

# 運転者支援システム開発のための自動車運転データに基づく 個人運転行動の認識とモデリングに関する研究

研究代表者氏名 岩手県立大学 教授 バサビ・チャクラボルティ

研究参加者氏名 千葉工業大学 准教授 眞部 雄介

岩手県立大学 学生 中野 光太郎

岩手県立大学 学生 村上 力

## <要旨>

運転者の注意散漫状態を検出して、運転者に注意喚起を行う運転者支援システムの構築に関して1、運転者個人の運転スキルの差異に関する分析を行う。2、運転者個人ごとの運転スキルの違いを反映したモデルを構築することによって平均的な運転者をベースにしたシステムよりも更に高い精度で運転者の状態を把握し正確な支援を行うシステムの構築のためのアルゴリズムを開発する。

キーワード：個人適応型運転支援システム，運転行動の個人性認識，運転行動モデリング

## 1 研究の概要

近年、高度な運転者支援システムを実装した自動車の重要性が高齢者の自動車運転支援などの分野で増加している。これらの既存の運転者支援システムは平均的な運転をする人を元に設計されている。しかし、運転者個人ごとの運転の仕方にはそれぞれ異なった特徴があり、平均的な運転を元にしたシステムでは十分な支援を行うことができない可能性がある。そのため、これらの問題を改善したモデルの作成を行う。

現在、運転者の注意散漫状態の自動検出に関する研究として様々なセンサーの値をもとにしたものが提案されている。例を挙げると、カメラから得られる運転者の画像をもとに畳み込みニューラルネットワークで注意散漫状態の検知を行うもの[1]、眼球運動をもとにリアルタイムの注意散漫状態を検知する[2]というものがある。特に画像と畳み込みニューラルネットワークを使った手法が多く提案されており、高い精度を得ることができている。

また、運転者の認知負荷に関する研究もおこなわれており、運転中に起こる様々な認知負荷によって運転者の運転行動や状態にどのような影響があるかという分析[3]もおこなわれている。このように多くの研究で運転者の注意散漫状態の検出手法に関する検討が行われているが様々なセンサーからのデータを使用したものは少ないといえる。

本研究では運転支援に関するシステムの中でも、運転者の注意散漫状態を検出するための機能に注目してシステム開発を行うが、扱うセンサーに関しても運転者が装着する際に不快にならない非侵襲型センサーを用いて行う。非侵襲型センサーを使う理由は、セン

サーによって運転者の運転に影響を与えないことや、手軽に利用できるという視点からアプリケーションへの応用がしやすいという点が挙げられる。

プロジェクトの流れとしてはまず、ドライビングシミュレータから得られるステアリングやブレーキなど運転者の運転操作に関するデータと、運転者の手首に装着して加速度や心拍数を計測することができるフィットネスバンド(Microsoft Band)から得られるデータを収集し、これらのデータから得ることができる運転者個人の運転技能や癖に関する分析を行い、それらを反映した個人ごとのモデル構築を行う。最終的には構築されたモデルを用いて通常運転状態と注意散漫状態を見分けるための実験を行う。

## 2 研究の内容

本研究では、運転者の注意散漫状態を認識するため、ドライビングシミュレータを用いて特定のシナリオを作成し、複数の注意散漫状態に関するデータを記録した。

注意散漫状態は、運転者が運転に集中できていない状態で、例えば助手席に乗っている人との会話や考え事などの認知負荷がかかる状態や、スマートフォンやエアコンを操作して、視線が道路から外れてしまう場合を想定した。

データの解析では、収集されたデータを使い、それぞれの運転者が注意散漫状態と通常状態の運転で、どのセンサーの値に大きな変化がみられるかの検証を行った。

モデルの作成では、静的特徴を使った分類期と動的

特徴をつかったニューラルネットワークによるモデルを作成し、それぞれで注意散漫状態の検知の精度比較を行った。

このように、本研究は、データ収集、収集したデータの分析、分析結果を元にした個人ごとのモデル作成というステップで行った。それぞれのステップの詳細と得られた結果について以下に示す。

## 2.1 データの収集

データの収集では、ドライビングシミュレータ(D3sim)を用いて数人の異なる運転者から、それぞれの運転行動や生体データを取得した。

データを記録するために使用するシナリオは実験の目的達成のためにいくつかのコンセプトに沿って作成した。

まず、運転者のモデルを作成するにあたり、多くのデータが必要なため、1回の計測で似たような道路を走行するパターンを複数回計測できるように設計を行った。

データの計測は地図上の特定の地点から開始し、前を法定速度で走行する車に追従するという流れで行われる。

1回の計測時間は約5分で前を走行する車が目的地に着いて停車したら被験者の車も停止して計測終了とした。実験の注意事項として、車が壁や他の車に衝突したり、前の車に追従できない程に距離を離されてしまった場合はデータのとり直しとした。



図1：計測に使用した市街地の地図

図1にデータの計測で使用したシナリオの地図を示す。

この地図上でいくつかのコース（開始地点や終了地点を設定した。

計測した注意散漫状態に関しては、それぞれに被験者に、通常運転、助手席に座っている人と会話しながらの運転、暗算しながらの運転という3つの異なる認

知負荷がかかった状態を想定して運転を行ってもらった。

通常運転は運転操作以外の認知負荷が無く、一番運転に集中することができる状態でデータを取得した。

それ以外の2つの状態はそれぞれ運転操作以外に認知負荷がかかっている状態を想定して設定した。

## 2.2 データの分析

データの分析では被験者から収集した運転行動に関するデータと被験者の右腕に装着したフィットネスバンド(Microsoft Band)から得られた生体データの解析を行った。

運転行動は、運転者が運転中に行う操作で、ハンドル、ブレーキ、アクセルの操作を指す。これらのデータは、それぞれのセンサーの値を一定間隔でサンプリングした時系列データとして取得することができる。

生体データに関しては、Microsoft BandをAndroidスマートフォンとペアリングし、データの記録のために作成したAndroid端末で動作するアプリを用いてそれぞれのセンサーの値の記録を行った。また、記録用に作成したアプリでは一定間隔ごとに運転中の被験者を撮影し、画像を保存した。データ収集に関する実験中の画像を図2に示す。このようにスマートフォンで運転者の顔を中心とした画像と右腕につけたMicrosoft Bandからは各センサーのデータを記録している。



図2 データ計測実験

表1と表2にそれぞれドライビングシミュレータで計測した運転行動に関する特徴量とMicrosoft Bandから得られた特徴量を示す。

表1 ドライビングシミュレータから得られる特徴量

1	Acceleration stroke
2	Brake stroke
3	Engine speed
4	Car speed
5	Steering torque
6	Steering angle

表2 Microsoft Band から得られる特徴量

1	Heart rate
2	Skin temperature
3	Galvanic skin response
4	Acceleration X axis
5	Acceleration Y axis
6	Acceleration Z axis
7	Gyro X axis
8	Gyro Y axis
9	Gyro Z axis

これらのデータを分析するにあたり、それぞれの被験者が通常状態と注意散漫状態でどの特徴にどの程度の変化がみられるかの検証を行った。

分析を行う前にまず1回の計測(約5分)で得られたデータの分割処理を行った。この処理では観測された時系列データをスライディングウィンドウ(3秒間隔、50%の重複)で切り出し、細かいデータに分割した。この処理によって走行中のどの部分でセンサーからの値に変化があったかを検証することができる。

次に、それぞれの注意散漫状態を検知するために、有効な特徴(通常状態と認知負荷状態で差が大きく出る特徴)を探すために特徴の値に関するヒストグラムを作成しそれぞれの運転状態に対しての比較を行った。特徴の値は最初に切り出した1つのウィンドウの平均、標準偏差、最大値、最小値を使用した。

	サンプル数	Accuracy
User1	867	0.62
User2	860	0.59
User3	834	0.61
User4	853	0.51

表3 サポートベクターマシンの分類結果

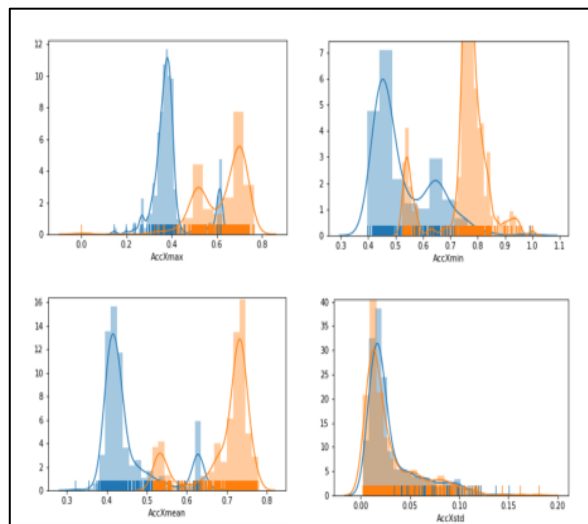


図2 加速度データに関するヒストグラム

図2に一人の被験者のMicrosoft Bandから取得したX軸の加速度データに関するヒストグラムを示す。図のそれぞれのグラフは、最大値(左上)、最小値(右上)、平均(左下)、標準偏差(右下)を表している。

各図の橙で示したデータは通常運転時のデータで、青で示したデータが会話運転時のデータである。このように特定の特徴で運転状態による差異が観測された。

### 2.3 静的特徴による分類

ここでは最終的なモデルの作成では時系列の時間ごとの変化に関する動的特性を保持した動的特徴を使用したニューラルネットワークを用いるがここではそれぞれの特徴の統計量を使った静的特徴を使った分類器を構築して分類精度の検証を行った。

使用した特徴はMicrosoft Bandから取得した特徴のうち表2に示した9個の特徴で、それぞれの最大値、最小値、平均、標準偏差を計算し、一つのサンプル当たり36次元の特徴とした。

分類に使用した分類器はサポートベクターマシンで制度の評価は、データをランダムに5個に分割し、その中の4個を学習データ、残りの1個をテストデータとして学習と分類を行い、認識精度を計算するという過程を10回繰り返す、5 fold cross validation 10 repeatsで行った。

得られた精度に関しては、全体的にランダムで分類した場合よりも少し高い精度を得ることができている。

### 2.4 動的特徴による分類

動的特徴による分類では、平均や最大値のような統計量ではなく、時系列データの動的特性を保持したままのデータを用いて分類器の構築を行った。Microsoft

Band から得られた時系列データをスライディングウィンドウによって分割し、得られたデータを特徴次元×時系列長の画像に変換して畳み込みニューラルネットワークによる学習を行った。

### 3 これまで得られた研究の成果

本研究では、データの計測に関しては、シナリオの設計など実験条件の見直しと改善を重ね研究の目的に合ったデータを収集することができた。データ量に関しても、それぞれの被験者に対して定期的に計測を行うことによって多くのデータを蓄積させることができた。

データ解析の結果に関しても、前回のプロジェクトに関する研究[4][5][6]と同様に個人ごとに運転者の運転行動に関する癖が異なっており、それぞれの運転者ごとのモデルを構築することによって注意散漫状態検知の精度が向上するということが証明することができた。

また新しくフィットネスバンドから得られる生体データや、フィットネスバンドの加速度センサーから得られるデータに関する解析を行った。運転者の腕の動きのデータにも通常運転時と会話運転時で差がみられることを確認することができた。

静的特徴を使った分類に関しては、フィットネスバンドから計測したデータのみを使い、一部の特徴から会話運転状態における運転の乱れを検知することができたと言える。反対に、計測したデータの中でも運転者の運転状態の影響を受けない特徴に関しても特定することができた。

最後に、動的特徴を使用したニューラルネットワークによる手法では、分類器の学習の多くの計算コストがかかったが、静的特徴を使った場合(2.3)よりも高い認識率を得ることができた。

### 4 今後の具体的な展開

今回、複数人の学生の運転データをもとに分析とモデルの構築を行ったが、データの信頼性の観点からも、今後はさらに多くの被験者のデータの計測しつつ精度の検証を行っていく必要があると考えられる。

作成したモデルに関しては、パラメーターのチューニングによって精度を向上させることができるが、個人ごとのモデルを作成する場合、それぞれのモデルに対してヒューリスティックにパラメーターのチューニングを行うことは現実的ではないため、分類器の学習を行う前の特徴抽出手法の改善を行い、なるべくパラメーターチューニングに依存しない手法で精度を向上させることができるように改善を行う必要があると考えられる。

よって、今後はモデルに関して特徴抽出手法、計算

量の削減にという課題に注目して改善を行っていく。

最終的には、構築したモデルを元に、スマートフォンを使った運転者の注意散漫状態検知を目的とした運転支援のためのアプリケーションへと応用する。

### 5 論文・学会発表等の実績

- 1) Basabi Chakraborty and Sho Yoshida, "Time series Classification with New Similarity Measure: An Application for Automatic Detection of Driver's Distraction", in Proceedings of NOLTA 2017, December, 2017.

### 6 受賞・特許

なし

### 7 参考文献

- [1]STREIFFER, Christopher, et al. DarNet: A Deep Learning Solution for Distracted Driving Detection. 2017.
- [2] LIANG, Yulan; REYES, Michelle L.; LEE, John D. Real-time detection of driver cognitive distraction using support vector machines. IEEE transactions on intelligent transportation systems, 2007, 8.2: 340-350.
- [3] LAMBLE, Dave, et al. Cognitive load and detection thresholds in car following situations: safety implications for using mobile (cellular) telephones while driving. Accident Analysis & Prevention, 1999, 31.6: 617-623.
- [4] CHAKRABORTY, Basabi; NAKANO, Kotaro. Automatic detection of driver's awareness with cognitive task from driving behavior. In: Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on. IEEE, 2016. p. 003630-003633.
- [5]Basabi, Chakraborty; Manabe, Yusuke; Sho, Yoshida; and Kotaro Nakano, Effect of Cognitive Distraction on Driving Behavior. In Proceedings of FITAT 2016 (Best Paper Award)
- [6] Basabi, Chakraborty; Manabe, Yusuke; Kotaro, Nakano; Sho, Yoshida. A preliminary study of automatic detection of distraction from driving behavior using driving simulator, presented in SIG-FPAI (人口知能学会研究会資料B502, pp. 17-22) 2016.