

令和3年度 博士論文

ドライブレコーダデータ解析による
運転状態推定に関する研究

指導教員

主査 小栗宏次 教授

副査 戸田尚宏 教授

副査 神山斉己 教授

2022年3月

愛知県立大学 大学院情報科学研究科 博士後期課程

2019841003

大石 啓之

目次

第1章	序論.....	1
1.1	研究背景と目的.....	1
1.2	本論文の構成.....	4
第2章	本論文の関連技術・研究.....	5
2.1	ITSについて.....	5
2.2	事業用自動車の事故.....	7
2.3	デジタルタコグラフ.....	10
2.4	ドライブレコーダ.....	12
2.5	ドライブレコーダ・デジタルタコグラフの活用.....	14
第3章	運転中の眠気検知手法の提案.....	17
3.1	眠気推定の先行研究.....	17
3.1.1	ドライバの状態と眠気.....	17
3.1.2	眠気の見義と評価方法.....	17
3.1.3	運転中の眠気センシング手法.....	26
3.1.4	従来手法.....	30
3.2	実験方法-データ収集.....	35
3.2.1	使用機器と車両.....	35
3.2.2	記録データ.....	36
3.2.3	レーン線位置の導出.....	38
3.3	眠気評定.....	40
3.4	データ解析.....	40
3.4.1	スクリーニング.....	40
3.4.2	レーン線データからわかる運転傾向.....	45
3.4.3	眠気による運転傾向の変化.....	47
3.4.4	考察.....	50
3.5	学習モデル.....	51
3.5.1	ランダムフォレスト.....	51
3.5.2	LSTM.....	54
3.5.3	CNNLSTM.....	55
3.6	提案手法.....	58
3.6.1	AttentionCNNLSTM.....	58
3.6.2	特徴量設計.....	61

3.7	眠気推定実験.....	63
3.7.1	使用するモデル.....	63
3.7.2	検証方法と評価指標.....	64
3.8	結果・考察.....	67
3.8.1	Leave-one-out 交差検証による推定精度.....	67
3.8.2	個人外推定.....	68
3.8.3	CNN 層の数の効果.....	70
3.8.4	Attention 層の効果.....	71
3.9	まとめ.....	73
第4章	修正操舵に着目しながら運転検出.....	74
4.1	先行研究.....	74
4.2	DS によるながら運転時の挙動調査.....	75
4.2.1	修正操舵について.....	75
4.2.2	車両挙動調査実験.....	75
4.2.3	実験結果.....	77
4.2.4	特徴量検討.....	81
4.3	実車データによるながら運転検出手法の提案.....	85
4.3.1	実車データからの操舵角算出.....	85
4.3.2	修正操舵に基づく特徴量抽出.....	87
4.3.3	アンサンブル学習によるながら運転検出.....	88
4.4	検証実験.....	89
4.4.1	DS を使用した実験.....	89
4.4.2	実車データを使用した実証.....	89
4.4.3	検証方法.....	90
4.5	結果・考察.....	91
4.6	まとめ.....	94
第5章	結論.....	94
	研究倫理.....	96
	利益相反.....	97
	謝辞.....	98
	参考文献.....	99
	研究業績.....	107

図 1.1	交通事故死者数の推移（昭和 23 年～令和 2 年）	1
図 1.2	事業用自動車総合安全プラン 2020	2
図 2.1	ITS のシステム概念図	5
図 2.2	官民 ITS 構想・ロードマップ（一部抜粋）	7
図 2.3	交通事故発生件数と死傷者数の推移	8
図 2.4	事業用自動車における事故件数	8
図 2.5	事業用自動車における交通事故死者数	9
図 2.6	トラックにおける死亡事故原因割合	10
図 2.7	アナログタコグラフ外観例	11
図 2.8	アナログタコグラフの記録例	11
図 2.9	デジタルタコグラフの解析画面例	12
図 2.10	ドライブレコーダの出荷台数（事業者＋一般向け）	13
図 2.11	ドライブレコーダの分類	13
図 2.12	トラックでのドライブレコーダ導入効果（2014 年）	14
図 2.13	レーダーチャートによる評価	15
図 3.1	VAS の例	19
図 3.2	覚醒状態の 7 カテゴリ分類	21
図 3.3	眠気レベル 2 に収束する推定例	32
図 3.4	学習データに実車走行データを用いた眠気レベル推定結果の例	33
図 3.5	DS と実車各データと正解眠気レベルとの相関関係	34
図 3.6	正解眠気レベルごとの左右レーン線距離同士の相関関係	34
図 3.7	個人内推定と個人外推定結果の比較	35
図 3.8	ドライブレコーダ内蔵型デジタルタコグラフ DTG7	36
図 3.9	録画映像サンプル	37
図 3.10	車線と車両の位置関係	38
図 3.11	フロントカメラ映像	39
図 3.12	車両と路面の幾何学的関係	39
図 3.13	評定された眠気レベルの時系列変化の例	40
図 3.14	運送業務における一日の運行例	41
図 3.15	レーン線までの距離	42
図 3.16	車線幅の算出方法	43
図 3.17	スクリーニング処理結果	44
図 3.18	スクリーニング処理によって除去された場面の例	44
図 3.19	ドライバごとの走行位置のヒストグラム	46
図 3.20	眠気レベルによるヒストグラム形状の変化（ドライバ G）	48
図 3.21	眠気レベルに対する各統計値の変化	49

図 3.22	Permutation importance の概要	53
図 3.23	LSTM モデルの概念図.....	55
図 3.24	複数チャンネルの畳み込み.....	56
図 3.25	Max プーリング層.....	57
図 3.26	CNNLSTM モデルの構成.....	57
図 3.27	CNN2LSTM モデルの構成.....	58
図 3.28	Bahdanau らのニューラル翻訳モデル.....	59
図 3.29	CNN2LSTMatt モデル	60
図 3.30	Leave-one-out 交差検証の方法.....	64
図 3.31	混同行列.....	65
図 3.32	Leave-one-out 交差検証と個人外推定の比較 (金子モデル・ドライバ G) ..	69
図 3.33	Leave-one-out 交差検証と個人外推定の比較 (RF モデル・ドライバ G) ...	69
図 3.34	Leave-one-out 交差検証と個人外推定の比較 (提案モデル・ドライバ G) ..	70
図 3.35	CNN 層の数による比較.....	71
図 3.36	Attention 層の重み (初期状態)	72
図 3.37	Attention 層の重み (学習済みモデル)	72
図 4.1	実験に用いた DS の全景.....	76
図 4.2	実験に使用した DS のコースレイアウト	76
図 4.3	走行コースの一部例.....	77
図 4.4	操舵角の時間変化 (通常運転時)	77
図 4.5	操舵角の時間変化 (ながら運転時)	78
図 4.6	操舵角の時間変化 (窓枠 20 秒間)	78
図 4.7	高速フーリエ変換により得られる周波数スペクトル.....	78
図 4.8	操舵角速度の時間変化 (通常運転時)	80
図 4.9	操舵角速度の時間変化 (ながら運転時)	80
図 4.10	大きな角速度の発生頻度比較	80
図 4.11	予測誤差とサンプリング周期	82
図 4.12	$e(n)$ の度数分布	82
図 4.13	ステアリングエントロピーの時間変化 (通常運転時)	83
図 4.14	ステアリングエントロピーの時間変化 (ながら運転時)	83
図 4.15	ステアリングエントロピーのヒストグラムによる比較.....	84
図 4.16	バンドパスフィルタ適用前後の比較.....	86
図 4.17	操舵角と横方向加速度の関係	87
図 4.18	DS 実験による操舵角と加速度からの推定操舵角の比較.....	87
図 4.19	バギング木によるアンサンブル学習の概念図.....	88
図 4.20	混同行列.....	90

図 4.21	特徴量の分布例 (DS データ使用時)	93
図 4.22	特徴量の分布例 (実車データ使用時)	93

第1章 序論

1.1 研究背景と目的

近年、自動車事故全体の発生件数は、1970年代ごろをピークに減少の一途をたどっている。図 1.1 に、過去 72 年間の自動車事故件数の推移を示す [1]。最新の情報では、2020 年は事故件数 309,178 件、死者数 2,839 人となっている [2]。内閣府が掲げている交通安全基本計画での 2020 年度までに交通事故死者数を 2,500 人以下にする目標 [3] は残念ながら達成できていないが、ここ数年は過去最少を更新し続けている。事業用自動車における交通事故に関しても、発生件数・死者数共に同様に減少を続けている。平成 29 年に策定した事業用自動車総合安全プラン 2020 (図 1.2) [4]において、令和 2 年までに事故件数 23100 件以下、死者数 235 人以下とする削減目標が示されている。交通事故件数全体に対し、事業用自動車が起こす事故件数割合は、約 7% (令和元年) 程度であるが、死亡事故件数では約 14%となる [5]。つまり、一度事故を起こすと事業用車両は死亡事故につながりやすいといえ、また、事業用自動車にはトラック・バスが含まれるため大型車両が多く、事故が起きると被害が甚大化しやすい。実際に平成 24 年と 28 年には、貸切バスの事故により多くの犠牲者が発生し、そのたびに大きな社会問題にもなっている。

事故の原因はさまざまであるが、事故統計によると法令違反別では、漫然運転とわき見運転が大きな割合を占め、トラックでは全体の約 30%を占める。




図 1.1 交通事故死者数の推移 (昭和 23 年～令和 2 年)
(出典：警察庁 「令和 2 年中の交通事故死者数について」)

事業用自動車総合安全プラン2020

～行政・事業者・利用者が連携した安全トライアングルの構築～

事業用自動車に係る総合的な安全対策の見直し

■ 軽井沢スキーバス事故を受けた新たな安全対策が策定されたこと、自動車の先進安全技術の普及が進みつつあること等の自動車事故をめぐる状況変化、人口減少や高齢化の進展、2020年東京オリンピック・パラリンピックの開催等の動向を踏まえ、事業用自動車総合安全プラン2009（平成21年策定）を改訂。

事業用自動車総合安全プラン2020（計画期間：H29～H32）

第10次交通安全基本計画の計画期間と合わせるとともに、プラン2009から以下の点を新たに追加し、2020年東京オリンピック・パラリンピックに向けて、世界一安全な輸送サービスの提供を実現するため、ソフト・ハード両面から総力を挙げて事故の削減に取り組む。

【主な追加対策事項】

- 各業態（バス、トラック、タクシー）における目標設定
- 「利用者」を含めた関係者の連携強化による安全トライアングルの構築

○ 軽井沢スキーバス事故等による安全対策を反映
○ 自動運転など交通事故の削減及び被害軽減に大きな効果が期待される新技術を安全対策に反映

【目標値】（プラン2009の目標）①死者数を平成30年に250人、②人身事故件数を平成30年に3万件、③飲酒運転ゼロ

① 平成32年までに**死者数235人** ② 平成32年までに**事故件数23,100件以下** ③ **飲酒運転ゼロ**（※）

【バス】 # 死者数10人以下	【バス】 # 事故件数1,100件以下	
【タクシー】 # 死者数25人以下	【タクシー】 # 事故件数9,500件以下	※バス、タクシー、トラック共通
【トラック】 # 死者数200人以下	【トラック】 # 事故件数12,500件以下	

（参考）H28事業用自動車交通事故発生状況 事故件数33,336件、死亡者数363人、飲酒運転54件

事業用自動車総合安全プラン2020 重点施策

<p>1. 行政・事業者の安全対策の一層の推進と利用者を含めた関係者の連携強化による安全トライアングルの構築</p> <ul style="list-style-type: none"> ・事業者における法令遵守の徹底と安全輸送の取組の強化 ・監査等の実効性の向上による違反行為等の是正及び悪質事業者の排除 ・利用者を含めた関係者の連携強化による安全性の向上 等 	<p>4. 超高齢社会を踏まえた高齢者事故の防止対策</p> <ul style="list-style-type: none"> ・高齢運転者の特徴を踏まえた事故防止対策 等
<p>2. 飲酒運転等悪質な法令違反の根絶</p> <ul style="list-style-type: none"> ・飲酒運転・薬物運転根絶のための指導等の実施 等 	<p>5. 事故関連情報の分析等に基づく特徴的な事故等への対応</p> <ul style="list-style-type: none"> ・モード毎や地域毎の特徴を捉えたきめ細やかな事故の分析とその結果に基づく適切な対策の実施 ・ドライブレコーダー映像等、事業者が保有する情報を活用した運転特性や運転技能の確認及び研修の実施等指導監督の徹底 等
<p>3. 自動運転、ICT技術等新技術の開発・利用・普及の促進</p> <ul style="list-style-type: none"> ・自動運転等新たな安全技術の開発・普及促進 等 	<p>6. 道路交通環境の改善</p> <ul style="list-style-type: none"> ・事故発生割合の高い区間における交差点改良や歩道の整備、中央帯の設置、信号機改良 等

図 1.2 事業用自動車総合安全プラン 2020

（出典：国土交通省 事業用自動車総合安全プラン 2020）

漫然運転は、居眠り運転等の原因により引き起こされ、居眠り運転は意識低下の状態に陥ることから重大な事故に直結する。また、わき見運転原因に、近年では携帯機器の使用があげられる。交通事故全体における携帯電話使用等に係る交通事故件数の推移は、スマートフォン等の普及に伴い平成 29 年にはピークとなり、令和 2 年では前年に比べて半減しているが依然として 1283 件発生している [6]。死亡事故率は、携帯電話等使用時は、使用なし時に比べて約 1.9 倍に上昇すると言われている [6]。ここでの携帯電話使用等に係る行動には、カーナビ等注視・携帯電話操作（画像目的・通話目的）が含まれる。平成 28 年には、位置情報を利用したスマートフォン向けゲームが広まり、ゲーム起因の重大事故も発生し社会問題にもなった。運転中の携帯電話使用等にかかわる違反については、令和元年に罰則強化され、各関係団体や事業者でも、事故防止のための啓発活動に力を入れている [7]。

事故を防止する技術として、様々な運転支援装置が研究され、一部実用化されつつある。（アダプティブ）クルーズコントロールや、プリクラッシュセーフティシステム、

車線逸脱警報システム、レーンキープアシストなどがその代表例である。これらは、将来的に自動運転の技術につながるものでもあり、近年性能向上が著しく、新車搭載率も増えてきている。しかし、未だ完全に機械に操作を任せる性質の機能ではなく、また、車両の使用サイクル（平均使用年数）が約 17 年以上と長い大型の事業用自動車には、普及に時間がかかることが予想される [8]。このため、現段階では居眠り運転やながら運転は防止することが必要であり、さらに、自動運転への過渡期には車両側が自動運転中にドライバに運転操作権限を渡す必要もあるとされている。そのためのドライバ状態モニタリングの研究が多く進められている。

これまでに居眠りを含む漫然運転や脇見運転によって車両挙動にどのような影響が及ぼされるのか調査したドライバモニタリングに関する様々な研究が行われてきた。漫然運転については例えば、福井は連続運転によるドライバの疲労と車両挙動に関して、操舵遅れ時間や車両の横変位量などの操舵機能に関する指標と覚醒度や認知判断機能との間に相互に関係があると報告している [9]。Eggert らは車両情報である速度や車間距離から衝突余裕時間(TTC)を算出して、車線変更時のドライバの運転モデルを作成する研究を行った [10]。また、Higgs らは車両情報から車両追従走行時の状態や行動群の識別や分類を行った [11]。伊藤らは、道路形状を考慮することにより車両挙動の変化からドライバの眠気レベル推定を実施した [12]。そして、脇見運転については岡山らは情報機器操作によってカーブ走行にどのような影響が出るのか調査した [13]。大北らは脇見がどのような状況に行われ、ヒヤリハットや事故の危険度にどのような影響を及ぼすのか調査した [14]。安部らは脇見時間と THW や減速行動の関係性について調査している [15]。また、江部らはカーナビの音声操作がドライバに及ぼす影響について調査した [16]。Kwan らはタッチスクリーンとロータリーコントローラによるカーナビ操作でそれぞれにどのような差が現れるのかについて調査している [17]。しかし、これらの研究はそれぞれの危険運転が車両挙動にどのように影響を及ぼしているのか調査しているものの、車両挙動からリアルタイムに危険な運転を検知している研究というわけではない。これでは実際の運転の際に危険挙動が現れていても、ドライバに注意するようなシステムを構築することは困難である。

リアルタイムに漫然運転や脇見運転を検出する研究として、漫然運転を検知する研究については大須賀らは顔表情による覚醒度の評定を行い心電図や視線などの生理指標を用いてドライバの状態推定を行う漫然運転を検知した [18] [19] [20] [21] [22] [23]。このように生体信号によってリアルタイムに眠気の推定を行うもの [24] [25] [26] [27] [28] [29] [30] [31] [32] [33] [34]がある。しかし、実用化の面を考えると、生体信号を接触式センサで取得するのはドライバにとって負担になり、非接触センサを用いたとしても、システムが大掛かりになり、走行時のノイズも問題となる。カメラによるドライバの撮影も、ロバスト性を十分考慮した特殊なカメラが必要であり、コスト面やドライ

バのプライバシーの問題もあり、ユーザーからは受け入れ難いシステムとなってしまう。

そこで、本研究では、様々な車両に取り付け可能なドライブレコーダに着目し、ドライブレコーダで取得可能なデータより、眠気状態やながら運転等のドライバ状態をリアルタイムに推定する方法を提案することを目的とする。

ドライブレコーダは、現在、一般車両・事業用車両含め、急速に普及している [35]。その機能等は後述するが、普及初期ではカメラ映像を事故の原因究明に用いる程度であったが、現在ではその用途は特に事業用では運行管理や安全運転指導など、多岐にわたっている [36]。ドライブレコーダ単体でドライバモニタリングが実現できれば、後付け可能であるため、最新の運転支援装置が搭載されていない古い年式の車両にも、予防安全機能を付加することが可能となる。

ドライバ状態を把握するための前述の研究では、安全のため、ドライビングシミュレーター（以下 DS）で検討されたものが多い。実際の車両を使用した場合でも、実験のための走行試験であったり、有事（事故やヒヤリハット）のデータを収集したデータベースを利用する研究が多い。本研究では、事業用自動車の通常の運行データを基に、普段の運転と異なる特徴を抽出する方法で、進めていく。

1.2 本論文の構成

本論文では、第 1 章は序論と研究背景、第 2 章で現在実用されている安全管理システムの概要、第 3 章と第 4 章で手法の提案と有用性の検討、第 5 章で全体のまとめとする。

第 2 章では ITS の現状と、事業用自動車の安全に関係する技術について述べる。

第 3 章ではドライブレコーダのデータから眠気レベル推定を行う手法の検討、

第 4 章ではながら運転の検出に有用な方法の提案について述べる。

第 5 章でまとめと今後の課題について述べる。

第2章 本論文の関連技術・研究

2.1 ITS について

ITS (Intelligent Transport Systems: 高度道路交通システム) は最先端の情報通信技術等を用いて人と道路と車両とを一体のシステムとして構築することにより, ナビゲーションシステムの高度化, 有料道路等の自動料金収受システムの確立, 安全運転の支援, 交通管理の最適化, 道路管理の効率化等を図るものである. (図 2.1)




図 2.1 ITS のシステム概念図

日本における ITS の方針は, 官民 ITS 構想・ロードマップが 2014 年に策定され, 以後原則毎年更新されている. 図 2.2 に 2020 年版の全体像を示す [37]. ITS 開発の基本的な考え方として, 交通事故の増大, 交通渋滞の拡大, 沿道環境の悪化, 地球環境との不調和, エネルギー消費の増大といった深刻な道路交通問題解決の切り札として期待されていることから, 早期に取り組みを行うことが重要である. このため, 以下の 9 つの重要な開発分野が整理されている [38]. この内容は, 基本的な柱はそのままに技術の進歩等に合わせて適宜見直されている.

1. ナビゲーションシステムの高度化
2. 自動料金収受システム
3. 安全運転の支援
4. 交通管理の最適化
5. 道路管理の効率化
6. 公共交通の支援
7. 商用車の効率化
8. 歩行者等の支援
9. 緊急車両の運行支援

この中で、本研究に深くかかわる 3. 安全運転の支援と、7. 商用車の効率化について概要を説明する。

安全運転の支援：

交通事故による死者数の増大により開発の必要性が高まった分野であり、交通事故の防止等を図るため、道路及び車両を高度情報化することにより、安全運転の支援分野の利用者サービスを早期に実現していくことを目標としている。利用者が体感できるサービスとしては、走行環境情報の提供や、危険警告、運転補助などがあげられ、最終的に自動運転につながっていく。システムの概要としては、事故等を未然に防ぐため、道路及び車両の各種センサにより道路や周辺車両の状況等の走行環境を把握し、車載機、道路情報提供装置により、リアルタイムで運転中の各ドライバーに走行環境情報の提供、危険警告を行う。

とされており、運転支援などは一部実用化されてきている。

商用車の効率化：

近年の物流サービスの多様化と渋滞発生等により、積載効率が低下した集配業務、物流事業におけるコストの増大、ドライバーの高齢化などの問題により必要性が高まった分野で、輸送効率の飛躍的向上を図るため商用車の効率化分野の利用者サービスを実現することを目標としている。具体的な利用者サービスは、商用車の運行管理支援や、商用車の連続自動運転があげられている。この分野も、実用化されている技術もあり、さらに、商用車の連続自動運転は、高速道路上での自動隊列走行の実証実験などが始まっている [39]。

本論文で取り上げるドライブレコーダ／デジタルタコグラフは、こうした開発目標に沿った機器でもあり、すでに安全や効率に寄与している。これらの機器の機能や応用は後述するが、さらなる高度化によって、ITS 技術の発展に貢献できる可能性がある。

官民ITS構想・ロードマップ²⁰²⁰ (ロードマップ全体像^{※1})

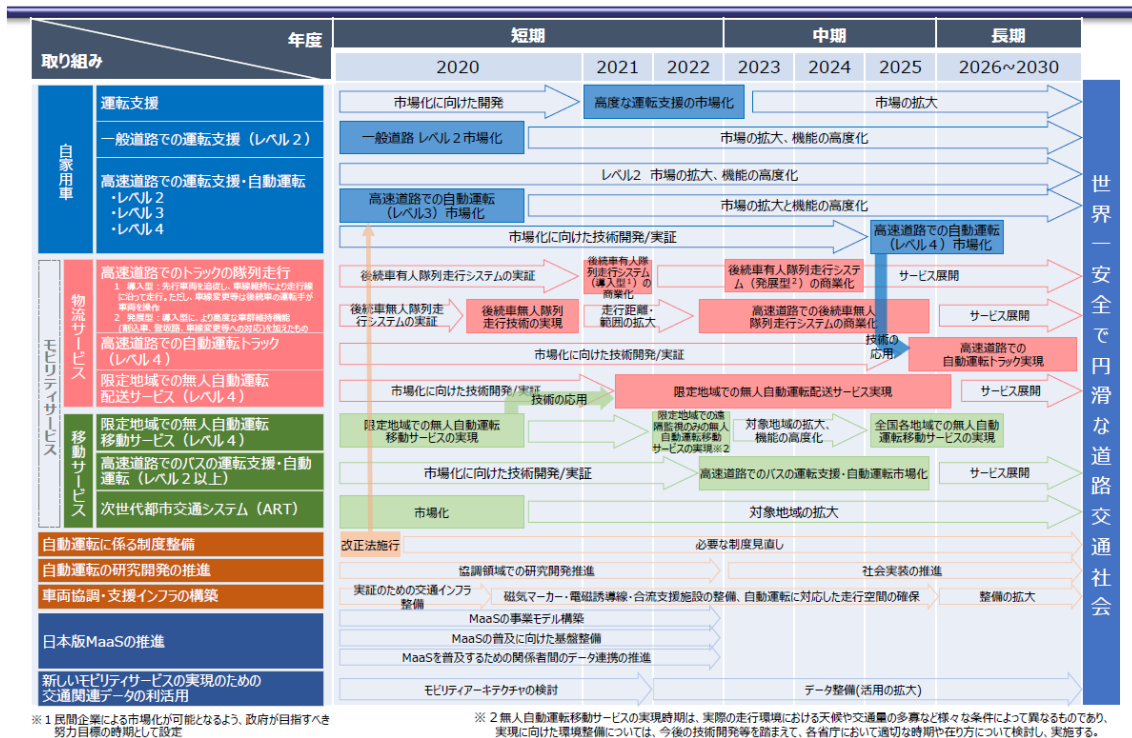


図 2.2 官民 ITS 構想・ロードマップ (一部抜粋)
(出典：首相官邸 官民 ITS 構想・ロードマップ 2020)

2.2 事業用自動車の事故

図 2.3 に、昭和 29 年から平成 30 年までの全体の交通事故件数、負傷者、死亡者数の推移を示す [40]。昭和 45 年には交通事故による死者数が最多となり、交通の安全に関し車両や車両の運転者等の責務を明確にした「交通安全対策基本法」が施行された。これを境に事故件数は減少するが、車両台数が増加するにしたがって再び上昇傾向になっている。その後、重点的な事故対策、シートベルト着用者率の向上、通学路における歩行空間の整備など様々な交通事故対策の実施や車両の衝突安全性の向上により平成 5 年頃から死者数は減少傾向に転じている。道路交通法の改定や自動車への安全運転のアシスト機能追加等により平成 15 年頃から事故発生件数も減少傾向になっている。このように、事故件数や死傷者数は自動車の母数や法整備、施策、安全技術の開発など、様々な要因で変動する。

事業用自動車における事故についても、近年は減少傾向になっている。図 2.4 に、事故件数、図 2.5 に死亡者数の推移を示す [41]。




図 2.3 交通事故発生件数と死傷者数の推移
(出典：内閣府 2019 年度版交通安全白書)




図 2.4 事業用自動車における事故件数
(出典：国土交通省 事業用自動車総合安全プラン 2020 最近の交通事故発生状況等)




図 2.5 事業用自動車における交通事故死者数

(出典：国土交通省 事業用自動車総合安全プラン 2020 最近の交通事故発生状況等)

これらの統計より、事業用自動車における事故件数は自動車全体の約 1/13 であるが、死者数は全体の約 1/10 であり、序論でも述べたように、件数当たりの死者発生割合が高いといえる。事業用自動車には大型車も含まれているため、大きな事故につながりやすいと考えられる。

事故原因の法令違反別割合を、図 2.6 に示す [5]。このグラフはトラックの死亡事故原因であるが、漫然運転と脇見運転を合わせると全体の 40%以上を占めている。居眠り運転は、事故原因としてここでは分類されていないが、一般的に漫然運転や過労運転に含まれ、ながら運転はわき見運転に含まれる。これらを統合して安全運転義務違反とする場合もある。

このような事業用自動車による法令違反や事故を防ぐ目的で、道路運送法、貨物自動車運送事業法、道路運送車両法、労働基準法などのさまざまな法令等が、ドライバや事業者に対して設けられている。例として労務面では、ドライバの過労防止のために、連続運転時間や休憩時間が定められている。自動車運送事業者は、運行管理者を営業所ごとに選任し、ドライバの指導監督、点呼によるドライバの疲労・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しなければならない。また、車両設備面では、大型車では速度を 90km/h 以下に抑える速度制限装置の装着義務化や、運行記録計の装着と記録管理の義務化などがあげられる。次節より、運行記録計の機能やその活用方法を述べる。




図 2.6 トラックにおける死亡事故原因割合

(出典：国土交通省 自動車運送事業に係る交通事故対策検討会報告書 (令和 2 年度))

2.3 デジタルタコグラフ

本節では、事業用自動車の安全運転管理機器であるタコグラフについて説明する。タコグラフ(Tachograph)とは、運行記録計とも呼ばれる機器であり、1952年にドイツで開発され、ドイツ語の Tachometer (回転速度計) と Graphink (記録) より自動車の速度を記録する機械は Tachograph と名付けられた [42]。

車両の運行状態を記録するものであり、「瞬間速度」、「走行距離」、「時間」の3種のデータを自動的に連続して記録しなければならないと、法により定められている。

図 2.3 で示した事故件数が、昭和 30 年代入りに大幅な増加となり、特に大型車両の事故が社会問題に発展した。これを機にタコグラフの装着が義務付けられ、1962年にバス、1967年には大型トラックに装着義務が課せられた。現在ではハイヤー・タクシー・中型トラックの一部にも装着が義務付けられている [43] [44]。国土交通省の型式認定を受けている機種しか使用できない。当初はアナログタイプでチャート紙という円盤状の記録紙への記録が主であった。図 2.7 に、アナログタコグラフの外観、図 2.8 に、記録されたチャート紙の例を示す。24 時間で一周する円盤状の台紙に、速度のグラフが自動で書き込まれる仕組みになっている。また、記録は1年間の保管義務がある。



図 2.7 アナログタコグラフ外観例



図 2.8 アナログタコグラフの記録例

タコグラフの装着により，事業者は車両の速度超過や労務違反を管理把握しやすくなり，また事故の際にも直前の運行状況がわかるため事故原因の究明もしやすくなるなど，事業用自動車の安全運転に貢献してきた。

1999 年にデジタル化され，電子データの記録媒体への記録が可能になった。「瞬間速度」，「走行距離」，「時間」の記録義務は変わらないが，デジタル化により，記録できる情報量が飛躍的に増加した [45]。現在では，エンジン回転数や GPS による位置情報，急発進急減速の管理，正確な時刻情報による細かな労務管理も可能になっている。また，ネットワーク型の登場で事業者／管理者は自社よりインターネットを介してのリアルタイム管理や動態管理も可能となってきている。図 2.9 に，デジタルタコグラフの記録管理ソフトの解析画面の一例を示す。このように，パソコン上の画面で任意の車両・時刻のデータをグラフとして確認することができる。



図 2.9 デジタルタコグラフの解析画面例

2.4 ドライブレコーダ

本節では、タコグラフと同様に、事故記録に役立つ機器であるドライブレコーダについて説明する。

ドライブレコーダは、カメラ車内外の映像を記録する機器である [46]。前述のデジタルタコグラフとは、映像が記録できる点が異なる。初期のドライブレコーダは、タクシーなどの事業用自動車から搭載が始まり、現在では、一般車両向けも含め、様々な機器が販売されている。低価格化が進み、あおり運転などの社会的問題の影響から、近年急速に市場が成長している。図 2.10 に、国内のドライブレコーダの出荷台数の推移を示す [35]。




図 2.10 ドライブレコーダの出荷台数 (事業者+一般向け)

ドライブレコーダには様々な種類があるが、カメラ・映像圧縮部・記録部からなるのはほぼ共通である。図 2.11 に、ドライブレコーダを機能などで大まかに分類した。記録方式のトリガ方式とは、内蔵加速度センサに大きな衝撃が入力されて事故があったと判断した場合に、車載器のメモリ内に循環記録していた映像を記録媒体へコピーして保存する方式である。初期のドライブレコーダでは記録媒体の容量が少なかったため、効率的に事故やヒヤリハット映像を記録するのに有用な方式であった。最近は記録媒体の大容量化と低価格化に伴い、走行中は常に録画する常時記録方式の採用が多い。一般的に、一般車両向けは録画のみのシンプルな機能であり、本体はカメラ一体型で小型化され、フロントガラスに直接設置するタイプが多い。事業用自動車向けは各種情報の記録や多カメラ対応など高機能型が多く、本体サイズも大きくなってしまったため、カメラも別体型が主流である。事業者向け高機能ドライブレコーダでは、画像認識による運転支援やタコグラフ機能、動画送信機能、バス向けでは6台以上のカメラ同時録画など、用途により様々な機能やサービスが使用できるものもある。

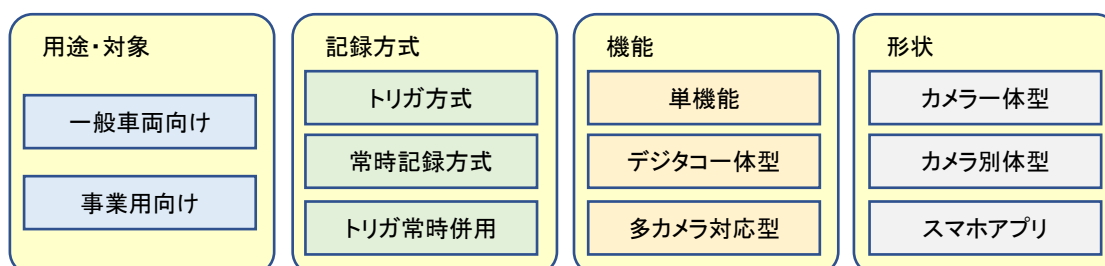


図 2.11 ドライブレコーダの分類

2.5 ドライブレコーダ・デジタルタコグラフの活用

本節では、事業者向けドライブレコーダ、デジタルタコグラフの導入効果や活用事例を紹介する。

図 2.12 に、トラック運送事業者へのドライブレコーダ導入効果のアンケート結果を示す [47]。半数以上の事業者において、安全運転指導に活用できたと回答があった。事業者向けのタコグラフ機能付きドライブレコーダでは、収集したデータより様々な運転指導が可能になっている。例えば、内蔵加速度センサで急ブレーキや急加速、急旋回があった場면을映像や位置データとともに記録し、事務所に帰ってきた時点で管理者と映像を確認、事象が起きた原因をすぐに確認、必要に応じて運転指導を行う。また、ヒヤリハット映像を集めて他のドライバーへの注意喚起に利用することができる。このほか、運行中に蓄積した情報から、図 2.13 に示すようなレーダーチャートを作成し、管理者へ評価指導のポイントをアドバイスすることも可能である。上記のようなドライバ指導を効果的に行うことで、アンケートの 1 位にもあったドライバの安全運転意識を高めることができる。




図 2.12 トラックでのドライブレコーダ導入効果 (2014 年)

(出典：2014 年度 「ドライブレコーダの導入効果に関する調査報告書」)

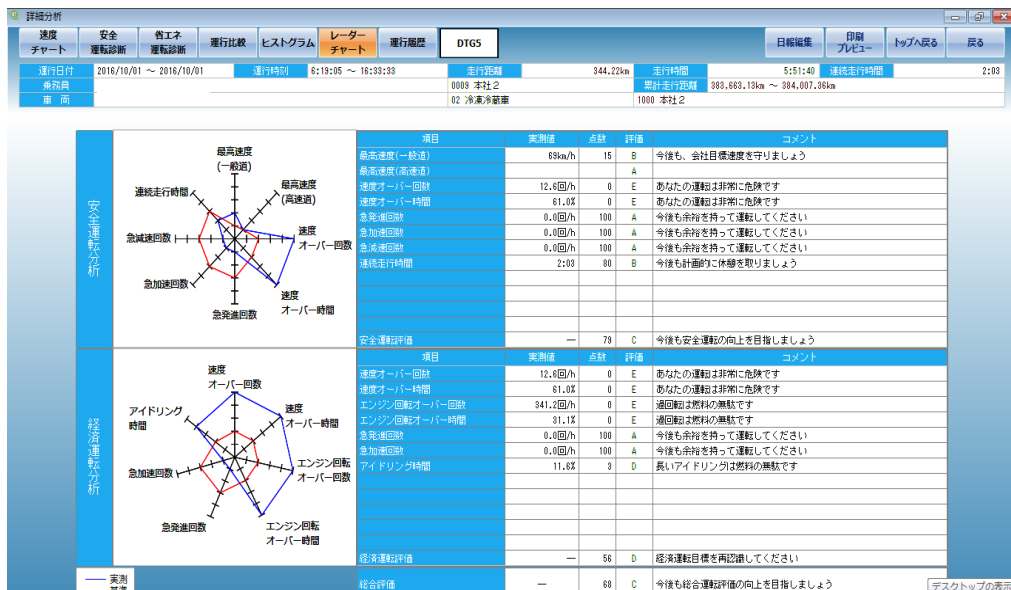


図 2.13 レーダーチャートによる評価

ドライブレコーダの映像を用いたドライバ指導の方法も確立しつつある。事故やヒヤリハット映像、また、日常の運転で注意すべき点を映像分析により切出し、個別に指導を行ったり、映像を共有し講習などで集団に指導を行う。特に映像資料を使用したKYT（危険予知トレーニング）は効果的な安全運転教育とされて推奨されている。また、危険な状況が多発する地点など、あらかじめ情報共有することも可能である。このような活用方法は、国土交通省発行の「ドライブレコーダの映像を活用した指導・監督マニュアル」にもまとめられている [48]。

最新のドライブレコーダでは、画像認識機能が搭載され、前方映像からレーン線を認識してLDW機能（Lane Departure Warning：車線逸脱警報）を利用することができる。また、前方車両の認識による車間距離警報機能、路面標示の認識による速度超過警告機能が可能である。これらは、リアルタイムにドライバに通知するほか、ドライブレコーダとして該当場面を蓄積記録することでドライバごとの運転傾向を把握でき、効果的に運転指導を行うこともできる。

眠気を検知する機器としての可能性も期待でき、過去に発生した事故の運行記録計データの解析から、高速道路で居眠り運転事故を起こす兆候として事故直前に速度低下や速度ムラが現れることが知られており [49]、この事実に基づいて危険な兆候を検出する車載システムも市販されている。しかし、オートクルーズ機能や速度制限装置など、車速を一定に保つ機能を使用している場合は適用できず、道路状況にも左右されやすい。また、LDW機能は居眠りによる車線逸脱にも有効であるため、ある程度の効果は期待

できるが、居眠り運転が発生した後の結果であり、理想的には逸脱を起こす前に眠気やその兆候を検知したい。

元来のドライブレコーダの機能とこれら画像認識結果を組み合わせることで、新たな評価指標や、安全運転支援機能が実現できる可能性がある。本研究の目的である眠気検知やながら運転検知はこの要素になり得る。

第3章 運転中の眠気検知手法の提案

本章では、ドライブレコーダから収集可能なデータである前方映像からの情報と車両操作情報より、運転中のドライバの眠気を推定する手法を提案し、その有効性を評価した。

3.1 眠気推定の先行研究

3.1.1 ドライバの状態と眠気

睡眠不足と生体リズムの影響によって生じた過剰な眠気が居眠り運転を招く。居眠り運転の発生率を調べた報告によれば、年間当たり一般ドライバの4~8%が居眠り運転をしているが、居眠り事故の発生率は1%未満である。これに対して年間10万km以上を走行する長距離トラックのドライバでは25~36%が居眠り運転の経験を持ち、11%が居眠り事故を起こしたことがあるという[50]。

睡眠不足と生体リズムによって早朝と午後に強い眠気が生じ、この強い眠気によって緩徐眼球運動や瞬眠が生じる。このような状態では、いつ事故が起こってもおかしくはないが、これに気付くことはほとんどなく、しかもある程度は運転が可能であるため、運転を中止することが困難である。やがて瞬眠のように数秒間で覚醒に戻るようなことはなくなり、睡眠が持続する。こうして居眠り運転が生じることになる。

このような状態検知して本人に自覚させる、または予兆を検知して居眠りが発生する前に回避行動をとることができるのが理想である。

3.1.2 眠気の定義と評価方法

運転中のドライバの眠気度合を評価する方法としては、大きく分けて主観評価と客観評価の2種類に分類される。以下、ドライバ自身による眠気の主観評価と、第3者が判定する客観評価の方法を示す。

主観評価

スタンフォード眠気尺度

スタンフォード眠気尺度(SSS)[51]は覚醒や眠気を表す20の記述を7つに分類されたカテゴリとなっている。7つの眠気尺度を表3.1に示す。評定者自身はこの中から、自分の状態に最も当てはまる数字を選択する。1が非常に覚醒した状態であり、7が最も強い眠気を示す。この方式は個人内での値の変動の検討には適しているが、個人間での

眠気の比較や過度の眠気の診断といった臨床的な使用には注意を要する。

表 3.1 スタンフォード眠気尺度

1	Feeling active and vital ; alert ; wide awake
2	Functioning at a high level, but not at peak ; able to concentrate
3	Relaxed ; awake ; not at full alertness ; responsive
4	A little foggy ; not at peak ; led down
5	Fogginess ; beginning to lose interest in remaining awake ; slowed down
6	Sleepiness ; prefer to be lying down ; fighting sleep ; woozy
7	Almost in reverie ; sleep onset soon ; lost struggle to remain awake

自覚症しらべによる評価

自覚症しらべ [52] は、日本産業衛生学会の産業疲労研究会によって作成された疲労の自覚症状を調べるための検査用紙である。検査用紙は表 3.2 に示す 25 種類の質問に 5 段階で回答をするもので、ねむけ感、不安定感、不快感、だるさ感、ぼやけ感の 5 つに分類される。使用時には各群ごとに分類されたものを質問毎の値を加算もしくは加算平均を行う。作業に伴う疲労状態の経時的変化をとらえることを目的としているため、値の相対的变化を見るものである。ただし、個人によって点数のばらつきが生じるため個人差が多い結果となってしまう問題点があるため注意が必要である。

表 3.2 自覚症しらべの質問項目と分類

分類	詳細
1 群 ねむけ感	ねむい、横になりたい、あくびがでる、やる気がとぼしい、全身がだるい
2 群 不安定感	不安な感じがする、ゆううつな気分だ、おちつかない気分だ、いらいらする、考えがまとまりにくい
3 群 不快感	頭が痛い、頭がおもい、気分がわるい、頭がぼんやりする、めまいがする
4 群 だるさ感	腕がだるい、腰がいたい、手や指がいたい、足がだるい、肩がこる
5 群 ぼやけ感	目がしょぼつく、目につかれる、目がいたい、目がかわる、ものがぼやける

Visual Analogue Scale による評価

Visual Analogue Scale (VAS) [53] は、図 3.1 に示すように 10cm の水平に引かれた線分の両端に覚醒と眠気の度合いの言葉を配置し、その地点での自分が示された線分中のどこに適するのかを判断させ、当てはまる場所に垂線を引くことによって眠気を評価に

用いられることがある方式である。



図 3.1 VAS の例

Epworth Sleepiness Scale

Epworth Sleepiness Scale(ESS)は Johns [54]によって開発された指標である。これは、表 3.3 に示すように 8 つの問いに対して 0 から 3 までの 4 つの選択項目に○を付けるものである。この数値の和が 11 以上の場合は睡眠時無呼吸症候群として定義されている。この指標は SSS とは異なり、時間指定がないため昼間全般についての眠気を評価することが可能である。

表 3.3 Epworth Sleepiness Scale

(出典：文献 [55])

眠気の程度についてお答えください。最近の日常生活のことを思い出してご記入ください。質問の中に最近経験されていないこともあるかもしれませんが、もしその状況があったとしたらどうなるか考えてご記入ください。

問 1 から問 8 の項目について、0, 1, 2, 3 のうちあてはまるものに○を付けて下さい。

問 1. 座って本を読んでいるとき、居眠りをする。

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 2. テレビをみるとき、居眠りをする。

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 3. 公共の場所で座っているとき、(映画館や会議中)、居眠りをする。

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 4. 用事なく午後横になっているとき、居眠りをする

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 5. 座って会話をしているとき、居眠りをする

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 6. 休憩をとらずに、1 時間以上車に同乗しているとき、居眠りをする

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 7. 休憩後(飲酒なし)、静かに座っているとき、居眠りをする

0. けっしてない 1. まれに 2. ときどき 3. いつも

問 8. 自分で運転中、交通渋滞で数分間止まっているとき、居眠りをする

0. けっしてない 1. まれに 2. ときどき 3. いつも

Roken Mental Work Strain checklist(MWS チェックリスト)

Roken Mental Work Strain checklist(MWS チェックリスト)は、精神的作業負担チェックリストであり、高橋ら [56] によって開発された指標である。このチェックリストには眠気、活性(全般的活性)、リラックス、緊張、注意集中困難、意欲減退といった 6 つの次元に関連する項目を、表 3.4 に示すように短時間で評定できるように各次元 2 項目を選択し、7 段階評定法(1:「あてはまらない」、3:「少し」あてはまる、5:「かなり」あてはまる、7:「非常に」あてはまる)を用いる。評価方法は各質問項目の点数の平均値を用いる。

表 3.4 MWS チェックリストの項目

分類	質問項目
眠気	<ul style="list-style-type: none"> ●まぶたが重いと感じる ●眠い
全般的活性	<ul style="list-style-type: none"> ●活力がみなぎっている ●積極的な気分だ
リラックス	<ul style="list-style-type: none"> ●くつろいだ気分だ ●ゆっくりした気分だ
緊張	<ul style="list-style-type: none"> ●緊張している ●どきどきしている
注意集中困難	<ul style="list-style-type: none"> ●思考がにぶっている ●注意の集中ができにくい
意欲減退	<ul style="list-style-type: none"> ●やる気がでない ●何かすることに気乗りがしない

客観評価

生理指標による評価

生理指標とは、心拍、脳波、血圧といった生体信号を用いて基準に従って評価を行うことを言う。例えば大須賀ら [18] [19] [20] [21] [22] [23] は、ドライバの覚醒状態を図 3.2 に示すように定義し、ドライバの瞬きと、心拍変動解析により推定をした。なお、図 3.2 に示す段階の説明を表 3.5 に示す。

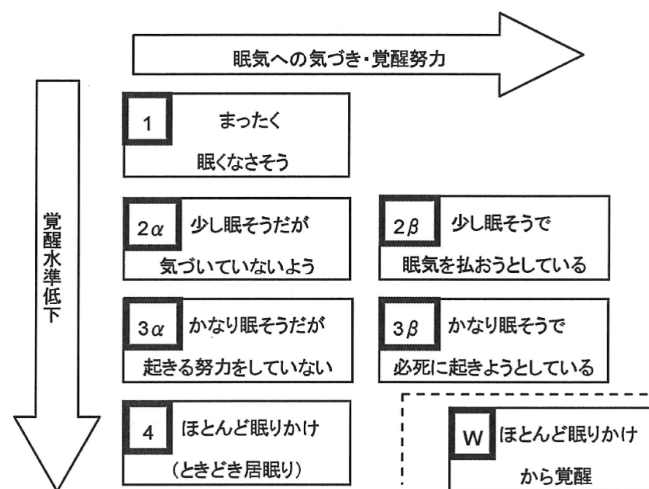


図 3.2 覚醒状態の 7 カテゴリ分類

表 3.5 覚醒度の基準

(出典：文献 [19])

評定値	カテゴリ	表情	覚醒努力
1	全く眠くなさそう	表情がしっかりしている (目が閉じている, 眼を しっかり開いている), 通常の瞬き (速くて間隔 も安定)	なし
2 α	少し眠そうだが気づい ていないよう	表情が少し緩んでいる (口の周りが弛緩してい る, 上瞼が少し下がって きている), 通常より小 さな瞬き, 回数も減る	覚醒努力は見られない
2 β	少し眠そうだが眠気を払 おうとしている	表情が少し緩んでいる (口の周りが弛緩してい る, 上瞼が少し下がって きている), 連続した早 い瞬き (群発瞬目) が見 られる	何らかの覚醒努力が見 られる (たとえば, 口 の動き, 顔に手をや る, 座り直し)
3 α	かなり眠そうだが起き る努力をしていない	表情がかなり緩んでいる (口が開いている, 上瞼 が下がってきている, 目 の焦点が定まらない), 遅い瞬きが多い, 瞬きの 回数が少ない	覚醒努力は見られな い, あくびは見られる こともある
3 β	かなり眠そうだが必死に 起きる努力をしている	表情がかなり緩んでいる が, 表情の変化が大きい (口が開いているが, 口 を動かす, 上瞼が下がっ てきているが, 瞼を見開 くときもある, 眼の焦点 が定まらない)	覚醒努力が多い (たと えば, 意識的とおもわ れる瞬き, 意識的とお もわれる一過性の深い 呼吸, 頭を振る, 肩の 上下動など無用な体全 体の動き), あくびが 見られる
4	ほとんど眠りかけ (と きどき居眠り)	表情が緩んでいて変化が ない (上瞼が下がってき ている, とくどき瞼を閉 じる (瞬きとは言えない 閉眼)), ゆっくりとし た瞬き	覚醒努力は見られな い, 無意識な顔の動き がある (前・後ろにガ クツとする)
W	ほとんど眠りかけから 起きる	ハッとして, 眼が開き, 表情がしっかりする (表 情が1か2に戻った場 合)	なし

MSLT

MSLT(Multiple Sleep Latency Test)とは、入眠潜時(睡眠傾向)を測定する方法である [57]。表 3.6 に示すようにこの方法には様々な規則がある。眠気が強ければ早く入眠し、眠気があまりなければ入眠に時間を要することを前提としている [58]。測定には被験者には遮音、遮光、温度調節された部屋でベッドの上に横になってもらい、消灯前には眠気の主観評価を行い、「目を閉じてください」と声をかけ、就寝してもらう。あらかじめ定められた基準で入眠したと判断してから 15 分間記録し続け、20 分間入眠しなかった場合は測定終了とし、入眠潜時判定後、4 から 5 回の平均睡眠潜時を算出し、評価を行うものである。

表 3.6 MSLT の準備
(出典： [59])

1.	検査試行前の 1~2 週間 睡眠日誌を記録 (可能であればアクチグラムを装着) 薬の利用状況を確認し、必要があれば中止
2.	検査の前日 普段のスケジュールで一夜の PSG を実施 (前夜の睡眠時間が最低 6 時間は確保できていることを確認する)
3.	検査の当日 1 検査環境 (検査室) 静かで暗く、温度・湿度がコントロールされている 2 着衣 普段着に着替える 3 嗜好品 アルコールまたはカフェインは禁止 検査 30 分前のタバコは禁止 4 食事 朝食：検査開始の最低 1 時間前に軽く取る 夕食：正午の検査終了後に軽く取る

MWT

MWT(Maintenance of Wakefulness Test)は Mitler ら [60]によって開発され、決まった時間の中で起きていられる能力(覚醒維持能力)を推定する手法である。この手法は MSLT とほぼ同様に脳波、眼球運動、オトガイ筋の筋電図、心電図などのポリグラフ測定を日中に 2 時間間隔で 4 回施行する [61]。

顔表情からのドライバの眠気評価指標

第 3 者による評価指標として、ドライバの顔表情の変化から眠気を評価する指標があ

る。北島ら [62]はドライバの眠気の基準として顔表情から眠気を分類する眠気顔表情評定を提案している。研究の概要を知らない 2 名が表 3.7 に示した基準で被験者 10 名の眠気表情評定を行った場合にその評定値は 0.755 と高い確率で一致する特徴がある。また、10 分ごとに記入した Roken Mental Work Strain checklist(MWS チェックリスト)の主観評価値と 10 分間の表情評定値の平均との相関係数を算出しても平均値で 0.795 と高い相関が認められている。したがって、この眠気表情評定値は眠気の基準として妥当であるとされ、広く用いられている。本研究でも、ドライバの眠気をこの表 3.7 の基準で評価した評定値で表す。

表 3.7 眠気レベルと顔表情
(出典：[62])

評定値 (レベル)	表情
1 全く眠くなさそう	視線の移動が早く、頻繁である
2 やや眠そう	唇が開いている、視線の動きが遅い
3 眠そう	瞬きはゆっくりと頻繁 口の動きがある 顔に手をやる
4 かなり眠そう	意識的と思われる瞬きがある 無用な体の動き、あくびの頻発
5 非常に眠そう	瞼を閉じる、頭が前に傾く 頭が後ろに倒れる

また、Zilberg ら [63]は北島らと同様に、事前に練習した評定者がドライバの顔表情から眠気を評価する手法を提案し、表 3.8 のように定義した。この方法は 10 秒ごとに眠気を推定している。また、北島らと Zilberg らの眠気レベルの対応を表 3.9 に示す。

表 3.8 Zilberg らによる眠気レベル判定基準

Drowsiness Level	Drowsiness State	Video image indicators
0	Alert	Normal fast eye blinks, often reasonably regular ; Apparent focus on driving with occasional fast sideway glances ; Normal facial tone ; Occasional body movements.
1	Slightly drowsy	Increase in duration of eye blinks, and possible increase in the rate of eye blinks ; Increase in duration and frequency of sideway glances ; Appearance of “glazed-eye” look and abrupt irregular movements – rubbing face/eyes, moving restlessly on the seat. Occasional yawning.
2	Moderately drowsy	Occasional disruption of eye focus ; Significant increase in the eye blink duration ; Disappearance of eye blink patterns observed during the alert state ; Reduction on the degree of eye opening ; Occasional disappearance of facial tone ; Episodes without an bode movements.
3	Significantly drowsy	Discernible episodes of almost complete eye closure, eyes are never fully open ; Significant disruption of eye movements (longer than for level 2) and facial tone followed by abrupt large body movement.
4	Extremely drowsy	Significant increase in duration of the eye closure episodes ; Longer duration of episodes with no body movements and sometimes followed by large isolated “correction” movements.

表 3.9 北島らと Zilberg らの眠気レベル対応表

	眠気レベル				
北島ら	1	2	3	4	5
Zilberg ら	0	1	2	3	4

3.1.3 運転中の眠気センシング手法

眠気状態センシングは様々な手法が提案されているが、車載要件として以下の観点を考慮して最適なセンシング方法を検討する必要がある [64].

1. ドライバの安全運転環境を妨げないこと

視界を妨げないこと、煩わしさが少ないこと（非拘束、非接触が望ましい）、生体安全性が確保されること、衝突時に人体にダメージを与えないこと、など。

2. 車両搭載が物理的に可能で厳しい使用環境に耐えること

車両搭載可能なサイズ、電磁波ノイズの厳しい車両環境で誤動作しないこと、広範囲に亘る温度・湿度、振動環境に長期間耐える信頼性の高いハードウェアであること、など。

3. 常時、リアルタイムにセンシングが可能なこと

運転開始直後からセンシング可能なこと、昼夜問わず常時センシングが可能なこと、など

4. 浅い眠気から深い眠気まで検出レンジが広く、また瞬眠も判定可能なこと

覚醒支援可能な浅い眠気センシングが可能であること、平均的な眠気推定だけでなく瞬眠についても瞬時判定可能であること、など。

5. センシング対象とするドライバを限定しないこと

睡眠時無呼吸症候群（SAS）患者は国内に数百万人、潜在患者は5人に1人と言われる。多くは無呼吸低呼吸指数（AHI）およびエプワース眠気尺度（ESS）で軽度と分類されるが、自覚がほとんどないドライバも多く、センシング対象は広いほど良い。

6. 低コストで他のアプリケーションへの拡張性が高いこと

車種グレード、トラック・乗用車等の種別に関係なく、広く普及させるために低コストで実現可能であること。

ドライバの眠気検出に関する研究で用いられている主な計測対象、手段、推定の着眼点を表 3.10 に示す。ドライバの眠気を推定するための入力として、脳波や眼電位、心拍、筋電位、皮膚電位、呼吸、体温といった生体信号を抽出するためのセンサやドライバの頭部および目、鼻、口といった顔特徴、上半身の動きといったドライバの行動計測するためのセンサ、運転操作としてアクセル開度、ブレーキペダルの踏力、ステアリン

グの操舵角を取得するセンサなどが挙げられる。

表 3.10 ドライバ覚醒度の推定事例

	計測対象	計測手段	推定の着眼点
運転操作	操舵	ステアリング角センサ	操舵周波数
	車線と車両のズレ	白線認識	横ズレ量によるふらつき
	車速	車両速度信号	速度変化
生体信号	心拍	心電図 (ECG)	心拍数, 心拍変動の分散
	呼吸	圧力センサ	呼吸数, 呼吸量
	脳波	脳電図 (EEG)	α 波, β 波含有率
	発汗, 体温	温湿度センサ	発汗量, 深部体温変化
	眼球運動	眼電図 (EOG)	低周波成分の含有率
	瞬目 (顔画像)	カメラ	開度, 瞬目回数, 閉眼時間

生体信号

ドライバに装着したセンサよりデータを取得できる生体信号はドライバの活動を直接センシングしているため、ドライバの状態を把握するのに優れた手法で、居眠り運転を検知する研究が様々行われている。例えば、脳波 (EEG) [65], 心電図 (ECG) [66], 筋電図 (EMG) [67] [68]といった生体信号が推定に用いられている。

しかし、このようなセンサを装着するのを煩わしく感じるドライバも少なくない。そこで、簡単に装着できる腕時計型や眼鏡型のセンサも提案 [69]されているが、ドライバが当該装置を装着していない場合に、安全運転支援を行えないという点で望ましくない。このため、ドライバにセンサを装着して取得する生体信号は、研究開発段階での評価において用いられるに留まっている。

車両側に生体信号を取得するためのセンサを取り付ける試みもなされており、運転席からドライバの体圧分布の変化を計測するセンサ [70]や、ステアリングなどドライバの皮膚が直接触れる個所に電極を装着し、電位を計測するセンサ [71], 頭部や身体の眠気によるふらつきを検出する座席に取り付けた圧力センサ [31] [72]が提案されている。しかし、ドライバの身体に直接装着するセンサに比べ、衣服を通してのセンシングとなること、ドライバの体の動きによってセンサと触れている面が離れる場合があることから、冗長なセンサ構成や、堅牢なセンシング性能が求められるといった課題がある。生体信号には個人差があり、これを吸収するために人ごとのベースラインの計測や、センサの較正と呼ばれる作業が必要であり、これらをいかに簡略化するか自動化する方法が必要である。また、各センサは、外乱の影響を受けやすく、電気的なノイズや、太陽光の影響に対して堅牢であることが必要である。予兆検出手法では、上田ら [73]は、眠気と相関があるとされる生理計測を利用し、脳波や心拍、眼電位を用いてそれらの波形や

周波数解析の結果から覚醒度を判定する方法を提案している。しかし、センサをドライバの身体に装着する必要があるため、運転に支障をきたす可能性があることから、実験段階に留まっている。

顔認識

ドライバの行動計測には、主にカメラと画像処理技術が用いられ、ドライバに直接装着するタイプと、車両側に取り付けるタイプの2種類がある。カメラを用いる主な利点は、眼球や、顔の動き、口の動きを含む表情変化、頭部や身体の動きを同時計測できることにある。ドライバに直接装着するカメラは眼球の動きから視線を計測、頭部の動きの計測においてその正確さから研究や実験、評価において用いられている [74]。しかし、前述の装着型の生体信号のセンサと同様に、センサを装着するのを煩わしく感じるドライバも少なくなく、カメラは車両に取り付けていることが望まれる。

画像中から顔の位置と大きさを正しく検出する機能の技術向上は目覚ましく、様々な顔や光環境の変化の画像を学習データとして用意し、機械学習を用いて顔検出器を生成する手法が提案されている [75] [76] [77] [78] [79]。しかし、既存の顔検出ロジックをドライバの顔検出に用いると、顔を検出できない場面が見受けられる。これは、影の生じたドライバの顔に相当する画像が検出器生成時に不足しているためであると考えられる。多くのドライバの顔画像を、太陽光の変化のある走行環境下において集めるのは非効率である。そこで、様々な光環境下で頑健な顔追跡を実現するため、目、鼻、口などの複数の局所領域から成る3次元形状モデルを用意し、予め顔の位置が検出された2次元の顔画像に当てはめる手法が提案されている [80]。複数の局所領域に影のエッジ部分がかかることはないため、局所領域は影を単純な明るさ変化として、2次元の顔画像に当てはめられる。しかし、この手法は顔の位置が既知であることを前提としており、影の生じたドライバの顔を検出できるように工夫されたわけではない。顔検出技術をドライバに適用するためには、車室内において太陽光の影響に対して堅牢であることが求められる。

居眠り状態の検出手法には、カメラによりドライバの目を閉じている時間の伸長を検出する方法 [81] [82]が提案されており、予兆検出手法では Hachisuka ら [83]は、カメラで撮影したドライバの表情を画像処理により解析し、眠気を推定する方法を提案している。この手法は、人がドライバの表情を観察し評定したときと同様の結果が期待できるが、覚醒低下による表情変化は、表情解析に用いられる基本6感情 [84]に比べて微小であるため、光環境の変化によってドライバの顔の見かけが変化する実車走行環境下への適応には課題が残る。

運転操作情報

生体情報からドライバを推定するのはドライバの危険状況を検知するのに有効であるが、実用化を考えると、運転しながら生体信号を取得することはドライバの負担や車両に特別な機材を搭載しなければならないなどの問題がある。また、顔表情を取得するための車載カメラの設置もドライバのプライバシーや撮影されることによるストレスを与えるなどの問題もある。そこで、運転操作情報を用いた眠気推定に関する研究も多くなされている。

運転操作情報を用いた眠気推定では、ドライバの運転パフォーマンスに基づくものと、覚醒低下に基づくものに分けられる。前者は、車載センサにより車線逸脱や車両のふらつき、車速変動からドライバの状態を推定する [85] [86]。この方法は、居眠り以外にも、車載機器や携帯電話の操作による注意散漫を検出でき、警報装置として実用化されている。ただし、この手法で判別できるのは運転が疎かになっているか否かであり、それが居眠りに起因するものかを判定することはできない。

一方、ドライバの覚醒低下を推定する手法は、居眠り状態を検出する手法と、居眠りの予兆を検出する手法に分類できる。前者は居眠り運転防止を目的としており、後者は、居眠り運転防止に加え、早期休憩提案サービスへの適用が期待できる。

運転操作からドライバの状態を推定するためには、横風や道路線形や路面の轍、先行車など周辺車両の挙動など外的要因と、ドライバ状態が運転操作に及ぼす影響を分離することが必要であり、操作を信号処理により代替指標を置き換えることでドライバ状態推定に用いようとする研究がなされている [85] [86]。

車両挙動とドライバ状態との関連性を調査した先行研究にも様々なものがある。例えば、福井は連続運転によるドライバの疲労と車両挙動に関して、操舵遅れ時間や車両の横変位量などの操舵機能に関する指標と覚醒度や認知判断機能との間に相互に関係があると報告している [9]。Eggert らは車両情報である速度や車間距離から衝突余裕時間 (TTC) を算出して、車線変更時のドライバの運転モデルを作成する研究を行った [10]。また、Higgs らは車両情報から車両追従走行時の状態や行動群の識別や分類を行った [11]。伊藤ら [12] は、道路形状を考慮することにより車両挙動の変化からドライバの眠気レベル推定を実施した。

一方、常時記録された運転データ(車両走行ログ)からリアルタイムに様々な危険状況を効果的に検出する手法の検討はまだ十分に行われていない。例えば西郷ら [87] は、ドライバモデルを作成し、車線内変位におけるモデル誤差の分散を調べ、一部ドライバにおいて眠気レベル 1 と眠気レベル 3 から 4、4 から 5 との間に有意差があることを確認

しているが、ドライバの眠気レベルの推定までは行われていない。

眠気レベルを推定するものとして、眠気の連続性 [88] を利用した過去の眠気の推定値を現在の眠気推定に用いた研究 [89] も行われている。しかしながら、実環境での検討事例は未だ少なく、全体的に乗用車の DS で検討されたものが多い。安全性の観点から実験に DS を使用するのが一般的であるが、運転環境や運転感覚が実車と全く同一とは言えず、実車両と差異が現れるといったような DS とのギャップが懸念される。実環境への適応を目指した研究として、金子ら [90] は速度や加速度情報に加え、車線内走行位置情報からのドライバの眠気レベル推定を提案している。

3.1.4 従来手法

金子らの提案する手法は、DS だけではなく実車環境へ適用している点やドライブレコーダのみを用いて眠気レベル推定が可能な点で優れていると考えている。特に、DS 環境においては、推定結果と眠気レベルとの間に高い関係性があることが確認されている [89]。しかしながら、実環境で計測されたデータに対して、DS 環境で得られるような十分な精度が得られていない。金子らの手法とその課題について概要を述べる。

推定に用いる特徴量

眠気の推定に用いる特徴量は表 3.11 の通りである。眠気が高まるふらつき量が増加する [91] ということが既に報告されていることから、ドライブレコーダから得られる車両情報からふらつき量を特徴量として抽出し眠気推定に用いている

表 3.11 ドライブレコーダから取得する推定に用いるデータ

取得手段	変数	特徴量名	単位
車両情報	v_x	走行速度	km/h
	a_x	進行方向加速度	G
	a_y	左右方向加速度	G
前方映像	f_F	FOE 揺らぎ	pixel
	d_F	FOE 基準点からのズレ	pixel
	p_c	自車位置	m
	p_l	左白線までの距離	m
	p_r	右白線までの距離	m
	v_r	横移動速度	m/sec

なお、車両情報はドライブレコーダに内蔵している速度パルス、G センサにより取得する。いずれのデータも 10Hz で取得する。FOE とは、車両に搭載されたカメラの進行

方向の無限遠方点を表す画像上の点であり、Focus of Expansion の略である。FOE に関連する特徴は、前方映像を画像認識した結果得られる情報から求めている。

上記各要素において、現在値より過去 10 秒間の基本統計量（平均値，標準偏差，最大値，最小値，中央値，最頻値，範囲）を求め、計 63 種類の特徴量を得る。さらに、眠気が段階的に変化することを考慮して、時刻 $t-T$ の推定値 y_{t-T} を追加し、64 種類の特徴量としている。この 64 種の特徴量だけでは目的変数を分類・回帰することはできないため、カーネル法を用いて非線形性を持つ特徴量にして処理する。式(3.1)に示すような特徴量同士の組み合わせで作る線形のカーネルによって高次元空間に射影し、これを新たな特徴量として利用する。

$$C_{i,j} = |B_i \times B_j| \quad (3.1)$$

ここで、 B_i と B_j はそれぞれ 64 種の特徴量のいずれかを表す。この特徴量の組み合わせは、 ${}_{64}C_2$ 個と膨大な数になってしまう上、そのまま眠気レベル推定に用いると、眠気と関係のない特徴量を用いた推定モデルが構築されてしまう。このため、目的変数（眠気）との相関係数を求め、一定以上の相関があるもののみ採用し、さらに、主成分分析を行うことで次元の削減をする。

3.1.2 節で紹介した北島らの提案した方法により、被験者の顔映像より 3 名の評定者が眠気レベルを 5 段階に 10 秒間隔で評定し、眠気の正解値としている。

推定手法

金子らの提案する手法は、上記特徴量から、重回帰分析を用いて眠気レベルの推定を行う。DS 実験により収集したデータを学習に用い、その結果を実車データでの推定に適用することを目指している。しかし、DS と実車環境では、それぞれ得られるデータ特性に大きく相違がある。この問題に対応するため、速度、カーブの曲率、勾配などのデータを用いて実車データの補正を行い、推定精度を向上させる工夫を施している。

従来手法の課題点

金子らの眠気レベル推定手法を用いると正解眠気レベルが異なっても、推定眠気レベルが 2 付近の値に収束してしまう。推定結果の例として、図 3.3 に示す。図中の横軸は走行開始からの時刻、縦軸は眠気レベルをあらわす。赤色は眠気レベルの正解値、黒色の線は推定結果、青色は黒色の線を量子化した結果を示す。これらの図から、正解眠気レベルに関わらずレベル 2 を推定していることがわかる。

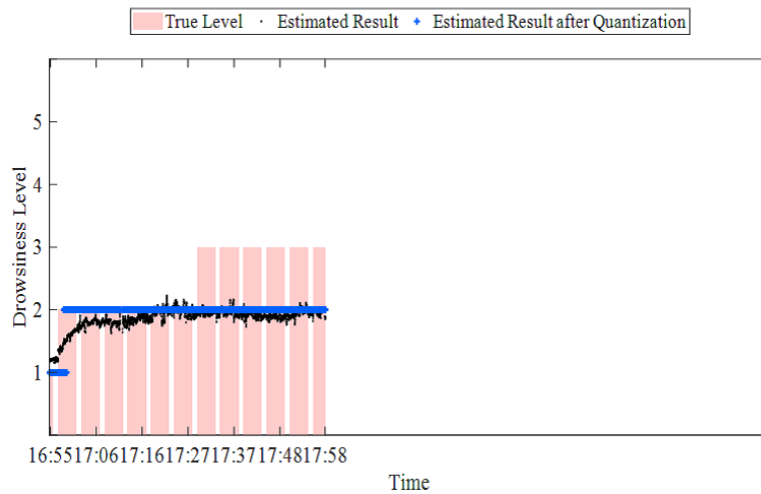


図 3.3 眠気レベル 2 に収束する推定例

眠気レベルがある特定のレベルに収束してしまうのは、推定器が眠気の特徴を正確に捉えることができていないためであると考えられる。これには様々な要因が考えられるが、DS での走行データから推定器を構築し、実走行データを評価していることによる学習と評価のデータ間の乖離が考えられる。金子らはデータ補正によってこれらの乖離を解消する方法を提案したが、依然、乖離が生じている可能性がある。そこで本研究では、実環境での走行データで学習し、評価する方法の有効性を検証する。

金子ら提案する手法のように、DS での走行データから推定器を構築し、実走行データを評価することのメリットとして、学習データの準備がしやすいことが挙げられる。例えば眠気レベル 4 や 5 など、高い眠気状態のデータを実環境で集めることは、事故の危険性が高まることが考えられるため困難である。このようなデータでも DS 環境であれば収集できるというメリットがある。また、実環境は DS と異なり、外乱が多い。例えば、車線変更や前方車両の有無、交通規制など、様々な外乱因子が存在し、その外乱に対する対処が必要となることが考えられる。しかしながら、実環境での走行データで学習し評価をすることで、学習と評価のデータ間の乖離は解消される。

従来法での比較実験

金子らは、前述のとおり DS のデータを学習した後、実走行データでの推定を行っていた。ここでは同様の手法を用いて、実車走行データを学習させる実験を行った。後述するトラックに搭載されたドライブレコーダのデータを使用し、前述の特徴量を抽出、学習を行い、眠気を推定した。推定結果の例を図 3.4 に示す。横軸は走行開始からの時刻、縦軸は眠気レベルをあらわす。青色は正解眠気レベル、赤色は推定結果、青色は赤色の推定結果を量子化した値を示す。この結果から、推定結果は正解値の変動に沿った

値になっている。それぞれのデータにおいて、正解眠気レベルが比較的高いデータ（レベル3から4）のデータにおいて推定眠気レベルもドライバの眠気の高まりを捉えていることがわかる。学習データを評価データと同じである実車で得られるデータとすることで、学習データと評価データ間の乖離がなくなり、同一の値に収束することはなくなっている。

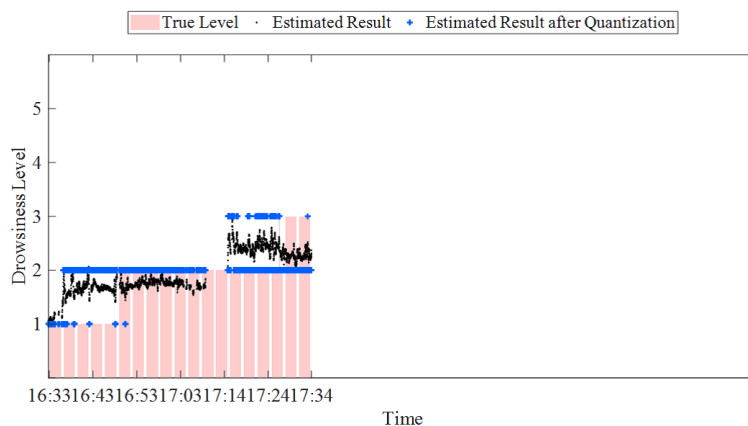


図 3.4 学習データに実車走行データを用いた眠気レベル推定結果の例

次に、ドライブレコーダで取得した特徴の観点から DS データと実車データを比較する。DS と実車、それぞれのデータと正解眠気レベルとの相関関係を図 3.5 に示す。図 3.5 より、DS と実車それぞれが眠気と関係のある特徴が異なっている。速度や左右方向加速度、FOE 揺らぎや横移動速度は DS の方が眠気との関係性が高い。対して、前方方向加速度や FOE 基準点からのズレは実車の方が眠気との関係性が高い。ただし、自転車位置および左白線までの距離は DS と実車が同じような特徴があることがわかる。




図 3.5 DS と実車各データと正解眠気レベルとの相関関係

さらに、正解眠気レベルごとの左白線までの距離と右白線までの距離との相関関係を調べた結果を図 3.6 に示す。左白線までの距離と右白線までの距離は、互いに負の相関関係がある。例えば、左白線までの距離が長くなると、右白線までの距離が短くなる。このことから、眠気レベルに関わらず左白線までの距離と右白線までの距離の間には負の相関関係があるはずだが、図より、DS において、眠気レベルが上がると正の相関関係になっていることがわかる。




図 3.6 正解眠気レベルごとの左右レーン線距離同士の相関関係

走行動画を確認すると、DS では眠気が高まった際に、白線をまたがった走行や塀にぶつかるような走行をしていることがわかった。それに対し、実車環境では事故に繋が

るためこのような走行にはなりえない。事故に繋がるような運転をしてよい環境であるかどうか、それぞれ眠気の特徴を変えていることを確認できた。このことから、実車データを推定する際の学習データとして DS を用いることは望ましくないと考える。

個人内推定と個人外推定の比較結果を図 3.7 に示す。個人外推定では、推定結果が大きく発散してしまう現象が一部現れた。このように、学習データに本人のデータが含まれているかどうかによっても、推定結果の精度に大きく影響する。




図 3.7 個人内推定と個人外推定結果の比較

3.2 実験方法-データ収集

3.2.1 使用機器と車両

本研究に使用するデータは、商用車向けに市販されているドライブレコーダ内蔵型デジタルタコグラフ（矢崎エナジーシステム株式会社製 DTG7）を用いて収集された。図 3.8 にその全景を示す。トラック運送会社の協力のもと、上記車載器を搭載した大型トラックの実際の営業運転による運行データを収集している。使用した車両は、表 3.12 に示す車両総重量 25t および 8t のトラックである。走行ルートは車両により異なり、各車両とも毎日同じルートで運行する。以下に、各ルートの走行条件を示す。一日の走行距離は約 200 km、ドライバの拘束時間は約 10 時間、ハンドル時間は約 8 時間である。走行距離の 50% を、高速道路及び自動車専用道を占める。被験者は、数名のドライバが、上記車両を 1 週間ごとにローテーションで運転する。1 週間の勤務は月曜から金曜の 5 日間である。全て男性であり、年齢は 30 代から 50 代である。ドライバには、特別なタスクを課すことはなく、日常の運行業務のデータを収集した。



図 3.8 ドライブレコーダ内蔵型デジタルタコグラフ DTG7


表 3.12 データ収集対象車両

車種	車両総重量	車幅	全長	形状	ルート
大型 (ISUZU GIGA)	25t	2.5m	12.0m	バン	固定
中型 (ISUZU FORWARD)	8t	2.5m	8.6m	バン	固定

3.2.2 記録データ

本ドライブレコーダでは、映像の他、速度、加速度、位置情報、ブレーキ信号、ウインカ信号、車間距離、レーン線との位置関係が記録媒体に記録される。フロントガラス上部中央に前方撮影用のカメラが設置されている。また、ドライバの様子を撮影するための赤外線カメラがスピードメーター上部に設置され、それぞれの映像を独立して録画できる。図 3.9 に、録画される映像のサンプルを示す。速度は車両からの速度パルス信号より、車載器内部で車両速度への変換処理を行い、記録される。車両からの信号線より、左右のウインカ信号、ブレーキ信号、バック信号も入力、記録する。車載器には、3 軸の加速度センサが搭載されており、車両の前後方向、左右方向、上下方向の加速度を 10Hz で記録できる。フロントカメラ映像からは、画像認識処理により、リアルタイムに車両幅両端からレーン線までの距離を算出し、他のセンサ情報とともに時系列データとして記録される。図 3.10 に、片側 2 車線の道路をトラックが走行する際の車線と

車両の位置関係を示す。なお、道路の構造における各部の名称は、道路交通法や道路構造令など関係する法規により異なる場合があるが、本論文では、車両が通行する部分を「車線」、車線を区切る白色や黄色の実線と破線からなる区画線を「レーン線」と、一般的な名称を用いて呼称する。



前方撮影映像

ドライバ撮影映像

図 3.9 録画映像サンプル




図 3.10 車線と車両の位置関係

3.2.3 レーン線位置の導出

図 3.11 に、フロントカメラで取得された画像の例を示す。この画像より、左右のレーン線と車両との距離を算出する。画像内の画素の輝度勾配に基づくエッジ抽出を行い、レーン線として路面にペイントされている白色線や黄色線の特徴を検出する。図 3.12 に、車両およびフロントカメラと路面との幾何学的関係を示す。車両を横から見た図と、上から見た図を表している。上記 2 つの図に共通する点 P_1 の画像上の座標 (X, Y) をレーン線の検出結果より求める。ここで、 h は地上からのカメラ高さ、 W_v は車両幅、FOE はカメラ進行方向の無限遠方点を表すもので Focus of Expansion の略である。角度 α はカメラを頂点とした FOE と P_1 の間の角度である。 β は対角線 L' と同じ平面上にあり、 P_1 と P_2 の間の角度とする。 X は画像上の P_1 - P_2 間、 Y は FOE- P_1 間のピクセル数である。 C は画像のピクセルあたりの角度であり、画像の解像度とレンズの特性によって決定されるカメラ固有の値である。 h と W_v は車両ごとに異なる定数である。 L はドライブレコーダ搭載時に車両ごとに校正することで、固定値 (6m) とした。左側レーン線までの距離 d_L は、式 3.2~式 3.4 により求められる。 d_L を、左側レーン線と車両左端までの距離とみなすこととする。また、右側の距離も同様に算出する。

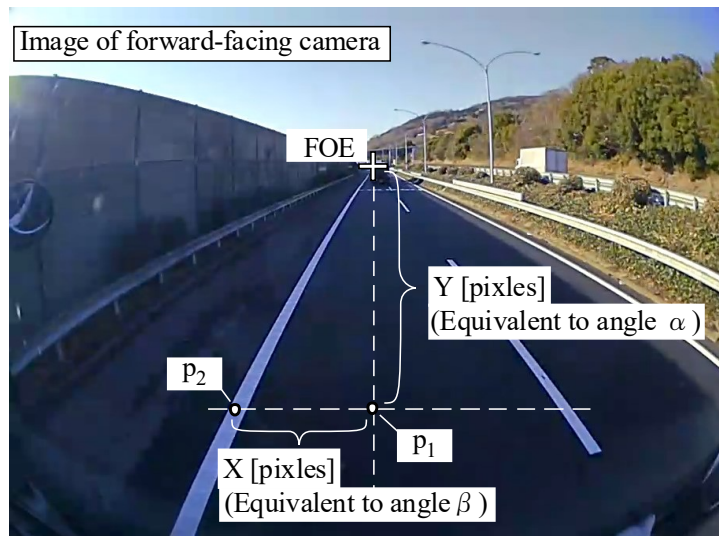


図 3.11 フロントカメラ映像




図 3.12 車両と路面の幾何的關係

$$\alpha = C \times Y \quad (3.2)$$

$$\beta = C \times X \quad (3.3)$$

$$d_L = \frac{h \times \tan \beta}{\sin \alpha} - \frac{W_V}{2} \quad (3.4)$$

3.3 眠気評定

運転傾向がドライバの眠気とどのように関連しているかを調べるため、走行データセットの眠気度のラベル付けを行った。眠気評定方法には、3.1.2 で述べられたように様々な方法が存在するが、本研究では、ドライバに負担をかけず、また、特別な意識をさせない自然な通常の運転状態を必要としたため、北島ら [62] が提案した顔表情評定法を用いた。走行中に撮影録画したドライバの顔表情を評定者 3 名が再生映像を見ながら、10 秒単位で眠気レベルを 5 段階に評定した。3 名の評定値が異なる場合は、多数決で投票数の多いものを採用した。図 3.13 に、顔映像から評定した眠気レベルの時系列変化の一例を示す。このように眠気レベルは時間とともに変動し、眠気の高まりおよびそこから回復などが読み取れる。このような評定結果の時系列データをドライブレコーダの記録データと合わせて分析に用いる。




図 3.13 評定された眠気レベルの時系列変化の例

3.4 データ解析

収集されたドライブレコーダデータより、車両挙動や運転特性を調査する。

3.4.1 スクリーニング

速度によるスクリーニング

図 3.14 に、1 日の運行データの例を示す。業務開始から終了までの速度データの時間変化を表す。グラフ中、70km/h~80km/h でほぼ一定で走行している区間は、高速道路

走行中の区間である。それ以外の、0km/h~60km/h の間で走行・停止を繰り返している部分はほぼ一般道路を表している。本研究では、外乱因子が少なく、比較的安定した長時間のデータを得るため、高速道路を対象区間としている。そこで、まず、車速が60km/h 未満の区間を除去した。




図 3.14 運送業務における一日の運行例

レーン線距離によるスクリーニング

図 3.15 に、計測された d_L と d_R の時間変化を示す。図中、黒線が d_L で、青線が d_R である。縦軸はレーン線までの距離である。通常、同じ車線内を走行している場合、 d_L と d_R の挙動は、図 3.15 の①に示すように、対称となるような動きになる。(例えば、車幅 2.5m の車両で車線幅 3.5m の道路を走行する場合、車線中央を走行すると d_L と d_R は 0.5m となる)

図中②と③の部分では、急激な変化があらわれているがこれは車線変更の際に現れる特有の波形である。②の部分は、走行車線から右側の車線へ向かって車線変更する場合である。左側のレーン線のデータ(d_L)に注目すると、車両が右方向へ移動するにつれて距離が大きくなっていき、ある地点(グラフの頂点)で、今まで右側レーン線だったラインが左側レーン線として認識されるようになる。③の部分は逆に、現在の走行車線から、左側の車線に移動する場合である。車線変更シーンでは、左右対称に大きく乱れることが分かる。このような、車線変更などの大きな移動量が発生する場合をそれぞれについて除去したい。

また、図中④の部分は、ジャンクションやパーキングエリアの入口、出口など、分岐または合流部分で現れることがある波形である。このシーンの特徴は、分岐・合流で必ず現れるわけではなく、発生しても分岐合流車線のある左右のどちらか一方のみが乱される特徴がある。

この他、レーン線の擦れなどが原因で認識できない場面も d_L , d_R が乱される原因になるため、除去対象とする。

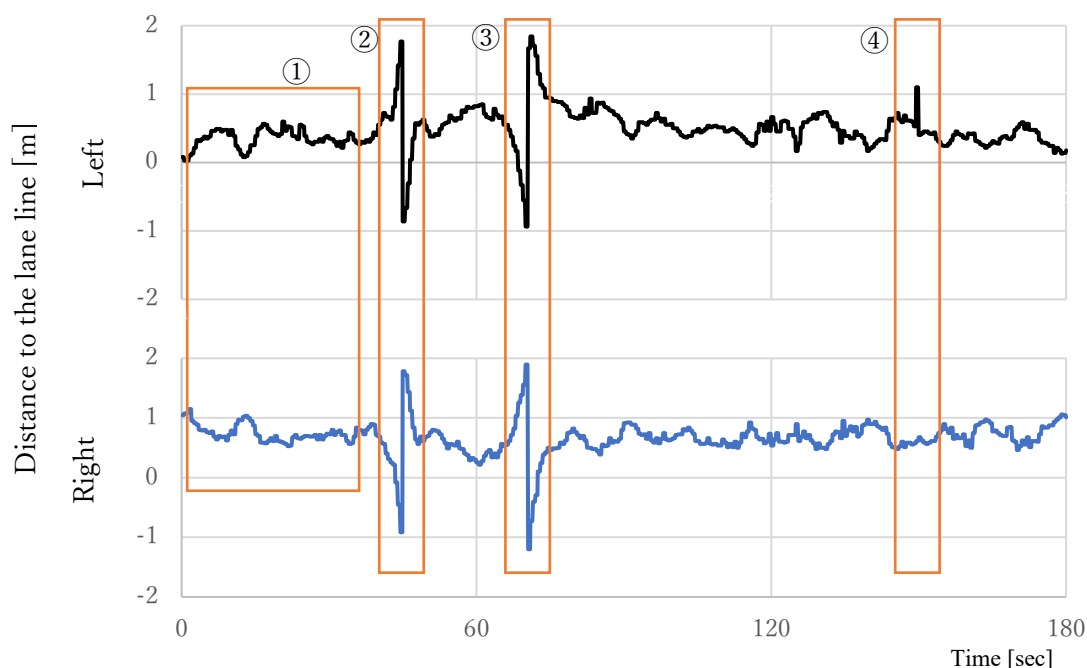


図 3.15 レーン線までの距離

上記3パターンごとに挙動が異なるため、それぞれでスクリーニング方法を検討した。まず、分岐・合流に対応するため、車幅とレーン線までの距離を合計して算出した車線幅 U_w の時間変化 D_w を求める (式 3.5, 式 3.6) (図 3.16)。

$$U_w = |p_l + p_r| + W_v \quad (3.5)$$

$$D_w(t) = |U_w(t) - U_w(t-1)| \quad (3.6)$$

式 3.5 で表される車線幅 U_w は、車線内を左右に移動しても理想的には一定の値を保つはずである。外乱により車線検知結果が乱れる場合は、左右の均衡が崩れ、車線幅に影響する。 U_w の変化量 D_w がしきい値 a 以上に急激に変化した場合、除去対象とする (式 3.6)。

次に、レーンチェンジ場面に対応する場合、左右対称に距離変化が起こるため、分岐・合流時のような車線幅変化が表れにくい。このため、左右独立に距離の時間変化を算出し (式 3.7, 式 3.8)、しきい値 b 以上に変化した場合、除去対象とする。

$$D_l(t) = |p_l(t) - p_l(t-1)| \quad (3.7)$$

$$D_r(t) = |p_r(t) - p_r(t - 1)| \quad (3.8)$$

レーンチェンジの場合は元の車線から隣の車線に完全に移って安定するまでに時間がかかるため、抽出された場面の前後数秒間も除去対象とした。図 3.15 の車線変更場面は約 9 秒で完了しており、さらに実際の車線変更シーンを多数分析した結果、各ドライバーとも、おおむね 10 秒以内に完了していた。さらに、安定するまでの猶予を考慮してこの時間は 10 秒間としている。

レーン線未検知場面に対応するため、まず、ある時間範囲で d_l および d_r の平均値 m を算出する。そして、平均値 m と現在値との差がしきい値 C 以上の場合、その該当区間全体を除去対象とする (式 3.9, 式 3.10)。

$$p_l = \begin{cases} p_l & \text{if } -c + m_l < p_l(t) < c + m_l \\ \text{NaN} & \text{others} \end{cases} \quad (3.9)$$

$$p_r = \begin{cases} p_r & \text{if } -c + m_r < p_r(t) < c + m_r \\ \text{NaN} & \text{others} \end{cases} \quad (3.10)$$




図 3.16 車線幅の算出方法

上記スクリーニング処理の結果を図 3.17 に示す。しきい値は a , b , c は、収集したデータからそれぞれ適切な値を求め、全てのデータで 0.25 とした。図中、黒線で示す部分が、除去された場面であり、大きく変動している箇所のみ除去されているのが分かる。実際に除去された場面の画像を図 3.18 に示す。車線変更、分岐・合流の他、レーン線の擦れ、前方を走行する車両でレーン線が見えない場面、雨天時の路面の反射によりレーン線が検出できない場面などが抽出除去できた。映像による検証の結果、本節で提案したスクリーニング手法により除去された低信頼性区間の要因は、6 割が車線変更、3 割が合流・分岐地点によるレーン線検知の乱れ、1 割がレーン線未検出であった。

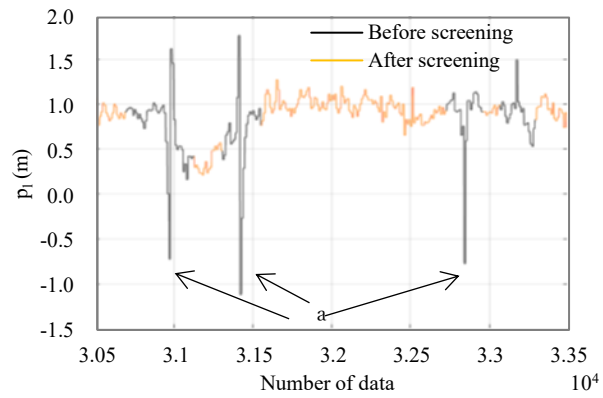



図 3.17 スクリーニング処理結果



- a: Lane change
- b: Branching point
- c: Merging point
- d: Faint white line
- e: Hiding by the vehicle ahead
- f: Road surface gloss

図 3.18 スクリーニング処理によって除去された場面の例

3.4.2 レーン線データからわかる運転傾向

図 3.19 に、車両左端から左側レーン線までの距離 d_L について、スクリーニング後の全データをドライバーごとに集計しヒストグラムを比較した結果を示す。ここでは、被験者のうち、運行本数が多く、十分な量のデータが収集できたドライバー 7 名のみグラフ化している。横軸は左側レーン線までの距離 d_L で、縦軸は度数を任意単位で表している。高速道路の標準車線幅は 3.5m であり、車線中央を走行した場合、車幅 2.5m の大型車の両側にはそれぞれ 0.5m の余裕がある。横軸で 0.5m 付近のデータは、ほぼレーンの中央付近を走行していることを示し、0m 付近のデータは、左側のレーン線を踏むぎりぎりで行っていることを示す。図中の 500mm の縦線は、車線中央を走行した場合の位置を示す。

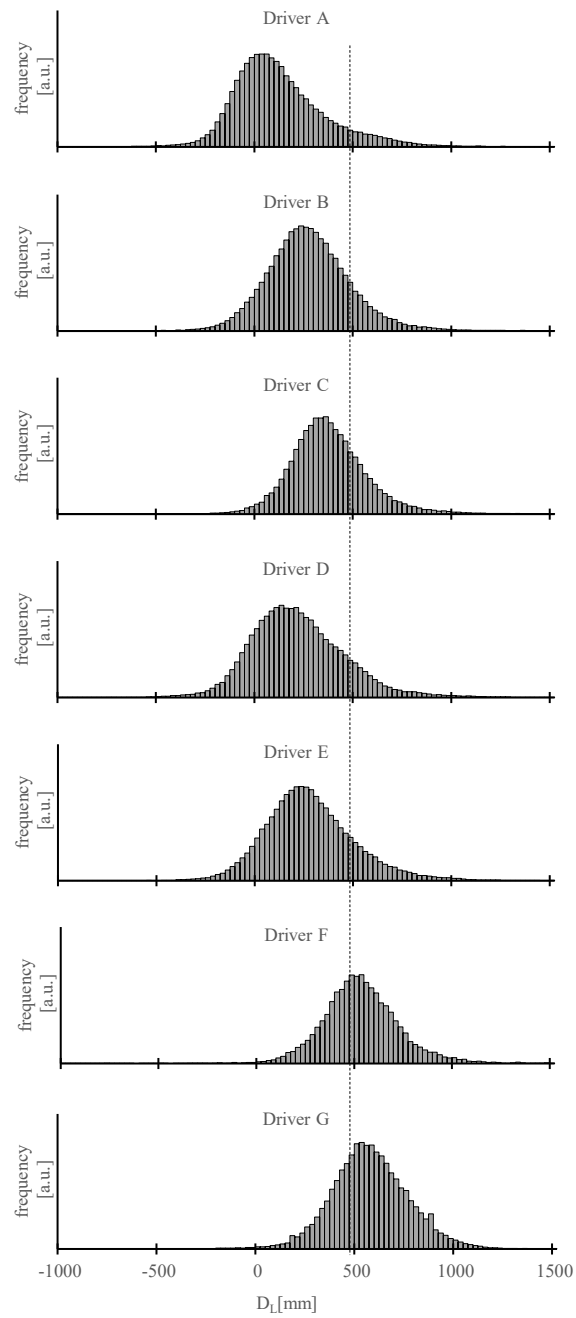


図 3.19 ドライバごとの走行位置のヒストグラム

この結果より、ドライバごとに走行位置の傾向が異なることが分かった。たとえば、ドライバ G は車線のほぼ中央付近を走行する傾向があるが、ドライバ A は左側レーン線の近くを走行する傾向がある。また、走行位置分布のばらつきも各ドライバ間で差が

あらわれた。横位置変動が小さいほど、ドライバはレーン線から一定の間隔を保って車線に沿って運転する傾向が高くなり、ばらつきが大きいほど、車線いっぱいを使って走行、またはふらつきが多いドライバということが分かる。

3.4.3 眠気による運転傾向の変化

全走行データの中から極端な渋滞がなく、1時間以上の連続走行のある運行を抽出し、総計105時間分のデータについて評定をし、眠気レベルのラベル付けを行った。眠気レベルを評定した運行データにおける、ドライバごとの各眠気レベルの発生割合と評定された時間長を表3.13に示す。評定したデータ中では5名のドライバで、レベル3以上の眠気があらわれている。また、レベル5は一度も発生しなかった。この中で、レベルが4まで達したドライバについて、さらに分析を行った。ドライバの中で、統計とるために眠気レベル4に相当する走行時間が十分存在するC、F、Gと、レベル3の割合が比較的多いAを対象に、眠気レベルと運転傾向の関係を調べた。

表 3.13 ドライバごとの眠気レベル発生割合

Driver	Drowsiness level				Period [Hour]
	Lv. 1	Lv. 2	Lv. 3	Lv. 4	
A	30.2%	44.8%	24.9%	0.1%	11.5
B	68.6%	29.6%	1.8%	0%	8.0
C	80.8%	17.6%	1.1%	0.5%	27.1
D	97.1%	2.9%	0%	0%	9.4
E	86.6%	13.4%	0%	0%	23.4
F	52.5%	38.7%	5.6%	3.1%	3.4
G	13.7%	30.3%	53.2%	2.8%	22.3

図 3.19 に示した走行位置のヒストグラムについて、眠気レベル1~4で層別を行い、ヒストグラム形状の変化を比較した。結果をドライバGを例にとって図 3.20 に示す。




図 3.20 眠気レベルによるヒストグラム形状の変化（ドライバ G）

この結果から、眠気が高まるにつれ、同じ車線内を走行中に走行位置がより左側に寄ることが明らかになった。また、走行位置の変化の他に、分布の広がりにも変化が現れることが分かる。ドライバにより多少差が出るが、ほぼ同様な傾向となった。図 3.20 で使用したレーン線までの距離に関して、ドライバ A, C, F, G ごとに統計値して平均、中央値、標準偏差、尖度、歪度を算出し、眠気レベルとの関係を調べた結果を図 3.21 に示す。平均値と中央値からは、個人差はあるが、眠気レベルの増加に伴って全体的に左側へ寄る傾向が見て取れる。ただし、一部のドライバは、レベル 1 と 2 の間、およびレベル 3 と 4 の間でほとんど同じまたは逆の動作を示したが、レベル 2 と 3 の間の変化は大きかった。また、眠気の増加とともに標準偏差は増大する傾向があることを示している。尖度や歪度からも、眠気の増加に伴い、数値が減少傾向になるとの関係が示された。表 3.14 に、平均値・中央値・標準偏差・尖度・歪度の各統計値について、評定された眠気レベルとの相関係数を示す。平均値に注目すると、相関係数は 0.514 から 0.967 と、ドライバによっては高い値を示した。




図 3.21 眠気レベルに対する各統計値の変化

表 3.14 各統計値と眠気レベルとの相関係数

Driver	A	C	F	G
Mean	-0.956	-0.514	-0.596	-0.967
Median	-0.963	-0.491	-0.686	-0.973
SD	0.616	0.860	0.600	0.807
Kurtosis	-0.950	-0.795	-0.907	-0.932
Skewness	-0.863	-0.722	0.182	-0.888

順序ロジスティック分析

上記結果はそれぞれの統計値と眠気レベルに関してピアソンの相関を調査したものである。しかし、本研究で使用した眠気レベルは5段階で評定しているが、各段階間の眠気度合は等間隔であるとは限らず、順序尺度と考えることもできる。そこで、眠気レベル1~4を順序尺度とした目的変数、左レーン線までの距離(d_L)を説明変数として順序ロジスティック回帰分析を適用した。ドライバごとの分析結果を表3.15に示す。すべてのドライバにおいて有意であり、オッズ比は0.997~0.999の値を示した。Nagelkerke R²は0.00228~0.0592の範囲となり、モデルの精度としては良くないことを示している。

表 3.15 順序ロジスティック回帰分析結果

Driver	A	C	F	G
Coefficient	-6.13e-4	-9.41e-4	-6.95e-4	-3.22e-3
Odds ratio	0.999	0.999	0.999	0.997
p	< .001	< .001	< .001	< .001
R ²	0.0029	0.0055	0.0046	0.0592

3.4.4 考察

一部の先行研究では横位置と眠気との関係についても議論されているが、それらのほとんどは標準偏差と変化のサイクルを評価している [92] [93]。たとえば、眠気が増すと横位置の標準偏差も大きくなる傾向にあると説明されている [92]。本研究の結果を先行文献と比較すると、一部の被験者は同等またはそれ以上の相関関係を示した。ただし、眠気の測定方法が異なるため、文献の結果と直接比較することはできない。

全体的な傾向としては、眠気が強いほど左に寄る傾向にある。しかし、被験者によっては、Lv1と2、Lv3と4の差は、差がないか、逆の傾向を示した。このことから、眠気測定に用いる表情にLv1と2で差があっても、運転傾向に影響を与えない可能性があると考えられる。同じことがLv3と4の間でも当てはまる。先行研究では、本研究で使用された北島らによる眠気レベルの評価が、約3を超えるレベルで事故のリスクを高めることが報告されている [30]。今回の研究では、レベル2とレベル3の違いが明確に表れているため、危険な状況での眠気判定の特徴として有効であることが確認された。

前述のとおり、先行研究の多くはDSを用いた実験であった。また、実車を使用した場合でも走行は実験的なものであり、日常の自然な走行とは乖離があると考えられる。そのため、実際の営業運転のデータを収集し、分析することは重要である。特に、本研

究で明らかになったドライバごとの横位置基準の違いや左へのオフセットは、DS 実験では言及されていない結果であり、実車特有の現象である可能性がある。また、先行研究では、飲酒運転が横位置の標準偏差に及ぼす影響が報告されている [94] [95]。しかし、今回の調査で運行データを提供していただいた運送会社では、運転前の対面点呼で飲酒運転ではないことを毎日確認しているため、影響はないと思われる。

3.5 学習モデル

3.5.1 ランダムフォレスト

ランダムフォレスト(Random Forests) [96]は、2001年に提案された機械学習アルゴリズムの一つである。主に分類や回帰、クラスタリングの用途で用いられ、汎化能力が高い手法である。

ランダムフォレストでは、与えられたデータ集合から n 組のブートストラップサンプルを作成し、そのブートストラップサンプルを用いて最大の決定木（弱識別器）を作成する。その際、各ノードはランダムにサンプリングした特徴量の中で最も良いものを選択していく。最終的に全ての木での多数決を行って強識別器を構築する。このようにブートストラップを利用した学習アルゴリズムであるため、ランダムフォレストは特徴量の個数が多くても効率的に学習することが可能である。また、クラス識別、クラスタリング、回帰分析を行うことができる。

ランダムフォレストは、学習サンプルを用いて複数の決定木構造を持つ識別器を構築する。各決定木は、分岐ノード(Split Node)と末端ノード(Leaf Node)により構築され、分岐ノードを繰り返し作成し、一定の基準により分岐が不可能になった際に、末端ノードを作成することにより構築される。分岐ノードは、ある1次元の特徴量と閾値の大小関係により左右に分岐する。また、末端ノードはたどり着いた学習サンプルの各クラス確率を保存する。これらの構造を持つ識別器の構築アルゴリズムについて以下に詳しく述べる。学習アルゴリズムを下記に示す。

木の数 T 、黄の最大の深さ D とする。学習サンプル集合 $S = \{x_1, y_1\}, \dots, \{x_N, y_N\}$, $x_i \in X, y_i \in \{1, 2, \dots, C\}$ を入力し、サブセットを作成する。サブセットは学習サンプル S からサンプルの重複を許容してランダムに選択する。サブセット一つを用いて決定木を構築する。決定木の分岐ノードはある特徴量 f_k と閾値 T_h を用いて左もしくは右へサンプルを分岐させる分岐関数が保存されている。そのため、 f_k と T_h は様々な候補の中から厳選する必要がある。分岐関数は、特徴選択回数 K としきい値選択回数 Y から、候補をランダムに $K \times Y$ 個選択し、情報利得 ΔE が最も高い候補に決定する。ある分岐ノード n にたどりついたサンプル集合 S_n 、分岐関数の候補 f_k と T_h により S_l と S_r に分割する。

$$S_l = \{i \in S_n \mid f_k(x_i) < T_h\} \quad (3.11)$$

$$S_r = S_n \setminus S_l \quad (3.12)$$

この S_l と S_r を用いて、式により情報利得 ΔE を算出する。情報利得とは、現在のノードのエントロピーから子ノードのエントロピーの和を引いたものであり、分岐関数によりどの程度情報量が減少したかを表している。子ノードのエントロピーが小さくなると情報利得は大きくなり、カテゴリをよく分割する分岐関数と表される。

$$\Delta E = E(S_n) - \frac{|S_l|}{|S_n|} E(S_l) - \frac{|S_r|}{|S_n|} E(S_r) \quad (3.13)$$

ここで、関数 $E(S)$ は情報エントロピーを表し、次式により算出される。

$$E(S) = - \sum_{i=1}^n p(c_i) \log p(c_i) \quad (3.14)$$

ここで、 $p(c_i)$ はクラス c_i の確率を表しており、学習サンプルの教師信号の出現頻度により求められる。これらの処理を繰り返すことによりサンプル集合を分割し、情報利得が 0 になった場合や最大の深さ D に達した場合に末端ノード l を作成し、到達したサンプル集合から各カテゴリの出現確率 $P(c \mid l)$ を計算する。このように、各決定木が構築される。

識別処理は、未知データを v とした時に各決定木に入力し、たどり着いた末端ノードに保存されている $P(c \mid l)$ を出力する。各決定木から出力された $(P_1(c \mid l), P_2(c \mid l), \dots, P_T(c \mid l))$ を用いて未知データの事後確率 $P(c \mid v)$ を算出する。これを用いて次式の単純ベイズ識別により未知データのクラスを推定する。

$$C_i^* = \arg \max_{c_i} P(c_i \mid v) \quad (3.15)$$

以上の処理によりマルチクラス識別が可能となる。

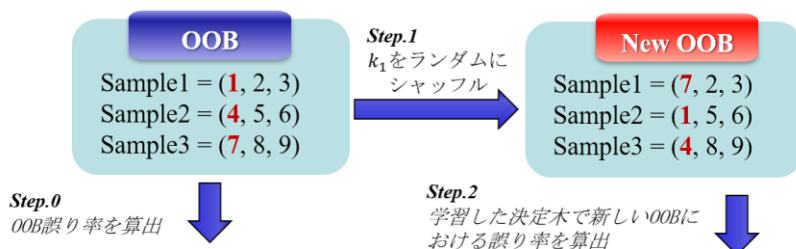
Permutation importance による特徴量寄与度の可視化

Random Forest や勾配ブースティングなどの決定木アルゴリズムのアンサンブル手法の強みは性能の高さの他に入力に用いた各特徴量の重要度を算出できることにある。この性質を活かして特徴量の重要度を測る方法として Permutation importance が提案されている [97]。Permutation importance の概要図を図 3.22 に示す。Permutation

importance では、モデル生成後、評価データを評価するときに、ある一つの特徴量のレコードの順序をシャッフルする。このとき他の特徴量やターゲットの順序は変更しない。順序変更後の精度が、順序変更前の精度に比べて下がっていれば、これは現実で起こり得るデータとはかけ離れているということになる。モデルの精度に影響を与えている特徴量ほど、順序入れ替えによる影響が強く見られる。これを全特徴量に対して行うことで、各特徴量の重要度を測ることができる。Permutation importance のアルゴリズムを下記に示す。ただし、簡単化のため Random forest に入力するデータとして特徴 A と特徴量 B の 2 つの特徴を持つデータを考える。

1. データを学習データと調整データに分ける。学習データの特徴 A,B を学習させ、モデルを訓練する。
2. 訓練後、調整データを使用してモデルの性能をタスクに適切な評価方法で測定する。(分類問題であれば Accuracy, 回帰問題であれば R2 score など) この時の性能値を baseline とする。
3. 学習データの特徴 A の値をランダムにシャッフルしてから訓練し、その性能を調整データで測定する。
4. 同様に特徴 B の値をランダムにシャッフルしてから訓練し、その性能を調整データで測定する。
5. 各特徴をランダムにシャッフルした時に baseline に比べて性能がどの程度落ちたかを計算することで各特徴がどのくらい性能に貢献しているかを正確に算出する。

----- 説明変数 k_1 の寄与度を算出する場合 -----
 ただし、説明変数の数は3, data = (k_1, k_2, k_3)



$$\text{特徴量寄与度} = - \text{OOBにおける誤り率} + \text{新しいOOBにおける誤り率}$$

図 3.22 Permutation importance の概要

3.5.2 LSTM

本研究では、学習モデルとして RNN (Recurrent Neural Network) およびその拡張である LSTM (Long Short-Term Memory) を用いる。RNN とは、中間層に再帰的構造を持つニューラルネットワークである。時刻 t において入力があると、 $t-1$ の中間層の状態も利用して中間層の計算を行う。過去の状態を参照して中間層の計算を行うため、時系列データを扱うのに適している。再帰型ではない一般のニューラルネットワークに対して、RNN における時刻 t の中間層の出力は、上記を拡張した次の式で表される。

$$y_j^{(t)} = \sum_{i=1}^I w_{ij} x_i^{(t)} + \sum_{j'=1}^J w_{jj'} y_{j'}^{(t-1)} + b_j \quad (3.16)$$

$$z_j^{(t)} = f(y_j^{(t)}) \quad (3.17)$$

LSTM モデルでは、時系列特徴量についてサンプリングを行ってからモデルに入力する。これは LSTM 層に入力するベクトルをサンプリング処理によって削減することによって学習時間を削減している。時刻 t の時の時系列特徴量を $x^{(1)} = \{x_{t-L_s+k}^{(1)}, x_{t-L_s+2k}^{(1)}, \dots, x_t^{(1)}\}$, $x^{(2)} = \{x_{t-L_s+k}^{(2)}, x_{t-L_s+2k}^{(2)}, \dots, x_t^{(2)}\}$, $x^{(n)} = \{x_{t-L_s+k}^{(n)}, x_{t-L_s+2k}^{(n)}, \dots, x_t^{(n)}\}$ として抽出する。ここで、 L_s は時系列特徴量抽出の窓枠、 k は時系列特徴量抽出時のサンプリング間隔である。定数 L_s , k は蓄積したドラレコデータから経験的に決定する。抽出された時系列特徴量 $\{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(n)}\}$ をモデルの入力層に入力する。

本研究で用いるモデルの構造を図 3.23 に示す。時系列特徴量 $\{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(n)}\}$ ごとにネットワークへ入力し、Convolution 層や LSTM によって特徴を抽出する。抽出された特徴を結合し、Dense 層で識別を行う。出力層の数は 1 つで、損失関数に平均二乗誤差、最適化関数として RMS prop を用いる。RMSprop は 2012 年に Tijmen Tieleman らが提唱した手法 [98] であり、AdaGrad [99] を改良したアルゴリズムである。

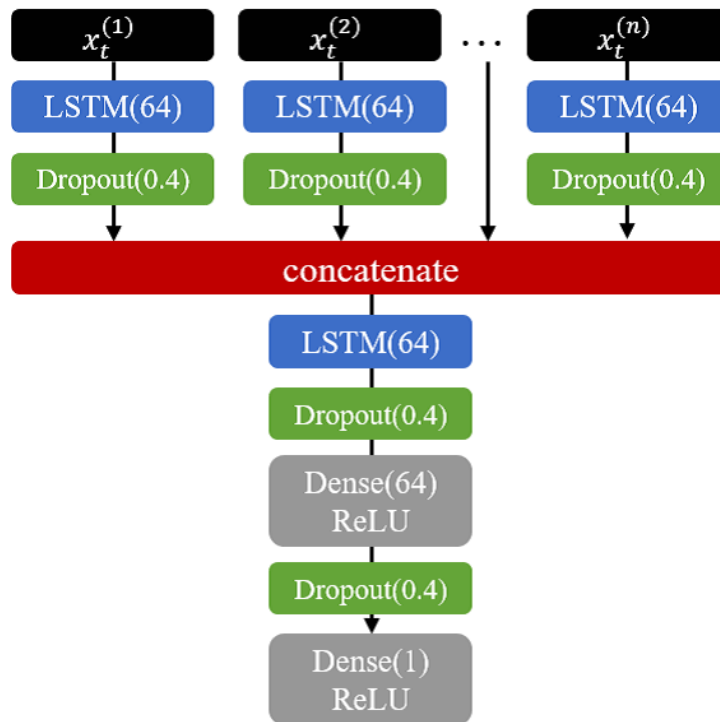


図 3.23 LSTM モデルの概念図

3.5.3 CNNLSTM

LSTM モデルでは、時刻 t のときの時系列特徴量を $\{x^{(1)}, x^{(2)}, \dots, x^{(12)}\}$ として抽出し、モデルに入力している。ただし、 L_s は時系列特徴量抽出時の窓枠、 k は時系列特徴量抽出時のサンプリング間隔である。時系列特徴量抽出時のパラメータ調整に関する検討から、定数 L_s や k は小さい値であればあるほど適していることがわかっている。すなわち、 L_s 分のデータすべてを入力することが望ましい。しかしながら、全ての値を学習しようとする、学習するパラメータや必要なメモリの量が膨大となる。そこで、従来のモデルである RNN に加えて、畳み込み層およびプーリング層を加えた新たなモデル CNL2LSTM モデルを提案する。

畳み込み層およびプーリング層の構造

畳み込み層は CNN の中心的な層で、CNN の全体の演算時間の約 90% を占める [100]。入力データに対してカーネルフィルタで畳み込み演算を行った結果を出力する。例えば画像に適用する場合、カーネルフィルタのサイズが $K \times K$ の場合、注目画素を中心とした $K \times K$ の領域の画素の値とカーネルフィルタとの積和を出力画像の注目画素の部分の値とする。

実際の CNN で使用する畳み込み演算は多チャンネル入力、多チャンネル出力の畳み込み

演算である。入力する特徴マップのチャンネル数が M 、出力のチャンネル数が N の時に畳み込み層はカーネルフィルタを $M \times N$ 枚持つ。一枚の画像 (Q) とカーネルフィルタ (K) の畳み込み演算を KP と表すとき、この畳み込み層の推論の演算は

$$y_j = \sum_{i=0}^{N-1} K_{j,i} \otimes Q_i \quad (0 \leq j < M) \quad (3.18)$$

と表される。これを図示すると図 3.24 のようになる。




図 3.24 複数チャンネルの畳み込み

プーリング層は畳み込み層で検出した特徴の位置感度を落とし、位置普遍性を上げるために畳み込み層の後に設置される層である。プーリング演算にもいくつか種類があるがよく使われるサイズが 2×2 の Max プーリングについて説明する。まず初めに、画像全体をプーリングのサイズで区切る。 4×4 の入力画像に 2×2 のサイズでプーリングを行う場合、画像は 4 個の部分に区切られる。この後この区切られたマスの中の最大値を各マスでの出力値として出力する。プーリングによって出力される画像のサイズは 4 分の 1 のサイズになる。Max プーリング層による処理の例を図 3.25 に示す。




図 3.25 Max プーリング層

推定に用いる CNNLSTM モデル

時系列変化を学習するために、Recurrent Neural Network の拡張である Long short-term memory (LSTM) [101]をベースとしたモデルを提案する。LSTM はRNN に比べ長期依存の時系列問題を解くのに適しているためである。CNNLSTM モデルの構成を図 3.26 に示す。本研究で提案するニューラルネットワークは、時系列変化の局所的な特徴を捉える Convolution 層、情報の位置変動に対応するための Pooling 層、時系列情報に対して認識を行う LSTM からなる。これらを組み合わせることで短期的にも長期的にも時系列変化を考慮した眠気推定が可能である。時系列特徴量 $\{x^{(1)}, x^{(2)}, \dots, x^{(12)}\}$ ごとにネットワークへ入力し、Convolution 層や LSTM によって特徴を抽出する。抽出された特徴を結合し、Dense 層で識別を行う。出力層の数は 1 つで、損失関数に平均二乗誤差、最適化関数として RMS prop を用いる。モデルのパラメータとして、学習率を 0.01、ドロップアウト係数を 0.4 としている。

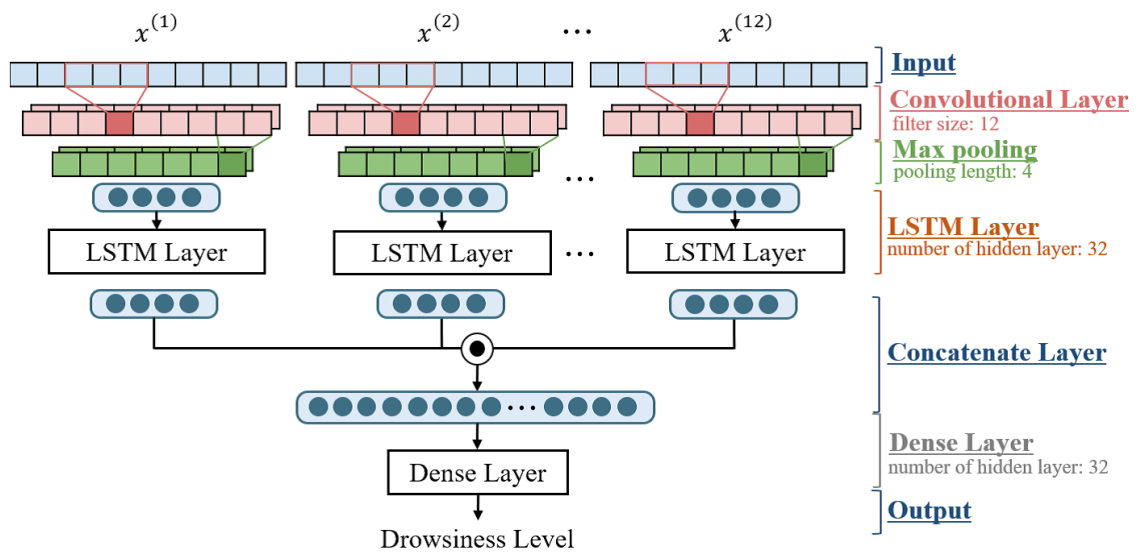


図 3.26 CNNLSTM モデルの構成

推定に用いる CNN2LSTM モデル

CNNLSTM モデルにおける CNN 層を増やすことはモデルの表現力を増やすだけではなく学習時間の削減も期待できる。推定に用いる CNN2LSTM モデルを図 3.27 に示す。このモデルでは CNNLSTM モデルの CNN 層を 2 層にしたモデルである。

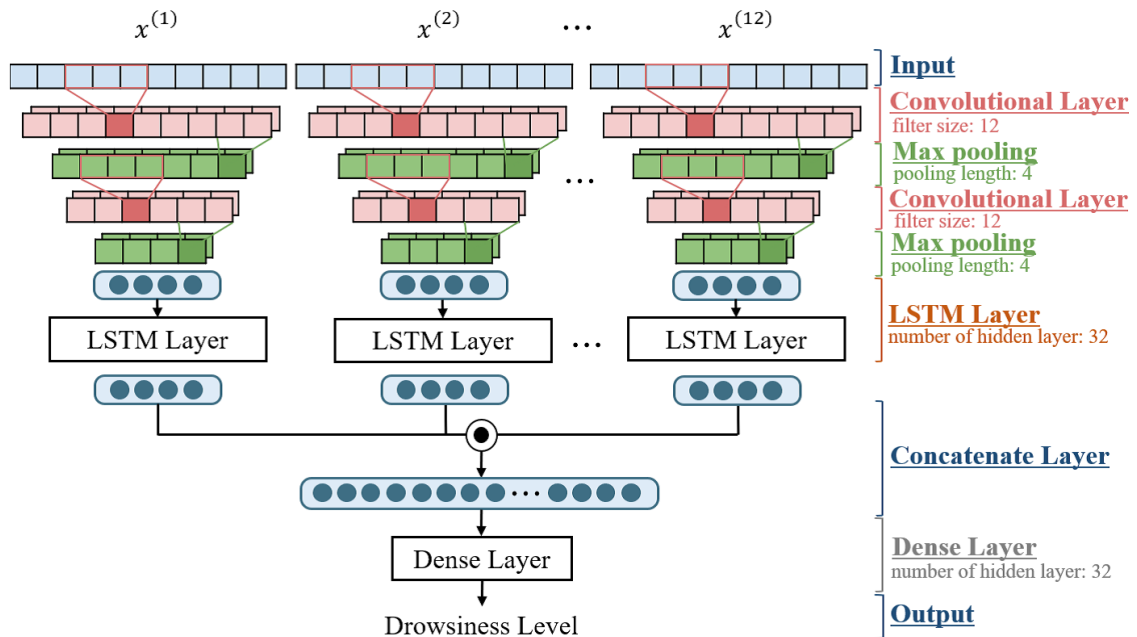


図 3.27 CNN2LSTM モデルの構成

3.6 提案手法

3.6.1 AttentionCNNLSTM

Attention 層の構造

アテンション技術の研究は深層学習が大きな注目を集める前から行われており、主に視覚的な注意、すなわち、画像処理において画像のどの部分に着目すればよいかについて取り組まれてきた。その後、2014年にBahdanauらにより発表された機械翻訳におけるアテンション機構がその高い精度と汎用性により大きな注目を集め、画像キャプション生成、音声認識、質問応答、機械読解をはじめとした様々なタスクで応用されるなど、深層学習の発展に大きく貢献している。図 3.28 に、その概念図を示す。




図 3.28 Bahdanau らのニューラル翻訳モデル

アテンションについて明確な定義は存在しないが、一般的には入力されたデータのうち、どの部分を重視するかを決定する手段の総称である。近年では、Bahdanau らにより導入されたメカニズムを指す場合が多い。具体的には、 $\{h_1, h_2, \dots, h_T\}$ をベクトル集合、 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_T]^T$ を各ベクトルに対するアテンションの分布（重み； $\sum_i \alpha_i = 1$ ）としたとき、下記の式のように h の重み付総和であるコンテキストベクトルを出力する単純な計算処理である。

$$c = \sum_{i=1}^T \alpha_i h_i \quad (3.19)$$

ここで、ベクトル h_i に対するアテンションの重み α_i は、

$$\alpha_i = \frac{\exp(S(h_i, s))}{\sum_{k=1}^T \exp(S(h_k, s))} \quad (3.20)$$

のように、ベクトル h_i とクエリ s を引数とするスコア関数 S の値に基づいて計算される。 s の表現や S の計算方法はタスクやネットワークにより異なるが、上記の式は多くの研究で共通である。

アテンションが大きな注目を集めたのは、ニューラルネットワークにおいて入出力間の関係性を学習するにあたり、入力データを一つの固定長のベクトル表現に変換することなく、可変長のデータ全体を保持したまま入力データの各要素と出力データとの関係性を学習することを可能にしたためである。アテンションはテキストをはじめとした系

列データを扱う再帰的ニューラルネットワーク（RNN）への導入について盛んに研究が行われているが、系列データ以外にも利用可能な汎用的な技術である。

推定に用いるモデル

推定に用いる CNN2LSTMatt モデルを図 3.29 に示す。本研究で提案するニューラルネットワークは、時系列変化の局所的な特徴を捉える Convolution 層、情報の位置変動に対応するための Pooling 層、時系列情報に対して認識を行う LSTM 層、予測に寄与した特徴の寄与度を算出する Attention 層 $a^{(1)}, a^{(2)}, \dots, a^{(n)}$ からなる。これらを組み合わせることで短期的にも長期的にも時系列変化を考慮した眠気推定が可能である。時系列特徴量 $\{x^{(1)}, x^{(2)}, \dots, x^{(n)}\}$ ごとにネットワークへ入力し、Convolution 層や LSTM 層によって特徴を抽出する。抽出された特徴を結合し、Dense 層で識別を行う。出力層の数は一つで損失関数に平均二乗誤差、最適化関数として RMS prop を用いる。モデルのパラメータとして、学習率を 0.01、ドロップアウト係数を 0.4 としている。

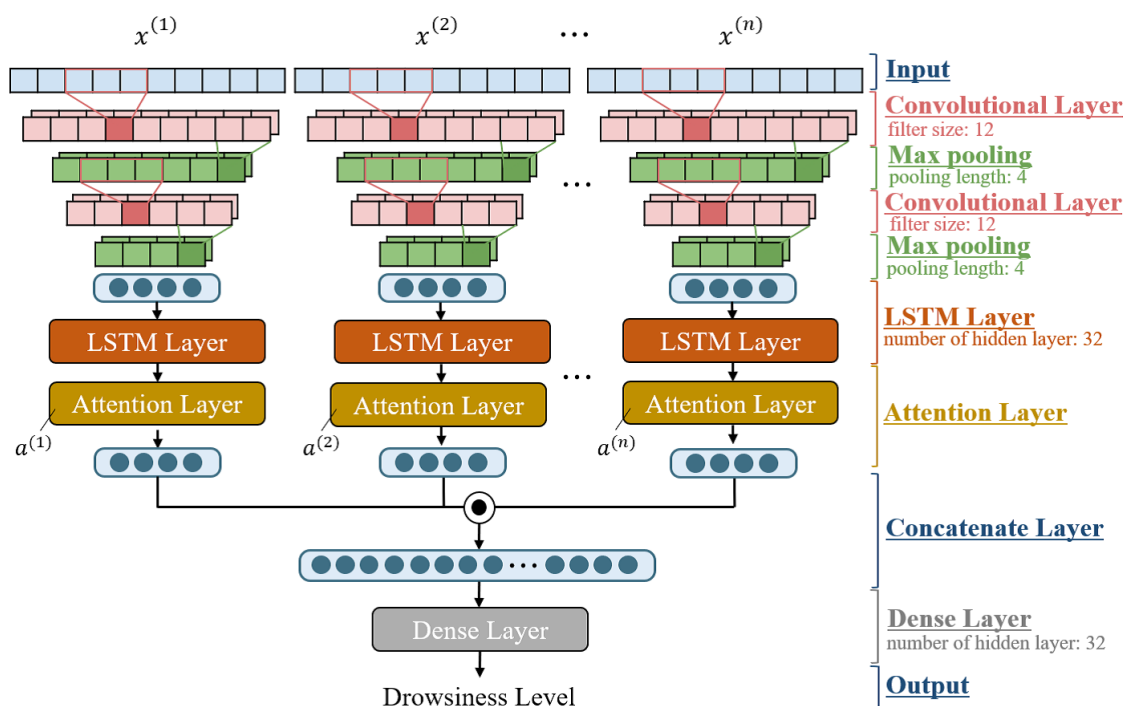


図 3.29 CNN2LSTMatt モデル

3.6.2 特徴量設計

走行位置揺らぎに基づく特徴量

3.4.2 と 3.4.3 において，レーン線検出に基づく走行位置と，眠気との関連を示した．このことを中心に，特徴量を設計する．スクリーニング処理後のレーン線までの距離の統計的变化をもとに特徴量化する．まず，時刻 t_s から t_e までの D_L の平均値を $m(t_s, t_e)$ ，標準偏差を $\sigma(t_s, t_e)$ とすると，車両の横位置の存在範囲 P_σ と N_σ は式 3.21 と 3.22 で表される．

$$P_\sigma(t_s, t_e) = m(t_s, t_e) + \sigma(t_s, t_e) \quad (3.21)$$

$$N_\sigma(t_s, t_e) = m(t_s, t_e) - \sigma(t_s, t_e) \quad (3.22)$$

3 章の結果で述べたように，横方向の走行位置やふらつきの程度には個人差があることが分かっている．この結果は， P_σ と N_σ に影響を与える可能性がある．個人差を吸収するために，絶対値ではなく相対値で考える．運転開始後数分間は眠気が起こらないと想定し，その間の統計値を基に相対値を表す特徴量を考案した．運転開始から W 秒後の P と N は，式 3.23 と式 3.24 により計算される．

$$P(t) = \begin{cases} P_\sigma(t - t_w + 1, t) - P_\sigma(1, t_w), & \text{if } t > t_w \\ 0, & \text{others} \end{cases} \quad (3.23)$$

$$N(t) = \begin{cases} N_\sigma(t - t_w + 1, t) - N_\sigma(1, t_w), & \text{if } t > t_w \\ 0, & \text{others} \end{cases} \quad (3.24)$$

定数 W は，蓄積したドライブレコーダのデータから経験的に決定する． P と N のそれぞれの変化量 D を抽出する． D_r と D_l は，それぞれ式 3.25 と式 3.26 から求める．

$$D_r = P(t) - P(t - t_w) \quad (3.25)$$

$$D_l = N(t) - N(t - t_w) \quad (3.26)$$

また、 P と N の差 S を式 3.27 から求め、特徴量とする。

$$S(t) = P(t) - N(t), \text{ if } t > t_w \quad (3.27)$$

さらに、 S の絶対値 B も特徴量とするため、式 3.28 より求める。

$$B(t) = |S(t)| \quad (3.28)$$

また、走行開始後 W 秒間で蓄積した走行位置からの変動が大きいシーンを抽出し、その回数 C を特徴量とする。 C は、左右それぞれ、式 3.29 と式 3.30 から求める。

$$C_r = \begin{cases} \frac{1}{W} \sum_{i=t-t_w}^t F_r(i), & \text{if } t > t_w \\ 0, & \text{others} \end{cases} \quad (3.29)$$

$$C_l = \begin{cases} \frac{1}{W} \sum_{i=t-t_w}^t F_l(i), & \text{if } t > t_w \\ 0, & \text{others} \end{cases} \quad (3.30)$$

ただし、 F_r と F_l は、それぞれ式 3.31 と式 3.32 によって計算される。

$$F_r(t) = \begin{cases} 1, & \text{if } d_r \geq P_o(1, t_w) \\ 0, & \text{others} \end{cases} \quad (3.31)$$

$$F_l(t) = \begin{cases} 1, & \text{if } d_l \geq N_o(1, t_w) \\ 0, & \text{others} \end{cases} \quad (3.32)$$

以上より、特徴量 $P_r, N_r, D_r, S_r, B_r, C_r$ および $P_l, N_l, D_l, S_l, B_l, C_l$ が得られる。各特徴量を整理する。

P と N は、運転開始直後 W 秒間の基準値からの変動であり、ヒストグラムの相対的な横方向の位置変動を表す。

D は、単位時間あたりのヒストグラムの横方向の位置変動量を意味する。

S はヒストグラムの幅の変化を示し、幅を広くするか狭くするかによって符号が変わります。 B は、ヒストグラムの幅の変動の大きさを絶対値で表す特徴量である。

C は、運転開始直後 W 秒間の基準値から大きく外れた回数。

下付き文字の l と r は、左右の車線の違いを示している。

学習に用いる特徴量とその名称の一覧を表 3.16 に示す。以後、特徴量の名称で記載する。

表 3.16 学習に用いる特徴量とその名称

No.	Feature	Lane	Feature name
1	P_r	Right	positive_right
2	N_r	Right	negative_right
3	S_r	Right	sigma_diff_right
4	B_r	Right	abs_sigma_diff_right
5	D_r	Right	diff_right
6	C_r	Right	sigma_cnt_right
7	P_l	Left	positive_left
8	N_l	Left	negative_left
9	S_l	Left	sigma_diff_left
10	B_l	Left	abs_sigma_diff_left
11	D_l	Left	diff_left
12	C_l	Left	sigma_cnt_left

時系列を考慮した特徴量

本研究では、時系列変化にも眠気特徴が現れるものとして、横方向の走行位置揺らぎに基づいて上記特徴量から時系列特徴量を抽出する。時刻 t における時系列の特徴量は、

$$x^{(1)} = \{ P_r(t - L_s + k), P_r(t - L_s + 2k), \dots, P_r(t) \}$$

$$x^{(2)} = \{ N_r(t - L_s + k), N_r(t - L_s + 2k), \dots, N_r(t) \}, \dots$$

$$x^{(12)} = \{ C_l(t - L_s + k), C_l(t - L_s + 2k), \dots, C_l(t) \}$$

で表される。ただし、定数 L_s は時系列特徴抽出時の窓枠、 k はサンプリング間隔である。

抽出された時系列特徴量 $\{x^{(1)}, x^{(2)}, \dots, x^{(12)}\}$ をモデルの入力層に入力する。

3.7 眠気推定実験

3.7.1 使用するモデル

前節で抽出した特徴量を用いて眠気を推定する。まず、比較用として、時系列特徴量を使用しない方法として、5.1 で記述したランダムフォレストを適用した。時系列特徴量を利用する方法として、LSTM を用いた。さらに、提案手法での推定結果と比較評価を行った。

3.7.2 検証方法と評価指標

3.4 で明らかになった結果より，眠気レベル 1 と 2 の間，およびレベル 3 とレベル 4 の間では，横方向の位置統計の差は小さいかあいまいである．レベル 2 とレベル 3 の違いは明らかであった．このことから，評定値および推定値をレベル 1-2 と，レベル 3-4 の二つに量子化する．量子化した結果について，下記指標により検証・評価した．

Leave-one-out 交差検証

本実験では Leave-one-out 交差検証で精度を算出した．Leave-one-out 交差検証の方法を図 3.30 に示す．この図では 6 データの走行データに対して精度を算出する場合を表している．Leave-one-out 交差検証では，標本群から 1 つの事例だけを抜き出してテスト事例とし，残りを訓練事例とする．これを全事例が一回ずつテスト事例となるよう検証を繰り返す．

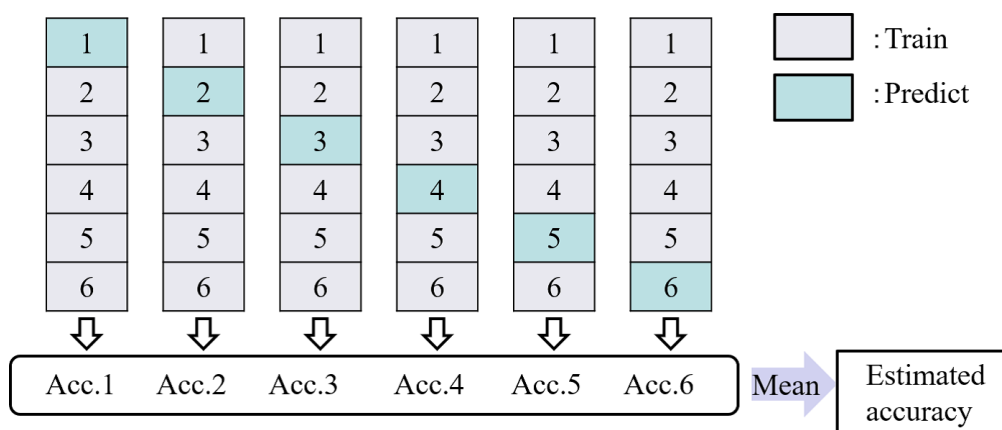


図 3.30 Leave-one-out 交差検証の方法

MAE

MAE (Mean Absolute Error) は平均絶対誤差ともいい，式 3.33 で定義される．

$$M = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.33)$$

ただし， N は評価したいデータの数， y_i は真値， \hat{y}_i は予測値をあらわす．推定値と真値が完全に一致する場合，MAE は 0 となる．MAE が小さければ小さいほどよいモデル

であることをあらわす。

精度

量子化したデータは、眠気レベル 3-4 の正誤について以下の 4 通りのケースが考えられる。

True Positive (TP)： 眠気レベル 3-4 のデータ内で、眠気レベル 3-4 だと判定されたデータ数

True Negative (TN)： 眠気レベル 3-4 以外のデータ内で眠気レベル 3-4 以外だと判定されたデータ数

False Positive (FP)： 眠気レベル 3-4 以外のデータ内で眠気レベル 3-4 だと判定されたデータ数

False Negative (FN)： 眠気レベル 3-4 データ内で眠気レベル 3-4 以外だと判定されたデータ数

上記パターンを混同行列として図 3.31 にあらわすことができる。

		予測値	
		Lv3-4	Lv3-4 以外
真値	Lv3-4	TP	FN
	Lv3-4 以外	FP	TN

図 3.31 混同行列

これらの要素を用いて、下記により各種評価指標を求める。

- ・適合率 (Precision)

眠気レベル 3-4 と判定されたデータのうち、実際にレベル 3-4 が含まれる割合を示す指標である。

$$P = \frac{TP}{TP + FP} \quad (3.34)$$

・再現率 (Recall)

全データ中に存在する眠気レベル 3-4 データのうち、どれだけレベル 3-4 と推定できたかを示す指標である。

$$R = \frac{TP}{TP + FN} \quad (3.35)$$

・正解率 (Accuracy)

予測結果全体と、答えがどれくらい一致しているかを示す指標である。

$$A = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.36)$$

・F 値 (F-measure)

適合率と再現率の調和平均をあらわす指標である。

$$F = \frac{2 \times R \times P}{R + P} \quad (3.37)$$

上記に示す適合率、再現率、正解率および F 値を評価指標として用いた。

眠気レベル 3 への立ち上がり誤差

眠気レベル 3 への立ち上がり誤差 (rising error) を式 3.38 で定義する τ を用いて評価する。

$$\tau = \frac{\sum_{k=1}^n |\tau_t(k) - \tau_p(k)|}{n} \quad (3.38)$$

ただし、 n は走行データの数、 τ_t は真値における眠気レベル 3 への立ち上がり地点、 τ_p は予測値における眠気レベル 3 への立ち上がり地点である。 τ が小さいほど立ち上がりの誤差の少ないモデルをあらわす。

眠気レベル3の立ち上がり検出率

眠気レベル3への立ち上がり検出率 (rising error rate) を式 3.39 で定義する τ_t を用いて評価する.

$$\tau_t = \frac{N_r}{N_a} \quad (3.39)$$

ただし, N_a は眠気レベル3以上が存在する走行データの数, N_r は眠気レベル3以上が存在するデータの内, 眠気レベル3以上を検出したデータの数であらわす. 眠気レベル3以上が存在する走行データの内すべてのデータで眠気レベル3への立ち上がりが検出できていれば, $\tau_t=1$ となり, 大きいほど性能の良いモデルであることをあらわす.

3.8 結果・考察

3.8.1 Leave-one-out 交差検証による推定精度

まず, 眠気レベル3-4を各モデルに対する精度の比較結果を, 表 3.17 に示す. 使用したデータセットは表 3.13 で示した全走行 105 時間 (73 走行分) の内, 22 走行分を学習用データとして用いている. 提案されたモデルは, 適合率は 0.706, 再現率 0.606, F 値は 0.652 と, 他の比較モデルより推定性能はよいことが確認された. さらに, 各モデル間で比較評価を行った.

表 3.17 各モデルの推定精度比較

model	precision	recall	F1-measure
RF	0.606	0.547	0.575
LSTM	0.579	0.527	0.552
proposed	0.706	0.606	0.652

精度評価指標として, 推定眠気レベルと正解眠気レベルの平均絶対誤差(MAE)も調査した. MAE は式 3.33 で表される指標である. また, 眠気レベル2からレベル3への変化を検知することが重要であると前述したが, 前節で述べたように, 眠気レベル2からレベル3への変化を検知することが重要である. 眠気レベル3への立ち上がり誤差 (TE)を比較した. 立ち上がり誤差 τ は式 3.38 により算出される.

実験の結果得られた MAE と TE を表 3.18 に示す。MAE の値が低いほど良好なモデルであり、提案した特徴を用いたモデルは比較法よりも精度が高いことが確認された。提案手法の中で、CNN 層、Attention 層、LSTM 層を統合した提案モデルが最も精度が高いことが確認された。TE も数値が小さいほど誤差の少ないモデルと考えられ、結果も比較法よりも精度が高い。ただし、時系列の特徴を使用しない RF model が最も低い値を示しました。時系列を反映したモデルでは、より長い周期を組み込んだ影響で、応答性にやや時間がかかることが原因の 1 つと考えられる。

表 3.18 各モデルの誤差比較

Model	MAE	TE
RF	0.54	1134
LSTM	0.51	1209
proposed	0.48	1156

生体信号より直接的に眠気を計測する手法に比べ、多少の応答性の悪さは、本手法では避けられない。

本研究の手法では、統計的な処理をするための窓枠が必要なことや、運転開始直後の参照用データの蓄積期間などの影響があるためである。応答遅れは、数十秒から数百秒程度と見積もられる。リアルタイム性の要求度合は、応用するアプリケーションに依存するが、精度を確保しつつ、リアルタイム性を向上させることは、今後の研究対象となりうる。

3.8.2 個人外推定

従来手法の Kaneko モデルでの眠気レベル推定では、3.1.4 で示したとおり、一部の個人外推定は推定結果が発散してしまう問題があった。このため、提案手法でも、個人外推定により検証した。ここでは、3.1.4 の予備実験と同様に、2 値化せずに眠気レベルを推定している。金子モデルでの結果を図 3.32 に、RF モデルでの結果を図 3.33、提案モデルでの結果を図 3.34 に示す。図中、黒線が Leave-one-out 交差検証の結果であり、青線又は赤線が個人外推定の結果である。従来モデルでは特定のドライバで結果が発散してしまう現象が、RF モデルと提案モデルでは発散することなく、誤差を抑えられていることがわかる。

従来モデルでは、ある運転特性をもった特定のドライバが学習データに含まれるか否かで大きく推定結果が変わってしまう。また、Leave-one-out 交差検証の MAE でも 7.58

と誤差が著しく大きく、未知のドライバデータに対して推定が困難で汎化性のないモデルであるともいえる。対して、提案モデルでは、個人外推定でも結果に大きな乖離はなく、未知のドライバに対する推定精度の向上がみられ、個人差の影響を抑制する特徴量設計の有効性が確認できた。




図 3.32 Leave-one-out 交差検証と個人外推定の比較（金子モデル・ドライバ G）




図 3.33 Leave-one-out 交差検証と個人外推定の比較（RF モデル・ドライバ G）




図 3.34 Leave-one-out 交差検証と個人外推定の比較 (提案モデル・ドライバ G)

3.8.3 CNN 層の数の効果

提案モデルにおける CNN 層を増やすことはモデルの表現力を増やすだけではなく学習時間の削減も期待できる。本実験では、CNN 層の数による推定精度の変化に関する検討を行った。

提案モデルについて、CNN 層が一層の場合 (CNNLSTM) と二層 (CNN2LSTM) の場合で精度への影響を調べた。それぞれの場合についてパラメータ調整も行っている。

CNNLSTM と CNN2LSTM との比較を図 3.35 に示す。CNNLSTM を青色、CNN2LSTM を赤色であらわしている。この図より、CNNLSTM と CNN2LSTM それぞれの最大値で比較すると、CNN2LSTM が精度を上回っており、層を増やした方がより良い精度が得られた。また、上位 15 つのモデルをみると、CNN2LSTM が多くを占めており、モデルとしての安定性も CNNLSTM より高いことがわかる。したがって、CNN 層を増やすことは精度向上につながる。

また、学習時間を比較すると、CNNLSTM は 1 epoch につき 1 分 21 秒かかっていたのに比べて、CNN2LSTM は 1 epoch につき 31 秒となり、学習時間の削減も実現できた。これは CNN 層の次の RNN 層に入力する際のベクトル数が、CNN 層 (および Max pooling 層) の増加によって削減でき、RNN 層で学習するパラメータが少なくなったことが大きく影響したのではないかと考える。ここで、epoch とは、データセット全体を 1 回学習する単位である。




図 3.35 CNN 層の数による比較

3.8.4 Attention 層の効果

提案モデルが時系列特徴量のどの部分に着目して推定をおこなっているのかを確認するため、Attention 層を分析することで可視化した。

学習の初期状態の Attention 層の重みを可視化したものを図 3.36 に示す。赤や青に近づく程、寄与度の高いことをあらわしている。図 3.36 より、ほぼ学習されていない初期状態では、どの特徴量も同じ区間に着目しており、それらの区間が広い区間であることがわかる。一方、図 3.37 に示す学習済みモデルの Attention 層の重みは特徴量ごとに異なる区間に着目しており、またその区間が一部分であることからモデルが効果的に時系列変化の特徴を学習していることがわかる。また、モデルは瞬間的な特徴だけでなく、時系列変化にも着目していることから、時系列特徴量の抽出および Neural Attention Model の有効性が示された。

瞬間的な特徴量で学習させる際に、特徴量同士の相関の高い特徴量が多数存在した。特徴量同士で相関の高い特徴量の特徴として、「シグマのプラス方向なのかマイナス方向なのか」という違いと「右白線から抽出しているか左白線から抽出しているか」の違いは、Random forest などの瞬間的な特徴で学習させる際には大きく影響してないことがわかっている。時系列特徴量とすることによってこれらの影響度が変わるのかどうか

を調査した。

図 3.37 中の「 N_l (negative left)および P_l (positive left)」、「 N_r (negative right)および P_r (positive right)」をみると同一のところを着目しており、「シグマのプラス方向なのかマイナス方向なのか」という違いは時系列特徴量についても大きく影響しないことがわかった。

図 3.37 中の「 C_l (sigma cnt left)および C_r (sigma cnt right)」、「 D_l (diff left)および D_r (diff right)」、「 B_l (abs(sigma diff left))および B_r (abs(sigma diff right))」、「 S_l (sigma diff left) および S_r (sigma diff right)」をみると、それぞれ異なる区間に着目しており、「右白線から抽出しているか左白線から抽出しているか」で特徴が異なっていることがわかる。

以上のことから、シグマのプラス方向とマイナス方向のどちらかの特徴量を削減することも可能であると考える。

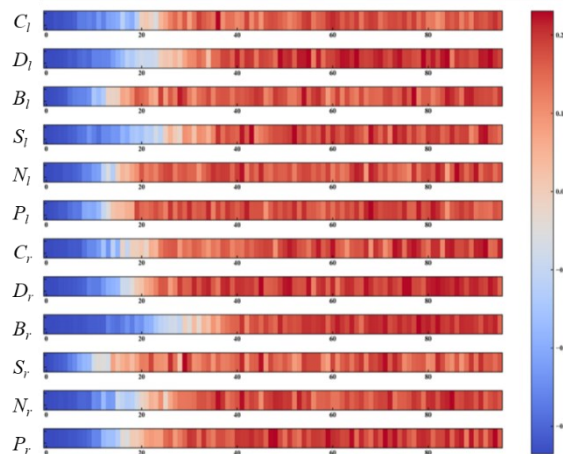


図 3.36 Attention 層の重み (初期状態)




図 3.37 Attention 層の重み (学習済みモデル)

3.9 まとめ

本章の目的は、ドライブレコーダから収集可能なデータである前方映像からの情報と車両操作情報より、運転中のドライバの眠気を推定する手法を提案し、その有効性を評価することであった。

まず、実際の車両のドライブレコーダデータの中から、特にレーン線検知データに注目し、眠気に対してレーン内走行位置がシフトしていく実車特有の特徴を抽出できた。これを基に特徴量の設計を行い、同時にこの特徴量を生かすための CNNLSTM をベースとした学習モデルを提案し、評価を行った。その結果、提案モデルおよび、特徴を時系列データとして扱うことの有効性を示すことができた。

実際の車両の走行データには、様々な状況やドライバの行動が存在する。眠気のほか、喫煙、飲食、会話、携帯電話での通話、ハンズフリー機器での通話、カーナビゲーションシステムやラジオの操作、わき見、安全確認行動、体調不良などである。ドライブレコーダの前方映像のみの情報を利用することで、これらと眠気を区別したり、運転に不向きな状態として統合的に判断してドライバや管理者に警告するシステムの開発につながる可能性もあり、今後の課題としていきたい。

第4章 修正操舵に着目しながら運転検出

本章では、ドライブレコーダやデジタルタコグラフのデータから、スマートフォン操作などによるながら運転を検出する目的で、車両挙動データの解析と検出手法を提案し、その有効性を評価した。

4.1 先行研究

わき見運転と事故

近年、自動車運転中にスマートフォン等携帯端末機器やカーナビゲーションなどを見たり、操作したりするいわゆる「ながら運転」が、危険行為として社会問題化している。それに伴い、ながら運転や脇見運転に関する研究が多くされており、その行為が車両挙動に与える影響についても報告がされている。これまでの研究では、ドライバを撮影するカメラを使用して運転以外の操作を認識する方法がいくつか提案されてるが、顔や姿の定期的なビデオ録画を嫌うドライバもいる。したがって、システムの普及のためには、ドライバのイメージなしに、車両の行動から注意散漫な運転を検出する必要がある。それにもかかわらず、車両の行動から脇見運転を常に検出するための研究はあまり行われていない。例えば、岡山らはカーブ走行時において情報機器端末を操作することがドライバの挙動にどのような影響を及ぼすのかについて検討している [13]。結果としてカーブ走行時にスマートフォンの小さな操作ボタンを押下する場合に操舵が滑らかに行われなくなると報告している。また、伊藤らはドライバが直線道路走行中に音声操作を行った際における警報音への反応時間について検証し、音声操作の負荷によって総操作時間が増加するにつれて警報音への反応時間が長くなることが示された [102]。また、ステアリング操舵角の基本周波数標準偏差から警報音への反応時間が推定可能であることが報告されている。操舵操作以外にも、車速制御や反応時間にも影響を及ぼすという報告がされている。荒川らは高速道路において運転中にスマートフォン操作を行った時の危険性の検証を DS を用いて行っている [103]。スマートフォン操作時は画面確認や注視に起因して、先行車に対する注意配分が減少するため、車速制御が上手く行えず、ブレーキペダルストロークの変化が大きくなる傾向が見られると報告している。また、大北らは脇見が原因でヒヤリハットに至った事例を抽出し、脇見を始める時の走行条件(車速、前後加速度、車間距離)、ドライバ操作(ブレーキ)等と、ヒヤリハットのレベルと脇見角度との関係を調べ、脇見がどういうときに行われ、事故やヒヤリハットの危険度とどう関係しているのか調査している [14]。結果として、わき見運転は余裕があると感じたときに行われていること、脇見が原因で事故に至った理由として、何らかの原因で脇見時間が長くなりすぎてしまい回避操作が遅れたということが考えられたと報告している。しかし、多くの研究ではカーブ走行時やブレーキ時、ヒヤリハット発生時など、ある評価区間における車両挙動について限定しており、常時評価することができるよう

な研究はなされていない。また特に、事故が起きてしまうと被害が甚大となる大型車の実車データでの評価は行われていない。また、漫然運転を車両挙動から検出する研究 [104] [89] はなされているものの、車両挙動からながら運転をリアルタイムに検出するような研究はなされていない。

4.2 DS によるながら運転時の挙動調査

本節では、実際の車両でのスマートフォン操作によるながら運転のリアルタイム検出に向け、ながら運転に特有な特徴を調査するため、DS での実験を行った。

4.2.1 修正操舵について

田中らはドライバが実車の直進状態を維持する実験において平均基本周波数 0.2~0.3Hz で操舵を行う傾向があることを報告している [105]。高速道路の直線区間において、車両速度、ヨー角速度、操舵角、操舵トルク、ドライバの心電図を計測して解析を行い、操舵角とヨー角速度の周波数特性には 0.25Hz 付近にピークを持つことを示している。つまり、直線を走行している際も一定周期でふらついているということが分かる。また、前章で述べたように伊藤らは情報提示装置の音声操作が運転操作に与える影響について調査し、音声操作中に集中力が低下し細かいハンドル操作ができなくなることで、修正操舵による基本周波数の平均値が通常時よりも小さくなり、標準偏差が相対的に大きくなると報告している [102]。上記のように、車線をキープする細かな操舵行為を修正操舵として着目する。ながら運転時に発生するドライバの行動として、前方から目線を外す→修正操舵が行われずに車線をはみ出そうとする→しばらく後に目線を前方に戻す→ハンドル操作が必要なことに気付く→修正操舵を行う。というサイクルを繰り返すことが仮定できる。この一連の行動の結果としてあらわれる修正操舵の特性をまず調査した。

4.2.2 車両挙動調査実験

高速道路走行時におけるながら運転と通常運転での修正操舵の違いについて DS を用いて比較検証を行った。図 4.1 に、使用したシステムの全景を示す。DS は、実車の車体や内装、運転装置を使用したもので、8 台のプロジェクタによりドライバ正面を中心とした周囲 270 度の範囲の環境を、車体周囲に配置した高さ 2.5m の多角形筒型スクリーンへ連続的に投影表示できる。走行環境の再現と走行ログの収集にはフォーラムエイト製 UC-win/Road(Ver.13.1) Driving Sim を使用した。図 4.2 に使用したコースの概略図、図 4.3 にコース鳥瞰の一部を示す。コースは実際の高速道路の一部を模した全長約

10km の道路をループさせて使用した。車線幅は実際の高速道路と同等の 3.5m で、片側 3 車線、曲率半径約 3km 以上の比較的緩いカーブ 3 種と直線区間で構成されている。走行させる車両モデルは、大型トラックのものを使用した。被験者に通常運転とながら運転の 2 つのそれぞれ 30 分間走行してもらい、操舵角について調査した。操舵角を含む走行ログは 100Hz で記録される。被験者は 5 名 (23.6 ± 0.48 歳) で、ながら運転についてはスマートフォンによる SNS 閲覧、もしくはネットサーフィンをするように指示をした。



図 4.1 実験に用いた DS の全景




図 4.2 実験に使用した DS のコースレイアウト



図 4.3 走行コースの一部例

4.2.3 実験結果

操舵角

実験によって取得された同一被験者による通常運転時，ながら運転時の操舵角の一例をそれぞれ図 4.4，図 4.5 に示す．グラフの縦軸は操舵角度，横軸は時系列を示す．グラフ中，250 秒程度で周期的にあらわれる波形は，DS コースのカーブに沿った操舵に由来するものである．その周期よりも短く，数秒単位でも細かい操舵操作があることがわかる．通常運転時と比べ，ながら運転時にはこの細かい操舵の振幅（操作量）が大きくなっていることがわかる．




図 4.4 操舵角の時間変化（通常運転時）




図 4.5 操舵角の時間変化（ながら運転時）

この操舵の周期的な特性を調査するため、一連の時系列信号である操舵角に高速フーリエ変換を適用し、サンプリング数 2048 点の約 20 秒間を窓枠として周波数スペクトルを得た。図 4.6 に、窓枠 20 秒の操舵角の拡大図を示す。また、高速フーリエ変換によって得られたスペクトルを図 4.7 に示す。




図 4.6 操舵角の時間変化（窓枠 20 秒間）




図 4.7 高速フーリエ変換により得られる周波数スペクトル

スペクトルの中から、スペクトル強度が高いものを基本周波数として抽出し、その周波数の逆数をとって周期を算出した。走行時間 30 分間に対して 20 秒ごとに窓枠を移動させて周期を算出し、その周期の平均と標準偏差を比較した。結果を表 4.1 に示す。5 名中 4 名の被験者において、通常運転時に比べ、ながら運転時の操舵周期が短くなっていることが分かった。その差は、該当 4 名の被験者において約 0.2 秒ほどであった。標準偏差は、ながら運転時は 4 名の被験者で通常時より低い結果となった。

表 4.1 通常運転時とながら運転時の操舵周期の比較

Sub.	State	Cycle_mean	Cycle_SD
A	Normal	4.2632	1.4283
	Distracted	3.9331	1.4306
B	Normal	3.9342	1.4216
	Distracted	3.7104	1.2980
C	Normal	4.0719	1.3944
	Distracted	3.8394	1.3837
D	Normal	4.0174	1.4003
	Distracted	4.1573	1.3418
E	Normal	4.2173	1.3661
	Distracted	3.9537	1.2358
Ave.	Normal	4.1008	1.4021
	Distracted	3.9188	1.3380

操舵角速度

次に操舵角を微分した値である操舵角速度について調査を行った。操舵角を微分して角速度を求めた結果をそれぞれ図 4.8, 図 4.9 に示す。縦軸は操舵角速度を、横軸は経過時間を示す。

通常運転時に比べ、ながら運転時にはひげ状のピークがより多く、大きくあらわれている。また、0.002rad/s 以下の領域でも細かい波形が多数あらわれた。0.002rad/s を閾値としてこれより大きな角速度が発生した件数をカウントし、ドライブごとに比較した結果を図 4.10 に示す。縦軸は、走行 1 分間当たりのカウント数を表す。全ての被験者において、ながら運転時には瞬間的な角速度の変化があらわれる回数が増えていることが分かる。閾値を 0.002rad/s 以下にすると、その差はより顕著にあらわれるようになる。

これには、車線を逸脱しそうになった後に車線中央に戻そうとする修正操舵があらわ

れており、修正操舵の操作において、ながら運転時の方の操作が粗く雑になってしまっているということが考えられた。




図 4.8 操舵角速度の時間変化（通常運転時）




図 4.9 操舵角速度の時間変化（ながら運転時）




図 4.10 大きな角速度の発生頻度比較

4.2.4 特徴量検討

前項の結果より，操舵操作時の粗さとみられる角速度の増大が明らかになった．そこで，操舵操作の滑らかさを表すステアリングエントロピーについて検討する．伊藤らはステアリングエントロピーという操舵の滑らかさを評価する指標について提案している [86]．

ステアリングエントロピー値 (H_p) の算出方法を述べる．まず，被験者に無負荷の通常状態で走行してもらい，その間のステアリング舵角データを収集する．本研究ではサンプリング間隔を，使用するドライブレコーダのサンプリング間隔に合わせ 100ms とした．ある時刻 n における過去 3 点 ($n-3$, $n-2$, $n-1$) の舵角値を用いて， $n-1$ 時点を中心とする 2 次テイラー展開により時刻 n の舵角予測値 $\theta_p(n)$ を算出する．時刻 n で舵角予測値 $\theta_p(n)$ と実際の舵角値 $\theta(n)$ との差 $e(n)$ を

$$e(n) = \theta(n) - \theta_p(n) \quad (4.1)$$

とする．ただし，

$$\begin{aligned} \theta_p(n) = & \theta(n-1) + (\theta(n-1) - \theta(n-2)) \\ & + \frac{1}{2}((\theta(n-1) - \theta(n-2)) - (\theta(n-2) - \theta(n-3))) \end{aligned} \quad (4.2)$$

として求める．図 4.11 に概念図を示す．図中，縦軸は操舵角，横軸は 100ms 周期の時系列を示す．ここで， θ は実際の計測値であり， θ_p は， θ より過去の 3 点からの予測値である． $e(n)$ は予測値と計測値の誤差を表す．

図 4.12 は， $e(n)$ の度数分布を示したものであり，横軸は $e(n)$ の数値，縦軸は度数である．横軸中の α はこの分布における 90 パーセンタイルの値とする．この分布は運転特性の滑らかさを表し，滑らかな操舵操作ほど分布の尖度は高くなり， α も小さくなる．粗い運転ほどその逆となる． α は各個人によって異なり，無負荷状態で得られた α は，各個人の運転特性の基準を示す値となる．そして， α を基準として図 4.12 のように度数分布を P1~P9 の領域に分け，各領域に含まれる割合より，式 4.3 から H_p を得る．

$$p = - \sum_{i=1}^9 P_i \log_9 P_i \quad (4.3)$$




図 4.11 予測誤差とサンプリング周期




図 4.12 $e(n)$ の度数分布

通常、タスクを与えた負荷状態では操舵操作は滑らかさを欠き、図 4.12 の度数分布は尖度が小さくなり、 H_p は増大する。300 秒の窓枠ごとに H_p 値を算出した結果を、一人の被験者の一回の走行実験を例に図 4.13 と図 4.14 に示す。図 4.13 より、通常運転時はおおむね 0.6 よりも小さい値を示し、図 4.14 のながら運転時は 0.6 よりも高い値を示していることが分かる。それぞれのヒストグラムによる比較を図 4.15 に示す。横軸は H_p であり、縦軸は度数を表している。この結果からも、上段の通常運転と下段のながら運転で H_p 値の分布の変化があらわれることが確認できた。




図 4.13 ステアリングエントロピーの時間変化（通常運転時）




図 4.14 ステアリングエントロピーの時間変化（ながら運転時）




図 4.15 ステアリングエントロピーのヒストグラムによる比較

被験者ごとの全走行の H_p 平均値と、通常運転時・ながら運転時の平均値の差を表 4.2 に示す。両者の差の大きさについては個人差があり、これらの結果を分類の閾値に利用するには工夫が必要と示唆される。どの被験者においてもながら運転時のほうが通常運転時と比べ、 H_p 値は高くなっていることが確認できた。

以上の結果をまとめると、操舵操作の周期的な観点と、粗さに関する視点から評価した結果、修正操舵の周期は、通常運転とながら運転間は被験者 4 名で 5.7%~7.7% の変化率、1 名は -3.5% と逆の傾向となった。一方、粗さを示すステアリングエントロピーは、5 名とも 13.6%~159% と正の変化を示し、周期の変化よりも大きな差となることが確認できた。これらの結果から、ながら運転のリアルタイム検出に用いる特徴量を、ステアリングエントロピーを中心に検討する。

表 4.2 被験者ごとのステアリングエントロピーの平均値比較

Sub.	Normal	Distracted	Difference
A	0.3880	0.6917	0.3037
B	0.6130	0.8591	0.2461
C	0.7078	0.8039	0.0961
D	0.4906	0.5800	0.0894
E	0.2990	0.7743	0.4753

4.3 実車データによるながら運転検出手法の提案

本節では、実車のドライブレコーダより取得したデータより、ながら運転を検出する手法を説明する。

4.3.1 実車データからの操舵角算出

ドライブレコーダは、車両に後付けで取り付けられる機器のため、DS と異なり車両挙動や車両操作情報のうち、車両からの信号を受けられる情報や車載器単独で計測可能な情報のみが記録できる。例えば大型トラックなどの商用車の場合、車速情報はタコグラフ用に車両より出力されており、簡単に収集可能であるが、ステアリング操作情報などを車両より出力する機能はない。前節で検討したステアリングエントロピーは、操舵角度の情報が必要であるが、実際の車両で利用するのは難しい。このため、操舵角度を別の情報からのモデルに置き換える必要がある。

実際の車両では、ステアリング操作の結果で現れる現象は、車両ヨー角の変化や、レーン線との位置関係の変化である。路面のレーン線との位置関係については、前章で述べたように前方映像の画像認識により算出可能である。しかし、レーン線挙動はカーブなどに左右されやすく、例えば蛇行している道路ではステアリングをまっすぐ保持していても車両とレーン線の位置関係は変動してしまうため、あまり適切ではない。

車両のヨー角より操舵角を算出する。

車両のヨー角は、ドライブレコーダなどの車載器にヨーレートセンサが搭載されている場合は簡単に収集可能である。しかし、搭載されている機種はごく一部であり、一般的には加速度センサを搭載している機種がほとんどである。そこで、車両横方向の加速度と車速からヨー角と操舵角を以下のモデル式によって算出する。

まず、図 4.17 に示すような仮想車両の簡易モデルにおいて転舵角 ϕ は操舵角 θ に対し、

$$\phi = k\theta \quad (4.4)$$

とする。ただし、 k は定数を表す。また、車両のホイールベース L および回転半径 R から、

$$\tan\phi = \frac{L}{R} \quad (4.5)$$

とする。ここで回転半径 R および角速度 ω から車速 v を

$$v = R\omega \quad (4.6)$$

とし、横方向加速度 a を

$$a = R\omega^2 \quad (4.7)$$

とすると、式 4.4～式 4.7 より、

$$\theta = \frac{1}{k} \arctan \frac{La}{v^2} \quad (4.8)$$

としてドライブレコーダの加速度データから操舵角 θ を推定する。ただし、ドライブレコーダによって取得される横方向加速度にはエンジンによる振動や道路の凹凸による振動成分が含まれるため、算出された操舵角に対し、バンドパスフィルタを適用した。ドライブレコーダで収集される加速度は 10Hz であることや、映像データより 1 秒以内に細かくハンドルを振動させるような操作は見られないことからバンドパスフィルタの周波数範囲は 0.1Hz～1.2Hz とした。バンドパスフィルタを適用した結果を図 4.16 に示す。縦軸は操舵角、横軸は時間を示す。細かな振動成分が除去できることが確認された。

検証実験として、DS で収集したデータを用いて、横方向加速度から操舵角を算出した結果と、直接収集した操舵角を比較検証した。結果を図 4.18 に示す。縦軸は操舵角、横軸は時間軸であり、赤線は DS から直接出力された操舵角、青線は出力された車速と横方向加速度から推定した操舵角である。図からは、2 つのデータはほぼ一致することが分かり、2 つのデータの相関係数を求めたところ 0.945 を示したことから、本手法は十分妥当性があることとした。




図 4.16 バンドパスフィルタ適用前後の比較




図 4.17 操舵角と横方向加速度の関係




図 4.18 DS 実験による操舵角と加速度からの推定操舵角の比較

4.3.2 修正操舵に基づく特徴量抽出

横方向加速度から算出された操舵角のデータがある窓枠で取得し、取得されたデータから特徴量抽出を行って、ながら運転の検出を行う。

本研究では窓枠 W は 30 秒, 60 秒, 90 秒の 3 つとし、特徴量の抽出は 10 秒おきに行うこととした。前節で示したようになりながら運転によって修正操舵に雑さが現れるため、時刻 t から $t+W$ までの操舵角の分散 $\sigma(t, W)$ 、および操舵角速度の絶対値の平均 $m(t, W)$ を特徴量として取得する。また、操舵の滑らかさに影響が現れるということからステアリングエントロピー値 $H_p(t, W)$ を特徴量として抽出する。そして、 H_p を算出する際に使用する予測操舵角と実操舵角の誤差を示す $e(n)$ は、突然大きく操舵を切った際に大きな値

が出るような値となっている。つまり $e(n)$ の値が大きくなる頻度、回数が増えれば増えるほど角速度が突然大きくなっているということが分かるため、特徴量として有効であると考えられる。そこで $e(n)$ の度数分布のパーセンタイル値 P 、および $e(n)$ の絶対値があらかじめ定義しておいた α を超える回数 C を取得し、これらも特徴量として使用した。提案した特徴量を以下にまとめる。

- Feature1 ステアリングエントロピー
- Feature2 パーセンタイル値
- Feature3 $e(n)$ が閾値を超える回数
- Feature4 操舵角の分散
- Feature5 操舵角速度の絶対値の平均

上記5種類の特徴量を窓枠3つで取得し、合計15特徴量を用いてながら運転検出を検出する。

4.3.3 アンサンブル学習によるながら運転検出

DS でながら運転と通常運転の修正操舵について比較した際、 H_p 値などは被験者によって値は大きく異なっており、個人差が大きく現れているということが考えられた。そのため、単純な閾値などでは分類できない可能性がある。そこで、学習データの情報を全て使うのではなく、一部を使用して学習し最後に結合させる手法であるアンサンブル学習の一種であるバギング木を使用することで、ながら運転の推定を行う。

図4.19に、バギング木の概念図を示す。学習データの中から、 m 開分割抽出し、新しいデータセットを作成する。分割されたデータセットをもとに弱学習機を構築し、図のようにそれぞれの弱学習機から結果を算出し、それを集約して判定を行う。

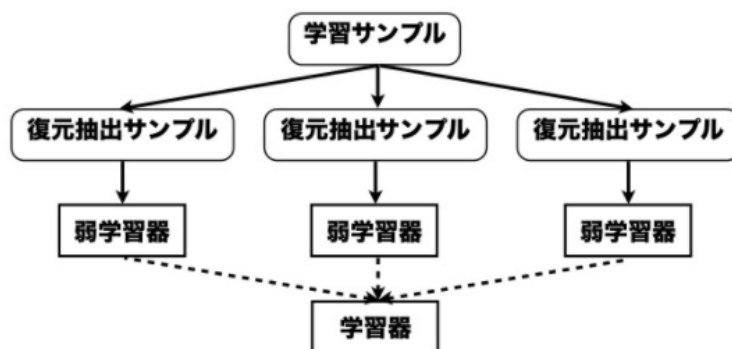


図 4.19 バギング木によるアンサンブル学習の概念図

引用：<https://www.slideshare.net/holidayworking/ss-11948523>

前述の特徴量と、映像から判定しながら運転の正解値を入力とした。バギング木での学習において、決定分岐の最大数は 2090、学習のサイクル数は 30 で実施している。検証は、5 分割した k -分割交差検証で実施した。

4.4 検証実験

4.4.1 DS を使用した実験

まず、前節で述べた DS のデータを使用して、学習、評価を行った。ながら運転、通常運転のそれぞれ 30 分×5 人の合計で 5 時間分のデータを計測した。ここでは、実車のドライブレコーダのサンプリング間隔に合わせて、10Hz にダウンサンプリングして検証した。

4.4.2 実車データを使用した実証

データ収集に使用した車両や機器は、第 3 章のものと同様であり、本実験で使用したデータは、研究に協力していただいた運送会社で日常業務に使用している機器により過去収集された記録を提供いただいたものである。

収集されるデータも、第 3 章と同じく速度、エンジン回転数、GPS 位置情報、搭載された 3 軸加速度センサによる加速度（車両に対して前後・左右・上下方向の 3 軸）などが 10Hz で記録される。

車速 v と左右方向の加速度値 a より、式 4.4~4.8 に従って推定操舵角を算出し、さらに式 4.1~式 4.3 に従ってステアリングエントロピー値を算出して分析を行った。式 4.8 における車両のデータは、ホイールベース L は 7m、 k はタイヤの切れ角と操舵角の関係を表すだけであり、学習推論性能に影響しないため、1 と仮定した。ドライブレコーダでは、前方映像と共にドライバの顔映像を記録しており、顔映像よりながら運転をしているデータを抽出し、ラベル付けを行った。また、ながら運転および通常運転のそれぞれの合計時間は、DS 実験と同様になるように抽出した。ただし、眠気が高まっているデータが通常運転のデータの中に含まれていることで精度が低下することが考えられるため、北島らの提案する眠気レベル[9]に従って評定し、危険な状態とされる[10]眠気レベル 3 以上の区間をあらかじめ除去している。なお、DS での実験の際には、眠気の発生はなかったと確認したため、同様のスクリーニングは実施していない。

算出したステアリングエントロピーより、4.4.2 節で提案した特徴量を求めた。得られた特徴量より、アンサンブル学習によるモデルの作成とながら運転の推定を行い、結果は交差検証により評価した。

4.4.3 検証方法

評価指標

3 章での検証にも用いた適合率・再現率・正解率・F 値を本実験にも適用する。以下、本実験における指標の定義である。

図 4.20 に混同行列を示す。

		予測値	
		ながら運転	通常運転
真値	ながら運転	TP	FN
	通常運転	FP	TN

図 4.20 混同行列

- ・適合率

ながら運転と判断されたデータの中に、実際に正解のながら運転が含まれる割合を示す指標である。

- ・再現率

実際のながら運転の全体データに対し、ながら運転と判定できた割合を示す指標である。

- ・正解率

正解値と判定結果がどのくらい一致しているかを示す指標である。

- ・F 値

適合率と再現率の調和平均を表す指標。

4.5 結果・考察

k-分割交差検証の結果を，表 4.3 と表 4.4 に示す．

DS での結果， Precision = 0.811, Recall = 0.807, Accuracy = 0.810, F-measure = 0.809 となった．ながら運転，通常運転をそれぞれ約 80%以上の精度で検出できており，DS でのながら運転検出に提案手法が有効であるといえる．

実車データでは， Precision = 0.767, Recall = 0.749, Accuracy = 0.761, F-measure = 0.758 となった．DS の結果と比較して精度がやや低下してしまっているもののそれぞれ約 75%以上の精度で抽出できているということを確認し，実車データにおいても提案手法の有効性が示された．同じくながら運転検出を目的とした先行研究では，静止した車両において ToF カメラ映像から姿勢検出をする手法にて識別率は 0.82 であったと報告されている [106]．このような直接ドライバの行動を検出する手法に比べると精度は劣るものの，走行状態で間接的に検知する可能性が示された．

表 4.3 DS データによる推定結果

Correct \ Estimated	Normal	Distracted
	Normal	81.3% (TN)
Distracted	19.3% (FN)	80.7% (TP)

表 4.4 実車データによる推定結果

Correct \ Estimated	Normal	Distracted
	Normal	77.2% (TN)
Distracted	25.1% (FN)	74.9% (TP)

分類できなかった原因を調査するため特徴量分布について通常運転とながら運転と比較した．それぞれ抽出された特徴量の分布の例を図 4.21 と図 4.22 に示す．図中に示された特徴量は横軸が H_p 値を示しており，縦軸が操舵角速度の絶対値の平均を示している．また，青色で示されている点が通常運転時のデータとなっており，橙色で示されているデータがながら運転時のデータとなっている．図 4.21 の DS 実験での分布より，通常運転時はステアリングエントロピーによらず，比較的一定の速度で操舵操作をしていることが分かる．しかし，ながら運転時では特に操舵速度が大きくなる方向に変化する傾向があることが分かった．ながら運転と通常運転で重なってしまっている箇所が多く

見られた。この重なり部分が精度を下げる原因になっていると考えられる。

このような分布はどの特徴量の組み合わせにおいても程度の差はあるが同様に見られた。これはスマートフォンを手を持っていても前方を確認して運転ができている区間や、逆に通常の運転でもその他の要因によって安定した操舵が行われなかったということが考えられる。また、操舵の方向は、車線から外れる方向と戻る方向を同等に扱っているが、車線中央に戻す操作のみに限定することで、分離性能が向上できる可能性がある。

図 4.22 の実車データにおいては、特徴量の重なっている範囲が DS データに比べ広くなっており、より分類が困難になっていることが考えられた。特に、青で示す通常運転時の分布が広がっている。このようになってしまう原因として、操舵角算出時に道路の凹凸による振動が全て取り除けず正しい操舵が算出されていない可能性があること、また、実車では DS 実験と比べて、衝突の危険という緊張感が常にあるため、操舵の操作がながら運転時においても比較的丁寧になっている可能性がある。一方 DS では体感できる旋回加速度が存在しないために大きく操舵しているという実感が湧きにくく、レーンをはみ出さないというタスクが優先されるために大きくハンドルを動かし、結果として修正操舵が強くあらわれ、推定に有利に働いていると考えられる。その他、実車と DS の相違点として、下記が挙げられる。

・車両モデルのインターフェース部の違い：

目線、ハンドルの径、ハンドル軸の取付角度、ドライビングポジションなど

・車両モデルのスペックの違い：

車両重量、サスペンション設定など

・走行感覚の違い：

速度感覚、風景や構造物の立体感、映像以外のフィードバックなど

・操作感覚の違い：

操舵角あたりの転舵角、ハンドルやペダルの重さや遊び、操作に対する反応速度

・走行環境の違い：

路面の凹凸、わだち、横風、勾配、周辺車両など

ここで、映像以外のフィードバックとは走行加速度、ヨーピッチロー、ハンドルの抵抗感、エンジン音、風切り音、ロードノイズ、振動などを指す。走行音やハンドルへのフォースフィードバック、6 軸モーション機構などにより実車の走行感覚に近い DS も存在するが、すべての感覚を実車に近づけるのは難しい。これらの中で、結果に比較的影響する因子として、上述の旋回加速度に加え、立体感の欠如に起因するレーン逸脱量の認識遅れにより、より操舵操作が急になることが考えられる。

その他、今回採用した横方向加速度に影響する外乱因子としては、レーンチェンジア、横風の影響、道路横断面の傾斜などがあげられるが、道路横断面傾斜により発生する横方向加速度は、操舵操作に比べて長周期で変化するためほとんど結果に影響しないと考えられる。しかし、レーンチェンジ時の操作は急な加速度変化が発生する。本研究で協

力していただいた運送会社では、高速道路での制限速度の 80km/h を遵守しているために追い越しのためのレーンチェンジの発生頻度は低く、除去対象にはしていない。しかし、精度向上のためには、ウインカ操作信号の利用などでレーンチェンジの発生を検知して推定に反映させる仕組みの必要性も考慮する必要がある。




図 4.21 特徴量の分布例 (DS データ使用時)




図 4.22 特徴量の分布例 (実車データ使用時)

追加の検証により、Feature1 と Feature2 は、時系列で似た挙動を示すことがあることが分かった。Feature3,4,5 についても同様な傾向を示す。Feature1 および 2 では、推定への寄与度は同等レベルであり、Feature3,4,5 でも同じことがいえる。つまり、使用する特徴量を削減できることが示唆される。しかし、Feature1,2 と Feature3,4,5 の比較では、走行データによって正解値との相関や推定への寄与度が変わるため、どちらが特徴量として有意かは今回のデータでは判別ができなかった。

通常の運転時には、前方から目線を外す要因として、進行方向周辺の車両交通状況の把握、道路標識などの確認、バックミラーなど周囲の安全確認行為、メーター類の確認行為などがあげられるが、いずれもごく短時間であり、走行に必要な行為でもあることから、ながら運転の対象外として特に除去はしていない。今後、精度向上のために上記例を含む目線を外す行為も研究対象として検討が必要となる可能性もある。

4.6 まとめ

本章ではドライブレコーダのデータのみから、ながら運転の検出を目的としており、ながら運転時の修正操舵の挙動について調査した上で、操舵の角速度、滑らかさに着目した特徴量からながら運転を検出する手法について提案した。DS および実車から取得されたそれぞれのデータに対して検証実験を行ったところ、高い精度で検出可能であるということを確認し、本提案手法の有効性が示された。今後の課題として、実車データにおける更なる精度向上が挙げられる。

第5章 結論

本研究では予防安全技術において必要なドライバ状態の把握のため、様々な車両に取り付け可能なドライブレコーダに着目し、ドライブレコーダで取得可能なデータより、眠気状態やながら運転等のドライバ状態をリアルタイムに推定する方法を提案することを目的とした。

主に大型商用車を対象とし、トラック運送会社から提供いただいた実際の運行データを基に解析・実験を行った。基礎データの収集や比較検証のため、一部 DS での実験も実施している。居眠り運転やながら運転は、事業用自動車の事故原因分析からも最も割合の高い漫然運転と脇見運転に分類されており、重要度は高い。

居眠り運転検出に必要な眠気レベルの推定では、レーン線検知結果が眠気レベルの上昇と共に変化することを、実車環境下で特有な運転挙動として抽出できた。さらにレーン線位置データに特有なノイズ成分を効果的に除去する方法を確立して機械学習に適用させるための前処理方法を検討した。時系列情報を考慮した特徴量設計および推定モデ

ルを構築し、評価を行った結果、有効性が確認でき、比較モデルや従来手法よりも精度が高い結果が得られた。また、従来モデルで問題となっていた個人外推定での推定値の発散現象も解消できた。

ながら運転の検知については、スマートフォン操作を対象として調査した。ながら運転は操舵操作の滑らかさに影響することが明らかとなり、ステアリングエントロピーという指標から学習推定に使用する特徴量を設計、評価を行った。実車データでは、車両に加わる横方向の加速度（旋回 G）を操舵角に変換し、同様の評価を行うことで有効性を確認している。

本研究で対象とした眠気とながら運転は、別々に評価をしており、同時発生した場合にどのような結果なるかは評価していない。車載器の機能として開発を進めていく上で状態を分離できるかどうかは考慮する必要がある。分離できない場合でも運転に適さない状況にあると判断させる、など、今後の課題となる部分である。

推定結果をどのように利用するかも、開発では重要になる。たとえドライバの異常を検知できたとしても、それをそのままドライバに通知する、またはドライバ評価システムでの評点に加えるなどの方法が考えられる。例えば、ながら運転の場合はドライバ自身がその行動を承知しているため、通知してもあまり意味はなく、システム全体でドライバ評価に繋げることが良いと考えられる。その結果、抑止効果にもなる。このためには、推定結果の評価指標のうち、再現率よりも適合率が重要である。今後の課題として精度向上を目指す際には、適合率の向上を進めていく必要がある。

今回使用した実際の車両のデータでの研究は貴重であり、意義のあるものとする。特に大型の実車データには振動などの外乱因子が多数存在するため、本実験で一部対応した外乱因子への対処方法は、将来的に高度な運転支援や自動運転の技術へも応用できる可能性がある。

また、本研究のように元来のドライブレコーダの機能同士や画像認識結果データを組み合わせることで、直接計測できない現象や新たな評価指標など、より多彩な安全運転支援機能が他にも実現できると期待でき、今後の研究課題としたい。

研究倫理


本研究は、愛知県立大学の研究倫理委員会による許可を受けて実施した。

[様式6-1]

許 可 通 知 書

27愛県大学情第6-17号
平成27年 10月5日

申請者
小栗 宏次 殿

愛知県立大学
研究倫理審査委員会委員長
高島 忠義 

下記の研究計画に関する研究倫理審査申請については許可とします。

記

受付番号 情27-04

研究課題名 ドライバ眠気レベル推定アルゴリズムの構築と評価

利益相反

本研究は愛知県立大学の利益相反マネジメント委員会審査結果による許可を受けて実施した。

様式3

利益相反マネジメント委員会審査結果通知書

27 愛県大学情第13-15号
平成27年 10月5日

小栗 宏次 様

愛知県立大学学長
高 島 忠 義



平成27年9月24日付で申告のあった事項についての審査結果を通知します。

申告者	所属 愛知県立大学情報科学部情報科学科 職名 教授 氏名 小栗 宏次
区分	■研究活動：課題名 ドライバ眠気レベル推定アルゴリズムの構築と評価
	□職務及び兼業活動
審査年月日	平成 27年 9月24日
審査結果	<input checked="" type="checkbox"/> 勧告事項なし <input type="checkbox"/> 勧告事項あり
意見留意事項	なし。
その他	

謝辞

本研究を進めるにあたり御指導を頂き、また研究以外においても多大な御支援を賜った小栗宏次教授に心から御礼を申し上げます。本研究に関する的確な助言と御支援を頂いた河中治樹准教授に厚く御礼申し上げます。国際学会での発表論文や国内論文について多大なご助言もいただきました。

また、本論文の審査にあたり、貴重なご意見やご助言を頂きました戸田尚宏教授、神山齊己教授に深く感謝致します。

本研究のデータ分析、アルゴリズム構築に多大なご協力を頂いた金子祐来氏、本井みくに氏、榊原大貴氏、グレンメリクシャー氏、および小栗研究室、河中研究室のメンバーにも心から感謝致します。

博士課程進学のお機会を与えて頂いた矢崎エナジーシステム株式会社 矢崎航社長、加藤忠様、村松義夫様、佐野茂樹様、山口光章様に深く感謝致します。さらに、忙しい時間を割き、多くの議論や実験協力をしていただきましたモビリティデバイス開発統括部の小林裕一様、鈴木佑季様、南良樹様に深く感謝致します。

そして、貴重な走行データの回収提供に快くご協力頂いた運送会社のドライバ様及び管理者様に感謝致します。

関係した皆様のおかげで博士論文を完成させるに至りました。ここに謹んでお礼申し上げます。

参考文献

- [1] 政府統計, “交通事故の発生状況 (2020 年),” 2020.
- [2] 警察庁交通局, “令和 2 年度中の交通事故の発生状況,” 2021.
- [3] 内閣府, “第 10 次交通安全基本計画,” 2016.
- [4] 国土交通省 事業用自動車に係る総合的安全対策検討委員会, “事業用自動車総合安全プラン 2020,” 2017.
- [5] 国土交通省自動車局, “自動車運送事業に係る交通事故対策検討会報告書 (令和 2 年度) [第 1 分冊]事業用自動車の交通事故統計 (令和元年度版),” 2021.
- [6] 警察庁, “やめよう! 運転中のスマートフォン・携帯電話等使用”.
- [7] 全日本トラック協会, “啓発ポスター,” 2019.
- [8] 一般社団法人自動車検査登録情報協会, “わが国の自動車保有動向,” 2021.
- [9] 福井勝彦, “連続運転時における操舵機能低下の評価法について,” 自動車技術, 1994.
- [10] J.Eggert and F.Damerow, "Complex Lane Change Behavior in the Foresighted Driver Model," 2015 IEEE 18th International Conference on Intelligent Transportation Systems, 2015.
- [11] B.Higgs and M.Abbas, "Identification and Classification of State-Action Clusters of Car Following Behavior," 2014 IEEE 17th International Conference on Intelligent Transportation Systems, 2014.
- [12] 伊藤潤, 河中治樹, 小栗宏次, “地図情報を考慮したドライバの眠気レベル推定,” 電子情報通信学会技術研究報告, 2013.
- [13] 岡山舜, 森田和元, 関根道昭, “カーブ走行時の情報機器操作がドライバの運転挙動に与える影響,” 自動車技術会論文集, 2016.
- [14] 大北由紀子, 菅沢深, 毛利宏, “ドライブレコーダのデータから解析した脇見運転の特徴,” 日本機械学会論文集, 2017.
- [15] 安部原也, 伊藤誠, 山村智弘, “追従運転時における車間時間の違いによる脇見時間への影響と追突警報の効果,” 計測自動制御学会論文集, 2012.
- [16] 江部和俊, 大桑政幸, 稲垣大, 土居俊一, “カーナビゲーションの負荷度評価,” 国際交通安全学会誌, 2001.
- [17] S. Kwon, S. Park, L. J. Hee, Y. M. Hwan, “2c2-1 comparisons of driver distraction from in-vehicle device use: rotary controllers and touch screens,” 人間工学, 2015.

- [18] 大須賀美恵子, 鎌倉快之, 井上裕美子, 野口祥宏, 嶋田敬士, 三代真己, “多次元生理指標を用いたドライバの覚醒状態推定(2),” 自動車技術会学術講演前刷集, 2011.
- [19] 大須賀美恵子, 鎌倉快之, 井上裕美子, 野口祥宏, Roongroj Nopsuwanchai, “ドライバの覚醒状態推定(1)-顔表情評定と生理指標-,” 自動車技術会, 2008.
- [20] 野口祥宏, Roongroj Nopsuwanchai, 大須賀美恵子, 鎌倉快之, 井上裕美子, “ドライバの覚醒状態推定(2)-眼瞼映像-,” 自動車技術会, 2008.
- [21] 大須賀美恵子, 鎌倉快之, 井上裕美子, 野口祥宏, 三代真己, “ドライバの覚醒状態推定(3)-多次元生理指標変化パターンの検討-,” 自動車技術会学術講演会前刷集, 2009.
- [22] 嶋田敬士, 野口祥宏, 三代真己, 大須賀美恵子, 鎌倉快之, 井上裕美子, “ドライバの覚醒状態推定(4)-眼瞼映像からの開口度検出-,” 自動車技術会学術講演会前刷集, 2009.
- [23] 大須賀美恵子, 鎌倉快之, 井上裕美子, 野口祥宏, 三代真己, “多次元生理指標を用いたドライバの覚醒状態推定,” 自動車技術会学術講演会前刷集, 2010.
- [24] 宮下和範, “自動車運転時のドライバの疲労特性に関する研究,” 日本人間工学会関東支部第42回大会講演集, 2012.
- [25] Ruben-Dario Pinzon-Morales, Yutaka Hirata, “Customization of Wavelet Function for Pupil Fluctuation Analysis to Evaluate Levels of Sleepiness,” Journal of Communication and Computer, 2013.
- [26] 柳平雅俊, 安土光男, “運転状態推定技術の開発-心拍解析による眠気状態の検出-,” PIONEER R&D, 2004.
- [27] 佐野聡, 富森英樹, 増田裕太, 小田切淳一, 加藤秀雄, 中野泰彦, “脈拍センサを用いた眠気警報システムの開発,” マルチメディア, 分散, 協調とモバイルシンポジウム, 2014.
- [28] Jurgen Schmidt, Christian Braunagel, Wolfgang Stolzmann, Katja Karrer-Gaub, “Driver Drowsiness and Behavior Detection in Prolonged Conditionally Automated Drives,” 2016 IEEE Intelligent Vehicles Symposium(IV), Gothenburg, Sweden, 2016.
- [29] 横山清子, 高橋一誠, “心拍変動時系列による自動車運転時の主観的疲労感推定の基礎的検討,” 電子情報通信学会論文誌 A, 2013.
- [30] 沼田仲穂, 北島洋樹, 五井美博, 山本恵一, “自動車運転時の眠気の子測手法についての研究(第2報, 眠気変動の子測と居眠り警報タイミングの決定),” 日本機械学会論文集(C編), 1997.
- [31] 金子成彦, 藤田悦則, “ドライバーの覚醒低下警告・防止に向けた技術開発,”

- IATSS Review, 2013.
- [32] Akihiro Imai , Koji Oguri, “Estimaion of Driver's Drowsiness Level Considering a Characteristic Sleepiness Transition of Drowsy Driving,” Proceedings of 20th ITS World Congress(ITSWC2013), 2013.
 - [33] Chin-Teng Lin, Ruei-Cheng Wu, Sheng-Fu Liang, Wen-Hung Chao, Yu-jie Chen , Tzyy-Ping Jung, “EEG-Based Drowsiness Estimation for State Driving Using Independent Component Analysis,” IEEE Transactions on Circuits and Systems, 2005.
 - [34] 宮崎陽平, 池田和章, 中島康祐, 伊藤雄一, 尾上孝雄, “SenseChair を用いた眠気検出に関する検討,” 情報処理学会インタラクシオン 2014, 2014.
 - [35] 一般社団法人ドライブレコーダー協議会, “ドライブレコーダー出荷統計”.
 - [36] 国土交通省自動車局, “運行管理の高度化に対する支援 デジタコ一体型ドライブレコーダー（国土交通大臣が認定した機器一覧）”.
 - [37] 首相官邸, “官民 ITS 構想・ロードマップ 2020,” 2020.
 - [38] 国土交通省, “ITS 全体構想”.
 - [39] 首相官邸, “トラック隊列走行の商業化実現に係る官民検討会中間とりまとめ,” 2019.
 - [40] 内閣府, “令和元年度版交通安全白書”.
 - [41] 国土交通省 事業用自動車に係る総合的安全対策検討委員会, “事業用自動車総合安全プラン 2020～最近の交通事故発生状況等～,” 2021.
 - [42] 矢崎エナジーシステム（株）, “10分でわかるアナログタコグラフ”.
 - [43] 省令, 貨物自動車運送事業輸送安全規則 第9条.
 - [44] 省令, 旅客自動車運送事業等運輸規則 第26条の1・第26条の2.
 - [45] 矢崎エナジーシステム（株）, “10分でわかるデジタルタコグラフ”.
 - [46] 国土交通省, “映像記録型ドライブレコーダーの概要,” [オンライン]. Available: <https://www.mlit.go.jp/jidosha/anzen/03driverrec/dorareco.html>. [アクセス日: 10 2021].
 - [47] 公益社団法人全日本トラック協会, “ドライブレコーダの導入効果に関する調査報告書,” 2014.
 - [48] 国土交通省, “ドライブレコーダーの映像を活用した指導・監督マニュアル,” 2017.
 - [49] 堀野定雄, “過労運転事故の要因分析と再発防止,” 国際交通安全学会誌, 2013.
 - [50] 林光緒, “睡眠と事故,” Clinical Neuroscience, 2004.

- [51] E. Hoddes, V. Zarcone, H. Smythe, R. Phillips, W. C. Dement, "Quantification of Sleepiness: A New Approach," *Psychophysiology*, 1973.
- [52] 窪田智英, 城憲秀, 武山英磨, 榎原毅, 井上辰樹, 高西敏正, 荒薦優子, 村崎元五, 井谷徹, "「自覚症しらべ」による連続夜勤時の疲労感の表出パターンの検討," *産業衛生学雑誌*, 2008.
- [53] T. H. Monk, "A visual analogue scale technique to measure global vigor and affect," *Psychiatry Research*, 1989.
- [54] M.W.Johns, "A New Method for Measuring Daytime Sleepiness : The Epworth Sleepiness Scale," *Sleep*, 1991.
- [55] 松田和徳, 堀洋二, 零治彦, 武田憲昭, "自覚的眠気評価法 Epworth SleepinessScale(ESS) の有用性-睡眠時無呼吸症候群のスクリーニング-, " *耳鼻臨床*, 2005.
- [56] 高橋誠, 北島洋樹, 本城由美子, "精神的作業負担チェックリストの作成とそれによる眠気とリラックス状態の関係構造の検討," *労働科学*, 1996.
- [57] M.A.Carskadon, W.C.Dement, M.M.Mitler, T.Roth, P.Westbrook, S.Keenan, "Guidelines for the Multiple Sleep Latency Test(MSLT) : A Stanford Measure of Sleepiness," *Association of Professional Sleep Societies*, 1986.
- [58] 日本睡眠学会, *睡眠学*, 朝倉書店, 2013.
- [59] 井上雄一, 林光緒, *眠気の科学-そのメカニズムと対応-*, 朝倉書店, 2012.
- [60] M.M.Mitler, K.S.Gujavarty, C.P.Browman, " MAINTENANCE OF WAKEFULNESS TEST : A POLYSOMNOGRAPHIC TECHNIQUE FOR EVALUATING TREATMENT EFFICACY IN PATIENTS WITH EXCESSIVE SOMNOLENCE," *Electroencephalogr Cin Neurophysiol*, 1982.
- [61] 本多和樹, *眠りの科学とその応用-睡眠のセンシング技術と良質な睡眠の確保に向けての研究開発-*, シーエムシー出版, 2011.
- [62] 北島洋樹, 沼田仲穂, 山本恵一, 五井美穂, "自動車運転時の眠気の子測手法についての研究 (第 1 報, 眠気表情の評定法と眠気変動の子測に有効な指標について)," *日本機械学会論文集(C 編)*, 1997.
- [63] E.Zilberg, Z.M.Xu, D.Burton, M.Karrar, S.Lal, "Methodology and initial analysis results for development of non-invasive and hybrid driver drowsiness detection systems," *The 2nd International Conference on Wireless Broadband and Ultra Wideband Communications*, 2007.
- [64] 大見拓寛, "画像センサによる眠気状態推定とドライバーステータスモニターの開発," *DENSO TECHNICAL REVIEW*, 2016.

- [65] E. Michail, A. Kokonozi, I. Chouvarda , N. Maglaveras, “EEG and HRV markers of sleepiness and loss of control during car driving,” 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2008.
- [66] G. Jahn, A. Oehme, J. F. Krems , C. Gelau, “Peripheral detection as a workload measure in driving: Effects of traffic complexity and route guidance system use in a driving study,” Transportation Research Part F: Traffic Psychology and Behaviour, 2005.
- [67] M. Akin, M. B. Kurt, N. Sezgin , M. Bayram, “Estimating vigilance level by using EEG and EMG signals,” Neural Computing and Applications, 2008.
- [68] S. Hu , G. Zheng, “Driver drowsiness detection with eyelid related parameters by Support Vector Machine,” Expert Systems with Applications, 2009.
- [69] JINS, “ JINS MEME, ” [オンライン]. Available: https://www.jins.com/jp/client_info/JINSJINS/infoimage/20211006_Press%20Release1.pdf. [アクセス日: 10 2021].
- [70] 金子成彦, “居眠り運転防止シート,” 日本機械学会誌, 2008.
- [71] 柳平雅俊, 安土光男, “眠気予測技術の開発,” PIONEER R&D, 2007.
- [72] 伊藤誠, 鈴木伊織, 稲垣敏之 , 吉村健志, “体圧センサ情報に基づくドライバーの副次行動検出,” 第 43 回交通科学協議会学術講演会, 2007.
- [73] 上田誠, 近藤光男, 松本博次, 早川晴雄 , 中田隆現, “追従走行実験における心理的・生理的反応に基づく運転疲労の定量化に関する研究,” 土木計画学研究・論文集, 2008.
- [74] nac, “Eye Mark Recorder,” [オンライン]. Available: <https://www.eyemark.jp/>. [アクセス日: 4 11 2021].
- [75] H.Ishiguro, T.Hayashi, T.Naito, J.Kasugai, K.Ogawa, K.Ohue , S.Uozumi, “Development of Facial-Direction Detection Sensor,” Proceedings of 13th ITS World Congress, 2006.
- [76] H.A. Rowley, S. Baluja , T. Kanade, “Neural Network-based Face Detection,” Proceedings IEEE Conf. on Computer Vision and Pattern Recognition, 1996.
- [77] C.Zhang , Z.Zhang, “A Survey of Recent Advances in Face Detection,” Microsoft Research Technical Report, 2010.
- [78] P. Viola , M. Jones, “Rapid Object Detection using a Boosted Cascade of Simple Features,” Proceedings IEEE Conf. on Computer Vision and Pattern Recognition, 2001.

- [79] R. Lienhart , J. Maydt, “An Extended Set of Haar-like Features for Rapid Object Detection,” Proceedings Int. Conf. on Image Processing, 2002.
- [80] A. Cauce, D. Cristinacce, C. Taylor , T. Cootes, “Locating Facial Features and Pose Estimation Using a 3D Shape Model,” Proceedings 5th Int. Symposium on Visual Computing, 2009.
- [81] H.Ueno, M.Kaneda , M.Tsukino, “ Development of Drowsiness Detection System,” Proceedings Vehicle Navigation and Information Systems Conference, 1994.
- [82] 大見拓寛, “運転者の居眠り状態評価画像センサ,” 人工臓器, 2013.
- [83] S. Hachisuka, T. Kimura, N. Ozaki, K. Ishida , H. Nakatani, “Drowsiness Detection Using Facial Expression Features,” DENSO Technical Review, 2010.
- [84] P. Ekman, W.V. Friesen , J.C. Hager, “Facial Action Coding System (FACS) The Manual on CD ROM,” A Human Face, 2002.
- [85] 福井勝彦, “連続運転時における操舵機能低下の評価方法,” 豊田中央研究所 R&D レビュー, 1995.
- [86] 伊藤敏行, 中山沖彦, アーウィンボアー, “車載情報機器に関する自工会安全性ガイドラインの策定とステアリングエントロピー法による運転者負荷評価,” 国際交通安全学会誌, IATSS Review, 2001.
- [87] 西郷慎太郎, ポンサトーン・ラクシンチャランサク , 永井正夫, “先行車追従時の規範ドライバモデルに基づく個別適合型運転状態診断システムの開発,” 自動車技術会論文集, 2011.
- [88] 今井章博 , 小栗宏次, “居眠り運転時の特徴的な眠気推移傾向を組み込んだ眠気レベル推定手法の提案,” 電子情報通信学会論文誌, D 編, 2013.
- [89] Yuki Kaneko, Haruki Kawanaka, Md.Shoaib Bhuiyan, Koji Oguri, Hiroyuki Oishi, Yuichi Kobayashi , Kanji Hashimoto, “Effects of Feedback in Estimating Driver's Drowsiness Level from Event Data Recorder,” Proceedings of 23rd ITS World Congress(ITSWC2016), 2016.
- [90] 金子祐来, 河中治樹, 小栗宏次, “ドライブレコーダからの眠気レベル推定における道路形状に依存しない推定アルゴリズム,” 映像情報メディア学会技術報, 2018.
- [91] 松尾治夫 , キアットアブデラジズ, “運転者の行動解析に基づく居眠り運転早期検出方法の開発,” 電子情報通信学会論文誌 D, 2015.
- [92] M. Ingre, T. Akerstedt, B. Peters, A. Anund , G. Kecklund, “Subjective sleepiness simulated driving performance and blink duration: Examining individual differences,” J. Sleep Res., 2006.

- [93] 小山哉, 荒川俊也, “ふらつき運転によるドライバ覚醒レベル推定警報システムの開発と脳波によるドライバ状態評価,” 自動車技術, 2004.
- [94] R. Simons, M. Martens, J. Ramaekers, A. Krul, I. Klöpping-Ketelaars, G. Skopp, “Effects of dexamphetamine with and without alcohol on simulated driving,” Psychopharmacology, 2012.
- [95] M.A.J. Mets, E. Kuipers, L.M. de Senerpont Domis, M. Leenders, B. Olivier, J.C. Verster, “Effects of alcohol on highway driving in the STISIM driving simulator,” Human Psychopharmacology: Clinical and Experimental, 2011.
- [96] Leo Breiman, “Random Forests,” Machine Learning, 2001.
- [97] André Altmann, Laura Toloşi, Oliver Sander, Thomas Lengauer, “Permutation importance: a corrected feature importance measure,” Bioinformatics, 2010.
- [98] Tijmen Tieleman, Geoffrey Hinton, “Lecture 6.5-rmsprop. COURSERA,” Neural networks for machine learning, 2012.
- [99] John Duchi, Elad Hazan, Yoram Singer, “Adaptive Subgradient Methods for Online Learning and Stochastic Optimization,” Journal of Machine Learning Research, 2011.
- [100] J. Cong, B. Xiao, “Minimizing computation in convolutional neural networks,” Artificial Neural Networks and Machine Learning-ICANN, 2014.
- [101] Sepp Hochreiter, Jürgen Schmidhuber, “Long short-term memory,” Neural computation, 1997.
- [102] 伊藤一也, 田中健次, “音声操作中の警報音聴取に対する注意配分改善手法の検討,” 人間工学, 2017.
- [103] 荒川俊也, “若年ドライバの高速道路走行時スマートフォン操作が及ぼす影響の検証,” 産業応用工学会論文誌, 2016.
- [104] 本井みくに, 河中治樹, 小栗宏次, “車線内走行位置ゆらぎとドライバの眠気レベルの関係分析,” 第17回ITSシンポジウム2019, 2019.
- [105] 田中克則, 景山一郎, “車両運動特性向上のためのタイヤ設計手法に関する研究(乗用車の直進性に対する評価指標とタイヤ特性について),” 日本機械学会論文集(C編), 2002.
- [106] 山賀瑛斗, 浅野直生, 杉浦裕太, 杉本麻樹, “Time-of-flight 測距センサアレイと機械学習を用いた運転手の姿勢識別,” 計測自動制御学会論文集, 2019.

研究業績

学術論文（査読付き）

大石啓之, 河中治樹, 小栗宏次, “実車両におけるドライバの眠気と車線内走行位置変化の関係に関する研究”, 電子情報通信学会論文誌 D, Vol. J105-D, No. 3, pp. 236-244, Mar. 2022.

Hiroyuki Oishi, Haruki Kawanaka, Koji Oguri, “A Model for Detecting Drowsiness Based on the Data Analysis of Drive Recorder”, International Journal of Intelligent Transportation Systems Research (IJIT), Vol. 20, pp. 192-203

大石啓之, 榊原大貴, 河中治樹, 小栗宏次, “修正操舵による車両のふらつきに基づきながら運転検出”, 電気学会論文誌 C, Vol. 142, No. 3, pp. 422-429

国際会議（査読付き）

Hiroyuki Oishi, Haruki Kawanaka, Koji Oguri, “Effectiveness of Data Screening for Driver Drowsiness Estimation Using Drive Recorder”, 2021 IEEE 10th Global Conference on Consumer Electronics (GCCE2021), 2021/10

国内学会発表

大石啓之, 河中治樹, 小栗宏次, “実車両のドライブレコーダーデータ分析による眠気検知手法の提案”, 第19回 ITS シンポジウム(2021)

特許

特許番号：特許第 6947556 号

発明の名称：車載機, 処理装置及びプログラム

特許出願公開番号：特開 2021-92962

発明の名称：車載機, 処理装置及びプログラム