

ランダムフォレストによる路線バス運行状態分類

米澤 拓也 新井 イスマイル^{1,a)} 秋山 豊和² 藤川 和利¹

受付日 2018年5月7日, 採録日 2018年11月7日

概要: バス運行業者が導入しているデジタルタコグラフで記録されている運行・回送・休憩といった車両状態は現状、運転者の手入力に依存しており、運転者の負担が大きい。本研究では、デジタルタコグラフから得られる車速・エンジン回転数や、GPS等から得られるセンサデータを機械学習することで、バスの運行状態の自動分類を試みる。センサデータに加えて、それらを加工して得た、停留所・事業所までの距離等の特徴量をランダムフォレストの入力とする自動分類手法を提案・実装し、2路線の実運行データで評価した結果、同一路線モデルにおいて92.9%の正答率を得た。このモデルにおいて運行ごとの運転者の手入力データと比較した結果、運転者による手入力よりも提案手法が4.1%~16.9%高い正答率を得た。

キーワード: IoT, ITS, 機械学習, センサデータ, 公共交通データ

Classification Method for Bus Operation States Based on Random Forest

TAKUYA YONEZAWA ISMAIL ARAI^{1,a)} TOYOKAZU AKIYAMA² KAZUTOSHI FUJIKAWA¹

Received: May 7, 2018, Accepted: November 7, 2018

Abstract: The state of the bus such as operation, forwarding, and break recorded in the digital tachograph depends on the manual input by the driver, and the drivers suffer from the burden. In this research, we attempt automatic classification of bus operation status by machine learning of vehicle speed/engine speed, GPS, and etc., which are obtained from digital tachograph, GPS, and etc. In addition to the raw sensor data, we propose additional features such as a distance to a bus stop, a distance to the business office, a distance to a car wash place, and etc., which are obtained by processing the raw data. As a result of the experiments in the real two routes, we obtained a correct answer rate of 0.929 in the same route model. Furthermore, the proposed method gained 4.1% to 16.9% higher correct answer rate than the manual input by the drivers.

Keywords: IoT, ITS, machine learning, sensor data, public transportation data

1. はじめに

2016年1月15日、長野県北佐久郡軽井沢町の国道18号碓氷バイパス付近で、定員45人の観光バスがガードレールをなぎ倒し、道路脇に転落するという事故が発生した。本事故において、乗員2人・乗客39人中14人が死亡、生存者も全員が重軽傷を負い、バス事故としては過去30年

の中で最多の死者が出る事故となった[1]。本事故の原因として、下記の2つがあげられる。

(1) 旅客運送業の人手不足による労働環境の悪化

日本バス協会は、満60歳以上の高齢運転手を雇用している事業者は648社で、13,908人が雇用されていると報告している[2]。また、満60歳以上の運転手が占める割合は全体の17.4%と、運転手の6人に1人以上であると報告している[2]。一方で、国土交通省はバス事業者数について、2000年の規制緩和を受け、事業者数は2000年度の3,308社から、2015年度には6,725社の約2倍に増加したと報告しており[3]、人出不足に拍車がかかっていることが明らかである。

¹ 奈良先端科学技術大学院大学総合情報基盤センター
Information Initiative Center, Nara Institute of Science and Technology, Ikoma, Nara 630-0192, Japan

² 京都産業大学コンピュータ理工学部
Faculty of Information Science and Engineering, Kyoto Sangyo University, Kyoto 603-8555, Japan

a) ismail@itc.naist.jp

(2) 運行管理者*1の管理不足

国土交通省はバスの運行会社に対し特別監査を行った結果、連続運転時間等道路運送法の基準に違反する記録があったと報告した。この理由として、バス事業者数の増加による収益の低下やノウハウの不足があげられる。市場競争の激化により多くのバス事業者の収益は悪化し、運行管理者の負担が増加している。規制緩和後に新規参入した運送事業経験のない事業者や、小規模事業者には運行管理のノウハウがないもの、法令を承知していない事業者が多いことが運行管理不足の原因になっていると考えられる [4]。また、本事故を受けて運輸規則の改正が実施され、運行管理者の態勢・責任は大幅に強化された [5]。このような背景から、運行管理者の負担は今後も増加していくと考えられる。

上記の背景より、旅客運送業において運行管理者が安全管理・運行管理の観点から、運行中や回送中といったバスの運行状態を正確かつリアルタイムに把握することが重要となる。また、車両の運行状態をリアルタイムに把握することで、運行管理者側からの運転者の管理が可能となり、運行管理を効率化することが可能になると考えられる。

このような課題を解決すべく、旅客運送業において IoT (Internet of Things) 技術の導入が期待されている。そのツールの一つとしてデジタルタコグラフがある。これは、従来から運送業の車両に取り付けが義務化されていた、車速・エンジン回転数を円盤状の紙媒体に記録し、運行後の運転状況確認や安全運転指導に役立てるタコグラフという装置をデジタル化したものである。従来の (アナログ) タコグラフをデジタル化しつつ、GPS や車速センサ、ドライブレコーダ等を接続した端末が研究開発されており、これをネットワーク接続することで、センサデータをリアルタイムに運行管理者に伝えることが可能になりつつある。しかしながら、先ほど取り上げた車両の運行状態については、運転者の手入力に頼る現状があり、運行管理者にとって負担が軽減されつつも、運転者の負担が増加する問題がある。

そこで、本論文ではデジタルタコグラフで自動収集されたセンサデータを機械学習によってバスの運行状態を自動分類する課題に取り組む。実際に兵庫県神戸市内を運行する 2 路線において、車速、回転数や GPS 等によって得られるセンサデータとそれらを加工して得た停留所・事業所までの距離等の特徴量をランダムフォレストによって機械学習し、評価した結果、同一路線モデルを用いた場合に 92.9% の正答率が得られた。また、運転者 3 名の手入力結果と比較したところ、4.1%~16.9% 高い正答率を得た。

本論文の貢献は以下のとおりである。

(1) 高精度な運行状態分類性能を確認

上述のとおり、提案する特徴量によって 92.9% の正答率を得た。

(2) 運転者の運行状態入力作業を不要化

提案手法が、運転者の正解率を 4.1%~16.9% 上回ったため、機械に置き換え可能な作業であることを確認した。

(3) 低コストに運用可能

ランダムフォレストは本研究で対象とする多クラス分類問題の学習・分類作業のどちらにおいても、他の機械学習アルゴリズムと比べて、計算機資源を多く必要としない。また、詳細は本文で述べるが、提案手法ではセンサデータ以外に必要な情報がバスが停車するような事業所、停留所の位置のみとなっており、学習に必要なデータの準備作業コストが低い。

2. 旅客運送業の課題と IoT 化の期待

旅客運送業は深刻な人材不足の問題を抱えつつ、規制緩和による競争の激化にさらされており、業務効率の向上が喫緊の課題となる。昨今、研究開発がさかんな自動運転はこれらの課題の抜本的な解決策として期待が高まっているが、実運用の目処が立っていないため、現状においては旅客運送業に携わるそれぞれの就業者を支援する情報システムの導入が現実的である。

従来より、運送業の車両にはタコグラフと呼ばれる車速・エンジン回転数を円盤状の紙媒体に記録し、運行後に運行管理者が運転者の運転状況を確認し、運転指導に役立てるシステムが用いられてきたが、分析手段が目視作業となっており、またリアルタイムな状況把握が困難であった。これに対して、デジタルタコグラフと呼ばれる (アナログ) タコグラフを電子化する機器が登場し、車速・エンジン回転数だけでなく、GPS や総走行距離 (ODO)、ドライブレコーダの映像、各種センサデータをデジタルデータとして蓄積し、可視化・分析の自動化が実現されつつある。さらに、デジタルタコグラフをインターネット接続することで、リアルタイムに運行中の運転者・車両の情報を運行管理者が把握することができるため、事故等の問題を未然に防ぐことも期待できる。

バスの IoT 化によって期待される具体的な成果は、慢性的な運行遅延の原因解明・対策、乗客の偏りの把握と適切な配車計画の支援、運転者の運転・休息割合の確認による健康管理、運転者の急病・迷惑乗客の発見と迅速な対処、危険運転の検知・自己の未然防止等、多岐にわたる。人材不足の旅客運送業においてこれらを人手で行うことは考えにくく、経営者にとってもコスト面の問題がクリアできれば IoT 導入の了解性は高い。

本論文では特に、上記分析の基底と考えられるバスの運行状態のリアルタイム把握に着目する。研究フィールド提

*1 運行管理者：運転者の乗務割の作成、休憩・睡眠施設の管理、運転者の指導監督、点呼による運転者の疲労・健康状態等の把握や安全運行の指示等、事業用自動車の運行の安全を確保するための業務を行う者。

供の協力を得ている、みなと観光バス株式会社やデジタルタコグラフの販売業者へのヒアリングを行ったところ、把握したいバスの状態は表 1 (運行状態については細分化して表 2 とする) のようにまとめられた。状態遷移図は図 1 のとおりである。現存するデジタルタコグラフを用いると、これらの情報は運転者の手入力が必要となっており、運行管理者にとっては負担は軽減するが運転者の負担が増加してしまっている。端末操作数が増えることはモチベーションの低下だけではなく、操作の正確性を低下させる懸念がある。

現状のデジタルタコグラフで抱える、旅客運送業のそれぞれの立場における課題を以下にまとめる。

- 運転者
 - IoT 導入における端末操作の負担増
 - 従前より存在する運行報告業務の負担
 - 運行管理者
 - ドライバーが記録する運行履歴の正当性の確保
 - 経営者
 - IoT 機器導入にともなうコスト増
- 以上をふまえると、運転者の負担を増加させずに運行管

表 1 運行管理者の求めるバスの運行状態分類
Table 1 Bus states required by operation managers.

状態名	定義
点検	運行開始前の点検作業中である
洗車	洗車作業中である
配車	点検後に停留所に向けて移動中である
待機	初めの停留所においてエンジンが OFF
運行	バスが運行中である
休憩	4 時間未満の休みでありエンジンが OFF
回送	運行を終了し、事業所へ移動している
給油	ガソリンスタンド内において停車中である
帰庫	事業所内において停車中である

表 2 「運行」状態の詳細
Table 2 Details of the state “In Service.”

状態名	詳細	定義
運行	バス停停車	バス停において停車中である
	バス停発着中	バス停付近で発着中である
	走行中	バスが走行中である

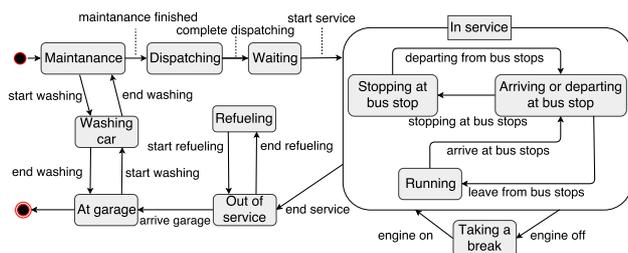


図 1 路線バス業務の流れ

Fig. 1 Flow of a route bus operation.

理者が望む運行状態をリアルタイムに得るには、運行状態を自動的かつ正確に推定することが必要となり、一方で導入する計算機資源費用や運用・導入のコストは抑える必要がある。

3. バス運行状態自動分類手法の検討

デジタルタコグラフで収集可能なセンサデータを活用して、バスの運行状態を自動分類する手法を検討する。センサデータは、製品によって取得可能な種類が異なるが、総走行距離や、従来のタコグラフで記録されていた車速とエンジン回転数、またカーナビゲーションシステム等の車載機で一般的に搭載されていると考えられる GPS および車速パルス・ジャイロセンサを用いた自律航法システムから得られる緯度、経度、高度、方位は一般的に共通して得られるため活用可能とする。なお、取得頻度についてはデジタルタコグラフの記録基準が 2Hz と定められているため、それに従う。これはあくまでオフラインで蓄積する場合の基準だが、筆者らの研究環境においてこの頻度で LTE 回線経由でリアルタイム送信しても回線状況が正常なときには取りこぼしがなかったため間引かない前提とする。

比較検討の結果は表 3 のとおりとなり、本論文ではランダムフォレストを採用することとした。学習コストは学習フェーズに要する計算機資源・計算時間が少ないことを示す。学習の適切な頻度は不明だがオンライン学習が必要となる場合も想定して考慮することとする。なお、推定コストは本研究の分類問題に対してはハードウェアの選定に差が出るほどの大差はないと判断し、比較項目に含まない。クラスの一意性は 1 つの入力に対して推定される状態が 1 つであること、ノイズ耐性はセンサの誤差の耐性があること、安定性はハイパパラメータや使う学習データによって性能が大きく左右されないこと、構築容易性はモデルの構築が容易であることを示す。以下に各手法の考察をまとめる。

3.1 ルールベース (RB)

センサデータを IF-THEN 形式によって判断して手作業で決定木を作成する。比較手法の中で計算量は最も少ないが、ルールに適合しない状態を処理できなかつたり、事前にセンサデータのパターンをすべてルール化することの困

表 3 分類手法の比較

Table 3 Comparison among classification methods.

	RB	RF	SVM	HMM	CNN	LSTM
学習コスト	○	○	△	○	×	×
クラスの一意性	○	○	△	○	○	○
ノイズ耐性	×	○	○	×	○	○
安定性	○	○	○	×	×	×
構築容易性	×	○	○	×	○	○

難さや、車両状態の追加や削除に柔軟に対応できない問題がある。

3.2 ランダムフォレスト (RF)

複数の決定木 (decision tree) を利用した多クラス分類手法である。決定木をアンサンブル学習における弱学習器の1つとして取り扱う。個々の学習器としての精度は高くないが、複数の決定木の結果を統合し、評価することによって高い予測性能を得ることが可能となる [6]。長所を下記にまとめる。

- 大きいデータセットにも効率的に動作する。
- 変数の数が大きい場合でも安定して動作する。
- 識別に用いる変数の重要度を算出することが可能。
- 欠損値を含むデータについても学習・識別が可能。

複数の決定木を作成し、バギングする過程が存在するため、データ数が少ないとうまく学習ができないという欠点がある。

3.3 サポートベクターマシン (SVM)

教師あり学習を用いる2クラス分類器の1つである。SVMでは、カーネル関数を用いて与えられたデータを高次元へと写像し、写像した空間において、2クラス間のマージンが最大となる識別境界を求める。これらから、SVMは高い汎化能力を持ち、大きな次元を持つ学習データを利用しても過学習を起こすことが少ないといわれている。通常の2クラスSVMを複数組み合わせることで、多クラス分類器を実現する手法が提案されている。

- one-versus-one (1対1) 方式

K 個のクラスの組合せについて2クラスSVMを学習し、その結果得られた $K(K-1)/2$ 個の分類器を適用して、最も多くの分類器が正例として投票したクラスを分類結果とする方法である。しかし、この方式では分類器がそれぞれ異なるクラスを推定した場合に、分類クラスが一意に定まらない可能性がある。とはいえ、候補の絞り込みとして機能するため、その候補から一意のクラスに特定できれば有用となる。しかし、 K の値が大きい場合、学習や予測にかかる計算時間がクラス数の2乗に比例し、大きいという欠点がある [7]。

- one-versus-rest (1対多) 方式

K 個のクラスがあるときにあるクラス C_k に属するデータを正例、それ以外のデータを負例として K 個の別々の $SVM_{y_k}(x)$ を学習する方法である。この方式では、個々のSVMによる予測が矛盾し、1つの入力に同時に複数のクラスが割り当てられる可能性があり [7]、その場合には上記1対1方式と同様、候補から一意のクラスに特定できれば有用となる。計算量はクラス数に比例して増加するため、クラス数が多い場合は当方式でも欠点となる。

3.4 隠れマルコフモデル (HMM)

HMMは、隠れ変数のあるマルコフモデルのことであり、音声認識や自然言語処理といった時系列データの解析に広く用いられている。路線バスの運行は、図1に示す状態遷移によって実現されているため、状態の遷移を隠れ変数で表し、現在の運行状態を出力状態とすることが可能である。この観点から、状態推定手法としてHMMを利用したモデル化が有用であると考えられる。

HMMを本課題に適用するためには、状態遷移を明確に定義し、モデル化する必要があるが、これらの作業は一定の運行ノウハウを必要とし、モデルを構築するためのデータ加工が必要なため、規制緩和後に新規参入した運送事業者経験のない事業者にとって大きな負担となると考えられる。また、センサデータ量が多く、またその変化タイミングが個別に異なるため、HMMに適切なウィンドウ設定の難易度が高い。さらに、推定した状態を連続して誤るとその後も誤推定が連鎖する恐れがある。

3.5 畳み込みニューラルネットワーク (CNN)

ニューラルネットワークはノードどうしの重みを変化させることによって出力を得る機械学習手法の1つである。畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) は、隣接層間の特定のユニットのみが結合する (従来の順伝播型ネットワークでは全結合) ことと、出力層の同一チャンネルの全ユニットで重みが同一であるといった重み共有を主な特徴としたニューラルネットワークで、物体カテゴリ認識等の画像認識においては、畳み込み層とプーリング層が交互に繰り返された後に全結合した多層パーセプトロンが配置されている構造がよく用いられる。畳み込み層では複数のフィルタを用いて入力に対する特徴の抽出を行い、プーリング層では畳み込み層で抽出された特徴に対して間引きを行い、特徴ベクトルを生成する [8]。

ノイズ耐性が高いメリットがあるが、ハイバパラメータや学習データによって性能が大きく変わるため安定性に欠けており、他手法と比べて学習時間が大幅にかかるといったデメリットがある。

3.6 Long short-term memory (LSTM)

LSTMは再帰型ニューラルネットワーク (Recurrent Neural Network: RNN) の拡張として提言されたモデルのことである。LSTMはRNNの中間層のユニットを lstm block と呼ばれるメモリと3つのゲートを持つブロックに置き換えることにより実現されている [9]。LSTMでは過去に学習したデータを忘却する手段が存在しないため、状況に合わせた対応が不可能であった。近年では、上記の課題を解決するために、忘却機能を持たせた、忘却機能付きLSTMが提案されている [10]。忘却機能付きLSTMは状況変化を自動で判別し、記憶を初期化可能となるため、モ

デルの汎用性を向上させることが可能となった。

LSTM も CNN と同様に、他手法と比べて学習コストと安定性にデメリットがある。

4. 特徴量の選定

ランダムフォレストは特徴量と呼ばれる入力情報を事前に決定する必要がある、この特徴量の質が分類性能を左右する。本研究で提案する特徴量は表 4 のとおりである。以下、それぞれの特徴量について述べる。

3 章でも述べたとおり、従来のタコグラフで記録義務がある車速・エンジン回転数や、カーナビゲーションシステムで一般的に取得可能な緯度・経度・高度・車速・方位はセンサデータとして活用可能である。これらに加えて、分類性能を向上させるため、過去の経験 [11], [12] を元に、本論文ではセンサデータを加工して 5 つの特徴量を設定している。バス停や事業所、洗車場等の位置情報はあらかじめ運用上、管理されていることを前提とする。5 つの特徴量の詳細は下記のとおりである。

- 車速の変化量
得られた車速データから、0.5 秒前の車速と現在の車速の変化量を計算し、定義するものとする。車速の変化量を定義することで、車両の挙動をより詳細に把握することが可能となる。特に「運行」の 3 状態の分類精度向上につながると考えられるため、新たな特徴量として定義した。
- 最寄りのバス停までの距離
それぞれの路線に属するバス停の座標データと車両の座標データから距離を算出する。最寄りのバス停までの距離を定義することにより、「運行-バス停停車」、「運行-バス停発着中」の 2 状態をより高精度に分類できると考えられるため、定義した。
- 事業所までの距離
事業所の座標データと車両の座標データから距離を算

出する。「待機」、「点検」、「給油」の 3 状態は、いずれも車両が停止している状態において行われるものであり、非常に類似している。しかし、「待機状態」は 1 つ目のバス停付近、「点検」状態は事業所内、「給油」状態はガソリンスタンドあるいは事業所内において行われる。これらの 3 状態の差異化を実現できると考えられるため、定義した。

- 洗車場までの距離
洗車場の座標データと車両の座標データから距離を算出する。「点検」、「洗車」の 2 つの状態はどちらも事業所内において、車両が停車した状態で行われるものであり、非常に類似している。また、洗車場は事業所の敷地内に位置しており、GPS 情報のみで分類することは難しいと考えられる。事業所内における上記の 2 状態の分類精度向上に寄与すると考えたため、定義した。
- 事業所フラグ
事業所における 4 隅の座標データと車両の座標データから、定義している。事業所内において行われる状態は「点検」、「洗車」、「給油」、「帰庫」の 4 つの状態である。上記の 4 つの状態をより正確に分類するために定義した。

5. 評価実験・考察

みなと観光バス株式会社の 2 路線の実走行データを用いて評価実験した。以降、実験環境、評価方法、評価結果、考察、今後の展望の順に述べる。

5.1 実験環境

評価実験に用いたデータセットは、異なる 2 つの路線 X と路線 Y を走行した計 4 車両、合計 8 運行分のデータである。本研究では構築したモデルに対し、同一路線モデルに対する分類性能、他路線モデルに対する分類性能、複数路線モデルの分類性能の評価を行った。評価路線と類似する路線を学習したモデルの方が分類性能が一般的に高くなるため、仮説としては、同一路線モデルと複数路線モデルが他路線モデルよりも分類性能が高くなると考えられる。同一路線モデルと複数路線モデルの違いについては、学習データ数が十分であれば同一路線モデルが最も分類性能が良いと考えられるが、不足した場合は複数路線モデルの方が汎用性が上がり、分類性能が同一路線モデルより勝る可能性がある。実験データに用いた運行車両ごとの運行数の偏りは、正解データを取得できた運行であったかどうかの都合によるものである。

図 2 および図 3 にデータ取得対象の 2 路線の路線図を示す。両路線とも兵庫県神戸市の六甲アイランドにある事業所を起点としている。なお、バス停の数はそれぞれ 20 個、11 個となっている。

また、表 5 に取得した運行データにおける運行ごとの開

表 4 ランダムフォレストに用いる特徴量

Table 4 Features for random forest.

特徴量	データ元
緯度	GPS
経度	GPS
高度	GPS
車速	車両
エンジン回転数	車両
総走行距離 (ODO)	車両
方位	方位センサ
車速の変化量	車速
最寄りのバス停までの距離	緯度, 経度
事業所までの距離	緯度, 経度
洗車場までの距離	緯度, 経度
事業所フラグ	緯度, 経度

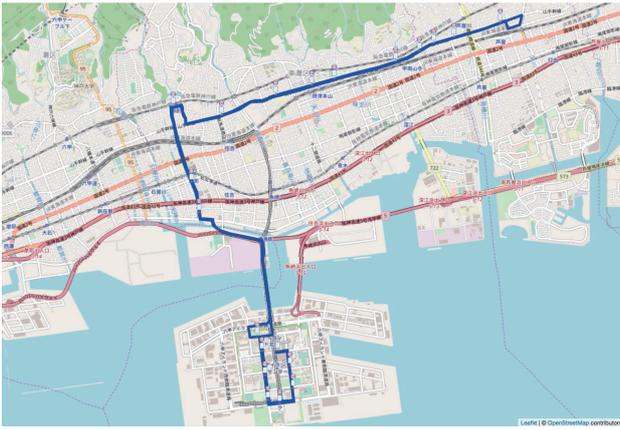


図 2 路線 X
Fig. 2 Route X.



図 3 路線 Y
Fig. 3 Route Y.

表 5 運行ごとのレコード数

Table 5 The number of records for each operation.

路線	車両	時間	レコード数
X	A	06:41:32-12:25:45	41,215
		12:36:08-18:20:56	41,266
		18:25:11-22:41:13	30,567
Y	B	06:50:43-12:15:53	38,971
		13:29:11-21:22:55	56,495
	C	06:05:00-14:12:23	58,463
		15:01:19-21:50:57	49,079
D	06:44:51-13:16:28	46,920	

始時間および終了時間, レコード数を示す. 路線 X の車両 A においては, 異なる運転手 3 人が 1 回ずつ運行し, 合計 3 運行分のデータセットとなっている. 路線 Y の車両 B, C, D においては, 異なる運転手 5 人が 1 回ずつ運行し, 合計 5 運行分のデータセットとなっている.

5.2 評価方法

本研究では, 運転者の誤操作を想定しているため, 車両に取り付けられた車載カメラの映像および時刻表, 車両の走行軌跡をもとに正答データを作成した. 表 6 に各車両における運行状態の正答データ総数を示す. 車両 A, B, C

表 6 各車両における運行状態の正答データ総数

Table 6 The numbers of correct data of each bus.

状態	A	B	C	D
点検	6,283	6,756	7,677	2,060
配車	4,986	1,629	1,518	765
待機	4,586	353	883	325
運行-走行	66,642	65,335	73,071	30,886
運行-発着	3,058	1,501	1,930	880
運行-停車	4,925	2,661	2,907	1,396
休憩	18,901	13,817	17,304	9,046
回送	1,760	1,933	1,485	1,024
給油	670	174	256	167
帰庫	144	574	219	371
洗車	1,093	733	292	0
合計	113,048	95,466	107,542	46,920

表 7 学習データと評価データの組合せ

Table 7 Sets of learning data and evaluation data.

実験名	学習データ	評価データ
同一路線 Y	C	B, D
他路線 X-Y	A	B, C, D
他路線 Y-X	C	A
複数路線	A, C	B, D

では図 1 における各運行状態すべてに 1 度以上遷移しているが, 車両 D では, 洗車状態への遷移が 1 度も行われなかった.

学習データと評価データを分離するため, 路線と車両の組合せを表 7 のとおり複数用意した. 組合せはこれ以外にも存在し, 最大 7% 弱の分類性能の差は出ているが, 紙面の消費を避けるため, 分類性能が最も良かった組合せを取り上げた. 以降, それぞれにおけるランダムフォレストの自動分類結果と正答データの照合を行い正答率を算出する.

最後に, 運転者の手入力の正答率を同様に算出し, 上記の実験で最も正答率の高い路線と車両の組合せモデルによる提案手法の正答率と比較する. なお, 提案手法による状態推定結果も, 運転者の手入力による状態もセンシング間隔である 0.5 秒間隔で記録 (手入力については次の入力があるまではすべて同じ状態が連続記録) されている. 運転者が状態変化時に 0.5 秒以内の精度で機器を操作することは困難であると考えられるため, 評価においてはマージンを持たせて 10 秒ごと, つまり 20 レコードごとの状態の正誤を判定し, 両者の評価結果とする. また, 運用上の都合となるが車載器のボタン数が限られていることと, 運転者の手間を不要に増加させることを防止するため, 表 2 に示した「運行」状態の細分化は行わない. 提案手法で細分化して推定している結果を 1 つの「運行」状態にまとめて評価することも考えられるが, 得られるセンサ値の傾向が本来異なるものであるため, こちらは細分化せずに評価する.

表 8 全評価結果の概要

Table 8 Overall results of the evaluation.

学習データ	評価データ			
	X(A)	Y(B)	Y(C)	Y(D)
X(A)	-	0.764	0.747	0.681
Y(C)	0.661	0.929	-	0.906
X+Y(A, C)	-	0.919	-	0.873

表 9 同一路線 Y の評価結果

Table 9 Evaluation results of "Same route Y."

状態名	B		D	
	正答率	レコード数	正答率	レコード数
点検	1.000	6,756	1.000	2,060
配車	0.952	1,629	0.018	765
待機	0.705	353	0.000	325
運行-走行	0.992	65,335	0.990	30,886
運行-発着	0.662	1,501	0.906	880
運行-停車	0.943	2,661	0.974	1,396
休憩	0.822	13,817	0.801	9,046
回送	0.135	1,933	0.083	1,024
給油	0.000	174	0.887	371
帰庫	0.943	574	0.275	167
洗車	0.000	733	-	-
合計	0.929	95,466	0.906	46,920

5.3 評価結果

評価項目の結果の概略を表 8 に示す。同一路線のモデルに対する正答率が最も高く、車両 C のモデルに対して車両 B の評価結果が 0.929 となった。続いて高い正答率を得たのが複数路線モデルで、他路線モデルは最も低い正答率となった。

同一路線 Y の評価結果を表 9 に示す。両車両において、点検状態、運行-走行状態、運行-停車状態、休憩状態が 0.8 以上と高い正答率を示した。また、待機状態と回送状態については両車両とも正答率が 0.7 以下という結果となった。配車状態、待機状態、給油状態、帰庫状態については、2 車両間において正答率に大きな差が見られた。

他路線 X-Y の評価結果を表 10 に示す。運行-走行状態は 3 車両において、正答率が最低でも 0.937 と、高い結果を示していることが分かる。しかし、待機状態、休憩状態、帰庫状態については、どの車両においても正答率は 0 という結果が得られた。また、回送状態、給油状態、洗車状態の 3 つの状態は、各車両間において、正答率に大きな揺らぎが確認できる。

他路線 Y-X の評価結果を表 11 に示す。点検状態、運行-走行状態、帰庫状態については、正答率が 0.9 以上と高い結果を示していることが分かる。また、待機状態、休憩状態、回送状態、給油状態、洗車状態については、正答率がほぼ 0 という結果となった。

複数路線の評価結果を表 12 に示す。点検状態、運行-走

表 10 他路線 X-Y の評価結果

Table 10 Evaluation results of "Different route X-Y."

状態名	B		C		D	
	正答率	レコード数	正答率	レコード数	正答率	レコード数
点検	0.979	6,756	0.817	7,677	0.050	2,060
配車	0.548	1,629	0.582	1,518	0.498	765
待機	0.000	353	0.000	883	0.000	325
運行-走行	0.937	65,335	0.949	73,071	0.959	30,886
運行-発着	0.524	1,501	0.677	1,930	0.669	880
運行-停車	0.734	2,661	0.603	2,907	0.824	1,396
休憩	0.000	13,817	0.000	17,304	0.000	9,046
回送	0.621	1,933	0.345	1,485	0.107	1,024
給油	0.724	174	0.184	256	0.000	167
帰庫	0.000	574	0.000	219	0.000	371
洗車	0.151	733	0.747	292	-	0
合計	0.764	95,466	0.747	107,542	0.681	46,920

表 11 他路線 Y-X の評価結果

Table 11 Evaluation results of "Different route Y-X."

状態名	正答率	レコード数
点検	0.939	6,283
配車	0.248	4,986
待機	0.000	4,586
運行-走行	0.985	66,642
運行-発着	0.485	3,058
運行-停車	0.069	4,925
休憩	0.000	18,901
回送	0.016	1,760
給油	0.000	670
帰庫	0.896	144
洗車	0.000	1,093
合計	0.661	113,048

表 12 複数路線モデルの評価結果

Table 12 Evaluation results of "Multi routes."

状態名	B		D	
	正答率	レコード数	正答率	レコード数
点検	1.000	6,756	1.000	2,060
配車	0.941	1,629	0.051	765
待機	0.992	353	0.000	325
運行-走行	0.980	65,335	0.983	30,886
運行-発着	0.653	1,501	0.876	880
運行-停車	0.952	2,661	0.988	1,396
休憩	0.779	13,817	0.678	9,046
回送	0.328	1,933	0.217	1,024
給油	0.000	174	0.000	371
帰庫	0.937	574	0.018	167
洗車	0.000	733	-	-
合計	0.919	95,466	0.873	46,920

行状態、運行-停車状態、については、正答率が 1 近くという非常に高い結果を示した。回送状態、給油状態、洗車状態については、2 車両とも正答率は 0.3 近く、あるいは 0 という結果となった。配車状態、待機状態、帰庫状態につ

表 14 運転者の手入力結果の混同行列
Table 14 Confusion matrix of the drivers' inputs.

	手入力結果									
	点検	配車	待機	運行	休憩	回送	給油	帰庫	洗車	ログオフ
点検	0	0	0	0	11	62	0	0	0	4
配車	0	0	0	39	2	0	0	0	0	0
待機	0	0	0	13	0	0	0	0	0	0
運行	0	0	0	2,225	0	0	0	0	0	0
休憩	0	0	0	354	44	0	0	0	0	0
回送	0	0	0	2	0	28	0	0	0	0
給油	0	0	0	0	0	0	0	0	0	0
帰庫	0	0	0	0	0	3	0	0	0	0
洗車	0	0	0	0	0	37	0	0	0	0
ログオフ	0	0	0	0	0	0	0	0	0	0

表 15 提案手法の推定結果の混同行列
Table 15 Confusion matrix of the proposed method.

	推定結果										
	点検	配車	待機	運行-走行	運行-発着	運行-停車	休憩	回送	給油	帰庫	洗車
点検	77	0	0	0	0	0	0	0	0	0	0
配車	2	39	0	0	0	0	0	0	0	0	0
待機	0	0	13	0	0	0	0	0	0	0	0
運行-走行	0	0	0	2,063	16	2	2	0	0	0	0
運行-発着	0	0	0	16	29	4	1	0	0	0	0
運行-停車	0	0	0	0	7	84	1	0	0	0	0
休憩	0	0	0	4	2	10	382	0	0	0	0
回送	0	0	0	19	0	0	0	11	0	0	0
給油	0	0	0	0	0	0	0	0	0	0	0
帰庫	0	0	0	0	0	0	0	0	0	3	0
洗車	21	0	0	0	0	0	0	0	0	16	0

表 13 運転者の手入力と提案手法の正答率の比較
Table 13 Evaluation results (drivers vs. proposed method).

	車両 B		車両 D
	運行 1	運行 2	運行 1
運転者手入力	0.719	0.812	0.885
提案手法	0.888	0.952	0.926

いては、2 車両間に大きな正答率の差が見られたが、3 状態とも車両 B の方が非常に高い正答率を示している。

最後に、運転者との手入力との比較を行う。表 8 より、同一路線モデルの分類精度が最も高精度という結果が得られたため、路線 Y における同一路線分類モデルと運転手の手入力結果の比較を行った。なお、比較対象は、路線 Y モデル構築に利用した車両 C を除く、車両 B の 2 運行と車両 D の 1 運行であり、合計 3 運行、3 ドライバーのデータセットとした。

表 13 に運転者の手入力による正答率と、運行状態分類モデルが出力した正答率の比較を示す。全運行において、運転者の手入力結果よりも運行状態分類モデルの方が高い正答率を示していることが分かる。得られた差は 0.041~

0.169 である。内訳を確認するために、手入力の性能が中間的で、提案手法の性能が最も良かった運行 2 の混同行列を示す。表 14 が運転者の手入力*2、表 15 が提案手法によるものである。運転者の手入力において、運行状態から休憩状態への切り替え忘れが最も多く見られた。次いで誤入力の多い状態は回送である。どちらの状態も提案手法では正しく推定できている割合が高いため、分類性能向上に貢献している。とはいえ、表 6 に示したとおり、1 業務において、運行の 3 状態（運行-走行、運行-発着、運行-停車）が占める割合が非常に高かったため、上記の切り替え忘れが発生しても、運転手の記録結果の正答率が極端に低くなるということにはなかった。

5.4 考察

構築した路線 X モデル、路線 Y モデル、路線 X+Y モデ

*2 運転者は業務の開始・終了時に認証のために ID カードを車載器にかざしており、業務時間外は「ログオフ」という状態が車載器に記録されている。本来、評価対象外にしてもよいものだが、正解データを作成する際にドライブレコーダの映像を確認する限り、明らかにカードをかざすタイミングが早すぎる・遅すぎるパターンがあったため評価対象とした。

表 16 各分類モデルにおける特徴量の重要度
Table 16 Features importance of each model.

路線 X		路線 Y		路線 X+Y	
最寄バス停距離	0.227	事業所距離	0.197	最寄バス停距離	0.237
事業所距離	0.172	最寄バス停距離	0.145	洗車場距離	0.141
洗車場距離	0.110	洗車場距離	0.125	事業所距離	0.111
総走行距離	0.094	緯度	0.107	総走行距離	0.101
経度	0.093	エンジン回転数	0.092	緯度	0.071

ルにおける特徴量の重要度の上位 5 項目を表 16 に示す。

各分類モデルにおいて、新たに定義した特徴量である最寄りのバス停までの距離、事業所までの距離、洗車場までの距離が上位 3 項目を占めていることが分かる。特に、路線 X モデルと路線 X+Y モデルにおいては最寄りのバス停までの距離の重要度が 0.25 弱となっており、この特徴量が大きく貢献していることが分かる。以降、モデル別に考察する。

5.4.1 同一路線分類モデル (路線 Y)

点検状態の正答率は車両 B, D とも 1 となっている。事業所内において停車している際に行われる他の状態として、洗車状態および車両 B における給油状態が存在する。しかし、これらの 2 状態のほとんどが点検状態に誤分類されていた。事業所内において停車している場合の記録のほとんどが点検状態に分類され、結果として点検状態の正答率が 1 となった。

運行-停車状態については、表 16 に示したとおり、最寄りのバス停までの距離を新たに定義し、特徴量として貢献していると考えられるため、正答率が 0.95 前後と非常に高い精度を示している。

休憩状態については、どの車両も同じ地点において休憩状態に遷移する。休憩状態の定義は「4 時間未満の休みでありエンジンが OFF」となっているが、データセット中のエンジン回転数を確認すると、休憩状態に遷移しているにもかかわらず、エンジン回転数が 0 になっていない、つまりエンジンを OFF にしていない事例が数多く見られた。この要因としては、当日の交通状況によるものが大きいと考えられる。路線 X では、片道約 35 分の経路をピストン運行する路線となっている。しかし、データ取得日が休日だったことも影響し、次の運行開始までの時間が短い場合にはエンジンをかけたまま休憩状態に遷移し、そのまま運行状態に遷移というパターンが見られた。このような定義どおりの休憩を行っていない場合において誤分類が発生している。

給油状態については、ガソリンの給油場所が異なるため、分類結果に大きな差が発生したと考えられる。モデル構築に利用した車両 B, C は、運行終了後に隣のガソリンスタンドにおいて給油した後に事業所に帰庫する。しかし車両 D は事業所内に設置されているガソリン給油装置を利用

して給油しており、事業所内において行われる他の状態である点検状態に誤分類されていた。

洗車状態および点検状態はどちらも事業所内において行われる状態となっている。本研究では、これらの 2 状態の差別化を図るために新たな特徴量として、事業所までの距離および洗車場までの距離を定義した。しかし、洗車状態終了後に車両の移動を行わず、点検状態に遷移する例が多く、データセット上ではこれらの 2 状態の区分がほぼ不可能となっていたと考えられる。洗車状態のほとんどが点検状態に誤分類されており、このような結果となった。

5.4.2 他路線分類モデル

点検状態については、同一路線分類モデルと同様に、事業所内において停車している場合にはレコードのほとんどが点検状態に誤分類されており、結果として点検状態の正答率が高くなった。

待機状態、休憩状態については、路線 X モデルおよび路線 Y モデルにおいて、正答率がすべて 0 という結果となった。路線 X および路線 Y において、待機と休憩を行う地点がほぼ固定である。よって、別の路線で構築したモデルでは分類が困難という結果となった。

運行-停車状態については、同一路線分類モデルでは、非常に高い正答率を示していたが、他路線分類モデルにおける正答率の平均は 0.7 程度と大きく低下していることが分かる。この理由として、新たに定義した特徴量である、最寄りのバス停までの距離が原因であると考えられる。図 2 に示す路線 X と図 3 に示す路線 Y を比較すると、路線前半では六甲アイランド内において共通するバス停を経由しているが、後半では、それぞれ東西に走行していき、まったく異なるバス停を経由していることが分かる。異なるバス停を経由するため、バス停間の距離間隔が変化し、別路線のデータセットの分類が困難になったと考えられる。また、運行-発着状態についても上記の理由により正答率が低くなったと考えられる。

給油状態については、車両 A, B が同一のガソリンスタンドにおいて給油を行っていた。よって、車両 A から構築した路線 Y モデルを車両 B に適用した際にも、正答率が極度に低下するということはなかったと考えられる。

5.4.3 複数路線分類モデル

点検状態については、同一路線分類モデル、他路線分類モデルと傾向が同様になっており、正答率が 1 となっている。

休憩状態、運行-発着状態、運行-停車状態は GPS 情報に大きく依存していると考えられ、同一路線分類モデルより正答率が低く、他路線分類モデルより高い正答率が得られた。

給油状態については、モデル構築に使用した 2 車両分のデータセット両方においてガソリンスタンドにおいて給油を行っているため、正答率が 0 となっている。

全体での正答率は同一路線分類モデルと比べると低い結果となっている。今後、新たな路線のデータセットを追加し、正答率の変化を検証する必要があると考えられる。

5.5 今後の展望

今後検証すべき課題として、下記の内容があげられる。

(1) モデルの分類の安定性の検証

本評価では路線 X で 1 車両、路線 Y で 3 車両のデータセットを用いて検証を行った。表 9 では、同一路線の走行データからモデルを構築したにもかかわらず、車両 B と車両 D の正答率に大きな揺らぎが確認できる。たとえば、配車状態においては、車両 B での正答率は 0.952 であるが、車両 D では 0.05 と大きな差が確認できる。このような分類のバイアスの原因を検証するために、運行データをさらに増やし、モデルの分類精度をより詳細に検証する必要があると考えられる。

(2) 別の路線を走行した車両のデータセットの採用

本評価では路線 X と路線 Y の 2 路線を対象として検証を行った。表 8 では、複数のモデルのうち、同一路線分類モデルの分類精度が最も高いという結果となった。しかし、複数路線分類モデルにおいては、同一路線分類モデルでは正答率が低かった待機状態および回送状態の正答率が向上している。これは、路線を統合したモデルを構築したことにより、汎用性が向上したことに起因する可能性がある。こちらについても運行データをさらに増やした検証が必要である。

(3) 正答率が低かった状態の分類精度向上

分類精度が最も高かった表 9 に示す同一路線分類モデルにおいて、回送状態、給油状態、洗車状態の正答率が非常に低いことが確認できる。たとえば、回送状態は一定時間の業務が終了した後に行われる状態であるにもかかわらず、運行前に行われる配車状態に誤分類されていた。この要因は、本研究で提案した状態分類モデルが状態遷移を考慮していないことに起因すると考えられる。ランダムフォレストが出力した結果に対して、簡単なルールベースによる状態遷移の検証を行うことで、出力結果の補正や状態遷移の正当性の検証が可能になると考えられる。

また、給油状態、帰庫状態、洗車状態については、表 6 のとおり、そもそもサンプル数が他の状態と比べて非常に少ない、データの不均衡が、それらの状態の分類性能を低下させる要因だと考えられる。データの不均衡の解決方法については He らの報告 [13] を皮切りに多く議論されているため、本研究の課題に即したものを適用し改善を図りたい。

(4) 他の分類手法の検証

本論文では主に学習コストの低さや安定性、モデル構築の容易性を優先して、ランダムフォレストを採用し

たが、HMM や LSTM 等の他手法では分類性能の向上が見られるかについても比較評価をしたい。

6. おわりに

旅客運送業の人手不足の一助となるべく、今後普及が期待できるデジタルタコグラフから得られるセンサデータを機械学習することでバスの運行状態を自動分類する手法を提案し、実運行データによる評価を行った。実運用性の高いランダムフォレストによって自動分類した結果、運転者の手入力よりも高い正答率を得ることに成功した。提案手法では、事前入力が必要な情報は停留所や洗車場、事業所等の位置情報のみとなっており、これらは元々運行管理者によって管理されていることが期待できる情報であるため、即効性の高い成果を得たといえる。今後は運行データをさらに増やしたり、データ不均衡の解決手法を適用したりすることで分類性能の改善を検討し、また他の分類手法の性能も検証したい。

参考文献

- [1] The Japan Times: Overnight bus crashes in Karuizawa, killing 14, Japan Times (online), available from <https://www.japantimes.co.jp/news/2016/01/15/national/night-ski-bus-flips-karuizawa-three-killed-11-critical-condition/#.WgT4Fx00MWp> (accessed 2017-11-10).
- [2] 公益社団法人日本バス協会：2016 年版日本のバス事業、入手先 (<http://www.bus.or.jp/about/pdf/h28-busjigyo.pdf>) (参照 2017-12-09).
- [3] 国土交通省：自動車関係統計データ、入手先 (<http://www.mlit.go.jp/common/000117167.pdf>) (参照 2017-12-09).
- [4] 公益社団法人日本バス協会：バス事業の現状と取り組みについて、入手先 (<https://www.mlit.go.jp/common/001127098.pdf>) (参照 2017-12-09).
- [5] 国土交通省：貨物自動車運送事業輸送安全規則。
- [6] Liaw, A. and Wiener, M.: Classification and Regression by randomForest, *R News*, Vol.2, No.3, pp.18–22 (2002).
- [7] Hsu, C.-W. and Lin, C.-J.: A comparison of methods for multiclass support vector machines, *IEEE Trans. Neural Networks*, Vol.13, No.2, pp.415–425 (2002).
- [8] Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P.: Gradient-based learning applied to document recognition, *Proc. IEEE*, Vol.86, No.11, pp.2278–2324 (1988).
- [9] Gers, F.A., Schraudolph, N.N. and Schmidhuber, J.: Learning Precise Timing with LSTM Recurrent Networks, *Journal of Machine Learning Research*, Vol.3, pp.115–143 (2003).
- [10] Gers, F.A., Schmidhuber, J. and Cummins, F.: Learning to forget: Continual prediction with LSTM, *Neural Computation*, Vol.12, No.10, pp.2451–2471 (2000).
- [11] 米澤拓也, 新井イスマイル, 藤川和利: 路線バスから得られたセンサデータの解析と車両状態推定に関する検討, 情報処理学会研究報告, Vol.2016-MBL-81, No.3, pp.1–5 (2016).
- [12] 米澤拓也, 新井イスマイル, 藤川和利: 路線バスから得られたセンサデータを利用した運行状態分類モデルの評価, 情報処理学会, マルチメディア, 分散, 協調とモバイル (DICOMO2017) シンポジウム論文集, pp.65–72 (2017).

- [13] He, H. and Garcia, E.A.: Learning from Imbalanced Data, *IEEE Trans. Knowledge and Data Engineering*, Vol.21, No.9, pp.1263–1284 (2009).



米澤 拓也

2015年同志社大学理工学部インテリジェント情報工学科卒業。2018年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。公共交通データの解析に関する研究に従事。



新井 イスマイル (正会員)

2002年明石工業高等専門学校専攻科機械・電子システム工学専攻修了。2008年奈良先端科学技術大学院情報科学研究科博士後期課程修了。博士(工学)。2008年立命館大学ポスドク研究員。2011年明石工業高等専門学校助教・講師・准教授を経て、2016年より奈良先端科学技術大学院大学総合情報基盤センター准教授。屋内測位システム、センサネットワーク、データ解析等、ユビキタスコンピューティングの研究開発に従事。電子情報通信学会、ACM、IEEE 各会員。



秋山 豊和 (正会員)

1999年大阪大学大学院工学研究科修士課程修了、2000年同大学院博士課程中退後、同大学サイバーメディアセンター助手を経て、2005年同センター講師。2008年京都産業大学コンピュータ理工学部講師、2011年同大学准教授を経て、2018年同大学情報理工学部教授。分散システム、IoT等に興味を持つ。博士(工学)(2003年9月、大阪大学)。電子情報通信学会、IEEE CS 各会員。



藤川 和利 (正会員)

1988年大阪大学基礎工学部情報工学科卒業。1991年同大学院基礎工学研究科博士後期課程退学後、同年同大学基礎工学部助手等を経て、2002年奈良先端科学技術大学院大学情報科学センター助教授、2005年同大学情報科学研究科助教授、2011年同情報科学研究科教授、現在に至る。博士(工学)。分散処理システム、マルチメディアシステム、ユビキタスコンピューティングの研究開発に従事。電子情報通信学会、IEEE、ACM 各会員。