

# DS および、実車データを用いた機械学習による飲酒運転検知モデルの開発\*

## Development of Drunk Driving Detection Models Using Machine Learning with Driving Simulator and Actual Vehicle Data

中村 典雅 Norimasa NAKAMURA  
山岡 将綺 Masaki YAMAOKA  
山高 大乘 Minoru YAMATAKA  
伊藤 隆文 Takafumi ITO

Drunk driving remains a major contributor to traffic accidents worldwide, making its detection a critical issue for road safety. This study aimed to develop machine learning models for drunk driving detection using data collected from both a driving simulator (DS, N=28) and actual vehicle experiments (N=18). Participants performed driving tasks before and after alcohol consumption, with data gathered on vehicle signals (such as speed, steering, and acceleration) and driver monitoring camera (DMC) features (including eye movements and head position). The research compared traditional statistical models with neural network approaches. Results showed that the 1D-CNN (One-Dimensional Convolutional Neural Network) consistently achieved the highest detection performance, particularly when applied to real vehicle data.

Keywords :

*Human engineering, Driving act/Driver behavior, Driver sensing /Driver monitoring, Drunk driving*

### 1. まえがき

飲酒運転は交通事故の原因となる深刻な問題であり、その防止に取り組むことは極めて重要である。米国国家道路交通安全局（NHTSA）は、2023年の交通事故死亡者数の約30%（約12,429件）が飲酒運転に起因していたと報告している<sup>1)</sup>。また、欧州の自動車安全性評価機関であるEuro NCAPは、将来的な評価項目に飲酒運転の検知を導入する計画を発表している<sup>2)</sup>。国際的な飲酒運転検知システムの実用化に向けた動きがある中、先端技術による安全性向上が期待されている。

従来は飲酒運転検知手法として、呼気中のアルコー

ル濃度を直接測定する方法が広く用いられてきた<sup>3)</sup>。しかし、この手法は運転開始時の測定結果に依存しており、運転中の状態変化をリアルタイムに把握することが困難である。さらに、呼気式のアルコールセンサの導入に追加コストが発生するといった課題もある<sup>4)</sup>。

一方で、リアルタイム検知が可能な手法としてCAN（車両信号）やDMC（ドライバモニタリングカメラ）等の既存のデバイスから取得可能なデータを活用して飲酒によるドライバの状態異常を検知するアプローチが注目されている。例えば、飲酒を伴う走行実験によってZhaoら<sup>5)</sup>は飲酒による走行速度平均および、標準偏差の上昇等を確認し、Tivestenら<sup>6)</sup>はドラ

イバの前方道路への視線集中等を確認している。また、Kochら<sup>7)</sup>はドライバの視線や頭部の動きを用いてリアルタイムでの検知が可能な飲酒運転検知手法の開発を行った。Kochらはまず、DS（ドライビングシミュレータ）実験を実施し、被験者の飲酒前後のCANおよび、DMCの時系列データを収集した。その後、収集した各時系列データから、平均などの統計量を算出し、それらを特徴量として用いることで、Logistic Regression, SVM, Random Forest等の機械学習手法による飲酒状態の検知モデルを作成した。

本研究では、機械学習による飲酒検知モデルの開発を目的として、DS実験に加えて、実車による実験を行いCANおよび、DMCデータを取得した。また、ニューラルネットワーク系のモデルを用いることで、取得した時系列データに対しての統計量の算出を行わず、そのまま特徴量として使用し、学習・評価することも行った。本論文では作成した複数のモデルによる飲酒運転検知性能の比較を行う。加えて、検知の際に重要だった特徴量を報告する。

### 2. 実験方法

本章ではデータ取得のためのDS実験と実車実験を説明する。両実験は株式会社デンソー社内の「人を対象とする研究審査委員会」によって自動車技術会「人を対象とする研究倫理ガイドライン」を遵守した審査承認を得て実施した。

#### 2.1 DS 実験

DSによる実験は、Fig. 1に示す株式会社デンソー先端技術研究所内の360°パノラマビューのDSを用いて行った。被験者として、運転免許証を所持する28名を募った。各被験者は飲酒前に市街地シナリオ、市街地ヒヤリハットシナリオ（歩行者飛び出し等のヒヤリハットが複数回発生するシナリオ）、高速道路シナリオの3シナリオをそれぞれ約10分ずつ走行する。走行の後、約1時間の飲酒時間を設け、被験者は軽食とともにワイン等のアルコール類の摂取を行った。呼気アルコール濃度0.40mg/L以上を目標にして飲酒を行ったが、被験者の安全を最優先し、目標値に達しな

かった場合でも、飲酒時間を切り上げることにした。飲酒後には、飲酒前と同様の3シナリオを走行した。



Fig. 1 Scene of the DS Experiment

#### 2.2 実車実験

実車実験は自動車学校内のコースにて、Fig. 2のような教習車を用いて行った。被験者として、運転免許証を所持する18名を募った。各被験者は飲酒前に周回、先行車追従、8の字走行、赤信号での停車などのタスクに従って約1時間走行する。その後DS実験と同じ要領で約1時間、飲酒時間を設け、呼気アルコール濃度0.40 mg/L以上を目標に飲酒を行った。飲酒後には、飲酒前と同様のタスクを実施し、約1時間走行した。安全に実験を行うため、自動車学校の指導員が、助手席に同乗し、走行中に危険が発生した場合に備えて、即座に補助ブレーキ操作を行える体制を整えた。加えて、走行速度上限は飲酒前後ともに40 km/hとした。



Fig. 2 Scene of the Actual Vehicle Experiment

#### 2.3 取得データについて

本研究のDS実験と実車実験ではそれぞれCANおよび、DMCデータを取得した。データはすべて15 Hzにリサンプリング処理を行う。CANデータとしては車速、アクセル踏量、ステアリング角、車体角速度、道路中央からの距離(DSのみ)を取得する。DMCデータについてはカメラ映像から顔方向(roll, pitch, yaw)、頭部位置(x, y, z)、視線方向(pitch, yaw)、開眼度(左目、右目)を算出する。さらに視線情報を用い、各フ

\* (公社)自動車技術会の了解を得て、「2025年春季大会学術講演会講演予稿集」文献番号 No. 20255129 より一部加筆して転載

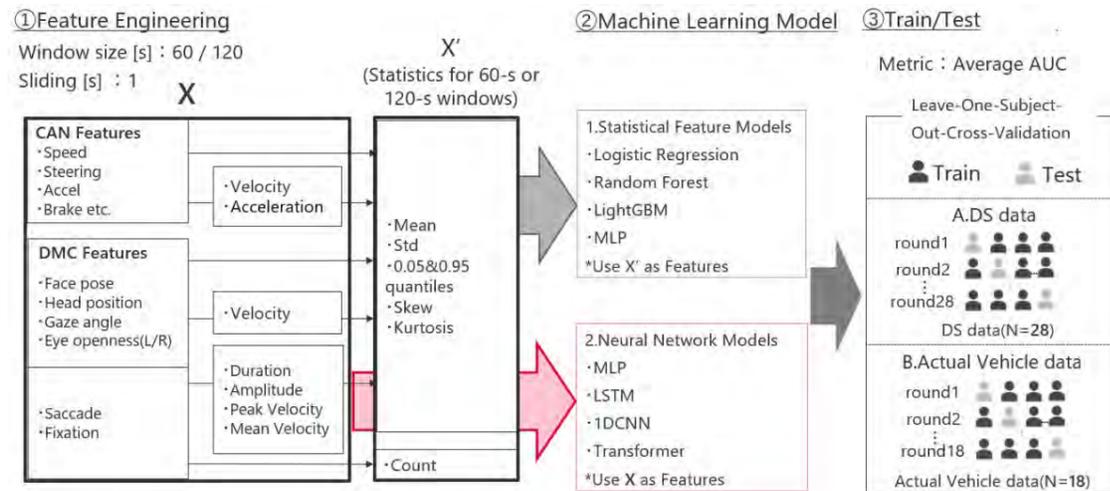


Fig. 3 Drunk Driving Detection Algorithm

レームがサッカードもしくは、停留に該当するか否かの判定を行う。

### 3. 飲酒運転検知アルゴリズム

Fig. 3 に本研究における飲酒運転検知の概念図を示す。飲酒運転検知モデルとして、2種類のモデルを作成する。1つ目は各センサ時系列データに対して、60秒窓または120秒窓で各統計量を算出し、それらを特徴量に用いるモデルである。2つ目は統計量を算出せず、時系列データをそのまま特徴量として、使用するニューラルネットワーク系モデルである。アウトプットとしてドライバが飲酒状態にある確率を1秒毎に算出する。評価条件として、時系列の窓長を60秒にする場合と120秒にする場合、DSデータを使用する場合と実車データを使用する場合の組み合わせにより、合計4パターンで学習・評価を行う。モデルの学習と評価にはLeave-One-Subject-Out-Cross-Validationを採用した。これは全被験者のうち1名を評価データとして取り除き、残りの被験者データを用いて学習を行う手法であり、この手順を全被験者繰り返すことで被験者間における汎化性能を評価することができる。モデルの性能指標として真陽性率と偽陽性率の関係を表すROC曲線(Receiver Operating Characteristic curve)の下面積であるAUC(Area Under the Curve)の全被験者平均を用いる。AUCはモデルが正例と負例をどれだけ正しく区分できているかを表し、値が1に近い

ほど性能が高いことを表す。

#### 3.1 入力特徴量の設計

サッカードと停留を除く、すべてのCANおよび、DMCデータについて、各データの速度(変化量)を算出する。さらに、サッカードおよび、停留については、それぞれの継続時間、振幅(pitch, yaw)、ピーク速度、平均速度を算出する。

#### 3.2 機械学習モデル

特徴量に統計量を用いるモデルでは、CANおよび、DMCデータに対して、60秒窓または120秒窓で各統計量を算出し、最終的な入力値とする。統計量は平均、標準偏差、5%・95%タイル、尖度、歪度、回数(サッカード、停留のみ)を使用する。特徴量を入力し、飲酒か否かを推定する分類器としてはLogistic Regression, Random Forest, LightGBM, MLP(Multilayer perceptron)の4モデルを使用する。Logistic Regressionは線形モデルであり、解釈性が高い手法である。Random ForestおよびLightGBMはいずれも決定木に基づくモデルであり、前者は多数の決定木を用いたバギングによって高い汎化性能を実現し、後者は勾配ブースティングを用いることで、より高精度かつ高速な学習が可能である。MLPは複数の全結合層から構成されるモデルで、非線形な関係を学習できる点が特徴である。

ニューラルネットワーク系モデルではCANおよ

び、DMCデータそれぞれについて、統計量を算出せず、60秒窓もしくは120秒窓の時系列データをそのまま使用する。分類器としてMLP, 1DCNN(1-Dimensional Convolutional Neural Networks), LSTM(Long Short-Term Memory), Transformerの4つを使用する。1DCNNは畳み込み演算を用いて時系列内の局所的な特徴を抽出する手法である。LSTMは長期依存関係を捉えるのに適したリカレントニューラルネットワークであり、時系列データの扱いに強いとされている。Transformerは自己注意機構により、時系列全体の関係性を効率的に学習できるモデルである。

## 4. 結果と考察

### 4.1 検知性能

#### 4.1.1 DSデータを用いた際の検知性能

Fig. 4, Fig. 5にDSデータを用いて学習・評価を行った際の性能を示す。Fig. 4, Fig. 5の各グラフの棒はAUC平均を、エラーバーは標準偏差を示す。灰色の棒グラフは、特徴量に統計量を用いるモデルを表し、赤色の棒グラフは、ニューラルネットワーク系モデルを表す。60秒窓、120秒窓ともにAUC平均が最も高いモデルは1DCNNとなった。AUC平均が最高の0.867となった120秒窓の1DCNNに関して、Fig. 6には分類の際の閾値を変更した場合の正解率・F1スコアを示す。正解率の最高値は0.707、F1スコアの最高値は0.690となった。Fig. 7にはROC曲線を示す。

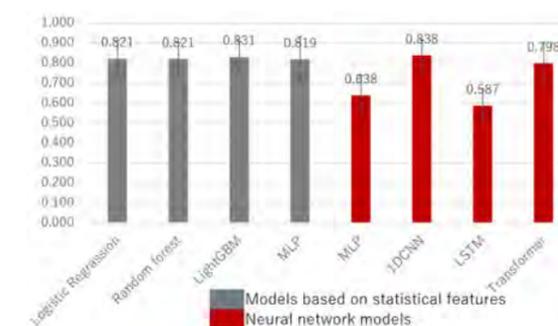


Fig. 4 Average AUC on DS Data (60-second Window)

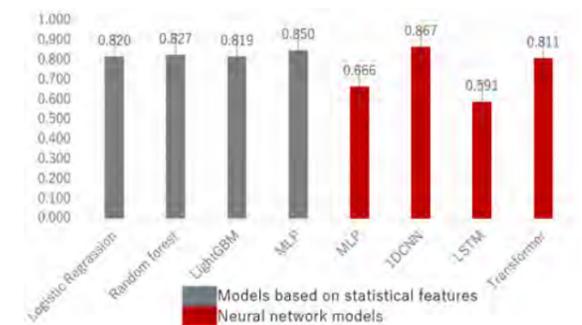


Fig. 5 Average AUC on DS Data (120-second Window)

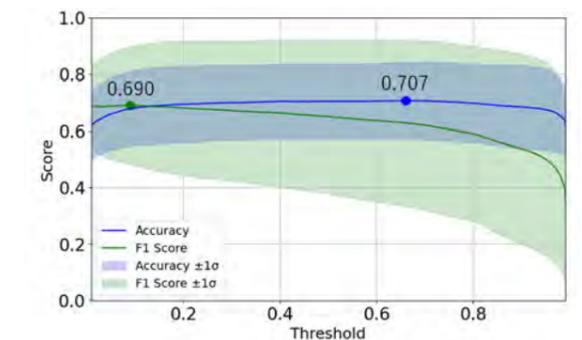


Fig. 6 Accuracy and F1 Score with Varying Thresholds (1DCNN/120-second Window)

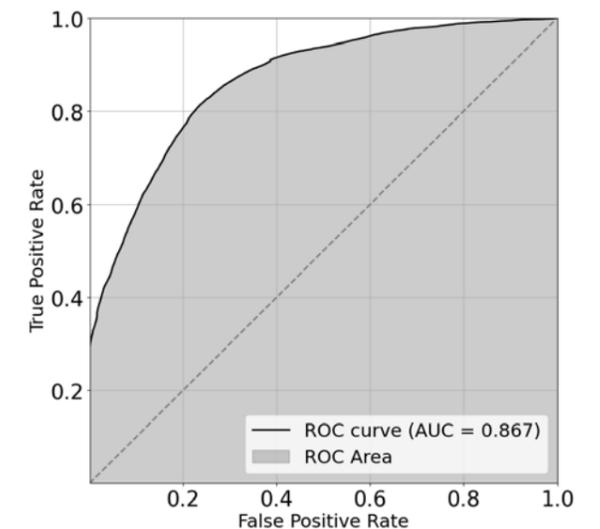


Fig. 7 ROC Curve (1DCNN/120-second Window)

#### 4.1.2 実車データを用いた際の検知性能

Fig. 8, Fig. 9に実車データを用いて学習・評価を行った際のAUC平均を示す。60秒窓、120秒窓ともにAUC平均は、1DCNNが最高となった。

AUC平均が最高の0.973となった120秒窓の1DCNNに関して、Fig. 10に閾値ごとの正解率・F1

スコアを示す。正解率の最高値は0.833となり、F1スコアの最高値は0.824となった。Fig. 11にはROC曲線を示す。また、Fig. 12には、ある被験者の飲酒前後の走行データの一部を対象に、モデルが出力した「飲酒である確率」の時間的推移を示す。閾値を0.5に設定した場合を仮定すると、飲酒前の検知開始直後を除いて正しく判定できているものの飲酒後は走行途中から正しい検知ができていない時間が長く存在する。

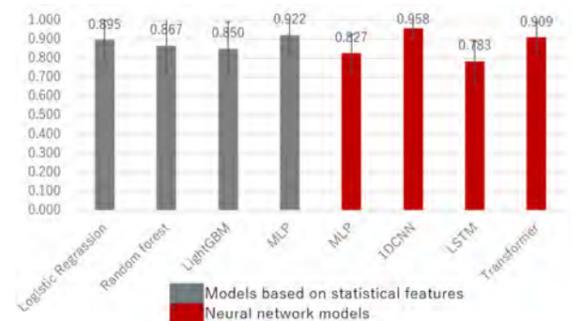


Fig. 8 Average AUC on Actual Vehicle Data (60-second Window)

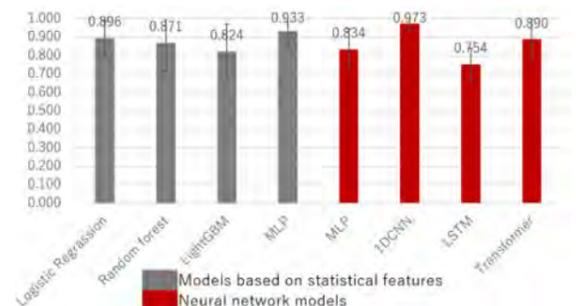


Fig. 9 Average AUC using Actual Vehicle Data (120-second Window)

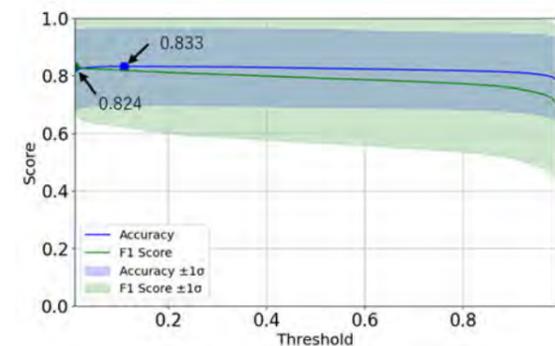


Fig. 10 Accuracy and F1 Score with Varying Thresholds (Actual Vehicle/1DCNN/120-second Window)

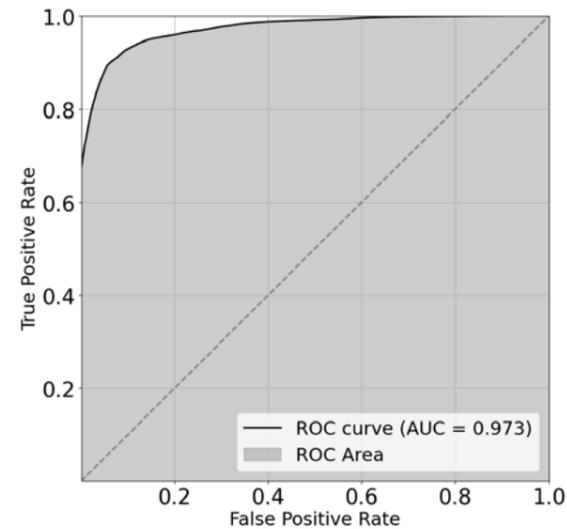


Fig. 11 ROC Curve (Actual Vehicle/1DCNN/120-second Window)



Fig. 12 A Sample of Drunk Driving Probability Profile (Actual Vehicle/1DCNN/120-second Window)

### 4.1.3 検知性能に関する考察

DSと実車それぞれのデータによる飲酒運転検知の結果を比較すると、DSよりも実車のAUC平均が全体的に高くなった。これにはいくつかの要因が考えられる。第1の要因に、実車とDSの緊張感や没入感の違いが挙げられる。実車では被験者は実際の運転環境に置かれるため、緊張感や没入感が高まり、飲酒による影響がより顕著に表れた可能性が考えられる。一方、DSは仮想空間での運転であるため、心理的な負担が低く、行動の変化が表れ難かった可能性が考えられる。第2の要因にDS酔いが与える影響が考えられる。DS酔いの症状は被験者により異なるものの、DS酔いの症状が強く出る被験者の場合は、飲酒による酩酊との識別が困難になってしまう可能性がある。第3の要因

に、実車での実験環境が比較的単純だったことが挙げられる。本研究では、実車実験を自動車学校内のシンプルなコースで実施し、制限速度を40 km/hに設定した。また、自車以外の自動車は最大で1台の先行車のみとした。これにより、交通環境の変化が最小限に抑えられ、走行速度など、データのばらつきが少なくなった。一方、DSでは市街地や高速道路などのシナリオを用意し、各シナリオに応じた速度制限を設定した。また、複数台の車両をコース上に配置するなど、現実に近い交通環境を再現した結果、環境が複雑化し、運転行動にばらつきが生じた可能性がある。

モデル別の検知性能を比較すると1DCNNがすべての条件においてAUC平均が最も高くなった。1DCNNは他のニューラルネットワーク系モデルと比較して時系列データの局所的な特徴を捉えることに長けたモデルであるため、飲酒によるドライバ挙動の局所的な変化を効果的に捉えることができたと考えられる。

### 4.2 重要特徴量

DS、実車それぞれについて、120秒窓で学習・評価した際の特徴量の重要度の確認を行う。Fig. 13にはDS、Fig. 14には実車データを用いてLogistic Regressionを行った際の回帰係数を示す。Fig. 13、Fig. 14では各特徴量について回帰係数の絶対値が大きい順に上位30件を表示している。各図の上部に表示されている特徴量が検知において特に重要であることが分かる。DSにおける特徴量の最上位は「サッカド振幅pitch方向の歪度」であり、実車における特徴量の最上位は「サッカド回数」となった。またDS、実車ともに上位にはCAN特徴量よりもDMC特徴量が多いこと分かる。これらの結果から、飲酒による状態の変化はCAN特徴量よりもDMC特徴量によく現れ、特にサッカドをはじめとした目の動きに現れやすいことが確認できた。

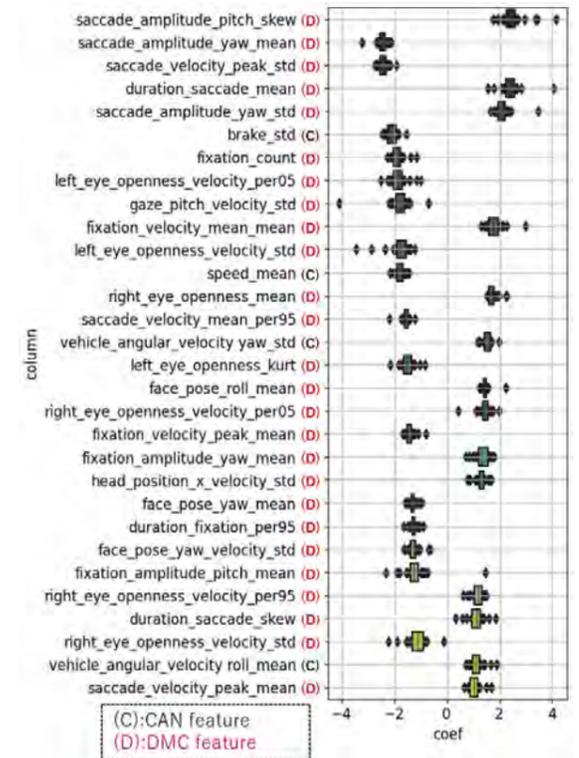


Fig. 13 Logistic Regression Coefficients (DS / 120-second Window)

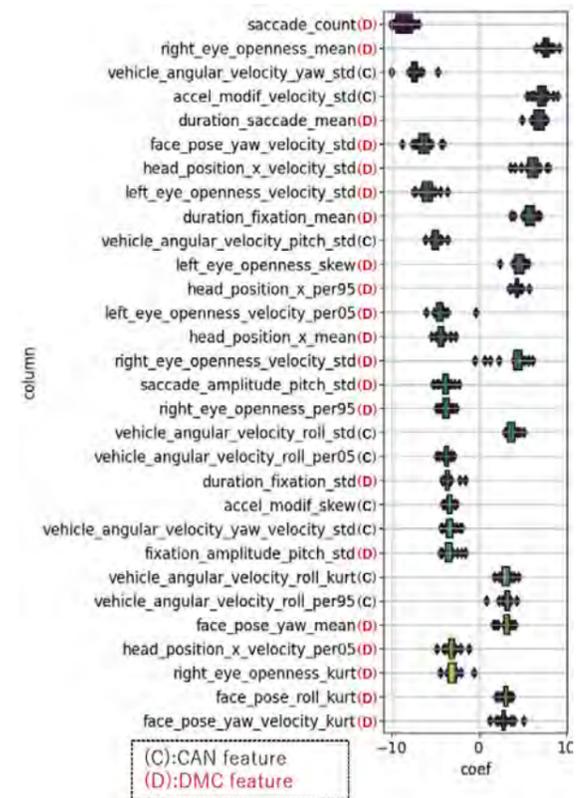


Fig. 14 Logistic Regression Coefficients (Actual Vehicle/ 120-second Window)

## 5. まとめ

本研究では DS, 実車それぞれの環境で飲酒運転データを取得し, 複数の機械学習手法により, 飲酒運転検知モデルの構築・学習・評価を行った. その結果, 以下の知見が得られた.

1. DS データ (N=28) を用いた飲酒運転検知を行った場合, 特徴量を 60 秒窓, 120 秒窓にした際の両方で, 1DCNN が最高性能になった.
2. 実車データ (N=18) を用いた飲酒運転検知を行った場合, 特徴量を 60 秒窓, 120 秒窓にした際の両方で, 1DCNN が最高性能になった.
3. 学習後の Logistic Regression モデルの回帰係数を可視化したところ, サッカーや開眼度等の眼球運動に関連した特徴量が回帰係数の絶対値の上位に多く含まれており, 飲酒運転の検知の際には特に目の動きが重要な指標となることを確認できた.

## 6. むすび

### 6.1 実験について

今回は DS および, 実車を用いて, データの収集を行ったが, 両実験方法に関して, 現実の走行環境との乖離が存在する. DS 実験は, 仮想の交通環境であり, 没入感が低いという問題がある. また, 被験者によっては DS 酔いが発生するため, 飲酒による酩酊との判別が困難になってしまうという懸念を抱えている. また実車実験に関しては, 今回は自動車学校のシンプルなコースを用いて, 速度制限を 40 km/h に設定して実施した. それに対して, 実際の公道ではさらに多様な複雑な交通状況が存在する. より実用的なデータを取得するために, 実際の交通状況に近い環境で実験を行うことが好ましい. 今後は公道での非飲酒状態の運転データで誤検知率を検証しながら, DS や教習所・テストコースのシナリオを見直し, 事故の要点を押さえた飲酒状態のデータの収集も検討していく.

### 6.2 学習・評価について

今回は DS と実車のデータを別々に学習・評価したものの, 今後は, すべてのデータを統合して行うこと

も考えられる. その際には CAN センサが異なるため, 数値の調整が必要となる. また, 今回使用しなかった機械学習モデルの利用の検討や, 各モデルについてハイパーパラメータチューニングなどの調整を行うことでさらに性能向上が期待できる.

### 6.3 呼気式アルコールセンサとの併用の可能性

本研究では, CAN および, DMC から取得したデータを用いて, 飲酒運転検知モデルの開発を行った. さらに, 呼気式アルコールセンサを併用する手法についても検討の余地がある. 運転開始時に呼気式アルコールセンサでのスクリーニングを行い, 走行開始後の検知を CAN データと DMC データを用いて連続的なモニタリングを行うことで, 走行開始から終了までの全過程において, 飲酒運転を高性能かつ網羅的に検知することが可能となる. 呼気式センサの導入には一定のコストが伴うものの, 本手法を組み合わせることで, より実用的かつ信頼性の高い飲酒運転防止システムの構築が期待される.

## 謝辞

実車実験の実施にあたり, 小郡自動車学校, 知立自動車学校, 中部日本自動車学校の皆様から, 多大なるご支援とご協力を賜りましたこと, 心より感謝申し上げます. 実験用の車両のご提供や施設のご利用許可などをご快諾いただき, 実験の円滑な実施に大変貢献していただきました. 厚く御礼申し上げます.

### 参考文献

- 1) National Highway Traffic Safety Administration: Traffic Safety Facts Research Note, Overview of Motor Vehicle Traffic Crashes In 2023. (2025)
- 2) Euro NCAP. Euro NCAP Vision 2030: a safer future for mobility. In-Cabin Monitoring. (2023)
- 3) 日本自動車研究所: アルコールインターロック装置の活用方策の検討のための基礎的調査 (全文) (2007)
- 4) Igor Radun, Jussi Ohisalo, Sirpa Rajalin, Jenni E. Radun, Mattias Wahde, Timo Lajunen: Alcohol ignition interlocks in all new vehicles: A broader perspective, Traffic Injury Prevention, Vol.15 Issue4 pp.335-342 (2014)
- 5) Xiaohua Zhao, Xingjian Zhang, Jian Rong: Study of the Effects

of Alcohol on Drivers and Driving Performance on Straight Road, Mathematical Problems in Engineering, Vol.2014, pp.1-9 (2014)

- 6) Emma Tivesten, Viktor Broo, Mikael Ljung Aust: The influence of alcohol and automation on drivers' visual behavior during test track driving, Volume 95, pp. 215-227 (2023)
- 7) Kevin Koch, Martin Maritsch, Eva van Weenen, Stefan Feuerriegel, Matthias Pfäffli, Elgar Fleisch, Wolfgang Weinmann, Felix Wortmann: Leveraging driver vehicle and environment interaction: Machine learning using driver monitoring cameras to detect drunk driving, Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems, Article No.322, pp.1-32 (2023)

## 著者



### 中村 典雅

なかむら のりまさ

先端技術研究所 HMI 研究室  
ドライバ状態推定技術開発に従事



### 山高 大乘

やまたか みのり

先端技術研究所 HMI 研究室  
ドライバ状態推定技術開発に従事



### 山岡 将綺

やまおか まさき

先端技術研究所 HMI 研究室  
ドライバ状態推定技術開発に従事



### 伊藤 隆文

いとう たかふみ

先端技術研究所 HMI 研究室  
人間特性技術の研究開発に従事