目した特徴抽出が有効であることが示唆された。

謝辞 本研究はJSPS科研費JP17K00128の助成を受けたものである。

参考文献

- [1] 植原啓介：プローブ情報システム：車載センサを活用した環境情報の取得、情報処理, Vol.51, No.9, pp.1144-1149 (2010).
- [2] 一般財団法人道路交通情報通信システムセンター：VICS | 一般財団法人道路交通情報通信システムセンター、入手先 (<http://www.vics.or.jp/index1.html>) (参照2018-04-10).
- [3] 和田健太郎, 小林桂子, 桑原雅夫：プローブ車両軌跡データのみを用いた交通の量的把握, 生産研究, Vol.67, No.2, pp.143-147 (2015).

- [4] 三輪富生, 山本俊行, 竹下知範, 森川高行: プローブカーの速度情報を用いた動的 OD 交通量の推定可能性に関する研究, 土木学会論文集 D, Vol.63, No.2, pp.252-265 (2008).
- [5] 丹下智之, 廣森聡仁, 梅津高朗, 山口弘純, 東野輝夫: 一部の車両軌跡情報および信号パラメータを用いた OD 交通量の推定手法, 情報処理学会研究報告, Vol.2016-ITS-64, No.5, pp.1-8 (2016).
- [6] 伊藤亮輔, 石原 進: 車載カメラ撮影映像提供システムにおける位置指定要求に対する映像選択方法, 情報処理学会論文誌, Vol.58, No.1, pp.79-88 (2017).
- [7] 玉井森彦, 尾上佳久, 安本慶一, 福倉寿信, 岩井明史: 画像処理に基づいた効率のよい渋滞動画の収集・共有方式, 情報処理学会研究報告, Vol.2013-MBL-65, No.36, pp.1-8 (2013).
- [8] バイオニア株式会社: サイバーナビ | カーナビ・カー AV (carrozzeria) | バイオニア株式会社, バイオニア株式会社 (オンライン), 入手先 (<https://jpn.pioneer/ja/carrozzeria/carnavi/cybernavi/?ref=header>) (参照 2018-09-12).
- [9] 柏倉俊樹, 三宮千尋, 田中雄介, 栗原慶典, 那和一成: Bag of Systems を用いた運転行動解析, 情報科学技術フォーラム講演論文集, Vol.14, No.1, pp.159-162 (2015).
- [10] 谷口忠大, 山下元気, 長坂翔吾, 坂東誉司, 竹中一仁, 人見謙太郎: 運転時系列のベイズ二重分節解析によるチャンク抽出, 計測自動制御学会論文集, Vol.49, No.11, pp.1047-1056 (2013).
- [11] 岡田将吾, 人見謙太郎, ワイナイ P. チャンドラシリ, 呂有為, 新田克己: 車載センサログの時系列データマイニングに基づく運転挙動の分析, 情報科学技術フォーラム講演論文集, Vol.11, No.4, pp.387-390 (2012).
- [12] 根山 亮, 福島真太郎, 宮崎勝彦, 那和一成: 一般道実走行における自車センサ情報を用いた車線変更の検出, 情報処理学会, 第 8 回 Web とデータベースに関するフォーラム論文集, Vol.2015, pp.110-117 (2015).
- [13] Chen, D., Cho, K. and Han, S.: Invisible Sensing of Vehicle Steering with Smartphones, *Proc. MobiSys'15*, pp.1-13, ACM (2015).
- [14] Chaovalit, P., Saiprasert, C. and Pholprasit, T.: A Method for Driving Event Detection Using SAX with Resource Usage Exploration on Smartphone Platform, *EURASIP Journal on Wireless Communications and Networking*, Vol.2014, pp.1-11 (2014).
- [15] Lin, J., Keogh, E., Lonardi S., et al.: A Symbolic Representation of Time Series, with Implications for Streaming Algorithms, *SIGMOD Workshop*, pp.2-11 (2003).
- [16] 宮城優里, 大西正輝, 渡辺知恵美, 伊藤貴之: 文字列化による人流データの圧縮と可視化, DEIM Forum 2015, F8-5 (2015).

推薦文

本論文では、運転行動を推定するために運転手の時系列の運転行動を抽象化して自然言語処理技術を適用し、効率的に解析する手法が示されている。提案手法は高い新規性を有し、評価を通じてその有用性を検証している。高度交通システムに関する研究者にとって有用な手法であり、質の高い論文となることが期待できる。また DICOMO2017 の発表論文の中で特に評価が高かったため本論文を推薦する。

(高度交通システムとスマートコミュニティ研究会主査
清原良三)



横山 達也 (学生会員)

平成 29 年公立ほこだて未来大学システム情報科学部情報アーキテクチャ学科卒業。現在、同大学大学院システム情報科学研究科システム情報科学専攻博士前期課程在学中。モバイルセンシング、高度道路交通システムに関する

研究に従事。



白石 陽 (正会員)

平成 14 年慶應義塾大学大学院理工学研究科博士課程単位取得退学。東京大学空間情報科学研究センター研究機関研究員、助手、助教を経て、平成 21 年より公立ほこだて未来大学助教。平成 28 年より同大学教授。博士 (工学)。

センサネットワーク、データベース、高度交通システムに関する研究に従事。ACM, 電子情報通信学会, 地理情報システム学会等各会員。