

博 士 論 文

自動車運転行動の特徴量抽出とドライバ脳活動計測
による運転技量の評価

李 曙光

目次

| | |
|--|-----------|
| 第 1 章 序論 | 1 |
| 1.1 我が国における ITS の現状..... | 3 |
| 1.2 次世代の自動車..... | 5 |
| 1.2.1 ITS とビッグデータ | 8 |
| 1.2.2 脳の計測 | 9 |
| 1.3 従来の運転特性に関する研究..... | 12 |
| 1.3.1 運転特性 | 12 |
| 1.3.2 脳の計測と運転特性 | 14 |
| 1.3.3 ドライバモデル..... | 15 |
| 1.4 本研究の目的..... | 17 |
| 1.5 本論文の構成..... | 18 |
| 第 2 章 運転技量の評価 | 21 |
| 2.1 運転技量と合成ジャーク | 23 |
| 2.2 運転技量とドライバモデル..... | 24 |
| 2.3 脳科学における動作のメカニズム..... | 25 |
| 2.4 運転技量と脳活動に関する仮説..... | 27 |
| 第 3 章 ドライバの運転特徴抽出手法 および特徴抽出実験 | 29 |
| 3.1 運転特徴抽出コンセプト..... | 31 |
| 3.1.1 目的とコンセプト | 31 |
| 3.1.2 運転特徴量..... | 32 |
| 3.1.3 ウェーブレット変換 | 34 |
| 3.1.4 特徴抽出手法 | 36 |
| 3.1.5 AdaBoost による特徴差の抽出コンセプト | 37 |
| 3.2 ドライバの運転特徴抽出アルゴリズム構築..... | 37 |
| 3.2.1 特徴抽出のアルゴリズム | 37 |
| 3.2.2 ウェーブレットについての検討..... | 38 |
| 3.2.3 データの正規化..... | 45 |
| 3.2.4 候補特徴量..... | 46 |
| 3.2.5 AdaBoost を用いた特徴量抽出 | 47 |

| | | |
|--|--------------------------|------------|
| 3.3 | 多曲率カーブ特徴量抽出実験..... | 49 |
| 3.3.1 | 実験概要 | 49 |
| 3.3.2 | 実験条件 | 53 |
| 3.3.3 | 実験結果 | 54 |
| 3.3.4 | 実験結果の考察..... | 70 |
| 3.3.5 | 熟練と未熟練走行の判別モデル | 76 |
| 3.4 | アドバイス実験..... | 77 |
| 3.4.1 | 実験概要 | 77 |
| 3.4.2 | 評価指標 | 80 |
| 3.4.3 | 実験結果 | 81 |
| 3.5 | 本章のまとめ..... | 84 |
| 第4章 ドライビングシミュレータを用いた脳の計測の実験環境の構築..... | | 85 |
| 4.1 | 本章の背景と目的..... | 87 |
| 4.2 | 機能的近赤外分光法(fNIRS)の紹介..... | 88 |
| 4.3 | ドライビングシミュレータの紹介..... | 88 |
| 4.4 | DS を用いた脳の計測実験..... | 89 |
| 4.4.1 | 実験概要 | 89 |
| 4.4.2 | 実験条件 | 91 |
| 4.4.3 | 脳機能 NIRS 計測..... | 91 |
| 4.4.4 | 実験結果 | 93 |
| 4.5 | 考察..... | 102 |
| 4.6 | まとめ..... | 102 |
| 第5章 ドライビングシミュレータ実験に基づく脳活動と運転技量の関係の解析..... | | 103 |
| 5.1 | 本章の背景と目的..... | 105 |
| 5.2 | DS 実験の実験概要 | 105 |
| 5.2.1 | 実験コースの紹介 | 105 |
| 5.2.2 | 実験コースの DS で再現 | 106 |
| 5.2.3 | 実験概要 | 108 |
| 5.2.4 | 脳機能 NIRS 計測..... | 109 |
| 5.3 | 解析対象データの紹介..... | 111 |
| 5.4 | 実験結果..... | 113 |
| 5.4.1 | 走行データの差異性 | 113 |

| | | |
|---------------|---------------------------|------------|
| 5.4.2 | 機械学習手法で抽出された特徴量の共通点 | 115 |
| 5.4.3 | 脳活動の差異性..... | 116 |
| 5.5 | 運転熟練者の頭頂連合野活動について | 119 |
| 5.6 | まとめ..... | 122 |
| 第6章 | 考察..... | 123 |
| 第7章 | 結論..... | 129 |
| 参考文献 | | 133 |
| 本研究に関する発表論文など | | 141 |
| 謝 辞 | | 149 |

第1章

序 論

1.1 我が国における ITS の現状

高度道路交通システム(Intelligent Transport Systems, 以下 ITS)は、道路交通の安全性、輸送効率、快適性の向上などを目的に、最先端の情報通信技術などを用いて人と道路、車両を一体のシステムとして構築する新しい道路交通システムである^[1]。特に、道路交通の情報化、知能化を図り、事故、渋滞、環境汚染、エネルギー消費といった道路交通問題を解決するためのシステムである。

ITS 分野では、1994 年に実用化に関する国際協力の取り組みとしてパリで第 1 回世界会議が開催され、道路交通のインテリジェント化に関する研究成果の情報交換が世界規模で行われた。このように新しい産業の創出に対する期待から、各国政府と企業界の ITS への関心が高まってきた。

日本における ITS システムアーキテクチャは当時の ITS 関係 5 省庁(現 4 省庁)が旧 VERTIS(現 ITS Japan)の協力を得て 1999 年 11 月に策定された。本システムアーキテクチャでは、開発分野は以下の 9 つに分類されている^[2]。

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

(1) ナビゲーションシステムの高度化

ナビゲーションシステムの高度化の代表的なシステムとして、道路交通情報通信システム(Vehicle Information and Communication System, 略称 VICS)がある。VICS によって提供される情報としては、渋滞情報、所要時間、事故・故障車・工事情報、速度規制・車線規制情報、駐車場の位置、駐車場・サービスエリア・パーキングエリアの満車・空車情報などがある^[3]。

(2) 自動料金収受システム

自動料金収受システムが挙げられた背景として、料金所は高速道路における渋滞が発生の要因の一つであり、また、道路建設と管理コストを縮減することが必要であることから、自動料金収受システム(Electronic Toll Collection System, 略称 ETC)というシステムが開発された。ETC は、有料道路の料金所ゲートに設置されたアンテナと車両に装着された車載器との間の無線通信により自動的に通行料金の支払いを行うシステムである^[4]。

上記の 2 つのシステムは、ITS 分野の代表的な成果である。国土交通省道路局のレポート^[5]では、交通分野に非常に重要な作用を発揮していることが報告されている。本レポートでは、VICS は交通を整流化して走行燃費の改善が CO₂ 排出を抑え、環境負荷が低減できることが報告されている。例えば、図 1-1 に示しているように、都市部において走行時速が 20km から 60km に向

上した場合、燃料消費量が約4割削減できることが示されている。

走行速度の向上により、燃料消費量が大幅に削減




図 1-1 VICS による燃料低減効果^[5]

また、本レポート^[5]は ETC の効果についても記述している。図 1-2 は首都高速道路における ETC 利用率と料金所渋滞量の関係であり、料金所では渋滞がほぼ解消されていることが示されている。平成 19 年 10 月には、利用率が 70%に達成し、料金所周辺の CO₂ 削減量は約 17 万トンに改善されている。

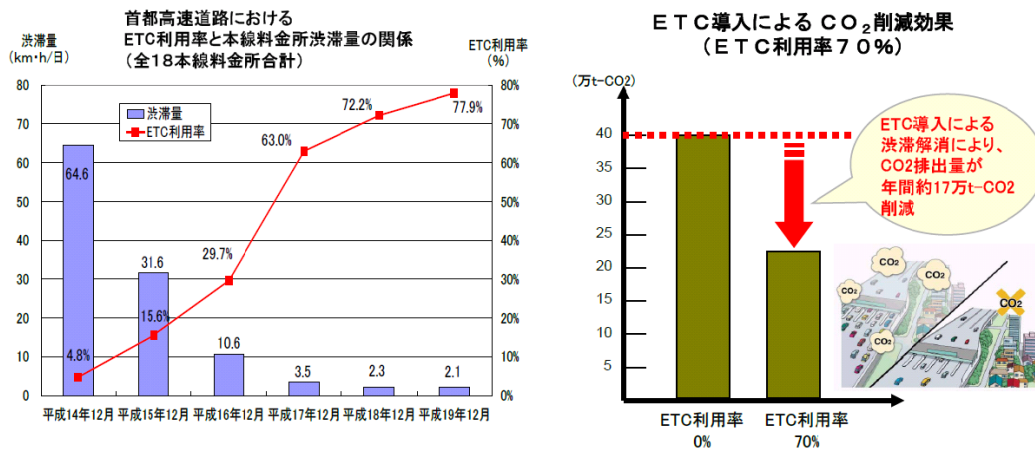


図 1-2 ETC によって交通渋滞と CO₂ 削減結果^[5]

(3) 安全運転の支援

近年の通信技術の発展によりドライバの運転データをビッグデータとして蓄積することが可能となった。そのため、ビッグデータを利用したモビリティに関する定量的な評価が可能となった。図 1-3 に示すように、日本においては 10 年前から一般車向けの簡易に取り付けられるドライブレコーダが市販されるようになり、交差点事故やヒヤリハット、ニアミスについて研究成果が発表されている^{[6][7][8]}。




図 1-3 ドライブレコーダ市場規模予測^[9]


(4) その他の開発分野

道路交通安全向上のための様々な研究が盛んに行われ、ITS 技術を応用した道路インフラ整備、先進安全自動車(ASV, Advanced Safety Vehicle)^[10]などの先進技術の開発も行われている。また、燃料消費低減のため電気自動車^[11]やハイブリッドシステムによる効率的なエネルギー運用技術も実用化されている。インフラと車両が交通安全や燃料消費に深く関係しているが、ドライバの運転技量も走行安全、燃料消費などに大きく影響を及ぼす要因である^[12]。

1.2 次世代の自動車

交通事故とエネルギー消費など代表的な道路交通の課題を解決するために、近年様々な運転支援システムが開発され、一部は既に商業化されるとともに、自動車における安全・安心・エコの向上が実現されている。一方で、日本では現在のドライバの年齢や運転頻度などの構成が深刻に変化している。例えば、先進国の日本を代表とし、人口構成の高齢化に比例して、高齢運転者が急速に増加している。図 1-4 に示しているように、警察庁の「平成 25 年中の交通事故死者数について」^[13]のデータによると、全般的に日本全国の交通事故の死者数が減少しているが、高齢者の死者数の減少率は下げ止まりの状態となっており、特に平成 24 年と 25 年には全年の交通死者の半分が高齢者であった。また、中国やインドなどの新興国では、数年間の経済成長を背景とした自動車の普及に伴い、運転初心者が爆発的に増加している。

高齢者（65歳以上）死者数の推移（各年12月末）



○ 高齢者（65歳以上）死者数の推移（各年12月末現在）

| | 15年 | 16年 | 17年 | 18年 | 19年 | 20年 | 21年 | 22年 | 23年 | 24年 | 25年 | 増減数 | 増減率 | 指数 |
|--------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-----|------|----|
| 高齢者 | 3,140 | 3,071 | 2,951 | 2,834 | 2,742 | 2,517 | 2,479 | 2,476 | 2,291 | 2,264 | 2,303 | 39 | 1.7 | 73 |
| 全年齢 | 7,768 | 7,425 | 6,927 | 6,403 | 5,782 | 5,197 | 4,968 | 4,922 | 4,663 | 4,411 | 4,373 | -38 | -0.9 | 56 |
| 高齢者構成率 | 40.4 | 41.4 | 42.6 | 44.3 | 47.4 | 48.4 | 49.9 | 50.3 | 49.1 | 51.3 | 52.7 | - | - | - |

注1 増減数（率）は、前年同期と比較した値である。

注2 指数は、平成15年を100としたものである。

注3 平成25年の高齢者死者数は、12月31日現在の交通事故日報集計システムにより集計された速報値である。

図 1-4 高齢者死者数の推移^[13]

ドライバの多様化による社会状況の変化に対応するために、次世代の自動車に関する研究開発が進められている。現在の代表的な運転支援システムとしては、追突防止システム(CAS, Collision Avoidance Support System), 車線維持運転支援システム(LKA, Lane Keeping Assist System), 自動巡航システム(ACC, Adaptive Cruise Control System)などである。運転支援システムは既存技術を基に、走行シーンに対応して各年齢層や運転技量の個人差に対応可能な運転支援システムを導入できれば、交通安全のさらなる向上が期待できる。そのため、ドライバの運転特性を表現可能なドライバモデルの研究開発に対する重要性が高まっている。

次世代交通に向けて、自動運転に関する関心も高まっている。NHTSA(米国運輸省道路交通安全局)は、2013年5月30日に自動運転に関する一次政策方針を公表した^[14]。2014年5月23日に、日本の内閣府でも「自動走行システム研究開発計画」が公表され、2014年度予算では総額24.5億円規模の予算が策定された。本計画書によると、この研究開発目標は

- ①交通事故低減等国家目標の達成
- ②自動走行システムの実現と普及
- ③2020年の東京オリンピック・パラリンピックを一里塚として飛躍

の三つである^[15]。また、国土交通省の調査によると、世界規模の大手自動車会社も各自の計画の発表を行っている(表 1-1, 表 1-2)^[16]。また、自動車関連の企業だけでなく、Google など IT 会社も自動運転技量に注力している現状である。

研究開発の技術目標については、NHTSA と日本内閣府が現在取り組んでいる自動化のレベルが明確に定義された^{[14][15]}。表 1-3 には各レベルの定義を記載している。

表 1-1 自動車会社における自動運転の実現に向けた取組状況(高速道路(高速域))^[16]

| | | ①Mercedes-Benz | ②BMW | ③Volkswagen | ④General Motors | ⑤トヨタ自動車 |
|-----------|------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|
| 自動運転の実現時期 | | 2013年 | 非公表 | 非公表 | 高速は2017年全車速は開発に5年程度必要 | 非公表 |
| 自動運転の実現内容 | | 公道での自動運転 | 高速道路での自動運転 | 高速道路での自動運転 | 高速道路での自動運転 | 公道での自動運転 |
| 走行範囲 | | 全車速 | 高速 | 高速 | 高速 | 全車速 |
| 対象車両 | | 一般車 | 一般車 | 一般車 | 一般車 | 一般車 |
| 自動運転の走行形態 | | 半自動的な追従走行 | 単独 | 単独 | 単独 | 単独 |
| 要素技術 | インフラ | — | — | — | 詳細地図 | 詳細地図 |
| | 通信 | — | — | — | — | 700MHz帯 |
| | 車両 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 |

表 1-2 自動車会社における自動運転の実現に向けた取組状況(高速道路(渋滞時))^[16]

| | | ⑥ Audi | ⑦ VOLVO | ⑧ Ford | ⑨ BOSCH |
|-----------|------|-------------------------|-------------------------|-------------------------|-------------------------|
| 自動運転の実現時期 | | 数年以内に発売 | 2014年 | 2017年から2025年の実現可能性 | 2014年に量産を開始見込み |
| 自動運転の実現内容 | | 渋滞中の自動運転 | 渋滞中の自動運転 | 渋滞中の自動運転 | 渋滞中の自動運転 |
| 走行範囲 | | 低速（渋滞） | 低速（渋滞） | 低速（渋滞） | 低速（渋滞） |
| 対象車両 | | 一般車 | 一般車 | 一般車 | 一般車 |
| 自動運転の走行形態 | | 単独 | 単独 | 単独 | 単独 |
| 要素技術 | インフラ | — | — | — | — |
| | 通信 | — | — | — | — |
| | 車両 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 | ・速度制御 ・車間制御 ・操舵制御 |

表 1-3 自動運転の階段^[17]

| 自動化の段階 | 状況 | 運転操作 | 走行環境の監視 | ドライバモニタリング | 異常時対応 | 想定される対象 |
|-------------|---------------------|-----------|-----------|------------|--------------|---------------------|
| 手動 | ドライバによる | ドライバ | ドライバ | | ドライバ | |
| 運転支援 | | ドライバとシステム | ドライバ | | ドライバ | 高速道路・低速走行など限定的 |
| 部分的自動化 | ハンドルアクセルなどの運転操作の自動化 | システム | ドライバとシステム | | ドライバ | 高速道路・特区など限定的なエリア |
| 限定的自動化 | 一定の条件下で環境認識も自動化 | システム | システム | 必要 | ドライバ | 一般道も含む広範囲な公道 |
| 高度な自動化 | 通常の走行環境なら自動化 | システム | システム | 必要 | システム(ドライバ責任) | 全ての道路環境 |
| 完全自動化(無人走行) | 異常時も含めて自動化 | システム | システム | 不要 | システム | 全ての道路環境 駐車場・専用道路 |

NHTSA の自律走行研究の研究計画によると、レベル 2 とレベル 3 の技術が本研究計画の中心となるほか、新たな自動運転技量への対応に必要な運転手トレーニングについても評価を行う^[14]。また、レベル 1 の高度な運転支援システム、レベル 2 とレベル 3 の準自動走行システムによる自動運転では、運転手が自動/手動運転モードの切り替えを行う。そのため、運転手が安全にモードの切り替えを行い、安全操作に関する情報が運転手に効果的に伝達されるように、運転手と自動車のインターフェースに求められる要件を策定する。また、システムの切り替えのタイミング、制御アルゴリズム、情報の提示タイミングや提示方法など、各レベルに関わらず、ドライバモデルも重要となる。そのため、ヒューマンファクター研究(Human Factor Research)は大きな課題の一つとして位置付けられている。これまで一般的には仮説に基づいたドライバモデルや過去の経験や知見、アンケートなどの主観評価によりシステムが検討されてきたが、次世代の交通では、さらなるドライバモデルの発展が求められ、多様化したドライバのニーズに対応するために個人差までも考慮したドライバ運転特性の解析が必要となる。

1.2.1 ITS とビッグデータ

ITS 技術の一つである情報通信技術(ICT, Information and Communication Technology)とセンシング技術を組み合わせ、積極的に活用したテレマティクスサービスが実用化されている。このようなシステムの代表的な構成は、図 1-5 となる。車両から得られるデータをプローブデータとして情報センターで収集し、データ処理を行った後、カーナビ、スマートフォンなどの端末のシステムへ交通情報を提供する。同時に、情報センターには膨大な量の情報が蓄積される。このデータベースは、各自動車会社とドライバが共有できる巨大なリソースと言える。もしこの共有リソースを積極的に活用できれば、様々な新しいサービスの提供が期待できる。代表的な実用例としては、2011 年 3 月 11 日の東日本大震災に対して、各大手車メーカーから匿名化して統計的に収集したプローブ情報(通行実績情報)の提供を受け、一週間後の 3 月 19 日から ITS Japan はホームページ上で「自動車・通行実績情報」の提供を開始した。図 1-6 に示しているように、被災後

の道路開通状況を把握でき、救援活動や物資輸送に多くの貢献を果たした^[18]。

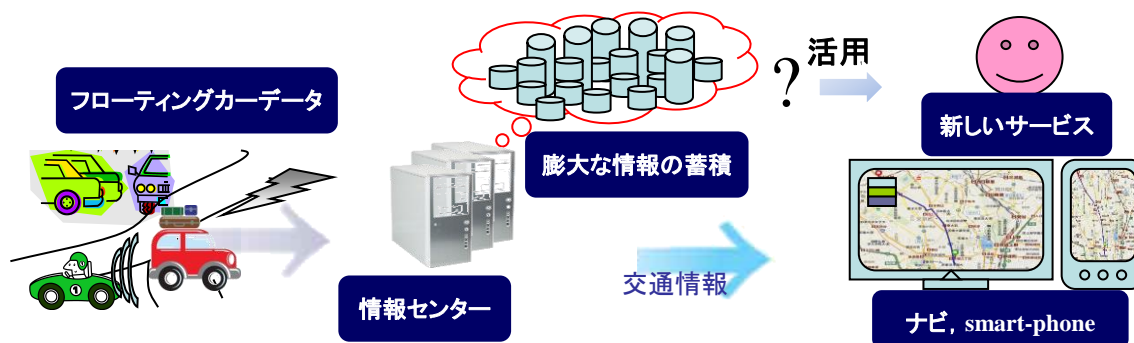


図 1-5 テレマティクスの代表的な構成

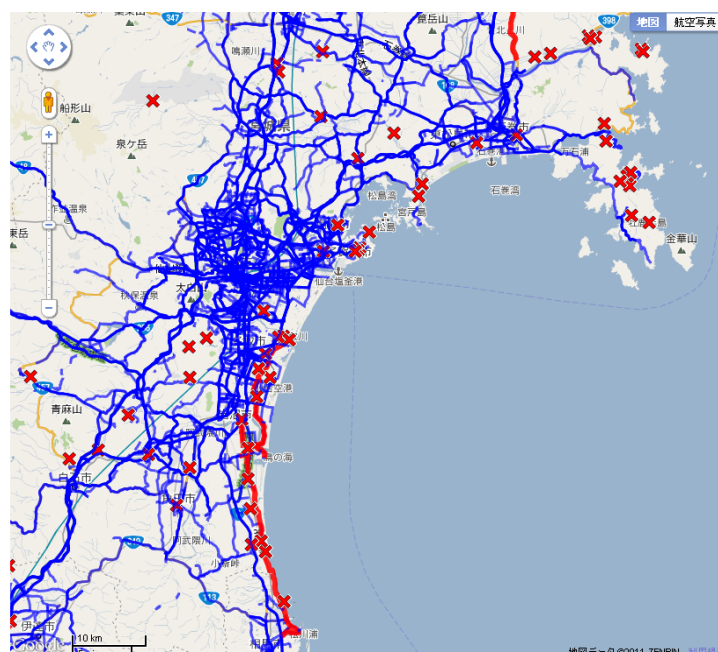


図 1-6 震災後道路通行情報(2011.4.13 時点)^[18]

(青:通行実績情報, 赤:通行止情報)

ICT とセンシング技術の統合による平時での運転行動の計測については、実路での運転行動を記録およびデータベース化が新エネルギー・産業技術総合開発機構 NEDO のプロジェクトで 2001 年に始められた。運転行動データベースは 2004 年から運転データベースとして公開され、大学・研究機関での研究や企業での技術開発に活用できるようになっている^[19]。

1.2.2 脳の計測

近年、脳の知識と脳の解析手段については、多く研究者が高い関心を持っている。特に、2014 年ノーベル医学生理学賞には、脳の空間認識に関する研究が選ばれている。計測手段としては脳の研究分野に非侵襲及び少侵襲画像診断方法において目覚ましい発展を遂げている^[20]。代表的

な手法としては脳波(EEG:Electroencephalography), ポジトロン断層法(PET:positron emission tomography), 単一光子放射断層撮影(SPECT:Single photon emission computed tomography), 脳磁図(MEG)(MEG:Magnetoencephalography), 磁気共鳴機能画像法(fMRI:functional magnetic resonance imaging), 近赤外脳機能計測法(fNIRS:functional near-infrared spectroscopy)がある. その中の MEG, EEG は直接脳の電気的な活動を計測するが, PET, SPECT, fMRI と fNIRS は間接的に脳の活動に伴う脳の血流の変化を計測して, 計測結果から逆に脳の活動を推測する方法である^[20].

脳の計測手法は既に交通分野の研究に応用されている. 既存研究によると, 脳波, fMRI, fNIRS の三つの手法が一般的に用いられている.

脳波はヒトの脳から生じる電気活動を頭皮上や蝶形骨底, 鼓膜, 脳表, 脳深部などに置いた電極で記録したものである^[21]. 図 1-7 には運転中のドライバの脳波を計測している様子である^[22]. 脳波は運転負荷, 注意散漫状態および眠気などドライバの状態監視^{[23][24][25][26][27]}に関する研究によく用いられている. また, ドライバの操作予測にも採用されている^{[28][29]}.



図 1-7 EEG:ドライバの運転特性に関する研究の応用事例^[22]

磁気共鳴機能画像法(fMRI)は認知や運動などの脳活動に伴う局所血流(ヘモグロビン濃度)変化における磁気共鳴特性を利用して画像化し, 脳の機能部位を調べる方法である^[30]. 該当方法は空間敏感が高精度で運転中のドライバの具体的に活性化している機能部位を観察するために応用されている. 例えば, 車間距離が短くなる時, 後続車のドライバの脳の各機能部位における変化^[31] や飲酒運転と通常運転のドライバの脳の機能部位を対照研究^[32]等研究事例が挙げられる.




図 1-8 fMRI: ドライバの運転特性に関する研究の応用事例^[32]

fNIRS の計測原理は、700~900nm の近赤外光を大脳皮質へ照射し、頭蓋内を通過した散乱光を検出する。神経活動が生じることにより局所脳の血流が増加し、ヘモグロビン濃度変化する。また、酸素化ヘモグロビン(oxy-Hb)および脱酸素化ヘモグロビン(deoxy-Hb)は近赤外光に対して吸収率が異なるので^[33]、散乱光の成分によって、酸素化ヘモグロビン(oxy-Hb)および脱酸素化ヘモグロビン(deoxy-Hb)の濃度変化を計測できる。脳血液量(CBV)と脳酸素交換量(COE)を算出することで脳機能を観測する^[34]。ドライバは自然な運転姿勢で脳の計測が可能であり、この方法は多く注目されている。研究事例としては列車運転シミュレータで運転による運転士の脳の賦活化^[35]と自動運転操作に対応する脳の活動^[36]など既存研究がある。特に、fNIRS を使って高速道路上で加速、減速中のドライバの脳活動の違いを計測することに成功していることも報告された^[37]。



図 1-9 fNIRS: ドライバの運転特性に関する研究の応用事例^[37]

各脳の計測手段には長所と短所があり、図 1-10 は各手段の比較を示している^[20]。例えば、MEG, EEG など直接計測方法では時間感度が良いが、空間感度が相対的に弱く、複雑な神経血管束は神経活動にフィルター効果が有ると報告された^[20]。一方、fMRI は空間感度が相対的に良いが、設備の使用条件が厳しい。fNIRS は装置の使用自由度が高く、ドライバが運転しながら脳の活性状況を計測可能である。fNIRS を利用することで、従来困難であった複雑な運転操作と脳の活性とを同時に計測することが可能となったため、ドライバの運転特性に関する新しい発見が期待されている。

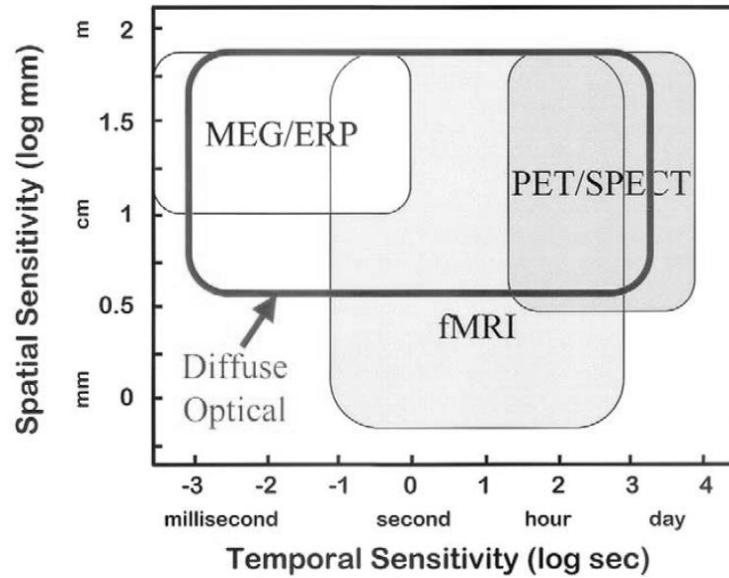


図 1-10 脳の計測手段の比較^[20]

[注:fNIRS は Diffuse Optical の一つ手法である.]

1.3 従来の運転特性に関する研究

1.3.1 運転特性

従来、運転技量の評価は経験則に基づいて行われ、定性的な知見が多く得られている^{[38][39][40][41]}。例えば、経験者運転特性分析^[38]、若者の運転の危険要因分析^[39]、カーブの線形条件と走行条件がドライバの運転挙動と主観評価^[40]、経験を重ねた熟練者が排除した無駄な動作や危険な動作をデータから検出^[41]するなど定性的な研究が展開された。しかし、自動車交通安全の向上を図るには、運転操作の定性的な評価だけでなく定量的な評価も必要である。定量的な評価には大量の運転操作データの取り扱いが不可欠であるが、これを踏まえた運転技量の評価手法は未だ確立されていない現状である。

また、運転技量の向上に関して様々な研究開発が行われている。図 1-11 に示すように、既存の研究は大きく分けて二種類の手法がある。一つは、ドライバの運転データを収集して、運転技量や安全運転レベルを評価する。例えば、福島らは衝突可能指数を提案し^[42]、ドライバ走行データからある期間を集計した場合、不安全割合という指標を用いて運転安全レベルを評価した。山田によれば、運転経験未熟者を定義し、その運転能力の測定、評価が可能なシステムを開発している^[43]。また、張慶らは出会い頭事故防止の教育のため、交差点における一時停止教育のための衝突体験型ドライビングシミュレータ(Driving Simulator, 以下 DS)を開発した^[44]。これらの方法は合わせて評価、再教育方法と呼ばれる。もう一つは、運転の規範操作のドライバモデルを作成することである。該当分野では、ドライバモデル、ドライバの状態観測などの研究が多数発表されている。既存のドライバモデルに関する研究では、多くは演繹的な手法でモデルを構築している^{[45][46][47]}。また、最近では熟練ドライバの運転データに基づく帰納的な手法によって規範

モデルを求める研究もあり、佐藤らは熟練ドライバ5人の運転データを帰納的な手法により、高速道路での厳しい車線変更場面の運転行動の規範モデルを提案している^[48]。

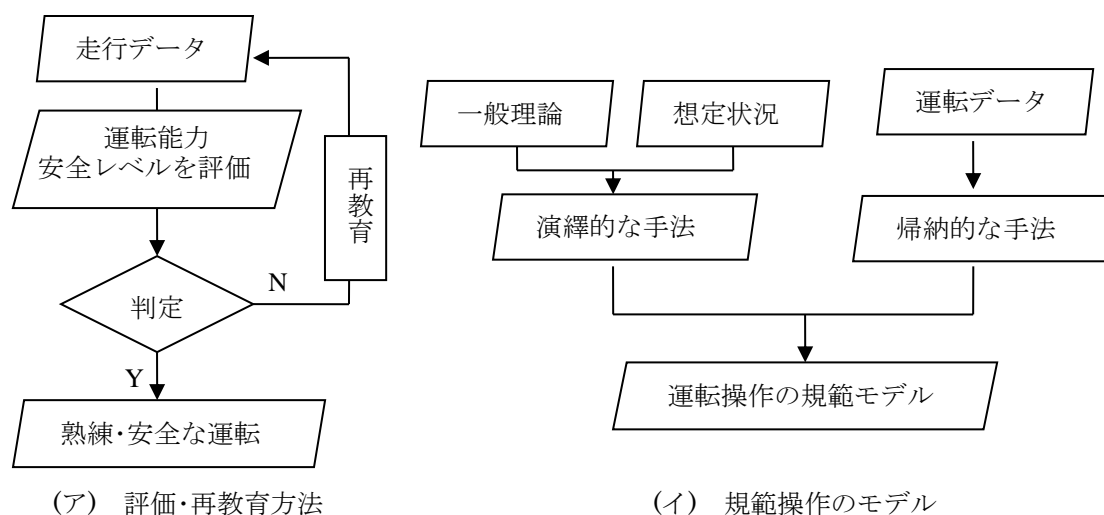


図 1-11 運転技量向上のための研究

しかし、これらだけではドライバの長期的な運転技量の向上を目指したドライバ支援システムにおいて不十分である。例えば、専門的な訓練によって熟練程度は向上できるが、このようなシステムは概してドライバの日々の通常走行を考えていない。運転技量が未熟なドライバに対して有効な運転操作のアドバイスを提供することは、運転技量の向上を図る現実的な方法の一つである。従って、有効なアドバイスを提供するにあたり、事前に熟練者と未熟者の運転操作の特徴差を把握することが重要である。例えば、運転支援システムのパラメータを個人の特性に合わせて設定するために、Zhang らはダブルレーンチェンジの実験データにおいて、操舵データの離散フーリエ変化における係数を用いて、候補特徴量を作成し、ニューラルネットワーク、決定木と SVM 等機械学習手法によって、ドライバスキルの判別モデルを学習により作成した。図 1-12 は Zhang らにより提案された次世代運転支援システムのコンセプトである^[49]。該当運転支援システムにはドライバの運転技量判別モデルを含み、ドライバの運転技量を判断したら応じるパラメータを調整できる。Naiwala らは狭い道路など初心者に対する困難な状況に着目して、熟練度を判別できるモデルの構築方法を提案した^[50]。運転技量評価に関する研究は多く展開されているが、熟練者と未熟練者の運転操作の特徴差は未だ明確な知見が得られていない。

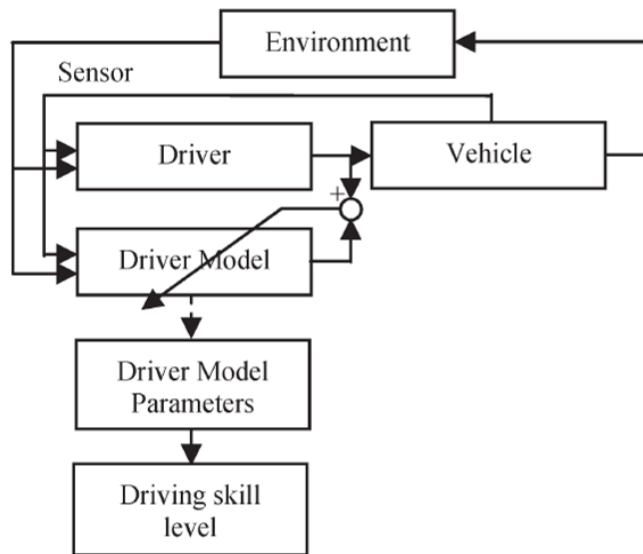


図 1-12 ドライバ特性を考えた運転支援システム^[49]

ドライバの実際の走行データを収集し、同じ道路で他の上手く走行したドライバと比べると、該当道路に対応する走行熟練と未熟練のドライバの特徴差が分かると仮定する。このような特徴差はアクセル・ブレーキ操作やハンドル操作に伴う車両の動きに現れるものと予想される。さらに、膨大な運転操作データベースから任意の道路において熟練者と未熟練者の特徴差がどこに、どのような特徴量として現れるのかを定量的に評価できれば、未熟練なドライバに対して熟練者の運転を実現できるようなアドバイスが与えられる。例えば、図 1-13 に示すように該当走行ルート上において、何らかの運転操作の特徴を抽出できれば、未熟練のドライバに有効なアドバイスが提供可能となる。例としては、場所 A に着く直前で“熟練のドライバは場所 A でゆっくりした操舵をした。”とアドバイスを提供できる。そのために、この道路に初めて走行する未熟練者でも同じ道路でよく走るドライバからの経験を共用できると考える。




図 1-13 熟練と未熟練のドライバの運転特徴差(コンセプト)

1.3.2 脳の計測と運転特性

運転行為は、走行環境を認知して集められた情報を脳が処理・判断するとともに指令を出して運転操作を行うことである。生理学では、脳の活動は運転行為の中心位置と言える。そのため、生理学的な立場から脳の活動に着目して運転特性を解析するために、ドライバの脳の活性を計測することが重要である。

脳の計測技術の発展によって、運転中のドライバの脳の活動の記録が可能となった。前節に記述された EEG, fMRI, fNIRS の三つの方法のうち、最も早くドライバ特性の研究に導入されたのは EEG である。最初はドライバの運転負担、眠気などドライバの状態観測するために生体計測技術の一つとして多くの研究に利用された。近年、ドライバの運転操作の予測研究にも使われている。代表的な研究は、池西らの EEG を用いたステアリング操舵意図の推定に関わる研究である^[51]。また、Stefan Haufe らと松島らは各自の DS 実験中に脳波を計測し、ブレーキ操作の予測モデルを提案した^{[22][52]}。しかし、EEG 実験中は電磁ノイズの影響を受けやすく、空間感度も弱いため、脳の機能部位の特定化すること困難など課題が残っている。

空間感度がより敏感な脳の非侵襲画像診断方法として、近年注目されている代表的な間接計測手法は、機能的磁気共鳴画像(fMRI)と機能的近赤外光分光法(fNIRS)である^[33]。前節で記述された既存研究^{[31][32][35][36][37]}によると、fMRI は設備の使用条件が厳しく、身体の移動には敏感に影響を受け、さらに金属の影響も強く受ける。また、被験者は常に仰臥位での実験が必要となるため、複雑な運転行為を行いながら脳の計測をすることは困難である。一方、fNIRS は装置の使用自由度が高く、ドライバが運転しながら脳の活性状況を計測可能である^{[35][36]}。そのため、fNIRS を利用することで、従来困難であった複雑な運転操作と脳の活性とを同時に計測することが可能となった。fNIRS を用いて柳沼らは前後方向の運転操作に対応する脳の活動の解析を行っている^[36]。Yoshino らは fNIRS を使って高速道路上で加速、減速中のドライバの脳活動の違いを計測することに成功している^[37]。そこで、本研究では、モーション装置と音響装置により実車に近い臨場感を実現することが可能な DS を利用するとともに fNIRS を導入し、新しい実験環境を構築する。この新しい実験環境により、臨場感の高い環境下におけるアクセル、ブレーキとハンドルを含む複雑な運転操作と運転走行中の脳の活性とを同期して計測し、ドライバの運転特性に関する新しい知見の発見に取り組む。

1.3.3 ドライバモデル

ITS 技術の発展に伴い導入された運転支援システムにより自動車を運転するドライバと自動車の協調性が大きく取り上げられており、人間-自動車系としてのシステム構築が注目されている^{[53][54]}。運転支援システムや自動運転システムの開発のために、様々なドライバモデルが構築された。基本的には制御理論、確率理論などに基づいてドライバモデルが構築された^[55]。ここで幾つかの代表的なモデルを例として挙げる。

●伝達関数モデル^[55]

図 1-14 に示しているのは伝達関数モデルである。人の認知判断操作の動作を纏めて、伝達関数で表現する代表的なモデルである。車の位置と目標コースの偏差を e で記号すると、比例ゲイン Kp で比例した動作と、微分ゲイン Kd で微分動作と、積分ゲインで偏差の積分動作を組み合わせると実舵角を出力する。ただし、その出力に対して、人間の応答遅れ無駄時間が $e^{-\sigma}$ で表現されている。




図 1-14 伝達関数モデル^[55]

代表的な伝達関数モデルによるドライバモデルとして、図 1-15 に示すような前方注視モデルがある。ドライバがある時間後に車両が到達する位置を注視しているという前提に基づいている。目標とする位置とドライバが走行しようとする車両軌跡との偏差に応じて、ドライバは操舵を行うというものである。人は、距離 L 先までそのまま進むと、目標コースから ϵ だけ、コースからずれると予測して、このずれが生じないように、操舵を行うというモデルである。この L を前方注視距離、その位置を前方注視点と呼ぶ^[56]。ここで、この予測する時間を予見時間 t 、この前方注視距離 L として、車速により長くなるという次のような関係がある^[56]。予見時間が短いと、運転が難しくなるという実験結果が報告されている。

$$t=L/V \tag{1-1}$$

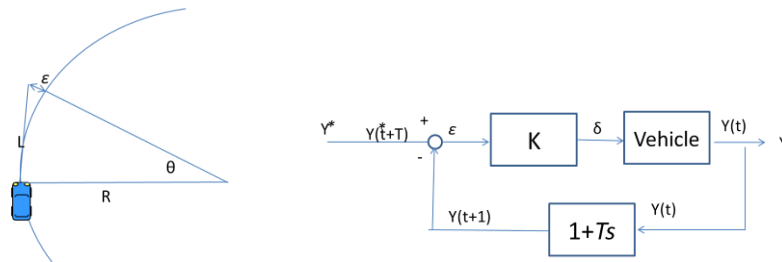


図 1-15 前方注視モデル^[56]

●ニューラルネットドライバモデル^[57]

ニューラルネットドライバモデルは道路線形情報(距離, 角度など), 車両状態情報(車速, 方位角度, ヨーレート, 操舵速度, 前後加速度, 左右加速度等)を入力情報として, ドライバも操舵角度とアクセルとブレーキ操作を出力として, 入出力のみに注目して, それをニューラルネットでモデル化したドライバモデルである。




図 1-16 ニューラルネットドライバモデル^[55]

●二視点制御操舵モデル^{[58][59]}

図 1-17 にこのモデルでは、ドライバは近い視点と遠い視点の二つの視点がある。各瞬間の操舵修正値は図 1-17 に示しているように、両視点に対して角度変化値との比例値と関わる^{[58][59]}。同論文には熟練度が違うドライバによって、各パラメータの値が異なる。初心者は近い視点の視角に対する係数が大きい傾向がある^[59]。




図 1-17 二視点制御操舵モデル^[58]

その他のドライバモデルも多く存在するが、これらはドライバが一様な特性を持つものと仮定している。初心者や高齢者など多様なドライバに対して、ドライバ特性を記述するものはない^[56]。本研究では、前節に記述したドライバ操作の特徴と脳の計測に基づいてドライバ運転特性の研究に新しい知見を獲得し、その結果を将来のドライバモデルに活用することを目指す。

1.4 本研究の目的

自動車の運転技量は安全走行，燃料消費，乗り心地などに大きく影響を及ぼす。交通安全と省エネルギーなど問題を解決するための高度運転支援システムや自動運転といった次世代の自動車では、ドライバの運転技量の評価が重要である。運転行為の三要素の「認知・判断・操作」は全て脳活動に関わる。そのため、運転技量の評価はドライバの操作特徴だけでなく、運転中のドライバの脳活動の検討が必要である。そこで、本研究は、ドライバモデルの高度化を目指し、ドライバの運転技量の評価手法を検討するためのビッグデータを活用した運転熟練者と未熟練者の運転特徴抽出手法の確立と、脳科学に基づいて生理学的の見地から運転技量差の裏付けを検

討することによる運転技量の評価における指針を提案することである。

先行研究では、体感は運転技量に対して重要な影響があることが示唆された^[56]。また脳科学の研究成果によって人が道具を使うとき、頭頂連合野が重要な役割を果たすことが示されている。これらの背景を踏まえて、本研究は、脳科学の知見をドライバ運転特性の研究に活用する。運転時のドライバは周囲環境と自車の運動状態に関する情報を感知し、関連情報を統合していると考えられる。そのため、情報統合に関する脳活動は運転技量に関係があるという仮説を提案する。本仮説を検討するためには二つの課題がある。一つは、運転技量のレベルの高いドライバと低いドライバの運転操作の特徴差を抽出することである。もう一つは、運転中のドライバの情報統合に関する脳領域の活性状態における差異を明らかにすることである。

まず、運転技量を評価するためには、ドライバの熟練度を定義することが必要である。本研究では、運転の円滑さの観点からドライバの運転熟練度を二分化する。運転熟練者と未熟練者の運転操作の差異性を抽出するために、機械学習手法に基づいて、多くのドライバに共通的に見られる運転特徴の抽出アルゴリズムを構築することを目指して研究を行う。

次に、運転中のドライバの脳活動を観測するためには、新しい実験環境の構築が必要である。本研究は臨場感の高い運転環境を再現可能な DS を活用し、アクセル、ブレーキとハンドルを含む複雑な運転操作と運転中の脳の活性とを同期して計測と解析を行うことが可能な新しい実験環境の構築を行う。また、本実験環境の有効性を被験者実験により検証する。

そして、構築された実験環境に基づいて脳活動と運転技量の関係を解明することを目指して研究を展開する。具体的には、DS 実験データに基づいて被験者を運転の熟練者と未熟練者とに分類し、両グループの運転操作の特徴差と脳の活動の差異性を検出することを目指して研究を行う。

最後に、実験結果において抽出された運転操作の特徴差と脳の活動の差異性に基づいて、既知の脳活動に関する知見から運転技量と脳活動の関係を考察する。特に、情報統合に関する脳活動は運転技量に関係があるという仮説を検討するために、運転技量の高いドライバと低いドライバにおける運転中の情報統合に関連する脳活動と運転走行データについて解析を行う。検討結果に基づいて、本仮説の検証を行うとともに、本研究で得られた知見について今後の高度運転支援システムおよび自動運転に関する研究への応用について考察する。

1.5 本論文の構成

本論文は7章からなる。以下にその構成を説明する。

第1章「序論」においては、本研究の背景として我が国における ITS の現状、ITS 分野のビッグデータと脳科学分野の脳計測技術および先行研究の状況について述べた。本背景に基づいて、

本研究の目的，論文の構成を述べた．

第2章「運転技量の評価」では，まず，運転技量を定義して，運転技量に関するドライバモデルの先行研究を述べる．その後，脳科学における動作のメカニズムについて述べるとともに，運転技量と脳活動の関係に関する仮説を提案する．

第3章「ドライバの運転特徴抽出手法および特徴抽出実験」では，まず，AdaBoostに基づいた運転特徴抽出手法を提案する．その後，DSで多曲率カーブコースにおいて被験者実験を行い，特徴抽出のためのデータ収集を行う．収集したデータに対して特徴抽出手法を掛けて，熟練者と未熟練者の運転特徴差を抽出する．また，抽出された特徴の妥当性を検討するために，AdaBoostによって学習された分類器の識別率を検討する．その後，抽出された特徴差に基づいて，未熟練者を対象としてアドバイス実験を行い，被験者の運転技量の向上を図り，本手法の有用性を示す．

第4章「ドライビングシミュレータを用いた脳の計測の実験環境の構築」では，DSを利用するとともにfNIRSを導入し，新しい実験環境を構築する．左右カーブの走行時における脳の活性化状態と運転行動を計測する．新実験環境で脳の計測のできるか如何かを検討する．

第5章「ドライビングシミュレータ実験に基づく脳活動と運転技量の関係の解析」では，脳活動と運転技量の間を調べるために，実在するテストコースをDSで再現して被験者実験を行う．DS実験により運転中のドライバの走行データと脳の活動を計測する．カーブの入口に着目して，運転熟練者と未熟練者を定義し，両グループの走行データの差異性と脳の活動の差異性を検出する．

第6章「考察」では，抽出された運転行動の特徴差とドライバ脳活動の差異性による運転技量の評価を念頭において，ドライバの脳で情報が統合されていることと運転技量の間を調べることを考察して，研究の仮説を検証することと今後の展望について述べる．

最後に，第7章「結論」において，本研究で得られた成果をまとめ，結論を述べる．

第2章

運転技量の評価

2.1 運転技量と合成ジャーク

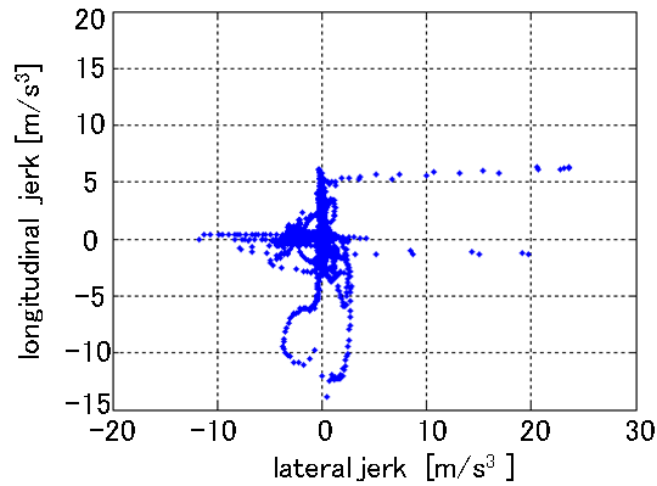
ドライバの運転技量に対して熟練と未熟練に分類することは重要なテーマの一つであり、様々な要素が関係する。そのため、着目する分類指標によって結果が異なってしまう。指標としては、ヨーレート、操舵角度、速度、ジャークなど様々な分類指標が考えられる。これらの複数の指標を統合して考えると、走行はヨーレートが小さく、操舵操作が小さく、かつスムーズで速度も速いのが熟練者の運転と考えられる。しかし、指標の数を増やすと熟練走行に対する選択条件が厳しくなり、熟練と未熟練の分類結果が異なる。そのため、分類指標の妥当性を検証するためには、膨大な実験データが必要となる。

既存の研究によると、多くの研究には加速度の時間変化であるジャーク(加加速度)がドライバの運転技量を明らかにする上で重要なファクタに成り得ることが示されており、ドライバが円滑に運転できれば安全性が向上するほか、燃料消費も顕著に減少し、乗り心地改善にもつながると報告されている^{[61][62]}。本研究ではカーブの走行に着目して解析を展開するため、横方向のジャークと前後方向のジャークを合成したジャーク(以下合成ジャーク)を分類時の指標に用いる。

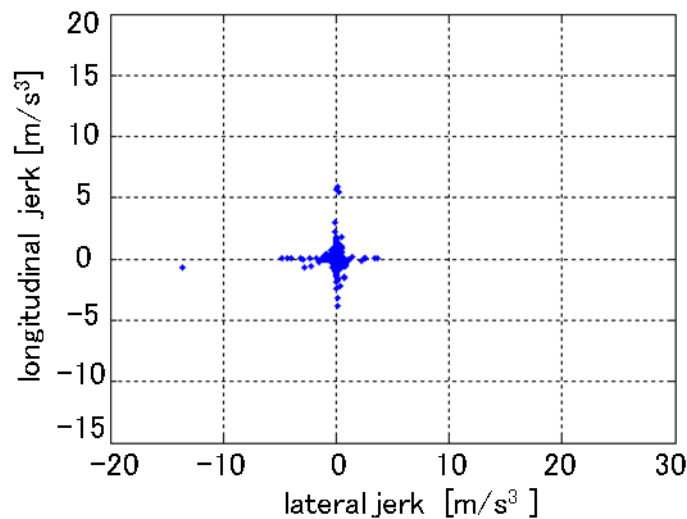
カーブを通過する時、合成ジャークの和が小さいほど運転に熟練していると想定する。各サンプルの横方向のジャークを J_{Lai} 、前後方向のジャークを J_{LOi} とすると、各走行に対して合成ジャークの累積値 J は次式で表される。式中の N がサンプル数である。この J の値を基に運転技量を熟練または未熟練に分類する。 J は大きければ該当走行がより未熟になる。

$$J = \sum_{i=1}^N \sqrt{J_{Lai}^2 + J_{LOi}^2} \quad (2-1)$$

具体的には、合成ジャークの累積値 J を計算するためには、前後方向、横方向のジャークを用意する必要がある。また、サンプル数は総和の大きさに影響されるので、前後方向と横方向のジャークを走行距離によって正規化して、結果的に各走行のサンプル数について整合を取り、合成ジャークの累積値として J の値が小さい走行は熟練者、大きい回は未熟練者と分類する、代表的な例を図 2-1 に示す。図 2-1 では、あるカーブを同じ進入速度で通過する時、熟練者と未熟練走行のサンプルを示しており、図中の横軸は場所によって正規化した横方向のジャークであり、縦軸は正規化した前後ジャークである。図の(a)と(b)を比較すると、熟練走行のジャークは大体原点に集中している。つまり、同じコースで熟練者は相対的に小さいジャークで走行しており、スムーズに走行できることを示している。



(a) 未熟走行時のジャークの分布



(b) 熟練走行時のジャークの分布

図 2-1 代表的な二回分走行のジャークの分布図

2.2 運転技量とドライバモデル

ドライバの操作は熟練度により、視覚系、体性感覚系、反力系の各認知機能に依存する程度が異なるという仮説を前提として、図 2-2 に示すようなマルチモードドライバモデルが先行研究で提案されている^[56]。モードとはインターフェースのモードを示し、ドライバは視覚系のモードによって、車両の変位や大きな角度変化ならヨー角度も視覚で感じられる。三半規管でも車両の角度変化を感じ、特に微小な変化であるロールやピッチは視覚で変化を認知するのは難しいため、この三半規管が主成分になると考えられる。これを体性感覚系のモードと言う。車両の加速度の変化は耳石器で感知するが、シートを通じて感じる体への力も反力的一种で、これと踏力やステアリング操舵力を反力系とした。そして、技量やシーンによって、この各モード

の取組比率を変えるゲインコントローラを備えるものとした。また、初心者、熟練者と専門ドライバに比べると、初心者は視覚系を重視、熟練者は視覚系と体感系を連合、専門ドライバは視覚系、体感系と反力系を連合して運転する^[56]。先行研究では、熟練者は視覚フィードバックだけではなく体感も使い、未熟練者は視覚を重視して頼る傾向があるという仮説に基づきモデルが構築されており、この新しいモデルに対してシミュレーション実験による実証が示されている^[56]。当該研究は体感が運転に対して重要な影響があるという仮説が示唆されているが、生理学的な立場から明確な証明は示されていない現状である。

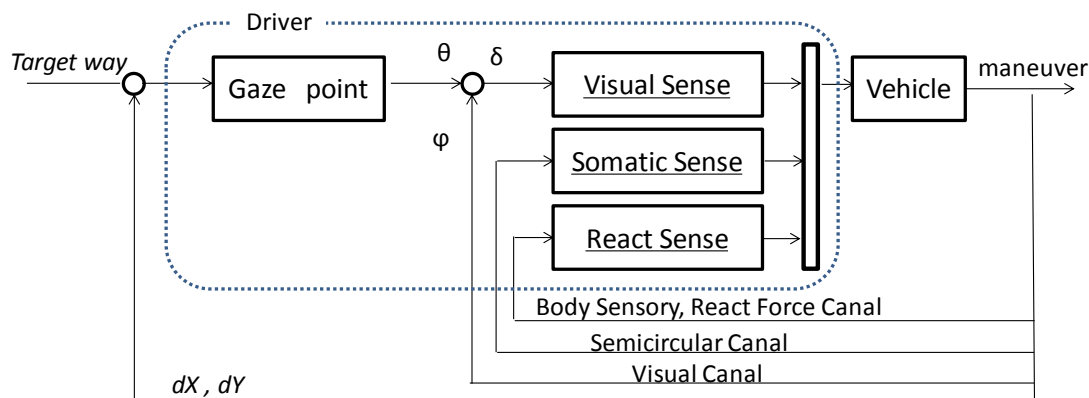


図 2-2 マルチモーダルドライバモデル^[56]

2.3 脳科学における動作のメカニズム

ドライバの運転特性については運転操作や脳活動に着目した解析方法が存在する。前者は走行シーンに対するドライバのアクセル、操舵とブレーキなど具体的な操作挙動に関する運転特性を解析する手法である。後者は、生理学的な立場から脳の活動に着目して運転特性を解析する手法である。運転行為は、走行環境を認知して集められた情報を脳が処理・判断するとともに指令を出して運転操作を行うことである。この過程が全て脳で反応できると考え、運転技量と脳活動の関係を探討するために、本節では脳科学における動作のメカニズムについて記述する。

人が運動する時、視覚情報や体性感覚情報など外部環境をセンシングして、集められた情報を脳が処理・判断するとともに指令を出して筋肉で力を発生し、動作を完成する。従って、視覚や体性感覚の外部環境を正しく情報を統合することが脳活動の重要な機能の一つである。既知の脳科学知識によって、運動に関する情報を統合する機能は頭頂連合野が重要な役割であると言われている。図 2-3 に頭頂連合野(BA7)の場所を示している。頭頂連合野の前後隣に体性感覚野(BA3)と視覚野(BA17, BA18)がある^[64]。解剖学的知見によって、この領域は、網膜座標系でコードされたニューロンが多く、手や頭など身体中心座標系にコードされたニューロンがある。頭頂連合野は、目の網膜でとらえた「網膜中心」の入力(ユークリッド座標系)を、「身体中心」の座標(極座標)に変換したり、運動前野の運動計画を修正したりする。そのため、体性感覚と視覚の統合による身体イメージの生成や保持に関わっている^{[65][66]}。




図 2-3 頭頂連合野の位置^[64]

図 2-4 は簡単な手操作運動の脳内表現を示している^[67]。体の動きなどを感じる一次体性感覚野(BA3)と視覚情報に関する視覚野(BA17,18)の情報を頭頂連合野(BA7)に入力し、頭頂連合野(BA7)で両情報から身体イメージが作成される。身体イメージは身体における様々な解剖学的要素、それら要素の潜在の運動、運動に際してそれぞれの要素を関連づける方法についての感覚運動的な意識である^[74]。手や関節などの速度・加速度・位置情報を感じて、自分の姿勢と運動状態を意識する。身体イメージを工学的に捉えると、身体の手や足といった解剖学的要素が身体中心座標系に占める領域とそれぞれの空間構造と位置情報が脳内に表現されることである。身体イメージに基づいて、前運動野(BA6)で運動計画され、運動野(BA4)にて操作が行われる。つまり、頭頂連合野(BA7)は、視覚情報のみならず、体性感覚の入力が同時に入ってきているニューロンが見つかる所であり、フィードバックを基にした運動の制御において大変重要な位置にある^[67]。

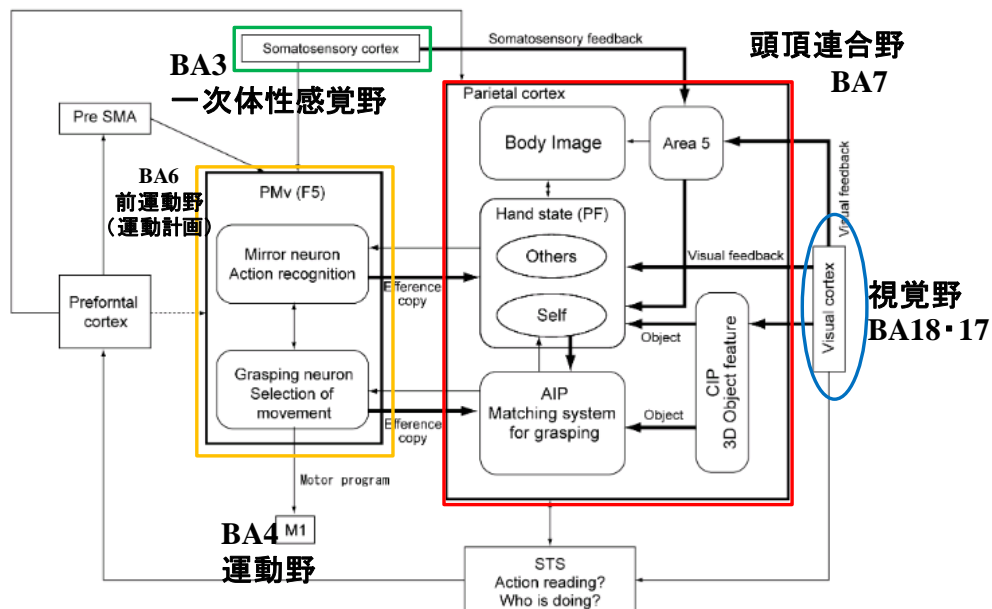


図 2-4 頭頂連合野(BA7)と操作^[67]

脳科学分野において、道具を使う時、頭頂連合野の活動に関する研究も多く展開している。理化学研究所の入来らは、ニホンザルの道具使用時における神経細胞の活動について研究を報告

した。実験結果からサルの前頭連合野には、体性感覚を視覚情報とすり合わせ、自分の身体を認識したときに活動する神経細胞があることが報告されている。普通のサルにとって、くま手はただの異物であるので、その神経細胞は活動しない。しかし、訓練によって、くま手を道具として使えるようになると、くま手があたかも自分の身体の一部になったかのように、その神経細胞が活動するようになる^{[65][68][69]}。また、人が一般的な運転を行う時、体性感覚野などからの内在感覚情報および運動野由来の運動情報は頭頂葉へと投射され、頭頂葉にはこれらの情報が自己身体イメージとして保持される^[70]。他には、身体イメージは決して固定されたものではなく、ダイナミックに可塑的に変化しうる。道具を使っているときは道具が身体の一部になることは拡張された身体イメージと言われる^{[68][69][70][71][72][75]}。しかし、これまでのサルなど実験では、脳の計測手段の制限により実験条件を統制し、静的な条件下での相対的な評価に留まっていた。近年、NIRSの誕生と発展によって、自然の運動状況下で動的に人の脳活動を計測することが研究の潮流になっている。例えば、高速道路の運転者の脳活動や自転車に乗っている人の脳活動に関する研究が報告されている^{[37][73]}。

2.4 運転技量と脳活動に関する仮説

前節まで、体感情報は運転技量に対して重要な影響があること、および脳科学の研究成果によって道具を使うとき、情報統合に関わる前頭連合野には重要な役割があることを述べた。本研究では、これらの背景を踏まえて、運転技量と脳活動に関する仮説を提案する。

先行研究に、餌を取るために道具を使っているサルは、前頭連合野の活性化により視覚情報と体性感覚情報を統合することによって、サル自身の腕や関節など身体要素の空間構造と位置情報を脳内で身体中心座標系に表現する。前頭連合野の活性化はエサを成功的に取るために重要であることを示されている^[65]。脳科学分野において、人を対象とした研究では、専門的な動作ができる人は前頭連合野の活性もより活性化していることも報告されている。例えば、よくトレーニングを積んだバレエの熟練者は、バレエの映像を見るだけでも頭頂葉がより活性化することが報告されている^[76]。また、ソフトボール選手を対象としたfMRIによるNO>GO>GO実験では、前頭連合野は熟練者の方が活性化することが分かっている^[77]。バレエやソフトボールの事例では前頭連合野の活性と運動技量に関わっていることを示されている。前頭連合野では視覚情報と体性感覚情報を統合して、前頭連合野の活性化による情報統合能力が熟練度に重要な影響があることが示されている。

ドライバは運転する時は、視覚野、体性感覚野と前庭神経を含む各機能からフィードバックした体感情報を感知している。ただし、図 2-5 に示しているように、感知した情報を単に足し合わせるのではなく、前頭連合野で情報を統合して、「認知・判断」のための適切な材料が用意されていると考えられる。そこで、本研究では、情報統合能力も同様に運転技量に重要な影響を与えると仮説を立てる。具体的には、本研究では前頭連合野の活性レベルと運転技量のレベルに関係があることを実験により検証する。

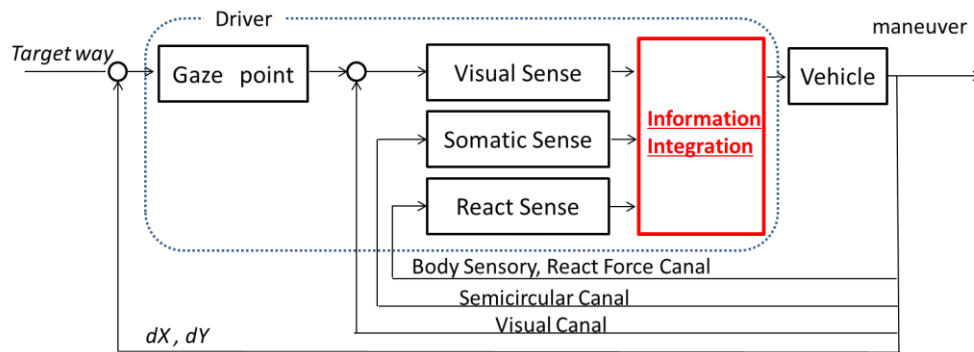


図 2-5 情報統合とドライバモデル

第3章

ドライバの運転特徴抽出手法 および特徴抽出実験

本章では、第 3.1 節で運転特徴抽出のコンセプトについて述べるとともに DS 実験に基づいて、特徴抽出手法により得られる運転特徴について述べる。また、ウェブレット変換の導入と機械学習手法の概要を説明する。

第 3.2 節では、特徴抽出アルゴリズムの詳細を記述する。まず、全体手法のフローチャートを示すとともに、ウェブレット変換における各パラメータの詳細設定に関する検討を行う。次に、候補特徴量を生成するために必要な窓処理について述べる。最後に AdaBoost による特徴量抽出の詳細を述べる。

第 3.3 節では、多曲率カーブにおいてドライバ 16 人の被験者実験を行い、熟練度二分化方法を提案し、熟練者と未熟練者の運転特徴量をカーブごとに抽出する。

第 3.4 節では、抽出された特徴差に基づいて、未熟練者を対象としてアドバイス実験を行い、被験者の運転技量の向上を図り、本手法の有用性を示す。

3.1 運転特徴抽出コンセプト

3.1.1 目的とコンセプト

ドライバモデルに関する研究は多く存在するが、従来研究では演繹手法により制御工学などの立場から伝達関数や方程式でドライバモデルは表現されてきた。モデルの理解や解釈については主観評価や仮説を立て、ドライバの走行データを用いて、モデルの理解や検証が行われてきた。

本研究は自動車分野のビッグデータを重要な背景として、ドライバの運転データに関するビッグデータに基づく、帰納的な手法の観点からの理解と解釈を目的としたドライバの運転特徴の抽出手法を提案する(図 3-1)。基本的なコンセプトは、蓄積した膨大な量の運転操作データから熟練と未熟ドライバにおける二つのグループの代表的な操作特徴差を抽出する。抽出した特徴量に基づいて、熟練者と未熟練者はどこでどのような操作に違いがあるかを見出す。

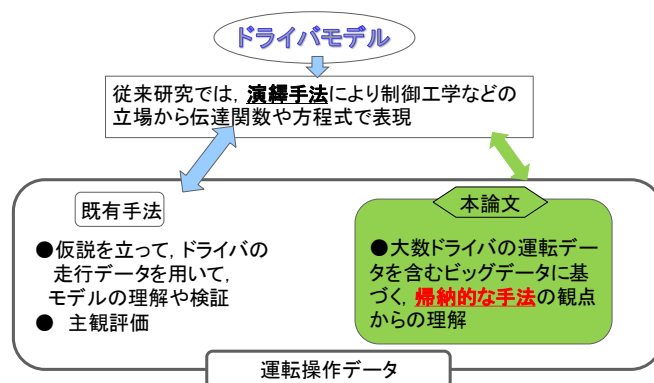


図 3-1 帰納的な手法の観点からのドライバモデルの理解と解釈

図 3-2 は、運転特徴手法のコンセプトを示している。まず、実車の運転操作データの取得を行う。次に、熟練者の多くはスムーズな運転を行い、逆に未熟者は操作が定まらずフラフラした運転になると仮定すると、ドライバは同じ場所で同じパラメータにおいて周波数特性が違える。そのため、ドライバの操作量(例:操舵, アクセル操作)を各周波数成分に分ける。最後に、機械学習手法によって熟練と未熟なドライバの運転特徴差を抽出する。

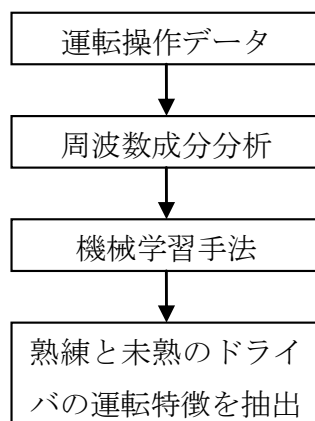


図 3-2 運転特徴抽出手法のコンセプト

次節から、運転操作データから熟練者と未熟練者の運転操作の違いを波形で表し、この部分を明確にするための周波数分析手法について述べる。また、運転特徴量の抽出手法は、画像分野で用いられている Boosting 技術を応用し、特徴量を抽出できないか検討する。

3.1.2 運転特徴量

ドライバの運転技量によって運転操作の特徴が異なる。特に操舵、アクセル、ブレーキのドライバが自ら操作を行う三つの運転行動にその差が出やすいと仮定し、これらの差異を運転特徴の差とする。また、道路条件、交通流量密度など周囲走行環境と自車状態もドライバの運転挙動に大きく影響するため、本論文ではドライバがカーブ通過時の運転状況に着目する。さらに、自車速度は三つの操作以外の重要なパラメータとなり、熟練者と未熟練者の運転方法における特徴差は操舵、アクセル、ブレーキの操作結果に伴い車両の動きとして現れるものと予想される。例えば、カーブを通過するとき、熟練者は適切な走行速度パターンを選択し、スムーズな操舵を行い、円滑に走行できると考えられる。

運転特徴が具体的にどのように現れるかを確認するために、DS で図 3-3 に示すカーブを想定し予備実験を行った。本実験では、被験者は走行始点 A から半径 60m のカーブを通過して終点 B で止まるまで走行速度は約 40km/h に維持するよう教示した。ドライバとして 6 人が実験に参加した。図 3-4 に代表的な 2 人のデータを用いて運転特徴を説明する。

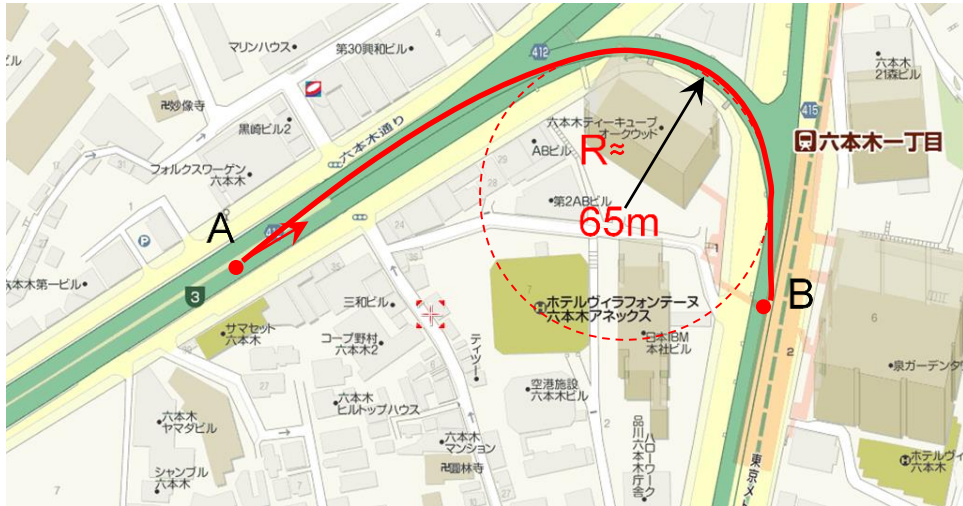




図 3-3 予備実験走行ルート



(a) ドライバ A:前車輪の旋回角度(操舵角度)と時速



(b) ドライバ B:前車輪の旋回角度(操舵角度)と時速

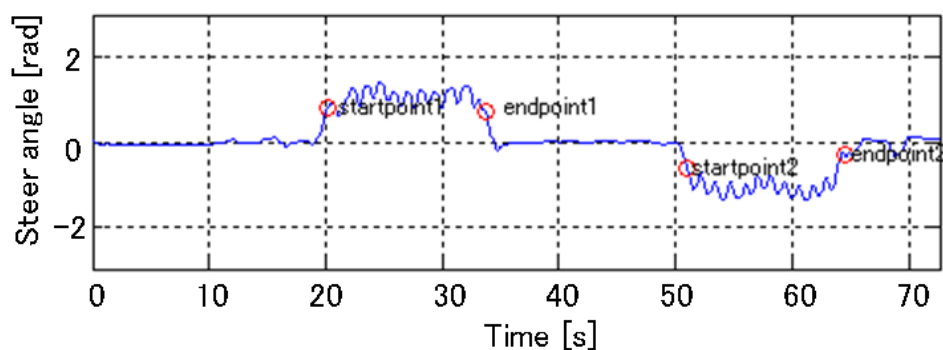
図 3-4 運転操作の比較

ドライバ A はカーブを進入した後、操舵速度を急に調整している。速度も変化が大きかったことが分かる。逆にドライバ B は、カーブで操舵が相対的にスムーズで、速度もあまり変化しなかった。これら結果を見ると、A の運転は未熟と言える。ドライバ A と B の運転操作を比べると、運転特徴はカーブ中の操舵操作と速度に現れると考えられる。今までは、この 2 人の運転

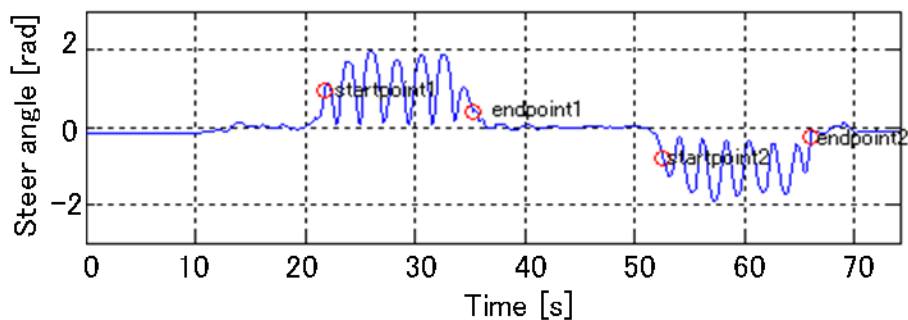
特徴差を定性的にしか評価できていない。このような特徴が定量的に評価できるのか、特徴を抽出することができるのかを検討することが必要である。また、他のパラメータに類似、あるいは明確な特徴差があるか、ドライバ A と B で差が生じるパラメータの中で何が重要なのか、を明らかにすることができればドライバに実用的なアドバイスができる。

3.1.3 ウェーブレット変換


運転操作は動的であるため、応答特性を評価するためには周波数分析が重要であると言える。例えば、熟練者の運転操作は、未熟練者の操作における周波数は異なる。熟練者はスムーズに運転し、逆に未熟方フラつきながら操作する傾向にある。図 3-5 には二つの連続なカーブを通過するとき、三つの代表的な運転方式を示している。カーブの入口から出口までドライバ 1 は意図的に振幅が小さく速い周波数で操舵操作を行っている。ドライバ 2 は振幅が大きく速く振動しながら運転し、ドライバ 3 はドライバ 1 と 2 に比べてスムーズな運転で低周波である。一般的な認識ではドライバ 3 の運転方式は三者中最も熟練者であると考えられる。三つの運転方式は操作の各周波数成分に明確な特徴差が存在すると考えられる。これはウェーブレット変換を適用する理由の一つであり、ドライバ操作を各周波数成分に分けて、同じ周波数成分に熟練と未熟練なドライバの特徴が現れると仮定される。



(a) ドライバ 1



(b) ドライバ 2



(c) ドライバ3

図 3-5 三つ代表的なドライバ運転方法




図 3-6 操舵角度の時刻歴データ

ウェーブレットを用いるもう一つの理由は、運転操作の特徴は局所的に短時間内に現れるものと考えられる。例えば、図 3-6 は実験から得られたデータの一つである。該当ドライバはカーブの出口で連続的に操舵角度を調整している。このような細かな特徴は熟練者と未熟練者の特徴差になる可能性がある。特徴を詳細に抽出するため、本研究では周期性と短時間情報の両方を解析する方法としてウェーブレット変換を用いる。

ウェーブレット変換は基本的には連続ウェーブレット変換(CWT)と離散ウェーブレット変換(DWT)の二種類がある。運転操作において、操舵角速度など比較的高周波なものや、アクセルなど低周波なものなど様々な周波数帯で現れることから、本論文は離散ウェーブレット変換を採用している。図 3-7 はウェーブレット変換の分解樹形図である。オリジナルデータは、一回分解されると高周波数成分 $cD1$ と低周波数成分 $cA1$ が生成される。 $cA1$ は実験から直接得られたデータと比べるとノイズが少なくなる。この過程を繰り返して3回目まで分解すると、 $cD1$ 、 $cD2$ 、 $cD3$ と $cA3$ が生成され、これらはウェーブレット変換の出力となる。図 3-6 の楕円部分の振動は $cD1$ ~ $cD3$ の高周波数成分から抽出されることが期待される。マザー・ウェーブレットの選択と分解のレベル数の決定の詳細は次節にて述べ、ここではコンセプトを中心に述べる。

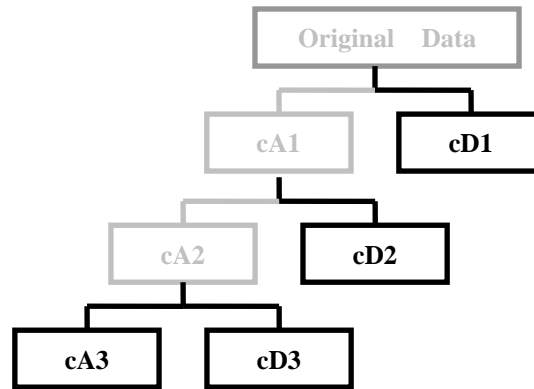


図 3-7 ウェーブレット変換の分解樹形図

3.1.4 特徴抽出手法

今までの特徴抽出は統計手法に基づき、候補特徴集合のうち、意味のある部分集合だけを選択する手法のことを指す^[78]。この概念は、画像認識、音声認識分野でよく使用されている機械学習の概念である。一般的に、特徴は二つの事物を区別できる最も顕著な部分を示す。つまり、全般の特徴ではなくて、選択した特徴量だけを見ると、それがどの種類に属するだけ分かればよい。例えば、ある画像に顔の存在を確認する場合、全ての画素を顔に対照する必要性がない、目鼻口など顔特有の特徴が確認できれば顔の存在も確認できる。ここでは、顔認識分野の代表的な技術を紹介し、本来の課題に合わせて活用できるかを検討する。

画像パターン認識における候補特徴量と特徴抽出手法^[79]として、第一世代の代表的な手法はニューラルネットワーク、線形判別分析(LDA)、サポートベクタマシン(SVM)である。候補特徴量は画像全体に着目して、各ピクセルの明るさ、輝度分布の情報を用いる。本世代の後期では、エッジ部分の輝度の値が大きく変化している特徴に着目し、該当特徴を活用してエッジ部分を探す方法としてウェーブレットなどを用いたアルゴリズムが提案され、この手法は本研究でも活用できる。第二世代は、対象物体の局所情報に着目し、Haar-like, HOG 特徴量が提案され、ブースティングによって、顔を抽出できる手法が提案された。最近の第三世代は、ブースティング技術を進化させ、局所領域のつながりにより特徴量を抽出する手法が提案されている。候補特徴量は局所情報を組み合わせて作り出し、最適な組み合わせを選択する方法である。

上記の三つの手法は、顔認識分野で統計的学習手法から特徴量を抽出している。第一世代は、各画素を直接的に候補特徴量として入力し、ニューラルネットワーク等によって顔検出モデルを構築する。ニューラルネットワークの算法構成特徴は研究者の事前知識が重要となってくる。第二世代は Haar-like など各画素の生データから様々な候補特徴量を作り、機械学習手法によって顔検出器を構築する。本世代は研究者の事前知識なく検出性能が高い検出器の学習が可能である。同時に、最適な特徴量を選ぶためには大量のサンプルが必要であるため、学習効率と過剰学習の問題がある。第三世代は特に二世代之特徴量間の関連性に着目して、Joint-haar-like などのような特徴量を作って、少ない弱識別器数で高い検出率を誇る。特徴量を組み合わせる方法は種類が

多く、本世代の候補特徴量は二世世代よりさらに大量の学習サンプルが必要になる。

本論文が対象とするドライバ運転特徴は、熟練と未熟が同じ道路である個所で特徴があると仮定できるため、ドライバの運転操作量から派生した大量のデータから代表的な特徴量の抽出手法に関し、候補特徴量は運転時のアクセル・ブレーキ操作やハンドル操作であり、これらは時系列歴に変化し、例えばカーブ間で前のカーブの操作が時系列的に後のカーブに影響を与えることはないため、第三世代の特徴量の組み合わせによる手法ではなく、二世世代の手法を参考にし、特徴抽出手法を提案する。

3.1.5 AdaBoost による特徴差の抽出コンセプト

特徴抽出手法では AdaBoost というアルゴリズムを用いる。Boosting の一種である AdaBoost は機械学習アルゴリズムで、膨大な個数のデータから特徴を抽出する学習、判別アルゴリズムであり、デジタルカメラの顔検出機能などに用いられている^[80]。提案手法では 2.4 節の窓関数処理によって生成された候補特徴量データを AdaBoost に入力すると運転操作の特徴が抽出される。

3.2 ドライバの運転特徴抽出アルゴリズム構築

3.2.1 特徴抽出のアルゴリズム

第 3.1 節の特徴量抽出のコンセプトに基づいて、本研究で提案する運転操作の特徴抽出手法の構築を行う。手法のフローチャートを図 3-8 に示す。

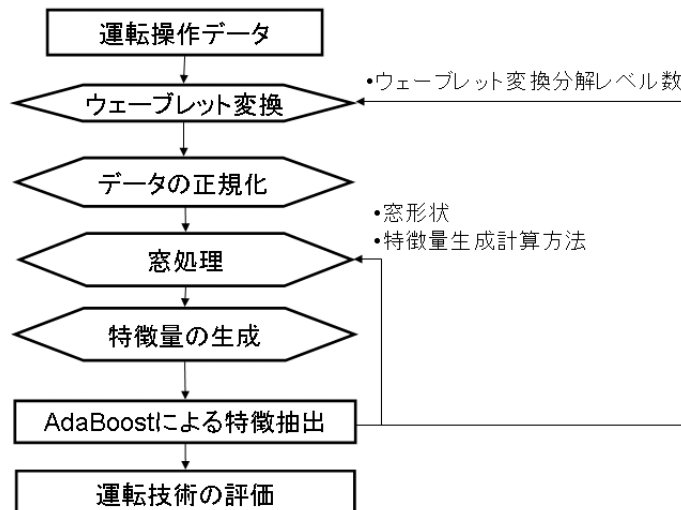


図 3-8 熟練と未熟の特徴差抽出する手法

まず、実車の計測機能など何らかの方法で運転操作データを取得できるとする。今回の分析では、DS によってデータを取得している。合成ジャークによって、熟練走行と未熟練走行を定義する。

熟練者の多くはスムーズな運転をし、逆に未熟者は操作が定まらずフラフラした運転になると仮定すると、ドライバは同じ場所で同じパラメータにおいて周波数特性が違うと言える。従って、実験から時刻歴の生データを直接ウェーブレット分析し、各周波数成分に分ける。

一般的に、実験から直接得られるデータは時刻歴であり、走行速度によって各回走行のサンプル数が異なるので、個人差が生じるため直接比較することは困難である。また、データベースにおいて運転操作の特徴の現れる箇所は自車位置と運転操作に対応する。そこで、比較のためウェーブレット分析で各レベルの成分に分けられたものを距離で正規化する。

本手法で用いる AdaBoost は機械学習アルゴリズムである。このアルゴリズムは大量のデータの中から特徴を抽出する方法であることから、AdaBoost に大量のデータを入力するための準備として、操舵角度、操舵速度、アクセル踏み量等運転特徴差が潜在するデータを用いる。

ドライバの運転の特徴は一般的に一定時間または空間内の操作量の平均などによって現れると考えられる。そこで、ウェーブレット変換の結果に対して窓関数を用いた処理を行うことで AdaBoost に入力する大量のデータを生成する。窓関数は任意のものを設定できるが、ここでは矩形の窓関数を設定する。このステップで生成されたデータは抽出される特徴の候補となる。以下、このデータを候補特徴量データと呼ぶことにする。


大量の候補特徴量データを AdaBoost のアルゴリズムに入力し、特徴を抽出する。特徴抽出の結果が不十分と判断された場合は窓関数の形など候補特徴量データの生成方法を変更する、もしくはウェーブレット変換のマザー・ウェーブレットと分解レベル数を調整するなどして、再度、候補特徴量データの生成と AdaBoost による特徴抽出を行う。

3.2.2 ウェーブレットについての検討


熟練と未熟練のドライバの操作差は操作データの各周波数成分に存在することと考えて、提案しているアルゴリズムは、ウェーブレット分解を用いているが、ウェーブレットについてマザー・ウェーブレットと分解に必要なレベル数を検討する必要もある。本節は該当二つの課題を中心に述べる。

マザー・ウェーブレットの選定は、様々な方法があり、マザー・ウェーブレットの選定方法によって結果も変わってくる^{[84][85][86][87][88]}。一般的に信号の特徴に合わせて適当なマザー・ウェーブレットを選定する。

本論文は、図 3-9 に 4 つマザー・ウェーブレットの比較検討を行った。その中の db8 は直交ウェーブレットであり、またドライバ操作の動特性に類似している。今回が db8 を選定して、分析を行う。




(a) bior2.2



(b) db3

(c) db1



(d) db8

図 3-9 マザー・ウェーブレットの比較(bior2.2, db3,db1,db8)

ウェーブレット分解で何レベルまで元波形を分解したらよいかの検討は非常に重要な問題である。もし段数が不足の場合、候補特徴量を生成した際、見たい成分にノイズと混在した波形になってしまう。逆に、段数が多すぎる場合には、候補特徴量の数が増えるのと、重要な操作特性を含んでいない波形になってしまう可能性がある。本手法では、カーブに関する運転挙動に着目しているため、カーブの長さや走行速度、ドライバ操作の特性から各候補特徴量生成するパラメータの分解レベルを決める。次に、何段まで分解するかの周波数を決める方法を記述する。




図 3-10 走行コース

ウェーブレット分解レベル数を決めるために、DS を用いて、図 3-10 に記載しているコースで時速 60km/h の試走行を行った。該当試走行のデータに基づいて次に示す。

まず、周波数 0.02Hz の例を考えると、この成分の該当周波数成分に対する挙動は 50 s ぐらいで一周期振動する。60km/h(16.6m/s)の場合は約 830m 距離で一周期の動作をすることになる。図 3-10 に描いているコースの総距離は約 870m である。つまり、60km/h の場合、周波数 0.02Hz の成分は大体全コースの線形によって決まる波形の特徴を表している。ここでは、図 3-10 のコースの走行結果を幾つが載せて、道路線形によって決まる操舵角度の周波数成分を確認する。

図 3-11 には図 3-10 に示しているコースに基づく実験から得られた操舵角度データと、マザー・ウェーブレット db8 を用いて分解した結果を示している。図 3-11(a)はドライバ 1 の操舵角度データである。一番上は実験の生データである。2 段目以降がウェーブレット分解の結果である。図 3-11(a)の左部分は各レベルの低周波数成分であり、右部分はそれに対する高周波数成分である。上からレベル数が段々増える。つまり、高周波数成分の周波数範囲は徐々に低周波数になる。図中注明した周波数は該当成分の中央周波数である。ウェーブレット分解樹形図によると、生データはレベル 1 に分解する場合、低周波数成分 A1 と高周波数成分 D1 になる。レベル 2 はレベル 1 の低周波数成分 A1 を入力し、更に低周波数成分 A2 と高周波数成分 D に分解される。この過程を繰り返して、10 段まで生データを分解している。同じ方法で、ドライバ 2 の 1 回走行の操舵角度における分解結果を図 3-11(b)に示す。

結果を見ると、図 3-11 に示している 2 回分の走行の A9 成分は波形がスムーズになって、更に(a)と(b)でよく類似している。周波数を見ると、D9 の中央周波数は 0.0781Hz 以下の低周波数である。D9 の中央周波数は 0.0781Hz から、A9 成分は大体 213m より長い距離内で一周期振動する成分である(注:該当走行の速度は約 60km/h である)。コースのカーブの長さは 188m であるため、A9 成分は大体カーブの始点から終点までの距離で 1 回振動する成分に対応する。即ち、道路線形によって決まる周波数成分であり、ドライバのカーブ中の走行特徴(操舵)を含んでいる可能性が高いと言える。

図 3-12 には二人のドライバの操舵角度の生データとウェーブレット分解結果の A9 成分における対照図である。二回分のデータを見ると、A9 成分は大体同じくで、カーブの影響が明確に分かっている。

今までの分析は具体的な例を踏まえて、カーブを通過する時、ドライバ運転挙動の周波数範囲は討論した。基本的にはカーブの長さや走行速度によって道路線形に影響された周波数成分を推算する。つまり、ウェーブレット分解に最低必要な周波数成分が分かる。

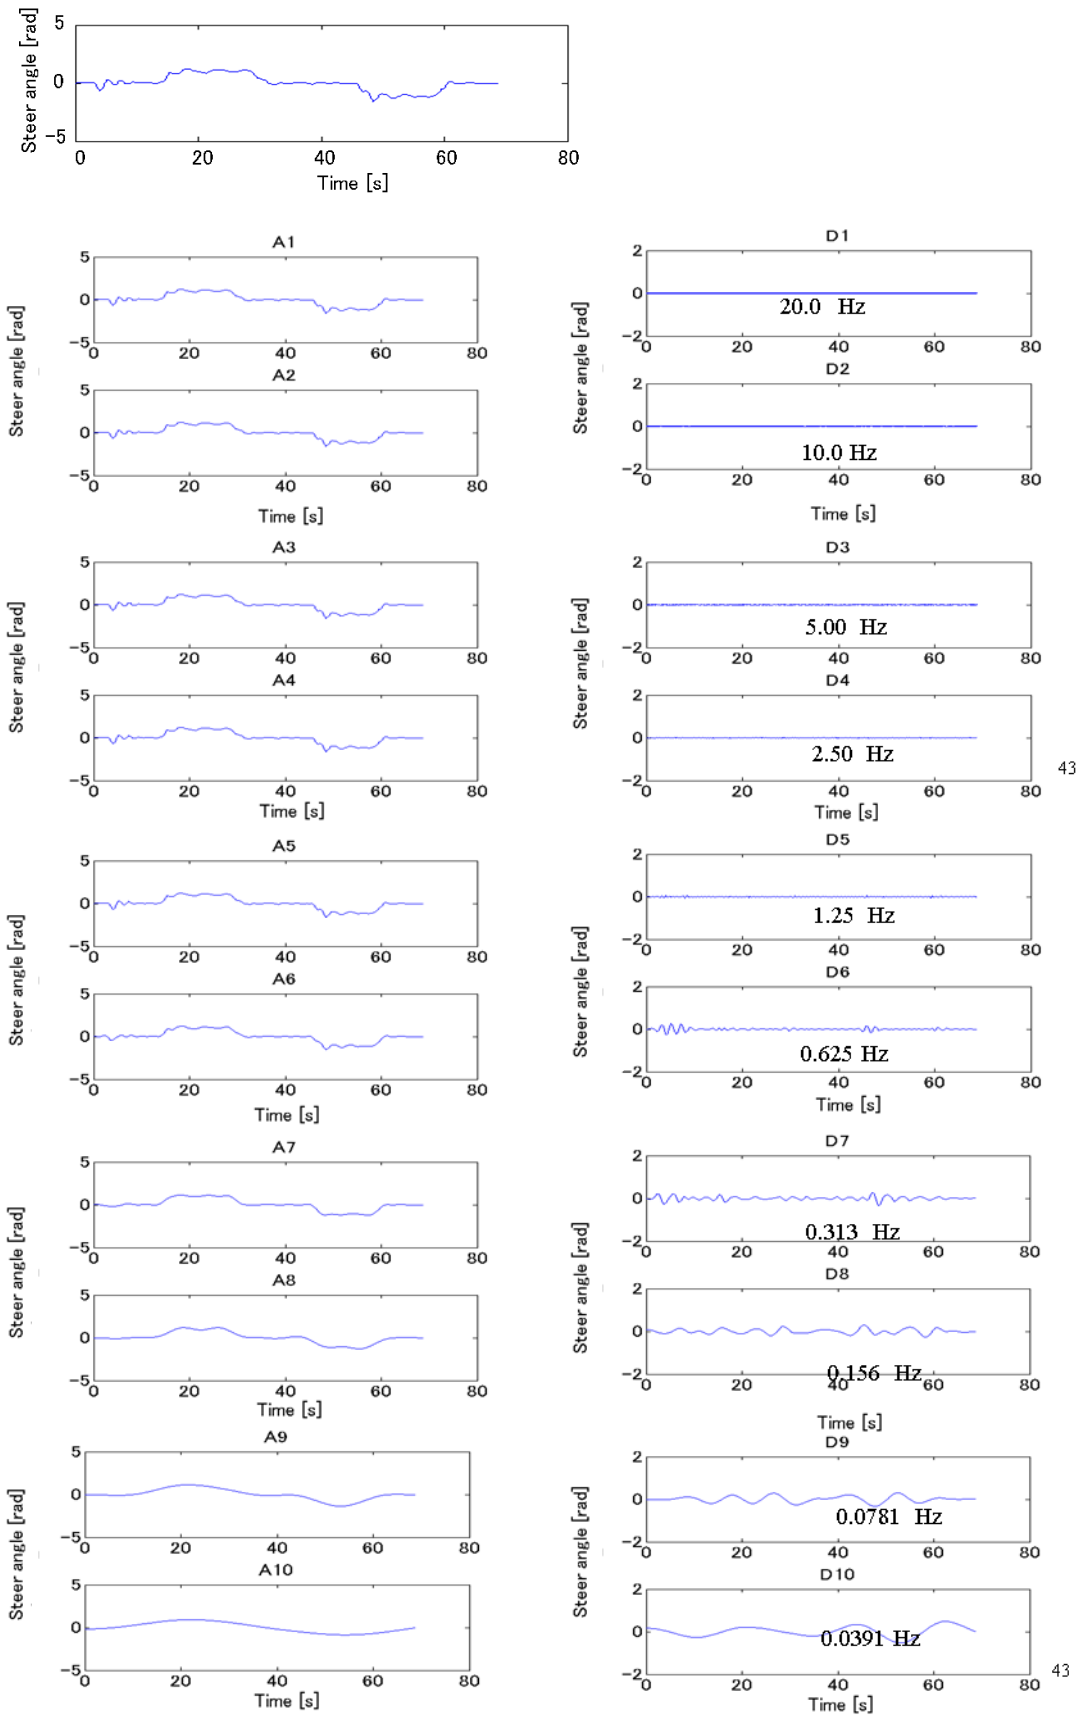


図 3-11(a)ドライバ 1 の操舵角度におけるウェーブレット分解結果




図 3-11(b) ドライバ 2 の操舵角度におけるウェーブレット分解結果

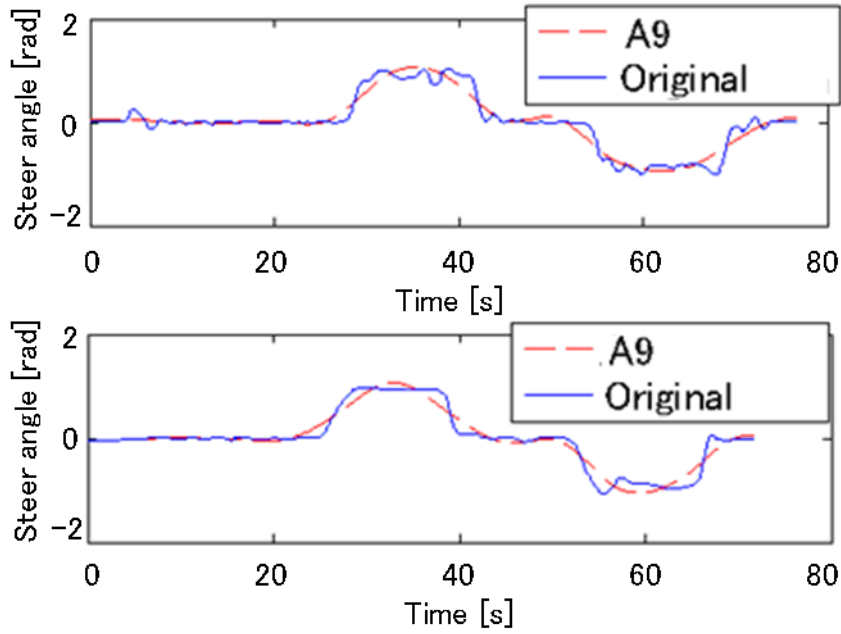


図 3-12 操舵角度とウェーブレット分解の A9 成分の対照図

下記は一般的な例として，該当周波数を決める算式を提案している．

図 3-13 に示しているように，車は速度 v で長さ L のカーブを通過する．A から B まで，1 周期で振動したの成分の周期は L/v である．つまり，最低周波数 f は

$$f = v/L \quad (3-1)$$

によって計算できる．即ち， f より低周波数成分はカーブの距離により長い距離に対応する特徴成分が分かる．




図 3-13 カーブ走行

3.2.3 データの正規化

運転操作は走行コースに依存することから、同じ場所でドライバの操作を比較して、運転の特徴が抽出できると考えている。運転操作データに対して提案手法を適用し、同一の基準で評価、解析するにはデータの正規化が必要である。ここではアクセル踏み量、アクセル踏み速度、ブレーキ踏み量、ブレーキ踏み速度、操舵速度、操舵角度など実験から得られる時刻歴の運転操作データをウェーブレット変換に通って、各周波数成分は線形補間によって走行位置を一定間隔にそろえる正規化を行う。今回の走行コースはカーブと直線の二つの区間を含んでいることから、各区間に対する補間方法は異なる。




図 3-14 データの正規化

まず、カーブでの補間方法を説明する。図 3-14(a)に示す点 A, B は実験から得られる点である。各点に対する円心角度 β は式(3-2)によって計算される。式中(X_i, Y_i)は各点の座標である。

$$\beta_i = \arctan (X_i/Y_i) \quad i = A, B... \quad (3-2)$$

点 C は補間目標点である。例えば点 C の加速度は以下で表される。

$$\begin{aligned} a_c &= (a_B - a_A)(\beta_C - \beta_A)/(\beta_B - \beta_A) + a_A \\ \beta_C &= 0.005 \times N \quad N = 1, 2, \dots \end{aligned} \quad (3-3)$$

式(3-3)において a は各点に対する加速度の値である。角度は実距離 0.3m に対応する中心角度ずつ増加させて全カーブの補間計算を進める。ここで点 A, B は C 点に対して最も近い点である。

直線区間については式(3-4)によって線形補間を行う。なお、 D_{AC} はサンプル点 A と補間目標点 C の直線距離であり、 D_{AB} は点 C の両端の最も近い点 A, B の距離である。

$$\begin{aligned} a_c &= (a_B - a_A) * D_{AC} / D_{AB} + a_A \\ X_C &= 0.3 \cdot N \quad N = 1, 2, \dots \end{aligned} \quad (3-4)$$




図 3-15 正規化前/後のデータ対照例

図 3-15 に正規化した結果の一例を示す。同図左側は時刻歴データ、右側は走行位置を基準に正規化したデータである。横軸は時間から距離になり、ドライバーの同じ場所における運転操作を比べることが可能になる。

3.2.4 候補特徴量

すべての運転操作は短時間 / 区間に発生する。1/60s に採集する 1 サンプルだけでは走行の全データではドライバーの運転特徴を表すことが困難である。したがって、候補の特徴は、ある区間ごとの特性を反映させる必要がある。ここでは、ウェーブレット変換の結果を用いた処理により候補特徴量データを生成する。サイズ窓関数は任意のものを設定できるが、今回は次式のものとする。

$$\tilde{J}_i = \sum_i^{i+15} \bar{J}_i - \sum_{i+16}^{i+30} \bar{J}_i \quad (3-5)$$

式(3-5)の窓関数の概念図 3-16 に示す。この窓関数は連続する 30 サンプルを対象にしたもので、式(4-8)の右辺の第一項は図中の左枠部①のサンプルの和、第二項は右枠部②のサンプルの和で両者の差を算出する。1 サンプルずつ移動させて窓関数処理を行い、候補特徴量データを生成する。




図 3-16 窓関数のコンセプト

熟練者と未熟者の特徴差は潜在するパラメータをすべて候補特徴量に含むため、操舵角度、操舵速度、アクセル踏み量、ブレーキ踏み量、速度のウェーブレット変換の結果を用い、窓関数処

理によって候補特徴量に生成する。予想的には、一定距離内の操作量が突然変化すれば、 J の値は大きくなる。つまり、生成した候補特徴量はドライバ潜在の変化を反映できる。

3.2.5 AdaBoost を用いた特徴量抽出

AdaBoost は多くの単純な識別器(弱関数)選択と組み合わせで強識別器を生成する方法である。弱識別器を選ぶたびに各学習データに重み係数が与えられ、この係数は既に選ばれた $t(t=1,2...T)$ 個の弱関数が間違えたデータの重みを重くし、正解したデータの重みを軽くするよう更新される。 $t+1$ 番目の弱別器は、この重みつき学習エラー値が最小となる、つまり、それより前に選ばれた弱識別器が苦手とするデータに対して頑強なものが選ばれる。この弱識別器の選択と、データの重み更新を T 回繰り返す、最終的に T 個の弱識別器を生成する^[89]。一つの弱識別器は一つ特徴量を抽出しながら、該当特徴量に対して熟練走行と未熟走行の閾値も計算出する。AdaBoost の計算アルゴリズムのイメージを図 3-17 と図 3-18 に示す。まず、特徴量 1 を抽出するイメージを図 3-17 で説明する。

特徴量1を抽出する時:

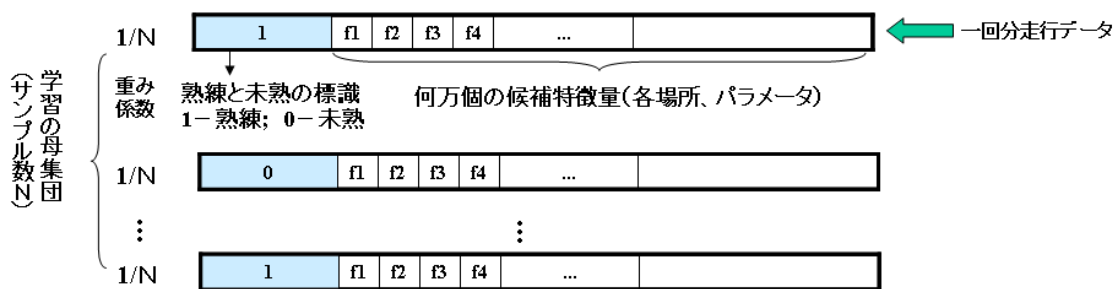


図 3-17 特徴量 1 の抽出イメージ

まず、1 回分の走行には、場所とパラメータ(操舵、アクセル、ブレーキ)など数万個の候補特徴量がある。走行データが仮に N 個あった場合、その全てを用い弱識別器を生成する。式(3-6)に弱識別器を示す。この弱識別器は、ある走行区間における母集団から生成されているため、この母集団以外の新しい複数走行データをこの弱識別器にかけることで、新たな走行と母集団との違いから、新たな走行が熟練か未熟か判断される。識別方法は、図中 $f1$ から順に判断され、一番特徴に違いがあった fn 個目とその走行の特徴量 1 と特徴が出た箇所を示す。

$$h(x) = \begin{cases} 1 & f_i > \theta \\ 0 & \text{others} \end{cases} \quad (3-6)$$

図 3-18 は、特徴 2 を抽出するイメージを示している。まず、前ステップで識別できなかった走行に対する重み係数を調整し、弱識別器に再度かける。識別出きるのは $1/A$, できないのは $1/B$ で $A > B$ である。上記過程を繰り返して、特徴量を抽出していく。1 つの特徴量が 1 つの弱識別器をもつ。すべて弱識別器を組み合わせると、ある走行は熟練か未熟かを判別するモデルが構築

できる.

特徴量2を抽出する時:

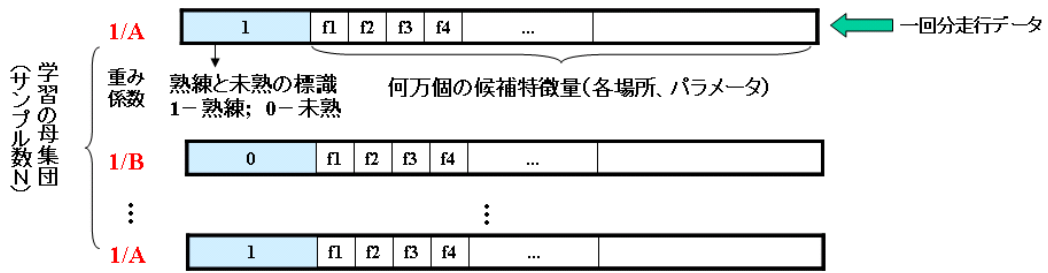


図 3-18 特徴 2 を抽出するイメージ

そして、各特徴量が出る時、特徴 1 と特徴 2 の弱識別器を組み合わせることで母集団全体を識別すると、該当特徴量までで構成されるモデルが熟練と未熟の識別する率が分かる。図 3-19 には該当過程を示している。

i個特徴量を抽出した場合、構築するモデルの識別率

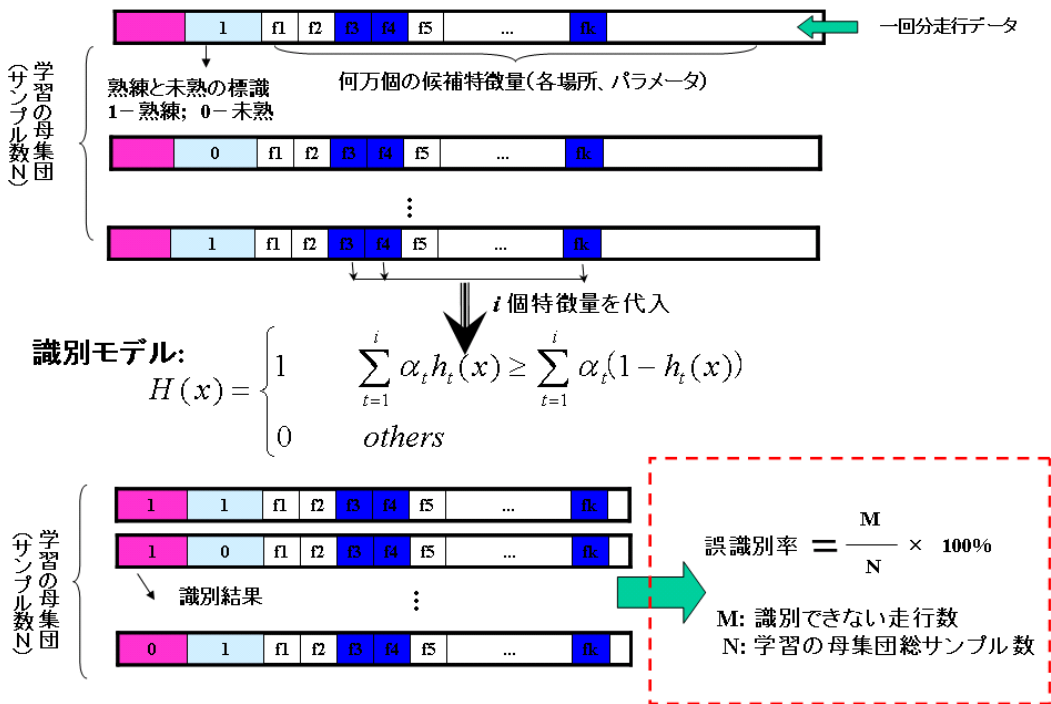


図 3-19 i 個特徴量によって構築したモデルの識別率の確認イメージ

3.3 多曲率カーブ特徴量抽出実験


前節までは、自動車分野にあるビッグデータを重要な背景として、大数ドライバーの運転データを含むビッグデータに基づく、帰納的な手法の観点からの理解と解釈を念頭に置いて、ドライバーの運転特徴の抽出手法を提案した。まず、特徴抽出アルゴリズムの詳細を記述する。全体手法のフローチャートについて述べ、ウェーブレット変換を採用するために必要な各詳細パラメータの設定について検討する。次に、候補特徴量生成するための窓処理について述べ、最後に、AdaBoostによる特徴量抽出の詳細を述べる。

本節では、上記提案手法の確認のため、DSを用いた検証実験の結果について述べる。


3.3.1 実験概要

(1) 車両運転性能を高めた DS


前節までで提案した運転特徴抽出手法を検討するため、DS実験によって必要な運転操作データを取得する。図 3-20 に実験用 DS を示す。



(a) 実験用 DS 全景



(b) 走行シナリオ



(c) 運転席



(d) 動揺装置

図 3-20 実験用 DS

本 DS は応答性を高め、モーションに関するスケールファクターについては本研究の実験ためにロールやヨー、路面不整など実車に限りなく近づけたチューニングがされている。図 3-20(a) は実験走行様子を示している。三つのプロジェクタで構成される投影システムにより、カーブ時の前方視界などをよくしている。図 3-20(c)に示す運転席では普通車両と同じ座席、ハンドル、ブレーキ、アクセル装置を用いている。本 DS は AT 車両のモデルを内蔵しているため、運転キャビンにはギアバーは設置されていない。図 3-20(d)には 6 自由度スチュワートプラットフォームを表している。これで車両運動を模擬し、ドライバにとって現実味を帯びた動きを体感できるようになっている。以下 DS の仕様を詳細に述べる。

(a) 動揺装置

三菱プレジジョン製 MMS-612E2 を使用している。これは、三菱プレジジョン製電動アクチュエータ P8160193 を 6 本、スチュワートプラットフォームに区合わせたものであり、6 自由度の運動が可能である。1 つのアクチュエータは、図 3-21 に動揺装置の外観を示す。アクチュエータの瞬時最大推進力は 21.5kN、最高速度は 333mm/s、可動範囲は 300mm である。



図 3-21 スチュワートプラットフォーム型動揺装置

動揺装置の可動範囲、最大速度、定格加速度を表 3-1 に示す。

表 3-1 動揺装置の可動範囲、最大速度、定格加速度

| | 可動範囲 | 最大速度 | 定格加速度 |
|-----|---------------|---------|-------|
| 前後 | -200mm～+180mm | 300mm/s | 0.5G |
| 左右 | ±190mm | 300mm/s | 0.5G |
| 上下 | -190mm～+230mm | 300mm/s | 0.5G |
| ロール | ±12deg | 20deg/s | |
| ピッチ | -11deg～+12deg | 20deg/s | |
| ヨー | ±11deg | 20deg/s | |

質量は約 1000kg、最大可搬重量は 1500kg であり、寸法は、幅 2600mm、奥行き 2300mm、高

さは 1500mm 以下である。アクチュエータ、制御装置、センサー等の異常が発生した際には、すぐに DS を止められるよう、運転者の手の届く位置、および実験従事者の手の届く位置に非常停止装置が備えられている。また、運転者にはシートベルトの装着を義務付けている。

(b)キャビン

動揺装置のアップフレームを別紙 1 に示す。アップフレームには安全のため柵が取り付けられているが、運転席を取り付けられるように、幅 900mm、長さ 1700mm の空間が空いている。合計 18 箇所 M12(直径 12mm)のボルトとナットで固定される。三菱プレジジョン社の設計の下、可搬重要に対して十分な強度を有している。

図 3-22 に示すキャビン(運転席)を、鉄製の板(幅 900mm、長さ 1700mm)上に取り付け、動揺装置上に定められたボルトによって定められた箇所に固定して取り付けられる。なお運転席は、ミスミ社のアルミフレーム(EFS8-4040)で構成され、座席、ハンドル、アクセルおよびブレーキペダル、3 点式シートベルトが取り付けられている。

座席は、実際の自動車のシートを流用している(トヨタ、プリウス)。ハンドルは、株式会社 JTEKT 社製のステアリングコラムと操舵反力制御装置(E1030103)を使用している。ペダルは、三菱プレジジョン社製のペダルユニットを使用している。運転席後部にはスピーカーを設置し、模擬走行音を出力する。

該当 DS を用いる実験の様子を図 3-23 と図 3-24 に示す。




図 3-22 キャビン



図 3-23 実験風景 1




図 3-24 実験風景 2

(2) 実験コースの設計

本研究はカーブを通過する際のドライバの運転特性を解析することに着目している。カーブの曲率はドライバの運転操作に対して大きな影響がある。本章の実験は、提案する手法が特徴を抽出できるかどうかを検討するため、単純な半径 60m のカーブで検討した。様々なカーブの曲率でドライバの運転操作の影響を評価するため、図 3-25 に示すコースを設計した。本コースは、6つカーブを含んでおり、カーブの曲率も異なる。カーブの半径は 50m, 100m, 200m ごとに長さは 1/8, 1/4 円周である。また、速度調整のためにカーブ間の直線距離を 300m 設けた。今回の走行環境は市街地環境を想定し、その CG 映像のイメージを図 3-26 に示す。

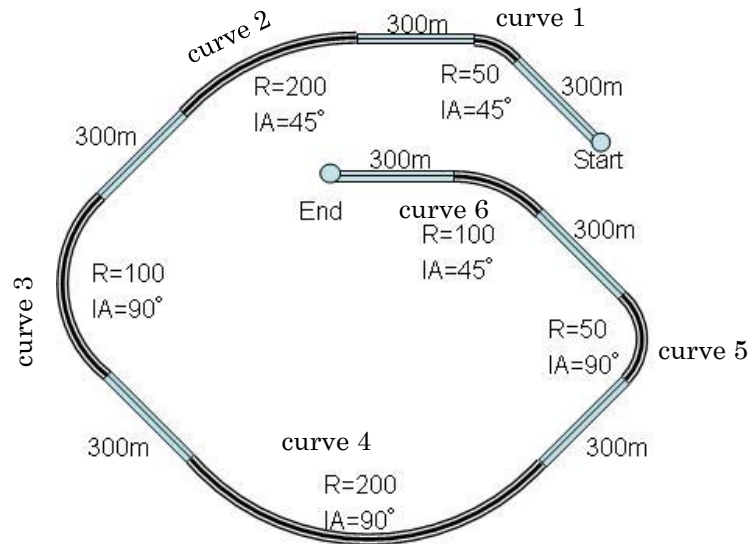


図 3-25 走行コースレイアウト



図 3-26 CG映像のイメージ

3.3.2 実験条件

運転免許を所有する 20～40 代の男女 16 名を被験者として実験を行った。実験では被験者に以下の項目を指示した。

- 1, 基本的には普段と同じように運転
- 2, カーブの進入速度を統一するため, 入り口前 100m, 50m の距離に速度 60km/h の標識を立て, 標識間の 50m で時速 60km/h 前後になるように調整して, カーブに進入してもらう。標識を図 3-27 に示している。
- 3, 走行するにあたり, 道路中央の黄色線を超えないように片側 1 車線で運転することを教示。
- 4, 周囲走行車両はない。
- 5, 最後のカーブを過ぎたら, そのまま走行してもらい, 停止線を過ぎてから左側に寄せて止まってもらう。これは, ドライバが DS をどのような車幅で運転しているのかを見るためである。

る。注:停車始点の標識として横黄色線は最後のカーブ出口から距離 100m にある。

最初の 2 回の走行を練習として上記を確認してもらい、本番のデータとして 10 回走行してもらう。



図 3-27 カーブの入り口前の速度提示標識

3.3.3 実験結果

(1) 運転熟練度の二分化

熟練と未熟練なドライバーの分類は複雑なテーマの一つである。着目点によっては、分類指標と結果は当然異なってしまう。指標としては、ヨーレート、操舵角度、速度、ジャークなど様々な分類指標がある。ここで提案方法は、複数の指標を統合して考える。例えば、ある走行はヨーレートが小さく、操舵操作が小さく、かつスムーズで速度も速いのが本当に熟練者の運転と考える。しかし、指標の個数が増えると熟練走行と未熟練走行の選択条件が益々厳しくなり、条件を満たす走行データも減り、学習サンプルの数がかかなり少なくなってしまう。当然、学習サンプルが十分多く、分類指標が多いほど方が良い。

熟練者と未熟練者の分類指標は合成ジャークだけで見ると、学習するサンプルの熟練走行は平均速度が低くになってしまう可能性が高い。今回、学習のサンプル数に限り、同じ速度で、合成ジャークの累積値は小さいほうが熟練という点を念頭において、下記に合成ジャークと速度の二つの指標を用いて、熟練走行と未熟練走行を分類する手法を提案される。




図 3-28 平均速度と合成ジャークの累積値の回帰直線

図中の太い実線の直線は V と J の回帰直線の結果である。同じ速度で J の値が小さい走行は熟練であることを原則として、直線右下部分の点に対応する走行は熟練である。例えば、点線縦楕円 A と C のプロットデータは速度がほぼ同じで J の値の差が大きい。つまり、同じ速度で走行していても J の値により熟練と未熟練を分類し、点線楕円 B と C を比べると C の方が J の値が大きいこれは速度が速いためのもので、点線楕円 B と C 内の走行は熟練となる。

また、図 3-28 の実線楕円内の二つ走行を見ると、該当 2 回の走行はそんなに大きな差がない。つまり、回帰直線に近い点に対する走行は、ほぼ同じ速度で、合成ジャークもほぼ同じになることから、熟練と未熟練が曖昧となる。そこで、図 3-28 に太破線で示す領域を設け、この点線の間に置ける走行回数は全走行回数の 20% として、この間の走行のデータは捨てて、残り 80% から熟練と未熟練のグループの学習母集団を作る

(2)各カーブの運転熟練度の二分化と考察

上記の実験によって、16 人分 160 回走行データをデータベースとする。第 3.3 節に述べる熟練と未熟練の分類手法を適用して、6 か所のカーブごとの結果を記述する。まず、各カーブの形状を表 3-2 に示す。

表 3-2 カーブの情報統計

| カーブ番号 | 半径[m] | 円心角度[deg] | 長さ[m] |
|-------|-------|-----------|-------|
| 1 | 50 | 45 | 39.25 |
| 2 | 200 | 45 | 157 |
| 3 | 100 | 90 | 157 |
| 4 | 200 | 90 | 314 |
| 5 | 50 | 90 | 78.5 |
| 6 | 100 | 45 | 78.5 |

今回の計算に用いるデータは、カーブの入り口の 50m 手前からカーブ出口後 50m のデータを用いている。カーブ 1 を例として挙げ、図 3-29 に計算距離を示す。




図 3-29 カーブ 1 の計算距離

合成ジャークの累積値と平均速度の回帰直線は、図 3-30 に示す通りである。中央 20%の曖昧部分を検出するため、回帰直線は両側に平行偏移されている。偏移量はカーブによって異なり、図中に偏移量を記載する。ドライバごとの熟練、未熟練と判断された結果を表 3-3 まとめる。カーブ 1 においては、全 160 回走行のデータベースから 128 回選ばれた。その中に熟練走行 75 回、未熟練走行 52 である。表 3-3 の個別ドライバの結果を見ると、ドライバ 1 は全 10 回走行中 8 回が未熟練になり熟練の走行がなく、残る 2 回は熟練と未熟練の曖昧部分に入ってしまった。同じ形式でカーブ 2~6 の結果も図 3-31 から図 3-35、表 3-4 から表 3-8 に示す。




図 3-30 カーブ 1 の熟練走行と未熟走行の分類

表 3-3 カーブ 1 で熟練走行と未熟走行の二分化結果

| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
|------|---|----|---|---|---|----|---|----|---|----|----|----|----|----|----|----|----|
| 熟練 | 0 | 10 | 2 | 5 | 3 | 10 | 1 | 10 | 0 | 0 | 2 | 4 | 10 | 4 | 5 | 9 | 75 |
| 未熟 | 8 | 0 | 4 | 3 | 0 | 0 | 8 | 0 | 8 | 9 | 4 | 4 | 0 | 2 | 2 | 0 | 52 |




図 3-31 カーブ 2 の熟練走行と未熟走行の分類

表 3-4 カーブ 2 で熟練走行と未熟走行の二分化結果

| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
|------|---|---|---|---|---|----|---|----|---|----|----|----|----|----|----|----|----|
| 熟練 | 0 | 9 | 7 | 1 | 4 | 10 | 1 | 10 | 3 | 0 | 3 | 8 | 4 | 6 | 4 | 8 | 78 |
| 未熟 | 8 | 1 | 1 | 2 | 4 | 0 | 9 | 0 | 5 | 10 | 6 | 1 | 1 | 2 | 0 | 0 | 50 |




図 3-32 カーブ 3 の熟練走行と未熟走行の分類

表 3-5 カーブ 3 で熟練走行と未熟走行の二分化結果

| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
|------|---|---|---|---|---|----|---|----|---|----|----|----|----|----|----|----|----|
| 熟練 | 0 | 7 | 7 | 1 | 2 | 10 | 1 | 10 | 3 | 0 | 3 | 5 | 9 | 5 | 3 | 9 | 75 |
| 未熟 | 8 | 0 | 0 | 6 | 6 | 0 | 9 | 0 | 2 | 10 | 4 | 3 | 0 | 2 | 1 | 0 | 51 |




図 3-33 カーブ 4 の熟練走行と未熟走行の分類

表 3-6 カーブ 4 で熟練走行と未熟走行の二分化結果

| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
|------|---|---|---|---|---|----|---|----|---|----|----|----|----|----|----|----|----|
| 熟練 | 1 | 9 | 9 | 2 | 6 | 10 | 1 | 10 | 7 | 0 | 5 | 2 | 4 | 1 | 0 | 10 | 77 |
| 未熟 | 7 | 1 | 0 | 2 | 4 | 0 | 8 | 0 | 1 | 10 | 3 | 4 | 0 | 4 | 7 | 0 | 51 |




図 3-34 カーブ 5 の熟練走行と未熟走行の分類

表 3-7 カーブ 5 で熟練走行と未熟走行の二分化結果

| | | | | | | | | | | | | | | | | | |
|------|---|---|---|---|---|----|---|----|---|----|----|----|----|----|----|----|----|
| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
| 熟練 | 0 | 7 | 3 | 3 | 2 | 10 | 3 | 10 | 0 | 0 | 3 | 5 | 9 | 7 | 5 | 8 | 75 |
| 未熟 | 8 | 1 | 4 | 4 | 4 | 0 | 7 | 0 | 9 | 9 | 2 | 2 | 0 | 1 | 1 | 1 | 53 |




図 3-35 カーブ 6 の熟練走行と未熟走行の分類

表 3-8 カーブ 6 で熟練走行と未熟走行の二分化結果

| | | | | | | | | | | | | | | | | | |
|------|---|----|---|---|---|----|---|---|---|----|----|----|----|----|----|----|----|
| ドライバ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 総 |
| 熟練 | 0 | 10 | 5 | 2 | 0 | 10 | 1 | 9 | 3 | 0 | 2 | 6 | 9 | 8 | 8 | 7 | 80 |
| 未熟 | 8 | 0 | 3 | 5 | 6 | 0 | 9 | 0 | 3 | 9 | 2 | 1 | 0 | 0 | 1 | 0 | 47 |

全体的に見ると、ドライバ 2, 6, 8, 13, 16 の走行は熟練走行として学習データに選択される。表 3-9 を見ると、運転歴が長いか運転頻度が高いドライバのデータが熟練走行として選ばれていることが分かる。

表 3-9 ドライバの運転頻度情報

| NO. | License Acquired Period | Driving Frequency | NO. | License Acquired Period | Driving Frequency |
|-----|-------------------------|-------------------|-----|-------------------------|-------------------|
| 1 | 4 years | 0 | 9 | 3.5 years | 1 |
| 2 | 20 years | 5 | 10 | 6 years | 0.5 |
| 3 | 19 years | 0.2 | 11 | 3years | 1 |
| 4 | 3 years | 1 | 12 | 3years | 4 |
| 5 | 10 years | 0.4 | 13 | 24years | 20 |
| 6 | 11 years | 8 | 14 | 1years | 1 |
| 7 | 4 years | 0.5 | 15 | 5years | 0.1 |
| 8 | 7 years | 7 | 16 | 13years | 1 |

*unit: times/month

(3)特徴抽出結果


運転操作データに対して修正した提案手法を適用し、これからカーブごとに解析した結果をまとめる。表 3-10 に候補特徴量の種類を記載する。候補特徴量については二種類に分類している。一つはドライバの操作量を反応する物理量である。これらは周期特徴が持っているので、全てのデータを違い周波数成分に分解して、候補特徴量を作る。もう一つは、車の状態量が採用されている。例えば、走行中の横変位など。該当種類の物理量は周波数成分が意味を持っていないので、正規化したデータから直接候補特徴量を作る。今回、学習の条件は AdaBoost の識別率が 100%に達すると特徴抽出を終えるように設定している。

表 3-10 候補特徴量生成するパラメータ


| 操作量 | | 状態量 | |
|-----|----------------|-----|----------------------------|
| 番号 | 変数名 | 番号 | 変数名 |
| 1 | 操舵速度 [rad/s] | 1 | 車速 [km/h] |
| 2 | 操舵角度 [rad] | 2 | 横変位 [m] |
| 3 | アクセル踏み速度 [%/s] | 3 | 前後ジャーク [m/s ³] |
| 4 | アクセル踏み込み量 [%] | 4 | 左右ジャーク [m/s ³] |
| 5 | ブレーキ踏み速度[m/s] | | |
| 6 | ブレーキ踏み量 [m] | | |

特徴抽出された結果を図 3-36 に示すカーブ 1 の結果を例に説明する。図 3-36(a)は AdaBoost アルゴリズムによって抽出される特徴数と学習グループの誤識別率関係である。図 3-36(a)の横軸は各特徴の弱識別器の数で、縦軸が弱識別器により判断されない確率に相当する。つまり、横軸 1 個目は特徴 1 の弱識別器だけを用いると誤識別率は 24%(76%で識別できる)、弱識別器 9 を組み合わせて用いることで、母集団を 3%の誤差(97%で判断できる)で判別できることを意味する。今回の学習は 100%の閾値を設定しているため、抽出される結果の特徴量の上位 11 個で 100%以上の認識率に達する。該当 11 個の特徴量に対する場所を図 3-36(b)に示す。各特徴量の情報を表 3-11 に記載する。

特徴量 1 はカーブの始点から 82.8m、即ち入り口前直線部分の 50m の所から 82.8m 地点で「横変位」に熟練者と未熟練者の操作量の違いとして特徴量が抽出されたことになる。他のカーブの結果も図 3-37 から図 3-41、表 3-12 から表 3-16 に記述されている。詳細的な考察は、次節で述べる。



(a) 弱関数(特徴数)と識別率の関係図(カーブ 1)




(b) 特徴抽出した場所

図 3-36 カーブ 1 に抽出された特徴量


表 3-11 カーブ 1 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|--------|---------------|------------|---------|------|
| 1 | 横変位 | 82.8 | - | 3.9374 | 大きい |
| 2 | 速度 | 72.9 | - | 46.8216 | 大きい |
| 3 | 横変位 | 49.8 | - | -1.0836 | 小さい |

| | | | | | |
|----|----------|-------|-------|---------|-----|
| 4 | アクセル踏み速度 | 83.1 | 2.5 | -5.1986 | 小さい |
| 5 | ブレーキ踏み量 | 75.3 | 0.625 | 0 | 小さい |
| 6 | アクセル踏み量 | 128.7 | 5 | -0.0002 | 小さい |
| 7 | アクセル踏み量 | 71.1 | 0.313 | 2.2412 | 大きい |
| 8 | 横変位 | 87 | - | 4.4415 | 大きい |
| 9 | アクセル踏み量 | 11.1 | 1.25 | -3.1444 | 大きい |
| 10 | ブレーキ踏み量 | 2.7 | 5 | 0 | 大きい |
| 11 | 横変位 | 128.4 | - | 2.0081 | 小さい |



(a) 弱関数(特徴数)と識別率の関係図(カーブ 2)




(b) 特徴抽出した場所


図 3-37 カーブ 2 に抽出された特徴量

表 3-12 カーブ 2 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|----------|---------------|------------|---------|------|
| 1 | 横変位 | 199.2 | - | 2.9764 | 大きい |
| 2 | ブレーキ踏み量 | 54.6 | 0.313 | 0 | 大きい |
| 3 | アクセル踏み速度 | 49.5 | 5 | -0.2849 | 大きい |
| 4 | アクセル踏み量 | 51.3 | 2.5 | 0.0312 | 大きい |
| 5 | 操舵角度 | 110.4 | 0.084 以下 | -0.3344 | 大きい |
| 6 | ブレーキ踏み量 | 48.6 | 0.084 以下 | 0.004 | 小さい |
| 7 | 横変位 | 38.7 | - | 0.5951 | 小さい |



(a) 弱関数(特徴数)と識別率の関係図(カーブ 3)




(b) 特徴抽出した場所


図 3-38 カーブ 3 に抽出された特徴量

表 3-13 カーブ 3 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|----------|---------------|------------|---------|------|
| 1 | 横変位 | 222 | - | 0.9007 | 大きい |
| 2 | 横変位 | 54.3 | - | 1.5653 | 小さい |
| 3 | 横変位 | 179.1 | - | 1.7372 | 大きい |
| 4 | 操舵速度 | 166.2 | 2.5 | -0.1068 | 大きい |
| 5 | アクセル踏み量 | 92.1 | 5 | 0.0219 | 小さい |
| 6 | 操舵速度 | 191.4 | 1.25 | -0.4918 | 小さい |
| 7 | 横変位 | 205.2 | - | 3.0789 | 大きい |
| 8 | アクセル踏み速度 | 196.2 | 5 | 0.3341 | 大きい |



(a) 弱関数(特徴数)と識別率の関係図(カーブ 4)

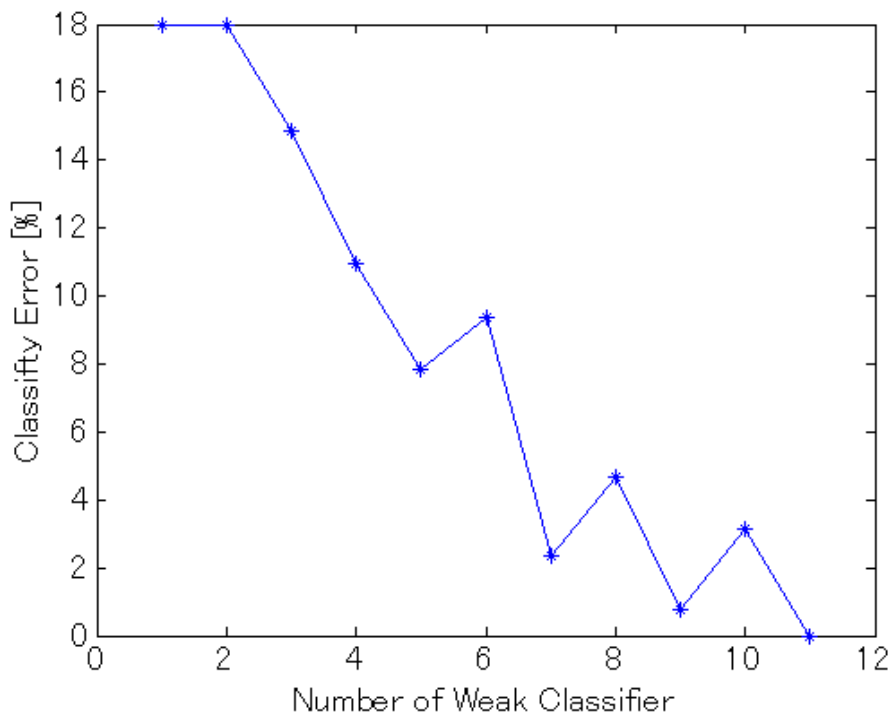


(b) 特徴抽出した場所


図 3-39 カーブ 4 に抽出された特徴量

表 3-14 カーブ 4 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|----------|---------------|------------|---------|------|
| 1 | 横変位 | 356.4 | - | 2.8231 | 大きい |
| 2 | ブレーキ踏み量 | 204 | 0.039 以下 | 0.0006 | 小さい |
| 3 | 操舵速度 | 17.1 | 0.313 | -0.1083 | 大きい |
| 4 | 操舵速度 | 312 | 1.25 | -0.1494 | 大きい |
| 5 | アクセル踏み速度 | 40.2 | 0.084 | -1.8370 | 大きい |
| 6 | 操舵速度 | 375 | 2.5 | 0.0718 | 大きい |
| 7 | 横変位 | 258.6 | - | 1.3608 | 大きい |
| 8 | 操舵速度 | 141.3 | 0.039 以下 | -0.0056 | 大きい |
| 9 | 操舵角度 | 46.8 | 0.156 | 0.2138 | 小さい |
| 10 | アクセル踏み速度 | 54 | 5 | 0.2807 | 小さい |
| 11 | 横変位 | 356.1 | - | 2.9393 | 大きい |



(a) 弱関数(特徴数)と識別率の関係図(カーブ 5)




(b) 特徴抽出した場所


図 3-40 カーブ 5 に抽出された特徴量

表 3-15 カーブ 5 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|----------|---------------|------------|---------|------|
| 1 | 横変位 | 140.1 | - | 2.0739 | 大きい |
| 2 | アクセル踏み量 | 94.8 | 0.313 | -0.1731 | 大きい |
| 3 | 操舵角度 | 130.2 | 0.313 | -1.0340 | 大きい |
| 4 | アクセル踏み速度 | 45.3 | 2.5 | 0.7606 | 小さい |
| 5 | アクセル踏み量 | 22.2 | 5 | 0.0010 | 小さい |
| 6 | アクセル踏み量 | 5.1 | 0.156 以下 | 15.615 | 小さい |
| 7 | アクセル踏み速度 | 79.8 | 5 | -0.5914 | 小さい |
| 8 | 前後ジャーク | 115.5 | - | -1.3488 | 大きい |
| 9 | アクセル踏み速度 | 26.1 | 0.156 以下 | -1.7471 | 大きい |
| 10 | アクセル踏み量 | 88.8 | 0.313 | -6.3653 | 大きい |
| 11 | 横変位 | 46.2 | - | -2.9846 | 小さい |



(a) 弱関数(特徴数)と識別率の関係図(カーブ 6)



(b) 特徴抽出した場所
 図 3-41 カーブ 6 に抽出された特徴量

表 3-16 カーブ 6 における抽出した特徴量

| 番号 | 特徴量の名前 | カーブ始点からの距離[m] | 中央周波数 [Hz] | 閾値 | 熟練の方 |
|----|----------|---------------|------------|---------|------|
| 1 | 横変位 | 135.6 | - | 1.4064 | 大きい |
| 2 | ブレーキ踏み量 | 77.4 | 1.25 | 0 | 小さい |
| 3 | 横変位 | 118.5 | - | 2.8951 | 大きい |
| 4 | アクセル踏み速度 | 8.7 | 0.156 | -4.6736 | 大きい |
| 5 | 横変位 | 44.1 | - | 0.2679 | 小さい |
| 6 | アクセル踏み量 | 40.8 | 1.25 | 0.1012 | 小さい |
| 7 | アクセル踏み量 | 136.2 | 2.5 | 0.0373 | 小さい |
| 8 | 操舵角度 | 96.6 | 5 | -0.0002 | 大きい |
| 9 | 横ジャーク | 167.4 | - | -2.0832 | 大きい |

3.3.4 実験結果の考察

(1) 抽出された運転特徴の分析

前節は、各カーブで特徴抽出された結果を記述した。本節はこれらについて考察を展開する。

まず例として、カーブ 1 で抽出された結果の分析方法を述べる。特徴量 1 はカーブ出口の近くにおける横変位である。図 3-42 には母集団総 127 回走行における該当成分のデータを示している。上側は熟練者のデータであり、下側は未熟練者のデータである。図中縦の点線の区間が今回抽出された特徴量に対応する場所である。窓のサイズから 30 サンプル(実際距離 9m に対応する)を取って、左半分の和と右半分の和の差が大きいパラメータが該当窓の特徴量として採用される。表 3-11 に記載されているように、熟練者は該当場所で特徴量が 3.9m より大きい。つまり該当距離内、熟練なドライバは前半と後半の差が大きく、即ち道路のセンターラインに早めに接近していることが分かる。




図 3-42 カーブ 1 の横変位の一部

図 3-43 には、特徴量 1 に対応する候補特徴量の分布を示している。熟練走行の全 75 回走行に対する値を昇順に並べ替えてプロットしている。未熟練走行は水平の青直線は今回抽出される特徴量の閾値である。閾値より大きい走行が熟練者となる。図中の楕円 A の熟練走行と楕円 B 未熟練走行は、特徴量 1 を抽出する際、閾値以下となるため、ここの部分は認識されない。AdaBoost のアルゴリズムから、特徴量 2 を抽出する時、楕円 A と B に対する重みを与え(重み係数をかける)調整して、この部分が区別できる候補特徴量が優先的に選ばれる。この過程を繰り返して、全ての走行における特徴量が抽出されていく。

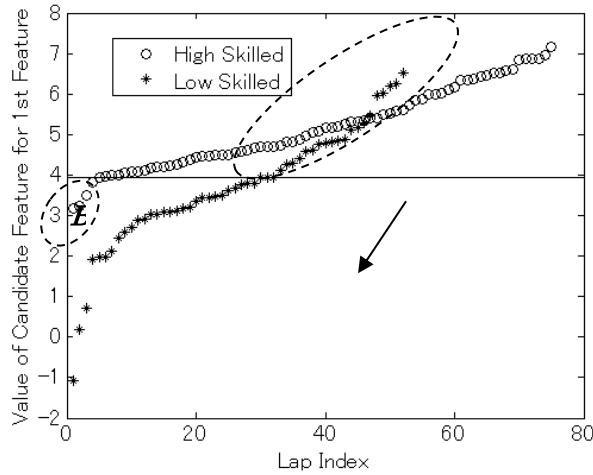


図 3-43 カーブ 1 の特徴量 1 の候補特徴量分布

(2) 抽出された特徴量の場所に関する検討

次に特徴量が抽出された場所の分布特徴を分析する. 熟練と未熟練なドライバーはどこに運転操作特徴の差が生じるのかを検討するために, カーブを図 3-44 のように分割する. 各カーブを入口と出口の 50m 部分をそれぞれ AB 区間, EF 区間とし, カーブを BC, CD, DE 区間として三等分し, 一つのカーブを全五分割に分ける. 各段に抽出された特徴量を表 3-17 に示している.




図 3-44 カーブの分段化

表 3-17 各範囲で抽出される特徴量個数(単位:個)

| 範囲 | AB | BC | CD | DE | EF |
|-------|----|----|----|----|----|
| カーブ 1 | 3 | 0 | 3 | 3 | 2 |
| カーブ 2 | 3 | 2 | 1 | 1 | 0 |
| カーブ 3 | 0 | 2 | 0 | 5 | 1 |
| カーブ 4 | 3 | 2 | 2 | 3 | 1 |
| カーブ 5 | 5 | 0 | 3 | 1 | 2 |
| カーブ 6 | 3 | 0 | 2 | 1 | 3 |
| 総 | 17 | 6 | 11 | 14 | 9 |

表 3-17 のデータを見ると、AB 段と DE 段は抽出された特徴数が多くて、つまり出口と入り口部分で熟練と未熟練ドライバの運転特徴に差が生じやすい。

個別に見ると、カーブ 5 は半径が小さく、円心角度が大きい。該当カーブに進入と退出部で熟練者と未熟者の特徴差が明確である。該当部分の運転技量の向上を促すことで、運転支援につなげられるとことを示唆している。

各カーブで抽出された特徴量種類の分布を表 3-18 にまとめる。操舵、アクセル、ブレーキで分類すると、操作量が全体的にはアクセルの操作に関する特徴量が多い。また状態量の横変位、車速、ジャークを見ると、横変位が一番代表的な特徴差といえる。つまり、本コースで熟練者と未熟練者の操舵とアクセル操作の差が大きい。状態に言えば、横変位の特徴差が明確なので、熟練と未熟のドライバは路線の選択も違い、今回は分類指標の中に合成ジャークと車速が用いた。しかして、熟練と未熟の特徴差が少なく出ている。表 3-19 に抽出された特徴量をカーブの範囲でまとめたものを示す。結果を読みやすいために、図 3-44 に表の内容を纏める。結果によると、AB 間はアクセルと横変位に特徴が多く出ている。従って、この区間内に速度の調整に関する操作は、熟練と未熟のドライバに明確な特徴差が存在する。特に、アクセル操作を見ると、カーブの進入と出口で熟練と未熟練の差が大きい。操舵角度は、BC 内で特徴差が明確的に存在している。横変位は AB,DE,EF 三段に集中しているが、即ちカーブ出口付近で横変位と操舵の特徴量が多く、カーブの入口と出口付近で熟練者と未熟練者の特徴の差が顕著に出ることが分かった。

表 3-18 カーブごとに各種特徴量の抽出される個数

| | 操舵 | アクセル | ブレーキ | 横変位 | 車速 | ジャーク |
|-------|----|------|------|-----|----|------|
| カーブ 1 | 0 | 4 | 2 | 4 | 1 | 0 |
| カーブ 2 | 1 | 2 | 2 | 2 | 0 | 0 |
| カーブ 3 | 2 | 2 | 0 | 4 | 0 | 0 |
| カーブ 4 | 5 | 2 | 1 | 3 | 0 | 0 |
| カーブ 5 | 1 | 7 | 0 | 2 | 0 | 1 |
| カーブ 6 | 1 | 3 | 1 | 3 | 0 | 1 |
| 総 | 10 | 20 | 6 | 18 | 1 | 2 |

表 3-19 カーブごとで各種特徴量の抽出される個数

| | AB | BC | CD | DE | EF |
|-----------|----|----|----|----|----|
| 操舵角度 | 1 | 0 | 2 | 0 | 1 |
| 操舵速度 | 1 | 1 | 0 | 3 | 1 |
| アクセル踏み込み量 | 4 | 2 | 3 | | 2 |
| アクセル踏み速度 | 5 | 1 | 1 | 2 | 0 |
| ブレーキ踏み量 | 2 | 2 | 2 | 0 | 0 |
| ブレーキ踏み速度 | 0 | 0 | 0 | 0 | 0 |
| 横変位 | 4 | 1 | 1 | 8 | 4 |
| 車速 | 0 | 0 | 1 | 0 | 0 |
| 前後ジャーク | 0 | 0 | 0 | 1 | 0 |
| 横ジャーク | 0 | 0 | 0 | 0 | 1 |




図 3-45 各区間に抽出された各種特徴量

(3) 抽出された特徴量の例

本節にはカーブ 1 で抽出された結果に代表的な例を選択して、抽出された特徴量の具体的な意味を述べる。

表 3-11 にリストされたカーブ 1 で抽出されたアクセル踏み量(7 番)のデータを図 3-46 に示す。熟練と未熟練の走行に対して各二回走行を例として挙げる。図中縦線は前章に記述された窓関数区間となり、この区間が特徴量として抽出された。該当場所はカーブ中心部であり、熟練者

と未熟練者も加速している。しかし、熟練者はアクセル踏み量がスムーズに変化しているのに対して、未熟練者はアクセルを複数回踏み込んでおり、躊躇しながら操作している様子が分かり、この差が特徴量として本手法で抽出され、なぜ抽出されたか同図の生データから確認できる。






図 3-46 アクセルに関する抽出された特徴量

図 3-45 からカーブ入出口で横変位における状態量の差が明確的に存在することが分かる。表 3-11 のカーブ 1 における特徴量 1 と 3 は図 3-47 を見ると、カーブの出口と入口で抽出される特徴量である。図 3-47 は二つの特徴量に対する正規化後の生データを示している。特徴量 1 はカーブの出口であり、図 3-47 (a) に代表的な 6 回分の走行のデータを示している。表 3-11 によると、該当場所の特徴量が大きい方、つまり図中点線の二つ枠において、左半分の和と右半分の和の差が大きい方が熟練である。即ち、熟練者はセンターラインに接近し、早めに安定走行している。未熟練者は未だ道路の左側壁に接近している。同様に分析すると、図 3-47 (b) に示している特徴量 3 はカーブの入口であり、熟練者は早めに道路の側壁に接近してカーブに進入することが分かる。他の 5 つのカーブを分析すると同様の傾向であった。つまり、熟練者と未熟練者はカーブの出入口で選択した走行戦略が異なる。該当する特徴に対して運転操作の目標値としてアドバイスを行うことで、運転技量の向上につなげられるということを示唆するものである。



(a) 1st Feature



(b) 3rd Feature

図 3-47 横偏位に関わる特徴量

3.3.5 熟練と未熟練走行の判別モデル

(a) 判別モデルの紹介

AdaBoost アルゴリズムは特徴量抽出の上で分類器も構築できる。分類器表 2 に示しているカーブ 1 において抽出された特徴量を例として概要的に紹介致す。前述のようにカーブ 1 の学習母集団に 127 回走行データがあり、学習結果によると、母集団の熟練と未熟練走行を確り分けるためには 12 個特徴量が必要である。つまり、熟練走行と未熟練走行の分類器は 11 個弱識別器によって組み合わせることである。弱分類器は特徴量と閾値を含んで、また学習過程に各弱分類器に対応する一つの係数を生じる。弱分類器分類器と対応する係数によって熟練と非熟練走行の分類器を構築する。カーブ 1 の走行データを該当分類器に入れて、熟練と未熟練を判別できる。

(b) Leave-one-out 方法で分類器の識別率の検定

分類器の識別率を検討するために、母集団に多くの走行回数を必要としない leave-one-out という交差検定方法を採用する。例えば、上記のカーブ 1 の場合、母集団に 127 回走行データがあり、毎回 126 だけ使って、分類器を学習して、残る 1 回はテストデータとして分類器を検証する。全 127 回学習とテストが終わったら、正しく識別した回数と総回数の比は識別率と呼ばれる。カーブごとで同じように識別率を検討して、母集団の構成と識別結果は表 3 に記載している。

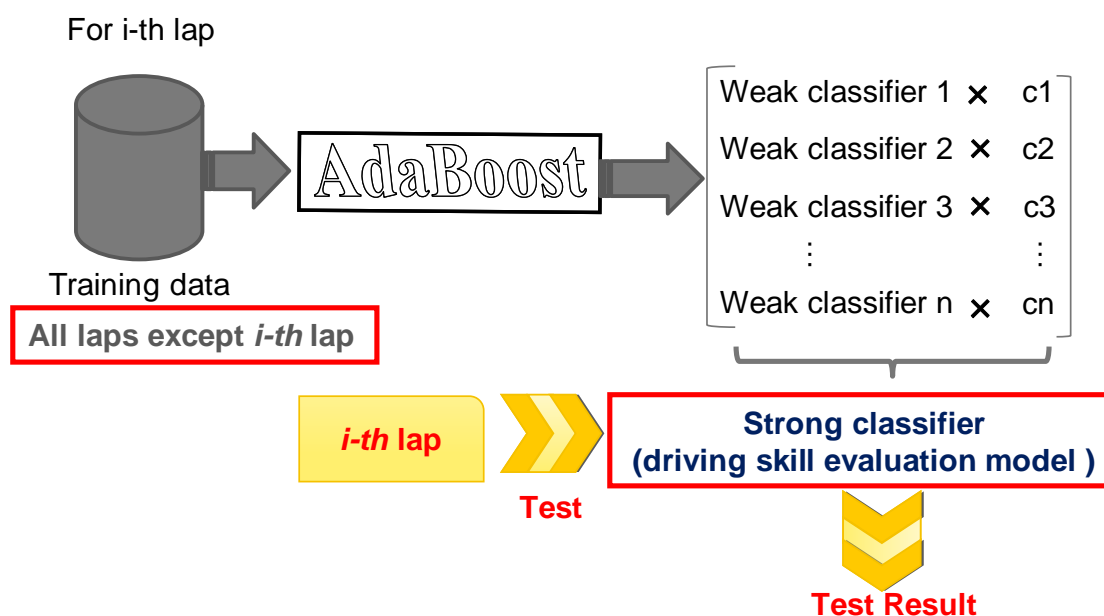


図 3-48 Leave-one-out 方法で分類器の識別率の検定

(c) 結果と考察

表 3-20 に示している結果を見ると、ほぼ 6-7 割の識別率になる。該当手法によって、熟練と未熟練走行の識別器を生成可能な見通しを得た。今後は提案手法によって構築された識別器とモデルの構築方法について再度検討、精度よく識別器を構築するための候補特徴量データの生成方法、或いは判別機の構築アルゴリズムを改善することの検討などを進める。

表 3-20 各カーブの検定結果

| Curve | 1 | 2 | 3 | 4 | 5 | 6 |
|--------------|-------|-------|-------|-------|-------|-------|
| High Skilled | 75 | 78 | 75 | 77 | 75 | 80 |
| Low Skilled | 52 | 50 | 51 | 51 | 53 | 47 |
| Total | 127 | 128 | 126 | 128 | 128 | 127 |
| Accuracy | 0.693 | 0.703 | 0.754 | 0.750 | 0.602 | 0.669 |

3.4 アドバイス実験

ここまで、本論文はカーブ走行に着目して、熟練運転者と未熟練の操作特徴差を抽出された。次世代自動車に向けて、色々な実用可能な場面がある。例えば、運転支援システムにドライバのスキル判別モデルを導入し、運転者のスキルに応じてシステムのパラメータを適合する。さらに安全性と快適性を向上させることができる。カーブの出入口で有用な情報の提示熟練ドライバの走行特徴に基づく自動運転システムの制御システムの構築できる。

本論文では熟練者と未熟練者でどの場所でどのような操作に違いがあるかが抽出された。本節は、研究成果の実用の例の一つとして、これを未熟練ドライバに教示することで、運転技量の向上できると検討する。

3.4.1 実験概要

第 3.3 節で記述された手法により抽出された特徴量に対して、非熟練者にアドバイスを提供し、ドライバの運転技量の変化を検討するための実験を行う。今回の実験は第 3.3 節に記述された実験結果に基づいて、ドライバ 1, 3, 5, 9, 10, 11, 12, 14 と 15 を含んだ 10 名のドライバを対象として実験を行う。第 3.3 節で提案された熟練度の二分化手法を応用して、図 3-49 に 10 名ドライバの第 3.3 節の実験結果を記載している。

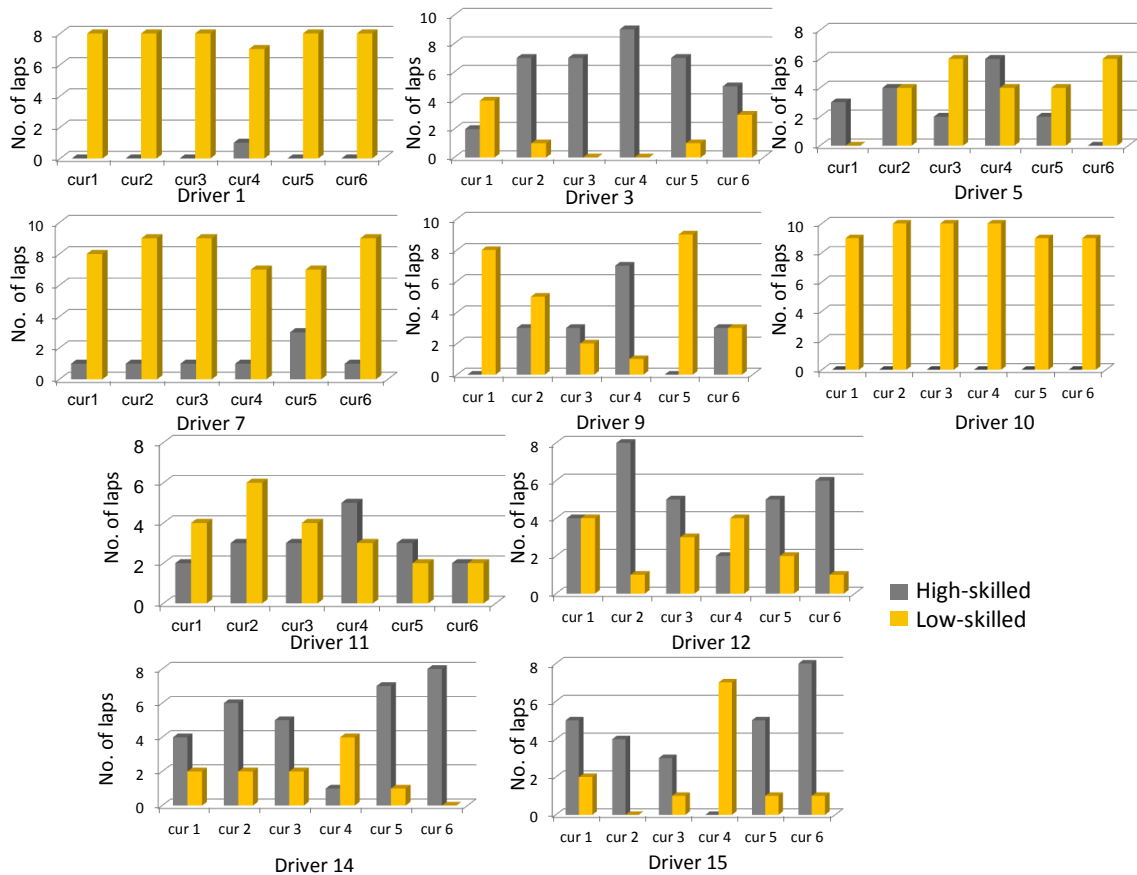


図 3-49 被験者ドライバの試走行分類結果

図 3-49 に示している 10 名ドライバにおける 10 回走行に熟練と未熟練の選択結果によって、ドライバ 1, 7 と 10 は非熟練者で、他のドライバは中レベルの熟練程度になることが分かる。

実験のパターンは表 3-21 に記述した五つがある。DS を慣れるため練習走行した後、3 回の自由走行ごとにアドバイスを提供しながら、10 回走行する。アドバイスのパターンを終了した後、効果を検討するために、もう一回自由走行を行う。DS の運転再現機能を活用して、被験者は熟練者の 1 回走行を体験して、もう 1 回走行する。

パターン順番の影響を避けるために、10 名ドライバは二つのグループに分けて、実験を実施した。ドライバ 1, 5, 12, 14 と 15 を一つのグループ - I にして、他のドライバはグループ - II にした。二つのグループの実験順番は異なり、グループ - I は(A-B-C-D-E)の順番で、グループ - II は(A-C-B-D-E)である。

表 3-21 実験のパターン

| Pattern | Content | laps |
|---------|--------------------------------------|------|
| A | Free travel | 3 |
| B | Driving following advice | 5 |
| C | Driving following advice | 5 |
| D | Free travel | 1 |
| E | Driving after experience skilled lap | 1 |

カーブ 1, 4, 6 は目標カーブとして選定し、アドバイスの提供する方法はパターン B とパターン C の 2 種類がある。パターン B は各カーブにおいて、熟練者と未熟練者の最も明確な特徴差としては抽出された特徴量の 1 番目である。具体的には、図 3-50 にはパターン B の略図を示している。全ての場所はカーブの出口ぐらゐであり、アドバイスの内容は表 5 に記載している。この三つのカーブの一番目特徴量はカーブの出口でセンターラインから離れる距離であり、熟練者は早めにセンターラインに接近していることが分かる。したがって、被験者にカーブの出口における少し前に、出口で早めにセンターラインに接近するようにアドバイスが提供され、実験を実施する。

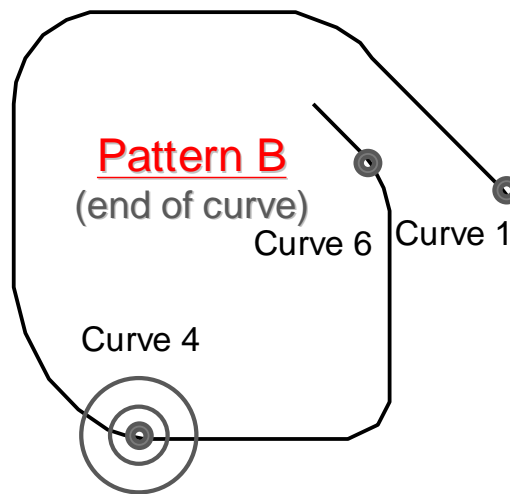


図 3-50 パターン B の略図

表 3-22 パターン B のアドバイス・リスト

| Curve | Advice |
|-------|---|
| 1 | At the exit of curve, close to the centerline as soon as possible |
| 4 | At the exit of curve, close to the centerline as soon as possible |
| 6 | At the exit of curve, close to the centerline as soon as possible |

パターン C にて、各カーブの入口での操作は走行未熟練の原因になると仮定されるため、入

口の近い所で抽出された特徴量に対して被験者にアドバイスを提供する。パターン C の略図と指示内容は図 3-51 と表 3-23 に示している。カーブ 1 と 6 はカーブの入口で、熟練者と未熟練者はセンターラインから離れて距離に特徴差が出ていることがわかる。熟練者は該当箇所では早めにセンターラインから離れて、カーブ内側の壁に接近する特徴がある。従って、カーブの入る前で未熟練者に早めにカーブのセンターラインから離れて走行するようにアドバイスを提供する。カーブ 4 の入口の近い所で、抽出された特徴量は操舵に関わって、未熟練者と比べると、熟練者は該当所で、あまり急に操作しなくて、円滑的に走行する特徴がある。そのために、被験者にカーブ 4 に入る前に、入口でスムーズに操舵してくださいとアドバイスを提供する。

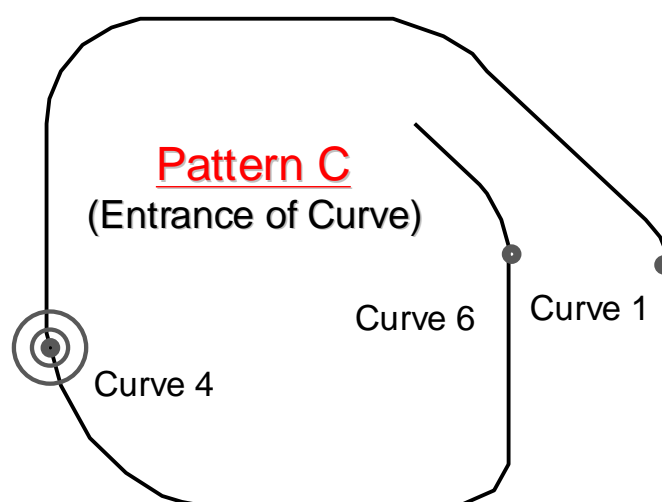


図 3-51 パターン C の略図

表 3-23 パターン C のアドバイス・リスト

| Curve | Advice |
|-------|---|
| 1 | At the entrance of curve, depart from the centerline as soon as possible. |
| 4 | At the entrance of curve, try best to steer smoothly. |
| 6 | At the entrance of curve, depart from the centerline as soon as possible. |

3.4.2 評価指標

実験前後、ドライバーのスキルの変化を評価するために、今回の二分化方法も第 3.3.3 節に述べた方法と同じように回帰直線により決まる。検討方法を図 3-52 に示している略図で説明すると、回帰直線より上側でデータとの差が大きいほど未熟練で、回帰直線より下側でデータとの差が大きいほど熟練となる。その差を図中に d と記す。未熟練者は d が正の値で、熟練者は負の値である。本項以降の分析は、この定義に基づいて展開される。




図 3-52 ドライバスキル変化の評価指標

3.4.3 実験結果

パターン B は基本的にカーブの出口付近で指示し、パターン C はカーブの入口付近で指示した。入口と出口でアドバイスの提供することの有効性を比較するために、10 名ドライバの平均値を図 3-53 に示している。ドライバごとで各パターンについて 5 回走行してもらい、全 50 回の平均値は縦軸であり、横軸は実験対象として三つのカーブである。平均値が小さいほど熟練となるので、結果を見ると、三つの全てのカーブがパターン C の方が良いと分かる。被験者を両グループに分けて実験を行ったので、実験の順番の影響がない。そのため、カーブの入口で適切なアドバイスを提供することがドライバのカーブ走行スキルの改善について有効性が高いと言える。




図 3-53 パターン B とパターン C の結果比較

アドバイスした後の効果を検討するために、アドバイス実験後の自由走行としてパターン D の結果と第 3.3 節に記述した実験データに比較する。第 3.3 節に記述した実験で各ドライバー 10 回の走行があり、その平均値がドライバー従来の運転熟練度と扱い、パターン D と比較の結果を図 3-54 に示している。両実験の時間差は 3 月間があり、第 3.3 節に記述して実験は図 3-54 に‘10-laps last year’と記載している。データを見ると、多くドライバーは熟練になることが分かる。図 3-55 に示しているように、全部 60 ペア値を見ると、43 ペアがパターン D の値が小さい。例えば、ドライバー 1 は第 3.3 節に記述した実験に略全部未熟練として定義され、一番曲率が大きいカーブ 5 以外の走行が全部向上された。つまり、適切なアドバイスを提供できれば、ドライバーの運転スキルが向上できることが分かった。

これにより、熟練者と未熟練者でどの場所でどのような操作に違いがあるかが抽出された。これを未熟練ドライバーに教示することで、運転技量を向上できると考えて、抽出された特徴量に対して、同じコースで前実験の参加者 10 名の未熟練のドライバーにアドバイスを提供し、ドライバーの運転技量の変化を検討するために実験を行った。アドバイスは最も明確な特徴差とカーブの入口の付近で抽出された特徴量に対して、アドバイスを提供され、実験結果はドライバーへアドバイスの有効性を検証した。

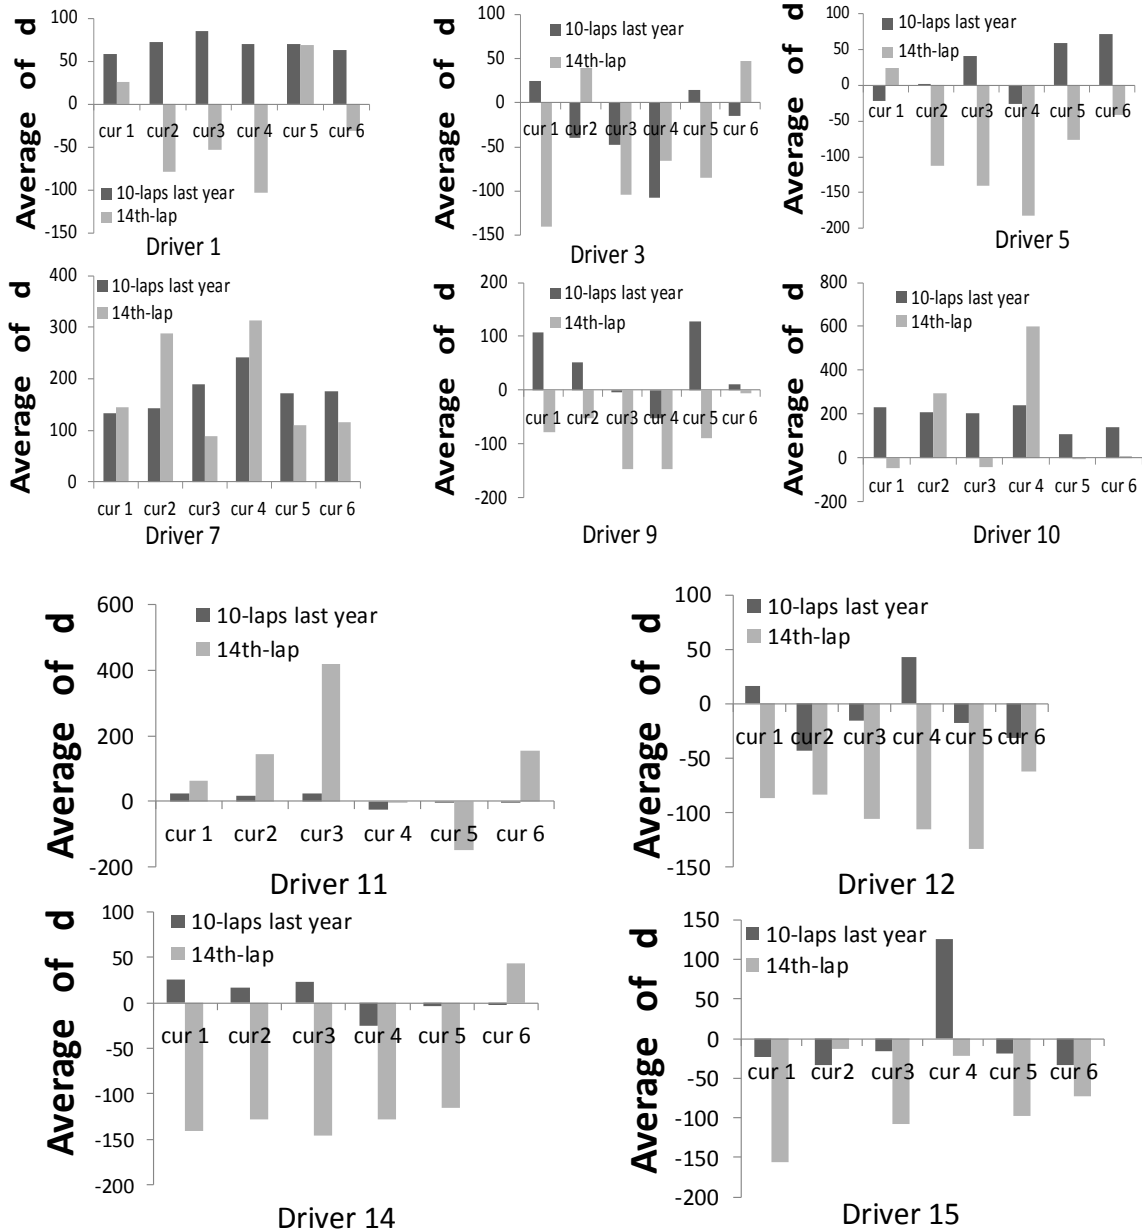


図 3-54 アドバイス実験後自由走行の結果(パターンD)




図 3-55 アドバイスの実験結果

3.5 本章のまとめ

本章は、自動車分野におけるビッグデータを重要な背景として、多数のドライバの運転データを含むビッグデータに基づく、帰納的な手法の観点からドライバ特性の理解と解釈を念頭に置いて、ドライバの運転特徴の抽出手法を提案した。

まず、特徴抽出アルゴリズムの詳細と全体手法のフローチャートについて述べた。特徴量抽出手法を用い、多曲率カーブにおいてドライバ 16 人の被験者実験を行い、熟練者と未熟練者の運転特徴量をカーブごとに抽出した。

次に、選定した熟練、未熟練のデータである母集団から、カーブごとに特徴量を抽出した。また、各特徴量について、抽出された箇所などもまとめて考察を行った。その結果として、特徴量はカーブの入口と出口の操舵とアクセルに関する操作量、該当場所の横変位は熟練者と未熟練者で差があることが分かり、長いカーブの中央部は熟練者と未熟練者の特徴差があまりないことが分かった。

さらに、抽出された特徴量に基づいて熟練者と未熟練者の判別モデルが構築され、交差検定方法によって判別モデルの識別率が検討され、本提案手法によって熟練と未熟練走行の識別器を生成可能な見通しを得た。今後は提案手法によって構築された識別器とモデルの構築方法について再度検討することや、精度よく識別器を構築するための候補特徴量データの生成方法、判別機の構築アルゴリズムの改善が課題となる。

最後に、抽出された運転特徴量に基づいて、未熟練者を対象としてアドバイス実験を行った。実験結果から被験者の運転技量の向上が可能であることを確認し、本提案手法の有用性を示した。

第4章

ドライビングシミュレータを用いた脳の 計測の実験環境の構築

4.1 本章の背景と目的

第一章の序論で述べたように、自世代自動車に向けてドライバの運転特性が重要となる。高度運転支援システムだけでなく、自動運転についてもドライバ運転特性までも考慮したドライバモデルが必要となる。運転手が自動／手動運転モードの切り替えを安全に行い、自動車の安全操作に関する追加情報が運転手に効率的に伝達されるように、運転手と自動車のインターフェースのために、ドライバ運転特性の解決は核心的な問題になる。また、システムの切り替えのタイミング、制御アルゴリズム、情報の提示タイミングや提示方法などを検討する時、「認知・判断・操作」を含んだドライバの運転特性の検討も必要である。

一方、本論文の前章までは AdaBoost に基づく特徴抽出手法を確立して、ビッグデータからドライバの運転特徴を抽出した。カーブ走行実験の結果から熟練者と未熟練者の運転特徴差と違いが生じる場所が明らかとなった。運転操作データだけを対象としてドライバの運転特性を解析する研究は多く有意な結果を得ている。ただし、結果に対して、生理学的な立場からの解釈にはまだ至っていない。また、運転行為は、走行環境を認知して集められた情報を脳が処理・判断するとともに指令を出して運転操作を行うことである。生理学で、脳の活動は運転行為の中心位置と言える。第一章の序論に述べたように、運転するドライバは頭頂連合野では体感情報している。所謂、運転する時視覚情報、体性感覚——手や関節の位置と運動情報、平衡感覚——加速度、回転速度など運動情報を含む体感情報を脳の頭頂連合野に統合していることである。ドライバの該当統合状況によって、運転特徴差を生じると考えて、この仮説の検討するために、脳の活動を計測できる新しい実験環境を構築しなければならない。

脳の計測技術の発展によって、運転中のドライバの脳活動の記録が可能となった。特に脳の非侵襲画像診断方法としては、近年注目されている代表的な間接計測手法は機能的磁気共鳴画像 (functional magnetic resonance imaging, fMRI) と機能的近赤外光分光法 (functional near-infrared spectroscopy, fNIRS) である。この二つの手法も既に先行研究の運転特性の研究に導入されている。fMRI は設備の使用条件が厳しく、身体の移動には敏感、かつ金属の影響を強く受ける。また、被験者は常に仰臥位での実験が必要となるため、複雑な運転行為を行いながら脳の計測することは困難である。

一方、fNIRS は装置の使用自由度が高く、ドライバが運転しながら脳の活性状況を計測可能である。そのため、fNIRS を利用することで、従来困難であった複雑な運転操作と脳の活性とを同時に計測することが可能となった。fNIRS を用いて柳沼らは前後方向の運転操作に対応する脳の活動の解析を行っている。Yoshino らは fNIRS を使って高速道路上で加速、減速中のドライバの脳活動の違いを計測することに成功している。fMRI では、実走実験とシミュレーション実験を比較する事ができないのに対して、fNIRS を用いたシミュレーション実験では、実走との比較が可能である。ITS 分野の脳研究で fNIRS を用いる最大の利点がある。fNIRS を用いて、ドライバの運転特性に関する研究について、新しい発見が期待されている。

そこで、本章では、モーション装置と音響装置により実車に近い臨場感を実現することが可能なDSを利用するとともにfNIRSを導入して、新しい実験環境を構築する。この新しい実験環境により、臨場感の高い環境下におけるアクセル、ブレーキとハンドルを含む複雑な運転操作と運転走行中の脳の活性とを同期して計測し、その解析を行うことが可能となる。具体的には、左右カーブの走行時における脳の活性化状態と運転行動を計測する。左右カーブの道路線形の違いにより生じるドライバの運転特性と脳の活性の違いを分析する。

4.2 機能的近赤外分光法(fNIRS)の紹介

fNIRS計測の指標は一般的には血流変動であるが、血流変動から、酸素消費や脳血液量を同時に定量的区別することができる。そのため、複数の脳反応の指標をモニターすることができ、ドライバの脳反応を多角的な指標で解析することが可能である。

fNIRSの計測原理は、700~900nmの近赤外光を大脳皮質へ照射し、局所脳活動に伴う毛細血管内の酸素化ヘモグロビン(oxy-Hb)と脱酸素化ヘモグロビン(deoxy-Hb)の濃度変化を検出することである(Fig.1)。加えて、局所脳活動の指標としてoxyHbとdeoxyHbから脳血液量(Cerebral blood volume: CBV)と脳酸素消費を反映する脳酸素交換量(Cerebral oxygen exchange: COE)を算出することができる。




図 4-1 fNIRS 計測原理^[12]

4.3 ドライビングシミュレータの紹介

本章では、第3章に記載されたDSを用いた。ここでは概要だけを述べる。本DSでは、三つのスクリーンにより120度のドライバの視野をカバーしている。6自由度スチュワートプラットフォームによりドライバは実車に近い動きを体感でき、また風騒音、エンジン音など現実に近い音響環境を作ることができる。これらの機能によって実環境での運転に極めて近い臨場感のある運転環境が提供されている。特に、Aピラーはドライバの視野に大きな影響があり、前後と右側の視野を

分割によって速度感も大きな違いがある。このために、今回の実験のために、第3章に記述されたDSの運転席にAピラーと車屋上を模擬する機構を追加した。図4-2に赤点線を包む対象である。




図 4-2 実験用 DS の運転席部

4.4 DS を用いた脳の計測実験

4.4.1 実験概要

本実験は15名ドライバ(男性:8名, 女性:7名, 平均年齢:31.4歳±4.4)にインフォームドコンセントを得て実験に参加してもらい、被験者の利き手は、Edinburgh Handedness Inventory によって、右利き12名, 左利き2名, 両利き1名であることが確認された。

実験コースとして仮想高速道路を作成した。図4-3にコースの全体平面線形を示している。コースは加速区間として1000mの直線部を用意し、その後、図4-4に示すカーブの平面線形とカント設置によって、緩和曲線を設けて曲率半径 $R=600\text{m}$ の曲線部を10箇所配した。なお、本実験では左右の曲線部を繰り返し走行するが、この際の脳反応に前曲線部の反応が残置することを避けるため、曲線部と曲線部の間に600mの直線部を配し、全長15.95kmの高速道路とした。本コースは直線部で2.5%、緩和曲線で2.5~8.0%、曲線部で8.0%程度の片勾配を設け、縦断勾配は全区間で設けなかった。図4-5には道路の横断面図を示している。走行しながら、臨場感と速度感を出せるために、CGで道路の両側に多くの樹を作って、遠方の山も作成された。図4-6には始点の景色を示している。




図 4-3 全コースの線形

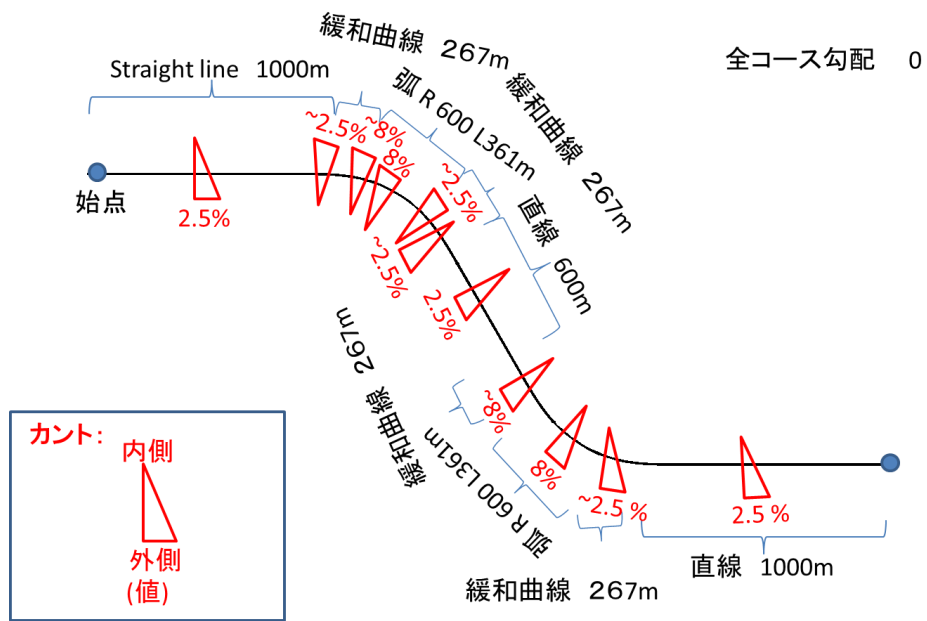


図 4-4 カーブの平面線形とカント設置




図 4-5 道路の横断面



図 4-6 走行始点の景色

4.4.2 実験条件

運転条件では、被験者に加速区間で車両速度を 100km/h まで加速させ、実験コースを 100km/h を保持して走行するように教示した。実施回数は 1 回であった。

4.4.3 脳機能 NIRS 計測

脳血流動態の測定は、多チャンネル NIRS 装置(島津製作所製、FOIRE-3000)を DS の背部に設置して行った(図 4-7)。3 波長の近赤外光(780,805,830nm)を頭皮から照射し、頭蓋内を通過した散乱光を検出するファイバ(計 32 本)を被験者の頭部に装着して計測した。ヘモグロビン濃度変化のサンプリング間隔は 70ms とした。計測部位は両側の前頭葉、運動野、頭頂葉とし、計 48ch(48 カ所)の計測点を設置した(図 4-8)。



図 4-7 脳機能計測 NIRS 装置と実験の様子

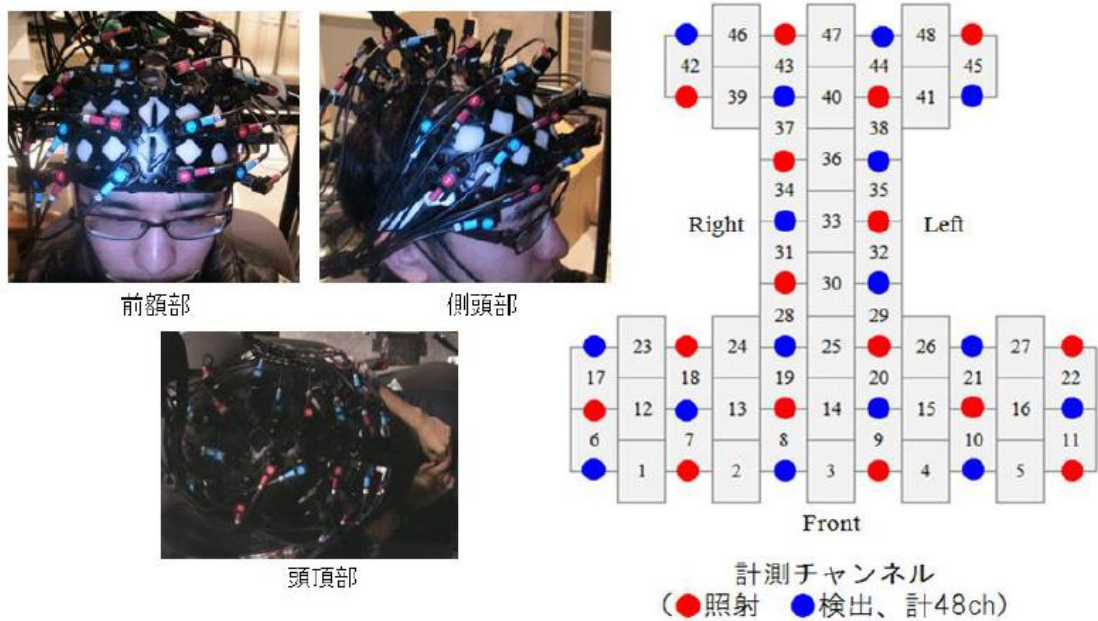


図 4-8 プローブフォルダの配置と理論チャンネル設定

プローブは、前頭葉および頭頂葉に設定した。これまでfNIRSのシミュレーション実験は前頭前野に限られていたため、運転動作に関わる運動野と空間認知に関わる頭頂葉を含む領域を対象部位に設定した。具体的な計測部位は、下記に示すブロードマンエリア(BA)であった。図 4-9 に示しているように、前頭葉は、BA9, 10(判断・注意), BA8(前頭眼野), BA46(作業記憶, 左は言語性, 右は視覚性), BA4(運動野, 特に足の領域)と、頭頂葉のBA7,40(空間認知)であった。




図 4-9 計測部位の概要図

計測変化量は、酸化型ヘモグロビン ($\Delta\text{Oxyhemoglobin}$: ΔOxyHb), 脱酸化型/還元型ヘモグロビン ($\Delta\text{Deoxyhemoglobin}$: $\Delta\text{DeoxyHb}$)である. 上記の変化量から下記を算出して脳反応の指標とした.

脳血液量 (ΔCBV : cerebral blood volume)は以下のように算出した. ΔCBV は, 照射/検出プローブに挟まれた光計測領域のボクセルにおける赤血球数の相対的な変動を表す.

$$\Delta\text{CBV} = \frac{[\Delta\text{OxyHb}] + [\Delta\text{DeoxyHb}]}{\sqrt{2}} \quad (4-1)$$

酸素交換量 (ΔCOE : cerebral oxygen exchange)は以下のように算出した. ΔCOE は毛細血管内から神経細胞への酸素交換 (oxygen delivery)を示す. ΔCOE 増加は血管内の脱酸素化を示し, 神経活動が起こり酸素需要が高まったために, 毛細血管内の酸素が細胞へ移動したことを意味する. ΔCOE 減少は脱酸素化が少なく, 神経活動が小さいことを意味する. 従来の脳科学で用いられている ΔOxyHb や ΔCBV よりも, ΔCOE は脳機能の亢進を示す指標として生理学的に精度が高いと考えられる.

$$\Delta\text{COE} = \frac{[\Delta\text{OxyHb}] - [\Delta\text{DeoxyHb}]}{\sqrt{2}} \quad (4-2)$$

ΔOxyHb , $\Delta\text{DeoxyHb}$, ΔCBV , ΔCOE の4つの成分を持つベクトルを生成し, 脳機能を評価する脳酸素調節モデルを用いて脳機能画像を作成して, 脳の活動を分析する^[34].

4.4.4 実験結果

(1) 脳の計測結果

脳の活動における計測変化量は, 酸化型ヘモグロビンと脱酸素化ヘモグロビンである. 上記の変化量を使って, 各カーブの始点に基準にして, カーブ走行中の酸素交換量 (ΔCOE : cerebral blood volume)を算出して脳反応の指標とした. 尚, 生体特有の周波数をカットするために, 0.1Hz

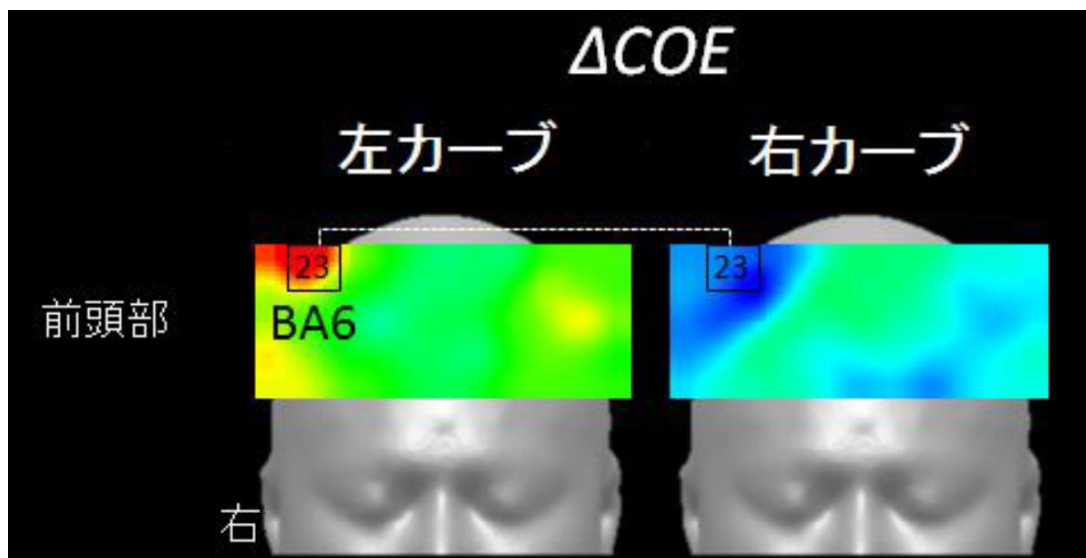
のLPF処理を行った。

具体的なデータ処理手順は下記による行った。

1. 被験者ごとにカーブ走行の開始時点からの各ヘモグロビンの平均変化波形を作成した。(カーブ走行:5走行の平均波形)
2. 各ヘモグロビン変化量の積分値を算出した。
3. 各指標の1秒あたりの変化量を算出した。
4. 「左カーブ走行中」と「右カーブ走行中」の脳活動を ΔCOE と ΔCBV を指標として用いてそれぞれ比較した(Kruskal-Wallis one-way analysis of variance)。

15名ドライバごとに左右カーブ5回ずつ走行があるので、75回走行の各チャンネルの値を積分して、カーブ走行中の各指標の1秒あたりの変化量を算出した。左右カーブの脳反応の違いと比較するために、Kruskal-Wallis one-way analysis of variance で比較した。有意水準は、 $p < 0.05$ とした。結果は図4-10に示している。

ΔCOE では、右脳の運動関連領域(BA6)で、左カーブ走行中と右カーブ走行中との間に有意差を認めた($p < 0.05$)。左カーブ走行では ΔCOE が増加し、右カーブ走行では ΔCOE は減少した。右カーブよりも左カーブで BA6 が活動したことが分かった。右脳 BA6 によって右カーブ走行と左カーブ走行を区別できる可能性が示された。



※ Kruskal-Wallis one-way analysis of variance

図 4-10 左右カーブの脳機能計測結果(運動関連領域)

また、図4-11に示すように下肢運動を司る一次運動野で、左カーブでは ΔCOE が増加したが、右カーブでは ΔCOE が減少した。 ΔCOE の増加は、脳酸素消費の亢進を示す。つまり、下肢運動に伴う一次運動野の活動は、右カーブより左カーブで亢進した。

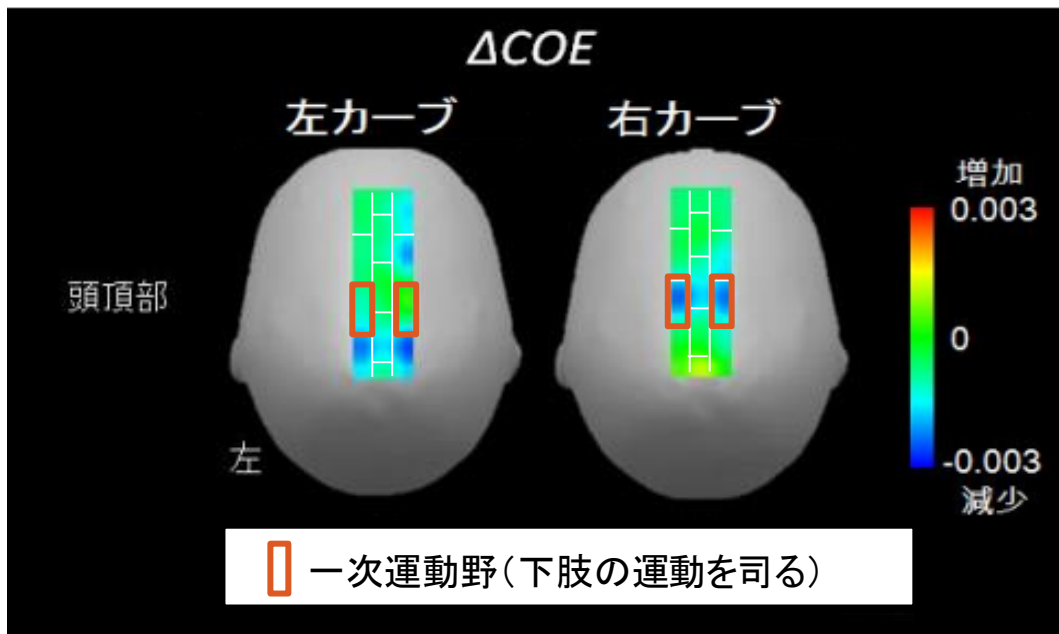


図 4-11 左右カーブの脳機能計測結果(一次運動野)

(2) 走行軌跡

各ドライバの走行軌跡の再現性を検討するために、図 4-12 と図 4-13 に示しているように解析された。図 4-12 は走行軌跡の一部だけ拡大したものである。

まず、各ドライバの同カーブの 5 回走行の軌跡を走行距離により正規化する。正規化の方法は道路のセンターラインを基準として、刻みが 0.3m の線形補間である。

次に、正規化されたデータを用いて、図 4-12 に示している実線 5 回走行の平均走行を計算する。

その後、各回走行軌跡と平均軌跡の偏位量を計算し、5 回走行の偏移量により一つの集合を作って、その集合からヒストグラムを作成し(図 4-13)の集合の 90%が踏まれる閾値を算出する。該当閾値が小さい方が走行軌跡の再現性が良いと評価される。各ドライバの左右カーブごとにおける閾値の結果を図 4-14 に示している。結果を見ると、右カーブの方は閾値が小さく、再現性が良いと分かる。




図 4-12 走行軌跡の正規化




図 4-13 全行軌跡と平均走行軌跡の偏差の分布図




図 4-14 走行軌跡の検討結果

具体的に左右カーブの走行軌跡の特徴差がカーブの何処でどのように表れるのかを解析するために、図 4-14 の結果を分析する。実験は二車線の道路において左の方で車線を走行したので、道路のセンターラインから横偏移を計算された。左右カーブの各 75 回走行データを正規化して、場所ごとに横偏移の平均値を計算して、グラフ化すると図 4-15 のようになる。

T-test($p < 0.05$)を用いて、左右カーブの統計的な有意差がある場所を検出した。有意差が出る場所はカーブ出入口である。両場所の平均値を見ると、入口で、センターラインはカーブの内外側の差を考えると、道路幅が 3.5m であるので、右カーブの方が内側からより離れると分かる。出口で、左の方がセンターラインからより離れる。右カーブの方は出口で早めに道路の中心に戻る事が分かる。




図 4-15 左右カーブの横偏移の平均位置

(3) 操舵角度

同じドライバーの左右カーブの走行技能、或いは操舵スキルを検討するために、操舵の微調整に着目して解析を行った。基本的なコンセプトは熟練者がスムーズに操舵することに比べて、未熟練者は微調整が多いと考えられる。微調整を定量的に評価するために、操舵角度の生データとそれぞれの円滑的な低周波数成分の偏差を採用した。具体的には、Fig.11 に示しているように、離散化ウェーブレット変換(db8)を使って、0.152Hz 以下の低周波成分と生データの差を用いた。




図 4-16 運転操舵データの低周波数成分

その後、生データと低周波成分をそれぞれ走行距離によって正規化した後、偏差を求めて、その偏差の分布図を作った。図 4-17 と図 4-18 には微調整が多い時と滑らかな時の操舵の例を示した。結果を見ると、滑らかな時の操舵の走行は偏差の分布がゼロの近くに集中し、微調整が多い時の走行は該当値が広い区間に分布している。この二つの例を見ると、該当偏差はドライバー走行中に操舵の微調整の状況、或いは円滑程度を反映できる。




図 4-17 操舵調整が多い走行の検討結果




図 4-18 操舵調整が少ない走行の検討結果

全 15 名ドライバーのデータは同じ傾向を持っているが、図 4-19 には例として、二名のドライバーの左右カーブのそれぞれ 5 回走行の操舵角度と対応低周波成分の偏差の分布図を示している。同一のドライバーについては左右カーブの操舵微調整についてはほぼ同じ傾向であるが、二名のドライバー間では差異性が大きいことが分かった。つまり、操舵の微調整はドライバーごとの個人特性を反応し、操舵の円滑程度はドライバーの運転習慣と運転技量に関わると考えている。

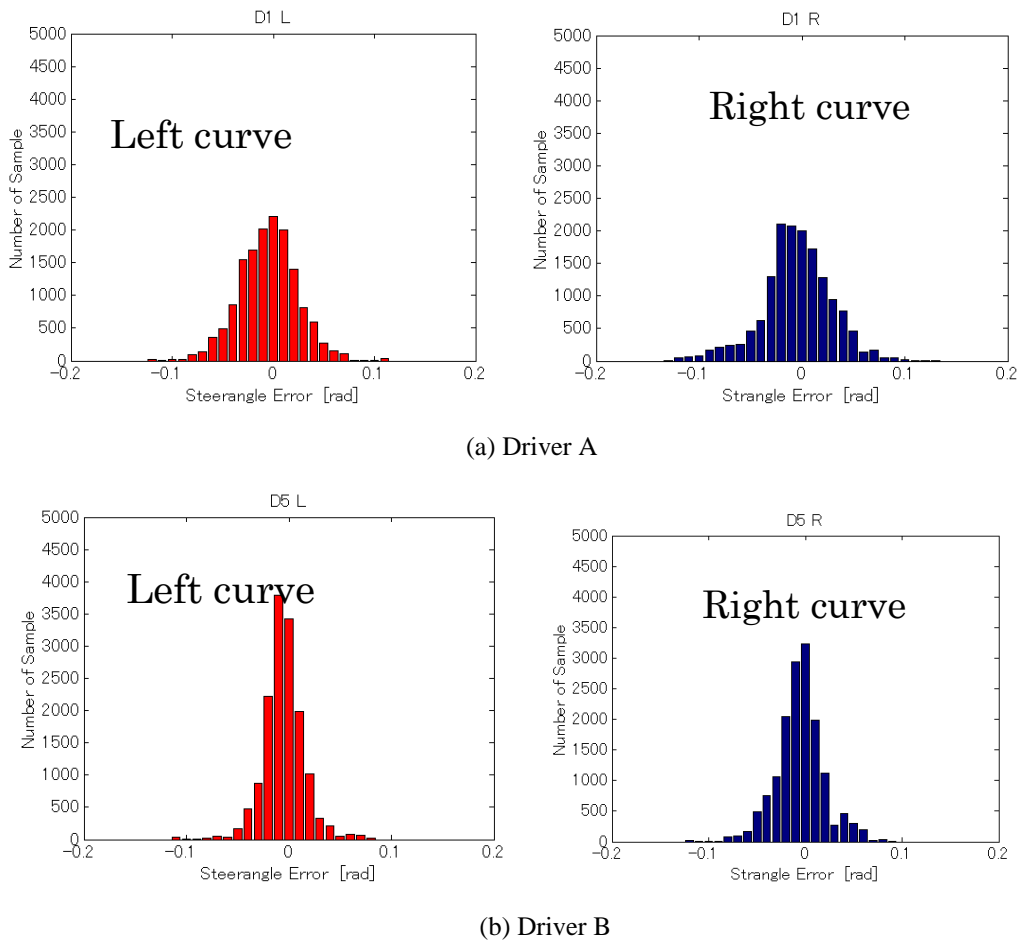


図 4-19 操舵微調整の検討結果

場所ごとで左右カーブの操舵特性を比較するために、操舵角度の絶対値を用いた。図 4-20 に左右カーブの場所ごとの前輪操舵の平均値と意差が出る場所を示している。左右カーブの操舵値を全体的な波形を見ると、場所ごとの平均値はほぼ同じである。有意差が出る場所はカーブの中心部で、左カーブの方がより微調整は多いという傾向があると分かった。




図 4-20 左右カーブの操舵角の比較

(4) アクセル

ここでは左右カーブのアクセル操作の特性を分析する。左右カーブ各 75 回走行におけるアクセル踏込量のデータを距離によって正規化して、分布図を図 4-21 に示している。全体的に見ると、両カーブのピーク値は約 19%にある。しかし、右カーブの方がピーク値は小さく、16%~18%の区間にサンプル数が多いので、右カーブの方がアクセルの振動が頻繁であると示唆される。該当振動を分析するために、左右カーブのアクセルデータを場所ごとに分析する。同場所で左右カーブ各 75 回走行の平均値を図 4-22 に記載している。T-test($p < 0.05$)によって、各場所の分布について統計的な有意差が出る場所はカーブの入口部の緩和曲線の始点と出口部の終点である。両場所で共に左カーブの方がアクセルの踏込量大きい。




図 4-21 左右カーブのアクセル踏込量の分布




図 4-22 アクセル踏込量の平均値の比較

4.5 考察

脳の計測の結果によると、右カーブよりも左カーブで BA6 が活動したことが分かった。下肢運動に関わる一次運動野にも違いが出た。走行データの分析結果によると、左右カーブにおいて、走行軌跡に対しては右カーブの方が再現性は高い。左カーブと比べると、右カーブはアクセルの踏込量が調整は多く、カーブの始点と終点で踏込量が微妙に小さくなっていることが分かった。操舵データの解析結果によると、同じドライバーにおいて、左右カーブを走行する時、操舵の微調整の違いがあまりなく、ドライバー同士は大きな差異性が存在することが分かった。場所ごとによると、左右カーブの全員の平均操舵角度の値を見ると、入口と出口がほぼ同じで、カーブ真ん中の円弧部分は有意差が多くでてきた。平均レベルで左カーブの方が調整はより多いと分かった。

4.6 まとめ

本章は、高度運転支援システムと自動運転に代表される次世代車の開発の核心な問題の一つとしてドライバー運転特性の検討するために、また本論文の前章まで抽出された熟練者と未熟練者の運転特徴差の生体工学の解釈を念頭において、高い臨場感を持っている DS と最先端の脳の計測技術 fNIRS によって新しい実験環境を構築された。

新しい実験環境の検証するために、高速道路の環境を想定して、運転中の脳機能計測を行った。左右カーブの運転結果と走行中の脳の活性データの分析を行った。脳の計測結果を見ると、左右カーブの走行において、脳の活動の差異が存在する部位が分かった。DS でドライバーの一般走行行動と脳の活性の評価実験が可能である。これまでは仮説に基づいたドライバーモデルや過去の経験や知見、アンケートなどの主観評価によりシステムが検討されているが、提案された方法は新しい手段としてドライバー運転特性に関する研究に導入し、新たな知見が期待される。

第5章

ドライビングシミュレータ実験に基づく 脳活動と運転技量の関係の解析

5.1 本章の背景と目的

第4章では運転特性を検討するために、脳の計測手法として近赤外線分光法(fNIRS)をDS実験に導入し、新しい実験環境が構築された。また、DS実験により、左右カーブにおいてドライバの脳の活性に関する差異が検出でき、運転中のドライバの運転データと合わせて脳の活動を計測できることを確認した。

本章では構築した新しい実験環境を用いて、頭頂連合野の活性化状態と運転技量の関係を解明することを目指して研究を展開する。具体的には、実在するテストコースをDS上で可能な限り再現して走行実験を行い、取得した実験データに基づいて運転熟練者と未熟練者を定義し、両グループの走行データの差異と機械学習手法で抽出された特徴差の整合性を確認するとともに両グループの脳の活動の差異を検出する。特に運転中の視覚情報と体性感覚情報と平衡感覚を含む体感情報を統合している頭頂連合野の活性化状況と運転技量差の関係を調べる。頭頂連合野の活性レベルと運転技量のレベルに関係があると仮説を立て、実験により検証する。

5.2 DS実験の実験概要

5.2.1 実験コースの紹介

本実験は、日本自動車研究所が所有するテストコースの外周路を用いた。図5-1にテストコースの全体図を示している。赤い線は外周路の平面線形を表す。




図 5-1 JARI のテストコース^[91]

外周路は郊外道路を模したアスファルト道路である。コースの周長は凡そ 5.7 kmで、道路は、中央に区画線がある 2 車線の道路幅員 7 m である。横断勾配については、直線部は両勾配 2%、曲線部は片勾配 2~3%、縦断勾配:最大 5.9 %であり、本コースの最小曲線半径は 60m である^[91]。図 5-2 にテストコースの俯瞰図を示している。



図 5-2 JARI のテストコースの俯瞰図^[91]

5.2.2 実験コースの DS で再現

実在するテストコースを DS で再現して実験を行った。実験の平面線形については、実道路で実走行を行い、その際に得られた GPS(RTK-GPS)の 3 次元位置情報を利用した。このデータに基づくことで、道路の線形と前後の勾配を忠実に再現した。

テストコースの再現では、道路の線形を現地と一致させるだけではなく、極めて現地と近似するために人の認知への影響の大きい光環境も考慮した。具体的には現地と DS の画面上の輝度を計測し、その計測値を用いて光環境の再現性の向上を図った。図 5-3 は現地及び DS で道路の輝度の計測に利用した計測用色彩輝度計である。



図 5-3 道路の輝度を計測用色彩輝度計[CS-100A]^[92]

図 5-4 と図 5-5 に DS で再現したコースと実道路の対照図を示している。DS のプロジェクタの最大表現輝度の制限があるため、図 5-4 で数字①～③の順番で示した「路面アスファルト」，「白線」，「青空」を主な要素として設定し、これらの輝度値が同比率で DS のスクリーン上で

再現されるように映像を調整する方法を用いた。実車コースで計測した輝度値と DS シナリオにそれぞれの輝度値を表 5-1 に示している。実道で一番明るいものの輝度値が 12500 cd/m^2 であり、映像の最大表現輝度は 200 cd/m^2 である。




図 5-4 DS で再現した道路




図 5-5 実道路の風景

表 5-1 DS 映像と実車の輝度対照表

| 視対象 | 実際輝度 cd/m ² | 比 | DS映像輝度 [実測/(理論値)] cd/m ² |
|-----|---------------------------|-------|---|
| 路面 | 2,000 | 0.16 | 32.1 (32) |
| 白線 | 7,300 | 0.584 | 116 (117) |
| 天空 | 5,000 | 0.4 | 79.8 (80) |
| 参考点 | 12,500 | 1 | 200 |

5.2.3 実験概要

本実験は、東京大学ライフサイエンス委員会倫理審査専門委員会の審査(審査番号 13-159)を受けた上で実施した。

DS 実験では、30代の8名ドライバ(男性:4名, 女性:4名, 平均年齢: 33歳±7)を対象として実験を行った。被験者には、図 5-6 に示しているように、実験コースの始点から車両速度を評価区間までに 80km/h まで加速させ、その後は 80km/h を保持して走行するように教示した。本実験前に実験コースについて時計回りと反時計回りで各一回ずつ練習走行を行った。順方向 8 回走行、逆方向 8 回走行を行った。図 5-7 には DS 実験の風景を示している。ドライバの脳の上に付けているのは fNIRS の計測ケーブルである。fNIRS を利用して運転中のドライバの脳の活動を計測する。




図 5-6 走行始点と方向の定義




図 5-7 DS 実験の風景

5.2.4 脳機能 NIRS 計測

脳血流動態の測定は、前章に記述された多チャンネル NIRS 装置(島津製作所製, FOIRE-3000)を利用して行った。3 波長の近赤外光(780,805,830nm)を頭皮から照射し、頭蓋内を通過した散乱光を検出するファイバを被験者の頭部に装着して計測した。ヘモグロビン濃度変化のサンプリング間隔は 70ms とした。

図 5-8(左)に示すように前頭葉、運動野と頭頂葉に対して計測を行い、総 98 チャンネルのデータを計測した。NIRS 装置のチャンネルの制限によって 98 チャンネルのデータを同時に計測できないため、運動関連野だけを計測したデータ(プローブ M)と頭頂葉および前頭野を計測したデータ(プローブ V)の二つを組み合わせた。つまり、脳の活動が 2 回の走行による計測結果を組み合わせ 98 チャンネルの計測結果とした。両方向ごと 8 回の走行について計測した。図 5-8(右)には各チャンネルの配置図を示している。なお、実験順番の影響を避けるために、実験の順次は乱数で決定し、表 5-2 に各ドライバの実験順次表を示している。

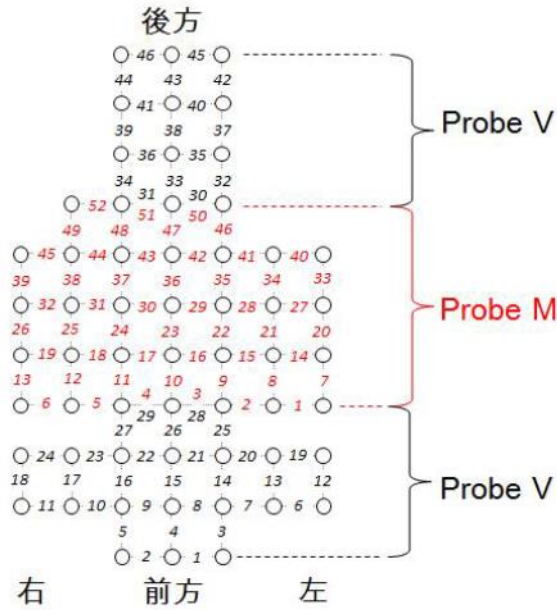


図 5-8 NIRS のプローブ装着位置と理論チャンネル配置図

表 5-2 実験順次表

| ドライバ ID | DS 実験順番 |
|---------|----------------|
| D1 | プローブ V ⇒プローブ M |
| D2 | プローブ V ⇒プローブ M |
| D3 | プローブ M ⇒プローブ V |
| D4 | プローブ M ⇒プローブ V |
| D5 | プローブ V ⇒プローブ M |
| D6 | プローブ M ⇒プローブ V |
| D7 | プローブ M ⇒プローブ V |
| D8 | プローブ V ⇒プローブ M |

図 5-9 に示している計測チャンネルと脳部位の関係図について述べる。脳科学のブロードマン脳地図^[93]によると、今回はブロードマン 3, 1, 2 野 - 一次体性感覚野, ブロードマン 4 野 - 一次運動野, ブロードマン 5 野 - 体性感覚連合野, ブロードマン 6 野 - 前運動野, 補足運動野, ブロードマン 7 野 - 体性感覚連合野, ブロードマン 8 野 - 前頭眼野, ブロードマン 9 野 - 前頭前野背外側部, ブロードマン 17 野 - 一次視覚野, ブロードマン 18 野 - 二次視覚野, ブロードマン 19 野 - 視覚連合野, ブロードマン 40 野 - 縁上回, ブロードマン 45 野 - 下前頭回 三角部を含んで計測を行った。

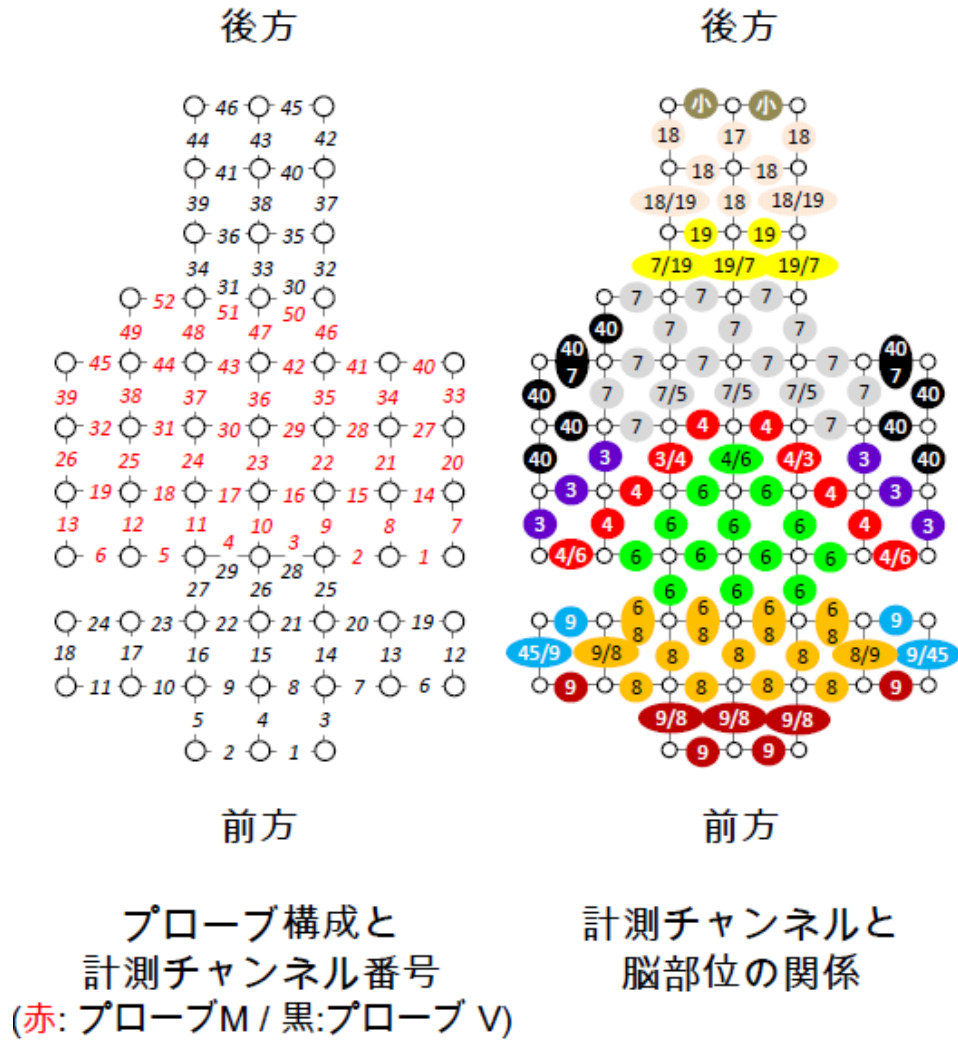


図 5-9 計測チャンネルと脳部位の関係図

5.3 解析対象データの紹介

本章の解析は第3章で述べたDS実験の走行結果に基づいて行う。特に、機械学習手法によって抽出された結果と未熟練者へのアドバイス実験の結果によると、カーブの入口では熟練者と未熟練者の差異が大きいので、図5-10に示しているように、カーブ進入前の長さ400mのストレートからカーブ進入後1000mまでを対象として解析を行う。この対象区間にはカーブの入口付近および定常円の区間が含まれる。

今回の解析データは図5-11に示しているように、DS実験の順方向で収集された60回走行における熟練走行と未熟練走行の脳活動の差異性を検討する。




図 5-10 解析対象区間

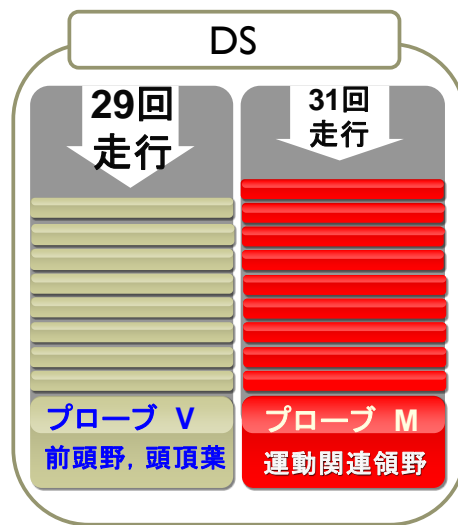


図 5-11 解析対象データ

熟練走行と未熟練走行の定義については、合成ジャークの累積値を用いた。第 1 章で述べたように、熟練者の走行は合成ジャークが小さく、燃費や運転安全などが大きく関わる。ジャークは加速度の時間微分であるので、ジャークが小さいと運転が滑らかで乗り心地も良いことが報告されている^[63]。

図 5-12 に考察区間の合成ジャークの累積値によって、全 60 回の走行データを中央値により分類する。合成ジャークが小さいと熟練グループで、大きいと未熟練グループと定義する。値を見ると、熟練グループは合成ジャークが[295.9, 505.6]の区間に選定され、未熟練グループは合成ジャークが[510.1, 969.1] の区間に選定されている。




図 5-12 合成ジャークによる熟練と未熟練の分類

5.4 実験結果

5.4.1 走行データの差異性

図 5-13 では、熟練と未熟練グループの走行速度、アクセルと操舵角度の平均波形と有意差検定(U-test, $p < 0.05$)の結果が示されている。緑色で示されているところが熟練と未熟練グループで有意差がある場所である。全体的に約 500m までは、走行速度、アクセルと操舵について両グループで大きな差はない。その後、約 500m から未熟なグループはアクセルの踏み込み量が落ち、速度が約 5km/h 減速され、580m 付近からカーブに対して大きく操舵を切り始めている。操舵を切り始めた後の過渡的な状態において未熟練グループはアクセル操作により速度を調整しているが、平均的に熟練グループより速度が低い傾向であることが分かった。その後、約 1000m の距離から、徐々に操舵が落ち着いてアクセル操作が熟練グループと同じように安定している。特に 1200m 以降は既にカーブの定常円の区間であり、徐々に速度、アクセル、操舵の差異がなくなる。逆に、操舵の切り始めからの過渡状態では、熟練者の速度とアクセルは未熟練者より安定している傾向があることが分かった。つまり、未熟練者はカーブの進入時の操舵にアクセルの踏み込みが少なくなるために速度が維持できず、走行が不安定となる傾向がある。




図 5-13 熟練と未熟練グループの走行結果

図 5-14 には熟練グループと未熟練グループの横変位が示されている。ここで、横変位は走行軌跡とカーブの内側の車線との距離である。横変位が小さいと、走行軌跡はカーブの内側に近い。全体的に、600m 以後で未熟練グループはカーブの内側から離れて、熟練グループはカーブの内側に近づいている。つまり、未熟者の走行軌跡はより膨れる傾向があり、熟練者の走行軌跡は‘out-in-out’という特徴がある。有意差検定(U-test, $p < 0.05$)検定の結果によると、特に 1000m 以後で有意差が有り、熟練者はカーブの内側により接近していることが分かった。1000m 以降は操舵データを合わせて考察すると、操舵が収束段階あるいは定常円の区間である。




図 5-14 入口で横偏移の比較

熟練と未熟練走行は合成ジャークで分類したので、具体的な場所ごとの差異性を検討するために、図 5-15 では場所ごと両グループの平均波形を示している。図中の緑色の点は両グループ

で有意差がある場所である(U- test, $p < 0.05$). 全体的には熟練グループの方が小さく, 特に 600m からの区間に有意差が多い. 該当区間は緩和曲線区間であり, 直線からカーブへ繋がっていくためにドライバが大きく操舵を切り始める. つまり, 操舵開始後は両グループの差が大きくなっている.




図 5-15 熟練と未熟グループの合成ジャークの平均波形

5.4.2 機械学習手法で抽出された特徴量の共通点

本項では, 熟練と未熟練グループの操作特徴差と第 3 章で提案された機械学習手法によって抽出された特徴差の共通性を考察する. 表 3-2 に本論文の第 3 章に抽出された特徴量と 5.4.1 項に記述された特徴差をまとめている.

第 3 章の熟練度の定義はカーブを通過する時, 一定速度を保持できていて合成ジャークが小さいと熟練と定義する. この定義に従うと一般的に速度が速い時の方が運転操作の難易度は上がるため, 速度が速くて合成ジャークが小さい場合はより熟練といえる. 5.4.1 項で記述された結果により, 今回定義された熟練グループは図 5-13 に示されるように速度が速く, 合成ジャークの累積値が小さかった. つまり, 速度が速く, 合成ジャークが小さいという観点で熟練度の定義は第 3 章と前節で共通となっている.

第 3 章で抽出された特徴量の統計評価によって, 主な特徴量はカーブの入口で出ており, アドバイス実験で入口の走行に対するアドバイスが有効であることが分かった. そのため, 本章はカーブの入口におけるドライバの運転特性に着目してドライバの脳活動の差異性を検討する. 機械学習手法で抽出された結果によって, 熟練と未熟練走行の一つの代表的な特徴は走行軌跡に現れた. 熟練者はカーブを進入するとき, 早めにカーブの内側に接近して, 走行軌跡はあまり膨れない傾向がある. 今回の熟練と未熟練者の走行軌跡も同様な傾向が出てきた. また, 熟練者は操


舵とアクセルの操作が滑らかであることについても両実験の共通の結果である。つまり、両実験において熟練と未熟練グループの走行の主な操作特徴が共通している。

表 5-3 抽出された特徴差と合成ジャーク定義の特徴差の対照表


| 項目 | 機械学習手法で抽出された結果 | DS のテストコース実験 |
|----------|---|---|
| 考察 区間 | 全カーブ | ストレートとカーブの入口 |
| 熟練 定義 | カーブを通過する時、同じ速度で合成ジャークが小さいと熟練に定義する。 | 合成ジャークの中央値により小さい走行が熟練する。 |
| 特徴 差 | <ul style="list-style-type: none"> ● 入口、出口は差異性が大きい ● <u>熟練者はカーブを進入すること、早めにカーブの内側に接近している。走行軌跡はあまり膨れない。</u> ● 熟練者は操舵とアクセルがスムーズとなる。 ● 入口でアドバイスを提供すると、ドライバのスキルを向上に対してより有効である。 | <ul style="list-style-type: none"> ● 未熟グループは走行速度が低い ● <u>熟練の人の走行軌跡は早めにカーブの内側に接近している。走行軌跡はあまり膨れない。</u> ● 未熟は操舵する前にアクセルの調整が大きい ● 熟練のグループは速度とアクセルが安定となる。 ● 操舵過程にも両グループ有意差が出て、熟練のグループの方が収束し早い。 |

5.4.3 脳活動の差異性

前項までは、熟練と未熟練グループの走行データの差異性を比較した。本項では操作の差異性に対する脳の活動の差異性に着目して解析する。図 5-16 には熟練と未熟練グループの脳活動が示されている。図中の赤色は酸素消費量(ΔCOE)が正值であることに対応し脳が活性化状態であることを示し、青色が非活性化状態を示している。両グループは共通して活性化しているエリアがあるが、全体的に熟練グループは活性化しているエリアが多い。また、区間的には、400m までの直線に対して両グループは余り差がなく、カーブが始まる約 600m 付近の大きな操舵操作に伴って、両グループは強い活性化部位が現れている。ドライバは実車位置や道路の線形など認知しながら、操舵とアクセルの操作によって速度と実車位置を調整する。そのため、直線からカーブへの道路の曲率変化に伴って運転に対するドライバの「認知・判断・操作」に関わる脳活動が強くなる。この過程で運転技量によって、熟練と未熟練のドライバでは脳活動に差異が生じる。



(a) 熟練走行グループの脳活性



(b) 未熟走行グループの脳活性


図 5-16 ドライバの脳活動状況

熟練と未熟練グループの差異性についてより詳細な検討を行うために、有意差検定を行った (U-test, $p < 0.05$). 具体的なデータ処理の手順としては、各走行の脳の計測データについてチャンネルごとに酸素消費量(ΔCOE)を 100m の単位で積分した後、両グループの有意差を検定する。結果は図 5-17 に示している。図 5-17(a)は表 5-4 に熟練と未熟練グループの有意差がある脳のエリアとその解釈を整理している。


熟練グループに対して、400m から 1000m の間に脳の両側の BA7(図 5-19 を参考)、両側 BA40、左脳 BA4(一部右脳も)、右脳 BA8 が未熟練グループより活性化して、600m 以後は右脳 BA18(一部左 BA18)も熟練グループの活性が強い。両側 BA7 と 両側 BA40 は空間認知と体感覚の脳機能に関わるエリアである。場所的に操舵要素の大きい区間で、ドライバーは空間認知と体感覚が高まっていることが分かった。左脳 BA4 は一時運動野でアクセルと操舵などの動きに、左脳 BA6 は動作の微調整に関するエリアであり、熟練の方が 400~1000m 区間では操舵に関わる運転調整と

運転出力がより高まっている。400~1000m の間に、右脳 BA8 の活性が高い。BA8 は前頭眼野の脳機能エリアで、右脳 BA8 は左視野に対する注意が高まっている。また、600m 以降、左視覚に深く関わる右脳 BA18 の活性が高いため、熟練グループは左カーブを走行している間、特に左視野の知覚が高まっていることが分かった。つまり、走行方向への知覚が高まっていることが分かった。LANDらはカーブ走行中のドライバが走行方向に注視していることを報告されている^[94]。さらに Dario D Salvucci らは熟練度によってドライバの注視点分布は違うと報告されている。^[59] 本実験の結果によってドライバの注視特性の差異性は前頭眼野の活性化状態にも反映できることを示唆された。

視覚に関わる BA8(前頭眼野)で見ると、未熟練グループに対して、400-600m 付近で BA8 を使っていて、熟練グループは 600-900m 付近で BA8 の活動が高まっている。



(a) 熟練走行グループがより活性化エリア



(b) 未熟練走行グループがより活性化エリア

図 5-17 熟練と未熟走行グループの有意差検定結果(U-test, $p < 0.05$)

表 5-4 熟練と未熟走行グループの有意差がある現象と解釈

| | 現象 | 解釈 |
|------|-------------------------------------|--|
| High | ●400~1000mの間、両側BA7, 両側BA40の活性が高い | ○操舵要素の大きい区間で、空間認知と体感覚が高まっている |
| | ●400~1000mの間、左BA4(一部右も), 左BA6の活性が高い | ○操舵要素の大きい区間で、運動調整と運動出力が高まっている |
| | ●400~1000mの間、右BA8の活性が高い | ○左視野に対する注意が高まっている |
| | ●600m以降、右BA18の活性が高い(一部左BA18も) | ○左カーブを走行している間、特に左視野の知覚が高まっている(走行方向への知覚が高まっている) |
| Low | ●左BA18が活性 | ○進行方向とは違う右視野の知覚が、highグループにくらべて優位 |
| | ●両側BA8が活性 | ○BA18の知見を合わせて考えると、視線が落ち着いてない可能性がある。 |

5.5 運転熟練者の頭頂連合野活動について

前節までは、全走行を解析対象として熟練と未熟練走行を比較することにより、体感に関わる頭頂連合野(BA7)には明確な差異性が存在し、体感と運転技量に関係があると示唆された。合成ジャークによって熟練と未熟走行グループを定義したが、ドライバーごとの解析は行っていなかった。運転熟練者の頭頂連合野の関係を解明するために、完全に熟練と未熟練に分類されるドライバーを対象として解析する。

図 5-18 には各ドライバーの熟練と未熟練の分類結果を示している。結果を見ると D1, D2, D3 と D5 のドライバーに対して多く走行が熟練と分類し、D4, D6, D7, D8 のは全部未熟と分類された。ただし、全員の最初の2回走行を練習として抜いた。そのため、ここでは D1, D2, D3 と D5 について熟練と定義された走行だけを熟練グループとし、D6, D7, D8 の未熟練走行を未熟練グループとし、この2つのグループの走行データを対象として解析を行う。D4 は半々で、判断できないので、今回の解析には不採用とする。




図 5-18 各ドライバの熟練と未熟の分類結果

熟練と未熟練グループの差異性についてより詳細な検討を行うために、有意差検定を行った (U-test, $p < 0.05$). 具体的なデータ処理の手順としては、各走行の脳の計測データについてチャンネルごとに酸素消費量(ΔCOE)を 100m の単位で積分した後、両グループの有意差を検定する. 左右脳の頭頂連合野(BA7)において、熟練ドライバより活性化したエリアを図 5-19 に示している. 400m から特に 600m 以後が両グループの差が連続的に生じていると分かった. 図 5-20 に熟練と未熟ドライバの頭頂連合野(BA7)の活性の比較を示す. 結果をみると、熟練の方が BA7 はより活性化していることが分かった.


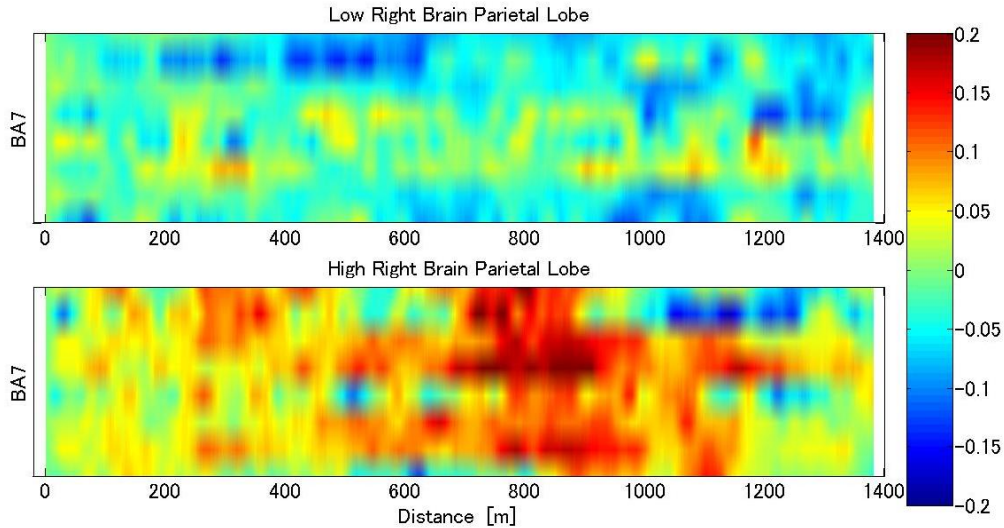
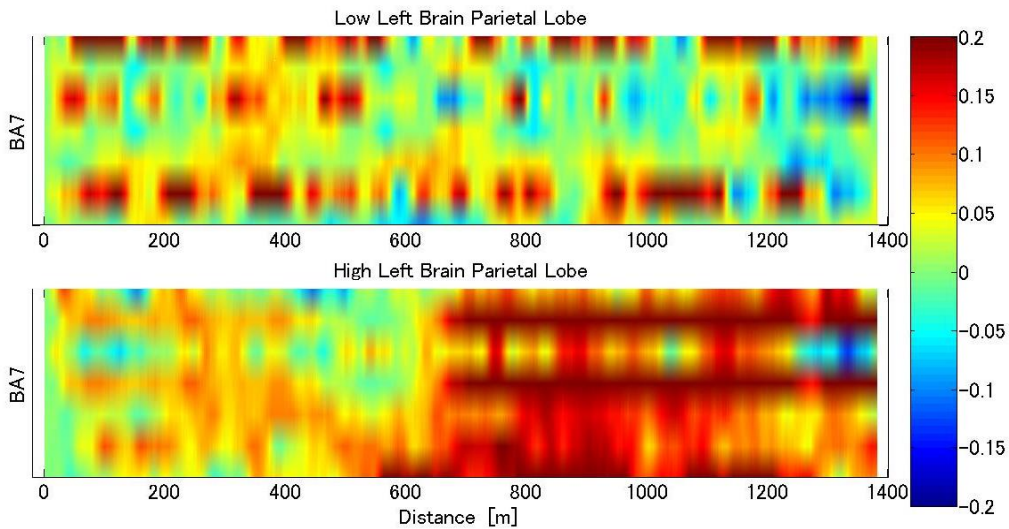


図 5-19 熟練ドライバより活性化エリア(BA7)



(a) 右脳の頭頂連合野(BA7)の活性の比較



(b) 左脳の頭頂連合野(BA7)の活性の比較

図 5-20 熟練と未熟ドライバの頭頂連合野(BA7)の活性の比較

運転技量と頭頂連合野(BA7)の関係を考察するために、熟練者と未熟練者の運転操作データと頭頂連合野(BA7)の活動を図 5-21 と図 5-22 に示している。熟練と未熟練グループの操作データを見ると、500m 前後まで略差がないが、500m から 1200m まで未熟練者はアクセルで速度調整が大きくて、速度が大幅落ちていることに対して、熟練の方がアクセルと速度共に安定していることが分かった。1200m 以後がカーブの定常円部に入ったので、両グループの速度、アクセルと操舵の差が段々になくなる。つまり、カーブの入口で、熟練ドライバは操舵とアクセル操作が一緒に行えるが、未熟練の方が操舵する時、アクセルを維持できない状況が分かった。図 5-22 に頭頂連合野(BA7)の領域に対して総 17 チャンネルの酸素消費量(ΔCOE)の波形を示している。500m から 1200m の区間内は、熟練の方が酸素消費量は大きくて、つまりより活性化している傾向が分かった。




図 5-21 熟練と未熟ドライバーの操作データの比較




図 5-22 熟練と未熟ドライバーの BA7 の活性化状況の比較

5.6 まとめ

本章では、第4章に構築された新しい実験環境を用いて、体感と運転技量の関係を解明することを目指して研究を展開した。具体的には、実在するテストコースをDS上で可能な限り再現して走行実験を行い、取得した実験データに基づいて、合成ジャークを用いて熟練と未熟練グループを定義し、熟練と未熟練走行の操作特徴差について解析した。両グループの走行データの差異性と機械学習手法で抽出された特徴差の整合性を確認した上、脳の活動の差異性について解析を行った。熟練ドライバーは運転する時、熟練と未熟練ドライバーの走行データの比較であり、カーブの入口で、未熟練ドライバーはアクセル操作調整が多かった。頭頂連合野(BA7)がより活性化していることが分かった。

第6章

考 察

高度運転支援システムや自動運転では、ドライバの運転技量の評価が重要である。運転行為の三要素の「認知・判断・操作」は全て脳活動に関わる。そのため、運転技量の評価はドライバの操作特徴だけでなく、運転中のドライバの脳活動の検討が必要である。運転する時、ドライバは視覚野、体性感覚野と前庭神経を含む各機能からフィードバックした体感情報を頭頂連合野で統合して、「認知・判断」のための適切な材料が用意されている。情報統合能力が運転技量に重要な影響を考えられる。本研究では、情報統合能力が運転技量に重要な影響を与えると仮説を立て、実験により検証する。

運転技量のレベルの定義については、本研究ではカーブの走行に着目して解析を展開するため、合成ジャークを分類時の指標に用いた。既存の研究によると、多くの研究には加速度の時間変化であるジャーク(加加速度)がドライバの運転技量を明らかにする上で重要なファクタに成り得ることが示されているからである^{[56][61][62]}。例えば、同じコースを走行するとき、熟練者は未熟練者に比べてスムーズに走行でき、相対的に小さいジャークとなる。

運転技量の評価のためには、熟練ドライバと未熟練ドライバの運転特徴差の把握が必要である。本研究では、運転操作特徴を抽出アルゴリズムとして、AdaBoost をベースとした手法を提案した。提案手法を検討するために、多曲率カーブにおいて運転免許を所有する 20~30 代の男女 16 名の被験者を対象として高い高臨場感を持つ DS を用いて走行実験を実施した。実験で得られた運転操作のデータについて合成ジャークを評価基準として熟練走行と未熟練走行とに分類し、熟練と未熟練ドライバの運転特徴をカーブごとで抽出した。抽出された箇所と特徴量を図 3-45 にまとめている。カーブの入口と出口において、操舵、アクセルと横変位に関わる特徴量が多く抽出された。カーブ進入時の速度や操舵調整が熟練と未熟練者の差と言え、横変位からは、カーブの進入と退出の軌跡に明確的な特徴差が存在することが示された(図 3-47)。

情報統合に関わる頭頂連合野の活性レベルと運転技量のレベルの関係を検討するためには、脳活動の計測が必要である。本研究では、DS を利用するとともに fNIRS を導入して、新しい実験環境を構築した。この新しい実験環境により、臨場感の高い環境下におけるアクセル、ブレーキとハンドルを含む複雑な運転操作と運転走行中のドライバの脳活動を同期して計測し、その解析を行うことが可能となる。新しい実験環境を検証するために、男女 15 名の被験者を対象として実証実験を行い、左右カーブの走行時における脳の活性状態と運転行動を計測した。本実験結果は fMRI を用いたドライバの脳活動に関する先行研究で報告された実験結果^[95]と一致しており、構築された実験環境で運転中のドライバの脳活動が計測可能であることが示された。

構築された実験環境を用いて、運転技量によるドライバの運転操作と脳活動の差異性を検討するために、被験者実験を行った。具体的には、実在するテストコースを DS で可能な限り再現して、健常ドライバ 8 名(男性 4 名、女性 4 名、平均年齢 33.3±4.6 歳)を対象として実験を行った。取得した実験データに基づいて、合成ジャークを用いて運転熟練者と未熟練者を定義し、両グループの走行データと頭頂連合野の活性状態の差異性を検出した。図 5-21 には熟練と未熟練

ドライバの走行データの比較であり、カーブの入口で、熟練ドライバは操舵とアクセル操作を同時に行えるが、未熟練ドライバは操舵する時にアクセル操作を維持できないことが分かった。該当結果と同じように、図 3-45 に示している提案された運転特徴抽出手法によって抽出された結果でも、カーブ進入時の速度や操舵調整について、熟練者と未熟練者との間に同じ傾向の明確な差が存在することが示された。つまり、本実験と運転特徴抽出実験の結果は一致していることが確認できた。図 5-22 には熟練者と未熟練者の頭頂連合野の活性化レベルを示している。本実験では頭頂連合野(BA7)の領域に対して 17 チャンネルを計測したため、17 チャンネルの酸素消費量(ΔCOE)の平均波形が図 5-22 に示されている。カーブの入口で熟練ドライバは酸素消費量(ΔCOE)の値が大きく、頭頂連合野はより活性化している傾向にあり、直線からカーブに進入する時、熟練ドライバは運転中の頭頂連合野の活性化レベルが高いことが示された。熟練ドライバと未熟練ドライバとで活性化レベルの違いが生じた頭頂連合野(BA7)は体性感覚情報を統合する脳機能である。図 5-21 と図 5-22 に示した実験結果によると、熟練ドライバは運転中頭頂連合野(BA7)がより活性化して、カーブを走行する時よりスムーズに運転できることが示された。つまり、本研究では、頭頂連合野の活性レベルと運転技量のレベルに関係があり、運転技量が高いドライバは運転中頭頂連合野の活性レベルも高いことを明らかにした。

実験結果では、運転技量によってドライバの頭頂連合野の活性化レベルが違うことが示された。頭頂連合野は情報統合に関わっているので、情報統合と運転技量の関係は図 6-1 のように表すことができる。運転する時、ドライバは各官能器官がセンサーとして運転に関連する情報を感知して、頭頂連合野で情報を統合して、判断のための適切な材料が用意される。運転熟練者は運転中頭頂連合野がより活性化し、情報統合の能力が高くて、運転が熟練になる。本研究では、情報統合が運転技量の評価において重要であることを明らかにした。

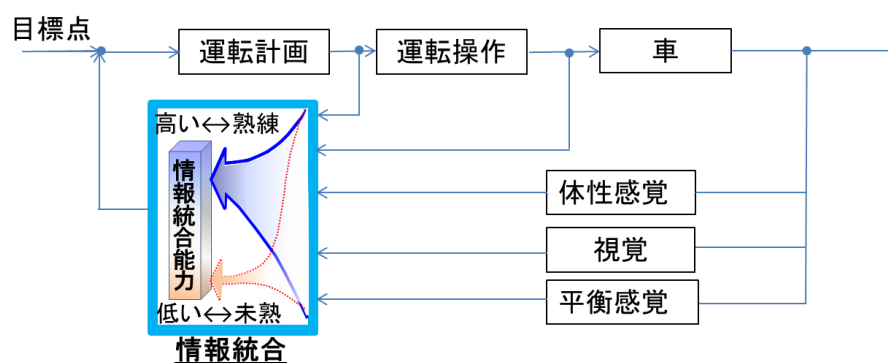


図 6-1 情報統合と運転技量の関係

本研究では、ドライバの情報統合の能力が運転技量に対して影響を与えることを示した。ここで、さらに情報統合について考察を行う。第 2.3 節で述べたように、餌を取るために道具を使っているサルを対象とした先行研究により、頭頂連合野では情報統合により拡張身体イメージを獲得していることが示されている^{[65][68][69]}。車を一つの道具として考えた場合、運転時のドライバは先行研究^{[65][68][69]}と同様に頭頂連合野で情報統合を行い、その結果として拡張身体イメージ

を獲得している可能性がある。このとき、車の輪郭などを含めた領域全体にドライバの身体イメージは拡張され、身体中心座標系で車の幅や姿勢が脳内に表現されることを意味する。そのため、ドライバの脳内で表現される車の幅や姿勢と現実の車両の幅や姿勢との誤差が小さいとき、熟練した走行ができるといった解釈もできる。つまり、車との高い一体感を持つドライバは運転技術が高く、その一体感に対して情報統合により獲得される拡張身体イメージの精度が影響していると考えられることもできる。

本研究の結果に基づいて、ドライバの情報統合能力について個人差がある。該当個人差を反映できる要素をドライバモデルに埋め込めれば、ドライバの運転特性をより高度化できる新しいドライバモデルを作成することが可能である。新しい高度運転支援システムや自動運転に関する研究開発への応用が期待できる。また、研究結果を活用して、ドライバの頭頂連合野の活動化レベルを計測して、情報統合の難易程度の立場から新しい車の性能を評価することへ活用することが期待できる。最後、提案手法によって、ドライバの脳活動がダイナミックに観測できたので、車を運転する際の判断や操作の脳内メカニズムを解明し、交通事故の防止することへの応用が期待できる。

本研究成果は次世代交通に関する様々な技術(安全・安心・快適)に組み込み、活用することが可能である。

第7章

結 論

自動車の運転技量は安全走行，燃料消費，乗り心地などに大きく影響を及ぼす．交通安全と省エネルギーなど問題を解決するために，高度運転支援システムから自動運転まで次世代自動車では，ドライバの運転技量の評価が重要である．本研究は，自動車分野におけるビッグデータの活用と脳科学分野の脳活動計測手法の進歩を背景として，自動車を運転するドライバの運転行動について，機械学習法と脳活動計測という新たな手法を活用して検討したものである．運転技量評価はドライバの運転操作特徴と運転中のドライバの脳活動とを合わせて検討することが必要なため，本研究では，まず，合成ジャークによって熟練と未熟練走行を定義し，機械学習法を用いて運転操作特徴を抽出する．次に，運転中のドライバの脳活動計測するために，脳活動計測手法を導入した新しい実験環境を構築する．そして，構築された実験環境を用いて，カーブ走行時のドライバの脳活動について熟練ドライバと未熟練なドライバの脳活動の差異について解析を行った．最後に，本実験環境を用いて，情報統合に係る頭頂連合野の活性レベルと運転技量のレベルに関係に関する仮説について考察を展開した．以下，各章における総括を述べ，本論文の結論を述べる．

第1章では，本研究の背景として我が国における ITS の現状，ITS 分野のビッグデータと脳科学分野の脳計測技術および先行研究の状況について述べた．本背景に基づいて，本研究の目的，論文の構成を述べた．

第2章では，まず，運転技量を定義して，運転技量に関するドライバモデルの先行研究を述べた．その後，脳科学における動作のメカニズムについて述べるとともに，情報統合が運転技量に重要な影響があるという仮説を提案した．

第3章では，熟練ドライバと未熟練ドライバの運転特徴差を把握するために，運転操作の特徴を抽出アルゴリズムとして，AdaBoost のアルゴリズムをベースとした手法を提案した．DS 実験により運転操作のデータを取得して，提案手法を検証した．これにより，熟練者と未熟練者がどのような場所で，どのような操作に違いがあるかが抽出された．また，抽出された特徴差に基づいて，未熟練者を対象としたアドバイス実験も行い，実験結果から被験者の運転技量の向上が可能であることを確認し，本提案手法の有用性を示した．

第4章では，運転中のドライバの脳活動を観測するために，新しい実験環境を構築した．高い臨場感を持っている DS と最先端の脳の計測技術 fNIRS によって新しい実験環境が構築された．新しい実験環境の有効性を検証するために，運転中のドライバの脳活動を計測して，左カーブと右カーブの走行の差などの特徴を検出した．DS でドライバの一般走行行動と脳の活性の評価実験が可能であることが検証された．

第5章では，新しい実験環境を用いて，脳活動と運転技量の関係を検討するために研究を行った．具体的には，実在するテストコースを DS 上で可能な限り再現して走行実験を行い，取得した実験データに基づいて，合成ジャークを用いて運転の熟練者と未熟練者を定義し，両グループ

の走行データの差異と脳の活動の差異を検出した。運転技量の高いドライバーでは、頭頂連合野(BA7)の活性化レベルが高いことがわかった。

第6章では、抽出された運転行動とドライバー脳活動の差異性による運転技量の評価を念頭において、ドライバーの脳で情報が統合されていることと運転技量の関係を考察している。頭頂連合野(BA7)は情報統合に関わっているため、頭頂連合野(BA7)の活性化レベルが高いドライバーは視覚、体感、操作などのドライバーの運転行動に係る情報の統合ができ、運転技量のレベルが高いことが示された。これらの知見から、ドライバーの運転技量は、拡張身体イメージを適切に生成できることと重要な関係があるという解釈もできる。

最後に本研究の結論を述べる。本研究では、情報統合が運転技量に重要な影響を与えるという仮説を立て、実験により仮説の妥当性を検証した。具体的には、まず、ドライバーの運転特性について、従来の多くの研究が演繹手法により制御工学などの立場から伝達関数や方程式で表現してきたが、本研究は機械学習手法を用いて帰納的な手法の観点からドライバーの運転特徴の抽出手法を提案した。次に、脳科学領域ではスタティックな実験条件下での脳活動の観測が一般的だが、本研究では運転中というダイナミックな条件下でドライバーの脳活動を観測可能な新たな実験環境を構築した。最後に、運転技量のレベルと頭頂連合野の活性化レベルの関係を明らかにし、仮説の妥当性を確認し、以下の結論を得た。

- 機械学習手法に基づいた特徴抽出手法を提案し、実証実験により熟練と未熟のドライバーの走行特徴を明らかにするとともに本提案手法の有効性を確認した。特徴量がカーブの入口と出口で多く出て、特に走行軌跡、操舵とアクセルに関わっていることが分かった。
- DS と fNIRS を組み合わせることによってドライバーの脳活動の計測が可能な新しい実験環境を構築した。DS 走行実験により本実験環境の有効性と、ドライバーの脳活動がダイナミックに観測できることを実証した。
- 構築された実験環境を用いて、自動車を運転するドライバーの運転技量と脳活動を計測し、運転技量の高いドライバーは情報統合能力が高いことを明らかにした。脳科学に基づいて生理学的の見地から、情報統合が運転技量に重要な影響を与えること明らかにした。運転技量を評価する新たな知見を得た。

今後の展望について、交通現象に対して他車両や信号や標識や歩行者など様々な交通要素に対して、提案方法を用いて運転の「認知・判断・操作」と脳の活動の関係を検討することによって、更なる新たな知見と発見が期待される。また、本研究結果に基づいて、ドライバーの運転特性をより高度化できる新しいドライバーモデルを作成することが可能であり、高度運転支援システムや自動運転に関する研究開発への応用が期待できる。研究成果は次世代交通に関する様々な技術(安全・安心・快適)に組み込み、活用することが可能である。

参考文献

- [1] 国土交通省道路局ホームページ, ITS 関連用語集
<http://www.mlit.go.jp/road/ITS/j-html/past/yougo/index.html#35> (2014年12月14日アクセス)
- [2] 藤岡健彦, 鎌田実, 自動車プロジェクト開発工学, 技報堂出版, 2001.5
- [3] 道路交通情報通信システムセンター, <http://www.vics.or.jp/about/index.html> (2014年12月10日アクセス)
- [4] 国土技術政策総合研究所 高度道路交通システム研究室ホームページ, ITS 関する研究
http://www.nilim.go.jp/japanese/its/0frame/under/01etc/index_04.htm (2014年11月29日アクセス)
- [5] 奥谷正, ITS をめぐる最近の動向(スマートウェイと大規模実証実験について), 日本道路協会, 第56回道路講習会, 平成21年1月
- [6] 道辻洋平, 目崎大輔, 永井正夫, 小竹元基, 鎌田実, 茂呂克己, “ドライブレコーダを活用した交差点黄信号におけるドライバ挙動の分析”, 2008年自動車技術会春季大会, 学術講演会前刷集, No.1-08, pp.31-36, 2008
- [7] 内田ら, 映像記録型ドライブレコーダ活用によるヒヤリハット研究, 自動車研究, Vol.27, No.11, 2005
- [8] 内田ら, “予防安全研究用ドライブレコーダを用いた歩行者認知遅れ要因の検討”, 2008年自動車技術会春季大会, 学術講演会前刷集, No.151-08, pp.17-22, 2008
- [9] ドライブレコーダの最新動向に関する調査結果, 矢野経済研究所, 2008
- [10] 狩野均, “高度道路交通システム(ITS)とAI”, 人工知能学会誌, 15巻2号, 2000年3月
- [11] 細川隆志, 谷畑孝二, 宮本寛明, “次世代電気自動車 iMiEV の開発(第二報)”, 三菱自動車テクニカルレビュー, No.20, pp.53-60, 2008
- [12] 山口大助, 市原隆司, 熊野史朗, 佐藤洋一, 須田義大, 李曙光, “自車状況と周囲状況を考慮したエコドライブレベルの評価”, 生産研究, 63巻2号, Page 137-142, 2011
- [13] 警察庁交通事故発生状況, 「平成25年中の交通事故死者数について」
<http://www.npa.go.jp/toukei/koutuu48/toukei.htm>
- [14] 松山貴代子, 米運輸省が発表した, 自律走行車開発に関する政策方針の概要, NEDO ワシントン事務所調査レポート, <http://www.nedodcweb.org/report.html>
- [15] 内閣府, SIP (戦略的イノベーション創造プログラム) 自動走行システム研究開発計画, 2014.5.23, <http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/>
- [16] 国土交通省, 国内外における最近の自動運転の実現に向けた取組概要,
<http://www.mlit.go.jp/road/ir/ir-council/autopilot/doc04.html>
- [17] 柴田文隆, 須田教授が考える「自動運転の5階段」, 讀賣新聞, 2014.06.17
- [18] ITS Japan 「通行実績・通行止情報」<http://www.its-jp.org/saigai/>
- [19] 赤松幹之, “人を知ることでモビリティはどう変わるのか”, JSAE Professional Course No.02-11, 2011
- [20] G. Strangman et al, Non-Invasive Neuroimaging Using Near-Infrared Light, BIOL PSYCHIATRY 2002;52:679-693
- [21] 本間伊佐子; 江部充. 脳波. 臨床検査, 1965, 9.12: 1248-1254.

- [22] Stefan Haufe et.al, EEG potentials predict upcoming emergency brakings during simulated driving, *Journal Of Neural Engineering*, 2011.8.056001
- [23] 寺田佳久ら, 脳波によるドライバ注意散漫状態推定技術の開発, *Panasonic Technical Journal* Vol.57 No.3,2011, pp. 73-75
- [24] Lars Torsval, et.al, Sleepiness on the job: continuously measured EEG changes in train drivers, *Electroencephalography and chmcal Neurophysiologist*, 1987. 66 502-511
- [25] Saroj K.L. Lal, et. al, Development of an algorithm for an EEG-based driver fatigue countermeasure, *Journal of Safety, Research* 34 (2003) 321–328
- [26] Hong J. Eoh, et.al, Electroencephalographic study of drowsiness in simulated driving with sleep deprivation, *International Journal of Industrial Ergonomics* 35 (2005) 307–320
- [27] 中野公彦ら, パラレルファクター解析によるドライビングシミュレータ運転者脳波の解析, *生産研究*, 2009, Vol.61, No.2, pp.66-69
- [28] Toshihito Ikenishi et. al, Estimation of the driver's steering intention for preceding car with the brain current distribution estimation, *12th International Symposium on Advanced Vehicle Control*, 2014
- [29] Toshihito Ikenishi, et. al “Parallel Factor Analysis of Driver’s EEG in Lane Change Maneuver for Cooperative Driver Assistance Systems”, *Analysis Design and Evaluation of Human-Machine Systems*, Vol.11, 2010, pp.105-110.
- [30] 日本聴覚医学会, 日本聴覚医学会用語集(2011.9.16), <http://audiology-japan.jp/audi/?p=3922>
- [31] Yuji Uchiyama, et.al, The neural substrates of driving at a safe distance: a functional MRI study, *Neuroscience Letters* 352 (2003) 199–202
- [32] V.D. Calhoun, et.al, A selective review of simulated driving studies: Combining naturalistic and hybrid paradigms, analysis approaches, and future directions, *NeuroImage*, 2012: Vol. 59, Issue 1, 25–35
- [33] Scott C. et.al, Functional Near-Infrared Spectroscopy, *IEEE Engineering In Medicine And Biology Magazine*, 2006: Vol.25,Issue 4, 54-62
- [34] Toshinori Kato, et.al, Human visual cortical function during photic stimulation monitoring by means of near-infrared spectroscopy. *Jouranal of Cerebral Blood Flow and Metabolism*, 1993: Vol.13, No.3, 516-520
- [35] 小島崇ら, 列車運転時の高次脳機能計測に関する研究, *日本機械学会第 15 回交通・物流部門大会講演論文集*, 2006, No.06-52, 313-316
- [36] 柳沼健, 綱島均, 丸茂喜孝, 小島崇, 伊藤誠, 稲垣敏之, 自動車運転時における前頭連合野の高次脳機能計測, *日本機械学会第 16 回交通・物流部門大会講演論文集*, 2007, No.07-51, 297-300
- [37] Yoshino K, Oka N, Yamamoto K, Takahashi H, Kato T. (2013) Correlation of prefrontal cortical activation with changing vehicle speeds in actual driving: a vector-based functional near-infrared spectroscopy study. *Front. Hum. Neurosci.* doi: 10.3389/fnhum.2013.00895.
- [38] Germaine L. odenheimer, Marie Beaudet, “Performance-Based Driving Evaluation of the Elderly

- Driver: Safety Reliability and Validity”, *Journal of Gerontology MEDICAL SCIENCES* 1994,11
- [39] Susan A. Ferguson, “Other high-risk factors for young drivers”, *Journal of Safety Research* 2003,(34) 71-77
- [40] 梶座邦朝, 萩原享, “カーブの線形条件と走行条件がドライバの運転挙動と主観評価に与える影響”, *土木計画学研究・講演集(CD-ROM)*, 2004.11
- [41] 多田昌裕, 大村廉, 岡田昌也, 納谷太, 野間春生, 鳥山朋二, 小暮潔, “加速度センサーを用いた行動計測に基づく運転動作解析手法”, *情報処理学会インタラクシオン 2007*
- [42] 福島達朗, 合志和晃, 松永勝也, 林政喜, 隅田康明, “安全運転教育システム ASSIST における運転者識別機能を持つ管理ソフトウェアの開発”, 第 10 回 ITS シンポジウム, *Proceedings 2-D-10*, 2011
- [43] 山田真以, 山下琴美, 山崎初夫, 川澄未来子, 山田宗男, 山本新, 中野倫明, “初心運転者の能力測定・評価に関する検討”, 第 10 回 ITS シンポジウム, *Proceedings 1-D-04*, 2011
- [44] 張慶, 合志和晃, 松永勝也, 林政喜, 菖蒲力功, “一時停止教育のための衝突体験型ドライビングシミュレータの開発”, 第 10 回 ITS シンポジウム, *Proceedings 1-C -06*, 2011
- [45] Y. Saboohi, H. Farzaneh, "Model for developing an eco-driving strategy of a passenger ehicle based on the least fuel consumption", *Applied Energy*, Vol.86, pp.1925–1932, 2009
- [46] L. Evans & R. C. Schwing (Eds.), "A Critical View Of Driver Behavior Models: What Do We Know, What Should We Do?", *Human behavior and traffic safety*, New York: Plenum Press, 1985. pp. 485-520, 1985.
- [47] 田中悠樹, 田中伸治, 桑原雅夫, “交差点錯綜区間のドライバモデルの構築及び検証”, *生産研究*, 63 巻 2 号, pp. 169-172, 2011
- [48] 佐藤桂, 前田公三, 綱井秀樹, 永井正夫, 佐々木和也, 米川隆, “高速道路での厳しい車線変更場面の運転行動解析とモデリング”, 第 10 回 ITS シンポジウム, *Proceedings 2-D-01*, 2011
- [49] Yilu Zhang, William C. Lin, Yuen-Kwok Steve Chin. “A Pattern-Recognition Approach for Driving Skill Characterization”. *IEEE Transactions on Intelligent Transportation System*, 2010: Vol.11, No.4: 905-916.
- [50] Naiwala P. Chandrasiri, Kazunari Nawa and Ichiro Kageyama, *Classification of Driving Skills based on Machine Learning*, FISITA 2010 World Automotive Congress, May, 2010
- [51] 池西俊仁, 町田寛, 鎌田崇義, 永井正夫, EEG を用いたステアリング操舵意図の推定, *自動車技術会*, 39(6), 23-28, 2008
- [52] 松島寛樹ら, ドライビングシミュレータ運転時における脳波計測とその解析, *ロボティクス・メカトロニクス講演会講演概要集 2009*, "2A2-M11(1)"-"2A2-M11(4)", 2009-05-25
- [53] 古川修, アクティブセーフティ技術の現状と今後の動向, *自動車技術* 63(1), 54-59, 2009-01-01
- [54] 清水俊喜, 栗谷川幸代, 景山一郎, ドライバの運転動作解析に関する研究, 本大学生産工学部第 45 回学術講演会講演概要, 2012-12
- [55] 栗谷川幸代, ドライバモデル, *日本機械学会交通物流部門・基礎セミナー「自動車の運動力学」*, 2012-6-16
- [56] 下山修, 自動車の運転技量差に注目したドライバ特性の研究, *東京大学博士論文*, 2014.3

- [57] Yukiyo Kuriyagawa, et.al, Research on Analytical Method of Driver-Vehicle-Environment System for Construction of Intelligent Driver Support System, *Vehicle System Dynamics*, 2002, Vol.37, No5, pp. 339-358.
- [58] F. Mars, Driving around bends with manipulated eye-steering coordination, *Journal of Vision* (2008) 8(11):10, 1-11
- [59] Dario D Salvucci, et.al, A two-point visual control model of steering, *Perception*, 2004, vol. 33, pp.1233-1248
- [60] T. Hiraoka, T. Kunimatsu, O. Nishihara, H. Kumamoto, Modeling of driver following behavior based on minimum-jerk theory, *Proc. of 12th World Congress on Intelligent Transport Systems*, (2005), CD-ROM
- [61] Noboru KUBO, Midori MORI, An Effective Automatic Classification Method of Drive Recorder Data, *Transactions Of The Japan Society Of Mechanical Engineers Series C*, Vol. 77, No. 778 (2011), pp.2506-2521
- [62] O'Brien, R.T., Iglesias, P.A, Urban, T.J, Vehicle lateral control for automated highway systems, *Control Systems Technology*, IEEE Transactions on May 1996, Volume: 4 Issue:3, 266-273
- [63] Y. L. Murphey, R. Milton, L. Kiliaris, Driver's Style Classification Using Jerk Analysis, *IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems* (2009) 23-28
- [64] 理科ねっとわーく <http://rikanet2.jst.go.jp/contents/cp0220c/contents/7h/f/f16.html>
- [65] 入来篤史, ニホンザル道具使用の脳内機構——シンボル操作の起源に挑む——, *Cognitive Studies*, 7(3), 195-201. (Sep. 2000)
- [66] 松村道一, 小田伸午, 石原昭彦編, 脳百話～動きの仕組みを解き明かす～, 市村出版, 2010. 10, pp16-17, pp112-113,
- [67] 村田哲, 手操作運動のための物体と手の脳内表現, *VISION* Vol. 16, No. 3, 141-147, 2004
- [68] 入来篤史, 道具を使う——心と言語と人が生まれるとき——, *Riken New*, No. 329, 6-9, 2008
- [69] 入来篤史, 道具を使う手と脳の働き, *日本ロボット学会誌*, Vol.18, No.6, pp.786-791, 2000
- [70] 開一夫, 長谷川寿一, ソーシャルブレインズ, 自己と他者を認知する脳, 東京大学出版会, pp71, 2009
- [71] 鍋島厚太 國吉康夫, 能動触における感覚統合と対象同定に基づく道具身体化モデル, 24 回 日本ロボット学会学術講演会, 2L21, 2006.
- [72] 上杉繁, 三輪敬之, 身体的インタフェースとしての道具, *エンタテインメントコンピューティング*, pp.1-2, 2006.9
- [73] Sophie K. Piper, Arne Krueger, Stefan P. Koch, Jan Mehnert, Christina Habermehl, Jens Steinbrink, Hellmuth Obrig, Christoph H. Schmitz, A wearable multi-channel fNIRS system for brain imaging in freely moving subjects, *NeuroImage* 85, 64-71, 2014
- [74] 衛藤裕司, ボディ・イメージとその類縁概念, ——「定義」に関する方法論の検討——, 大分大学教育科学部研究紀要, 21(2), 325-333, 1999
- [75] A Iriki, M Tanaka, Y Iwamura, Coding of modified body schema during tool use by macaque postcentral neurones. *Neuroreport*: 1996, 7(14):2325-30

- [76] B. Calvo-Merino, D.E. Glaser, J. Grezes, R.E. Passingham and P. Haggard, Action Observation and Acquired Motor Skills: An fMRI Study with Expert Dancers, *Cerebral Cortex* 2005, No.15: pp.1243--1249
- [77] 浦田瞳, 熟練ソフトボール選手と非運動群の脳賦活部位の違い: GO/NO-GO 課題を用いた fMRI 研究, *人間科学研究* 2006, Vol. 19, pp. 6
- [78] BISHOP, Christopher M. パターン認識と機械学習上. ベイズ理論による統計的予測, 2007.
- [79] 山下隆義, 統計的学習手法を用いた物体認識における特徴量の進化; 2008.6
<http://www.vision.cs.chubu.ac.jp/ssii08/ssii08-yamashita.pdf>
- [80] P. Viola, M. Jones, Robust Real-time Object Detection, *International Journal of Computer Vision*, Vol.57, No.2, (2001), 137-154
- [81] 須田義大・山口大助, ユニバーサルドライビングシミュレータの開発と展開, *油空圧技術*, 日本工業出版 Vol.49, No.4, pp. 36-39, (2010)
- [82] 山口大助, 市原隆司, 熊野史朗, 佐藤洋一, 須田義大, 李曙光, 自車状況と周囲状況を考慮したエコドライブレベルの評価, *生産研究* 63(2), pp. 137-142, (2011)
- [83] 堀口研一, 熊野史郎, 山口大助, 佐藤洋一, 須田義大, 運転状況を考慮した脇見推定手法, 第 6 回 ITS シンポジウム, pp. 483-488, (2007)
- [84] 谷口龍太, 三田彰, 波動伝播特性を用いた損傷検知手法に関する基礎的研究, *応用力学論文集* Vol.5, 2002 年 8 月
- [85] Chinmaya Kar, A.R. Mohanty, Monitoring gear vibrations through motor current signature analysis and wavelet transform, *Mechanical Systems and Signal Processing* 20, 158–187, 2006
- [86] H. Douglas, P. Pillay, The Impact Of Wavelet Selection On Transient Motor Current Signature Analysis, *Electric Machines and Drives*, 2005 IEEE International Conference, 2005
- [87] 上浦正樹, 離散ウェーブレット解析を用いた復元波形に関する検討, 北海学園大学学術研究会, 2008,9, 第 137 号
- [88] Mallat, S, "A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Pattern Anal. and Machine Intell.*, vol. 11, no. 7, pp. 674-693, 1989
- [89] 田村暁斗, 諸岡健一ら, AdaBoost による気道・食道自動識別, *電子情報通信学会論文誌 D* Vol. J92-D No.12 pp.2249-2260
- [90] Niu Bing; Cai Yu-Dong; Lu Wen-Cong; Li Guo-Zheng; Chou Kuo-Chen, *Protein and Peptide Letters*, Volume 13, Number 5, May 2006, pp. 489-492(4)
- [91] 日本自動車研究所, <http://www.jari.or.jp/tabid/148/Default.aspx>
- [92] コニカミノルタのホームページ: <http://www.konicaminolta.jp/>
- [93] 脳科学辞典・ブロードマン脳地図, <http://bsd.neuroinf.jp/wiki/ブロードマンの脳地図>
- [94] LAND, Michael F.; LEE, David N. Where do we look when we steer. *Nature*, 1994.
- [95] Schweizer, T. A., Kan, K., Hung, Y., Tam, F., Naglie, G., & Graham, S. J. (2013). Brain activity during driving with distraction: an immersive fMRI study. *Frontiers in human neuroscience*, 7.

本研究に関する発表論文など

1. 学術論文

[1] 著者: **李曙光**, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大, ナイワラ P.チャンドラシリ,
那和一成, 松村健, 田口康治

題目: カーブ走行の操舵に着目したドライバの運転特徴抽出に関する研究

雑誌名: 自動車技術会論文集 Vol.43, No.6, 2012

[2] 著者: **Shuguang Li**, Shigeyuki YAMABE, Yoichi SATO, Takayuki HIRASAWA,
Yoshihiro SUDA, Naiwala P. CHANDRASIRI, Kazunari NAWA

題目: Driving Feature Extraction from High and Low Skilled drivers in Curve Sections Based
on Machine Learning

雑誌名: Journal of Mechanical Systems for Transportation and Logistics, Vol.6, No.2, 2013

[3] 著者: **Shuguang Li**, Shigeyuki YAMABE, Yoichi SATO, Yoshihiro SUDA,
Naiwala P. CHANDRASIRI, Kazunari NAWA

題目: Learning characteristic driving operations in curve sections that
reflect drivers' skill levels

雑誌名: International Journal of ITS Research

[4][査読中] Noriyuki Oka, Kayoko Yoshino, Kouji Yamamoto, Hideki Takahashi, **Shuguang Li**,
Toshiyuki Sugimachi, Kimihiko Nakano, Yoshihiro Suda, Toshinori Kato

題目: Greater activity in the frontal cortex on left curves: a vector-based fNIRS study of
left and right curve driving Frontal lobe

雑誌名: PLOS ONE

2. 国際学会

[1] 著者: **Shuguang Li**, Shigeyuki Yamabe, Yoichi Sato, Takayuki Hirasawa,
Yoshihiro Suda, Naiwala P. Chandrasiri, Kazunari Nawa,
Takeshi Matsumura, Koji Taguchi

題目: Finding Dominant Driving Operations in Curve Sections Differentiating
Skilled and Unskilled Drivers

学会名: 34th FISITA World Automotive Congress

論文番号: Paper Reference No. F2012-I01-016

場所, 月・年: Beijing, China, November, 2012

[2] 著者: Naiwala P. Chandrasiri, Kazunari Nawa, Akira Ishii, **Shuguang Li**,
Shigeyuki Yamabe, Yoichi Sato, Takayuki Hirasawa,
Yoshihiro Suda, Takeshi Matsumura, Koji Taguchi

題目: Driver Skill Analysis using Machine Learning: The full curve and curve

segmented cases

学会名 : The 12th International Conference on ITS Telecommunications (ITST 2012)

論文番号 : Paper Reference No. 1569626149

場所, 月・年 : Taipei, Taiwan, November, 2012

[3] 著者 : **Shuguang Li**, Daisuke Yamaguchi, Yoichi Sato, Yoshihiro Suda,

Takayuki Hirasawa, Shojiro Takeuchi, Satomi Yoshioka

題目 : Differentiating Skilled and Unskilled Drivers by Using an Adaboost Classifier
for Driver's Operations

学会名 : 18th World Congress on Intelligent Transport System

論文番号 : Paper No. TS92-3044

場所, 月・年 : Orlando, USA, October, 2011

[4] 著者 : Noriyuki Oka, Kayoko Yoshino, Kouji Yamamoto, Hideki Takahashi,

Yoshitomo Orino, **Shuguang Li**, Toshiyuki Sugimachi, Shigeyuki Yamabe,

Kimihiko Nakano, Yoshihiko Tabuchi, Yoshihiro Suda, Toshinori Kato,

題目 : Activation of the right prefrontal cortex during left curve driving:
a vector-based fNIRS study

学会名 : The 20th Annual Meeting of the Organization for Human Brain Mapping

場所, 月・年 : Hamburg, Germany June, 2014

[5] 著者 : Kouji Yamamoto, Hideki Takahashi, Orino Yoshitomo, **Shuguang Li**,

Toshiyuki Sugimachi, Kimihiko Nakano, Yoshihiko Tabuchi,

Yoshihiro Suda, Noriyuki Oka, Kayoko Yoshino, Toshinori Kato

題目 : Validation Study on Evaluation of Traffic Safety Installations Using fNIRS

学会名 : ITS WORLD CONGRESS 2014

場所, 月・年 : Detroit, USA September 2014

[6] 著者 : **Shuguang Li**, Toshiyuki Sugimachi, Shigeyuki Yamabe, Kimihiko Nakano,

Yoshihiko Tabuchi, Yoshihiro Suda, Kouji Yamamoto, Hideki Takahashi,

Orino Yoshitomo, Noriyuki Oka, Kayoko Yoshino, Toshinori Kato

題目 : Characteristics between Driving Operation and Brain Activity in Curve Sections

学会名 : ITS WORLD CONGRESS 2014

場所, 月・年 : Detroit, USA September 2014

[7] 著者 : Takashi Ichihara, Shiro Kumano, Daisuke Yamaguchi, Yoichi Sato,

Yoshihiro Suda, **Shuguang Li**

題目 : Evaluation of eco-driving skill using traffic signals status information

学会名： ITS World Congress (ITSWC2010) 論文番号: TP 064 - 2
場所, 月・年： Busan, South Korea, 2010.11

[8] 著者： **Shuguang Li**, Shigeyuki Yamabe, Yoichi Sato, Takayuki Hirasawa, Y
oshihiro Suda

題目： Advanced Driver Assistant System Using Telematics

学会名： 7th IFAC Symposium on Advance in Automotive Control

場所, 月・年： Tokyo, Japan, September, 2013

3. 国内学会・シンポジウム

[1] 著者：**李曙光**, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大,

ナイワラ P. チャンドラシリ, 那和一成, 松村健, 田口康治

題目：カーブ走行の操舵に着目したドライバの運転特徴抽出に関する研究

学会名：自動車技術会春季学術講演会

論文番号：JSAE Paper No. 7-20125334 場所, 月・年：横浜パシフィコ, 2012.5

[2] 著者：**李曙光**, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大

題目：テレマティクスデータ活用を想定した運転操作レベルの判別

学会名：第 11 回 ITS シンポジウム 2012 場所, 月・年：名古屋, 2012.12

[3] 著者：**李曙光**, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大,

ナイワラ P. チャンドラシリ, 那和一成, 松村健, 田口康治,

題目：機械学習手法を用いたカーブ走行時の運転熟練／未熟練の特徴抽出に
関する研究”

学会名：日本機械学会第 21 回交通・物流部門大会 場所, 月・年：東京, 2012.12

[4] 著者：洪性俊, 山邊茂之, **李曙光**, 大口敬

題目：ドライビングシミュレータを利用した 車線閉鎖時における車線変更挙動の分析

学会名：第 11 回 ITS シンポジウム 2012 場所, 月・年：名古屋, 2012.12

[5] 著者：**李曙光**, 山口大助, 平沢隆之, 佐藤洋一, 須田義大, 竹内彰次郎, 吉岡里見

題目：ドライバの熟練度に関する運転特徴量の抽出

学会名：第 10 回 ITS シンポジウム 2011

論文番号：Paper No. 1-D-04 場所, 月・年：東京, 2011.5

[6] 著者：山口大助, **李曙光**, 平沢隆之, 佐藤洋一, 須田義大, 竹内彰次郎, 吉岡里見

題目：スキルの高いドライバの運転特徴抽出に関する研究

学会名:自動車技術会春季学術講演会

論文番号: JSAE Paper No. 363-20115357 場所, 月・年: 神奈川, 2011.5

[7] 著者: 山口大助, 須田義大, 中野公彦, 安藝雅彦, 鄭仁成, 山邊茂之, 李昇勇, **李曙光**

題目: 省エネ運転制御アルゴリズムに関する研究,

学会名: 日本機械学会 2011 年度年次大会

論文番号: DVD-ROM 論文集, No.11-1, 場所, 月・年: 東京工業大学, 2011.09

[8] 著者: 山口大助, 市原隆司, 熊野史朗, 佐藤洋一, 須田義大, **李曙光**,

題目: 自車状況と周囲状況を考慮したエコドライブレベルの評価”,

学会名: ITS シンポジウム 2010,

場所, 月・年: 京都, 2010.12

[9] 著者: 山口大助, 市原隆司, 熊野史朗, 佐藤洋一, 須田義大, **李曙光**,

題目: 信号提示を考慮したエコドライブ評価

学会名: 自動車技術会秋季大会,

場所, 月・年: 北九州国際会議場, 2010.9

[10] 著者: **李曙光**, 杉町敏之, 山邊茂之, 中野公彦, 田淵義彦, 須田義大,

高橋秀喜, 折野好倫, 山本浩司, 吉野加容子, 岡徳之, 加藤俊徳

題目: 脳の計測に基づくドライバの運転特性分析

学会名: 日本機械学会第 22 回交通・物流部門大会 場所, 月・年: 東京, 2013

[11] 著者: **李曙光**, 杉町敏之, 山邊茂之, 中野公彦, 田淵義彦, 須田義大,

高橋秀喜, 折野好倫, 山本浩司, 吉野加容子, 岡徳之, 加藤俊徳

題目: ドライビングシミュレータを用いた脳の計測に基づくドライバの運転特性

学会名: 自動車技術会春季大会 場所, 月・年: 横浜, 2014.5

[12] 著者: **李曙光**, 杉町敏之, 山邊茂之, 中野公彦, 田淵義彦, 須田義大,

高橋秀喜, 折野好倫, 山本浩司, 吉野加容子, 岡徳之, 加藤俊徳

題目: fNIRS を用いた実車とドライビングシミュレータ運転時のドライバの脳活動と走行データの比較

学会名: 第 12 回 ITS シンポジウム 2013 場所, 月・年: 仙台 2014.12

4. 紀要

[1] 著者: **李曙光**, 山口大助, 平沢隆之, 佐藤洋一, 須田義大

題目: ドライバの熟練度に関する運転特徴量の抽出

雑誌名: 生産研究 巻: 64, 号: 2, ページ: 263-268, 2012 年

- [2] 著者: **李曙光**, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大
題目: テレマイクスデータ活用を想定した運転レベルの判別
雑誌名: 生産研究 巻: 65, 号: 2, ページ: 205-210, 2013年6月
- [3] 著者: 洪性俊, 山邊茂之, **李曙光**, 大口敬
題目: ドライビングシミュレータを利用した車線閉鎖時における車線変更挙動の分析
雑誌名: 生産研究 巻: 65, 号: 2, ページ: 241-245, 2013年6月
- [4] 著者: 山口大助, 市原隆司, 熊野史郎, 佐藤洋一, 須田義大, **李曙光**,
題目: 自車状況と周囲状況を考慮したエコドライブレベルの評価
雑誌名: 生産研究 第63巻, 第2号, 2011

5. 表彰等

- [1] 李曙光, 東京大学大学院情報学環・学際情報学府 専攻長賞, 2012年

6. 関連特許提出

- [1] [公開中](WO2012157255) VEHICLE DATA ANALYSIS METHOD AND VEHICLE DATA ANALYSIS SYSTEM

謝 辭

本論文は、著者が東京大学大学院工学系研究科機械工学専攻博士課程在学中に、東京大学生産技術研究所における研究をまとめたものです。

本研究は、東京大学生産技術研究所 須田義大教授のご指導の下、行われたものです。温かいご指導および多大なるご助言を頂きましたことを心より感謝いたします。

東京大学大学院工学系研究科 金子成彦教授、東京大学生産技術研究所 佐藤洋一教授、東京大学大学院情報学環・学際情報学府 中野公彦准教授、東京大学工学系研究科 機械工学専攻 小竹元基准教授には、本論文をまとめるにあたり、貴重なご助言を頂きました。深く感謝申し上げます。

本研究の遂行に当たりまして、大変多くの方々にお世話になりました。

トヨタ自動車株式会社の杉本浩伸様、竹内彰次郎様、吉岡里見様、松村健様、田口康治様、トヨタ IT 開発センターの Naiwala P. Chandrasiri 様、小森達也様には、研究の方向性・重要性に関する様々な貴重なご助言を頂きました。深く感謝いたします。

中日本高速道路株式会社の山本浩司様、高橋秀喜様、織部福良様、升方充様、折野好倫様、石橋善明様、馬淵一三様には、研究に多大なるご協力を頂きました。深くお礼申し上げます

脳の学校株式会社の加藤俊徳様、吉野加容子様、岡徳之様には、脳の計測を伴う実験においてご協力いただくだけでなく、データ解析と脳科学の見地から本研究に関する助言を頂きました。深く感謝いたします。

日産自動車株式会社の伊藤一也様、對馬将示様、斉藤春樹、安野芳樹様には、ドライバの運転特性等に関わる知見に基づくご助言を頂きました。深く感謝いたします。

三菱プレジジョン株式会社、株式会社ジェイテクト、株式会社代田橋製作所の方々にはドライビングシミュレータに関わる技術サポートして頂き、深く感謝いたします。

東京大学生産技術研究所須田研究室シニア協力研究員 田淵義彦先生、田島洋先生、埼玉工業大学の下山修教授には、研究に必要な多くの知識や技術をご教授頂きました。深く感謝いたします。

研究に全面的にサポートしていただいた元須田研究室特任助教、現交通安全環境研究所の山口大助様、元須田研の特任助教、現東北大学准教授山邊茂之様、須田研の特任助教杉町敏之様には研究方針の相談など様々なご協力を頂きました。特に、言語に関して様々なご支援を頂きました。誠にありがとうございました。

須田研究室における生活を全般的に支えていただき、励ましの言葉を頂いた秘書足立菜摘様、古市綾様、中里志緒様、堀川千晶様、研究に常にお世話をして頂きました。助教平沢隆之様、元特任研究員安藝雅彦様、特任助教林世彬様、特任助教タン・ジェフリー・トゥ・チュアン様などの方々に本当に支えて頂いたこと実感しています。深く感謝いたします。

そして、同研究室といたしましては、先輩の王文軍様、中川智皓様、洪介仁様、安藤孝幸様、仁科穰様、平山勝彦様、市原隆司様、鈴木啓祐様、辻隆史さま、平山遊喜様、音羽勇哉様、許準会様、金成燁様、坂本正哉様、日高洋祐様、及び中野研究室元博士課程の中村弘毅様には研究への取り組み方など多くのことを学ばせて頂きました。

修士同期の機械工学研究科 亀井潤也様、金秀娟様には、色々なご支援を頂戴し、非常に思い出深い留學生活を過ごさせて頂きました。須田研究室の修士課程学生として卒業のイングカナン タヴァーリー ラタナチョート様、ロジャナアーパー ティーラパット様、小川大策様、水野翔太様、後藤大希様、滝野雄一郎様、黄羿超様、及び修士課程学生として在籍木本健介様、渡辺翔様、荒川大輝様、北川善智様、チョンピタクポン・タグーン様、元受託研究員の萩原純行様、受託研究員の中村竣様は、非常に研究熱心で、実験の協力をはじめ、研究に対するご助言を頂きました。深く感謝いたします。

須田研の皆様のおかげで研究室生活を充実して過ごすことができました。深く感謝いたします。

また、中国北京清華大学の李克強教授、成波教授、中国上海同済大学の呉光強教授には、日本での留學生活における各方面にサポートして頂きました。深く感謝いたします。

中国教育部留學基金委員会(CSC)および中華人民共和国駐日本国大使館教育処から留學生活に関する支援を頂きました。深く感謝いたします。

最後に、東京大学での留學学生生活を支えてくれた家族と全ての友人に心よりお礼申し上げます。特に、私生活において自分の研究と仕事を抱えながらも支えてくれた李耀華様に深く感謝いたします。

李 曙光